

MINISTÉRIO DA EDUCAÇÃO E CULTURA
UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE PESQUISAS HIDRÁULICAS

**PROGNÓSTICO E OTIMIZAÇÃO DO RENDIMENTO DO MILHO
(*Zea Mays L.*) NO RIO GRANDE DO SUL**

SERGIO DANIEL AGUINSKY FERNANDES

COPIADO
ADICIONADO
SERV. DE ATAC.
DE ARQUIVOS

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Recursos Hídricos e Saneamento Ambiental da Universidade Federal do Rio Grande do Sul como requisito parcial para obtenção do título de Mestre em Engenharia.

Porto Alegre, 29 de Abril de 1991

RESUMO

O objetivo do trabalho foi o desenvolvimento de uma metodologia que proporcionasse subsídios básicos necessários ao planejamento e operação de Sistemas de Irrigação para as regiões potencialmente produtivas de milho no estado do Rio Grande do Sul. O propósito de tal metodologia baseou-se na determinação e estabelecimento de relações que quantificassem o rendimento de grãos em função da precipitação ao longo do ciclo da cultura.

Uma análise das estimativas dos parâmetros obtidos para os diversos postos evidenciaram uma possibilidade de regionalização destas estimativas, minimizando a quantidade de informação necessária para obtenção das mesmas. Tais relações foram empregadas para prognóstico de rendimentos e também para estimativa da melhor época de semeadura, exclusivamente do ponto de vista térmico e hídrico, com base em series históricas de precipitação e temperaturas diárias.

Posteriormente foi desenvolvida uma análise de otimização no intuito de obter diretrizes e recomendações para gerenciamento da água em Sistemas de Irrigação com milho, como também para a criação da informação básica necessária à elaboração de análises econômicas.

Summary

The purpose of this study was to develop a methodology which would provide the basic information required in planning and operating irrigation systems for potential maize-producing areas in the state of Rio Grande do Sul, Brazil. This methodology was based on determining and establishing relationships to predict grain yield as a function of precipitation during the maize growth cycle. An analysis of parameter estimates obtained for the different stations showed the possibility of regionalizing these estimates, thus minimizing the amount of information required to obtain them. These relationships were used to allow a prognosis of yields and to estimate the best sowing period, from the standpoint of heat and water, only based on historical daily precipitation and temperature series.

Later, an optimization analysis was performed to establish guidelines and make recommendations for water management in Irrigation Systems for maize and to obtain the basic information required for economic analysis.

APRESENTAÇÃO

Este trabalho foi desenvolvido no Programa de Pós-Graduação em Engenharia de Recursos Hídricos e Saneamento Ambiental do Instituto de Pesquisas Hidráulicas da Universidade Federal do Rio Grande do Sul, sob a orientação do Prof. Raul Dorfman da Universidade Federal do Rio Grande do Sul e co-orientada pelo Prof. Antônio E. L. Lanna.

Agradeço ao Dr. Raul Dorfman pela sugestão do tema e tempo dedicado ao desenvolvimento do trabalho; ao Dr. Antônio E. L. Lanna pelas devidas sugestões, idéias e correções; agradeço em especial o financiamento do custo operacional das fitas que proporcionaram a informação meteorológica.

Quero também demonstrar o meu agradecimento ao Dr. Robin T. Clarke pelas oportunas sugestões e recomendações efetuadas, assim como o tempo dispensado.

Ao Prof. Alejandro Borches Casalas pelo inestimável auxílio matemático prestado.

Agradeço aos colegas Hugo Pasinato, Eduardo Zamanillo, Pedro Molinas e ao casal Jorge Silvestrini e Beatriz Camaño, que também contribuíram com idéias, críticas e sugestões que foram incorporadas ao trabalho.

Ao Instituto de Pesquisas Agronômicas (IPAGRO) meus sinceros agradecimentos pela colaboração prestada, em especial ao Eng. Agr. Vilson R. Sutilli pela valiosa contribuição da sua experiência e conhecimento. Também agradeço ao então Diretor do IPAGRO Dr. Moacir Berlato e ao pesquisador da Seção de Ecologia Eng. Agr. Ronaldo Matzenauer pelo fornecimento de dados.

À CAPES e CNPq minha sincera gratidão pelo auxílio financeiro prestado durante todo o período de Mestrado, sem o qual não teria sido possível a conclusão deste trabalho.

Agradeço à MINITAB INC., em especial à Miss Claudia Hugues, o desinteressado fornecimento de uma cópia completa desse Software poderosíssimo que me acompanhou desde o início até o fim do trabalho.

À minha esposa Martha e aos meus filhos Daniela e Juan Bernardo os meus mais sinceros agradecimentos pela paciência e compreensão.

À Martha, Daniela y Juan Bernardo.

INDICE

1. Introdução e objetivos do trabalho	1
2. Revisão bibliográfica	5
2.1. Introdução	5
2.2. Classificação dos modelos para estimativa de rendimentos	5
2.2.1. Modelos de simulação do crescimento dos cultivos	5
2.2.2. Modelos de análise Clima-cultivo	7
2.2.3. Modelos empíricos	10
2.3. Fatores que afetam o crescimento e o rendimento dos cultivos	14
2.3.1. Soma Térmica	15
2.3.2. O efeito da evapotranspiração no rendimento	18
2.4. A Função de Produção da água	21
2.5. A incerteza nos modelos para previsão de rendimentos	26
2.6. Variabilidade dos rendimentos em função da água	27
2.7. Aplicação dos modelos de previsão de rendimentos na irrigação	30
2.8. Análise crítica	33
3. Metodologia	34
3.1. Introdução	34
3.2. Concepção dos modelos, variáveis envolvidas e fontes de erro	35
3.2.1. Modelo de Regressão Múltipla Linear	36
3.2.2. Modelo de Regressão Múltipla não-linear	37
3.2.3. Cálculo e discretização da Soma Térmica	38
3.2.4. Estimacão da Precipitação Efetiva	40
3.2.5. Constituição das amostras de Rendimentos	42
3.3. Critérios para avaliação dos ajustes	44
3.4. Aplicabilidade dos Modelos	46
3.4.1. Otimização do uso da água em Sistemas de Irrigação	47
3.4.1.1 Extremos da função $Y = \prod_{i=1}^n . X_i^{\lambda_i}$	48

3.4.1.2. Maximização do Modelo LIN	55
3.4.2. Determinação da melhor época de semeadura com base em precipitações e temperaturas.	57
3.4.3. Prognóstico do Rendimento final em função do avanço da Soma Térmica	58
4. Breve descrição agrometeorológica das Estações Experimentais	61
4.1. Estação Experimental de Taquari - RS	62
4.2. Estação Experimental de Veranópolis - RS	63
4.3. Estação Experimental de Santo Augusto - RS	64
4.4. Estação Experimental de São Borja - RS	65
4.5. Estação Experimental de Livramento - RS	66
4.6. Estação Experimental de Passo Fundo - RS	67
4.7. Estação Experimental de Cruz Alta - RS	68
4.8. Estação Experimental de Santa Rosa - RS	69
4.9. Estação Experimental de Sete Lagoas - MG	69
5. Seleção dos parâmetros J e E para estimação da precipitação efetiva	70
6. Ajuste inicial dos modelos LOG/LIN aos dados das estações experimentais	73
6.1. Estação Experimental de Taquari - RS	77
6.1.1. Ajuste do Modelo LIN, Taquari - RS	78
6.1.2. Ajuste do Modelo LOG, Taquari - RS	80
6.1.3. Ajuste do Modelo LOG somente $c/\lambda_1, \lambda_2, \lambda_3$	82
6.2. Estação Experimental de Veranópolis -RS	83
6.2.1. Ajuste do Modelo LIN, Veranópolis - RS	84
6.2.2. Ajuste do Modelo LOG, Veranópolis - RS	85
6.2.3. Ajuste do Modelo LOG3, Veranópolis -RS	87
6.3. Estação Experimental de Santo Augusto - RS	88
6.3.1. Ajuste do Modelo LIN, Santo Augusto - RS	89
6.3.2. Ajuste do Modelo LOG, Santo Augusto - RS	90
6.3.3. Ajuste do Modelo LOG3, Santo Augusto - RS	92
6.4. Estação Experimental de São Borja - RS	93
6.4.1. Ajuste do Modelo LIN, São Borja - RS	94
6.4.2. Ajuste do Modelo LOG, São Borja - RS	96

6.4.3. Ajuste do Modelo LOG3, São Borja - RS	97
6.5. Estação Experimental de Livramento - RS	98
6.5.1. Ajuste do Modelo LIN, Livramento - RS	99
6.5.2. Ajuste do Modelo LOG, Livramento - RS	101
6.5.3. Ajuste do Modelo LOG3, Livramento - RS	102
6.6. Equação Regional para as estações Santo Augusto, Cruz Alta, Santa Rosa e Passo Fundo	103
6.6.1. Ajuste do Modelo LIN, Regional - RS	104
6.6.2. Ajuste do Modelo LOG, Regional - RS	106
6.6.3. Ajuste do Modelo LOG3, Regional - RS	108
6.7. Estação experimental da Embrapa, Sete Lagoas - MG	109
6.7.1. Ajuste do Modelo LIN, Sete Lagoas - MG	110
6.7.2. Ajuste do Modelo LOG, Sete Lagoas -MG	111
7. Verificação dos Modelos LOG/LIN	113
7.1. Modelo LIN	114
7.1.1. Calibração do Modelo LIN. Amostra 1.	114
7.1.2. Verificação do Modelo LIN. Amostra 2	115
7.1.3. Comentários do ajuste e da verificação. Modelo LIN	115
7.2. Modelo LOG	116
7.2.1. Ajuste do Modelo LOG. Amostra 1.	116
7.2.2. Verificação do Modelo LOG. Amostra 2.	117
7.2.3. Comentários do ajuste e da verificação. Modelo LOG	117
8. Relação entre λ_i e ETP_i	118
8.1. Método do coeficiente C_1 para previsão de rendimentos.	124
8.2. Aplicação do Método do coeficiente C_1 para previsão de rendimentos	125
9. Análise iterativa das estimativas de λ_i	131
9.1. Algoritmo Iterativo para análise de convergência de λ_i	131
9.2. Resultados do algoritmo iterativo com 4 variáveis (X_1, X_2, X_3 e X_4)	133
9.2.1. Resultados da 1ª iteração	133
9.2.2. Resultados da 30ª iteração	134
9.3. Verificação das estimativas λ_i obtidas na 30ª iteração	136

9.3.1. Ajuste de C_1 . Amostra 2.	136
9.4. Ajuste de C_1 com as Amostras 1 e 2	138
9.4.1. Comentários	139
9.5. Resultados do algoritmo iterativo com 3 variáveis (X_1 , X_2 e X_3)	140
9.5.1. Resultados da 1ª iteração	140
9.5.2. Resultados da 30ª iteração	141
10. Equações de rendimentos máximos e distribuição ótima da água.	143
10.1. Taquari - RS	143
10.1.1. Modelo LOG	143
10.1.2. Modelo LIN	143
10.1.3. Modelo ITER	143
10.1.4. Comentários	146
10.2. Veranópolis - RS	147
10.2.1. Modelo LOG	147
10.2.2. Modelo LIN	148
10.2.3. Modelo ITER	148
10.2.4. Comentários	150
10.3. Santo Augusto - RS	151
10.3.1. Modelo LOG	151
10.3.2. Modelo LIN	151
10.3.3. Modelo ITER	153
10.3.4. Comentários	153
10.4. São Borja - RS	155
10.4.1. Modelo LOG	155
10.4.2. Modelo LIN	155
10.4.3. Modelo ITER	156
10.4.4. Comentários	157
10.5. Livramento - RS	158
10.5.1. Modelo LOG	158
10.5.2. Modelo LIN	160
10.5.3. Modelo ITER	160
10.5.4. Comentários	161
10.6. Regional - RS (Sto Augusto, Cruz Alta, Sta Rosa e Passo Fundo)	162

10.6.1. Modelo LOG	162
10.6.2. Modelo LIN	162
10.6.3. Modelo ITER	163
10.6.4. Comentários	165
10.7. Sete Lagoas - RS	166
10.7.1. Modelo LOG	166
10.7.2. Modelo LIN	166
10.7.3. Modelo ITER	168
10.7.4. Comentários e verificação das equações Y_{max} .	168
11. Estimação da melhor época de semeadura com base em séries em base em séries históricas de precipitação e temperatura	170
11.1. Extensão da série de temperaturas	171
11.1.1. Taquari - RS	172
11.1.2. São Borja - RS	173
11.1.3. Veranópolis - RS	174
11.1.4. Santo Augusto - RS	175
11.2. Rendimentos médios vs Data de semeadura	176
11.2.1. Taquari - RS	177
11.2.2. São Borja - RS	179
11.2.3. Veranópolis - RS	181
11.2.4. Santo Augusto - RS	183
12. Prognóstico do rendimento final em função do avanço da soma térmica	185
12.1. Prognósticos para Taquari - RS	187
12.2. Prognósticos para São Borja - RS	189
12.3. Prognósticos para Veranópolis - RS	190
12.4. Prognósticos para Santo Augusto - RS	191
12.5. Prognósticos para Cruz Alta - RS	193
12.6. Prognósticos para Passo Fundo - RS	194
12.7. Prognósticos para Santa Rosa - RS	194
13. Conclusões e recomendações	196
14. Referências Bibliográficas	198

INTRODUÇÃO

O milho (*Zea mays* L.) é plantado praticamente em todo o estado do Rio Grande do Sul, destacando-se pelas suas amplas possibilidades de utilização, tanto para consumo humano como animal. É a segunda cultura do Estado em produção e a terceira em área cultivada, predominando nas pequenas propriedades, onde apresenta baixas produtividades.

Estudos recentes (Simas, 1988) fizeram projeções de oferta e demanda até o ano 2000 com objetivo de avaliar a situação do abastecimento interno deste grão. Tais estudos indicam que a questão do abastecimento de milho poderá estar seriamente comprometida a curto prazo na falta de medidas que venham a regularizar e homogeneizar os níveis de oferta e demanda, pois a taxa de aumento da área plantada não tem acompanhado a evolução da taxa de consumo ou demanda do milho em grão. Em consequência, além do incentivo ao aumento da área plantada é fundamental a elevação dos níveis atuais de produtividade através do uso de técnicas mais avançadas de exploração agrícola, como por exemplo a utilização de cultivares mais produtivas e resistentes a pragas e doenças; através de um manejo do solo mais racional e, de uma forma geral, otimizando todas as variáveis e/ou insumos envolvidos na produção.

A água, seja ela proveniente da natureza e/ou de forma artificial, exerce papel vital dentro de qualquer esquema de produção agrícola, merecendo especial atenção.

A grande dúvida ainda existente no estado do Rio Grande do Sul é a viabilidade econômica e financeira de Projetos de Irrigação, sejam estes de natureza privada ou pública. A essência de qualquer análise econômica é a quantificação dos custos e benefícios envolvidos com o Projeto hipotético. Particularmente, quando se trata de um Projeto de Irrigação, a variável mais importante é a água. O problema então consiste na quantificação do efeito deste recurso na produção; e para isto é preciso basear-se em relações que descrevem o fenômeno da produção em função do suprimento hídrico. O dimensionamento das estruturas do Projeto (em consequência, custos) é baseado em tal suprimento, ao qual está associado uma certa vazão. Uma vez conhecidos os custos

e benefícios envolvidos em função do suprimento hídrico será possível tomar uma decisão para escolha da melhor alternativa a ser implementada.

Por outro lado, na ausência de Sistemas de Irrigação, onde as lavouras de milho estão sujeitas apenas à ocorrência de precipitação, também é importante a quantificação do efeito das chuvas no rendimento final, como também especular a respeito deste a medida que a cultura vai se desenvolvendo. Este fato poderia ser justificado pela relevância econômica que apresenta o conhecimento antecipado de um valor esperado de produção.

Uma ferramenta já comprovadamente eficaz, com uso criterioso, na solução de problemas constituídos ou representados por um sistema que considera interações entre fatores ambientais e fenômenos físicos, químicos e biológicos, são os modelos matemáticos.

No presente trabalho adotou-se este tipo de abordagem, considerando um sistema integrado pelo solo, clima, água e planta. As variáveis climáticas levadas em consideração no modelo foram precipitações e temperaturas máximas e mínimas diárias. O fenômeno estudado foi o da resposta do milho em grão ao efeito das variáveis citadas em diversos estádios de crescimento compreendidos entre a semeadura e a maturação fisiológica. Uma acumulação diária de unidades térmicas simulou tais estágios de crescimento. O estudo abrangeu as localidades de Livramento, São Borja, Santo Augusto, Veranópolis, Taquari, Cruz Alta, Passo Fundo e Santa Rosa no Rio Grande do Sul, e Sete Lagoas no estado de Minas Gerais.

OBJETIVOS E RELEVÂNCIA DO TRABALHO

A meta de Projetos e Sistemas de Irrigação é providenciar água aos cultivos para evitar ou minimizar a ocorrência de déficits hídricos que reduzirão os rendimentos a níveis indesejados. A questão que aqui se levanta é em que proporção as capacidades de sistemas de distribuição e aplicação de água devem satisfazer as necessidades hídricas dos cultivos. Para lidar realisticamente com os fatores envolvidos na capacidade de sistemas de distribuição e aplicação de água, é preciso a existência de informações econômicas a respeito da resposta que as culturas apresentam em função do suprimento hídrico.

As culturas diferem na tolerância ao stress hídrico e, portanto, na tolerância à depleção da umidade do solo. Os requerimentos hídricos e a resposta das culturas à irrigação e/ou precipitação variam não somente com a espécie vegetal, mas também com o estágio fenológico, condições ambientais e com aspectos associados ao gerenciamento da água, práticas culturais, época de semeadura, etc.

O complexo sistema dinâmico 'Solo-Água-Planta-Atmosfera' têm tornado difícil o trabalho de especialistas ligados ao planejamento e alocação de Recursos Hídricos na obtenção de informações úteis a seus propósitos. Esta situação obriga a um desenvolvimento de pesquisas neste tópico para que os resultados experimentais possam prontamente serem utilizados.

A capacidade de Sistemas de Irrigação, ou a taxa contínua máxima de vazão para suprir às culturas é um parâmetro importante no Planejamento de Sistemas de Irrigação. A aptidão de um Sistema de Irrigação para satisfazer os requerimentos hídricos das culturas, onde a precipitação sazonal é insuficiente para sustentar a produção, depende diretamente da capacidade de tal Sistema.

Atualmente o Brasil, e em particular o estado do Rio Grande do Sul, carece de informações precisas a respeito da resposta das culturas ao meio-ambiente e, em consequência, ao Planejamento de Sistemas de Irrigação está associado um certo grau de incerteza.

OBJETIVOS DO TRABALHO

1. Desenvolver uma metodologia que requeira a mínima informação disponível para quantificação e prognóstico do rendimento de grãos de milho.
2. Aplicação desta metodologia para sugestão empírica das lâminas de irrigação, com o objetivo de maximizar os rendimentos dada uma disponibilidade hídrica mínima.
3. Complementar informações básicas necessárias à análises econômicas e financeiras envolvendo Projetos de Irrigação, seja para dimensionamento como para operação de Sistemas.

2. REVISÃO BIBLIOGRÁFICA

2.1 Introdução

Estudos e pesquisas no campo da produção vegetal em função de variáveis climáticas vêm sendo realizados pelo menos a partir do século XX (Briggs e Shants (1917), Miller e Dulley (1923), Kiesselbach (1929) e Dillman (1931), citados por Stewart e Hagan (1973), entre outros).

As Funções de Produção, ou ainda chamadas também Modelos de previsão ou quantificação dos rendimentos de uma cultura, são essencialmente conjuntos de expressões matemáticas, físicas ou combinações destas, e todas estas variações têm um objetivo em comum: quantificar ou estimar a produção de uma cultura em função de variáveis agrometeorológicas. Estas expressões, Funções ou Modelos podem ser classificadas de várias formas, dada as diferentes abordagens que têm sido empregadas para avaliar o processo da produção vegetal. Neste capítulo se apresenta concisamente uma classificação destas abordagens, bem como se discutem as variáveis consideradas relevantes em tal processo apresentando-se alguns trabalhos que contribuíram substancialmente ao desenvolvimento desta Ciência.

A classificação a seguir de modelos clima-planta utilizados para previsão de rendimentos, obedece à classificação e descrição sugerida por Frère et al. (1980), citando a Baier (1979).

2.2 Classificação dos Modelos para estimativa de rendimentos

2.2.1 Modelos de simulação do crescimento dos cultivos

Os modelos de simulação do crescimento dos cultivos

podem ser definidos como uma representação simplificada dos mecanismos físicos, químicos e biológicos implícitos no processo de crescimento das plantas. Se os processos básicos dos cultivos (produção e distribuição das relações entre matéria seca e água) foram corretamente compreendidos e formulados, é possível simular a resposta global da planta às condições do meio-ambiente. Em consequência, não é necessário fazer distinção entre as diversas regiões climáticas, uma vez que o modelo de simulação incorpora de forma intrínseca os fatores limitativos do crescimento. Nos climas úmidos, com baixos níveis de radiação e temperatura, o modelo apresentará a resposta máxima dos rendimentos aos aumentos de radiação total recebida. Em climas áridos e quentes, estes modelos proporcionarão uma resposta máxima dos rendimentos à soma total das precipitações e sua distribuição temporal.

Nestes modelos de simulação se podem introduzir diversos tipos de intervalos de tempo; por exemplo, dado o ciclo cotidiano dos processos vegetativos, os intervalos horários serão os mais adequados supondo que, neste caso, a porcentagem calculada da evolução de tais processos não mudará significativamente no transcurso de uma hora. Desta forma, é possível avaliar processos específicos como a fotossíntese, transpiração e respiração durante uma hora, e logo após acumular as frações horárias durante o dia, e as frações diárias ao longo da estação de crescimento, a fim de obter a produção sazonal total de matéria seca e/ou em grão.

Na atualidade, os modelos de simulação devem ser vistos mais como um guia para pesquisar o comportamento dos sistemas biológicos do que como uma solução final. A simulação pode resultar útil se o modelo leva em conta os fenômenos de maior relevância e se não foram formuladas hipóteses incorretas. Esta abordagem permite penetrar profundamente nas relações solo-água-planta-atmosfera, explica porque alguns fatores são mais importantes que outros para fins de produção, sugere fatores que provavelmente tenham relevância estatística e propicia as bases para novos experimentos sobre processos que parecem ser mais importantes, mas que ainda não foram totalmente compreendidos. Por esta razão, o enfoque físico não substitui o

enfoque empírico, mas o complementa.

Um exemplo típico de modelo dinâmico de crescimento vegetal é o Modelo TROIKA, de Lambert e Reicovsky (1984), o qual simula o fluxo da água desde o solo, passando pelas raízes, caule, folhas até os estômatos em contato com a atmosfera. O armazenamento de água se considera presente nas folhas, raízes e anéis cilíndricos de solo imaginários coaxiais com as raízes, constituindo uma variável de estado. Um dos objetivos deste modelo é a determinação do potencial da água nas folhas.

Outra abordagem semelhante foi proposta por Tscheschke e Gilley (1979), desenvolvendo o Modelo CORNGRO, um modelo computacional que simula os processos ambientais e fisiológicos presentes no crescimento do milho e que, portanto, leva em conta as variáveis envolvidas no processo físico (fotossíntese, radiação, troca de gases, etc.) e cujo objetivo é previsão de rendimentos, além de prever também o aparecimento de estágios fenológicos e o crescimento foliar.

2.2.2 Modelos de análise Clima-planta

Os modelos de análise Clima-cultivo podem ser definidos como o produto de dois ou mais fatores, onde cada um representa a relação funcional simplificada entre uma resposta particular da planta (rendimento, por exemplo) e as flutuações de determinadas variáveis em diferentes subperíodos do desenvolvimento das plantas. Os efeitos globais, tal como aparecem expressos pelos valores numéricos dos fatores, modificam cada um dos outros mas não são cumulativos, como no caso de uma equação de regressão linear múltipla. Esta classe de modelos dispensa formulação de hipóteses sobre os fenômenos naturais que governam o crescimento das plantas e do meio-ambiente. Desta forma, os requisitos relacionados com os dados de entrada não são tão rigorosos como na abordagem descrita anteriormente, mas a informação de saída depende muito destes dados, e é menos detalhada que no caso de modelos físicos. Entretanto, estes

modelos constituem um instrumento prático de pesquisa para analisar as respostas dos cultivos às variações climáticas quando se dispõe de informação reduzida.

Em tais modelos se utilizam procedimentos estatísticos para avaliar os parâmetros que traduzem o significado da correspondência dos cultivos com os dados climatológicos ou agrometeorológicos. Um dia é um intervalo de tempo conveniente, mas na prática se podem usar períodos mais longos desde que as características da resposta dos cultivos não mudem de forma substancial durante o intervalo escolhido com relação às variáveis consideradas no processo.

Um exemplo desta abordagem é o modelo proposto por Baier (1973), citado por Frère e Popov(1980), onde se analisam as contribuições cotidianas ao rendimento final, para qualquer cultivo, de até três variáveis agrometeorológicas (radiação, temperatura e umidade do solo), se bem que se consideram outras respostas dos cultivos como crescimento vegetativo e desenvolvimento reprodutivo.

Outro exemplo desta abordagem é a metodologia desenvolvida por Frère e Popov (1980), baseada num balanço hídrico cumulativo registrado ao longo da estação de crescimento de uma cultura, discretizando o período emergência-maturação em intervalos de dez dias. Através deste balanço hídrico é calculado um índice I que assinala, em porcentagem, a amplitude com que são satisfeitas as demandas hídricas da cultura. Este valor pode ser interpretado também como um indicador do estado hídrico da planta. Inicialmente I vale 100, e permanece em 100 até que num dado decêndio é detectado um excesso ou déficit hídrico que penalizará o valor 100 em função da magnitude do excesso ou déficit. Assim, o valor do índice I será 100 caso não tenha ocorrido déficits e/ou excessos, e será menor que 100 caso contrário¹.

Esta metodologia foi aplicada em diversas regiões para

1

O critério de redução do índice I está muito bem exposto em 'Pronóstico de Cosechas basado en datos Agrometeorológicos'. (Frère e Popov, 1980).

várias culturas; a título de exemplo se apresentam os resultados obtidos pelos autores, utilizando esta técnica, para o milho em Togo, África.

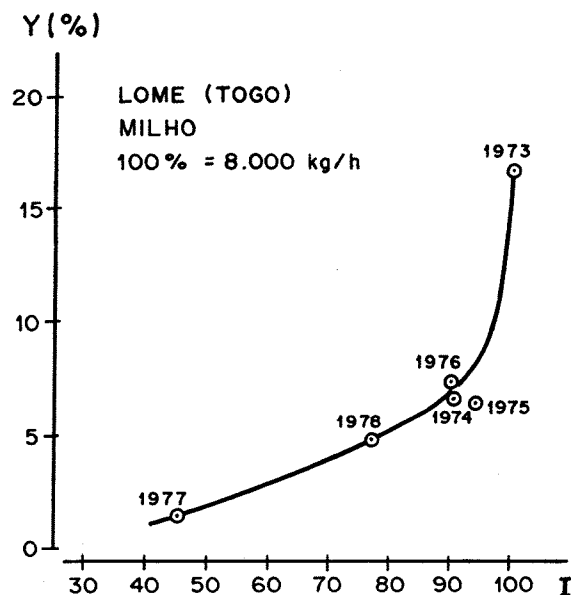


FIGURA 2.1 Rendimento do milho em grão (Y) vs índice I em Togo (África), segundo Frère e Popov (1980).

Uma leve crítica a este método, e talvez esta seja a razão pela qual os autores recomendam o mesmo como uma avaliação qualitativa e não quantitativa, é a respeito da sua precisão na previsão de rendimentos na faixa de valores entre 90 e 100 do índice I. De acordo com a figura 2.1, uma pequena variação deste índice implica num incremento elevado de rendimentos.

Os autores concluem (dos resultados) que não há correlação evidente entre a precipitação total com os rendimentos observados, e que é indispensável considerar a disponibilidade hídrica em cada período.

2.2.3 Modelos empíricos

Na abordagem empírica, uma ou mais variáveis que representam as condições do clima, solo ou uma tendência, se colocam em relação com as respostas da cultura. As variáveis independentes são frequentemente a temperatura, precipitação ou variáveis derivadas destas, como por exemplo um índice da deficiência hídrica ou stress hídrico. Os parâmetros destas equações se obtém necessariamente de forma empírica, utilizando técnicas de estatística, como na análise de regressão. Este tipo de abordagem não conduz facilmente a um esclarecimento das relações entre causa e efeito, mas constitui um enfoque sumamente prático para avaliação e previsão de rendimentos. Nestes modelos, os parâmetros e a validade dos resultados dependem em grande medida da concepção do modelo como também da representatividade dos dados de entrada.

Se as condições do meio-ambiente e as técnicas de cultivo são suficientemente homogêneas em toda a superfície representada pela amostra, ou se o solo e a posição geográfica foram adequadamente ponderados nas equações, é de se esperar que os parâmetros e os cálculos terão um significado prático para fins de avaliação das condições do cultivo ou previsão de rendimentos da localidade específica em questão.

Um exemplo de aplicação destes modelos é o trabalho realizado por Baker e Horrocks (1973) em Missouri, Indiana e Michigan; eles utilizaram um modelo de regressão linear múltipla, sendo o rendimento a variável dependente (Y) contra 20 variáveis climáticas. Entre as variáveis independentes (X_i) se destacam por sua relevância precipitações mensais, temperaturas diárias médias mensais, radiação solar acumulada, soma térmica, etc.. Um fato interessante é que consideraram a precipitação bruta como precipitação efetiva, sem correções para separação do escoamento superficial. Uma crítica a este trabalho é a respeito da sua validade, já que o número de eventos utilizados para calibração do modelo foi de 27 (Missouri) e 21 (Indiana e Michigan), sendo que para o local que apresentou menor número de variáveis

independentes (Michigan), este número era de 15.

Analisando os resultados obtidos neste trabalho (Tabela 2.1) observa-se uma extrema variabilidade na grandeza dos coeficientes para uma mesma variável nos três locais, como também ausência de significado físico dos parâmetros; além disso, os valores dos termos constantes da regressão são muito elevados, em módulo, comparados com a grandeza dos rendimentos, que variaram entre 43.3 e 120.7 bushels/acre. Uma outra crítica é a existência de combinações lineares entre as variáveis independentes. Uma delas, por exemplo, é a combinação existente entre as precipitações mensais (X1, X3, X4, X15) e a precipitação acumulada X16, sendo que $X16 = X1 + X3 + X4 + X15$.

Lorber e Haith (1981) desenvolveram um modelo de previsão de rendimentos de milho no qual consideraram as variedades, época de semeadura, soma térmica, evapotranspiração e ocorrência de geadas, estimando a evapotranspiração através de um balanço hídrico diário.

Aparentemente, o modelo de regressão múltipla utilizado excluiu o termo constante, sendo que as variáveis independentes são em número de três. O ciclo do milho foi dividido, portanto, em três períodos ou estágios, sendo que o primeiro englobava desde a emergência até o início do florescimento, o segundo período incluía o florescimento e a maturação leitosa do grão, e o terceiro a maturação fisiológica.

A equação que utilizaram foi a proposta por Jensen (1968), citado pelos autores, e tem a seguinte forma:

$$\frac{Y_S}{Y_O} = \prod_{i=1}^n \left[\frac{ETR_i}{ETP_i} \right]^{\lambda_i} \quad (2.1)$$

onde :

Y_S = Rendimento estimado (Kg/ha)

Y_O = Rendimento potencial (Kg/ha)

ETR_i = Evapotranspiração real no período i

ETP_i = Evapotranspiração potencial do milho no período i

λ_i = Parâmetro correspondente ao período i

$i = 1, \dots, 3$

Tabela 2.1. Variáveis e parâmetros dos modelos segundo Baker e Horrocks (1973), para Missouri, Indiana e Michigan (USA)².

Coefficiente (b _i)	Variável indep. (X _i)	Missouri (b _i)	Indiana (b _i)	Michigan (b _i)
b1	precipit. Junho, cm	3.39	53.50	19.00
b2	temperat. Junho, C	5.65	2.37	--
b3	precipit. Julho, cm	25.30	43.44	-16.43
b4	precip. Agosto, cm	-3.08	2.66	-7.61
b5	precip. anteced, cm	-2.53	-0.39	2.98
b6	crescim. teórico, gm	-121.40	-127.00	-21.27
b7	crescim. diário, gm	917.75	-3615.82	-613.37
b8	temper. combinadas	1.55	0.05	--
b9	fotossíntese, gm	121.28	--	--
b10	dias fisiol., C	-4.80	-3.87	1.61
b11	fotoss. acumul., gm	-67111.80	-89322.20	-10574.42
b12	soma térmica, C	0.29	1.13	0.21
b13	peso seco teórico, gm	1.47	1.50	--
b14	precip. combinada, cm	-1.58	0.01	-0.06
b15	precip. Julho, sq cm	-4.56	-6.06	1.56
b16	prec. diária acum., cm	0.23	-0.40	0.23
b17	data plantio, dias	-1.13	-5.92	0.23
b18	dias de stress	0.92	--	--
b19	radiação, lg	0.06	1.05	0.28
b20	temper. Junho, sq C	--	9.03	-2.23
Termo constante (C)		-5288.5	1873.5	3200.1

O rendimento potencial Y_0 é função da data de semeadura e da variedade:

$$Y_0 = H.Y_f - d.P \quad (2.2)$$

onde:

H = Fator adimensional associado à variedade

Y_f = Rendimento potencial do híbrido específ. (Kg/ha)

d = Número de dias entre a data de plantio e a data preferencial (dias)

P = Penalização diária para plantio fora da época

Usaram o modelo de regressão múltipla $Y = \sum_{i=1}^n b_i.X_i + C$

preferencial (Kg/ha/dia)

Outro efeito climático incorporado em tal modelo foram as geadas, onde o dano ou prejuízo estimado devido às geadas foi calculado pela expressão:

$$F = \min [6.5 \cdot 10^{-6} \cdot R^2 ; 0.4] \quad (2.3)$$

onde:

F = Fator adimensional que representa uma redução no rendimento final

R = Soma térmica remanescente até a maturação fisiológica quando a temperatura do ar atingiu valores inferiores a -2 °C.

A máxima perda foi estabelecida em 40%. Juntando as equações (2.1), (2.2) e (2.3):

$$Y_o = (H \cdot Y_f - d \cdot P) \prod_{i=1}^n \left[\frac{ETR_i}{ETP_i} \right]^{\lambda_i} (1-F) \quad (2.4)$$

Para obtenção dos valores de λ_i foi utilizado o critério dos mínimos quadrados para ajuste, sendo que o número de eventos introduzidos na calibração era de nove. Para validar o modelo os autores apresentam quatro eventos, onde se observa pouca diferença entre os valores observados e calculados (3 a 8%).

Neste trabalho se pode observar que nos eventos não ocorreram situações de stress hídrico acentuado (rendimento mínimo observado = 5254 Kg/ha) e, portanto, poderão haver limitações no uso destes parâmetros em circunstâncias não representadas pelos eventos incluídos na calibração. Entretanto, os autores usaram os mesmos parâmetros para simular rendimentos em localidades próximas ao local de ajuste, com rendimentos observados pouco inferiores a 5254 Kg/ha para validação do modelo.

Eles não acharam uma forma óbvia de generalizar os valores dos λ_i e, portanto, estes deveriam ser obtidos por calibração. Uma razão provável é que eles ajustaram uma regressão sem termo constante, e isto pode mascarar o significado físico dos expoentes λ_i . Como se verá mais adiante, o autor atribui significados físicos aos parâmetros do modelo, sendo fundamental a utilização de uma equação de regressão com termo constante.

Geralmente, os modelos empíricos se caracterizam pela ausência de significado físico dos parâmetros envolvidos, entretanto, o trabalho a ser desenvolvido se pode enquadrar sob este prisma, uma vez que os parâmetros são obtidos através de procedimentos ou técnicas estatísticas, ainda que estes tenham um significado físico relevante e possam ser estimados, em segunda instância, por outras formas, como se verá mais adiante (Itens 8,9).

2.3 Fatores que afetam o crescimento e o rendimento dos cultivos

Pode-se afirmar que todos os fatores que de uma ou outra forma afetam a evapotranspiração de uma cultura afetarão também o seu rendimento. O desenvolvimento de processos quaisquer dentro da planta são também fortemente influenciados pelo meio-ambiente. As condições meteorológicas governam os processos metabólicos das plantas, tais como abertura dos estômatos e difusão de dióxido de carbono dentro das folhas. As plantas somente armazenam uma pequena quantidade de água que precisam para transpiração; assim, o reservatório de armazenamento fornecido pelo solo e sua recarga periódica são essenciais na manutenção de um crescimento contínuo de acordo com Tscheschke e Gilley (1979).

A água influencia direta ou indiretamente a maioria dos fatores envolvidos na produção. A água no solo é essencial para uma sementeira, germinação e emergência bem-sucedidas, extensão radicular, absorção de nutrientes minerais e processos químicos e microbiológicos dentro do solo que resultam da decomposição de resíduos vegetais e mineralização de nutrientes essenciais, e o fluxo de água através da rizosfera é essencial para a manutenção de um balanço de sais favorável (Hood et al., 1987).

As propriedades do solo afetam a extensão radicular, disponibilidade e absorção de água e nutrientes minerais e a aeração, essencial para a respiração das raízes, entre outros fatores (Tscheschke e Gilley, 1979).

As variáveis meteorológicas governam o crescimento das plantas e o aparecimento de fases fenológicas diferenciadas, que são responsáveis pela variabilidade no consumo de água em todo seu ciclo. As temperaturas do ar e do solo afetam a taxa de absorção de água pelas raízes, bem como o fluxo através das plantas e a velocidade das reações bioquímicas que ocorrem na

soma térmica constituem as variáveis climáticas mais importantes que controlam o aparecimento de fases fenológicas na maioria das culturas.

2.3.1 Soma Térmica

A variabilidade na demanda potencial de água de uma cultura, desde a sementeira até a maturação, em condições agroclimáticas específicas, é explicada por sua fenologia, ou seja, o consumo de água varia de acordo com o estágio fenológico em que a planta se encontra. Sabe-se de longa data que no período de florescimento, polinização e enchimento dos grãos a demanda é maior em relação a outros estádios fenológicos. A questão é associar a uma cultura determinada, uma variável climática que controle ou pelo menos estime razoavelmente a ocorrência dos diversos estádios fenológicos, e desta forma estar-se-á também estimando qualitativamente a demanda de água.

Como já foi comentado anteriormente, as variáveis climáticas que possuem efeito pronunciado no aparecimento de fases fenológicas são: a radiação, o fotoperíodo e a temperatura. Para o caso do milho em particular, a soma térmica tem apresentado ótimos resultados para estimativa da ocorrência de estádios fenológicos.

A soma térmica consiste numa contabilização temporal das unidades de calor, em graus centígrados, necessárias para a cultura atingir, em média, um estágio fenológico específico. Neste trabalho a soma térmica é considerada como sendo a quantidade de unidades térmicas requeridas para a cultura do milho atingir a maturação fisiológica.

A razão de se trabalhar com unidades térmicas e não com dias do calendário está na precisão obtida. Comumente a ocorrência da maturação fisiológica é medida registrando o número de dias desde a sementeira ou emergência até a maturação. Dada a variabilidade climática, este método deixa a desejar, pois numa mesma localidade uma cultivar de milho pode alcançar a maturação em 120 dias e em outro ano pode levar 140 dias, dependendo da altitude, latitude e data de sementeira.

Um trabalho clássico a respeito foi elaborado por Gilmore e Rogers (1958), no qual chegam à conclusão que a soma térmica necessária para alcançar a maturação do milho permanece relativamente constante, apesar de que o número de dias do calendário variem amplamente.

Apesar de que o elemento meteorológico temperatura não determina completamente a maturação, e de que a temperatura pode refletir o efeito de outros fatores climáticos, os autores acreditam que este método é justificado pela superioridade apresentada com relação à simples contagem do número de dias para se alcançar a maturação.

Tem sido usado freqüentemente como medida das unidades térmicas requeridas uma soma direta das unidades de calor, subtraindo uma temperatura-base (abaixo da qual se assume que o crescimento da planta se paraliza) da temperatura média diária do ar. Este método é conhecido como Método Residual Direto, e as unidades térmicas se calculam pela fórmula:

$$UT = \frac{(T_{max} + T_{min})}{2} - T_b \quad (2.5)$$

onde:

UT = unidades térmicas (°C)

Tmax = Temperatura máxima do ar (°C)

Tmin = Temperatura mínima do ar (°C)

Tb = Temperatura-base (°C)

UT representa as unidades de calor que contribuem para o crescimento da planta. Para o caso do milho sabe-se que o limite superior ótimo de crescimento é o valor de 30 °C , e o valor da temperatura-base (Tb) é 10 °C ; assim, assume-se que a planta não se desenvolve com temperaturas fora do intervalo [10-30] °C . De acordo com tal intervalo, o Método Residual Direto não avalia as unidades térmicas efetivas que realmente contribuem ao crescimento do milho quando Tmax e Tmin ocorrem fora deste intervalo. Por exemplo, se num dia Tmax = 20 °C e Tmin = 0 °C , o valor da unidade térmica (UT) é nulo; entretanto, houve um aproveitamento térmico por parte da planta já que ocorreram temperaturas superiores a 10 °C durante o dia, evidenciado pelo valor de Tmax. Para evitar este problema, ou pelo menos diminuir este erro, Gilmore e Rogers (1958) propuseram um método que corrige este efeito através da consideração de temperaturas que ocorrem somente no intervalo [10-30] °C . Este segundo método é conhecido como Método das Temperaturas Máximas e Mínimas corrigidas, e as unidades térmicas se calculam pela expressão:

$$UT = \frac{[(10+t1)+(Tmax-t2)]}{2} - Tb \quad (2.6)$$

onde:

$$t1 = \begin{cases} T_{min} - 10, & \text{se } T_{min} > 10 \text{ (}^\circ\text{C)} \\ 0, & \text{se } T_{min} \leq 10 \text{ (}^\circ\text{C)} \end{cases}$$

$$t2 = \begin{cases} T_{max} - 30, & \text{se } T_{max} > 30 \text{ (}^\circ\text{C)} \\ 0, & \text{se } T_{max} \leq 30 \text{ (}^\circ\text{C)} \end{cases}$$

Os autores compararam estes dois métodos, entre outros, para o caso do milho, e obtiveram coeficientes de variação de 6.08 % para o Método Residual Direto e 1.63 % para o segundo método, tomando como temperatura-base o valor de 10 °C .

No Rio Grande do Sul, Berlato et al.(1974) apresentam uma comparação de métodos de cálculo da soma térmica para estimativa do espigamento do milho, concluindo que o Método das Temperaturas Máximas e Mínimas corrigidas é o mais consistente pela menor variabilidade apresentada com relação aos outros métodos.

Chielle (1977) comparou dois métodos para determinação da soma térmica de cultivares precoces e tardias de milho concluindo que existe, em média, uma diferença de 9 % nos requerimentos térmicos entre as variedades precoces e tardias.

Maluf et al.(1980) desenvolveram um trabalho semelhante para várias localidades no Rio Grande do Sul, no qual apresentam o Método Residual Direto com menor variabilidade para os propósitos do trabalho.

Chielle e Sutili (1980) testaram vários métodos para avaliação dos requerimentos térmicos com o objetivo de classificar e recomendar variedades híbridas de milho. Neste trabalho, o método que apresentou melhores resultados foi o Método das Temperaturas Máximas e Mínimas corrigidas.

Chielle (1981) avaliou os requerimentos térmicos para vinte cultivares de milho precoces até o florescimento, pelos dois métodos já apresentados, obtendo um coeficiente de variação da soma térmica de 5 %.

Obviamente, o Método das Temperaturas Máximas e Mínimas corrigidas é mais correto que o Método Residual Direto porque leva em conta somente as temperaturas que teoricamente contribuem a um crescimento efetivo da planta, e o seu uso se justifica no caso de climas com variações bruscas das

temperaturas diárias, que é o caso de algumas regiões do Rio Grande do Sul, onde se verificam temperaturas acima de 30 °C e abaixo de 10 °C , principalmente na região do Planalto.

2.3.2 O efeito da evapotranspiração no rendimento

Segundo Stewart e Hagan (1973), é necessário diferenciar uma previsão de rendimentos associada a um programa de irrigação de uma previsão de rendimentos associada com um dado nível de ET. Uma programação de irrigação que visa maximizar os rendimentos não exige necessariamente uma previsão do rendimento máximo, mas exige que a redução do rendimento seja mínima. Este objetivo será alcançado se a ET resultante no período sazonal é maximizada ou se os déficits de ET são minimizados e bem distribuídos nas fases de crescimento da cultura. Os experimentos realizados em Davis, na Califórnia (USA), conduzidos por estes autores, demonstram que existe uma real possibilidade de prever ou estimar rendimentos através da ET. A figura 2.2 mostra os resultados de um experimento realizado com milho (*Zea mayz* L.), onde aparecem os pontos observados e uma função linear obtida por




FIGURA 2.2 Rendimento de grãos (15,5 % umidade) vs evapotranspiração para o milho em Davis (USA), segundo Stewart e Hagan (1973).

regressão simples; cada observação corresponde a um tratamento; os quatro pontos superiores do gráfico resultaram de aplicações semanais de uma lâmina de 5 cm, para um total de 46 cm/ciclo. Os quatro pontos inferiores representam tratamentos que não foram irrigados após o plantio, e o consumo de água do milho ficou limitado à ocorrência de precipitação e ao armazenamento de água do solo. Os pontos intermediários representam níveis médios de irrigação entre 15 e 30 cm em toda a estação de crescimento.

A forte linearidade entre Y e ET leva a crer que existe uma relação fundamental entre estas variáveis. De acordo com Stewart e Hagan (1973), este fato merece uma análise mais profunda devido às importantes implicâncias na previsão de rendimentos.

Stewart e Hagan (1973) citam muitos pesquisadores - Briggs e Shants (1917), Miller e Dulley (1923), Kiesselbach (1929) e Dillman (1931), entre muitos outros - que cultivaram plantas em solos férteis em grandes lisímetros de drenagem, medindo a transpiração (T) e a produção total de matéria seca (G), e através dos resultados concluíram que G é linearmente proporcional à T . Portanto, G vs T é da mesma natureza que Y vs ET , se G e Y podem ser considerados sinônimos.

Para quantificar os déficits de ET e seus efeitos no rendimento, deve-se começar no ponto onde este efeito é nulo; este ponto pode ser chamado de $Y_{max}-ET_{max}$; valores mais altos de ET podem ocorrer quando por exemplo a componente evaporação (E) é aumentada por excessivas irrigações antes que a cultura se estabeleça totalmente. De acordo com esta definição, Y_{max} não aumentará com o acréscimo de ET além deste ponto, mas Y permanecerá como Y_{max} ou diminuirá. Este efeito foi observado experimentalmente com o milho (Stewart e Hagan, 1960-1970), aplicando altos níveis de irrigação. Com este tratamento - lâmina total de 60 cm/ciclo - assumido como excessivo, o nível de umidade do solo permaneceu acima da Capacidade de Campo durante a maioria do tempo; ET foi incrementada acima de ET_{max} em aproximadamente 25 mm, e o rendimento Y caiu em aproximadamente 840 kg/ha. Os valores mais altos de ET observados no gráfico resultam de aplicações que totalizam 45 cm. Este ponto é chamado de $Y_{max}-ET_{max}$. A partir deste ponto a função decresce linearmente. Apesar de que ET_{max} depende principalmente do meio-ambiente, Y_{max} e a declividade da função Y vs ET estão associados com o potencial genético da planta. Portanto, se a função Y vs ET é feita relativamente (Y_{max} e ET_{max} correspondendo a 100%), a

razão do decréscimo percentual de Y em função de um decréscimo percentual de ET deverá ser uma constante para cada variedade ou cultivar.

Em qualquer outro clima onde uma dada variedade é bem adaptada e outros fatores que não a água limitarem o rendimento, o valor relativo da função Y vs ET deverá ter uma declividade constante. Se isto for verdade, o conhecimento desta declividade combinado com o conhecimento de $Y_{max}-ET_{max}$ para uma dada localidade, produzirá o conhecimento quantitativo de toda a função Y vs ET. O valor relativo das declividades para diferentes variedades deverá ser inicialmente obtido experimentalmente (Stewart e Hagan, 1973).

Jensen e Sletten (1965), citado por Stewart e Hagan (1973), encontraram uma proporcionalidade entre o rendimento relativo Y e a evapotranspiração relativa para o sorgo em grão, baseado em ponderações empíricas conferidas para determinar os efeitos específicos nos estádios de crescimento da cultura; observou-se que ocorreram reduções no rendimento de 35 e 70% em resposta à reduções de 20 e 40% de ET, respectivamente. Em ambos os casos, a razão (redução percentual de Y/redução percentual de ET) foi igual à 1,75. Isto é uma indicação da linearidade existente entre uma redução no rendimento e o déficit de evapotranspiração.

Hogg et al. (1969) afirmam, para o caso da cana-de-açúcar, que o rendimento da cultura é aproximadamente proporcional em forma linear à evapotranspiração.

A função Y vs ET não assume restrições físicas de solo, sistema e operação quanto à distribuição e infiltração da água na área em questão, não assume restrições quanto à capacidade de medir ou predizer em qualquer tempo o grau de umidade do perfil do solo, e também não assume restrições operacionais tanto externas como internas que impeçam uma programação ótima de irrigação (Stewart e Hagan, 1973).

A função Y vs ET descreve os valores reais esperados em muitas circunstâncias sem irrigação e também em situações onde a irrigação é praticada. Entretanto, pode acontecer não se alcançar a ET_{max} sazonal com uma eficiência de irrigação ostensiva de cem por cento. Há duas razões: a primeira é que não existem sistemas que possam assegurar uma perfeita uniformidade da água infiltrada no solo; contudo, cada aplicação pode preencher o perfil do solo em toda a área se o número de irrigações é minimizado e os déficits de ET são absolutamente impedidos; a segunda razão é que o armazenamento de água no solo,

mesmo que a aplicação seja uniforme, haverá percolação; e em consequência, a lâmina a ser aplicada na área não corresponderá à ET, pois deverá ser acrescida mais uma fração associada com a eficiência de aplicação.

2.4 A Função de Produção da água

Enquanto que a ET é uma variável intimamente associada com o rendimento, a água aplicada artificialmente (IRR) é uma variável que está associada a precipitação efetiva e o armazenamento; interessa mais a projetistas, agricultores e economistas. Normalmente, IRR representa uma das três fontes de consumo de água da planta, as outras duas são a água disponível no solo na data da semeadura (ASWP) e a precipitação (R). Estas três fontes somadas podem ser chamadas de suprimento hídrico (FWS):

$$FWS = ASWP + R + IRR \quad (2.7)$$

A figura 2.3 mostra a relação Y vs FWS, que na realidade é uma relação entre Y e IRR, mas que também reflete a porção de FWS que deriva de ASWP e R (Stewart e Hagan, 1973).

Enquanto que ASWP converteu-se quase 100 % em ET, e a conversão de R em ET foi próximo à 100 %, a água aplicada artificialmente (IRR) inclui uma porção que não é consumida pela planta, que pode ser chamada de NON-ET.




FIGURA 2.3-Rendimento de grãos de milho vs(suprimento hídrico)em Davis(USA), segundo Stewart e Hagan(1973)

A Figura 2.4 combina os gráficos das Figuras 2.2 e 2.3, e mostra que as curvas andam juntas em determinado trecho. O ponto que limita a separação das curvas Y vs FWS e Y vs ET corresponde à contribuição de ASWP + R, valor este que foi totalmente convertido em ET.

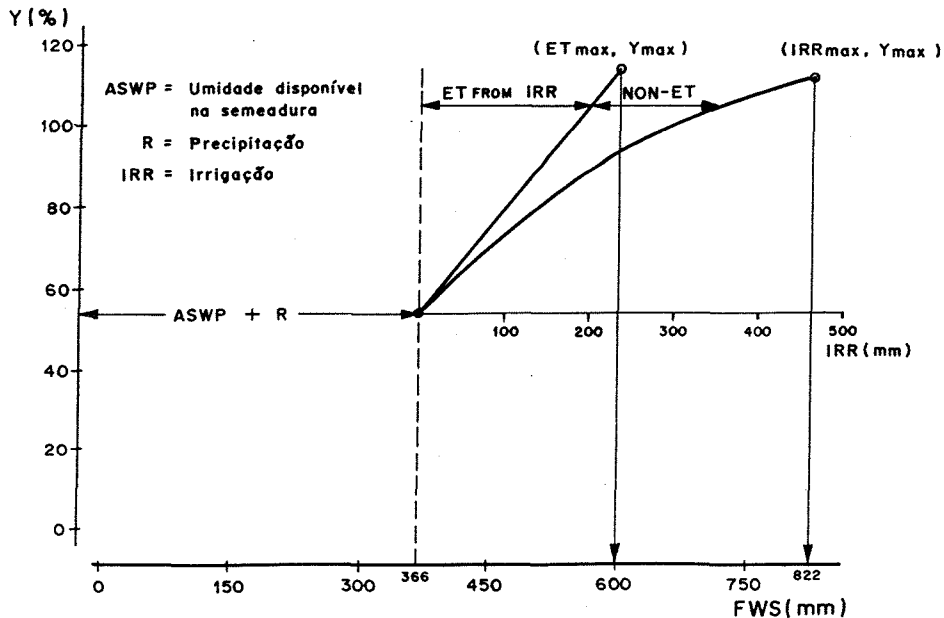


FIGURA 2.4 Rendimento vs ET e Rendimento vs FWS (ASWP + R + IRR), em Davis (USA), segundo Stewart e Hagan (1973).

Ascendendo ao longo da curva da função Y vs FWS observa-se um incremento da diferença FWS - ET, que é a causa da convexidade da função Y vs FWS. Este incremento é devido à diminuição da eficiência de aplicação na medida em que se alcançam valores mais altos de ET. Assim, conceitualmente, $IRR = ET + NON-ET$, e a definição da eficiência de aplicação (E_a) é a razão entre a ET e a lâmina aplicada artificialmente (IRR):

$$E_a = \frac{ET}{IRR} \quad (2.8)$$

Portanto, se a eficiência de aplicação for 100 %, as funções Y vs FWS e Y vs ET serão idênticas. Como já foi mencionado anteriormente, a forma convexa da função Y vs IRR indica que a eficiência de aplicação decresce na medida em que a ETmax é alcançada. Se IRR é um valor bem abaixo do que o

requerido para alcançar Y_{max} , as perdas por percolação serão mínimas ou até eliminadas. Adicionalmente, toda a ASWP será extraída pelas raízes da planta antes da maturidade. Quando IRR é suficiente para assegurar que não ocorram déficits de ET, algumas perdas por percolação serão inevitáveis e uma parte da água disponível do solo permanecerá armazenada após maturação. Esta porção de água não convertida em ET deve ser levada em conta também quando é desejada uma lixiviação ou quando se deseja providenciar uma certa umidade no solo após a colheita. Do exposto conclue-se que a convexidade da função Y vs IRR está associada com as eficiências de aplicação. Ocasionalmente, se a eficiência de irrigação for essencialmente constante, a função Y vs IRR será essencialmente uma linha reta; e o deslocamento desta função com relação à função Y vs ET dependerá da magnitude da eficiência de aplicação.

Os experimentos de Stewart e Hagan (1973) mostram a completa dependência das funções Y vs IRR com relação à eficiência para diferentes níveis de IRR. Assim, a obtenção das funções Y vs IRR implica no conhecimento das eficiências de aplicação de água.

Esta análise realça a relevância da precipitação nas Funções de Produção, principalmente em climas úmidos onde as chuvas são substanciais.

Yaron (1971), afirma que a maior dificuldade na obtenção empírica das Funções de Produção é a escolha das variáveis independentes. Ele considerou em trabalhos realizados as variáveis fundamentais relacionadas com a prática da irrigação que pudessem ser controladas pelo agricultor e, assim, serem operacionalmente significativas. Dentre as variáveis por ele utilizadas estão: profundidade umidecida do solo, quantidade total de água aplicada e número de irrigações.

Burnett e Moldenhauer (1957) desenvolveram um modelo de previsão de rendimentos do algodão utilizando valores de precipitação bruta. Estes autores recomendam a inclusão da precipitação na previsão de rendimentos desde que seja controlado adequadamente o escoamento superficial.

Mais recentemente, uma abordagem que tem sido empregada para estimar rendimentos é discretizar o ciclo vegetativo da cultura em intervalos temporais ou intervalos fenológicos entre a sementeira e a maturação, a semelhança do trabalho apresentado por Lorber e Haith (1981) e o trabalho aqui proposto. Rao et al. (1988) apresentam uma coletânea destas abordagens, chamadas 'Dated Water Production Function', expostas na Tabela 2.6.1:

Tabela 2.6.1 Algumas Funções de Produção discretizadas

Fonte	Função (Y/Ym)	Variável independente
Hall e Butcher (1968)	$\prod_{i=1}^n a_i (SMD_i)$	Índice defic.hídrico
Jensen (1968)	$\prod_{i=1}^n (AET/PET)^{\lambda_i}$	ET relativa
Hiler e Clark (1971)	$1 - \frac{A}{Y_m} \sum_{i=1}^n CS_i (1 - AET/PET)_i$	Déficit relativo ET
Hanks (1974)	$\prod_{i=1}^n (T/Tp)^{\lambda_i}$	Transpiração rel.
Minhas et al. (1974)	$\prod_{i=1}^n [1 - (1 - AET/PET)_i]^{b_i}$	Déficit relativo ET
Blank (1975)	$\sum_{i=1}^n A_i (AET/PET)_i$	ET relativa
Stewart et al. (1976)	$1 - \sum_{i=1}^n YRR_i (1 - AET/PET)_i$	Déficit relativo ET
Sudar et al. (1981)	$Y_m \sum_{i=1}^n (1 - AET/PET)_i YS_i$	Déficit relativo ET

T e Tp se referem à transpiração real e potencial, respectivamente.

Dorfman (1985) apresenta uma revisão de métodos para estimar as Funções de Produção da água quando as informações são escassas; entre elas estão:

1) Hogg et al. (1969):

$$\frac{Y_a}{Y_p} = a + b \cdot EPF + C \cdot EPF^2 \quad (2.9)$$

onde:

Y_a = produção atual
 Y_p = rendimento potencial
 EPF = fator efetivo de evaporação dado por:
 $EPF = [ER + (ANI \cdot RAM) / PET]$
 ER = precipitação efetiva
 ANI = quantidade de ciclos de irrigação
 RAM = armazenamento de água do solo
 PET = evapotranspiração potencial
 a, b e C = parâmetros estimados por regressão

2) Hargreaves e Christiansen (1973):

$$Y_a = (0.8W + 1.3W^2 - 1.1W^3) Y_p \quad (2.10)$$

onde:

Y_a = rendimento atual
 Y_p = rendimento potencial
 W = variável hídrica composta

3) English e Nuss (1982):

$$Y_p = A_1 + A_2 \cdot R + A_3 \cdot R^2 \quad (2.11)$$

onde:

$R = ET_a / ET_m$
 ET_a = evapotranspiração real
 ET_m = evapotranspiração potencial
 A_i = parâmetros obtidos empiricamente

2.5 A incerteza nos modelos para previsão de rendimentos

Entre os fatores que influenciam a relação água-rendimento, as características fisiológicas das distintas espécies de uma cultura e as condições sob as quais a planta cresce, são os fatores que apresentam um maior grau de incerteza. As condições climáticas são imprevisíveis, e a resposta fisiológica de um cultivo ao clima e umidade do solo também não é totalmente previsível (English, 1981).

As eficiências de irrigação é outra fonte considerável de incerteza. Do ponto de vista operacional, a água aplicada deve ser definida como aquela quantidade que chega até o terreno cultivado, e não a quantidade que é consumida pela planta. Assim, perdas por escoamento superficial ou por percolação reduzem a taxa de rendimento por unidade de água aplicada. Mas acontece que estas perdas são difíceis de avaliar em certas circunstâncias; por esta razão, a eficiência de irrigação pode afetar consideravelmente a relação água-rendimento (English, 1981).

English e Orlob (1978) colocam que sistemas de irrigação por aspersão produzem rendimentos maiores do que sistemas de irrigação por gravidade. Obviamente, esta afirmação só é válida quando a seleção do método de irrigação foi criteriosamente elaborada.

Outros fatores que estão indiretamente associados com a relação água-rendimento como por exemplo a estrutura física do solo, capacidade de troca de cátions, relação de adsorção de sódio, drenabilidade, manejo de fertilizantes, herbicidas, pesticidas, data de semeadura, espaçamento e densidade de plantas, também contribuem ao aumento de incertezas.

Um estudo detalhado com o objetivo de determinar o impacto das incertezas em modelos de prognóstico de rendimentos foi conduzido por English e Orlob (1978), onde analisaram situações hipotéticas mas com dados reais e circunstâncias realísticas. As decisões a serem tomadas eram:

- a) Que cultivos explorar;
- b) Que superfície explorar;
- c) Quanta água usar.

Obviamente, o reconhecimento da existência de incertezas em modelos para prognóstico de rendimentos não deve desencorajar esforços no sentido de tornar possível a obtenção de relações água-rendimento, mas sim devem ser levadas em conta como um alerta, tomando as precauções cabíveis para tentar minimizar o erro.

Em climas úmidos e temperados, como no Rio Grande do Sul, um fator que deve ser levado em conta é a época de semeadura. Segundo Sutili et al. (1977), para o caso do milho, duas variáveis climáticas possuem efeito pronunciado nos rendimentos: a soma térmica e a precipitação. Para que a cultura usufrua ao máximo das condições térmicas e hídricas, ela deve ser semeada numa época que minimize os déficits hídricos.

De acordo com o trabalho desenvolvido pelos autores anteriormente citados, de forma geral, à medida que se atrasa a época de semeadura os rendimentos, em média, diminuem. Eles acharam através de experimentos a campo (ensaios ecológicos) desenvolvidos durante alguns anos, que a época recomendada de plantio, para a maioria das regiões do Rio Grande do Sul, vai de Setembro a meados de Outubro.

2.6 Variabilidade dos rendimentos em função da água

De acordo com Musick e Dusek (1971), a maior causa da variabilidade dos rendimentos está associada com o número, distribuição temporal, magnitude das irrigações sazonais e com a quantidade e distribuição das chuvas. Eles conduziram experimentos em Idaho (USA), com o objetivo de avaliar a variabilidade dos rendimentos de trigo e sorgo em grão. A Figura 2.5 apresenta os resultados obtidos.

Os rendimentos baixos obtidos podem ser representados por uma relação linear entre a água utilizada pelo cultivo e o rendimento (curva de resposta mínima); entretanto, os rendimentos altos indicam que sob certas condições de gerenciamento da água, a relação entre a resposta máxima do cultivo e a água fornecida é de natureza convexa, correspondendo à envolvente superior dos pontos observados, conforme exposto anteriormente por Stewart e Hagan (1973).




FIGURA 2.5—Resposta do Sorgo em grão a diferentes tratamentos hídricos. (IDAHO, USA)

Segundo Schneider et al. (1969), a variação dos rendimentos em tratamentos realizados com um mesmo total de água fornecida ilustra o efeito da programação ou distribuição temporal das irrigações, como mostra a Figura 2.6. A curva de resposta máxima mostra os rendimentos esperados em condições ótimas de gerenciamento da água. Por outro lado, uma programação pobre em número e magnitude de irrigações em relação com as fases de desenvolvimento da planta produz uma curva de resposta mínima. A maioria dos pontos próximos à curva de resposta máxima correspondem a bons níveis de irrigação. Para obter um resultado eficiente da precipitação, o nível da irrigação deve ser o suficiente para proporcionar taxas ótimas de evapotranspiração. Em contrapartida, precipitações inoportunas produzem o mesmo efeito que um manejo pobre da água ao longo do desenvolvimento da cultura. O trigo de inverno utiliza a água mais eficientemente quando esta é aplicada em fases fenológicas críticas para o rendimento.




FIGURA 2.6 Resposta do trigo a diferentes tratamentos hídricos em Texas (USA), segundo Schneider ET AL.(1969).

Finalmente, Schneider et al.(1969) afirmam que uma Função de Produção está intrínsecamente associada com critérios de manejo da irrigação, isto é, estabelecimento de patamares de tensão ou potencial matricial da água no solo durante o desenvolvimento da cultura.

Dorfman (1985), citando a Downey (1972) e Levit (1980), salienta que a ocorrência de um stress hídrico entre o florescimento e a maturação é indesejável e causa um uso ineficiente da água. Este período também corresponde à taxa máxima de evapotranspiração, e os especialistas devem estar conscientes deste fato no momento da alocação temporal da água, de forma a não restringir a água neste período.

Downey (1972), afirma que a magnitude da redução no rendimento não é somente função da evapotranspiração, mas que depende também da severidade do stress e particularmente do estágio fenológico em que ocorre.

2.7 Aplicação dos modelos de previsão de rendimentos na irrigação

A irrigação aliada com boas práticas de manejo possui o potencial para estabilização de rendimentos altos e também reduz o risco associado com as flutuações do rendimento. A agricultura irrigada requer um manejo adequado a fim de maximizar os retornos do produtor, sendo a programação da irrigação o fator primário associado aos custos envolvidos com esta prática. Modelos de simulação são comumente usados no auxílio às tomadas de decisões em diferentes fases da produção de cultivos.

Jones e Smajstrla (1980), citados por Hood et al.(1987), apresentam uma ampla revisão do uso de tais modelos na programação da irrigação. Eles discutiram os seguintes níveis de sofisticação nesses modelos:

- a. Balanço hídrico;
- b. Resposta das culturas;
- c. Crescimento dinâmico das culturas.

Estes autores desenvolveram um modelo de crescimento da soja (*Glycine max L.*) para estimar o consumo de água e para avaliar o potencial do incremento da produção através da irrigação.

Morey e Gilley (1973), desenvolveram um modelo de simulação do balanço hídrico para avaliar sistemas de irrigação com milho em Minnesota (USA) utilizando precipitação diária e evapotranspiração potencial como dados climáticos de entrada. As alternativas de manejo que consideraram, estavam relacionadas com lâminas aplicadas, tempo de irrigação, níveis de deficiência da água do solo e área total irrigada. Também estudaram a viabilidade de sistemas de irrigação comparando os incrementos no retorno com custos adicionais.

Morey et al.(1980), conduziram testes para avaliar e validar tal modelo, adotando quatro tratamentos hídricos diferentes para o milho. Os resultados mostraram que tal modelo prevê satisfatoriamente os níveis de umidade do solo, fortalecendo a adequacidade do modelo proposto para trabalhos de simulação.

Jensen e Wright (1978) realizaram uma análise dos problemas associados com a programação da irrigação usando modelos baseados na evapotranspiração para a região oeste dos Estados Unidos, quantificando os níveis de confiança de programação da irrigação associada com incertezas na estimativa da evapotranspiração real, água aplicada, fluxo da água no solo e precipitação efetiva, concluindo que a maior incerteza, para as condições daquela região, estava associada com a quantidade de água aplicada.

Wright e Jensen (1978) desenvolveram relações para estimativa da radiação líquida e evapotranspiração potencial a serem utilizadas no manejo da irrigação, estimando valores de ET para a alfafa (Idaho, USA) muito próximos aos valores observados.

Howell e Hiller (1975) obtiveram relações empíricas entre o rendimento do sorgo em grão e a evapotranspiração, com o objetivo de aumentar a eficiência no uso da água. Determinaram a resposta do rendimento aos déficits hídricos ocorridos durante três fases de crescimento do sorgo, concluindo que o tempo de permanência do déficit é mais nocivo aos rendimentos do que a própria magnitude do déficit.

Howell et al. (1975) usaram estas relações empíricas para otimizar o rendimento do sorgo em grão sob condições limitadas de frequência de irrigação. Utilizando Programação Dinâmica, maximizaram os rendimentos sujeitos a restrições de disponibilidade hídrica. Encontraram que a quantidade de água pode ser significativamente reduzida sem a ocorrência de decréscimos acentuados nos rendimentos, se as aplicações de água fossem programadas de forma ótima.

Doss et al. (1974) conduziram experimentos com soja no Alabama (USA) e determinaram que a distribuição temporal das aplicações de água é fundamental para elevar os rendimentos, concluindo que a resposta à irrigação era maior quando feita após o início da polinização, do que antes.

Hill et al.(1979,1985a,1985b), citado por Hood et al.(1987), desenvolveram modelos para previsão de rendimentos de alfafa, milho, feijão, batata e trigo em Utah e Idaho (USA), baseados na ET e Balanço Hídrico. O rendimento foi expresso em termos do rendimento potencial máximo. Eles associaram estes modelos com esquemas de manejo da água para examinar e avaliar o efeito da irrigação, encontrando uma relação linear entre o rendimento e a evapotranspiração, apesar de que a declividade desta relação varia em função do local e do cultivo.

Rotunno (não publicado, 1989) realizou um trabalho no qual comparou dois métodos para avaliação dos déficits hídricos do milho, sendo que um método baseou-se na fórmula de Penman, e o segundo método baseou-se na Função de Produção do milho para a localidade estudada. Estes dois métodos foram comparados com dados de evapotranspiração máxima registrada em lisímetro de drenagem, concluindo que a Função de Produção fornece estimativas intermediárias entre os valores do lisímetro e a fórmula de Penman.

2.8 Análise crítica

a._ O rendimento dos cultivos é linearmente dependente da evapotranspiração sazonal acumulada.

b._ A declividade da função $Y = f(ET)$ está associada com o potencial genético do cultivo, fato que induz a trabalhar com rendimentos relativos e não brutos.

c._ A forma da função $Y=f(R)$, onde R é a precipitação, está associada com o grau de eficiência desta precipitação transformar-se em evapotranspiração.

d._ A utilização de variáveis climáticas em modelos de previsão de rendimentos, como soma térmica, radiação e fotoperíodo, apresentam resultados melhores do que usando os dias do calendário para verificar a ocorrência de estágios fenológicos.

e._ A distribuição temporal da precipitação é mais importante do que o total precipitado.

f._ A precipitação em climas úmidos é fundamental no rendimento e na obtenção das Funções de Produção.

g._ Finalmente, uma metodologia empírica para estimar rendimentos requer a divisão do ciclo (distribuição temporal) da cultura, a inclusão de uma variável que estime razoavelmente a ocorrência de fases fenológicas, e um tratamento adequado da precipitação bruta.

3. METODOLOGIA

3.1 Introdução

O desenvolvimento de uma metodologia que visa principalmente quantificar o efeito da água no rendimento de uma cultura, é determinado pela abordagem empregada na tentativa de explicar o processo de produção vegetal. Nesta dissertação o enfoque é empírico, no qual uma análise histórica de eventos que ocorreram no passado permite avaliar o comportamento da produção vegetal em determinadas condições, semelhantes às aquelas representadas pela amostra que gerou os parâmetros da ou das equações.

Na definição desta metodologia apresentaram-se dois fatores conflitantes: o desejo de descrever sempre mais rigorosamente o processo, incorporando o maior número possível de variáveis envolvidas na produção, contra a dificuldade na utilização prática de modelos que possuam muitas variáveis, já que observações dessas variáveis podem não estar disponíveis.

A metodologia a ser apresentada neste trabalho procurou apresentar simplicidade na sua aplicação prática, sem omitir as variáveis consideradas relevantes, de forma que em aplicações práticas posteriores houvesse o mínimo grau de dificuldade.

Neste capítulo se discutem e apresentam os aspectos qualitativos e quantitativos envolvidos no tratamento da informação que deu origem aos parâmetros das equações que tentam descrever o processo, a concepção da forma das equações, as variáveis envolvidas no processo, as fontes de erro e critérios para avaliação dos ajustes. Também aqui se descrevem algumas técnicas de aplicabilidade destes modelos, tais como otimização do uso da água em Sistemas de Irrigação, estimativa da melhor época de plantio com base em temperaturas e precipitações, e prognóstico do rendimento final em função do avanço da soma térmica.

3.2 Concepção dos Modelos, Variáveis envolvidas e Fontes de Erro

Os modelos aqui descritos requerem apenas duas informações climáticas e informações da cultura.

As variáveis climáticas são precipitações e temperaturas máximas e mínimas diárias. Da cultura se requer o conhecimento da variedade híbrida, data da semeadura e rendimento correspondente.

Ambos os modelos consistem numa acumulação diária das unidades térmicas e da precipitação desde a semeadura até um valor total de Soma Térmica que deve ser significativo para estimar os rendimentos, que aproximadamente coincide com a maturação fisiológica.

Os valores acumulados da precipitação estimada como sendo efetiva, são distribuídos em quatro intervalos parciais da Soma Térmica, cuja soma destes quatro valores idênticos deve ser igual ao valor da Soma Térmica total.

Apesar de que a metodologia foi aplicada ao milho, presume-se que a mesma possa ser aplicada a outras culturas com a devida escolha das variáveis que melhor representam o desenvolvimento, fenologia e rendimento da planta. Em particular, no Rio Grande do Sul, sabe-se que o rendimento do milho é sensível à Soma Térmica e Precipitação (Berlato et al, 1973; Sutili, 1974, entre outros).

De acordo com a necessidade de considerar a distribuição temporal da precipitação e seu efeito no rendimento do milho, ao longo de intervalos de Soma Térmica, adotaram-se equações que tornassem isto possível.

Dentre as equações que têm apresentado resultados satisfatórios a respeito (Stewart e Hagan, 1973; Lorber e Haith, 1981; entre outros), na tentativa de descrever o comportamento da produção, estão as equações empíricas ajustadas por regressão. Quando se analisa somente valores acumulados de precipitação, evapotranspiração, lâminas de irrigação, etc, geralmente se utilizam equações de regressão simples com uma variável independente. Devido a que no presente trabalho se estuda o efeito da distribuição da precipitação nos intervalos de Soma Térmica, é preciso uma discretização dos valores totais, transformando-os em valores parciais, constituindo assim equações de regressão múltiplas lineares e não-lineares.

No presente trabalho adotaram-se dois modelos de regressão, com o objetivo de verificar e comparar qual dos dois é mais adequado, e se ocorrem diferenças significativas entre eles, ou qual apresenta menor erro nas estimativas.

3.2.1 Modelo de Regressão Múltipla Linear (Modelo LIN)

Na escolha do modelo LIN se supõe que ocorra independência e linearidade na produção de grãos nos intervalos representados pelas variáveis independentes, embora na realidade o processo de produção vegetal seja um processo contínuo e ininterrupto, e que um stress ou excesso ocorrido num intervalo afete a produção nos outros intervalos sucessivos.

No modelo LIN tem-se:

$$Y = \sum_{i=1}^n a_i \cdot X_i + B + \epsilon \quad (3.1)$$

onde:

Y = rendimento de grãos (%), onde 100% é um valor arbitrado,
 X_i = precipitação efetiva no intervalo i (mm),
 a_i = coeficiente da variável X ,
 B = termo constante da regressão,
 n = número de intervalos considerados,
 $i = 1, \dots, n$
 ϵ = variável aleatória com $E(\epsilon) = 0$, $\text{Var}(\epsilon) = S$ e
 $\text{cov}(\epsilon_k, \epsilon_j) = 0$, com $k \neq j$,
 $E(\epsilon)$ = esperança de ϵ ,
 $\text{Var}(\epsilon)$ = variância de ϵ ,
 $\text{Cov}(\epsilon)$ = covariância entre ϵ_k e ϵ_j .

3.2.2 Modelo de Regressão Múltipla Não-linear ou linear com anamorfose logarítmica (Modelo LOG)

No modelo LOG tem-se:

$$Y = C_1 \cdot \prod_{i=1}^n X_i^{\lambda_i} \cdot \eta \quad (3.2)$$

onde:

- Y = rendimento de grãos (%)
- X_i = precipitação efetiva no intervalo i (mm)
- λ_i = expoente da variável X
- C_1 = coeficiente da regressão
- n = número de intervalos
- $i = 1, \dots, n$
- η = variável aleatória com $E(\log \eta) = 0$, $\text{Var}(\log \eta) = S$ e $\text{cov}(\log \eta_k, \log \eta_j) = 0$, com $k \neq j$,
- $E(\log \eta)$ = esperança dos logaritmos de η ,
- $\text{Var}(\log \eta)$ = variância dos logaritmos de η ,
- $\text{Cov}(\log \eta_k, \log \eta_j)$ = covariância entre $\log \eta_k$ e $\log \eta_j$.

Biologicamente, a adoção de uma equação onde as variáveis independentes estão interligadas por um produto e não por uma operação aditiva, como no caso do modelo LIN, é, sob o ponto de vista da fisiologia vegetal, mais próxima da realidade, porque se supõe que o stress num intervalo afeta a produção nos outros intervalos consecutivos. Além disto, o Modelo LOG proporciona uma melhor interpretação e separação dos significados físicos entre os parâmetros C_1 e λ_i da equação (3.2), como se verá mais adiante. Matematicamente também é mais prática a adoção do modelo LOG, cuja razão está exposta no item 3.4.1.

3.2.3 Cálculo e Discretização da Soma Térmica

As unidades térmicas (UT), em graus Celsius, que teoricamente contribuíram a um desenvolvimento efetivo da cultura considerada, foram calculadas pelo método das temperaturas máximas e mínimas corrigidas, inicialmente proposto por Gilmore e Rogers (1958), descrito anteriormente na revisão bibliográfica. Este método têm apresentado resultados satisfatórios na estimativa da ocorrência de fases fenológicas do milho, no Rio Grande do Sul (Berlato et al., 1974; Chielle, 1977; Maluf et al., 1979; Chielle e Sutili, 1980). O método de Gilmore e Rogers (1958) calcula as unidades térmicas (UT) através da seguinte expressão:

$$UT = \frac{[(10+t1)+(Tmax-t2)]}{2} - Tb \quad (3.3)$$

onde:

UT = unidades térmicas (°C)

$$t1 = \begin{cases} T_{min} - 10, & \text{se } T_{min} > 10 \text{ (}^\circ\text{C)} \\ 0, & \text{se } T_{min} \leq 10 \text{ (}^\circ\text{C)} \end{cases}$$

$$t2 = \begin{cases} T_{max} - 30, & \text{se } T_{max} > 30 \text{ (}^\circ\text{C)} \\ 0, & \text{se } T_{max} \leq 30 \text{ (}^\circ\text{C)} \end{cases}$$

Tmin = temperatura mínima (°C)

Tmax = temperatura máxima (°C)

Tb = temperatura-base da cultura³ (graus Celsius)

O valor de Tb foi suposto constante para todas as localidades estudadas, e sendo igual a 10°C. O valor total da Soma Térmica selecionado para estimativa dos rendimentos requer uma análise de sensibilidade dos rendimentos e dos parâmetros das equações de regressão em função da variação deste valor. Esta análise consiste num processo iterativo onde se estuda o comportamento do coeficiente de determinação (R²) e a magnitude dos parâmetros (λ_i) à variação do valor total de Soma Térmica. Os

3

O leitor pode se referir ao trabalho de Gilmore e Rogers (1958) para maiores detalhes sobre a temperatura-base (Tb).

valores iniciais foram obtidos de trabalhos desenvolvidos no Rio Grande do Sul por Berlato et al. (1974) e Chielle e Sutili (1980), entre outros. É de se esperar que os valores de Soma Térmica, resultantes do processo iterativo que maximizam o coeficiente de determinação e proporcionam parâmetros com valores razoáveis, sejam aproximadamente iguais aos valores recomendados por trabalhos experimentais a campo.

O critério para seleção do número de intervalos (n) de Soma Térmica baseia-se em fundamentos fisiológicos e estatísticos. Tentou-se selecionar um comprimento de intervalo térmico, no qual um déficit hídrico severo causasse um decréscimo da mesma magnitude nos rendimentos, evidenciado pela forma da equação não-linear. Um critério subjetivo para adoção do comprimento do intervalo, no qual um déficit total anularia os rendimentos, pode ser 25% da Soma Térmica total.

Como as variáveis independentes são precipitações efetivas e não evapotranspiração real (variável que leva em conta o efeito do armazenamento de água do solo), um valor excessivo do número de intervalos pode conduzir a erros substanciais nas estimativas de rendimento, dependendo da capacidade de armazenamento de água do solo. Portanto, como aqui as variáveis independentes são precipitações efetivas, o número de intervalos selecionado deve ser pequeno o suficiente para minimizar o efeito da água armazenada no solo em intervalos sucessivos. Em consequência, em solos com alta capacidade de armazenamento, o número de intervalos deve ser reduzido, e em solos com baixas capacidades de armazenamento, o número de intervalos pode ser aumentado. Em contrapartida, o número de intervalos deve ser grande o suficiente para considerar o efeito da distribuição temporal da precipitação nos rendimentos. Um baixo valor do número de intervalos (n) não representa este efeito, o que constitui uma restrição à escolha de baixos valores de n.

Como a abordagem empregada nas estimativas de rendimento é empírica, e os parâmetros das equações são obtidos originalmente por regressão, a variância destes deve ser pequena o suficiente para que o modelo forneça estimativas razoáveis e de boa precisão nas aplicações.

Aumentando o número n, está-se aumentando o número de variáveis independentes e reduzindo os graus de liberdade dos resíduos para um mesmo tamanho de amostra.

Por uma razão prática, um número n igual de intervalos adotado para todas as estações estudadas facilitará posteriormente uma análise conjunta de todos os parâmetros.

Tendo em vista as considerações fenológicas da

cultura, associadas com a qualidade dos dados de entrada, e na tentativa de estar numa situação de equilíbrio entre todos os fatores sensíveis ao valor de n , adotou-se n igual a quatro (4), como sendo o valor mais razoável.

3.2.4 Estimação da Precipitação efetiva

O valor bruto da precipitação diária observada não é um valor confiável como indicador do que realmente contribuiu ao desenvolvimento da planta e da parte que ficou armazenada no solo. No presente trabalho, por não estarem disponíveis suficiente quantidade de ensaios com irrigação controlada, tornou-se necessário a adoção de um tratamento para estimar a precipitação efetiva a partir da precipitação bruta.

Schwarzbach (1988) utilizou uma função composta (equação 3.4) por duas equações simples para estimar a fração da precipitação diária que infiltra no solo (ver Figura 3.1):

$$P_{ef} = \begin{cases} P_b, & \text{se } P_b < K \\ J, & \text{se } P_b \geq K \end{cases} \quad (3.4)$$

onde:

- P_b = precipitação diária bruta (mm)
- P_{ef} = precipitação efetiva (mm)
- $J = K * E$
- K, E = valores obtidos por calibração⁴

⁴

Ver item 5




FIGURA 3.1 Relação adotada entre a precipitação efetiva (P_{ef}) e a precipitação bruta (P_b).

Aguinsky et al. (1988) trabalharam com valores brutos de precipitação diária para estimar rendimentos de milho em função desta ao longo de subperíodos fenológicos sucessivos, desde a emergência até a maturação fisiológica, e os resultados se mostraram satisfatórios para as condições da amostra, em Taquari, no Rio Grande do Sul.

Com o objetivo de minimizar o efeito residual provocado por precipitações diárias intensas no rendimento estimado, utilizou-se a equação (3.4) para estimar a precipitação efetiva.

A escolha dos parâmetros E e J baseou-se numa análise de sensibilidade dos modelos LOG e LIN à variação daqueles. É conveniente realizar-se uma análise de frequência dos valores diários de precipitação para se saber em que faixa de precipitações ocorre a maioria. No Rio Grande do Sul, o efeito provocado por chuvas intensas e longas (3 ou 4 dias) é diluído pelo número de vezes em que este evento não ocorre, nos meses do período agrícola (setembro-abril).

Os dados de entrada dos modelos (rendimentos e dados climáticos) provém de estações experimentais distribuídas no estado do Rio Grande do Sul, sendo que os rendimentos de milho foram obtidos em parcelas experimentais.

Apesar de que neste trabalho as distâncias entre as parcelas experimentais e a localização dos pluviógrafos e pluviômetros foram mínimas, sugere-se que a distância entre o pluviômetro ou pluviógrafo e as parcelas experimentais deve ser menor do que aquela em que a variabilidade espacial da precipitação se manifesta, podendo constituir uma fonte aditiva de erros. A avaliação destas distâncias deve ser realizada.

A simplificação assumida para calcular a

precipitação efetiva e a variação dos erros na estimativa de rendimentos pode não ser adequada para outros locais, estando na dependência tanto do padrão de precipitações do período agrícola como na capacidade do solo em transformar a precipitação bruta em disponível para a planta. Esta observação será novamente abordada no capítulo 13.

3.2.5 Constituição das amostras de rendimentos

Como se está analisando somente o efeito da precipitação nos rendimentos, é requisito indispensável que os eventos incluídos na amostra para calibração tenham experimentado exclusivamente o efeito da precipitação e não de outros fatores que os modelos não representam, tais como geadas, granizo, temporais, doenças, pragas, contribuições ascendentes de um aquífero livre, etc..

Na prática, em condições de campo, é quase impossível separar totalmente o efeito da precipitação, pois quando ocorrem déficits ou excessos acentuados a planta fica suscetível às doenças, pragas, etc, em virtude do seu enfraquecimento. Desta forma se introduzem erros de difícil avaliação.

Outra fonte de erro nos rendimentos é a variabilidade espacial e temporal no meio-ambiente em que estes foram obtidos. Além da variabilidade espacial das características físico-hídricas do solo (capacidade de infiltração, retenção de umidade, etc.) a variabilidade temporal causada pela erosão e pelo homem afetam a estimação de rendimentos, principalmente quando ocorrer grandes mudanças dentro do período coberto pela amostra. As informações necessárias para detecção destas mudanças não são fáceis de obter, e por conseguinte os modelos assumem o sistema invariante no tempo e no espaço. Quando o período coberto pela amostra é muito longo (mais de 15 anos civis) o efeito provocado nos rendimentos devido a mudanças nas práticas de correção do solo, adubação, manejo de pragas e invasoras, etc., pode assumir um valor limitante. Segundo Sutili (c. pessoal, 1988) na década de 60 a adubação nas estações experimentais, nas quais os dados foram obtidos, era feita frequentemente com esterco. A partir da década de 70, a adubação passou a ser realizada dentro de padrões mais homogêneos. Para minimizar tal efeito é recomendável a constituição de uma amostra na qual não hajam ocorrido mudanças significativas, se possível, no período por ela coberto; ou incluir uma variável no modelo que represente a variação do nível tecnológico em função do tempo.

Para reduzir o efeito da variabilidade devido ao potencial genético de cultivares, e desde que esta variação seja linear em função da água, é importante que a amostra esteja constituída por cultivares com ciclo e potencial genético equivalentes, adimensionalizando os rendimentos relativos a um valor bruto arbitrado. Isto é importante para estimar rendimentos onde as práticas de manejo são diferentes, como no caso de lavouras comerciais, desde que a variação entre os rendimentos obtidos em estações experimentais e lavouras comerciais seja linear para uma mesma quantidade de água. Por exemplo, se o valor utilizado para adimensionalizar os rendimentos da estação experimental é 8000 kg/ha, correspondendo a 100 %, o valor que corresponderá a 100 % para a lavoura, deve ser o valor, em kg/ha, que em média é obtido na lavoura quando na estação experimental se verifica o valor de 8000 kg/ha. Por outro lado, segundo Berlato (c. pessoal, 1988), se o modelo proporciona a resposta da cultura ao efeito da água, e de como uma disponibilidade hídrica deve ser distribuída no ciclo, tais resultados podem ser extendidos à lavoura, já que a resposta de uma cultura à água é uma só.

Geralmente, os ensaios agrícolas para avaliação de rendimentos, entre outras características das plantas, consistem em efetuar 3 ou 4 repetições do mesmo tratamento, em blocos ao acaso, cujas médias são publicadas em boletins e relatórios técnicos de tiragem anual⁵.

Quando se constitui a amostra que dará origem às estimativas dos parâmetros, está-se lidando com valores médios e não pontuais, como no caso de vazões ou níveis em modelos hidrológicos. Devido a que o acesso às cadernetas de campo, onde foram registrados os valores de cada repetição do ensaio, não é tarefa fácil, os valores dos rendimentos nas amostras utilizadas provém das médias das repetições, o que é um fato limitante. Mais correto seria se trabalhar com intervalos de confiança da média e não com ela propriamente, simplesmente para verificar se os rendimentos estimados pela regressão estão dentro do intervalo de confiança, pois numa amostra pequena de 3 ou 4 pode haver um desvio significativo, o que é comum nesses ensaios. Este efeito é diluído quando os rendimentos provem das médias de vários tratamentos.

Devido a todos os fatores apresentados, o autor acredita que uma constituição criteriosa da amostra é o requisito

5

'Reunião Técnica Anual do Milho no Rio Grande do Sul',
IPAGRO, Secretaria da Agricultura, RS.

mais importante para estimar rendimentos sob uma base empírica, sendo necessário, às vezes, usar o critério de excluir eventos que influenciam grandemente o ajuste da regressão. Quando eventos semelhantes ocorrem, uma posição conservadora é descartar estes na dúvida que hajam experimentado efeitos de variáveis que os modelos não incluem.

3.3 Critérios para avaliação dos ajustes

Basicamente dois tipos de ajuste foram efetuados no desenvolvimento do trabalho:

- ajustes das equações de regressão aos dados observados de rendimento e precipitação,
- ajustes de séries históricas à distribuições teóricas de probabilidade.

Nos ajustes das equações de regressão múltipla, as avaliações foram feitas com base nos seguintes indicadores:

- magnitude dos parâmetros
- coeficiente de determinação
- análise de variância
- teste F da regressão
- análise visual dos valores observados e calculados.

O objetivo aqui não é apresentar o equacionamento necessário à obtenção dos indicadores objetivos e a teoria dos mínimos quadrados. Portanto, só serão apresentados conceitos, equações e procedimentos que por sua ausência poderiam suscitar dúvidas ao leitor⁶. Obviamente, os indicadores citados estão associados de certa forma, mas a utilização de algum ou alguns deles pode acelerar o processo de avaliação dos ajustes, dependendo dos objetivos.

Na seleção do valor total de Soma Térmica (STT) que é considerada significativa para estimar rendimentos, a magnitude dos parâmetros a_1, a_2, \dots, a_n e $\lambda_1, \lambda_2, \dots, \lambda_n$ dos modelos LIN e LOG, refletem o efeito da relevância do valor da Soma Térmica no intervalo n dos modelos. No modelo LIN, um valor de a_n que não difere significativamente de zero, indica que a variável

6

Maiores detalhes sobre o assunto são encontrados em Draper e Smith (1980), Ryan e Joiner (1976), entre outros.

independente X_n não está contribuindo a um incremento no rendimento Y . No modelo LOG, valores de $\lambda_n < 0^7$ indicam que a variável X_n está causando um decréscimo no rendimento Y .

O valor do coeficiente de determinação (R^2), além de medir a porcentagem com que as variáveis independentes explicam a variação dos rendimentos através de uma função linear, é um indicador útil para avaliar a sensibilidade dos rendimentos à variação de parâmetros envolvidos na estimação da precipitação efetiva.

A soma dos quadrados total, dos resíduos e da regressão, representada pela soma dos quadrados decomposta nas variáveis independentes, dão uma visão global do ajuste e da relevância apresentada pelas variáveis independentes nos rendimentos. Estes valores também são usados para testar hipóteses de significância das variáveis.

A variância dos parâmetros reflete a precisão com que o parâmetro pode ser estimado usando a amostra. São essenciais tanto para testar hipóteses de significância destes como para o estabelecimento de intervalos de confiança que poderão ser usados para estimar margens de erro na previsão de rendimentos.

Finalmente, uma análise visual dos pontos observados e calculados pode ajudar na detecção de tendências de subestimação ou superestimação de valores na faixa de rendimentos coberta pela amostra.

Quando se analisaram as frequências de séries históricas de precipitação, fez-se uma inspeção do histograma de frequências para estabelecer as características das séries (simetria e curtose).

Para verificação da normalidade de uma série histórica, aplicou-se o teste sugerido por Ryan et al. (1987)⁸, que é equivalente ao teste de Shapiro-Wilk, para verificação do ajuste da distribuição normal a uma série. Este método consiste em calcular a correlação entre os valores observados (X) e os "Normalscores". Estes são calculados pela seguinte aproximação:

$$\phi^{-1}(p) = -4.91((p^{*.14}) - ((1-p)^{*.14}))$$

7

Se $\lambda_n < 0$, $X_n^{\lambda_n} < 1$.

8

Maiores detalhes em MINITAB STUDENT HANDBOOK. Ryan, Ryan e Joiner (1988) e MINITAB REFERENCE MANUAL. MINITAB, INC (1988).

onde:

$\phi(x)$ = é a função densidade de probabilidade da distribuição normal,
p = é a posição de plotagem, e calculada pela fórmula de Bloom: $p = (i - 3/8)/(n + 1/4)$,
i = número de ordem decrescente na série
n = tamanho da amostra

Uma correlação alta entre estes valores é consistente com a normalidade da série; assim, se rejeita a hipótese de normalidade de uma série se o coeficiente de correlação cai abaixo de valores tabelados em função do tamanho da amostra e do nível de significância adotado. Neste trabalho usou-se $\alpha = 0.05$.

3.4 Aplicabilidade dos modelos

Quando já se dispõe de um modelo que descreve razoavelmente os rendimentos ao efeito das variáveis independentes, se espera que tal modelo também simule razoavelmente rendimentos que não foram registrados mas que poderiam ter ocorrido. Esta propriedade confere aos modelos versatilidade de uso, constituindo-se em ferramentas valiosas para ajudar a compreender, quantificar e planejar o processo de produção vegetal.

3.4.1 Otimização do uso da água em Sistemas de Irrigação

Se a variação de uma magnitude pode ser representada por uma função matemática, e se há interesse em analisar os possíveis pontos críticos da função, pode ser que um tratamento analítico ajude a conduzir à solução do problema, que consiste em achar os pontos no domínio da função que maximizam ou minimizam a variável dependente.

Em Sistemas de Irrigação, quando uma parte ou toda a água se torna uma variável de decisão, é interessante encontrar uma função que descreva o comportamento dos rendimentos máximos ao efeito de uma disponibilidade hídrica mínima, devido a razões econômicas.

São duas as funções às quais se aplica a análise de otimização:

A equação (3.2) do modelo LOG

A equação (3.32) do modelo LIN

3.4.1.1 Extremos da função $Y = \prod_{i=1}^n X_i^{\lambda_i}$

Deseja-se analisar os extremos da função⁹ :

$$Y = \prod_{i=1}^n X_i^{\lambda_i} \quad (3.3)$$

onde:

Y = variável dependente¹⁰ ,
 X_i = variável independente¹¹ ($X_i > 0$),
 λ_i = expoente da variável X_i (constante real),
 $i = 1, \dots, n$,
 n = número de variáveis independentes,

sujeita à restrição:

$$\Psi(X_1, X_2, \dots, X_n) = \sum_{i=1}^n X_i - C_2 = 0, \quad (3.4)$$

onde C_2 é uma constante real¹² . Utilizando o método dos multiplicadores de Lagrange, pode-se achar os extremos da função (3.3) sujeita à restrição (3.4). Para tanto é necessário analisar os pontos estacionários da seguinte função de Lagrange (\mathcal{L}):

$$\mathcal{L}(X_1, X_2, \dots, X_n, \lambda) = Y + \lambda \cdot \Psi \quad (3.5)$$

9

Observe-se ao maximizar a equação (3.3) estar-se-á maximizando a equação do modelo LOG proposta (equação 3.2)

10

Y representaria o rendimento de grãos (%)

11

X_i representa, no caso, a precipitação efetiva no intervalo i (mm).

12

Em particular, C_2 é o suprimento hídrico total representado pela soma das precipitações efetivas nos n intervalos de Soma Térmica.

$$\text{ou } \mathcal{L}(X_1, X_2, \dots, X_n, \lambda) = \prod_{i=1}^n X_i^{\lambda_i + \lambda} \left[\sum_{i=1}^n X_i - C_2 \right] \quad (3.6)$$

onde λ é um multiplicador indeterminado, conhecido como multiplicador de Lagrange.

A condição necessária para existência de extremos é :

$$\frac{\partial \mathcal{L}}{\partial X_1} = \frac{\partial \mathcal{L}}{\partial X_2} = \dots = \frac{\partial \mathcal{L}}{\partial X_n} = \frac{\partial \mathcal{L}}{\partial \lambda} = 0, \quad (3.7)$$

e calculando (3.7) resulta o seguinte sistema:

$$\left. \begin{aligned} \frac{\lambda_1}{X_1} \cdot \prod_{i=1}^n X_i^{\lambda_i + \lambda} &= 0 \\ \frac{\lambda_2}{X_2} \cdot \prod_{i=1}^n X_i^{\lambda_i + \lambda} &= 0 \\ \cdot & \\ \cdot & \\ \frac{\lambda_n}{X_n} \cdot \prod_{i=1}^n X_i^{\lambda_i + \lambda} &= 0 \\ \sum_{i=1}^n X_i - C_2 &= 0 \end{aligned} \right\} \quad (3.8)$$

E resolvendo o sistema (3.8) acha-se somente um ponto estacionário que será chamado $P^\circ(X_i^\circ)$, onde X_i° é dado por :

$$X_i^\circ = \frac{\lambda_i \cdot C_2}{\sum_{i=1}^n \lambda_i} \quad (3.9)$$

Uma das formas para investigar o caráter e a existência de um extremo é expandir a função através da série de Taylor no ponto de interesse. O objetivo é analisar o incremento

da função neste ponto, assumindo que as condições necessárias já foram satisfeitas, que as funções (3.3) e (3.4) sejam duas vezes diferenciáveis na vizinhança do ponto P° e que todas as derivadas parciais de segunda ordem sejam contínuas em P° .

Expandindo a função (3.3) por série de Taylor no ponto P° resulta :

$$\Delta Y = \sum_{i=1}^n \frac{\partial Y}{\partial X_i} (P^\circ) \cdot dX_i + \frac{1}{2!} \sum_{i=1}^n \sum_{j=1}^n \frac{\partial^2 Y}{\partial X_i \partial X_j} (P^\circ) \cdot dX_i \cdot dX_j + \theta \quad (3.10)$$

onde θ representa termos de mais alta ordem. Da restrição (3.4) tira-se a dependência entre os dX pela relação :

$$\frac{\partial \psi}{\partial X_1} dX_1 + \frac{\partial \psi}{\partial X_2} dX_2 + \dots + \frac{\partial \psi}{\partial X_n} dX_n = 0, \quad (3.11)$$

mas como

$$\frac{\partial \psi}{\partial X_1} = \frac{\partial \psi}{\partial X_2} = \dots = \frac{\partial \psi}{\partial X_n} = 1, \quad (3.12)$$

resulta

$$\sum_{i=1}^n dX_i = 0 \quad (3.13)$$

As derivadas parciais de primeira ordem da função Y são dadas por :

$$\frac{\partial Y}{\partial X_i} = \frac{\lambda_i}{X_i} \cdot Y \quad (3.14)$$

e do sistema de equações (3.8) se observa que :

$$\frac{\lambda_1}{X_1} = \frac{\lambda_2}{X_2} = \dots = \frac{\lambda_n}{X_n} \quad (3.15)$$

portanto,

$$\frac{\partial Y}{\partial X_1}(P^0) = \frac{\partial Y}{\partial X_2}(P^0) = \dots = \frac{\partial Y}{\partial X_n}(P^0) = K_1 \quad (3.16)$$

onde K_1 é uma constante. As derivadas parciais de segunda ordem da função Y são dadas por :

$$\frac{\partial^2 Y}{\partial X_i \partial X_j} = \frac{\lambda_i \lambda_j}{X_i X_j} Y - \alpha \frac{\lambda_i}{X_i^2} Y, \quad (3.17)$$

onde

$$\alpha = \begin{cases} 0, & \text{para } i \neq j \\ 1, & \text{para } i = j \end{cases} \quad (3.18)$$

Chamando

$$K_2 = \frac{\lambda_i \lambda_j}{X_i X_j} \cdot Y(P^0) = \lambda_i \lambda_j \cdot \frac{\sum_{i=1}^n \lambda_i}{\lambda_i C_2} \cdot \frac{\sum_{i=1}^n \lambda_i}{\lambda_j C_2} \cdot Y(P^0) = \left[\frac{\sum_{i=1}^n \lambda_i}{C_2} \right]^2 \cdot Y(P^0) \quad (3.19)$$

e

$$K_3(i) = \frac{\lambda_i}{(X_i^0)^2} \cdot Y(P^0) \quad (3.20)$$

(note-se que K_2 é constante) e substituindo (3.19) e (3.20) em (3.10) vêm :

$$\Delta Y = \sum_{i=1}^n K_1 \cdot dX_i + \frac{1}{2!} \sum_{i=1}^n \sum_{j=1}^n K_2 \cdot dX_i \cdot dX_j - \frac{1}{2!} \sum_{i=1}^n K_3(i) \cdot dX_i^2 \quad (3.21)$$

mas como K_1 e K_2 são constantes, (3.21) fica :

$$\Delta Y = K_1 \sum_{i=1}^n dX_i + \frac{K_2}{2} \sum_{i=1}^n \sum_{j=1}^n dX_i \cdot dX_j - \frac{1}{2} \sum_{i=1}^n K_3(i) \cdot dX_i^2 \quad (3.22)$$

mas por outro lado,

$$\sum_{i=1}^n \sum_{j=1}^n dX_i dX_j = \left[\sum_{i=1}^n dX_i \right]^2 \quad (3.23)$$

e substituindo (3.23) em (3.22), tendo em conta (3.13), resulta finalmente :

$$\Delta Y = -\frac{1}{2} \sum_{i=1}^n K_3(i) \cdot dX_i^2 \quad (3.24)$$

Na equação (3.24) se pode observar que se todos os expoentes λ_i são positivos ($\lambda_i > 0$), $K_3(i)$ será maior que zero para todo i ($K_3(i) > 0 \forall i$). Logo, o incremento ΔY no ponto P° será negativo para quaisquer incrementos ΔX_i que satisfaçam a condição (3.13):

$$\Delta Y(P^\circ) < 0 \forall \Delta X_i$$

Desta forma fica demonstrado que P° é um ponto de máximo do problema (3.3)-(3.4).

Substituindo o ponto de máximo (equação 3.9) na equação (3.3) :

$$Y_{max} = \prod_{i=1}^n \left[\frac{\lambda_i C_2}{\sum_{i=1}^n \lambda_i} \right]^{\lambda_i} \quad (3.26)$$

Desenvolvendo (3.26) e colocando C_2 em evidência, se chega a :

$$Y_{max} = \frac{\prod_{i=1}^n \lambda_i^{\lambda_i}}{\left[\sum_{i=1}^n \lambda_i \right]^{\left[\sum_{i=1}^n \lambda_i \right]}} \cdot C_2^{\left[\sum_{i=1}^n \lambda_i \right]} \quad (3.27)$$

Chamando

$$\epsilon = \sum_{i=1}^n \lambda_i \quad (3.28)$$

e

$$\Pi = \prod_{i=1}^n \lambda_i^{\lambda_i} \quad (3.29)$$

e substituindo (3.28) e (3.29) em (3.27) se chega a :

$$Y_{max} = \frac{\Pi}{\epsilon^\epsilon} \cdot C_2^\epsilon \quad (3.30)$$

que é a equação (3.3) maximizada sujeita à restrição (3.4).

Aplicando o resultado da equação (3.30) à equação (3.2) do modelo LOG, a Função de Produção otimizada seria:

$$Y_{max} = C_1 \cdot \frac{\prod}{\epsilon^\epsilon} \cdot C_2^\epsilon \quad (3.31)$$

Observe-se que na equação (3.31) o expoente ϵ determina a concavidade, convexidade ou linearidade existente entre a produção de grãos e a lâmina total C_2 , que fisicamente significa o grau de variação dos incrementos em Y_{max} à variação dos incrementos em C_2 . Por exemplo, se $\epsilon=1$, a razão dos incrementos será constante e a declividade de Y_{max} também será constante, o que significa um processo linear. Isto é verdadeiro quando C_2 é distribuído de forma ótima, i.e., quando a distribuição da água obedece à equação (3.9). Isto quer dizer também que os rendimentos serão maximizados se os déficits forem minimizados em cada intervalo, de acordo com (3.9), para uma disponibilidade mínima C_2 .

Isto pode ser visualizado graficamente na Figura 3.2, onde a curva representa a equação (3.31), e os pontos representam os valores de rendimentos obtidos com uma distribuição não-ótima (onde a distribuição de C_2 não obedece à equação (3.9)), calculados pela expressão (3.2). Observe-se nesta Figura que os rendimentos obtidos pela equação maximizada são superiores aos obtidos com a equação (3.2), para uma mesma disponibilidade C_2 , sendo a envolvente dos pontos, à semelhança dos ensaios representados nas Figuras 2.5 e 2.6, realizados por Schneider et al. (1969) e Musick e Dusek (1971).




FIGURA 3.2 Relação entre Y_{max} , Y , $\sum \lambda_i$ e C_2

3.4.1.2 Maximização¹³ do Modelo LIN

Seja a função :

$$Y = \sum_{i=1}^n \alpha_i \cdot X_i + \beta \quad (3.32)$$

e a mesma restrição (3.4), com $\alpha_i > 0$, $X_i > 0$ e $i=1, \dots, n$.

A equação (3.32.) não se presta para a mesma análise realizada com o modelo LOG porque as derivadas parciais de (3.32) não se anulam em nenhum ponto do seu domínio. Entretanto, a questão de achar o ponto de máximo da função (3.32) não pode ser obviamente comprovada matematicamente. Mas isto não impede especular o resultado que se obtém quando simplesmente se substitue a equação (3.9), que é o resultado da maximização do Modelo Log, na equação (3.31) :

$$Y_{maxLin} = \sum_{i=1}^n \alpha_i \cdot \frac{\alpha_i \cdot C_2}{\sum_{i=1}^n \alpha_i} + \beta \quad (3.33)$$

que simplificando resulta :

$$Y_{maxLin} = \left[\frac{\sum_{i=1}^n \alpha_i^2}{\sum_{i=1}^n \alpha_i} \right] \cdot C_2 + \beta \quad (3.34)$$

13

Pede-se ao leitor que não interprete 'maximização' com o estrito sentido matemático da palavra.

e chamando :

$$\rho = \sum_{i=1}^n \alpha_i^2 \quad (3.35)$$

e

$$\delta = \sum_{i=1}^n \alpha_i, \quad (3.36)$$

substituindo (3.35) e (3.36) em (3.34) :

$$Y_{maxLin} = \frac{\rho}{\delta} \cdot C_2 + \beta \quad (3.37)$$

Como a equação (3.32) é linear, somente se pode esperar que a curva (3.37) seja igual à curva de Y_{max} , obtida a partir do modelo LOG, se as seguintes relações são satisfeitas :

$\epsilon=1$, $\beta=0$, e se ambas as declividades são idênticas, o que implica em :

$$C_1 \cdot \Pi = \frac{\rho}{\delta} \quad (3.38)$$

Quando se ajusta o modelo LIN a um processo, está-se forçando a linearidade do processo ao efeito das variáveis independentes, o que constitui uma restrição à adoção desta equação para representar processos não-lineares. Por esta razão, aqui considera-se o Modelo LIN como caso particular do modelo LOG na representação de um processo linear ($\epsilon=1$). Entretanto, quando se trata de processos quase lineares (que é o nosso caso), a diferença entre as curvas (3.37) e (3.31) poderá não ser significativa, como se verá mais adiante nos resultados, onde se comparam estas duas equações.

3.4.2 Estimação da melhor época de semeadura com base em precipitações e temperaturas.

Geralmente, as recomendações para as épocas preferenciais de plantio ou semeadura provém de ensaios experimentais contínuos de semeadura em várias épocas no mesmo período agrícola, conhecido no Rio Grande do Sul como 'ensaios ecológicos', realizado pela Secretaria da Agricultura. Estes ensaios são repetidos por alguns anos, e os rendimentos médios de cada época refletem a sensibilidade da cultura ao efeito da mudança das variáveis meteorológicas, uma vez que todos os outros fatores que afetam o rendimento supõem-se constantes.

Devido ao rigorismo experimental e longos períodos de observação requeridos, os ensaios ecológicos são dispendiosos em recursos e mão-de-obra. Além disto, é necessário um período extenso de observação experimental para que os rendimentos médios de cada época reflitam as condições meteorológicas médias da mesma época de semeadura. Quando um modelo representa a variação dos rendimentos de uma cultura, levando em conta uma variável climática derivada, que estima razoavelmente a ocorrência de fases fenológicas, e se esta variável climática derivada não varia em função do tempo, a ocorrência das fases fenológicas e o consumo de água da planta serão função desta variável derivada e não do tempo. No caso, a variável derivada é a Soma Térmica, supondo que os requerimentos térmicos do milho permaneçam constantes, independente da data de semeadura. Contudo, Daynard (1972), citado por Lorber e Haith (1981), mostra que a soma térmica total requerida pelo milho varia muito pouco, mas que as porcentagens deste valor apresentaram uma distribuição desigual nas fases fenológicas em função da data de semeadura. Mas Gilmore e Rogers (1958) não acharam um impacto consistente da data de semeadura nos requerimentos térmicos do milho até o florescimento.

Baseando-se na hipótese de que os requerimentos térmicos do milho para atingir as fases fenológicas permanecem constantes, o que na realidade é uma aproximação (mais uma fonte de erros), podem ser simuladas séries de rendimentos com base em séries históricas de precipitação e temperaturas diárias, já dispondo dos parâmetros estimados. Cada série de rendimentos gerada corresponde a uma época de semeadura. No Rio Grande do Sul, o período agrícola para as culturas de verão começa aproximadamente em Agosto e pode ir até Maio, sendo que o plantio do milho pode ser realizado a partir de Agosto até fins de

Dezembro e início de Janeiro.

No trabalho, o período coberto para análise foi de 1º de Setembro até 31 de Dezembro, distribuindo as épocas de sementeira de dez em dez dias, aproximadamente. Recomenda-se para este tipo de análise séries históricas com pelo menos vinte anos de extensão.

A estimativa da melhor época de sementeira consiste em analisar o comportamento dos rendimentos médios da série gerada para cada época de sementeira. Obviamente, a melhor época de sementeira deverá ser aquela em que o rendimento médio é maior.

Os modelos utilizados para simular rendimentos não levam em conta a temperatura do solo para germinação, excesso de umidade na data de plantio, ocorrência de geadas e granizo, etc., e por esta razão a data de sementeira estimada pelo modelo como melhor, pode não corresponder do ponto de vista prático. Por conseguinte, os resultados obtidos por tais modelos devem ser utilizados como orientação na falta de ensaios experimentais consistentes.

3.4.3 Prognóstico do rendimento final em função do avanço da Soma Térmica

Na agricultura é interessante estimar o rendimento final de uma cultura antes da colheita, devido a que tal estimativa pode constituir uma base para tomada de decisões relativas aos fatores envolvidos com a produção.

Arkin et al. (1977) salientam que o conhecimento antecipado de um valor de produção ajuda a avaliar as melhores épocas de plantio, taxas de aplicação de fertilizantes, taxas de irrigação, mão-de-obra e armazenamento de grãos. Quando a área abrangida pelo prognóstico é significativa na produção de grãos a nível estadual ou nacional, o prognóstico pode afetar as taxas de mercado.

Estes autores associaram um modelo que estima rendimentos de sorgo em função de variáveis meteorológicas estocásticas, com funções de probabilidade. O propósito era fazer previsões de rendimento de sorgo antes da colheita. Eles apresentam um evento para validar o procedimento, onde se fazem estimativas de rendimento no início, aos 30, 45, 60 e 75 dias após a emergência, sendo que a colheita aconteceu no 97º dia.

Para realizar as estimativas adotaram o intervalo 20-80% da distribuição de probabilidades acumulada de rendimentos. A medida que o tempo transcorre após a emergência, o modelo é atualizado com a informação meteorológica ocorrida até o momento do novo prognóstico, reduzindo a faixa de rendimentos estimada e aumentando a precisão do prognóstico. O rendimento observado no evento foi de 4400 Kg/ha e o intervalo do último prognóstico (no 75° dia) foi de 2400-6000 Kg/ha, com mediana 4800 Kg/ha.

Com as mesmas idéias e propósitos de Arkin et al.(1977), aqui se descreve o procedimento para prognosticar o rendimento final do milho em função do avanço da Soma Térmica.

O prognóstico consiste em analisar as frequências dos rendimentos de milho geradas pelo modelo com as séries sintéticas de precipitação efetiva, geradas estocasticamente, nos intervalos de Soma Térmica X_1, X_2, X_3 e X_4 , sendo que a cada data de semeadura estão associados uma média X_m e um desvio σ .

Como o modelo inclui quatro intervalos de Soma Térmica ($n = 4$), o prognóstico é efetuado na data de semeadura e ao fim dos intervalos de Soma Térmica, totalizando quatro estágios:

1. Desconhecendo X_1, X_2, X_3 e X_4
2. Desconhecendo X_2, X_3 e X_4
3. Desconhecendo X_3 e X_4
4. Desconhecendo X_4

A medida que a planta se desenvolve, primeiramente se conhece X_1 , após X_1 e X_2 , e no estágio 4 se conhecem X_1, X_2 e X_3 . Desta forma, as probabilidades acumuladas dos rendimentos são condicionadas aos valores que por ventura já se conhecem, dependendo do estágio em que o prognóstico é realizado. O modelo se atualiza com estes valores conhecidos, fornecendo uma faixa mais estreita de rendimentos estimados para um mesmo intervalo de probabilidades acumulada.

O prognóstico do rendimento final no estágio 4 pode ser fortalecido pela estimativa de uma equação de regressão que somente inclua as variáveis X_1, X_2 e X_3 , se esta o permitir.

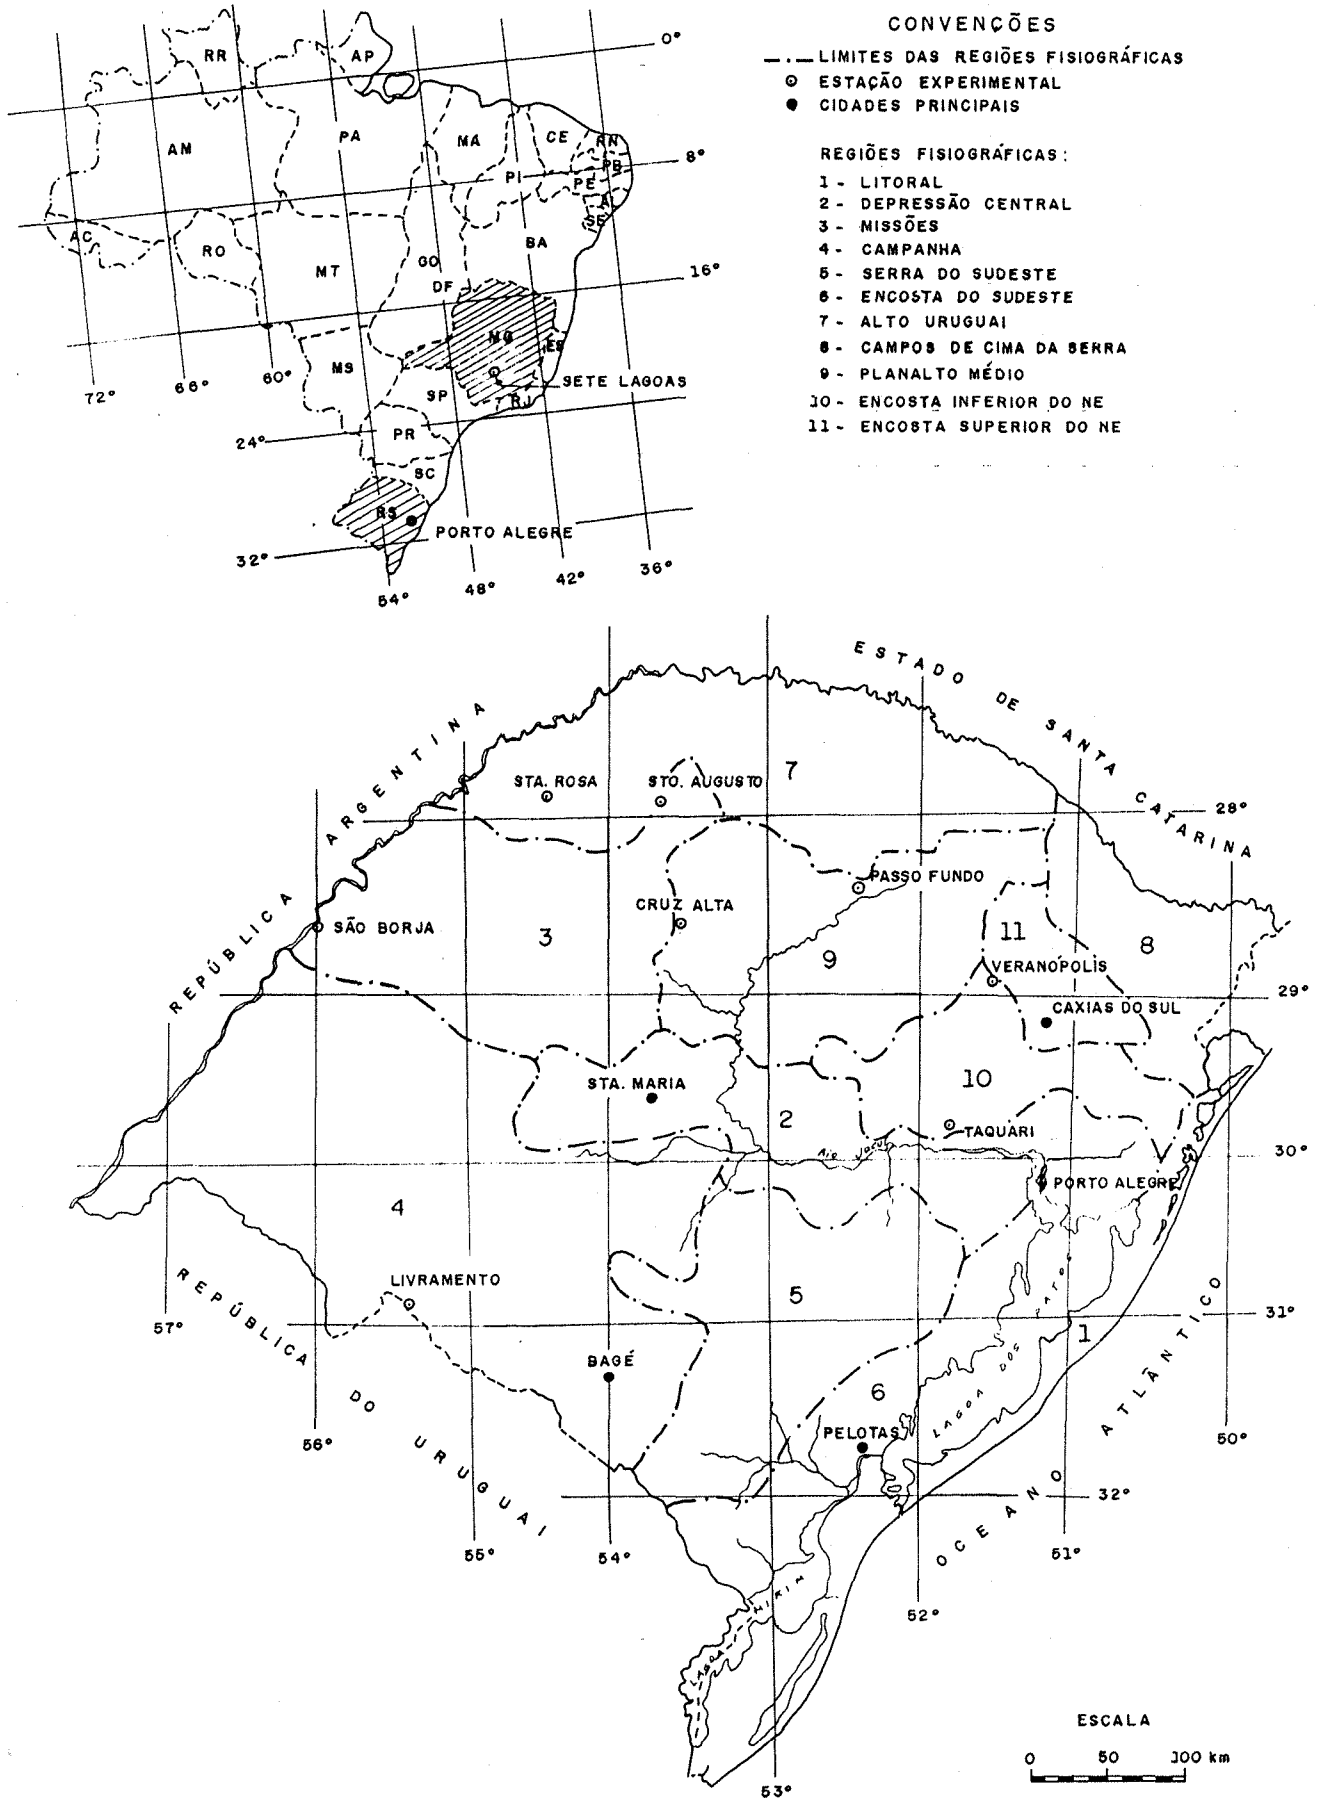


FIGURA 4.1 Localização das estações experimentais (do IPAGRO) estudadas.

4. Breve descrição agrometeorológica das Estações Experimentais

Neste capítulo se apresentam algumas informações básicas de solo e clima onde estão assentadas as estações experimentais. A classificação dos solos descrita, bem como a classificação climática segundo Koeppen, obedecem ao 'Levantamento de Reconhecimento dos Solos do estado do Rio Grande do Sul, Boletim Técnico N° 30, Ministério da Agricultura.1973'. Neste Boletim aparecem três classificações:

- a) Classificação brasileira, segundo a Divisão de Pesquisa Pedológica do Ministério da Agricultura.
- b) Classificação segundo USDA, Supplement to Soil Classification System (7th Approximation). Washington, 1967.
- c) Classificação segundo FAO. Key to Soil units for the Soil Map of the World. Land Water Division. Roma. 1970.

Os valores das características físico-hídricas apresentados foram cedidos pelo Setor de Irrigação e Drenagem do IPH/UFRGS, e devem ser vistos apenas para se ter uma idéia da grandeza destes valores, dada a variabilidade espacial dos mesmos.

As estatísticas climáticas que constam nas tabelas foram obtidas de 'Observações Meteorológicas no estado do Rio Grande do Sul. Boletim Técnico N° 30. Instituto de Pesquisas Agronômicas. Secretaria da Agricultura.RS.' Estes valores dão uma visão global do comportamento das variáveis climáticas mais importantes na produção, dentro do período agrícola (setembro - maio), para as culturas de verão. Nestas tabelas se apresentam:

- Número total mensal de geadas ocorrido durante todo o período de observação.
- Número total mensal de dias em que ocorreu precipitação com ou de granizo durante todo o período de observação.
- Temperatura máxima média mensal (°C).
- Temperatura mínima média mensal (°C)
- Precipitação média mensal (mm).
- Número médio mensal de dias em que ocorreu precipitação \leq 1 mm.
- Precipitação máxima mensal ocorrida em 24 horas (mm).

4.1 Estação Experimental de Taquari - RS

LOCALIZAÇÃO GEOGRÁFICA

Latitude : 29° 48'

Longitude : 51° 49'

Altitude : 76 m

CARACTERÍSTICAS GERAIS DO SOLO (unidade de mapeamento Rio Pardo)

Predominam nesta unidade solos profundos, argilosos e bem drenados. Fertilidade natural baixa. Estes solos constituem uma área de 2120 quilômetros quadrados, representando aproximadamente 0.79 % da área do Estado.

Densidade do solo : 1.4 g/cm³

Porosidade : 46 %

Capac. Armazto. : 56 mm, 0-40 cm, 0.1-15 atm

CLASSIFICAÇÃO DO SOLO

a) LATERÍTICO BRUNO AVERMELHADO DISTRÓFICO textura argilosa relevo ondulado substrato siltito.

b) PALEUDULT

c) DYSTRIC NITOSOLS

CLASSIFICAÇÃO DO CLIMA SEGUNDO KÖEPPEN : Cfa 2 (subtropical úmido sem estiagem)

Tabela 4.1 Estatísticas climáticas Est Exp Taquari - RS¹⁴

	set	out	nov	dez	jan	fev	mar	abr	mai
<u>Variável climática</u>									
Nº total geadas	14	0	0	0	0	0	0	2	14
Nº total granizo	10	0	1	0	5	1	2	0	0
Tmax média (°C)	22.2	24.4	26.9	29.4	30.5	30.1	27.9	25.1	22.4
Tmin média (°C)	12.4	13.9	15.7	17.8	19.4	19.6	18.2	14.7	12.3
Precip. média (mm)	141	106	90	112	145	130	130	77	89
Nº dias c/precip.	9	8	7	8	10	9	9	7	7
Prec.máx.24 hs (mm)	68	66	67	67	73	117	75	58	80

4.2 Estação Experimental de Veranópolis - RS

LOCALIZAÇÃO GEOGRÁFICA

Latitude : 28° 56'
 Longitude : 51° 33'
 Altitude : 705 m

CARACTERÍSTICAS GERAIS DO SOLO (unidade de mapeamento Carlos B.)

Predominam nesta unidade solos medianamente profundos, moderadamente drenados, com cores bruno-escuras a bruno avermelhadas, textura franca a franco-argilosa no horizonte A e argilosa no B. Fertilidade natural moderada. Ocorrem numa área de 3180 quilômetros quadrados, o que representa 1.18 % da área do Estado.

CLASSIFICAÇÃO DO SOLO

- a) LATERÍTICO BRUNO AVERMELHADO DISTRÓFICO textura argilosa relevo forte ondulado substrato basalto.
- b) HAPLUDULT
- c) FERRIC ACRISOLS

CLASSIFICAÇÃO DO CLIMA SEGUNDO KOEPPEN : Cfb 1
 (temperado)

Tabela 4.1 Estatísticas climáticas Est Exp Veranópolis - RS¹⁵

	<u>set</u>	<u>out</u>	<u>nov</u>	<u>dez</u>	<u>jan</u>	<u>fev</u>	<u>mar</u>	<u>abr</u>	<u>mai</u>
<u>Variável climática</u>									
Nº total geadas	36	21	5	0	0	0	1	13	48
Nº total granizo	10	6	4	3	6	1	1	4	2
Tmax média (°C)	20.1	22.0	24.3	26.1	26.1	26.3	24.8	21.9	19.6
Tmin média (°C)	10.6	12.0	13.6	15.3	16.7	16.6	15.4	12.5	10.0
Precip.média (mm)	181	147	127	156	147	122	135	94	84
Nº dias c/precip.	11	10	9	9	11	10	10	8	7
Prec.max.24 hs(mm)	99	111	109	102	82	68	89	82	82

4.3 Estação Experimental de Santo Augusto - RS

LOCALIZAÇÃO GEOGRÁFICA

Latitude : 27° 54'
 Longitude : 53° 45'
 Altitude : 380 m

CARACTERÍSTICAS GERAIS DO SOLO (unidade de mapeamento S. Angelo)

São solos profundos (>200 cm), podendo atingir 400 cm, bem drenados, friáveis e de coloração vermelha escura, com baixa fertilidade natural. Este tipo de solo ocorre em aproximadamente 19560 quilômetros quadrados, representando 7.26% do território do Rio Grande do Sul.

Densidade do solo : 1.16 g/cm³
 Porosidade : 56 %
 Capac. Armazto. : 68 mm, 0-40 cm, 0.1 - 3 atm

CLASSIFICAÇÃO DO SOLO

- a) LATOSOL ROXO DISTRÓFICO textura argilosa relevo ondulado substrato basalto.
- b) HAPLORTHOX
- c) RHODIC FERRALSOLS

CLASSIFICAÇÃO DO CLIMA SEGUNDO KOEPPEN : Cfa 1g
 (tropical úmido sem estiagem)

Tabela 4.1 Estatísticas climáticas Est Exp S. Augusto - RS¹⁶

	set	out	nov	dez	jan	fev	mar	abr	mai
<u>Variável climática</u>									
Nº total geadas	5	1	0	0	0	0	0	2	5
Nº total granizo	3	3	0	2	2	0	0	0	1
Tmax média (°C)	23.6	25.8	27.6	29.7	29.7	29.3	28.2	25.6	22.5
Tmin média (°C)	12.8	13.5	14.8	17.8	19.2	18.9	17.6	13.8	12.3
Precip.média (mm)	142	132	116	179	175	106	131	101	152
Nº dias c/precip.	9	8	7	9	11	9	12	6	7
Prec.max.24 hs (mm)	83	112	90	108	106	51	86	82	123

4.4 Estação Experimental de São Borja - RS

LOCALIZAÇÃO GEOGRÁFICA

Latitude : 28° 39'
 Longitude : 56° 00'
 Altitude : 99 m

CARACTERÍSTICAS GERAIS DO SOLO (unidade de mapeamento São Borja)

São solos profundos, bem drenados, vermelhos, argilosos, friáveis em toda a extensão do perfil, derivados de basalto e com fertilidade natural moderada. Estes solos perfazem uma área de 2080 quilômetros quadrados, ou seja, 0.77 % da área total do Estado.

Densidade do solo : 1.41 g/cm
 Porosidade : 44 %
 Capac. Armazto. : 128 mm, 0-40 cm, 0.1 - 3 atm

CLASSIFICAÇÃO DO SOLO

- a) LATERÍTICO BRUNO AVERMELHADO DISTRÓFICO textura argilosa relevo suavemente ondulado substrato basalto
 b) PALEUDALF
 c) DYSTRIC NITOSOLS

CLASSIFICAÇÃO DO CLIMA SEGUNDO KOEPPEN : Cfa 12

Tabela 4.1 Estatísticas climáticas Est Exp S. Borja - RS¹⁷

	set	out	nov	dez	jan	fev	mar	abr	mai
<u>Variável climática</u>									
Nº total geadas	19	0	0	0	0	0	0	0	33
Nº total granizo	6	1	2	0	1	0	0	0	1
Tmax média (' C)	23.1	25.9	28.3	30.4	31.4	31.4	29.1	24.4	23.1
Tmin média (' C)	12.1	13.7	15.6	18.2	19.8	19.5	17.8	14.9	11.9
Precip. média (mm)	128	138	132	136	137	131	152	156	104
Nº dias c/precip.	8	7	7	8	8	7	7	7	6
Prec.max.24 hs(mm)	106	112	80	75	84	108	129	93	74

4.5 Estação Experimental de Livramento - RS

LOCALIZAÇÃO GEOGRÁFICA

Latitude : 30° 53'
 Longitude : 55° 31'
 Altitude : 210 m

CARACTERÍSTICAS GERAIS DO SOLO

A Estação Experimental de Livramento está assentada sobre a associação das unidades de mapeamento Livramento e São Pedro, mas a classificação apresentada é da unidade de mapeamento Livramento.

CLASSIFICAÇÃO DO SOLO

- a) SOLOS BRUNOS GLEIZADOS DISTRÓFICOS textura argilosa relevo ondulado substrato arenito.
- b) PALEUDULT
- c) DYSTRIC NITOSOLS

CLASSIFICAÇÃO DO CLIMA SEGUNDO KÖEPPEN : Cfa 2
 (subtropical úmido sem estiagem)

Tabela 4.1 Estatísticas climáticas Est Exp S. Livramento - RS¹⁸

	<u>set</u>	<u>out</u>	<u>nov</u>	<u>dez</u>	<u>jan</u>	<u>fev</u>	<u>mar</u>	<u>abr</u>	<u>mai</u>
<u>Variável climática</u>									
Nº total geadas	42	16	0	0	0	0	0	23	53
Nº total granizo	1	3	0	0	0	0	0	1	0
Tmax média (' C)	20.7	23.0	25.2	28.5	28.7	28.3	26.7	23.8	20.5
Tmin média (' C)	10.6	12.0	13.9	16.4	17.9	17.5	16.1	12.3	10.6
Precip. média (mm)	118	121	102	96	146	138	124	90	117
Nº dias c/precip.	7	7	5	6	8	7	6	5	7
Prec.max.24 hs(mm)	69	102	72	80	97	117	95	78	107

4.6 Estação Experimental de Passo Fundo - RS

LOCALIZAÇÃO GEOGRÁFICA

Latitude : 28° 15'
 Longitude : 52° 24'
 Altitude : 709 m

CARACTERÍSTICAS GERAIS DO SOLO (unidade P. Fundo)

Predominam nesta unidade solos profundos (mais de 250 cm), argilosos, bem drenados, de coloração avermelhada e muito friáveis. Normalmente há o desenvolvimento de um horizonte B latossólico, podendo ocorrer ligeira podzolização. Fertilidade natural fraca. A área total abrangida por esta unidade é 7560 quilômetros quadrados, representando cerca de 2.8 % da área total do Estado.

Densidade do solo : 1.28 g/cm³
 Porosidade : 52 %
 Capac. Armazto. : 52 mm, 0-40 cm, 0.1 - 2 atm

CLASSIFICAÇÃO DO SOLO

- a) LATOSOL VERMELHO ESCURO DISTRÓFICO textura argilosa relevo ondulado substrato basalto
- b) HAPLORTHOX
- c) RHODIC FERRALSOLS

CLASSIFICAÇÃO DO CLIMA SEGUNDO KOEPPEN : Cfa 1

Tabela 4.1 Estatísticas climáticas Est Exp P. Fundo - RS¹⁹

	set	out	nov	dez	jan	fev	mar	abr	mai
<u>Variável climática</u>									
Nº total geadas	14	3	2	0	0	0	0	4	19
Nº total granizo	1	5	1	1	1	0	0	1	2
Tmax média (' C)	21.8	23.8	26.1	28.0	27.9	28.3	26.9	24.0	21.3
Tmin média (' C)	10.9	12.5	14.1	16.0	16.8	16.7	15.6	12.5	10.1
Precip. média (mm)	166	129	131	172	155	178	114	63	92
Nº dias c/precip.	10	10	8	9	12	10	10	6	7
Prec.max.24 hs(mm)	65	84	81	110	74	155	96	142	79

4.7 Estação Experimental de Cruz Alta - RS

LOCALIZAÇÃO GEOGRÁFICA

Latitude : 28 ' 38'
Longitude : 53 ' 36'
Altitude : 473 m

CARACTERÍSTICAS GERAIS DO SOLO (unidade Cruz Alta)

São solos profundos (mais de 250 cm), bem drenados, porosos, de coloração vermelha escura e textura média (menos de 35 % de argila), apresentando o desenvolvimento de horizonte B latossólico, com fertilidade natural pobre e sem reservas de nutrientes. Esta unidade ocupa uma área de aproximadamente 7945 quilômetros quadrados (2.95 % da área do Estado).

Densidade do solo : 1.25 g/cm Porosidade :
51 %
Capac. Armazto. : 106 mm, 0-40 cm, 0.1 -2 atm

CLASSIFICAÇÃO DO SOLO

- a) LATOSOL VERMELHO ESCURO DISTRÓFICO textura média relevo ondulado substrato arenito
- b) HAPLORTHOX
- c) ORTHIC FERRALSOLS

CLASSIFICAÇÃO DO CLIMA SEGUNDO KÖEPPEN : Cfa 1

As observações climáticas da Estação Experimental de Santo Augusto (Tabela 4.3) podem ser vistas para se ter uma idéia aproximada do comportamento das variáveis climáticas mais relevantes, dada a proximidade entre estas Estações (88 Km em linha reta), e por estarem na mesma região fisiográfica (Planalto Médio).

4.8 Estação Experimental de Santa Rosa - RS

LOCALIZAÇÃO GEOGRÁFICA

Latitude : 27° 51'

Longitude: 54° 29'

Altitude : 273 m

CLASSIFICAÇÃO DO SOLO (idem Santo Augusto, item 4.3)

A Estação Experimental de Santa Rosa fica aproximadamente a 70 Km em linha reta da Est. Exp. de Santo Augusto, e ambas pertencem à mesma região climática (Missões) e fisiográfica (Alto Uruguai). Portanto, as variáveis climáticas apresentadas para Santo Augusto poderão dar uma visão aproximada do clima da Estação de Santa Rosa.

4.9 Estação Experimental de Sete Lagoas - MG

LOCALIZAÇÃO GEOGRÁFICA

Latitude : 19° 28'

Longitude: 44° 15'

Altitude : 732 m

Como havia disponibilidade de informação de rendimentos e precipitação diária para esta localidade (sem temperaturas), aplicou-se uma análise semelhante. Porém, o trabalho não enfatiza esta Estação da mesma forma com que as outras. O objetivo de incluir Sete Lagoas no trabalho é comparar resultados com uma localidade que possui características climáticas e pedológicas bem diferenciadas, além de estar a uma distância considerável do Rio Grande do Sul (± 1800 Km), permitindo avaliar a adequacidade dos modelos em situações diferentes das que ocorrem no Rio Grande do Sul.

Capacidade de Armzto.: 76 mm (0-40 cm; 0,1-15 atm)

5. Seleção dos parâmetros J e E para estimação da precipitação efetiva

Uma vez estabelecida a amostra de rendimentos e conhecido o valor aproximado de Soma Térmica Total (STT) até a maturação, que seria a tarefa inicial, o passo seguinte foi a seleção de valores razoáveis para J e E (item 3.2.4, equações 3.4 e 3.5) com objetivo de estimar a precipitação efetiva (P_{ef}) a nível diário, ou seja, estimar a parcela da precipitação bruta (P_b) que penetra no solo e que teoricamente ficaria disponível para a planta.

Um procedimento que pode facilitar a seleção de J e E é realizar uma análise de sensibilidade do ajuste dos modelos LOG/LIN à variação destes, apoiando-se em critérios físicos que serão discutidos a seguir.

O objetivo principal de adotar um tratamento da precipitação bruta é minimizar erros grosseiros que são introduzidos na estimativa dos parâmetros dos modelos LOG/LIN, principalmente devido a intensas precipitações diárias, pois sabe-se que tais precipitações não ficam disponíveis no solo em sua totalidade. Portanto, é preciso estimar o valor máximo da precipitação que penetra e fica disponível no solo para a planta. O conhecimento das capacidades de armazenamento e velocidade de infiltração de água dos solos em questão ajuda nesta estimativa. No capítulo 4 pode ser observado que as menores capacidades de armazenamento dos solos onde estão assentadas as estações experimentais são superiores a 50 mm, na profundidade 0-40cm, entre Capacidade de Campo e Ponto de Murcha; também se observa que a maioria dos solos são profundos e bem drenados. Com base nestas informações, de antemão se pode estabelecer uma faixa razoável dos valores máximos de precipitação efetiva que poderia ficar disponível no solo. Os valores entre 30 e 70mm parecem ser razoáveis para escolher o valor de J. O restante da precipitação considera-se como excesso (escoamento superficial e/ou percolação).

Um segundo objetivo deste tratamento é descontar uma fração da precipitação bruta, à qual se atribui o significado de perdas iniciais e retenção superficial. Isto é conseguido através do expoente E, que deve ser menor do que a unidade ($E < 1$). Note-se que quando $E=1$ está se considerando a precipitação efetiva igual à precipitação bruta, enquanto $P_b < J$. Sabe-se que sempre ocorrem perdas por menores que sejam; portanto, um valor de E próximo da unidade parecería ser razoável.

Na Figura 5.1 se apresentam os resultados da análise de sensibilidade efetuada para cinco localidades, que consistiu em

ajustar ambos os modelos para 30 combinações de J e E (J = 10,30,50,70 e 90mm; E = 0.5;0.6;0.7;0.8; 0.9 e 1.0) para cada localidade, e analisar o comportamento do coeficiente de determinação R^2 . Nesta Figura se observa que os dois modelos são pouco sensíveis à variação de J, exceto quando J = 10mm, onde ocorrem diferenças significativas com relação a valores superiores de J. Para valores elevados de J (70 e 90mm) não se observa o mesmo comportamento, fato que pode ser explicado pelo padrão de precipitações diárias ocorridas durante o período coberto pela amostra. Quanto à variação de E, se observa um incremento de R^2 a medida que E se aproxima da unidade, a exceção do modelo LOG na estação Veranópolis e o modelo LIN em Santo Augusto, para J = 30,50 e 70mm, onde as diferenças no comportamento de R^2 não são significativas aparentemente.

Considerando estes resultados e tendo em conta as capacidades de armazenamento dos solos em questão e o padrão de precipitações, selecionou-se J = 50mm e E = 0.9 para todas as localidades, uma vez que a escolha de valores específicos de J e E para cada localidade não se justifica neste caso.

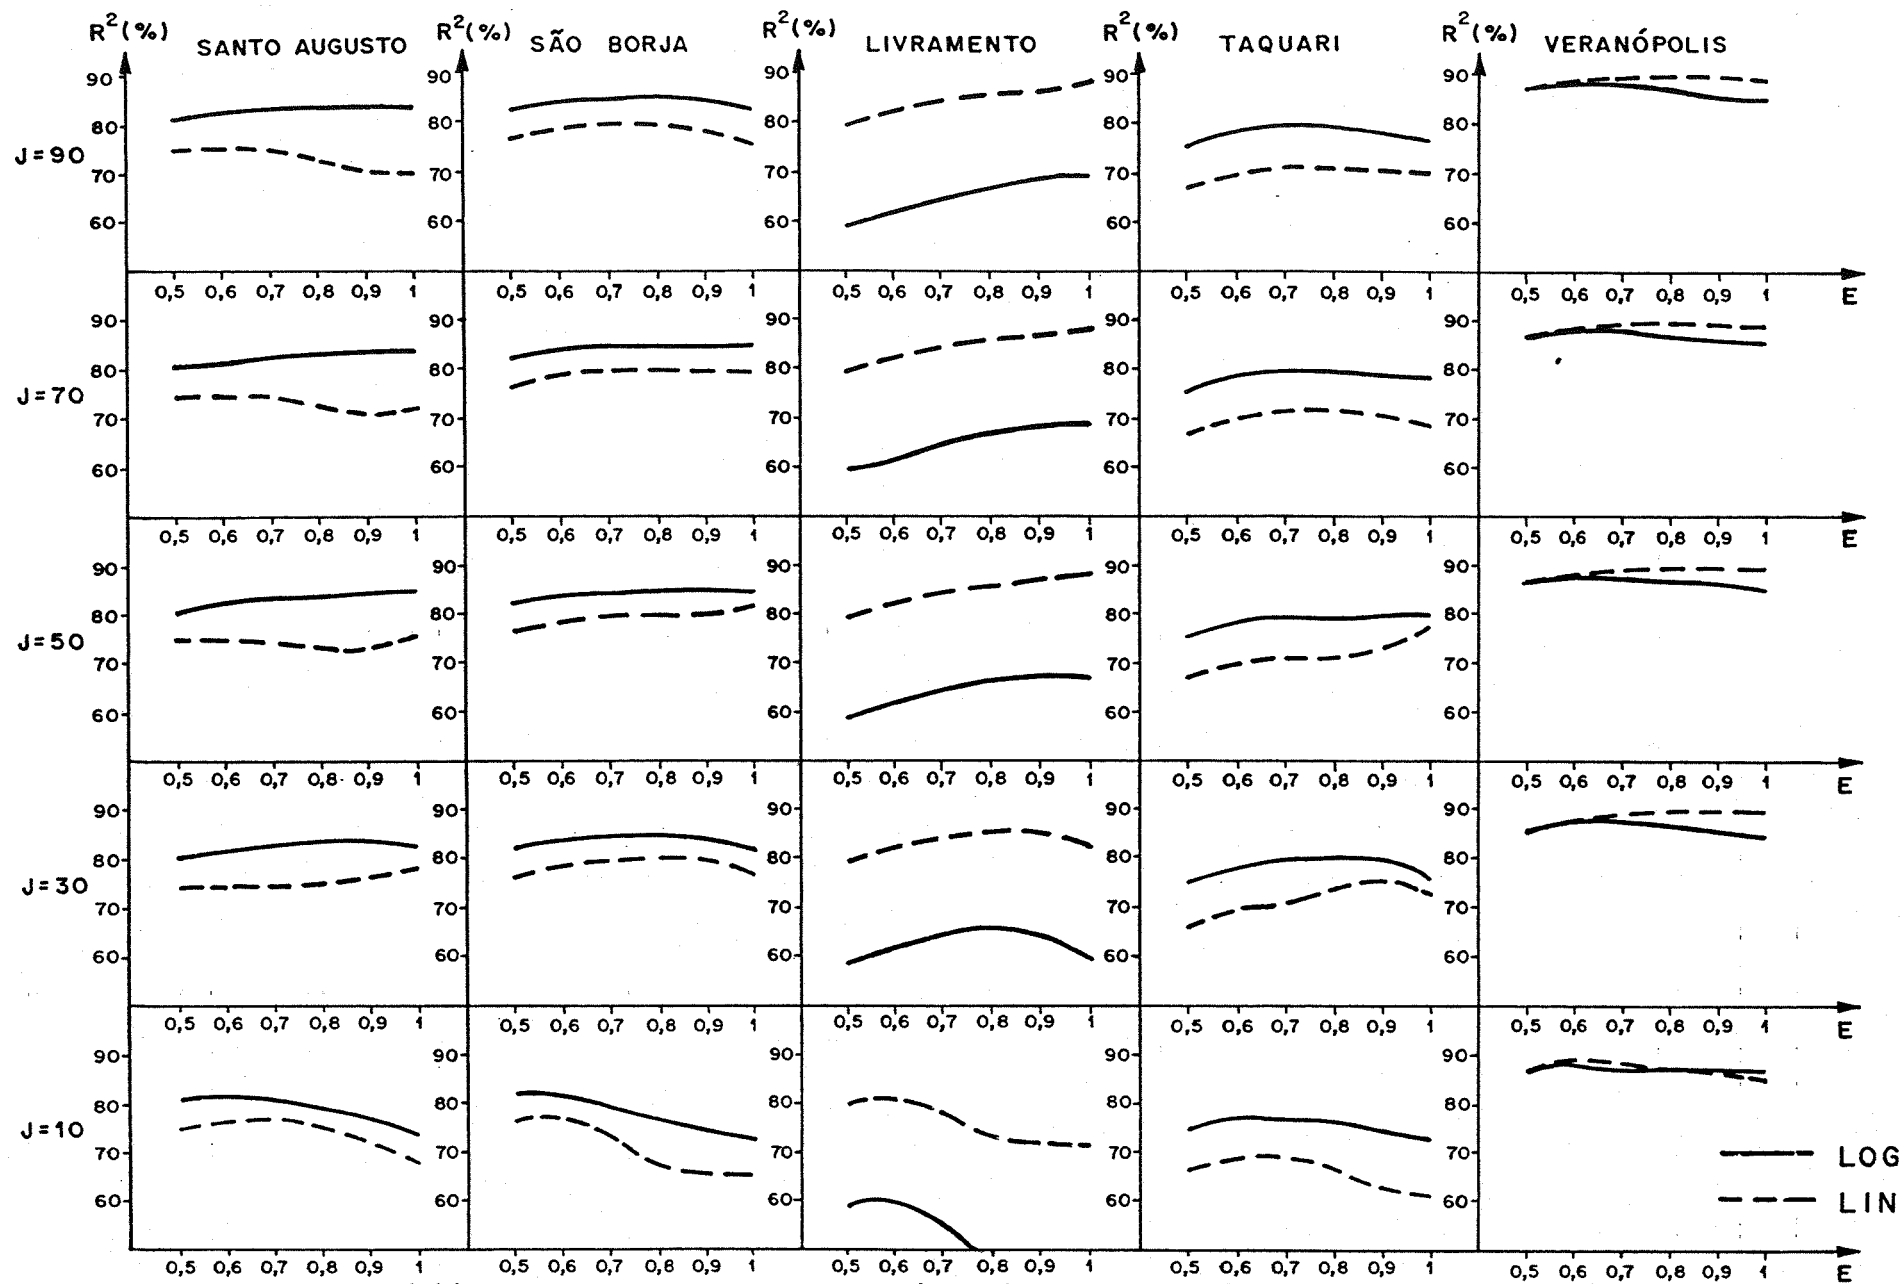


FIGURA 5.1 Sensibilidade dos Modelos LOG/LIN à variação dos parâmetros J e E para estimação da precipitação efetiva.

6. Ajuste inicial dos modelos LOG/LIN aos dados das estações experimentais

Neste capítulo se apresentam os ajustes das equações de regressão dos modelos LOG/LIN aos dados das estações experimentais já descritas no capítulo 4. Para cada estação ou posto se ajustaram os dois modelos, e inicialmente, se apresenta uma tabela onde constam as estatísticas básicas da amostra utilizada (por exemplo Tabela 6.1.1). A notação utilizada é a seguinte:

N = número de eventos ou observações

$$\text{MEDIA} = \sum_{i=1}^N X_i / N$$

MEDIANA = valor com posição $(N - 1)/2 + 1$ da série ordenada. Se N for par, a mediana é calculada através da média dos valores com posição central $N/2$ e $N/2+1$.

MEDIA-T = média truncada (Trimmed mean) nas extremidades inferior e superior da série ordenada. Após a ordenação, 5% (arredondando ao inteiro mais próximo) dos menores valores, e 5% dos maiores valores da série são excluídos, calculando assim a média com os 90% restantes.

STDEV = desvio padrão da série. STDEV é calculado por :

$$\text{STDEV} = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (X_i - X_m)^2}, \quad \text{onde } X_i \text{ é um valor}$$

observado e X_m é a média.

SEMEAN = desvio da média, e calculado por :

$$\text{SEMEAN} = \frac{\text{STDEV}}{\sqrt{N}}$$

MAX = valor máximo observado na série.

MIN = valor mínimo observado na série.

Q1, Q3 = Primeiro e terceiro quartil. MINITAB primeiro ordena os valores em ordem crescente. Q1 estará na posição $(N + 1)/4$ e Q3 estará na posição $3(N + 1)/4$. Se a posição não é um valor inteiro, é usada interpolação.

A apresentação das equações de regressão é feita da seguinte forma :

Modelo LIN :

$$Y = \beta + a_1X_1 + a_2X_2 + a_3X_3 + a_4X_4$$

Modelo LOG :

$$Y = C_1 \cdot X_1^{\lambda_1} \cdot X_2^{\lambda_2} \cdot X_3^{\lambda_3} \cdot X_4^{\lambda_4}$$

Logo abaixo destas equações se mostram :

s = desvio padrão de Y, ou o erro padrão da estimativa. Este valor fornece uma estimativa de σ , e é calculado por :

$$s = \sqrt{\frac{1}{N-2} \sum_{i=1}^N (Y_i - Y_c)^2}$$

O valor de s pode ser interpretado como uma medida de quanto diferem os valores observados (Y_i) e os valores calculados (Y_c) em média, com (N-2) graus de liberdade.

R^2 = coeficiente de determinação. Este valor é uma medida de quanto explicam as variáveis independentes a variação de Y. Uma expressão de R^2 é a seguinte :

$$R^2 = 1 - \frac{\sum_{i=1}^N (Y_i - Y_c)^2}{\sum_{i=1}^N (Y_i - Y_m)^2}$$

$R^2(NT)$ = coeficiente de determinação ajustado ou não-tendencioso. Este valor dá uma estimativa não-tendenciosa da população R^2 , e pode ser calculado por:

$$R^2(NT) = 1 - \frac{\sum_{i=1}^N (Y_i - Y_c)^2}{\sum_{i=1}^N (Y_i - Y_m)^2} \left[\frac{N-1}{N-p-1} \right]$$

Nas tabelas onde se apresentam as estatísticas das estimativas dos parâmetros (Tabela 6.1.2, por exemplo), a seguinte notação é utilizada :

Coef = valor estimado do parâmetro.
Stdev = desvio standard da estimativa do parâmetro.

razão-T = $\frac{\text{Coef}}{\text{Stdev}}$, é um valor essencial para testar a

significância da estimativa do parâmetro. Supõe-se que este valor segue uma distribuição t-Student, com N-1 graus de liberdade.

p = nível de significância associado ao valor anterior. É obtido calculando o valor acumulado de probabilidades da distribuição t-Student, com N-1 graus de liberdade. Em outras palavras, $p = P(|t_2| > t_p)$, onde t_p é da população.

Quando se descrevem as estatísticas das estimativas dos parâmetros do modelo LOG, observe-se que na coluna 'Preditor', aparecerá $\log_{10} C_1$ e não C_1 .

Nas tabelas de análise de variância (Tabela 6.1.3, por exemplo), a notação é a seguinte :

SS = soma dos quadrados;
GL = número de graus de liberdade;
MS = média da soma dos quadrados, calculada por :
MS = SS/GL;
F = MS/SS(erro). F é essencial para avaliar a significância de toda a regressão. Supõe-se que esta razão segue uma distribuição F (Fisher-Snedecor);
p = nível de significância ou probabilidade

associada ao valor de F anterior, com p' graus de liberdade para o numerador e $N-p'-1$ graus de liberdade para o denominador, onde p' é o número de variáveis independentes ($p = P \langle F \rangle F_p$);

SEQ SS = subdivisão de SS(regressão) explicada por cada variável independente. Este valor mostra a relevância de cada variável X_i na regressão.

Observe-se que os valores que constam na tabela de análise de variância, para o caso do modelo LOG, se referem aos logaritmos, e não aos valores originais. Idem para o desvio-padrão das estimativas (s).

6.1 Estação experimental de Taquari-RS

Através de uma análise visual dos parâmetros das equações, do coeficiente de determinação, e com base em ensaios locais para avaliação da soma térmica requerida até a maturação fisiológica, o valor de 1400°C se mostrou significativo para estimar rendimentos. Portanto, tomaram-se quatro períodos parciais de soma térmica de 350°C (0-350, 351-700, 701-1050, 1051-1400°C). Pode ser que o valor total de soma térmica não coincida exatamente com a maturação fisiológica, mas pode ser um valor aproximado. Esta observação aplica-se a todas as estações experimentais estudadas.

A maioria dos eventos (N = 31) utilizados na amostra desta estação provém das médias entre os híbridos Agrocerees 64 (precoce), Pioneer 6872 (precoce) e Pioneer 6874 (precoce), cujos experimentos foram conduzidos pela Seção de Ecologia do IPAGRO. Na amostra foram incluídos também rendimentos médios de ensaios estaduais de híbridos comerciais precoces.

O período envolvido pelos eventos está entre 1970-1986, sendo que um ou mais eventos pertencem ao mesmo ano agrícola, mas em épocas de semeadura diferentes.

A seguir se apresenta uma tabela (Tab. 6.1) onde se observam as estatísticas básicas da série dos rendimentos Yobs(%) e as precipitações efetivas observadas X_1 , X_2 , X_3 e X_4 , em mm.

Tabela 6.1 Descrição estatística da amostra de Taquari

	Yobs (%)	X1 (mm)	X2 (mm)	X3 (mm)	X4 (mm)
N	31	31	31	31	31
MEDIA	44.6	113.8	71.3	65.7	71.3
MEDIANA	46.0	111.0	67.0	68.0	55.0
MEDIA-T	44.6	110.0	68.1	63.9	68.0
STDEV	15.0	55.8	44.5	35.0	46.1
SEMEAN	2.7	10.0	8.0	6.3	8.3
MAX	70.0	259.0	191.0	163.0	189.0
MIN	18.0	22.0	8.0	4.0	8.0
Q3	53.0	138.0	91.0	89.0	103.0
Q1	30.0	78.0	37.0	37.0	37.0

6.1.1 Ajuste do Modelo LIN. Taquari -RS.

Equação de regressão :

$$Y = 0.02 + 0.0204 X_1 + 0.276 X_2 + 0.238 X_3 + 0.0973 X_4 \quad (6.1.1)$$

$$s = 6.086 \quad R = 85.7\% \quad R^2(\text{NT}) = 83.5\%$$

Tabela 6.1.1. Estatísticas dos parâmetros estimados. Modelo LIN, Estação experimental de Taquari, RS.

Preditor	Coef	Stdev	razão-T	p
β	0.022	4.837	0.00	0.996
a_1	0.02042	0.02212	0.92	0.365
a_2	0.27579	0.02772	9.95	0.000
a_3	0.23849	0.03407	7.00	0.000
a_4	0.09726	0.02582	3.77	0.001

Tabela 6.1.2 Análise de Variância. Modelo LIN, Estação experimental de Taquari, RS.

ORIGEM	GL	SS	MS	F	P
Regressão	4	5790.2	1447.6	39.08	0.000
Erro	26	963.1	37.0		
Total	30	6753.4			
ORIGEM	GL	SEQ SS			
a_1	1	231.5			
a_2	1	3546.3			
a_3	1	1486.8			
a_4	1	525.6			




Figura 6.1.1. Rendimentos observados $Y_{obs}(\%)$ vs Rendimentos estimados pelo Modelo LIN $Y_{cLIN}(\%)$. Estação experimental de Taquari-RS.

Os valores descritos na Tabela 6.1 mostram que as séries de rendimentos e precipitações variaram bastante. O rendimento mínimo observado foi de 18 % (1440 Kg/ha) e um máximo de 5600 Kg/ha, com média 3568 Kg/ha. Nas precipitações se observa uma variação mais acentuada, sendo que foram registrados valores mínimos de precipitação de 8 e 4 mm em X2 e X3, respectivamente.

No gráfico da Fig. 6.1.1 se observa um ajuste razoável para valores baixos, médios e altos de rendimento. A regressão revelou ser significativa estatisticamente ($F = 39.08$), apesar que a significância do termo constante esteja comprometida pelo valor de $P(0.996)$. Contudo, como o valor da constante é pequeno (0.02), e a média dos rendimentos observados possui ordem de grandeza muito superior (44.6 %), este fato não compromete as estimativas, e desta forma o efeito negativo da constante é mínimo.

As variáveis que apresentaram maior relevância no rendimento foram X2 e X3 (também apresentaram o menor desvio dos coeficientes), cujos coeficientes se mostraram significativos.

6.1.2 Ajuste do Modelo LOG. Taquari -RS.

Equação de regressão :

$$Y=0.893X_1^{0.078} X_2^{0.369} X_3^{0.355} X_4^{0.142} \quad (6.1.2)$$

$$s = 0.05304 \quad R^2 = 90.6\% \quad R^2(\text{NT}) = 89.2\%$$

Tabela 6.1.3 Estatísticas dos parâmetros estimados. Modelo LOG, Estação experimental de Taquari-RS.

Preditor	Coef	Stdev	razão-T	P
C ₁	-0.0494	0.1269	-0.39	0.700
λ ₁	0.07759	0.04339	1.79	0.085
λ ₂	0.36925	0.03396	10.87	0.000
λ ₃	0.35527	0.03301	10.76	0.000
λ ₄	0.14210	0.03025	4.70	0.000

Tabela 6.1.4 Análise de Variância. Modelo LOG, Estação experimental de Taquari-RS

ORIGEM	GL	SS	MS	F	P
Regressão	4	0.70631	0.17658	62.76	0.000
Erro	26	0.07315	0.00281		
Total	30	0.77946			
ORIGEM	GL	SEQ SS			
λ ₁	1	0.01983			
λ ₂	1	0.28433			
λ ₃	1	0.34008			
λ ₄	1	0.06207			

A seguir mostra-se o gráfico rendimento observado Yobs(%) vs rendimento calculado pelo Modelo LOG YcLOG(%):

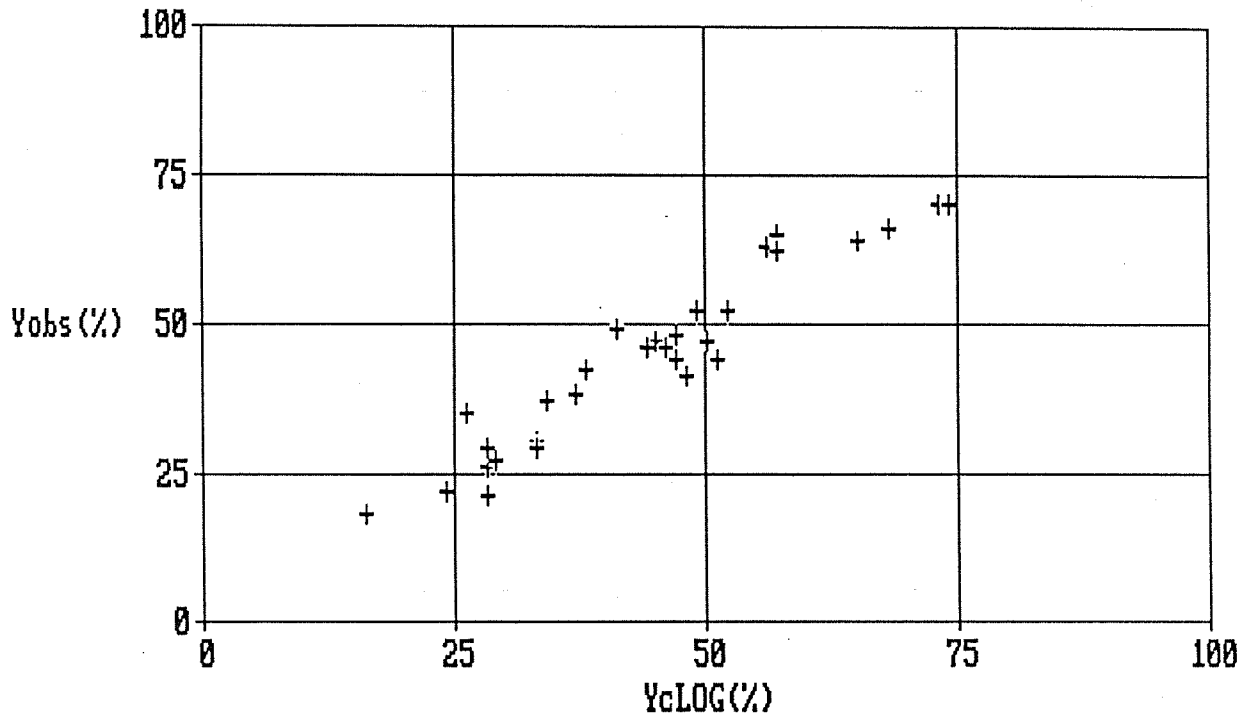


Figura 6.1.2 Rendimento observado vs rendimento calculado(LOG). Taquari-RS.

Na Fig. 6.1.2 se pode observar uma leve aproximação dos pontos que estavam mais afastados da reta 1:1 no ajuste do Modelo LIN. No Modelo LOG, a variável que apresentou uma maior soma de quadrados (SEQ SS) foi a variável λ_3 , ao contrário do ajuste anterior, que foi λ_2 . Por uma razão fenológica é de se esperar, para o caso do milho, que a variável mais importante seja λ_3 (precipitação efetiva no intervalo 700-1050°C), já que neste intervalo de soma térmica ocorrem processos reprodutivos importantes nesta cultura (pendoamento, espigamento) e uma porção significativa do enchimento de grãos.

A significância do termo constante se mostrou melhor do que no ajuste do Modelo LIN; o coeficiente de determinação melhorou e a estatística F aumentou para 62.76.

6.1.3 Ajuste do Modelo LOG3. Taquari -RS.

Equação de regressão (dos logaritmos):

$$Y = 0.163 + 0.121 X_1 + 0.333 X_2 + 0.362 X_3 \quad (6.1.3)$$

Tabela 6.1.5 Estatísticas dos parâmetros estimados utilizando somente 3 preditores (λ_1, λ_2 e λ_3). Taquari -RS.

Preditor	Coef	Stdev	razão-T	P
C_1	0.1625	0.1582	1.03	0.314
λ_1 (mm)	0.12128	0.05655	2.14	0.041
λ_2 (mm)	0.33338	0.04414	7.55	0.000
λ_3 (mm)	0.36247	0.04399	8.24	0.000

$$s = 0.07077 \quad R^2 = 82.7\% \quad R^2(\text{NT}) = 80.7\%$$

Tabela 6.1.6 Análise de Variância. Regressão com λ_1, λ_2 e λ_3 . Estação experimental de Taquari-RS.

ORIGEM	GL	SS	MS	F	P
Regressão	3	0.64424	0.21475	42.88	0.000
Erro	27	0.13522	0.00501		
Total	30	0.77946			

Esta regressão se mostrou significativa para estimar rendimentos. A vantagem de usar esta regressão será discutida em capítulo posterior. Note-se que a significância do termo constante melhorou bastante em relação aos ajustes anteriores.

6.2 Estação experimental de Veranópolis-RS.

A amostra de rendimentos constituída para esta estação inclui 35 eventos, dos quais a maioria foram obtidos da média entre os híbridos precoces Pioneer 309-B e Pioneer X-307, em ensaios ecológicos conduzidos pela seção de ecologia do IPAGRO, entre 1976 e 1983. Para aumentar o tamanho da amostra foram incluídos rendimentos médios dos Ensaio Estaduais de Híbridos Comerciais Precoces, conduzidos entre 1970 e 1985.

Para esta estação, o valor de STT que se mostrou significativo para estimar rendimentos foi 1200°C. Sendo assim, tomaram-se quatro intervalos de 300°C.

A seguir se apresenta a Tabela 6.2.1, onde constam as estatísticas básicas mais importantes de toda a amostra, incluindo os rendimentos e as precipitações efetivas nos quatro intervalos.

Tabela 6.2.1 Descrição estatística da amostra, Veranópolis-RS.

	Yobs	X ₁	X ₂	X ₃	X ₄
N	35	35	35	35	35
MEDIA	36.1	111.3	91.8	74.2	66.8
MEDIANA	31.0	121.0	81.0	74.0	64.0
MEDIA-T	35.5	109.4	86.2	73.3	66.3
STDEV	16.2	53.8	60.9	35.0	31.9
SEMEAN	2.7	9.1	10.3	5.9	5.4
MAX	67.0	283.0	275.0	157.0	134.0
MIN	15.0	8.0	8.0	8.0	14.0
Q3	48.0	140.0	118.0	94.0	86.0
Q1	22.0	81.0	53.0	54.0	38.0

Os rendimentos variaram entre 15% (1200 Kg/ha) e 67% (5360 Kg/ha), apresentando média 36.14% (2890 Kg/ha), mediana 31% (2480 Kg/ha) e desvio 16.2% (1296 Kg/ha). Pode ser observado nesta tabela que ocorreram situações de stress nos quatro intervalos de soma térmica, evidenciado pelos valores mínimos (MIN), e que no período considerado crítico (X₃), 75% das precipitações efetivas ocorreram abaixo de 94 mm.

6.2.1 Ajuste do Modelo LIN, Veranópolis-RS.
Equação de regressão:

$$Y = -9.94 + 0.0747 X_1 + 0.129 X_2 + 0.246 X_3 + 0.115 X_4 \quad (6.2.1)$$

$$s = 5.583 \quad R^2 = 89.5\% \quad R^2(\text{NT}) = 88.1\%$$

Tabela 6.2.2 Estatísticas dos parâmetros estimados.
Modelo LIN, Veranópolis-RS.

Preditor	Coef	Stdev	razão-T	p
β	-9.942	3.401	-2.92	0.007
a_1	0.07467	0.02004	3.73	0.001
a_2	0.12883	0.01781	7.23	0.000
a_3	0.24640	0.02819	8.74	0.000
a_4	0.11478	0.03114	3.69	0.001

Tabela 6.2.3 Análise de Variância. Modelo LIN, Veranópolis-RS.

ORIGEM	GL	SS	MS	F	p
Regressão	4	7983.0	1995.8	64.02	0.000
Erro	30	935.2	31.2		
Total	34	8918.3			
ORIGEM	GL	SEQ SS			
a_1	1	3148.9			
a_2	1	2254.9			
a_3	1	2155.7			
a_4	1	423.6			

Pela Tabela 6.2.2 se observa que as estimativas dos parâmetros são altamente significativas, evidenciado por 'p'. O desvio da estimativa (s) foi baixo, com valor 5.58% (447 Kg/ha), e a equação de regressão apresentou $R^2(\text{NT}) = 88.1\%$.

A estatística F da Tabela 6.2.3 mostra que a regressão é significativa para estimar rendimentos. Na parte inferior desta tabela se observa que a variável X_4 apresenta a menor Soma dos Quadrados parcial (SEQ SS), seguida por X_3 , X_2 e X_1 .

A Figura 6.2.1 mostra um bom ajuste das estimativas para valores altos e baixos de rendimento.




Figura 6.2.1 Rendimentos observados (Yobs) vs rendimentos estimados pelo Modelo LIN (YcLIN), Veranópolis-RS.

6.2.2 Ajuste do Modelo LOG. Veranópolis-RS.

Equação de regressão:

$$Y = 0.369X_1^{0.162}X_2^{0.265}X_3^{0.409}X_4^{0.226} \quad (6.2.2)$$

$$s = 0.07758 \quad R^2 = 86.4\% \quad R^2(\text{NT}) = 84.6\%$$

Tabela 6.2.4 Estatísticas dos parâmetros estimados. Modelo LOG. Veranópolis-RS

Preditor	Coef	Stdev	razão-T	p
C ₁	-0.4330	0.1537	-2.82	0.008
λ ₁ (mm)	0.16194	0.04933	3.28	0.003
λ ₂ (mm)	0.26523	0.04452	5.96	0.000
λ ₃ (mm)	0.40874	0.04670	8.75	0.000
λ ₄ (mm)	0.22560	0.05508	4.10	0.000

Tabela 6.2.5 Análise de Variância. Modelo LOG, Veranópolis-RS.

ORIGEM	GL	SS	MS	F	p
Regressão	4	1.15083	0.28771	47.80	0.000
Erro	30	0.18057	0.00602		
Total	34	1.33140			
ORIGEM	GL	SEQ SS			
λ_1	1	0.34072			
λ_2	1	0.29071			
λ_3	1	0.41841			
λ_4	1	0.10099			




Figura 6.2.2 Rendimentos observados (Yobs) vs rendimentos estimados pelo Modelo LOG (YcLOG), Veranópolis-RS.

A Tabela 6.2.4 apresenta uma significância elevada para todos os parâmetros estimados, principalmente para os preditores X_2 , X_3 e X_4 , devido ao valor reduzido de 'p'. O ajuste apresentou $R^2(NT) = 84.6\%$, valor um pouco mais baixo do que o ajuste do Modelo LIN (88.1%). Na análise de variância (Tabela 6.2.5), a variável que mais explicou a soma dos quadrados foi X_3 , seguida em ordem decrescente por X_1 , X_2 e X_4 , e a probabilidade da regressão não ser significativa para estimar rendimentos foi muito baixa ($p < 0.05\%$).

Na Figura 6.2.2 observa-se que as estimativas são razoáveis, e que os pontos se distribuem com certa semelhança aos pontos da Figura 6.2.1.

6.2.3 Ajuste do Modelo LOG3. Veranópolis -RS.

Equação de regressão:

$$Y = 0.877X_1^{0.162}X_2^{0.298}X_3^{0.387} \quad (6.2.3)$$

$$s = 0.09530 \quad R^2 = 78.9\% \quad R^2(\text{NT}) = 76.8\%$$

Tabela 6.2.6 Estatísticas dos parâmetros estimados. Modelo LOG3.Veranópolis-RS

Preditor	Coef	Stdev	razão-T	p
C_1	-0.0568	0.1513	-0.38	0.710
λ_1	0.16204	0.06060	2.67	0.012
λ_2	0.29825	0.05379	5.55	0.000
λ_3	0.38680	0.05699	6.79	0.000

Tabela 6.2.7 Análise de Variância. Modelo LOG3, Veranópolis-RS.

ORIGEM	GL	SS	MS	F	p
Regressão	3	1.04984	0.34995	38.53	0.000
Erro	31	0.28156	0.00908		
Total	34	1.33140			

Apesar deste ajuste ser menor do que nos dois casos anteriores, esta regressão se justifica pela importância de poder estimar rendimentos a aproximadamente 40 dias antes de se atingir a Soma Térmica de 1200°C, ou melhor, quando a cultura atinge 900°C de Soma Térmica.

6.3 Estação experimental de Santo Augusto-RS

A amostra de rendimentos constituída para o posto Santo Augusto inclui 30 eventos, dos quais a grande maioria correspondem à variedade tardia SAVE 231, de experimentos conduzidos em várias épocas de semeadura pela Seção de Ecologia do IPAGRO, entre 1971 e 1981, sendo que no período agrícola 1971/1972 foi incluída a variedade Agroceres 28. Estes ensaios ecológicos foram realizados semeando três variedades com ciclos precoce, médio e tardio, sendo que cada tratamento consistiu de três ou quatro repetições.

Para este posto, o valor de STT adotado para estimar rendimentos foi 1560°C ; portanto, tomaram-se quatro intervalos de soma térmica de 390°C.

A seguir se apresenta a Tabela 6.3.1, onde constam as estatísticas básicas da amostra utilizada nos ajustes.

Tabela 6.3.1 Descrição estatística da amostra.Santo Augusto-RS.

	Yobs	X ₁	X ₂	X ₃	X ₄
N	30	30	30	30	30
MEDIA	48.3	139.6	122.7	109.6	81.3
MEDIANA	49.5	130.5	123.5	106.0	74.5
MEDIA-T	48.4	136.3	121.3	108.5	79.8
STDEV	18.8	64.1	58.6	47.8	44.7
SEMEAN	3.4	11.7	10.7	8.7	8.2
MAX	84.0	334.0	252.0	212.0	179.0
MIN	12.0	17.0	11.0	11.0	14.0
Q3	63.0	174.5	165.7	140.5	108.2
Q1	31.0	98.2	74.7	70.8	42.2

Os rendimentos variaram entre 12% e 84%, com média 3860 Kg/ha (48.3%) e desvio de 1500 Kg/ha. Pela semelhança entre a média e a mediana (49.5%) pode-se concluir que a série de rendimentos se distribui simetricamente, sendo que 75% dos rendimentos ocorreram abaixo de 63% (5040 Kg/ha). Pelos valores mínimos (MIN) registrados na Tabela 6.3.1 pode ser constatado que ocorreram situações de déficit em todos os intervalos de soma térmica, já que 25% dos rendimentos ocorreram abaixo de 2480 Kg/ha.

6.3.1 Ajuste do Modelo LIN. Santo Augusto-RS.

Equação de regressão :

$$Y = -7.14 + 0.0851 X_1 + 0.134 X_2 + 0.149 X_3 + 0.132 X_4 \quad (6.3.1)$$

$$s = 10.08\% \quad R^2 = 75.2\% \quad R^2(\text{NT}) = 71.2\%$$

Tabela 6.3.2 Estatísticas dos parâmetros estimados. Modelo LIN, Santo Augusto-RS.

Preditor	Coef	Stdev	razão-T	p
β	-7.142	6.665	-1.07	0.294
a_1	0.08511	0.03309	2.57	0.016
a_2	0.13361	0.03375	3.96	0.001
a_3	0.14934	0.04185	3.57	0.001
a_4	0.13248	0.04741	2.79	0.010

Tabela 6.3.3 Análise de Variância. Modelo LIN, Santo Augusto-RS.

ORIGEM	GL	SS	MS	F	p
Regressão	4	7704.8	1926.2	18.97	0.000
Erro	25	2539.0	101.6		
Total	29	10243.9			
ORIGEM	GL	SEQ SS			
a_1	1	2921.3			
a_2	1	3009.6			
a_3	1	981.1			
a_4	1	792.9			

A Tabela 6.3.2 mostra que a estimativa da constante não é significativa para $p < 29.4\%$, e que todas as outras estimativas dos parâmetros são significativas para $p < 1.6\%$. O ajuste do Modelo LIN não foi elevado, com $R^2(\text{NT}) = 71.2\%$ e $s = 10.08\%$ (806.4 Kg/ha).

A Tabela 6.3.3 mostra $F = 18.97$, o que confere significância à regressão. Na parte inferior desta tabela se observa que a variável que mais explica a variação dos rendimentos em torno da média é X_2 , seguida por X_1 , X_3 e X_4 .




Figura 6.3.1 Rendimentos observados (Yobs) vs rendimentos estimados pelo Modelo LIN (YcLIN), Santo Augusto-RS.

Na Figura 6.3.1 se observam dois pontos que não se ajustaram bem (superestimação e subestimação), principalmente para rendimentos observados superiores a 40%.

6.3.2 Ajuste do Modelo LOG - Santo Augusto - RS

Equação de regressão :

$$Y = 0.166X_1^{0.271}X_2^{0.332}X_3^{0.372}X_4^{0.244} \quad (6.3.2)$$

$$s = 0.08219 \quad R^2 = 86.2\% \quad R^2(\text{NT}) = 84.0\%$$

Tabela 6.3.4 Estatísticas dos parâmetros estimados. Modelo LOG, Santo Augusto-RS.

Preditor	Coef	Stdev	razão-T	p
C_1	-0.7785	0.1996	-3.90	0.001
λ_1	0.27113	0.06639	4.08	0.000
λ_2	0.33150	0.05633	5.89	0.000
λ_3	0.37181	0.06071	6.12	0.000
λ_4	0.24437	0.05488	4.45	0.000

Tabela 6.3.5 Análise de Variância. Modelo LOG, Santo Augusto-RS.

ORIGEM	GL	SS	MS	F	p
Regressão	4	1.05657	0.26414	39.10	0.000
Erro	25	0.16887	0.00675		
Total	29	1.22544			

ORIGEM	GL	SEQ SS
λ_1	1	0.31552
λ_2	1	0.37649
λ_3	1	0.23061
λ_4	1	0.13395




Figura 6.3.2 Rendimentos observados (Yobs) vs rendimentos estimados pelo Modelo LOG (YcLOG), Veranópolis-RS.

Pelas Tabelas 6.3.4 e 6.3.5 se conclue que o ajuste do Modelo LOG é melhor que o anterior ($R^2(NT) = 84\%$). Também melhoraram a significância dos parâmetros.

Na Figura 6.3.2 se observa uma distribuição dos pontos muito semelhante à da Figura 6.3.1.

6.3.3 Ajuste do Modelo LOG3 . Santo Augusto - RS

Equação de regressão :

$$Y = 0.242X_1^{0.362}X_2^{0.395}X_3^{0.354} \quad (6.3.3)$$

$$s = 0.1079 \quad R^2 = 75.3\% \quad R^2(NT) = 72.4\%$$

Tabela 6.3.6 Estatísticas dos parâmetros estimados. Modelo LOG3, Santo Augusto-RS.

Preditor	Coef	Stdev	razão-T	p
C_1	-0.6157	0.2576	-2.39	0.024
λ_1 (mm)	0.36176	0.08298	4.36	0.000
λ_2 (mm)	0.39542	0.07152	5.53	0.000
λ_3 (mm)	0.35393	0.07954	4.45	0.000

Tabela 6.3.7 Análise de Variância. Modelo LOG3, Santo Augusto-RS.

ORIGEM	GL	SS	MS	F	p
Regressão	3	0.92262	0.30754	26.41	0.000
Erro	26	0.30282	0.01165		
Total	29	1.22544			

Excluindo a variável X_4 , o ajuste deste modelo apresentou uma significância superior das estimativas dos parâmetros e da regressão, comparado com o ajuste do Modelo LIN (6.3.1), justificando a relevância desta regressão para estimar rendimentos quando a cultura atinge 1170°C.

6.4 Estação experimental de São Borja-RS

A amostra de rendimentos de São Borja foi constituída por 29 eventos obtidos, em sua maioria, de ensaios ecológicos conduzidos pelo IPAGRO entre 1978 e 1984, em várias épocas de sementeira. Foram incluídos na amostra híbridos de ciclo precoce : Pioneer 309B (78/79), Pioneer 6874 (79/80,80/81,81/82) e Dekalb XL 560 (82/83 e 83/84). Nesta amostra também foram incluídas as médias dos rendimentos dos Ensaios Estaduais de Híbridos Comerciais Precoces (EEHCC).

Para São Borja, o valor de STT que se mostrou significativo para estimar rendimentos foi 1200°C, tomando-se quatro intervalos de 300°C.

A Tabela 6.4.1 a seguir apresenta as estatísticas básicas dos rendimentos Yobs e das precipitações efetivas nos quatro intervalos.

Tabela 6.4.1 Descrição estatística da amostra. São Borja-RS

	Yobs	X ₁	X ₂	X ₃	X ₄
N	29	29	29	29	29
MEDIA	27.6	79.8	83.2	68.2	49.5
MEDIANA	25.0	66.0	60.0	52.0	55.0
MEDIA-T	27.4	77.7	81.0	66.7	48.7
STDEV	16.6	47.6	67.5	49.2	28.7
SEMEAN	3.1	8.8	12.5	9.1	5.3
MAX	57.0	214.0	223.0	175.0	119.0
MIN	2.0	2.0	2.0	2.0	2.0
Q3	39.0	106.5	134.0	97.5	64.5
Q1	14.0	44.0	32.0	30.0	24.0

A média dos rendimentos observados da amostra é 27.6% (2207 Kg/ha) - inferior à média dos outros locais -, com mínimo de 2% (160 Kg/ha) e máximo de 57% (4560 Kg/ha). Acredita-se que uma das causas (e talvez a mais importante) de São Borja apresentar rendimentos médios inferiores aos outros postos é explicada pelo padrão de precipitações da área. São Borja apresenta rendimento médio de 27.6%, com um total médio de precipitação efetiva ($X_1 + X_2 + X_3 + X_4$) de 280 mm; Taquarí apresenta rendimento médio 44.6%, com um total médio de precipitação efetiva de 322 mm; Veranópolis apresenta rendimento médio de 36.14% com precipitação total média 344 mm; Santo Augusto apresenta rendimento médio 48.3% e uma precipitação total média de 454 mm. No ítem 10 este fato será confirmado comparando as séries históricas de precipitação efetiva de São Borja com as outras estações.

6.4.1 Ajuste do Modelo LIN. São Borja-RS

Equação de regressão :

$$Y = - 19.2 + 0.0693 X_1 + 0.0677 X_2 + 0.275 X_3 + 0.340 X_4 \quad (6.4.1)$$

$$s = 7.911 \%$$

$$R = 80.6\%$$

$$R (NT) = 77.3\%$$

Tabela 6.4.2 Estatísticas dos parâmetros estimados. Modelo LIN, São Borja-RS.

Preditor	Coef	Stdev	razão-T	P
β	-19.199	6.269	-3.06	0.005
a_1	0.06928	0.03717	1.86	0.075
a_2	0.06770	0.02393	2.83	0.009
a_3	0.27537	0.03499	7.87	0.000
a_4	0.34021	0.05680	5.99	0.000

Tabela 6.4.3 Análise de Variância. Modelo LIN. São Borja-RS.

ORIGEM	GL	SS	MS	F	p
Regressão	4	6234.8	1558.7	24.90	0.000
Erro	24	1502.2	62.6		
Total	28	7737.0			
ORIGEM	GL	SEQ SS			
λ_1	1	245.5			
λ_2	1	1035.5			
λ_3	1	2708.5			
λ_4	1	2245.4			

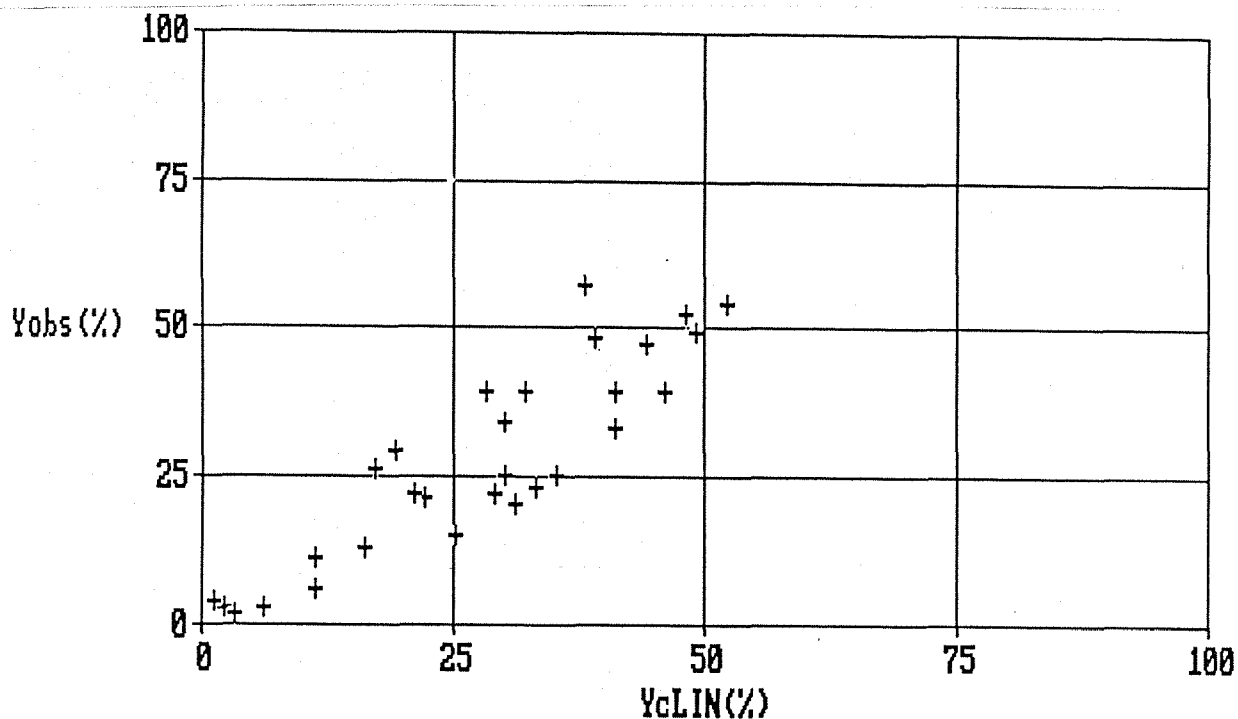


Figura 6.4.1 Rendimentos observados (Yobs) vs rendimentos calculados pelo Modelo LIN (YcLIN). São Borja-RS.

O ajuste apresentou $R^2(NT) = 77.3\%$, com $s = 7.91\%$ (633 Kg/ha). De acordo com a Tabela 6.4.2, todas as estimativas dos parâmetros são significativas a exceção do coeficiente de a_1 , onde $p(|t| > t_p) = 7.5\%$.

A Tabela 6.4.3 mostra a relevância das precipitações efetivas em cada intervalo na variação dos rendimentos em torno da média. A variável que mais explica é X_3 , seguida em ordem decrescente por X_4 , X_2 e X_1 . O valor de $F = 24.9$ coloca em evidência a significância da regressão para estimar rendimentos.

A Figura 6.4.1 mostra estimativas razoáveis para valores baixos e altos da amostra de rendimentos, a exceção de uma observação.

6.4.2 Ajuste do Modelo LOG. São Borja-RS.

Equação de regressão :

$$Y = 0.207X_1^{0.031}X_2^{0.153}X_3^{0.727}X_4^{0.290} \quad (6.4.2)$$

$$s = 0.1706 \quad R^2 = 85.3\% \quad R^2(\text{NT}) = 82.8\%$$

Tabela 6.4.4 Estatísticas dos parâmetros estimados. Modelo LOG, São Borja-RS.

Preditor	Coef	Stdev	razão-T	p
C ₁	-0.6826	0.2830	-2.41	0.024
λ ₁	0.03097	0.09409	0.33	0.745
λ ₂	0.15260	0.07351	2.08	0.049
λ ₃	0.72734	0.07971	9.13	0.000
λ ₄	0.29002	0.08632	3.36	0.003

Tabela 6.4.5 Análise de Variância. Modelo LOG. São Borja-RS.

ORIGEM	GL	SS	MS	F	p
Regressão	4	4.0381	1.0095	34.68	0.000
Erro	24	0.6986	0.0291		
Total	28	4.7367			
ORIGEM	GL	SEQ SS			
λ ₁	1	0.2224			
λ ₂	1	0.7791			
λ ₃	1	2.7080			
λ ₄	1	0.3286			

Este modelo apresentou R²(NT) superior ao Modelo LIN; entretanto, a significância do parâmetro estimado λ₁ ficou comprometida - p(|t|>t = 74.5%).

Pela Tabela 6.4.5 se observa que a estatística F aumentou e que se manteve a mesma ordem da magnitude da soma dos quadrados (SEQ SS) explicada por cada variável.

Na Figura 6.4.2 se observa, em média, que as estimativas melhoraram, a exceção de uma observação (Y_{obs} = 57%) que o modelo não conseguiu explicar (Y_{CLOG} ≈ 30%). As possíveis causas desta divergência estão expostas em 3.2.5.




Figura 6.4.2 Rendimentos observados (Yobs) vs rendimentos calculados pelo Modelo LOG (YcLOG). São Borja-RS.

6.4.3 Ajuste do Modelo LOG3. São Borja -RS.

$$Y = 0.731X_1^{0.005}X_2^{0.094}X_3^{0.762} \quad (6.4.3)$$

$$s = 0.2027 \quad R^2 = 78.3\% \quad R^2(\text{NT}) = 75.7\%$$

Tabela 6.4.6 Estatísticas dos parâmetros estimados. Modelo LOG3, São Borja-RS.

Preditor	Coef	Stdev	razão-T	p
C_1	-0.1356	0.2750	-0.49	0.626
λ_1	0.0047	0.1114	0.04	0.967
λ_2	0.09424	0.08487	1.11	0.277
λ_3	0.76223	0.09389	8.12	0.000

Tabela 6.4.7 Análise de Variância. Modelo LOG3. São Borja-RS.

ORIGEM	GL	SS	MS	F	p
Regressão	3	3.7095	1.2365	30.09	0.000
Erro	25	1.0272	0.0411		
Total	28	4.7367			

Esta regressão apresentou $R^2(NT) = 75.7\%$, com erro padrão médio das estimativas (dos logaritmos) 0.2027.

A Tabela 6.4.6 mostra que o único parâmetro estimado confiável é λ_3 , sendo que nenhum dos outros parâmetros apresentou significância satisfatória. Mesmo assim, a estatística F da Tabela 6.4.7 é significativa. Na verdade, pelos valores dos parâmetros da regressão, se pode concluir que a ordem de magnitude de λ_3 é muito superior às encontradas nos outros postos. Como λ_1 e λ_2 são muito próximos a zero, a influência de X_1 e X_2 será muito pequena comparada à X_3 . São Borja é o local onde λ_3 apresenta a maior relevância sobre as outras localidades, responsável por 67% da soma dos quadrados. É um assunto interessante para estudos posteriores.

6.5 Estação experimental de Livramento-RS

A amostra de rendimentos em Livramento foi constituída por 22 eventos obtidos em ensaios ecológicos com várias épocas de semeadura (Reunião Técnica anual do Milho, 1969, 1970, 1971 e 1972), utilizando o híbrido de ciclo precoce Morgan Rendidor.

Neste local, o valor de STT que demonstrou melhor ajuste na estimativa de rendimentos foi 1200°C, tomando quatro intervalos de 300°C.

As semeaduras de 15/12/69 (800 Kg/ha), 30/12/69 (763 Kg/ha) e 15/01/70 (788 Kg/ha) foram excluídas da regressão pois existia a suspeita de que estes eventos sofreram efeitos de variáveis que os modelos LOG e LIN não consideram. O fato que levantou tal suspeita foi a magnitude do rendimento que havia sido semeado 15 dias antes, em 30/11/69, apresentando 2588 Kg/ha. Se supõe que para apenas 15 dias de diferença entre datas de semeadura, os rendimentos 2588 e 800 Kg/ha são excessivamente divergentes para que esta diferença tenha sido causada somente pela diferença de precipitação em 15 dias, mesmo que o solo apresente baixa capacidade de armazenamento.

A Tabela 6.5.1 apresenta as estatísticas básicas das séries de rendimento e precipitações que compõem a amostra.

Tabela 6.5.1 Descrição estatística da amostra. Livramento-RS

	Yobs	X ₁	X ₂	X ₃	X ₄
N	22	22	22	22	22
MEDIA	41.3	87.8	75.9	90.4	78.2
MEDIANA	36.5	93.5	58.0	79.0	68.5
MEDIA-T	41.1	87.8	74.8	88.2	76.7
STDEV	17.5	42.6	51.1	49.5	50.7
SEMEAN	3.7	9.1	10.9	10.5	10.8
MAX	73.0	170.0	169.0	190.0	184.0
MIN	14.0	4.0	4.0	34.0	2.0
Q3	61.2	120.3	124.5	132.2	105.5
Q1	30.5	44.7	37.0	45.8	42.8

A média dos rendimentos observados é 41.3% (3306 Kg/ha), com mínimo de 14 % (1090 Kg/ha) e máximo de 73 % (5820 Kg/ha).

A precipitação efetiva total média ocorrida é baixa (332 mm), comparando com requerimentos hídricos potenciais para o estado do RS, que está na faixa dos 550-650 mm, segundo observações realizadas em lisímetros de drenagem em Taquarí (Matzenauer et al., 1983).

6.5.1 Ajuste do Modelo LIN. Livramento-RS

Equação de regressão :

$$Y = - 5.40 + 0.0422 X_1 + 0.121 X_2 + 0.245 X_3 + 0.149 X_4 \quad (6.5.1)$$

$$s = 5.465 \% \quad R^2 = 92.1\% \quad R^2(\text{NT}) = 90.2\%$$

Tabela 6.5.2 Estatísticas dos parâmetros estimados. Modelo LIN, Livramento-RS.

Preditor	Coef	Stdev	razão-T	p
β	-5.397	4.374	-1.23	0.234
a ₁	0.04219	0.02826	1.49	0.154
a ₂	0.12128	0.02481	4.89	0.000
a ₃	0.24539	0.02557	9.60	0.000
a ₄	0.14876	0.02509	5.93	0.000

Tabela 6.5.3 Análise de Variância. Modelo LIN. Livramento-RS.

ORIGEM	GL	SS	MS	F	p
Regressão	4	5897.1	1474.3	49.37	0.000
Erro	17	507.7	29.9		
Total	21	6404.8			
ORIGEM	GL	SEQ SS			
a ₁	1	0.0			
a ₂	1	896.3			
a ₃	1	3951.2			
a ₄	1	1049.5			

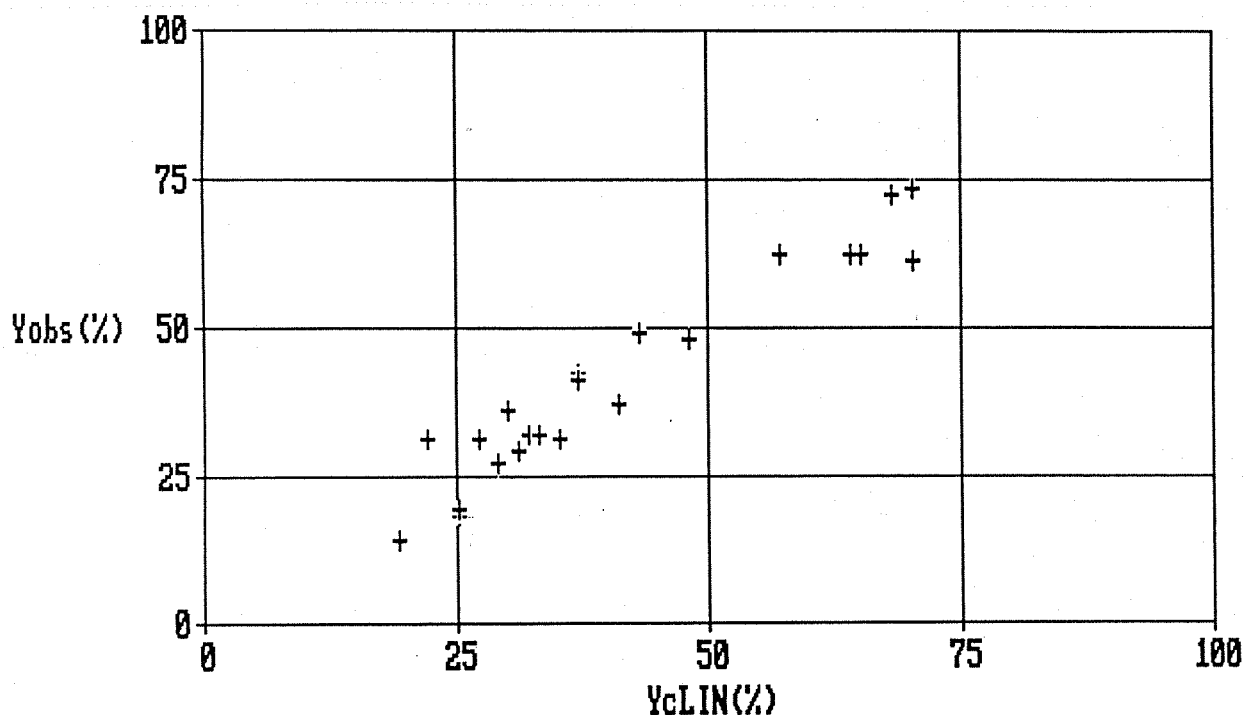


Figura 6.5.1 Rendimentos observados (Yobs) vs rendimentos calculados pelo Modelo LIN (YcLIN). Livramento - RS.

O ajuste do Modelo LIN aos dados foi muito bom, apresentando $R^2(NT) = 90.2\%$, com um desvio baixo entre os valores observados e calculados ($s = 5.46\%$). As estimativas dos coeficientes da regressão foram significativas, a exceção da interseção e do coeficiente de X_1 , mas como o valor da interseção é muito baixo (-5.4%) e o coeficiente de X_1 também, o peso exercido nas estimativas é pequeno se comparado às grandezas dos

outros coeficientes.

A significância do coeficiente de X_1 se reflete na Tabela 6.5.3, onde se observa que a variável X_1 não contribui em quase nada para explicar a variação dos rendimentos em torno da média. Somente a variável X_3 explica 62 % da variação de Y_{obs} , seguida em ordem decrescente por X_4 (16%) e X_2 (14%). A estatística F mostra que a regressão é significativa.

Na Figura 6.5.1 aparece um bom ajuste do modelo LIN para toda a faixa de rendimentos observados.

6.5.2 Ajuste do Modelo LOG. Livramento-RS

$$Y = 0.397X_1^{0.101}X_2^{0.154}X_3^{0.677}X_4^{0.137} \quad (6.5.2)$$

$$s = 0.09955 \quad R^2 = 79.3\% \quad R^2(NT) = 74.5\%$$

Tabela 6.5.4 Estatísticas dos parâmetros estimados. Modelo LOG, Livramento-RS.

Preditor	Coef	Stdev	razão-T	p
C_1	-0.4005	0.2754	-1.45	0.164
λ_1	0.10085	0.06277	1.61	0.127
λ_2	0.15384	0.05314	2.89	0.010
λ_3	0.67720	0.09048	7.48	0.000
λ_4	0.13728	0.05050	2.72	0.015

Tabela 6.5.5 Análise de Variância. Modelo LOG. Livramento-RS.

ORIGEM	GL	SS	MS	F	p
Regressão	4	0.64706	0.16176	16.32	0.000
Erro	17	0.16846	0.00991		
Total	21	0.81551			
ORIGEM	GL	SEQ SS			
λ_1	1	0.00005			
λ_2	1	0.04758			
λ_3	1	0.52621			
λ_4	1	0.07322			

O ajuste do Modelo LOG foi notavelmente inferior ao ajuste do Modelo LIN (74.5 % contra 90.2 %). O autor não conseguiu ainda uma razão aparente para explicar este fato. A grande vantagem neste caso do Modelo LIN pode ser observada na Figura 5.1. Nesta

Figura, nota-se que Livramento é o único posto onde o Modelo LIN supera com vantagem o ajuste do Modelo LOG.

Na Tabela 6.5.5 se observa uma hierarquia semelhante à da Tabela 6.5.3 no que diz respeito à soma dos quadrados (SEQ SS) explicados por cada variável na regressão.

Na Figura 6.5.2 se observa uma dispersão maior dos pontos em torno da reta 1:1 se comparada à Figura 6.5.1.




Figura 6.5.2 Rendimentos observados (Yobs) vs rendimentos calculados pelo Modelo LOG (YcLOG). Livramento-RS.

6.5.3 Ajuste do Modelo LOG3. Livramento-RS.

$$Y = 0.824X_1^{0.112}X_2^{0.120}X_3^{0.657} \quad (6.5.3)$$

$$s = 0.1159$$

$$R^2 = 70.4\%$$

$$R^2(\text{NT}) = 65.4\%$$

Tabela 6.5.6 Estatísticas dos parâmetros estimados.
Modelo LOG3, Livramento-RS.

Preditor	Coef	Stdev	razão-T	p
C_1	-0.0838	0.2904	-0.29	0.776
λ_1	0.11213	0.07290	1.54	0.141
λ_2	0.12017	0.06015	2.00	0.061
λ_3	0.6571	0.1050	6.26	0.000

Tabela 6.5.7 Análise de Variância. Modelo LOG3. Livramento-RS.

ORIGEM	GL	SS	MS	F	p
Regressão	3	0.57384	0.19128	14.25	0.000
Erro	18	0.24167	0.01343		
Total	21	0.81551			

O modelo LOG3 apresentou um coeficiente de determinação mais baixo do que o Modelo LOG com quatro preditores, como era de se esperar, pois a variável X_4 , que tinha certa relevância, foi excluída neste caso.

Na Tabela 6.5.6 pode ser observada a baixa significância da constante da regressão ($p(|t| > t_p = 77.6 \%$)).

6.6 Equação Regional para as estações Santo Augusto, Cruz Alta, Santa Rosa e Passo Fundo

Nas localidades de Cruz Alta, Santa Rosa e Passo Fundo não foi possível a obtenção de um número suficiente de rendimentos para realizar uma regressão única para cada local. Uma vez que as estações experimentais acima se encontram dentro de uma região em comum num raio de aproximadamente 100 Km, apresentando características agroclimáticas semelhantes (capítulo 4), optou-se por constituir uma amostra única que inclui rendimentos e precipitações efetivas destas quatro localidades, obtendo assim uma equação de regressão Regional (na verdade duas, pois se ajustam dois modelos para cada amostra).

Tomando como vértices desta região Santo Augusto, Cruz Alta, Santa Rosa e Passo Fundo, alguns dos municípios mais importantes inseridos nesta região são : Giruã, Santo Ângelo, Ijuí, Panambí, Ibirubá, Tapera, Carazinho, Chapada, Sarandí, Palmeira das Missões e Três de Maio.

Esta amostra regional inclui 60 eventos, dos quais 30 são de Santo Augusto, variedade híbrida de ciclo médio Pioneer X 307, obtidos em ensaios ecológicos com várias épocas de semeadura, conduzidos pela Seção de Ecologia do IPAGRO, entre 1971 e 1981; 15 eventos são de Cruz Alta, híbrido de ciclo precoce SAVE 342 (Silva et al., 1985); 8 eventos de Passo Fundo, que foram os rendimentos médios dos EEHCP, e 7 eventos de Santa Rosa, também obtidos dos EEHCP.

O valor de STT utilizado para estimar rendimentos foi de 1560°C para todas as localidades desta região, uma vez que para Santo Augusto este valor havia fornecido resultados satisfatórios. Além do mais, todos os postos estão inseridos numa região mais ou menos homogênea de clima e solo, o que leva a pensar em não haver diferenças elevadas nos requerimentos térmicos do milho. A seguir se apresenta a Tabela 6.6.1, onde constam as estatísticas básicas da amostra.

Tabela 6.6.1 Descrição estatística da amostra. Regional-RS

	Yobs	X ₁	X ₂	X ₃	X ₄
N	60	60	60	60	60
MEDIA	48.4	138.8	98.6	91.9	101.6
MEDIANA	50.0	128.0	93.0	86.0	100.0
MEDIA-T	48.8	134.1	95.7	90.5	100.1
STDEV	18.6	70.5	53.7	46.1	53.8
SEMEAN	2.4	9.1	6.9	5.9	6.9
MAX	84.0	334.0	252.0	213.0	232.0
MIN	10.0	17.0	11.0	11.0	14.0
Q3	62.0	169.7	132.5	126.0	141.3
Q1	32.5	93.7	51.0	61.2	59.2

Como pode ser visto na tabela acima, a média dos rendimentos é elevada com relação aos outros postos; da mesma forma, a precipitação efetiva total média nos quatro períodos alcança 430.9 mm. Deve ser ressaltado que esta região é uma das mais importantes na produção de grãos de milho no Estado.

6.6.1 Ajuste do Modelo LIN. Regional-Regiões Planalto e Missões

$$Y = - 9.95 + 0.0486 X_1 + 0.141 X_2 + 0.239 X_3 + 0.156 X_4 \quad (6.6.1)$$

$$s = 8.478 \% \quad R^2 = 80.7\% \quad R^2(NT) = 79.3\%$$

Tabela 6.6.2 Estatísticas dos parâmetros estimados.
Modelo LIN, Regional-RS.

Preditor	Coef	Stdev	razão-T	p
β	-9.949	4.103	-2.43	0.019
a_1	0.04861	0.01714	2.84	0.006
a_2	0.14051	0.02100	6.69	0.000
a_3	0.23879	0.02436	9.80	0.000
a_4	0.15582	0.02261	6.89	0.000

Tabela 6.6.3 Análise de Variância. Modelo LIN. Regional-RS.

ORIGEM	GL	SS	MS	F	p
Regressão	4	16555.6	4138.9	57.59	0.000
Erro	55	3953.0	71.9		
Total	59	20508.6			

ORIGEM	GL	SEQ SS
a_1	1	3712.4
a_2	1	2969.2
a_3	1	6459.2
a_4	1	3414.8




Figura 6.6.1 Rendimentos observados (Yobs) vs rendimentos calculados pelo Modelo LIN (YcLIN). Regional-RS.

6.7 Estação experimental da Embrapa. Sete Lagoas-MG

Nesta localidade não foi possível a obtenção dos dados de temperatura necessários para a divisão do ciclo usando o critério da soma térmica que até aqui vinha sendo aplicado para todos os postos do Rio Grande do Sul. Por este motivo, fez-se necessária a divisão do ciclo com base num critério temporal, que consiste em dividir o número total de dias contados entre a semeadura e a maturação fisiológica em quatro intervalos equivalentes. Este número total de dias não foi mencionado na referência, e se estabeleceu através de uma análise de sensibilidade visual do ajuste e dos parâmetros da equação de regressão variando o número total de dias (NTD), e por conseguinte, o comprimento dos intervalos. O valor de NTD = 100 dias se mostrou significativo para estimar rendimentos, tomando 4 intervalos de 25 dias.

Os rendimentos desta amostra são os rendimentos médios das três variedades semeadas no ensaio : Phoenix (tardia), Mezcla Amarilla (precoce) e Pioneer (média). Não foi especificada a variedade Pioneer.

A Tabela 6.7.1 descreve as estatísticas da amostra de rendimentos e precipitações efetivas de Sete Lagoas-MG, e pode ser observado que realmente ocorreram situações de déficit, fato

Tabela 6.7.1 Descrição estatística da amostra. Sete Lagoas-MG.

	Yobs	X ₁	X ₂	X ₃	X ₄
N	15	15	15	15	15
MEDIA	42.7	133.9	143.4	110.3	96.1
MEDIANA	46.0	138.0	140.0	121.0	60.0
MEDIA-T	43.2	134.6	146.0	108.5	93.3
STDEV	22.4	63.1	57.3	67.8	77.5
SEMEAN	5.8	16.3	14.8	17.5	20.0
MAX	75.0	228.0	251.0	241.0	227.0
MIN	4.0	31.0	2.0	3.0	2.0
Q3	58.0	198.0	182.0	162.0	174.0
Q1	22.0	78.0	128.0	59.0	28.0

evidenciado pelos valores mínimos (MIN) de precipitação efetiva nos 4 intervalos.

Para esta estação, a regressão obtida ajustando o Modelo LOG resultou ser menos confiável que a obtida com Modelo LIN. O número de observações é pequeno para sugerir a realização de estimativas; entretanto, se houver necessidade de estimar rendimentos, é recomendável utilizar o Modelo LIN para tanto.

6.7.1 Ajuste do Modelo LIN. Sete Lagoas-MG

Equação de regressão :

$$Y = - 11.4 + 0.0241 X_1 + 0.0822 X_2 + 0.260 X_3 + 0.108 X_4 \quad (6.7.1)$$

$$s = 7.404 \% \quad R^2 = 92.2\% \quad R^2(\text{NT}) = 89.0\%$$

Tabela 6.7.2 Estatísticas dos parâmetros estimados. Modelo LIN, Sete Lagoas-MG.

Preditor	Coef	Stdev	razão-T	p
β	-11.446	9.353	-1.22	0.249
a_1	0.02406	0.03755	0.64	0.536
a_2	0.08218	0.04012	2.05	0.068
a_3	0.26030	0.03022	8.61	0.000
a_4	0.10804	0.03142	3.44	0.006

Tabela 6.7.3 Análise de Variância. Modelo LIN. Sete Lagoas-MG.

ORIGEM	GL	SS	MS	F	p
Regressão	4	6445.2	1611.3	29.39	0.000
Erro	10	548.2	54.8		
Total	14	6993.3			
ORIGEM	GL	SEQ SS			
a_1	1	365.5			
a_2	1	1604.8			
a_3	1	3826.7			
a_4	1	648.1			

Apesar do pequeno tamanho da amostra ($N = 15$), a significância das estimativas dos parâmetros não foram tão ruins, exceto para C_1 e λ_1 , e o ajuste foi satisfatório, com $R^2(\text{NT}) = 89.0\%$.

A regressão é significativa para estimar rendimentos, fato evidenciado por $F = 29.39$ (Tabela 6.7.3). Da variação total dos rendimentos ($SS \text{ Total} = 6993.3$), X_3 explica 3826.7, seguido em ordem decrescente por X_2 (1604.8), X_4 (648.1) e X_1 (365.5).




Figura 6.7.1 Rendimentos observados (Yobs) vs rendimentos calculados pelo Modelo LIN (YcLIN). Sete lagoas-MG

6.7.2 Ajuste do Modelo LOG. Sete Lagoas-MG

$$Y = 0.290X_1^{0.057} X_2^{0.330} X_3^{0.544} X_4^{0.140} \tag{6.7.2}$$

$$s = 0.1662 \quad R^2 = 86.6\% \quad R^2(\text{NT}) = 81.3\%$$

Tabela 6.7.4 Estatísticas dos parâmetros estimados. Modelo LOG, Sete Lagoas-MG.

Preditor	Coef	Stdev	razão-T	p
C ₁	-0.5377	0.6167	-0.87	0.404
λ ₁	0.0566	0.2099	0.27	0.793
λ ₂	0.33040	0.09188	3.60	0.005
λ ₃	0.54409	0.08525	6.38	0.000
λ ₄	0.14019	0.09796	1.43	0.183

Pelo elevado número de graus de liberdade dos resíduos (55) se pode observar na Tabela 6.6.2 que todas as estimativas dos parâmetros são significativas. Note-se que o nível de significância da interseção aqui calculado ($p = 1.9 \%$) foi o menor de todos. O ajuste foi satisfatório, apresentando $R^2(\text{NT}) = 79.3\%$, $s = 8.5 \%$ (680 Kg/ha).

Na parte inferior da Tabela 6.6.3 pode-se ver que a variável X_3 é a que mais explica a soma dos quadrados, seguida em ordem decrescente por X_1 , X_4 e X_2 . Nesta tabela há forte evidência de que todas as variáveis são significativas para estimar rendimentos, e em consequência toda a regressão, que apresentou $F = 57.59$.

Na Figura 6.6.1 se apresentam os valores observados e calculados pelo Modelo LIN, onde se observa uma dispersão maior nas faixas centrais do que nos extremos inferiores e superiores. Aparentemente ocorreu uma leve superestimação de rendimentos abaixo de 20 %.

6.6.2 Ajuste do Modelo LOG. Regional-Regiões Planalto e Missões

Equação de regressão :

$$Y = 0.123X_1^{0.144}X_2^{0.330}X_3^{0.513}X_4^{0.336} \quad (6.6.2)$$

$$s = 0.07776 \quad R^2 = 87.8\% \quad R^2(\text{NT}) = 86.9\%$$

Tabela 6.6.4 Estatísticas dos parâmetros estimados. Modelo LOG, Regional-RS.

Preditor	Coef	Stdev	razão-T	p
C_1	-0.9113	0.1398	-6.52	0.000
λ_1	0.14392	0.04416	3.26	0.002
λ_2	0.33015	0.03827	8.63	0.000
λ_3	0.51302	0.03749	13.69	0.000
λ_4	0.33560	0.03624	9.26	0.000

Tabela 6.6.5 Análise de Variância. Modelo LOG. Regional-RS.

ORIGEM	GL	SS	MS	F	p
Regressão	4	2.38749	0.59687	98.71	0.000
Erro	55	0.33256	0.00605		
Total	59	2.72004			
ORIGEM	GL	SEQ SS			
λ_1	1	0.33063			
λ_2	1	0.45820			
λ_3	1	1.08027			
λ_4	1	0.51839			




Figura 6.6.2 Rendimentos observados (Yobs) vs rendimentos calculados pelo Modelo LOG (YcLOG). Regional-RS.

Este ajuste foi melhor do que no caso anterior, apresentando $R^2(NT) = 86.9\%$. Da mesma forma a significância dos parâmetros C_1 e λ_1 aumentou.

Na Tabela 6.6.5 a estatística F quase dobrou de valor comparada ao ajuste do Modelo LIN.

A ordem de relevância das variáveis na soma dos quadrados é X_4 , X_3 , X_2 e X_1 .

Na Figura 6.6.2 a superestimação de rendimentos baixos é

menor do que no Modelo LIN, mas em compensação ocorreu uma leve superestimação para rendimentos altos, mas pode se dizer que isto ocorre dentro de limites aceitáveis.

6.6.3 Ajuste do Modelo LOG3. Regional-RS

Equação de regressão :

$$Y = 0.406X_1^{0.256}X_2^{0.286}X_3^{0.501} \quad (6.6.3)$$

$$s = 0.1233 \quad R^2 = 68.7\% \quad R^2(\text{NT}) = 67.0\%$$

Tabela 6.6.6 Estatísticas dos parâmetros estimados. Modelo LOG3, Regional-RS.

Preditor	Coef	Stdev	razão-T	p
C_1	-0.3912	0.2029	-1.93	0.059
λ_1	0.25620	0.06732	3.81	0.000
λ_2	0.28642	0.06020	4.76	0.000
λ_3	0.50074	0.05939	8.43	0.000

Tabela 6.6.7 Análise de Variância. Modelo LOG3. Regional-RS.

ORIGEM	GL	SS	MS	F	p
Regressão	3	1.86910	0.62303	41.00	0.000
Erro	56	0.85094	0.01520		
Total	59	2.72004			

Excluindo a variável X_4 neste ajuste, o coeficiente de determinação caiu de 86.9 % para 67 %, pois a variável X_4 explicava aproximadamente 19 % da variação dos rendimentos no caso anterior.

Mesmo com um ajuste não muito elevado, a regressão pode ser considerada significativa para estimar rendimentos, apresentando $F = 41$.




Figura 6.7.2 Rendimentos observados (Yobs) vs rendimentos calculados pelo Modelo LOG (YcLOG). Sete Lagoas-MG.

Tabela 6.7.5 Análise de Variância. Modelo LOG. Sete Lagoas-MG.

ORIGEM	GL	SS	MS	F	p
Regressão	4	1.79076	0.44769	16.21	0.000
Êrro	10	0.27620	0.02762		
Total	14	2.06696			
ORIGEM	GL	SEQ SS			
λ_1	1	0.06870			
λ_2	1	0.51441			
λ_3	1	1.15109			
λ_4	1	0.05657			

Pela Tabela 6.7.3 se pode ver que as estimativas de C_1 , λ_1 e λ_4 não são significativas, e este fato pode ser atribuído em parte ao pequeno tamanho da amostra, somado à pouca relevância que a precipitação efetiva têm no rendimento quando ocorrida no início e no fim do ciclo. A Tabela 6.7.5 mostra que a regressão é significativa para estimar rendimentos ($p = 0.2 \%$).

Na Figura 6.7.2 existe uma dispersão ainda maior do que no ajuste do Modelo LIN em torno da reta 1:1, refletindo num ajuste menor ($R^2 = 81.3 \%$).

7. Verificação dos Modelos LOG/LIN

Neste capítulo se apresenta a verificação dos modelos LOG/LIN calibrados inicialmente tomando a maior amostra já descrita em 6.6 (Regional). Posteriormente se mostrarão resultados nos capítulos 8, 9, 10 e 11 que também poderão ser interpretados de forma 'sui generis' como verificações dos modelos LOG/LIN, principalmente no capítulo 8, onde se apresentam regressões com 202 graus de liberdade para os resíduos.

Tabela 7 Valores observados de rendimento e precipitação efetiva da amostra Regional. Amostras 1 e 2.

CALIBRAÇÃO					VERIFICAÇÃO				
Amostra 1					Amostra 2				
Y	X ₁	X ₂	X ₃	X ₄	Y	X ₁	X ₂	X ₃	X ₄
(%)	(mm)	(mm)	(mm)	(mm)	(%)	(mm)	(mm)	(mm)	(mm)
52	330	75	72	203	10	128	33	14	80
62	169	108	134	60	46	134	178	62	109
74	146	85	141	189	73	37	157	178	57
31	112	123	45	74	71	128	168	97	146
31	121	125	11	156	50	97	123	70	43
50	17	161	163	98	55	89	50	143	185
84	133	252	105	145	42	150	70	55	54
31	83	46	43	150	29	104	55	71	34
57	216	74	194	29	38	104	128	31	139
50	212	79	107	86	70	202	38	164	128
44	112	196	77	21	63	53	101	96	143
35	100	46	39	120	34	99	107	45	97
62	75	140	142	91	62	203	75	140	142
31	153	32	80	105	74	164	124	127	108
55	328	78	67	202	26	79	41	63	69
40	47	39	69	136	24	123	79	41	63
45	182	35	116	111	54	180	154	81	32
12	41	63	69	16	46	140	142	91	107
12	90	45	17	75	54	144	188	79	39
18	86	76	23	83	72	334	138	148	96
53	96	112	123	45	49	99	224	140	34
20	64	103	37	27	60	191	134	53	132
60	159	54	100	89	41	135	107	76	75
59	179	60	135	102	66	170	127	97	129
71	93	33	213	116	59	251	100	74	183
56	55	86	61	170	32	100	46	39	122
70	153	145	102	109	75	282	56	94	168
47	96	109	110	67	60	159	37	103	232
16	79	39	70	14	25	125	11	154	59
39	135	196	102	21	78	261	112	119	178

A amostra Regional, originalmente com 60 eventos, foi dividida aleatoriamente em duas amostras menores com 30 eventos cada (Tabela 7). Destas duas amostras, uma foi utilizada para calibrar os dois modelos, e a segunda para verificação dos mesmos. Para cada modelo se apresenta, então, o resultado da calibração e o seu desempenho na simulação de rendimentos.

7.1 Modelo LIN

7.1.1 Calibração do Modelo LIN. Amostra 1.

Equação de regressão :

$$Y = - 10.4 + 0.0272 X_1 + 0.125 X_2 + 0.265 X_3 + 0.168 X_4 \quad (7.1.1)$$

$$s = 8.024 \quad R^2 = 84.7\% \quad R^2(\text{NT}) = 82.2\%$$

Tabela 7.1.1 Estatísticas dos parâmetros estimados. Modelo LIN.

Preditor	Coef	Stdev	razão-T	p
β	-10.446	5.223	-2.00	0.056
a_1	0.02723	0.02238	1.22	0.235
a_2	0.12480	0.02758	4.53	0.000
a_3	0.26523	0.03057	8.68	0.000
a_4	0.16839	0.02980	5.65	0.000

Tabela 7.1.2 Análise de variância. Modelo LIN.

ORIGEM	GL	SS	MS	F	p
Regressão	4	8893.6	2223.4	34.53	0.000
Resíduos	25	1609.7	64.4		
Total	29	10503.4			

7.1.2 Verificação do Modelo LIN. Amostra 2




Figura 7.1 Rendimentos observados (Yobs) e calculados (Ycalc) usando a equação (7.1.1).

7.1.3 Comentários do ajuste e da verificação. Modelo LIN.

No ajuste se observou um nível de significância baixo para a estimativa de β ($p = 5.6\%$) e para a_1 mais ainda ($p = 23.5\%$). O ajuste foi satisfatório, apresentando $R^2(NT) = 82.2\%$, com erro padrão médio das estimativas 8.024% (642 Kg/ha). A estatística $F = 34,53$ da Tabela 7.1.2 indica que a regressão é significativa para estimar rendimentos.

Os valores das estimativas de β e a_1 se mostraram coerentes com o significado físico que as precipitações efetivas possuem no desenvolvimento do milho, como evidenciado pela estimativa de a_3 , que coincide com o período crítico de florescimento/enchimento de grãos.

A equação (7.1.1) mostra no gráfico da Figura 7.1 que pode simular rendimentos dentro de uma faixa razoável de erro, acompanhando valores altos e baixos, comprovado também pela boa

correlação entre valores observados e calculados (correlação = 0.864).

7.2 Modelo LOG

7.2.1 Ajuste do Modelo LOG. Amostra 1.

Equação de regressão :

$$Y = 0.103X_1^{0.163}X_2^{0.321}X_3^{0.508}X_4^{0.368} \quad (7.2.1)$$

$$s = 0.08072 \quad R^2 = 89.2\% \quad R^2(\text{NT}) = 87.5\%$$

Tabela 7.2.1 Estatísticas dos parâmetros estimados. Modelo LOG.

Preditor	Coef	Stdev	razão-T	P
C_1	-0.9858	0.2009	-4.91	0.000
λ_1	0.16296	0.05817	2.80	0.010
λ_2	0.32110	0.06139	5.23	0.000
λ_3	0.50757	0.05036	10.08	0.000
λ_4	0.36819	0.04681	7.87	0.000

Tabela 7.2.2 Análise de variância. Modelo LOG

Origem	GL	SS	MS	F	P
Regressão	4	1.35221	0.33805	51.88	0.000
Erro	25	0.16289	0.00652		
Total	29	1.51511			

7.2.2 Verificação do Modelo LOG. Amostra 2.




Figura 7.2.1 Rendimentos observados (Yobs) e calculados (Ycalc) usando a equação (7.2.1).

7.2.3 Comentários do ajuste e da verificação. Modelo LOG.

O ajuste do Modelo LOG foi um pouco melhor que o do Modelo LIN, com $R^2(NT) = 87.5\%$, e a significância das estimativas dos parâmetros muito satisfatórias (Tabela 7.2.1). A estatística F da Tabela 7.2.2 aumentou para 51.88. O gráfico da Figura 7.2.1 mostra o bom desempenho da equação 7.2.1 para estimar rendimentos, evidenciado também pela correlação entre valores observados e calculados (correlação = 0.887).

8. Relação entre λ_i e ETP_i

Observando o resultado da análise de otimização (eq. 3.12) e aplicando esta equação em todas as estações nas quais se ajustaram os modelos, teremos porcentagens diferentes, e em consequência distribuições diferentes da água num mesmo intervalo de soma térmica. Ora, é de se esperar que dentro de uma região como o Rio Grande do Sul, estas porcentagens de distribuição da água durante o ciclo de crescimento do milho sejam aproximadamente semelhantes, e se ocorre variação nestas porcentagens (que é o caso), este fato deveria ser atribuído a dois fatores principais : à variação da evapotranspiração potencial entre as estações e a erros amostrais, pois sabe-se que a evapotranspiração potencial (ETP) varia de região para região (e numa mesma região em menor grau).

A otimização dos rendimentos com multiplicadores de Lagrange apresentada no item 3.4.1 prova que para maximizar os rendimentos é preciso distribuir C_2 proporcionalmente à magnitude dos parâmetros λ_i . Este resultado permite desenvolver a seguinte análise : vamos supor que se estime e conheça a priori a ETP do milho em cada intervalo de soma térmica (ETP_i). Em consequência, a evapotranspiração potencial total (ETP_T) será :

$$ETP_T = \sum_{i=1}^n ETP_i \quad (8.1)$$

Sem entrar em considerações de frequência e eficiência de irrigação no momento, vamos supor também que as precipitações efetivas X_i fiquem totalmente disponíveis para a planta e se transformem integralmente em evapotranspiração (ET_i) :

$$X_i = ET_i \quad (8.2)$$

Para que se atinja o rendimento máximo sem que os outros fatores sejam limitantes, a precipitação efetiva deverá ser igual à evapotranspiração potencial ETP_i :

$$X_i = ETP_i = ET_i \quad (8.3)$$

Lembrando a restrição 3.8 e substituindo em (8.3), a equação (3.12) fica :

$$ETP_i = \frac{\lambda_i}{\epsilon} \sum_{i=1}^n ETP_i \quad (8.4)$$

e isolando $\frac{\lambda_i}{\epsilon}$:

$$\frac{\lambda_i}{\epsilon} = \frac{ETP_i}{\sum_{i=1}^n ETP_i} \quad (8.5)$$

Se as hipóteses anteriores estão corretas, a equação (8.5) expressa uma relação fundamental entre λ_i e ETP_i , e os parâmetros λ_i nesta equação se correspondem proporcionalmente com a magnitude da evapotranspiração potencial em cada intervalo. Isto quer dizer também que os déficits devem ser distribuídos proporcionalmente às magnitudes de ETP_i para maximizar os rendimentos por unidade de água.

Se na equação (8.5) ETP fosse estimada através do produto entre o coeficiente de cultivo Kc_i e a evapotranspiração potencial de referência ETP_i^0 , a equação (8.5) poderia ser expressa por :

$$\frac{\lambda_i}{\epsilon} = \frac{Kc_i \cdot ETP_i^0}{\sum_{i=1}^n Kc_i \cdot ETP_i^0} \quad (8.6)$$

Para verificar a equação (8.6) seria interessante comparar o termo da esquerda da equação achado para cada posto com a evapotranspiração potencial média do milho em cada intervalo para

todos os eventos incluídos na amostra que geraram as estimativas de λ_i . Devido à falta de dados para calcular ETP_o , fez-se uma regressão de λ_i sobre Kc_i , acreditando-se que a maior parte da variação de ETP_i é devida ao coeficiente de cultivo Kc_i , e em menor grau é explicada pela variação de ETP_o .

Os valores de Kc_i utilizados na regressão foram tirados do trabalho de Lorber e Haith (1981), onde apresentam a variação deste em função da porcentagem do ciclo vegetativo do milho. Foi feita uma interpolação linear para obter valores aproximados de Kc_i nos intervalos 0-25, 25-50, 50-75 e 75-100 %. Os resultados estão expostos na Tabela 8.1.

Tabela 8.1 Valores aproximados de Kc_i nos 4 intervalos de soma térmica.

STT (%)	0-25	25-50	50-75	75-100
Kc_i	0.550	0.830	1.200	0.700




Figura 8.1 λ_i , Kc_i vs porcentagem da soma térmica nos quatro intervalos, PST(%).

Tabela 8.2 Valores de λ_i estimados pelo Modelo LOG.

Posto	λ_1	λ_2	λ_3	λ_4	ϵ
Taquari	0.079	0.369	0.355	0.142	1.201
Veranópolis	0.162	0.265	0.409	0.226	1.218
Livramento	0.101	0.154	0.677	0.137	0.946
S. Augusto	0.271	0.331	0.372	0.244	1.062
Regional	0.144	0.330	0.513	0.336	1.069
Sete Lagoas	0.057	0.330	0.544	0.140	1.323
São Borja	0.031	0.153	0.727	0.290	1.070
Media	0.121	0.276	0.514	0.216	1.127

Plotando os valores médios de λ_i (ver Figura 8.1), juntamente com os valores de Kc_i da Tabela 8.1 vs a percentagem da Soma Térmica em cada intervalo, se pode ver nitidamente a mesma tendência e comportamento da variação de Kc_i e λ_i em função da variação da ST.

Clarke (1988, c.pessoal), sugeriu uma análise de variância dos parâmetros estimados λ_i (entre as estações e entre os intervalos de soma térmica) que inclui uma regressão sobre Kc_i (ver Tabela 8.3):

Tabela 8.3 Análise de variância para λ_i com regressão sobre Kc_i .

ORIGEM	GL	SS	MS	F	p
ENTRE INTERVALOS	3	0.58842	0.19614	15.33	< 0.001
REGRESSÃO SOB Kc_i	1	0.58702	0.58702	45.89	< 0.001
DESVIOS DA REGR.	2	0.00140	0.00070	0.050	NS
ENTRE POSTOS	6	0.02391	0.00399	0.310	NS
Erro	18	0.23027	0.01279		
TOTAL	27	0.84261			

Esta análise divide a soma dos quadrados desvios entre todas as observações em componentes que têm origem na variação entre as estações (Postos) e entre os intervalos; o resto, que não têm explicação óbvia, é o 'erro'.

A variação entre os intervalos pode subdividir-se numa componente que resulta da regressão de λ_i sobre Kc_i (com 1 grau de liberdade) e um resíduo (com 2 graus de liberdade) que mede os desvios da linearidade em torno da reta de regressão. Esta variância pode ser comparada com a variância não-explicada (i.e. o 'erro'); um teste-F não mostra evidência significativa de não-linearidade na relação entre λ_i e Kc_i ($F = 0.0007/0.012793$; < 1).

Este teste é um teste de hipótese 'declividade da regressão = 0', depois de remover a variação entre as sete estações. Portanto, é razoável adotar a hipótese que λ_i e Kc_i são relacionados linearmente pela seguinte equação de regressão :

$$\lambda_i = -0.211 + 0.601 Kc_i \quad (8.7)$$

$$s = 0.09915 \quad R^2 = 69.7\% \quad R^2(NT) = 68.5\%$$

Tabela 8.4 Estatísticas dos parâmetros estimados da equação (8.7).

PREDITOR	Coefficiente	Stdev	razão-T	p
constante	-0.21143	0.06652	-3.18	0.004
Kc_i	0.60148	0.07784	7.73	<0.001

Tabela 8.5 Análise de variância da regressão sobre Kc_i .

ORIGEM	GL	SS	MS	F	p
Regressão	1	0.58702	0.58702	59.72	<0.001
Erro	26	0.25559	0.00983		
Total	27	0.84261			




Figura 8.2 λ_i vs Kc_i e linha de regressão (equação 8.7).

Este resultado (equação 8.7) verifica parcialmente a equação (8.6), com Kc_i explicando 68.5% da variação dos expoentes λ_i para os sete postos. A equação (8.7) poderá ser útil nos casos em que o número de eventos seja insuficiente para estimar os cinco (5) parâmetros do Modelo LOG. Também é preciso que os coeficientes de cultivo locais (Kc_i) sejam aproximados aos utilizados na regressão (Tabela 8.1), e que o ciclo do milho considere 4 intervalos de crescimento equivalentes, de preferência dividindo a STT em 4 intervalos parciais de Soma Térmica.

8.1 Método do coeficiente C_1 para previsão de rendimentos.

A seguir se apresenta uma metodologia simples, em seis etapas, que ilustra a utilização da equação (8.7) para previsão de rendimentos quando há escassez de informação:

1. Disponer de, no mínimo, 6 ou 7 eventos (datas de semeadura e rendimentos correspondentes), dos quais não haja suspeita de que sofreram efeitos de variáveis que o Modelo LOG não inclui (geadas, granizo, doenças, etc.), sempre excluindo alguns eventos para posterior verificação. De preferência as cultivares deverão apresentar potencial genético equivalente.
2. Acumular a precipitação efetiva diária nos quatro períodos ou intervalos equivalentes de soma térmica necessária entre a semeadura e a maturação (STT).
3. Fazendo uso da equação (8.7) estimar os λ_i em cada intervalo de soma térmica :

$$\lambda_i = -0.211 + 0.601 Kc_i$$

4. Nesta etapa, com as precipitações efetivas conhecidas em cada intervalo, calcula-se X' para cada evento, onde :

$$X' = X_1^{\lambda_1} \cdot X_2^{\lambda_2} \cdot X_3^{\lambda_3} \cdot X_4^{\lambda_4} \quad (8.8)$$

5. Conhecendo X' para cada evento, faz-se uma regressão do tipo :

$$Y = C_1 \cdot X' \quad (8.9)$$

com o objetivo de obter uma estimativa de C_1 . A análise de variância resultante desta regressão dará um diagnóstico da significância de C_1 , juntamente com o desvio da estimativa de C_1 (Stdev e p).

6. Agora só resta verificar a previsão de rendimentos com os parâmetros estimados λ_i e C_1 . Isto é feito comparando os

valores observados (que haviam sido excluídos inicialmente) e calculados pelo Modelo LOG da forma descrita aqui.

8.2 Aplicação do Método do coeficiente C_1 para previsão de rendimentos

Os dados aqui utilizados foram obtidos de ensaios de semeaduras contínuas durante o período 1979-1985, na Estação Experimental de Taquarí (Seção de Ecología do IPAGRO). Estes dados não tomaram parte na amostra que gerou os parâmetros das equações (6.1.1) e (6.1.2).

Foram utilizados híbridos de ciclo equivalente, já que não foi mantido o mesmo material durante todo o período experimental, sendo : Agroceres 64 (1979-1983), Agroceres 64-A (1984) e Pioneer 6872 (1985). O delineamento experimental foi de blocos ao acaso com quatro repetições por tratamento, onde se observou a precipitação bruta (mm) em cada um dos quatro (4) subperíodos a seguir:

Subperíodo 1: Emergência até 30 dias após emergência;

Subperíodo 2: Término do Subperíodo 1 até início do endoamento;

Subperíodo 3: Início do endoamento até 30 dias após;

Subperíodo 4: Término do Período 3 até maturação fisiológica;

totalizando assim um período de aproximadamente 120 dias, sem contar os dias passados entre a semeadura e a emergência (10 dias, em média).

Deve ser destacado que os valores de precipitação aqui utilizados são brutos, porque as datas de ocorrência dos subperíodos acima não foram possíveis de obter, não podendo aplicar a metodologia descrita em 3.2.4. Os dados de rendimento e precipitação estão apresentados na Tabela 8.6.

Tabela 8.6 Rendimentos e precipitações observadas. E.E. Taquari-RS.79/85.

ANO	n	RENDIM. (Kg/ha)	subper.1 (mm)	subper.2 (mm)	subper.3 (mm)	subper.4 (mm)	Total (mm)
(1979)	1	5880	261	206	203	113	783
★(1979)	2	6400	224	236	120	109	689
(1979)	3	6654	303	104	150	143	700
(1980)	4	4250	265	45	117	60	487
(1980)	5	5566	71	231	163	36	501
(1980)	6	5123	129	133	133	78	473
(1981)	7	4180	168	152	74	198	593
★(1981)	8	5094	152	35	209	28	424
★(1981)	9	1667	77	82	55	76	290
★(1982)	10	2317	75	60	70	50	255
(1982)	11	2379	83	70	69	33	255
(1982)	12	6344	273	253	129	34	688
★(1983)	13	3780	184	152	81	175	591
(1983)	14	4383	152	47	65	295	558
★(1984)	15	5049	106	193	109	93	500
(1984)	16	4762	129	171	70	118	488
(1984)	17	4082	109	121	118	154	502
(1985)	18	1410	163	128	17	57	365
(1985)	19	1672	206	66	34	40	347
(1985)	20	1730	66	17	57	68	210

Fonte: Seção de Ecologia do IPAGRO.

★ : Rendimentos selecionados aleatoriamente para estimar C_1 .

1. Das 20 observações apresentadas na Tabela 8.6, 6 foram selecionadas aleatoriamente²⁰ (marcadas com ★), deixando as 14 restantes para verificação na etapa 6.
2. Na Tabela 8.6 já estão acumuladas as precipitações nos quatro intervalos. Apesar de que no critério usado para acumular X_1 , X_2 , X_3 e X_4 não se utilizou a Soma Térmica, pode se dizer que, aproximadamente, cada intervalo representa 25% do ciclo total.

Isto é realizado facilmente com o comando SAMPLE. É importante verificar que os eventos selecionados sejam representativos da amostra original, cubrindo faixas de rendimentos baixos, médios e altos.

3. Para estimar os λ_i , usaram-se os mesmos valores de Kc apresentados na Tabela 8.1, e aplicando a equação (8.7):

$$\lambda_1 = -0.211 + 0.60110.55 \quad \therefore \lambda_1 = 0.120$$

$$\lambda_2 = -0.211 + 0.60110.83 \quad \therefore \lambda_2 = 0.288$$

$$\lambda_3 = -0.211 + 0.60111.20 \quad \therefore \lambda_3 = 0.510$$

$$\lambda_4 = -0.211 + 0.60110.70 \quad \therefore \lambda_4 = 0.210$$

4. Para cada evento marcado com (*) na Tabela 8.5, calcule-se:

$$X' = X_1^{\lambda_1} \cdot X_2^{\lambda_2} \cdot X_3^{\lambda_3} \cdot X_4^{\lambda_4} .$$

A Tabela 8.7 mostra os rendimentos selecionados aleatoriamente, as precipitações X_i e X' .

Tabela 8.7 Rendimentos, X_i e X' .

n	Yobs (Kg/ha)	X_1 (mm)	X_2 (mm)	X_3 (mm)	X_4 (mm)	X'
1	5049	106	193	109	93	225.812
2	5094	152	35	209	28	156.203
3	2317	75	60	70	50	108.367
4	3780	184	152	81	175	221.062
5	1667	77	82	55	76	114.845
6	6400	224	236	120	109	284.230

5. Uma vez calculado X' , fazemos uma regressão dos rendimentos Y_{obs} sobre X' . Para visualizar melhor a relação linear entre estas variáveis, é interessante plotar Y_{obs} vs X' :




Figura 8.3 Y_{obs} vs X' . Estação Experimental de Taquari-RS.

Equação de Regressão :

$$Y = 21.9 X' \quad (8.10)$$

$$s = 968.5 \text{ Kg/ha} \quad R^2(\text{NT}) = 95.7\%$$

Tabela 8.8 Estatísticas da estimativa de C_1 . Taquari-RS

Preditor	Coef	Stdev	razão-T	p
X'	21.885	2.019	10.84	0.000

Tabela 8.9 Análise de Variância. Taquari-RS

ORIGEM	GL	SS	MS	F	p
Regressão	1	110147416	110147416	117.44	0.000
Erro	5	4689601	937920		
Total	6	114837016			

Pela Figura 8.3, Tabelas 8.8 e 8.9 pode se deduzir que, apesar de haver alguma dispersão dos pontos (Y_{obs_i}, X_i') em torno da linha de regressão, esta se mostrou significativa ($F = 117.44$), com uma significância elevada de C_1 ($p < 0.001$). Finalmente, neste estágio, já podemos estabelecer a equação completa para estimar rendimentos de acordo com a amostra apresentada na Tabela 8.5 :

$$Y = 21.9X_1^{0.120} X_2^{0.288} X_3^{0.510} X_4^{0.210} \quad (8.11)$$

6. Com a equação (8.11) procede-se à verificação da mesma, calculando os rendimentos e comparando com as observações (ver Tabela 8.10 e Figura 8.4). Para os 14 eventos que foi feita a simulação, aparentemente as estimativas foram satisfatórias, acompanhando valores baixos e altos de rendimento. A correlação entre valores observados e calculados foi alta ($R = 0.889$), validando a equação (8.10) neste caso.

Tabela 8.10 Rendimentos observados e estimados com a equação (8.11) em (Kg/ha). Estação Experimental de Taquari-RS.

n	Yobs	Ycalc
1	2379	2283
2	5123	4848
3	4762	4098
4	4082	5018
5	4383	3363
6	5566	4989
7	5880	8026
8	1730	1560
9	4250	3430
10	1410	1617
11	4180	4690
12	1672	1817
13	6344	5280
14	6654	6043




Figura 8.4 Rendimentos observados (Yobs) e Rendimentos calculados usando a equação (8.10). Estação Experimental de Taquari-RS.

9. Análise iterativa das estimativas de λ_i

No capítulo 8 se mostraram fortes indicativos de que a utilização de um único conjunto de estimativas de λ_i não seria uma decisão muito errada, ou dizendo de outra forma, os resultados não mostraram evidência significativa para rejeitar a hipótese de que λ_i se correlaciona linearmente com Kc_i ; também se mostrou que a variação dos λ_i entre os postos não é significativa. E se podemos dizer que a variação entre postos não é significativa, podemos também supor que a média das estimativas de λ_i , obtidas em todos os postos, sejam bons estimadores da população λ_i .

Portanto, é de se supor que numa região onde a variação de Kc_i é pequena, a variação de λ_i também será pequena. Esta consideração é muito importante, pois levanta a curiosidade de saber o que aconteceria se se fixasse o valor de λ_i , atribuindo ao coeficiente do Modelo LOG (C_1), as diferenças encontradas nos ajustes iniciais, e, em consequência, as diferenças na distribuição de C_2 para alcançar rendimentos máximos, supondo que tais diferenças devem-se a erros amostrais.

Com o objetivo de estimar um único conjunto de λ_i para ser usado no Rio Grande do Sul, verificando ao mesmo tempo a significância destes no caso onde se analisaram vários postos, Lanna (1989, com. pessoal) sugeriu a utilização de um algoritmo que permite analisar a convergência das estimativas de λ_i . O modelo resultante da aplicação deste algoritmo será denominado Modelo ITER, ao qual corresponderá também uma equação de rendimentos máximos denominada $Y_{maxITER}$. O procedimento é descrito a seguir no item 9.1

9.1 Algoritmo Iterativo para análise de convergência de λ_i .

1. Faz-se a regressão inicial para cada posto de acordo com o Modelo LOG :

$$Y = C_1 X_1^{\lambda_1} \cdot X_2^{\lambda_2} \cdot X_3^{\lambda_3} \cdot X_4^{\lambda_4} ,$$

obtendo assim uma estimativa inicial de C_1 e λ_i .

2. Conhecidas as estimativas iniciais de C_1 para cada

posto, faz-se uma regressão múltipla com interseção nula com todos os postos, onde a variável dependente será Y/C_1 (cada posto com seu C_1 correspondente):

$$Y/C_1 = X_1^{\lambda'_1} \cdot X_2^{\lambda'_2} \cdot X_3^{\lambda'_3} \cdot X_4^{\lambda'_4},$$

e desta forma se terá uma estimativa global de λ_i' .

3. Com a estimativa de λ_i' já conhecida, estima-se C_1' para cada posto, através de uma regressão linear simples com interseção nula:

$$Y = C_1' \cdot X', \text{ onde: } X' = X_1^{\lambda'_1} \cdot X_2^{\lambda'_2} \cdot X_3^{\lambda'_3} \cdot X_4^{\lambda'_4}$$

4. Retorna ao passo 2 com C_1' individual para cada posto repetindo a operação até que as diferenças entre os λ_i' entre uma iteração e outra seja pequena o suficiente para finalizar o procedimento.

Ao final da última iteração se terá, desta forma, uma estimativa específica de C_1 para cada posto e um conjunto de λ_i' comuns a todos os postos. A seguir se apresentam os resultados da aplicação deste algoritmo, primeiramente considerando as quatro variáveis independentes (X_1 , X_2 , X_3 e X_4), e após com três variáveis, excluindo X_4 . O posto de Sete Lagoas não participou pela necessidade de verificar este procedimento posteriormente (item 9.3).

9.2 Resultados do algoritmo iterativo com 4 variáveis (X_1 , X_2 , X_3 e X_4)

9.2.1 Resultados da 1ª iteração

$$Y/C_1 = X_1^{0.059} \cdot X_2^{0.292} \cdot X_3^{0.534} \cdot X_4^{0.294} \quad (9.2.1)$$

$$s = 0.2711$$

$$R^2(\text{NT}) = 0.984$$

Tabela 9.2.1 Estatísticas das estimativas de λ_i na 1ª iteração.

Preditor	λ_i	St.dev. λ_i	T-ratio	p
X_1	0.05896	0.05703	1.03	0.300
X_2	0.29236	0.05248	5.57	<0.001
X_3	0.53353	0.05292	10.08	<0.001
X_4	0.29432	0.05217	5.64	<0.001

Tabela 9.2.2 Análise de variância na 1ª iteração.

ORIGEM	GL	SS	MS	F	p
Regressão	4	984.35	246.09	3515.6	<0.001
Resíduos	203	14.92	0.07		
Total	207	999.27			

Tabela 9.2.3 Estimativas de C_i para cada posto na 1ª iteração.

POSTO	C_i	St.dev. C_i	T-ratio	p
Taquari	0.338	0.01044	32.41	<0.001
São Borja	0.236	0.01197	19.70	<0.001
Livramento	0.257	0.01253	20.54	<0.001
Veranópolis	0.233	0.00576	40.50	<0.001
Sto Augusto	0.211	0.00762	27.71	<0.001
Regional	0.241	0.00469	51.45	<0.001

9.2.2 Resultados da 30ª iteração

$$Y/C_1 = X_1^{0.092} \cdot X_2^{0.254} \cdot X_3^{0.532} \cdot X_4^{0.255} \quad (9.2.2)$$

$$s = 0.1111$$

$$R^2(NT) = 0.997$$

Tabela 9.2.4 Estatísticas de λ_i' na 30ª iteração.

Preditor	λ_i'	St.dev. λ_i'	T-ratio	p
X ₁	0.09231	0.02338	3.95	<0.001
X ₂	0.25428	0.02151	11.82	<0.001
X ₃	0.53196	0.02169	24.52	<0.001
X ₄	0.25535	0.02139	11.39	<0.001

Tabela 9.2.5 Análise de variância na 30ª iteração.

ORIGEM	GL	SS	MS	F	p
Regressão	4	915.41	228.85	22885.0	<0.001
Resíduos	203	2.51	0.01		
Total	207	917.92			

Tabela 9.2.6 Estimativas de C_i para cada posto na 30ª iteração.

POSTO	C _i	St.dev.C _i	T-ratio	p
Taquari	0.403	0.01242	32.45	<0.001
São Borja	0.286	0.01402	20.40	<0.001
Livramento	0.317	0.01341	23.62	<0.001
Veranópolis	0.282	0.00683	41.39	<0.001
Sto Augusto	0.259	0.00882	29.42	<0.001
Regional	0.295	0.00551	53.44	<0.001

Comparando as Tabelas 9.2.1 e 9.2.4 se observa um incremento elevado da significância dos λ_i' , evidenciado pela coluna T-ratio. Na 1ª iteração o desvio padrão médio das estimativas era 0.2711, ao passo que na 30ª iteração este valor se reduziu a menos da metade ($s = 0.1111$).

De acordo com os resultados da 30ª iteração, as equações para cada posto são as seguintes (Tabela 9.2.7) :

Tabela 9.2.7 Parâmetros estimados após a 30ª iteração.

Posto	C_1	λ_1	λ_2	λ_3	λ_4
Taquari	0.403	0.0923	0.2543	0.5320	0.2553
São Borja	0.286	"	"	"	"
Livramento	0.317	"	"	"	"
Veranópolis	0.282	"	"	"	"
Sto Augusto	0.259	"	"	"	"
Regional	0.295	"	"	"	"

Note-se que os valores de λ_i apresentados na Tabela 9.2.7 são muito semelhantes aos λ_i mostrados no capítulo anterior (Tabela 8.2). A seguir a Figura 9.2.1 mostra o ajuste das equações apresentadas na Tabela 9.2.7, comparando os valores de rendimentos observados (Yobs) e calculados (Ycalc) para todos os postos.

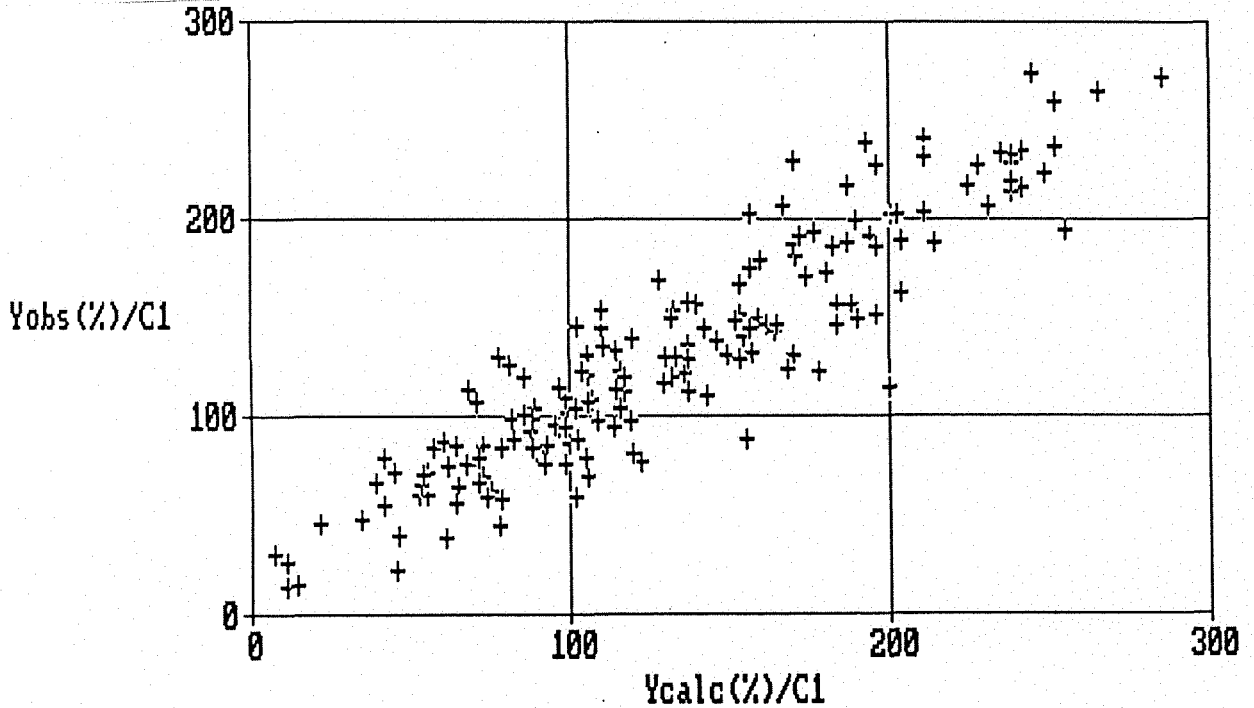


Figura 9.2.1 Yobs(%) / C₁ vs Ycalc(%) / C₁ para todos os postos.

O importante deste procedimento é que o resultado é muito próximo ao resultado que se obtém calibrando individualmente os parâmetros do modelo LOG, havendo somente a necessidade de estimar somente um parâmetro ao invés de cinco (ver item 9.3).

9.3 Verificação das estimativas λ_i' obtidas na 30ª iteração.

Para verificar as estimativas λ_i' utilizou-se a amostra de Sete Lagoas-MG, originalmente com 15 eventos. Esta amostra dividiu-se em duas : uma de 8 eventos para calibração de C_1' (Amostra 2) e outra de 7 eventos para verificação (Amostra 1), expostas na Tabela 9.3.1.

Tabela 9.3.1 Rendimentos e precipitações efetivas em Sete Lagoas-MG.

n	Amostra 1					Amostra 2				
	Y (%)	X ₁ (mm)	X ₂ (mm)	X ₃ (mm)	X ₄ (mm)	Y (%)	X ₁ (mm)	X ₂ (mm)	X ₃ (mm)	X ₄ (mm)
1	56	78	186	163	80	63	31	134	138	227
2	56	64	251	155	134	9	104	160	3	39
3	35	228	140	139	23	65	201	137	162	174
4	4	108	73	10	60	22	213	114	78	2
5	58	43	182	121	198	75	140	133	241	28
6	56	138	140	180	47	45	118	208	27	198
7	46	198	128	99	16	9	159	2	59	54
8						41	186	163	80	162

9.3.1 Ajuste de C_1' . Amostra 2.

Primeiramente calculou-se X' pela expressão :

$$X' = X_1^{\lambda_1'} \cdot X_2^{\lambda_2'} \cdot X_3^{\lambda_3'} \cdot X_4^{\lambda_4'} \quad (9.3.1)$$

e após realizou-se uma regressão com interseção nula. A equação de regressão obtida é a seguinte :

$$Y = 0.240 X' \quad (9.3.2)$$

$$s = 10.88 \quad R^2(NT) = 95.22\%$$

Tabela 9.3.2 Estatísticas da estimativa de C_1' . Sete Lagoas - MG.

Preditor	Coef	Stdev	razão-T	p
C_1'	0.23982	0.01982	12.10	0.000

Tabela 9.3.3 Análise de Variância. Sete Lagoas - MG.

ORIGEM	GL	SS	MS	F	p
Regressão	1	17342	17342	146.38	0.000
Erro	7	829	118		
Total	8	18171			

O gráfico da Figura 9.3.1 mostra uma relação linear entre os rendimentos observados (Yobs) e X' . O ajuste foi bom, com um coeficiente de determinação de 95.22%, sendo a significância da estimativa de $C_1 \leq 0.001$, com desvio 0.01992. O erro padrão médio das estimativas pode ser considerado baixo, sendo igual a 10.88% (870 Kg/ha). Da mesma forma, a regressão (9.3.2) apresentou significância para estimar rendimentos, com $F = 146.38$.

Desta forma, conhecendo a estimativa de C_1 , pode ser montada a equação completa para estimar rendimentos em Sete Lagoas :

$$Y = 0.240 \cdot X_1^{0.0923} \cdot X_2^{0.2543} \cdot X_3^{0.532} \cdot X_4^{0.2553} \tag{9.3.3}$$




Figura 9.3.1 Rendimentos observados (Yobs) vs X' e reta de regressão.

9.3.2 Verificação da equação (9.3.3). Amostra 1.

Usando a equação (9.3.3) para estimar rendimentos da Amostra 1, os resultados são os seguintes (Tabela 9.3.4) :

Tabela 9.3.4 Rendimentos observados e calculados. Sete Lagoas-MG.

n	Yobs	Ycalc	s(Ycalc)	Interv.Conf 95%
1	56	62	5.15	(50 , 74.46)
2	56	73	6.06	(59.97, 87.64)
3	35	43.76	3.53	(34 , 51.12)
4	4	11	0.88	(9.57, 12.73)
5	58	63	5.21	(50.73, 75.39)
6	56	56	4.65	(45.22, 67.20)
7	46	31	2.59	(25.25, 37.53)

Na tabela 9.3.4 nota-se que dos sete eventos, o Nº 4 e Nº 7 caem fora dos intervalos de confiança com 95% de probabilidade²¹, sendo que o evento 4 apresentou um rendimento muito baixo (320 Kg/ha), e o calculado 852 Kg/ha. Realmente nesta faixa inferior de rendimentos é muito arriscado se fazer um prognóstico, porque o déficit é muito severo a planta acaba sendo debilitada, ficando mais suscetível a doenças e pragas. No evento Nº7, o rendimento observado foi 46% (3680 Kg/ha), e o calculado 31.39% (2511 Kg/ha), o que significa um erro relativo de 31.8%.

9.4 Ajuste de C_1 com as Amostras 1 e 2.

Com o objetivo de dispor de uma equação com os parâmetros λ_i' , mas com uma estimativa de C_1 mais significativa, realizou-se uma regressão juntando as amostras 1 e 2 da Tabela 9.3.1, supondo que aumentando o tamanho da amostra se incorpora maior informação à estimativa de C_1 . Esta equação resultante será utilizada no capítulo 10.

21

O cálculo dos intervalos de confiança é facilmente realizado usando o subcomando PREDICT do comando REGRESSION. Por maiores detalhes sobre intervalos de confiança e a sua aplicação, o leitor pode se referir à Ryan, Ryan e Joiner (1988) e Draper e Smith (1980).

A equação de regressão obtida é a seguinte :

$$Y = 0.227 X' \quad (9.4.1)$$

$$s = 10.03 \quad R^2(NT) = 95.7 \%$$

Tabela 9.4.1 Estatísticas da estimativa de C_1' . Sete Lagoas - MG.

Preditor	Coef	Stdev	razão-T	p
X'	0.22716	0.01257	18.07	0.000

Tabela 9.4.2 Análise de Variância. Sete Lagoas - MG.

ORIGEM	GL	SS	MS	F	p
Regressão	1	32890	32890	326.67	0.000
Erro	14	1410	101		
Total	15	34300			

9.4.1 Comentários

Como se esperava, o desvio da estimativa de C_1' diminuiu de 0.01982 (Tabela 9.3.2) para 0.01257 (Tabela 9.4.1). A Figura 9.4.1 mostra a relação linear entre os rendimentos observados (Y_{obs}) vs X' e a reta de regressão. A Figura 9.4.2 mostra os rendimentos observados vs calculados pela equação (9.4.1) :




Figura 9.4.1 Rendimentos observados vs X' e reta de regressão. Sete Lagoas.




Figura 9.4.2 Rendimentos observados vs rendimentos calculados. Sete Lagoas.

9.5 Resultados do algoritmo iterativo com 3 variáveis (X_1 , X_2 e X_3)

Aplicou-se da mesma forma o algoritmo exposto em 9.1, mas agora excluindo a variável independente X_4 , pela necessidade de dispor de uma equação para estimar rendimentos somente com 3 intervalos, antecipando-se à data da colheita, pois o prognóstico é realizado quando a cultura atinge aproximadamente 75% da soma térmica total, fornecendo assim ao agricultor uma estimativa do rendimento futuro para que possa tomar decisões referentes ao armazenamento, comercialização, etc.. Isto é possível porque realmente a precipitação no 4º intervalo não tem uma influência tão decisiva no rendimento, e o modelo LOG3 leva em conta implicitamente as chances de chuva no 4º intervalo.

9.5.1 Resultados da 1ª iteração

Equação de regressão :

$$Y/C_1 = X_1^{0.127} \cdot X_2^{0.264} \cdot X_3^{0.570} \quad (9.3.1)$$

$$s = 0.2597 \quad R^2(\text{NT}) = 0.980$$

Tabela 9.5.1 Estatísticas das estimativas de λ_i' na 1ª iteração.

Preditor	λ_i'	St.dev. λ_i'	T-ratio	p
X_1	0.12652	0.04784	2.64	0.005
X_2	0.26380	0.05017	5.26	<0.001
X_3	0.57037	0.04783	11.93	<0.001

Tabela 9.5.2 Análise de variância na 1ª iteração.

ORIGEM	GL	SS	MS	F	p
Regressão	4	672.86	224.29	3204	<0.001
Resíduos	203	13.75	0.07		
Total	207	686.61			

Tabela 9.5.3 Estimativas de C_i para cada posto na 1ª iteração.

POSTO	C	St.dev.C	T-ratio	p
Taquari	0.785	0.02556	30.70	<0.001
São Borja	0.495	0.03188	15.54	<0.001
Livramento	0.620	0.03554	17.45	<0.001
Veranópolis	0.556	0.01794	31.01	<0.001
S Augusto	0.525	0.02243	23.41	<0.001
Regional	0.620	0.03554	17.45	<0.001

9.5.2 Resultados da 30ª iteração (3 variáveis)

Equação de regressão :

$$Y/C_1 = X_1^{0.095} \cdot X_2^{0.210} \cdot X_3^{0.507} \quad (9.3.2)$$

$$s = 0.1401$$

$$R^2(\text{NT}) = 0.992$$

Tabela 9.5.4 Estatísticas das estimativas de λ_i' na 30ª iteração.

Preditor	l	St.dev.l	T-ratio	p
X_1	0.09495	0.02582	3.68	<0.001
X_2	0.21044	0.02708	7.77	<0.001
X_3	0.50743	0.02581	19.66	<0.001

Tabela 9.5.5 Análise de variância na 30ª iteração.

ORIGEM	GL	SS	S	F	p
Regressão	3	480.64	160.21	8010	<0.001
Resíduos	203	4.00	0.02		
Total	207	484.65			

Tabela 9.5.6 Estimativas de C_1 para cada posto na 30ª iteração.

POSTO	C	St.dev.C	T-ratio	p
Taquari	1.49879	0.04811	31.16	<0.001
São Borja	0.96364	0.05909	16.31	<0.001
Livramento	1.21516	0.06277	19.36	<0.001
Veranópolis	1.09264	0.03781	28.90	<0.001
S Augusto	1.07445	0.04659	23.06	<0.001
Regional	1.24671	0.03596	34.67	<0.001

Comparando as Tabelas 9.5.1 e 9.5.4 nota-se um incremento na significância das estimativas de λ_1' , principalmente de λ_1' . O erro padrão médio dos logaritmos se reduziu de $s = 0.2597$ para $s = 0.1401$ na 30ª iteração, indicando uma acurácia superior do modelo LOG3 na 30ª iteração.

10. Equações de rendimentos máximos e distribuição ótima da água.

Neste capítulo se apresentam os resultados da aplicação da equação (3.31-Pág.54) usando as estimativas de λ_i e C_1 estimadas inicialmente com o Modelo LOG; a curva resultante será chamada Y_{maxLOG} . A mesma equação (3.31) será aplicada usando as estimativas λ_i e C_1 obtidas no capítulo 9 com o algoritmo iterativo incluindo 4 variáveis independentes; as curvas resultantes neste caso serão chamadas $Y_{maxITER}$. Também se mostra, para fins comparativos, a curva obtida através da aplicação da equação (3.34-Pág.55), usando as estimativas de α_i e β do Modelo LIN calibrado no capítulo 6; esta curva será chamada Y_{maxLIN} . A cada equação de rendimentos máximos corresponderá uma distribuição ótima de C_2 , que é o resultado da aplicação da equação (3.9). De acordo com motivos expostos no capítulo 8 (1º parágrafo), somente se apresentará uma tabela de distribuição ótima da água, que corresponde às estimativas λ_i obtidas com o algoritmo iterativo.

10.1 Taquari-RS.

10.1.1 Modelo LOG

Equação de rendimentos máximos :

$$Y_{maxLOG} = 0,281.C_2^{0.94} \quad (10.1.1)$$

10.1.2 Modelo LIN

Equação de rendimentos máximos :

$$Y_{maxLIN} = 0,226.C_2 + 0,02 \quad (10.1.2)$$

10.1.3 Modelo ITER

Equação de rendimentos máximos :

$$Y_{maxITER} = 0.100.C_2^{1.13} \quad (10.1.3)$$




Figura 10.1.1 Rendimentos observados e equação teórica YmaxLOG vs C₂. Taquari - RS




Figura 10.1.2 Rendimentos observados e equação teórica YmaxLIN vs C₂. Taquari - RS




Figura 10.1.3 Rendimentos observados e equação teórica $Y_{maxITER}$ vs C_2 . Taquari - RS

Tabela 10.1.1 Distribuição ótima da água e rendimentos esperados de acordo com o Modelo ITER. Taquari - RS

TOTAL (mm)	X1 (mm)	X2 (mm)	X3 (mm)	X4 (mm)	Y (%)
100	8	22	47	23	18
150	12	34	70	34	29
200	16	45	94	45	41
250	20	56	117	56	52
300	24	67	141	68	64
350	28	78	164	79	76
400	32	90	188	90	89
450	37	101	211	101	102
500	41	112	235	113	115
550	45	123	258	124	128
600	49	135	282	135	141
650	53	146	305	146	154

10.1.4 Comentários

As equações de rendimentos máximos obtidas das três formas apresentadas divergem muito pouco entre si. Este fato pode ser visualizado melhor na Figura 10.1.4, onde se superpõem as três equações. Isto quer dizer que a equação (3.34), apesar de não ter sido demonstrado matematicamente que é uma equação de rendimentos máximos, acompanha perfeitamente as outras duas curvas, não devendo este fato ser encarado apenas como simples coincidência, pois este paralelismo se verifica na maioria das estações. Nas três primeiras figuras apresentadas, pode ser observado que acima de $C_2 = 300$ mm, poucos eventos receberam distribuições aproximadamente ótimas (precipitações efetivas totais), razão pela qual estes eventos estão mais afastados da curva de rendimentos máximos, o que significaria um incremento maior na produção se C_2 fosse uma variável de decisão.





Figura 10.1.4 YmaxLOG, YmaxLIN e YmaxITER vs C_2 . Taquari-RS.

10.2 Veranópolis-RS.

10.2.1 Modelo LOG

Equação de rendimentos máximos :

$$Y_{maxLOG} = 0.090 \cdot C_2^{1.06} \quad (10.2.1)$$

Figura 10.2.1 Rendimentos observados e equação YmaxLOG vs C₂. Veranópolis-RS.




Figura 10.2.2 Rendimentos observados e equação Y_{maxLIN} vs C_2 . Veranópolis-RS.

10.2.2 Modelo LIN

Equação de rendimentos máximos :

$$Y_{maxLIN} = 0,170 \cdot C_2 - 9,94 \quad (10.2.2)$$

10.2.3 Modelo ITER

Equação de rendimentos máximos :

$$Y_{\max ITER} = 0.070 \cdot C_2^{1.13}$$

(10.2.3)




Figura 10.2.3 Rendimentos observados e equação $Y_{\max ITER}$ vs C_2 . Veranópolis-RS.

Tabela 10.2.1 Distribuição ótima da água e rendimentos esperados de acordo com o Modelo ITER. Veranópolis-RS.

TOTAL (mm)	X1 (mm)	X2 (mm)	X3 (mm)	X4 (mm)	Y (%)
100	8	22	47	23	13
150	12	34	70	34	20
200	16	45	94	45	28
250	20	56	117	56	37
300	24	67	141	68	45
350	28	78	164	79	53
400	32	90	188	90	62
450	37	101	211	101	71
500	41	112	235	113	80
550	45	123	258	124	89
600	49	135	282	135	99
650	53	146	305	146	108
700	57	157	329	158	117

10.2.4 Comentários

É interessante notar as diferenças entre as declividades das equações de Taquarí (10.1.2 e 10.1.3) e as de Veranópolis (10.2.2 e 10.2.3). Estas diferenças significam que para uma mesma disponibilidade hídrica C_2 , os rendimentos esperados serão maiores em Taquarí. As causas prováveis que podem explicar esta diferença são :

- O tipo de solo em Taquarí pode ser mais favorável à cultura do milho (maior armazenamento, melhor drenabilidade, etc.).
- Podem haver diferenças nos potenciais genéticos das cultivares que integram a amostra de Taquarí e Veranópolis.
- Pode ser que uma maior Soma Térmica Total (STT) em Taquarí permita um maior crescimento da planta, e em consequência uma maior produtividade.
- O nível tecnológico pode ser superior em Taquarí.

A Figura 10.2.4 mostra as três curvas juntas, onde pode ser visto que não ocorreram diferenças significativas entre elas. Mais uma vez a equação Y_{maxLIN} mostrou que acompanha bem as outras duas curvas.




Figura 10.2.4 Y_{maxLOG} , Y_{maxLIN} e $Y_{maxITER}$ vs C_2 . Veranópolis - RS.

10.3 Santo Augusto-RS

10.3.1 Modelo LOG

Equação de rendimentos máximos :

$$Y_{maxLOG} = 0.031 \cdot C_2^{1.22} \quad (10.3.1)$$




Figura 10.3.1 Rendimentos observados e YmaxLOG vs C₂. Sto Augusto-RS.

10.3.2 Modelo LIN

Equação de rendimentos máximos :

$$Y_{maxLIN} = 0,130 \cdot C_2 - 7,14 \quad (10.3.2)$$




Figura 10.3.2 Rendimentos observados e YmaxLIN vs C₂. Sto Augusto-RS.




Figura 10.3.3 Rendimentos observados e YmaxITER vs C₂. Sto Augusto-RS.

10.3.3 Modelo ITER

Equação de rendimentos máximos :

$$Y_{maxITER} = 0,064 \cdot C_2^{1,13} \quad (10.3.3)$$

Tabela 10.3.1 Distribuição ótima da água e rendimentos esperados de acordo com o Modelo ITER. Sto Augusto-RS.

TOTAL (mm)	X1 (mm)	X2 (mm)	X3 (mm)	X4 (mm)	Y (%)
100	8	22	47	23	12
150	12	34	70	34	19
200	16	45	94	45	26
250	20	56	117	56	33
300	24	67	141	68	41
350	28	78	164	79	49
400	32	90	188	90	57
450	37	101	211	101	65
500	41	112	235	113	73
550	45	123	258	124	82
600	49	135	282	135	90
650	53	146	305	146	99
700	57	157	329	158	107

10.3.4 Comentários

Neste posto ocorreu um fato peculiar : ambas as equações Y_{maxLOG} e Y_{maxLIN} obtidas com as estimativas dos parâmetros calibrados inicialmente não corresponderam à envolvente superior dos rendimentos observados, como deveria ser teoricamente. Isto quer dizer que os dois modelos subestimaram os rendimentos que estão acima das duas curvas (Figuras 10.3.1 e 10.3.2).

Entretanto, este fato não ocorreu com a curva $Y_{maxITER}$, mostrando um desempenho muito melhor para descrever rendimentos máximos, pois pode dizer-se que a curva $Y_{maxITER}$ constitui uma envolvente perfeita até 500 mm, aproximadamente. Esta diferença é importante, e realça a necessidade do emprego de um único conjunto de estimativas dos λ_i . A Figura 10.3.4 mostra a superposição das três equações.




Figura 10.3.4 YmaxLOG, YmaxLIN e YmaxITER vs C_2 . Sto Augusto - RS.




Figura 10.4.1 Rendimentos observados e YmaxLOG vs C_2 . São Borja - RS.

10.4 São Borja-RS.

10.4.1 Modelo LOG

Equação de rendimentos máximos :

$$Y_{maxLOG} = 0,062 \cdot C_2^{1,20} \quad (10.4.1)$$

10.4.2 Modelo LIN

Equação de rendimentos máximos :

$$Y_{maxLIN} = 0,267 \cdot C_2 - 19,20 \quad (10.4.2)$$




Figura 10.4.2 Rendimentos observados e Y_{maxLIN} vs C_2 . São Borja - RS.

10.4.3 Modelo ITER

Equação de rendimentos máximos :

$$Y_{maxITER} = 0,072 \cdot C_2^{1,13} \quad (10.4.3)$$




Figura 10.4.3 Rendimentos observados e $Y_{maxITER}$ vs C_2 . São Borja - RS.

Tabela 10.4.1 Distribuição ótima da água e rendimentos esperados de acordo com o Modelo ITER. São Borja-RS.

TOTAL (mm)	X1 (mm)	X2 (mm)	X3 (mm)	X4 (mm)	Y (%)
100	8	22	47	23	13
150	12	34	70	34	21
200	16	45	94	45	29
250	20	56	117	56	37
300	24	67	141	68	45
350	28	78	164	79	54
400	32	90	188	90	63
450	37	101	211	101	72
500	41	112	235	113	81
550	45	123	258	124	90
600	49	135	282	135	100
650	53	146	305	146	109
700	57	157	329	158	119

10.4.4 Comentários

Houve pouca diferença entre os Modelos $Y_{\max\text{LOG}}$ e $Y_{\max\text{LIN}}$, como pode ser notado na Figura 10.4.4. Apesar da equação $Y_{\max\text{ITER}}$ cair um pouco mais abaixo e mais próxima da nuvem de pontos, é mais conservador adotar esta última para descrever os rendimentos máximos. É interessante notar a semelhança desta equação com a equação (10.2.3) de Veranópolis; praticamente são idênticas, evidenciado pela semelhança entre os C_1' das duas estações.

Esta semelhança de parâmetros leva a crer que a causa fundamental de São Borja apresentar rendimentos inferiores à Veranópolis e às outras estações reside na quantidade e distribuição das precipitações, como também ao regime térmico.

A equação (10.4.2) deve ser vista com cautela, pois a interseção é elevada (-19,2 %), podendo ocorrer subestimações de rendimentos máximos para lâminas baixas. Um limite inferior arbitrado em torno de 120 mm parece ser razoável para minimizar este problema.





Figura 10.4.4 $Y_{\max\text{LOG}}$, $Y_{\max\text{LIN}}$ e $Y_{\max\text{ITER}}$ vs C_2 . São Borja-RS.

10.5 Livramento -RS.

10.5.1 Modelo LOG

Equação de rendimentos máximos :

$$Y_{maxLOG} = 0,129 \cdot C_2^{1,07} \quad (10.5.1)$$

Figura 10.5.1 Rendimentos observados e Y_{maxLOG} vs C_2 . Livramento - RS.




Figura 10.5.2 Rendimentos observados e Y_{maxLIN} vs C_2 . Livramento - RS.




Figura 10.5.3 Rendimentos observados e $Y_{maxITER}$ vs C_2 Livramento - RS

10.5.2 Modelo LIN

Equação de rendimentos máximos :

$$Y_{\max LIN} = 0,177.C_2 - 5,40 \quad (10.5.2)$$

10.5.3 Modelo ITER

Equação de rendimentos máximos :

$$Y_{\max ITER} = 0,079.C_2^{1,13} \quad (10.5.3)$$

Tabela 10.5.1 Distribuição ótima da água e rendimentos esperados de acordo com o Modelo ITER. Livramento-RS.

TOTAL	X1	X2	X3	X4	Y
(mm)	(mm)	(mm)	(mm)	(mm)	(%)
100	8	22	47	23	15
150	12	34	70	34	23
200	16	45	94	45	32
250	20	56	117	56	41
300	24	67	141	68	51
350	28	78	164	79	60
400	32	90	188	90	70
450	37	101	211	101	80
500	41	112	235	113	90
550	45	123	258	124	100
600	49	135	282	135	111
650	53	146	305	146	121
700	57	157	329	158	132

10.5.4 Comentários

Lembra-se novamente que o ajuste inicial do Modelo LIN tinha superado com vantagem o ajuste do Modelo LOG (ver item 6.5.1 e 6.5.2). O afastamento da curva $Y_{\max\text{LOG}}$ em relação às curvas




Figura 10.5.4 $Y_{\max\text{LOG}}$, $Y_{\max\text{LIN}}$ e $Y_{\max\text{ITER}}$ vs C_2 . Livramento - RS.

$Y_{\max\text{LIN}}$ e $Y_{\max\text{ITER}}$ não reflete totalmente este fato, pois a amostra não é suficientemente grande de forma a permitir a ocorrência de vários eventos com distribuição ótima da água. Entretanto, é mais seguro indicar a equação $Y_{\max\text{LIN}}$ e $Y_{\max\text{ITER}}$ para descrever rendimentos máximos (ver Figura 10.5.4). A curva $Y_{\max\text{ITER}}$ apresentou um bom desempenho acompanhando $Y_{\max\text{LIN}}$, verificando mais uma vez a consistência do procedimento apresentado em 9.1.

Deve ser notada a semelhança entre as declividades das equações de rendimentos máximos das estações Livramento, Veranópolis e São Borja. Isto pode indicar que a cultivar de Livramento (Morgan Rendidor) apresenta potencial genético equivalente às cultivares de São Borja e Veranópolis, ou que este fato seja compensado pelo fator tecnológico e ambiental, caso contrário.

10.6 Regional-Rs. (Sto Augusto, Cruz Alta, Sta Rosa e Passo Fundo).

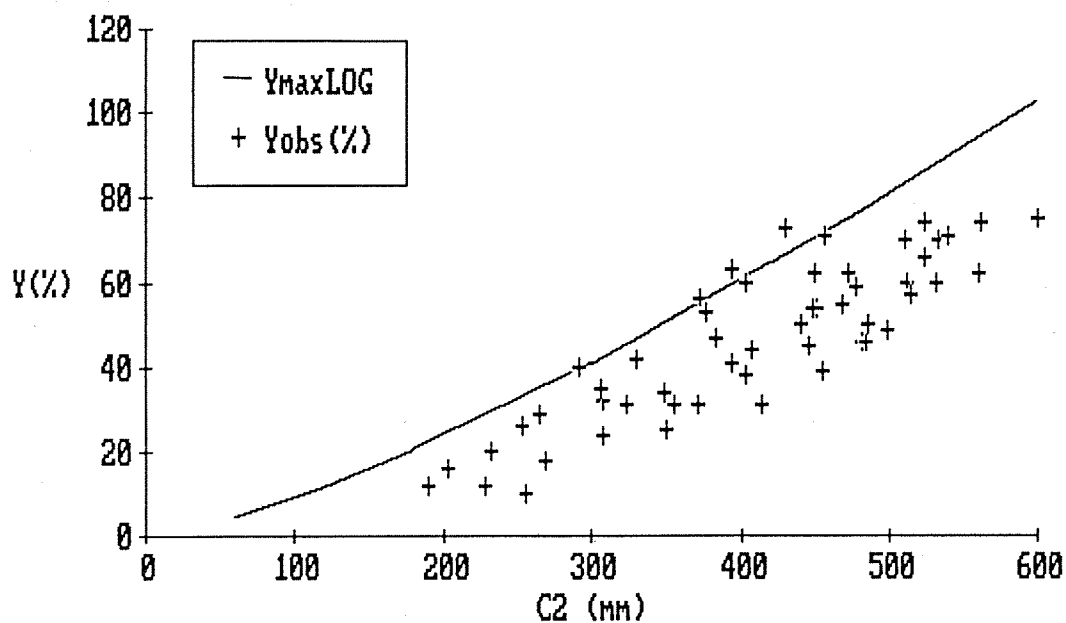


Figura 10.6.1 Rendimentos observados e YmaxLOG vs C_2 . Regional - RS.

10.6.1 Modelo LOG

Equação de rendimentos máximos :

$$Y_{maxLOG} = 0,022 \cdot C_2^{1,32} \quad (10.6.1)$$

10.6.2 Modelo LIN

Equação de rendimentos máximos :

$$Y_{maxLIN} = 0,177 \cdot C_2 - 9,95 \quad (10.6.2)$$




Figura 10.6.2 Rendimentos observados e Y_{maxLIN} vs C_2 .
Regional - RS.

10.6.3 Modelo ITER

Equação de rendimentos máximos :

$$Y_{maxITER} = 0,154 \cdot C_2^{1,13} \quad (10.6.3)$$




Figura 10.6.3 Rendimentos observados e $Y_{\max \text{ITER}}$ vs C_2 . Regional - RS.

Tabela 10.6.1 Distribuição ótima da água e rendimentos esperados de acordo com o Modelo ITER. Regional-RS.

TOTAL (mm)	X1 (mm)	X2 (mm)	X3 (mm)	X4 (mm)	Y (%)
100	8	22	47	23	14
150	12	34	70	34	21
200	16	45	94	45	30
250	20	56	117	56	38
300	24	67	141	68	47
350	28	78	164	79	56
400	32	90	188	90	65
450	37	101	211	101	74
500	41	112	235	113	84
550	45	123	258	124	93
600	49	135	282	135	103
650	53	146	305	146	113
700	57	157	329	158	123

10.6.4 Comentários

Na Figura 10.6.4 se observa uma forte aproximação entre as três curvas, apesar de que o expoente ϵ de $Y_{\max\text{LOG}}$ seja maior que ϵ de $Y_{\max\text{ITER}}$ (1,32 contra 1,13), sendo este fato compensado pelo baixo valor do coeficiente 0,022. Pode-se dizer que a diferença entre estas três equações é mínima, ou quase não existe até a faixa dos 600 mm.

A semelhança pode ser explicada porque os três modelos apresentam resultados também semelhantes na distribuição da água usando a equação (3.9). Aplicando a equação (3.9-Pág.49) os resultados são os seguintes na distribuição de C_2 :

Tabela 10.6.2 Distribuição de C_2 , em porcentagem, nos quatro intervalos de soma térmica para os três modelos (LOG, LIN e ITER). Regional-RS.

MODELO	X_1 (%)	X_2 (%)	X_3 (%)	X_4 (%)
LOG	10,9	24,9	38,8	25,4
LIN	8,3	24,1	40,9	26,7
ITER	8,1	22,4	46,9	22,5




Figura 10.6.4 $Y_{\max\text{LOG}}$, $Y_{\max\text{LIN}}$ e $Y_{\max\text{ITER}}$ vs C_2 Regional-RS.

A Tabela 10.6.2 prova também que quando o tamanho da amostra é grande, e no ajuste todas as estimativas dos parâmetros se mostram significativas, a diferença entre os modelos tende a diminuir, principalmente entre o Modelo LIN e os outros dois, pois o processo é quasi-linear.

10.7 Sete Lagoas-MG.

10.7.1 Modelo LOG

Equação de rendimentos máximos :

$$Y_{maxLOG} = 0,087 \cdot C_2^{1,07} \quad (10.7.1)$$

10.7.2 Modelo LIN

Equação de rendimentos máximos :

$$Y_{maxLIN} = 0,183 \cdot C_2 - 11,45 \quad (10.7.2)$$




Figura 10.7.1 Rendimentos observados e YmaxLOG vs C₂. Sete Lagoas.




Figura 10.7.2 Rendimentos observados e Y_{maxLIN} vs C_2 . Sete Lagoas.




Figura 10.7.3 Rendimentos observados e $Y_{maxITER}$ vs C_2 . Sete Lagoas.

10.7.3 Modelo ITER²²

Equação de rendimentos máximos

$$Y_{maxITER} = 0,0563.C_2^{1,13} \quad (10.7.3)$$

10.7.4 Comentários e verificação das equações Ymax.

Na localidade de Sete Lagoas-MG realizaram-se experimentos para avaliar a resposta máxima do milho à variação das lâminas de irrigação, o que permitiu uma comparação com as equações teóricas YmaxLOG, YmaxLIN e YmaxITER. Couto et al.(1981) apresentam resultados lineares do rendimento de grãos de milho ao efeito de lâminas aplicadas por aspersão, utilizando a cultivar BR200-X. Ajustou-se uma equação de regressão à reta apresentada por eles :

$$Y = -500,0 + 11,79.C_2 \quad (10.7.4)$$

onde :

Y = rendimento de grãos da cultivar BR200-X (Kg/ha)

C₂ = lâmina aplicada por aspersão (mm)

Transformando a equação (10.7.4) para porcentagem de 8000 Kg/ha, resulta a equação (10.7.5), que será chamada YmaxOBS :

$$Y_{maxOBS} = 0,147.C_2 - 6,25 \quad (10.7.5)$$

O desempenho da equação YmaxITER na previsão de rendimentos máximos em Sete Lagoas é muito importante, pois os eventos desta amostra não participaram nas estimativas de λ_i ; apenas para C₁. Isto quer dizer que se há mérito na equação (10.7.3) deve-se ao ajuste de C₁. É notável que com os parâmetros λ_i obtidos no Rio Grande do Sul, ajustando somente um parâmetro (C₁), se estimem rendimentos quase tão bem ou melhor (por exemplo, a equação YmaxITER apresentou melhor resultado que YmaxLIN) do que

22

Observe-se que a estação de Sete lagoas não participou nas estimativas de λ_i . A obtenção da estimativa de C₁ foi realizada no item 9.4 .

ajustando localmente cinco parâmetros. Na Figura 10.7.4 estão as três curvas de rendimentos máximos, sendo que uma delas (Y_{maxOBS}) é observada. Y_{maxOBS} quase se confunde com Y_{maxLOG} , sendo que $Y_{maxITER}$ está logo abaixo. Y_{maxLIN} superestima rendimentos superiores a uma lâmina de 200 mm, e se afasta muito das outras três curvas, de forma que não é aconselhável o uso desta equação.

É interessante notar que entre as declividades de Y_{maxLOG} , $Y_{maxITER}$ e Y_{maxOBS} não há uma diferença significativa, sendo que a cultivar utilizada no ensaio de Couto et al. (1981) que gerou Y_{maxOBS} é diferente das cultivares da amostra que gerou Y_{maxLOG} e $Y_{maxITER}$. A conclusão, então, é que não há diferença nos potenciais genéticos entre as cultivares de ambas amostras.

A proximidade entre Y_{maxOBS} das curvas teóricas (10.7.1) e (10.7.3) verifica a metodologia exposta no capítulo 3 (item 3.4.1), indicando que a equação (3.31) pode ser usada para descrever rendimentos máximos não muito além da realidade experimental.




Figura 10.7.4 Y_{maxOBS} , $Y_{maxITER}$ e Y_{maxLOG} vs C_2 . Sete Lagoas - MG.

11. Estimação da melhor época de semeadura com base em séries históricas de precipitação e temperatura.

Aqui se apresentam os resultados da metodologia descrita em 3.4.2 (Pág.57), que através da simulação de rendimentos, utilizando séries históricas de precipitação e temperatura, teve por objetivo estimar a melhor época de semeadura, analisando as séries geradas de rendimentos.

O trabalho inicialmente começou com a extensão de séries de temperaturas, mais propriamente com a extensão de séries de Soma Térmica nos intervalos, uma vez que o período de registro das temperaturas diárias era inferior ao período de registro das precipitações, de forma que houve necessidade de estender as séries de soma térmica por intervalos para aproveitar integralmente a série histórica de precipitações.

O passo seguinte foi a simulação de rendimentos em cada ano agrícola, fixando datas de semeadura espaçadas de dez em dez dias, que variaram entre 1º Setembro e 31 de Dezembro. A análise das séries sintéticas resultantes do processo de simulação forneceram informações que podem ajudar a estimar ou selecionar uma data de semeadura que cause o menor prejuízo possível à produção.

Neste capítulo se apresentam as médias rendimento das séries geradas em função da data de semeadura em forma gráfica, o que dará uma visão do comportamento do rendimento médio à variação da data de semeadura. Como informação complementar se apresenta também a variação da precipitação efetiva total média ($\sum X_i$) e da precipitação efetiva no 3º intervalo de soma térmica (X_3) em função da data de semeadura.

11.1 Extensão da série de temperaturas

Para estender a série de temperaturas estudou-se primeiramente o caráter da série histórica de temperaturas, chegando-se à conclusão que a extensão dos valores diários de temperatura máxima e mínima seria inviável a partir somente do dia do calendário e da precipitação, para atender o nível de precisão desejado. Mas como os modelos desenvolvidos neste trabalho acumulam e transformam a precipitação diária em intervalos de soma térmica, a alternativa que surgiu foi analisar a ocorrência, em número de dias, no fechamento de cada intervalo de soma térmica, aplicando este procedimento a cada data de semeadura.

Como são quatro intervalos de soma térmica, a cada data de semeadura corresponderão quatro séries. O fato que possibilitou a extensão dos intervalos de soma térmica foi a pequena oscilação da média de cada série; isto é, o número de dias necessários para atingir um determinado valor de soma térmica - sempre para uma mesma data de semeadura e local - apresenta pequena variação anual. A Tabela 11.1 ilustra o comportamento do número de dias necessários para atingir o valor de soma térmica em cada intervalo, em função da data de semeadura.

Tabela 11.1 Nº de dias para atingir 390, 780, 1170 e 1560 °C de Soma Térmica. Data de semeadura : 01/09. Santo Augusto - RS.

390 C	780 C	1170 C	1560 C	Data/Sem
45	79	110	140	01/09/70
46	82	114	143	01/09/71
49	89	120	148	01/09/72
46	85	117	149	01/09/73
46	83	114	142	01/09/74
51	87	119	149	01/09/75
39	74	104	133	01/09/76
40	78	108	138	01/09/77
51	89	120	154	01/09/78
52	89	121	151	01/09/79
48	82	116	148	01/09/80
45	84	116	145	01/09/81
51	90	119	146	01/09/82
47	82	116	145	01/09/83
46	79	108	136	01/09/84
48	82	112	141	01/09/85

A seguir se apresentam os resultados das médias com intervalos de confiança de 99 % para Taquari, São Borja, Santo Augusto e Veranópolis. Deve ser considerado o posto Santo Augusto como representativo dos postos que integram a amostra Regional. Nas localidades de Livramento e Sete Lagoas não se obteve informação para realizar este mesmo estudo. Os intervalos de confiança do número médio de dias para atingir um determinado valor de soma térmica dá uma visão da pequena oscilação ou "ruído" em torno da média. Deve ser destacado que este método proporciona resultados aproximados, que satisfazem os objetivos do trabalho, e que o número de anos da série extendida de soma térmica é inferior à metade do número de anos da série histórica de temperaturas.

11.1.1 Taquari-RS.




Figura 11.1.1 Variação do número médio de dias para atingir 350,700, 1050 e 1400 °C, com intervalos de confiança de 99%. Taquari - RS.

Tabela 11.1.1 Valores utilizados (em dias) para extensão dos intervalos de Soma Térmica. Taquarí - RS.

$X_1 \pm \Delta X_1$	$X_2 \pm \Delta X_2$	$X_3 \pm \Delta X_3$	$X_4 \pm \Delta X_4$	Data/Sem ²³
44 3	78 3	107 3	133 3	01/09
41 3	74 3	103 3	128 3	10/09
38 3	71 2	98 3	124 3	20/09
36 3	67 2	94 3	119 3	01/10
35 2	64 2	91 2	115 2	10/10
33 2	61 2	87 2	112 2	20/10
31 2	58 2	84 2	108 2	01/11
30 3	56 1	81 2	106 2	10/11
28 3	54 1	79 2	104 2	20/11
26 3	52 1	77 2	102 2	01/12
25 3	50 1	75 2	102 2	10/12
25 3	50 1	75 2	104 2	20/12
24 4	49 1	75 1	106 2	30/12

11.1.2 São Borja - RS.

Tabela 11.1.2 Valores utilizados (em dias) para extensão dos intervalos de Soma Térmica. São Borja - RS.

$X_1 \pm \Delta X_1$	$X_2 \pm \Delta X_2$	$X_3 \pm \Delta X_3$	$X_4 \pm \Delta X_4$	Data/Sem
35 4	63 3	89 3	111 4	1
32 4	60 2	85 3	106 4	2
30 4	57 2	81 3	102 4	3
28 3	54 2	77 3	98 3	4
27 3	52 2	74 3	95 3	5
26 3	50 2	71 3	92 3	6
25 3	47 2	68 2	89 2	7
24 3	45 1	66 2	87 2	8
22 2	44 1	64 2	85 2	9
21 2	42 1	62 1	83 2	10
20 2	41 1	61 2	83 2	11
20 2	40 1	61 1	83 2	12
20 2	40 1	61 1	83 2	13

Para indicar a data de semeadura, de agora em diante será utilizada a numeração 1...13 para indicar as datas 01/09...30/12.




Figura 11.1.2 Variação do número médio de dias para atingir 300, 600, 900 e 1200°C, com intervalos de confiança de 99%. São Borja -RS.

11.1.3 Veranópolis - RS.

Tabela 11.1.3 Valores utilizados (em dias) para extensão dos intervalos de Soma Térmica. Veranópolis - RS.

$X_1 \pm \Delta X_1$	$X_2 \pm \Delta X_2$	$X_3 \pm \Delta X_3$	$X_4 \pm \Delta X_4$	Data/Sem
45 5	79 3	108 5	135 5	1
41 5	75 3	103 4	129 5	2
39 5	72 3	99 4	125 5	3
37 5	68 3	95 4	120 5	4
35 4	65 3	92 3	117 4	5
33 4	62 3	88 3	112 4	6
32 4	59 2	85 3	109 4	7
30 4	57 2	82 3	107 4	8
28 3	55 2	79 3	104 3	9
27 3	52 1	77 2	103 3	10
26 4	51 2	76 2	103 3	11
25 5	50 1	75 2	106 2	12
24 7	49 1	75 2	109 3	13




Figura 11.1.3 Variação do número médio de dias para atingir 300,600, 900 e 1200°C, com intervalos de confiança de 99%. Veranópolis - RS.

11.1.4 Santo Augusto -RS.

Tabela 11.1.4 Valores utilizados (em dias) para extensão dos intervalos de Soma Térmica. Santo Augusto - RS.

$X_1 \pm \Delta X_1$	$X_2 \pm \Delta X_2$	$X_3 \pm \Delta X_3$	$X_4 \pm \Delta X_4$	Data/Sem
47 4	83 3	115 3	144 4	1
44 4	79 3	110 3	139 4	2
41 4	76 2	106 3	135 3	3
39 4	72 2	102 3	131 3	4
37 3	69 2	99 2	128 3	5
35 3	66 2	96 2	126 3	6
34 3	64 2	93 2	123 3	7
32 3	62 2	91 2	121 3	8
31 3	60 1	90 2	121 2	9
30 3	59 1	89 2	121 2	10
29 3	58 1	88 2	123 2	11
29 5	58 1	89 2	127 2	12
29 5	58 1	90 2	133 2	13




Figura 11.1.4 Variação do número médio de dias para atingir 390, 780, 1170 e 1560°C, com intervalos de confiança de 99 %. Santo Augusto - RS.

11.2 Rendimentos médios vs Data de semeadura

Aqui se apresentam os resultados da aplicação dos modelos LOG e ITER, que anteriormente haviam mostrado resultados satisfatórios. A forma de obtenção dos resultados é muito simples, como descrito no item 3.4.2 (Pág.57). A média dos rendimentos calculada com o modelo LOG é denominada Y_{bLOG} (Y_{barLOG}); análogamente, com o modelo ITER é denominada Y_{bITER} ($Y_{barITER}$). A média da precipitação efetiva no 3º intervalo de soma térmica será chamada X_{3H} , e a média da precipitação efetiva total ($\sum X_i$), será chamada P_{ef} . A cada curva estão associados intervalos de confiança com 90 %, probabilidade considerada razoável, principalmente para as precipitações, que apresentam um desvio muito grande com relação à média.

11.2.1 Taquarí - RS.




Figura 11.2.1.1 Rendimentos médios estimados com o modelo LOG (YbLOG) vs Data de sementeira (Data/Sem). Taquarí - RS.




Figura 11.2.1.2 Rendimentos médios estimados com o modelo ITER (YbITER) vs Data de sementeira (Data/Sem). Taquarí - RS.




Figura 11.2.1.3 Média da precipitação efetiva no 3º intervalo de soma térmica vs data de semeadura. Taquarí - RS.




Figura 11.2.1.4 Média da precipitação efetiva total vs data de semeadura. Taquarí - RS.

11.2.2 São Borja - RS.




Figura 11.2.2.1 Rendimentos médios estimados com o modelo LOG (YbLOG) vs Data de semeadura (Data/Sem). São Borja - RS.




Figura 11.2.2.2 Rendimentos médios estimados com o modelo ITER (YbITER) vs Data de semeadura (Data/Sem). São Borja - RS.




Figura 11.2.2.3 Média da precipitação efetiva no 3º intervalo de soma térmica vs data de semeadura. São Borja - RS.




Figura 11.2.2.4 Média da precipitação efetiva total vs data de semeadura. São Borja - RS.

11.2.3 Veranópolis - RS.




Figura 11.2.3.1 Rendimentos médios estimados com o modelo LOG (YbLOG) vs Data de semeadura (Data/Sem). Veranópolis - RS.




Figura 11.2.3.2 Rendimentos médios estimados com o modelo ITER (YbITER) vs Data de semeadura (Data/Sem). Veranópolis - RS.




Figura 11.2.3.3 Média da precipitação efetiva no 3º intervalo de soma térmica vs data de semeadura. Veranópolis - RS.




Figura 11.2.3.4 Média da precipitação efetiva total vs data de semeadura. Veranópolis - RS.

11.2.4 Santo Augusto - RS.




Figura 11.2.4.1 Rendimentos médios estimados com o modelo LOG (YbLOG) vs Data de semeadura (Data/Sem). Santo Augusto - RS.




Figura 11.2.4.2 Rendimentos médios estimados com o modelo ITER (YbITER) vs Data de semeadura (Data/Sem). Santo Augusto - RS.




Figura 11.2.4.3 Média da precipitação efetiva no 3º intervalo de soma térmica vs data de semeadura. Santo Augusto - RS.




Figura 11.2.4.4 Média da precipitação efetiva total vs data de semeadura. Santo Augusto - RS.

12. Prognóstico do rendimento final em função do avanço da soma térmica.

Neste capítulo se apresentam os resultados da metodologia descrita em 3.5.3, sendo aqui complementada com mais detalhes.

O prognóstico é realizado em quatro etapas :

(1) Na data da semeadura. Neste momento não se sabe nada a respeito da precipitação que virá a ocorrer.

(2) Quando já se conhece a precipitação efetiva que ocorreu no 1º intervalo de soma térmica (X_{1H}).

(3) Quando se conhecem X_{1H} e X_{2H} .

(4) Quando se conhecem X_{1H} , X_{2H} e X_{3H} .

Inicialmente são geradas 4 séries sintéticas normais de precipitação efetiva (500 anos). Observe-se que a cada data de semeadura estão associadas 4 séries históricas de precipitação efetiva, que correspondem aos 4 intervalos de soma térmica. Cada uma destas 4 séries possui média X_m e desvio S . A verificação da normalidade das séries foi feita usando o teste descrito em Minitab (1988).

Para facilitar a compreensão do procedimento, vamos chamar as séries sintéticas de precipitação efetiva de X_{1S} , X_{2S} , X_{3S} e X_{4S} . Então, o prognóstico é realizado da seguinte forma :

Na etapa (1), calcula-se a série Y_1 :

$$Y_1 = C_1 \cdot X_{1S}^{\lambda_1} \cdot X_{2S}^{\lambda_2} \cdot X_{3S}^{\lambda_3} \cdot X_{4S}^{\lambda_4} \quad (12.1)$$

e realiza-se uma análise de frequência sobre a série resultante Y_1 (note-se que o tamanho da série Y é o mesmo das séries X_{is} .

No caso serão 500 rendimentos), calculando qual o rendimento mínimo que ocorreu 95, 90, 80, 60 e 50 % das vezes. Também a média é calculada.

Na etapa (2), uma vez conhecido X_{1H} , substitui-se em (12.1) X_{1S} por X_{1H} , resultando a série Y_2 :

$$Y_2 = C_1 \cdot X_{1H}^{\lambda_1} \cdot X_{2S}^{\lambda_2} \cdot X_{3S}^{\lambda_3} \cdot X_{4S}^{\lambda_4} \quad (12.2)$$

repetindo-se novamente a análise de frequência descrita anteriormente, observando que, neste estágio, X_{1H} é constante.

Na etapa (3), a equação (12.2) fica :

$$Y_3 = C_1 \cdot X_{1H}^{\lambda_1} \cdot X_{2H}^{\lambda_2} \cdot X_{3S}^{\lambda_3} \cdot X_{4S}^{\lambda_4}, \quad (12.3)$$

onde X_{1H} e X_{2H} são as precipitações efetivas conhecidas até o momento do prognóstico nesta etapa.

Finalmente, na etapa (4), só haverá uma série sintética de precipitações efetivas, que corresponderá ao último intervalo de soma térmica :

$$Y_4 = C_1 \cdot X_{1H}^{\lambda_1} \cdot X_{2H}^{\lambda_2} \cdot X_{3H}^{\lambda_3} \cdot X_{4S}^{\lambda_4}, \quad (12.4)$$

Nesta etapa, a variação dos rendimentos da série Y_4 é devida exclusivamente à X_{4S} , pois X_{1H} , X_{2H} , e X_{3H} são constantes, tornando o prognóstico mais preciso do que nas etapas anteriores, reforçado este fato ainda porque a precipitação efetiva no último intervalo não é tão relevante como no 3º.

Nas tabelas dos resultados a seguir se apresenta uma comparação entre o prognóstico utilizando os parâmetros C_1 e λ_i obtidos na calibração inicial (Modelo LOG), com os obtidos na análise iterativa (Modelo ITER). Na parte inferior das tabelas se apresentam as estimativas dos modelos que somente incluem 3 variáveis independentes, os modelos LOG3 e LOG3ITER, sendo que estes últimos dois não participam da análise de frequência, somente são estimativas. O autor optou por realizar a análise de frequência somente com as estimativas realizadas com o Modelo ITER, em primeiro lugar por economia de espaço, e em segundo pela semelhança de resultados entre estes dois modelos. Para um detalhamento maior, o leitor pode-se referir ao programa PROGMAYZE, que gerou as tabelas dos resultados a seguir. Notação utilizada nas tabelas de resultados :

- A primeira coluna (ESTÁGIO) indica a etapa do prognóstico.
- ITER representa a média dos rendimentos estimados com o Modelo ITER.
- LOG representa a média dos rendimentos estimados com o Modelo LOG.
- Nas colunas das probabilidades estão os rendimentos mínimos (%) associados à probabilidade indicada no topo da coluna respectiva. Por exemplo, na Tabela 12.1.1, no Estágio 1, se pode afirmar com 95 % de certeza, que o rendimento mínimo será 19 %. Já no Estágio 4, com a mesma certeza ou probabilidade (95 %), este rendimento mínimo aumentou para 51 %, pois se incorporou ao prognóstico mais informação (precipitações).

12.1 Prognósticos para Taquari -RS

Tabela 12.1.1 Prognósticos de rendimentos (%) para o evento de 15/08/80.

Rendimento Observado : 70 %.(X1=129 X2=140 X3=121 X4= 33mm).
Taquari -RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	54	56	19	28	35	42	49	55
2	55	57	19	28	35	43	50	56
3	61	65	20	32	42	49	55	61
4	79	78	51	59	70	75	78	81

Rendimento estimado com o Modelo LOG3 : 77 %.

Rendimento estimado com o Modelo LOG3ITER : 76 %.

Tabela 12.1.2 Prognósticos de rendimentos (%) para o evento de 06/10/83.

Rendimento Observado : 37 %.(X1=168 X2= 41 X3= 32 X4= 98mm).
Taquari -RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	44	45	15	20	28	33	38	44
2	47	47	16	22	30	35	41	46
3	42	39	14	21	29	34	38	42
4	30	32	20	24	28	29	30	31

Rendimento estimado com o Modelo LOG3 : 33 %.

Rendimento estimado com o Modelo LOG3ITER : 31 %.

Tabela 12.1.3 Prognósticos de rendimentos (%) para o evento de 11/10/79.

Rendimento Observado : 62 %.(X1=122 X2=191 X3= 68 X4= 39mm).
Taquari -RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	44	45	15	20	28	33	38	44
2	45	46	15	21	29	34	39	45
3	60	68	20	30	41	49	54	60
4	65	73	43	52	59	62	65	67

Rendimento estimado com o Modelo LOG3 : 69 %.

Rendimento estimado com o Modelo LOG3ITER : 61 %.

Tabela 12.1.4 Prognósticos de rendimentos (%) para o evento de 15/10/80.

Rendimento Observado : 52 %.(X1=149 X2=112 X3= 37 X4=103mm).
Taquari -RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	44	45	15	20	28	33	38	44
2	46	47	15	21	30	35	40	46
3	53	57	18	27	37	44	48	54
4	42	49	28	33	38	40	42	43

Rendimento estimado com o Modelo LOG3 : 47 %.

Rendimento estimado com o Modelo LOG3ITER : 41 %.

Tabela 12.1.5 Prognósticos de rendimentos (%) para o evento de 15/10/82.

Rendimento Observado : 47 %.(X1=152 X2= 80 X3= 58 X4= 45mm).
Taquari -RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	44	45	15	20	28	33	38	44
2	46	47	16	21	30	35	40	46
3	49	50	17	25	34	40	44	49
4	49	51	32	39	44	47	49	50

Rendimento estimado com o Modelo LOG3 : 50 %.

Rendimento estimado com o Modelo LOG3ITER : 48 %.

Tabela 12.1.6 Prognósticos de rendimentos (%) para o evento de 05/11/81.

Rendimento Observado : 21 %.(X1= 98 X2= 39 X3= 22 X4= 92mm).
Taquari -RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	47	45	18	26	34	38	43	47
2	48	46	18	27	35	39	44	48
3	44	40	18	27	32	37	41	45
4	24	27	17	20	22	23	24	25

Rendimento estimado com o Modelo LOG3 : 26 %.

Rendimento estimado com o Modelo LOG3ITER : 24 %.

12.2 Prognósticos para São Borja - RS

Tabela 12.2.1 Prognósticos de rendimentos (%) para o evento de 15/08/80.

Rendimento Observado : 54 %.(X1=138 X2=201 X3= 97 X4= 63mm). São Borja -RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	34	33	9	11	17	23	29	34
2	35	33	9	11	18	24	30	35
3	45	39	12	14	25	33	40	45
4	56	49	30	40	49	52	55	58

Rendimento estimado com o Modelo LOG3 : 40 %.

Rendimento estimado com o Modelo LOG3ITER : 48 %.

Tabela 12.2.2 Prognósticos de rendimentos (%) para o evento de 15/10/78.

Rendimento Observado : 3 %.(X1=131 X2=127 X3= 2 X4= 9mm). São Borja -RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	29	28	8	11	17	21	24	28
2	31	29	9	12	17	22	25	30
3	37	33	10	16	23	29	33	38
4	6	3	3	3	5	6	6	6

Rendimento estimado com o Modelo LOG3 : 2 %.

Rendimento estimado com o Modelo LOG3ITER : 6 %.

Tabela 12.2.3 Prognósticos de rendimentos (%) para o evento de 15/10/83.

Rendimento Observado : 6 %.(X1=101 X2= 29 X3= 18 X4= 47mm). São Borja -RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	29	28	8	11	17	21	24	28
2	30	29	8	11	17	21	25	29
3	25	26	7	10	15	19	22	26
4	13	10	7	7	10	12	13	14

Rendimento estimado com o Modelo LOG3 : 9 %.

Rendimento estimado com o Modelo LOG3ITER : 13 %.

Tabela 12.2.4 Prognósticos de rendimentos (%) para o evento de 01/10/81.

Rendimento Observado : 48 %.(X1= 42 X2= 44 X3=162 X4= 23mm). São Borja -RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	31	30	7	10	16	21	26	31
2	29	29	7	10	16	20	25	29
3	26	28	7	9	16	20	24	26
4	43	52	24	26	37	40	43	45

Rendimento estimado com o Modelo LOG3 : 51 %.

Rendimento estimado com o Modelo LOG3ITER : 40 %.

12.3 Prognósticos para Veranópolis - RS

Tabela 12.3.1 Prognósticos de rendimentos (%) para o evento de 03/09/85.

Rendimento Observado : 17 %.(X1=140 X2= 47 X3= 8 X4= 77mm). Veranópolis -RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	52	51	17	27	36	42	48	53
2	52	50	18	27	36	41	47	53
3	42	40	17	23	30	35	40	43
4	11	15	8	9	10	11	11	11

Rendimento estimado com o Modelo LOG3 : 14 %.

Rendimento estimado com o Modelo LOG3ITER : 11 %.

Tabela 12.3.2 Prognósticos de rendimentos (%) para o evento de 07/09/82.

Rendimento Observado : 55 %.(X1=157 X2=275 X3=74 X4=62mm). Veranópolis - RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	52	51	17	27	36	42	48	53
2	53	51	18	27	36	42	47	54
3	66	65	28	36	48	55	64	68
4	58	59	43	48	53	56	57	59

Rendimento estimado com Modelo LOG3 : 56 %.

Rendimento estimado com o Modelo LOG3ITER : 51 %.

Tabela 12.3.3 Prognósticos de rendimentos (%) para o evento de 01/10/77.

Rendimento Observado : 37 %.(X1= 81 X2= 67 X3= 78 X4=114mm).
Veranópolis-RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	45	44	16	22	30	36	42	46
2	44	41	15	21	29	35	41	44
3	41	38	16	24	30	35	39	42
4	37	36	26	30	33	35	37	38

Rendimento estimado com o Modelo LOG3 : 34 %.

Rendimento estimado com o Modelo LOG3ITER : 36 %.

Tabela 12.3.4 Prognósticos de rendimentos (%) para o evento de 15/10/76.

Rendimento Observado : 66 %.(X1=146 X2=155 X3=157 X4= 62mm).
Veranópolis-RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	44	42	16	22	30	35	40	44
2	45	44	16	23	31	36	41	45
3	51	51	22	32	39	44	48	51
4	69	64	48	56	62	66	68	71

Rendimento estimado com o Modelo LOG3 : 63 %.

Rendimento estimado com o Modelo LOG3ITER : 66 %.

12.4 Prognósticos para Santo Augusto - RS

Tabela 12.4.1 Prognósticos de rendimentos (%) para o evento de 16/08/80.

Rendimento Observado : 78 %.(X1=201 X2=189 X3=212 X4= 74mm). Sto
Augusto -RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	50	51	21	25	34	40	45	50
2	51	55	21	26	35	42	46	52
3	57	64	25	33	43	48	54	58
4	85	85	49	64	75	81	86	88

Rendimento estimado com o Modelo LOG3 : 87 %.

Rendimento estimado com o Modelo LOG3ITER : 81 %.

Tabela 12.4.2 Prognósticos de rendimentos (%) para o evento de 14/10/77.

Rendimento Observado : 27 %.(X1=123 X2= 79 X3= 41 X4= 63mm). Sto Augusto -RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	43	43	11	20	28	35	40	44
2	44	43	11	20	30	36	41	45
3	42	41	10	22	30	35	40	44
4	28	31	23	24	26	27	28	29

Rendimento estimado com o Modelo LOG3 : 29 %.

Rendimento estimado com o Modelo LOG3ITER : 28 %.

Tabela 12.4.3 Prognósticos de rendimentos (%) para o evento de 26/11/81.

Rendimento Observado : 29 %.(X1=125 X2= 11 X3=154 X4= 59mm). Sto Augusto -RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	42	39	19	24	31	35	39	42
2	44	43	19	24	32	37	41	44
3	26	21	14	17	20	23	25	26
4	33	26	24	28	31	32	33	34

Rendimento estimado com o Modelo LOG3 : 21 %.

Rendimento estimado com o Modelo LOG3ITER : 36 %.

Tabela 12.4.4 Prognósticos de rendimentos (%) para o evento de 18/11/80.

Rendimento Observado : 65 %.(X1=216 X2= 74 X3=194 X4= 29mm). Sto Augusto -RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	42	39	18	23	30	35	38	42
2	46	49	19	26	33	38	42	46
3	44	47	22	27	34	37	41	44
4	64	61	48	53	58	62	64	66

Rendimento estimado com o Modelo LOG3 : 60 %.

Rendimento estimado com o Modelo LOG3ITER : 64 %.

12.5 Prognósticos para Cruz Alta - RS.

Tabela 12.5.1 Prognósticos de rendimentos (%) para o evento de 01/10/78.

Rendimento Observado : 20 %. (X1= 64 X2= 83 X3= 27 X4= 11mm). Cruz Alta -RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	44	42	14	19	27	34	39	44
2	42	38	14	17	26	32	37	42
3	40	36	13	18	27	32	37	40
4	24	25	12	17	21	23	24	25

Rendimento estimado com o Modelo LOG3 : 22 %.

Rendimento estimado com o Modelo LOG3ITER : 25 %.

Tabela 12.5.2 Prognósticos de rendimentos (%) para o evento de 01/10/80.

Rendimento Observado : 69 %. (X1=261 X2=112 X3=119 X4=176mm). Cruz Alta -RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	44	42	14	19	27	34	39	44
2	47	47	16	20	30	37	42	48
3	49	49	16	22	33	40	45	50
4	65	61	31	46	57	62	65	68

Rendimento estimado com o Modelo LOG3 : 71 %.

Rendimento estimado com o Modelo LOG3ITER : 64 %.

Tabela 12.5.3 Prognósticos de rendimentos (%) para o evento de 23/10/84.

Rendimento Observado : 31 %. (X1= 83 X2= 46 X3= 42 X4=151mm). Cruz Alta -RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	49	45	11	14	29	37	44	49
2	47	42	11	14	29	36	42	48
3	40	36	9	13	25	33	37	42
4	28	27	22	24	26	27	28	29

Rendimento estimado com o Modelo LOG3 : 24 %.

Rendimento estimado com o Modelo LOG3ITER : 28 %.

Tabela 12.5.4 Prognósticos de rendimentos (%) para o evento de 28/10/86.

Rendimento Observado : 70 %.(X1=253 X2= 87 X3=164 X4=102mm). Cruz Alta -RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	49	45	11	14	29	37	44	49
2	52	50	12	16	32	40	47	53
3	53	51	12	17	33	42	49	55
4	75	68	58	64	70	72	75	77

Rendimento estimado com o Modelo LOG3 : 77 %.

Rendimento estimado com o Modelo LOG3ITER : 71 %.

12.6 Prognósticos para Passo Fundo - RS.

Tabela 12 6 1 Prognósticos de rendimentos (%) para o evento de 30/10/78

Rendimento Observado : 19 % (X1=145 X2= 60 X3= 27 X4=145mm) Passo Fundo-RS .

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	58	53	27	34	42	48	53	58
2	58	52	28	34	42	48	52	57
3	51	46	27	33	40	45	49	52
4	24	26	19	21	23	23	24	25

Rendimento estimado com o Modelo LOG3 : 24 %.

Rendimento estimado com o Modelo LOG3ITER : 25 %.

12.7 Prognósticos para Santa Rosa - RS.

Tabela 12.7.1 Prognósticos de rendimentos (%) para o evento de 29/10/76.

Rendimento Observado : 53 % (X1=101 X2= 96 X3=100 X4= 81mm) Santa Rosa -RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	52	47	17	27	36	43	48	52
2	51	46	16	26	36	42	47	52
3	51	46	19	29	37	44	48	52
4	53	48	43	46	49	51	52	54

Rendimento estimado com o Modelo LOG3 : 49 %.

Rendimento estimado com o Modelo LOG3ITER : 52 %.

Tabela 12.7.2 Prognósticos de rendimentos (%) para o evento de 15/10/78.

Rendimento Observado : 19 % (X1= 56 X2=100 X3= 27 X4= 24mm) Santa Rosa -RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	52	47	17	27	36	43	48	52
2	48	42	16	25	34	40	45	49
3	49	42	18	27	35	42	46	50
4	25	26	20	22	23	24	25	26

Rendimento estimado com o Modelo LOG3 : 22 %.

Rendimento estimado com o Modelo LOG3ITER : 25 %.

Tabela 12.7.3 Prognósticos de rendimentos (%) para o evento de 21/10/81.

Rendimento Observado : 38 % (X1=104 X2= 99 X3= 60 X4=129mm) Santa Rosa -RS.

ESTAGIO	ITER	LOG	Probabilidades					
			95%	90%	80%	70%	60%	50%
1	52	47	17	27	36	43	48	52
2	51	46	16	26	36	42	47	52
3	52	47	19	29	37	44	49	53
4	41	39	33	35	38	39	40	42

Rendimento estimado com o Modelo LOG3 : 39 %.

Rendimento estimado com o Modelo LOG3ITER : 40 %.

13. Conclusões e Recomendações

Os resultados apresentados foram desenvolvidos a partir de dados brutos de precipitação e produtividade do milho. Portanto, o estudo deve ser encarado como uma tentativa de obter as respostas de produção que propiciam informações para análises de pré-viabilidade técnica e econômica de projetos de irrigação. Entretanto, as análises de regressão e otimização se mostraram coerentes, o que mostra que o estudo foi conduzido com uma metodologia aceitável, existindo uma forte indicação de validade dos modelos apresentados.

Os modelos empregados para estimar rendimentos se mostraram consistentes para tal finalidade, sendo que a condição fundamental para um bom desempenho dos mesmos é a qualidade da informação de entrada, exigindo uma criteriosa análise preliminar antes de serem efetuadas as regressões. As análises devem considerar, sobretudo:

- O número de eventos (data de semeadura e rendimento correspondente não deve ser inferior a vinte (20)).

- Inclusão de cultivares com potencial genético e ciclo equivalentes.

Utilização de variáveis climáticas nos modelos de previsão tais como soma térmica, radiação e fotoperíodo. De preferência incluir a variável que possui maior relevância na fenologia da cultura.

- Discretização do ciclo da cultura.

- Distribuição temporal das precipitações.

Neste trabalho a simplificação assumida para cálculo da precipitação efetiva pode não ser adequada para outros locais, dependendo do padrão de precipitações dentro do período agrícola como também do comportamento do solo em transformar a precipitação bruta em água disponível para a planta. Apesar de que as perdas em sistemas agrícolas são baixas se conclui que o procedimento adotado para transformar a precipitação bruta em efetiva não é relevante como se esperava, pois as estimativas dos parâmetros dos modelos incorporam intrinsecamente uma componente da precipitação efetiva.

A utilização da Soma Térmica como variável climática apresentou vantagens sobre a utilização do número de dias entre a semeadura e a maturação:

- As estimativas de rendimentos são mais precisas.
- Não há necessidade de fixar o número de dias entre a semeadura e a maturação.
- É possível incluir numa mesma amostra eventos com datas de semeadura bem espaçadas sem incorrer em erros grosseiros.
- Possibilidade de extensão de séries de soma térmica quando a informação é escassa.
- Biologicamente, a soma térmica é mais precisa para efetuar a medição da fenologia do milho.
- Com relação à seleção da melhor época de semeadura, de uma forma geral, os rendimentos médios caem consideravelmente a partir de 1º de setembro. Tendo em vista que no mês de setembro ocorrem ainda muitas geadas e chuvas intensas, o mais razoável é recomendar o plantio no final de setembro e início de outubro.

Da análise de otimização realizada, juntamente com os resultados obtidos da sua aplicação, se pode concluir:

a) O modelo LOG $Y = C_1 \prod_{i=1}^n X_i^{\lambda_i}$ apresenta resultados mais coerentes.

b) O rendimento do milho é linearmente dependente do volume de água disponível, desde que os déficits sejam bem distribuídos, como demonstrado na análise da otimização.

c) Para alcançar os rendimentos máximos num sistema onde o suprimento hídrico constitui uma variável de decisão, é necessário distribuir tal suprimento hídrico proporcionalmente às magnitudes das estimativas dos parâmetros do modelo LOG (λ_i).

d) A curva da resposta máxima se constitui na envolvente superior dos rendimentos observados.

e) A distribuição da precipitação é muito mais importante que o total.

f) Os parâmetros λ_i se relacionam linearmente com a evapotranspiração potencial (ETPi).

g) É possível, conhecendo ETPi, obter estimativas de λ_i .

Finalmente, o estudo realizado nos leva às seguintes recomendações:

a) Avaliação da precipitação efetiva e a sua quantificação nos modelos LOG/LIN.

b) Apesar da forte evidência de que as estimativas dos parâmetros do modelo LOG, depuradas, possam ser utilizadas em outras regiões, recomenda-se uma comprovação local.

c) Extensão deste tipo de metodologia a outras regiões e/ou outras culturas.

Bibliografia consultada

- AGUINSKY, S.; DORFMAN, R.; MATZENAUER, R. 1988. Modelo para prognóstico e otimização do rendimento do milho (*Zea mays* l.). In: CONGRESSO NACIONAL DE IRRIGAÇÃO E DRENAGEM, 8., Florianópolis, 1988. ANAIS. Florianópolis, ABID. v.1, p.161-80.
- ARKIN, G.F.; RICHARDSON, C.W.; MAAS, S.J. 1978. Forecasting grain sorghum yields using probability functions. Transactions of the ASAE, Saint Joseph,
- BAKER, C.H. & HORROCKS, R.D. 1978. A computer simulation of corn grain production. Transactions of the ASAE, Saint Joseph,
- BERLATO, M.; SUTILI, V.; CASTRO, A.O. 1974. Comparação de 3 métodos de cálculo das exigências térmicas para espigamento do milho (*Zea mays*, L.). Agronomia Sulriograndense, Porto Alegre, 10(1):87-94.
- BURNETT, E. & MOLDENHAUER, W.C. 1957. Using rainfall records as guides to predict yields of cotton on drylands of the high and rolling plains of Texas. College Station, Texas Agricultural Experiment Station, 8p.
- CHIELLE, Z. G. 1977. Exigências térmicas das cultivares de milho precoces e tardias em ensaio estadual; resumo. In: REUNIÃO TÉCNICA ANUAL DO MILHO, 22., E DO SORGO GRANÍFERO, 6., Porto Alegre, 1977. ATA. Porto Alegre, IPAGRO. p.11.
- CHIELLE, Z.G. 1981. Somas térmicas em ensaio estadual de milhos precoces e normais. In: REUNIÃO TÉCNICA ANUAL DO MILHO, 26., Porto Alegre, 1981. Ata. Porto Alegre, IPAGRO, EMATER. p.102-4.
- CHIELLE, Z.G. & SUTILI, V.R. 1980. Somas térmicas em milho, em ensaios estaduais de milhos precoces e normais. In: REUNIÃO TÉCNICA ANUAL DO MILHO, 25., E DO SORGO GRANÍFERO, 9., Porto Alegre, 1980. Ata. Porto Alegre, IPAGRO. p.61-4.

- CHILDS, S.W.; GILLEY, J.R.; SPLINTER, W.E. 1977. A simplified model of corn growth under moisture stress. Transactions of the ASAE, Saint Joseph, 20(5):858-65, Sept.6Oct.
- COUTO, L.; COSTA, E.; GARCHA, J.C. 1981. Função de produção e eficiência no uso da água pela cultura do milho. In: REUNIÃO TÉCNICA ANUAL DO MILHO, 26., Porto Alegre, 1981. Ata. Porto Alegre, IPAGRO, EMATER. p.105-8.
- DOORENBOS, J. & PRUITT, W. 1976. Las necesidades de agua de los cultivos. Roma, Organización de las Naciones Unidas para la Agricultura y la Alimentación. 194p. (FAO: Riego y Drenaje, 24).
- DOORENBOS, J. & KASSAM, A.H. 1979. Efectos del agua sobre el rendimiento de los cultivos. Roma, Organización de las Naciones Unidas para la Agricultura y la Alimentación. 212p. (FAO: Riego y Drenaje, 33).
- DORFMAN, R. 1985. Planning of irrigation systems under conditions of scarce data. Haifa, Technion-Israel Institute of Technology. 114f. (Tese Dout. Ciência Tecnologia).
- DOSS, B.D.; PEARSON, R.W.; ROGERS, H.T. 1974. Effect of soil water stress at various stages on soybean yield. Agronomy Journal, Madison, 66(2): 297-9, Mar./Apr.
- DOWNEY, L.A. 1972. Water-yield relations for nonforage crops. Journal of the Irrigation and Drainage Division. American Society of Civil Engineers, New York, 98(1): 107-15, Mar.
- DRAPER, N.R. & SMITH, H. 1981. Applied Regression Analysis. 2.ed. New York, John Wiley. 709p.
- ENGLISH, M.J. & NUSS, G.S. 1982. Designing for deficit irrigation. Journal of the Irrigation and Drainage Division. American Society of Civil Engineers, New York, 108(2): 91-106, June.

- FRERE, M. & POPOV, G.F. 1980. Pronostico de cosechas basado en datos agrometeorologicos. Roma, Organización de las Naciones Unidas para la Agricultura y la alimentación. 66p. (FAO: Producción y Protección Vegetal, 17).
- GILMORE, E.C. & ROGERS, J.S. 1958. Heat units as a method of measuring maturity in corn. Agronomy Journal, Madison, 50: 611-5.
- HAGAN, R.M. & STEWART, J.I. 1972. Water deficits- irrigation design and programming. Journal of the Irrigation and Drainage Division. American Society of Civil Engineers, New York, 98(2): 215-37, June.
- HILER, E.A.; HOWELL, T.A.; LEWIS, R.B.; BOSS, R.P. 1974. Irrigation timing by the stress day index method. Transactions of the ASAE, Saint Joseph, 17(3): 393-9, May/June.
- HOGG, H.C.; DAVIDSON, J.R.; CHANG, J. 1969. Economics of a water-yield function for sugar cane. Journal of the Irrigation and Drainage Division. American Society of Civil Engineers, New York, 95(1): 127-38, Mar.
- HOOD, C.P.; McCLENDOM, R.W.; HOOK, J.E. 1987. Computer analysis of soybean irrigation management strategies. Transactions of the ASAE, Saint Joseph, 30(2): 417-23, Mar./Apr.
- HOWELL, T.A. & HILER, E.A. 1975. Optimization of water use efficiency under high frequency irrigation; I. Evapotranspiration and Yield relationship. Transactions of the ASAE, Saint Joseph, 18(5): 873-8. Sep./Oct.
- HOWELL, T.A. & HILER, E.A.; REDDELL, D.L. 1975. Optimization of water use efficiency under high frequency irrigation; II. System simulation and dynamic programming. Transactions of the ASAE, Saint Joseph, 18(5): 879-87. Sep./Oct.

- HSIAO, T.C. 1973. Plant responses to water stress. Annual review of Plant Physiology, Palo Alto, 24: 519-70.
- IPAGRO. 1979. Observações meteorológicas no estado do Rio Grande do Sul. Porto Alegre. 272p. (Boletim Técnico IPAGRO,3).
- JENSEN, M.E. & WRIGHT, J.L. 1978. The role of evapotranspiration models for irrigation scheduling. Transactions of the ASAE, Saint Joseph, 21(1): 82-7, Jan./Feb.
- JENSEN, M.E.; WRIGHT, J.L.; PRATT, B.J. 1971. Estimating soil moisture depletion from climate, crop and soil data. Transactions of the ASAE, Saint Joseph, 14(5): 954-9, Sep./Oct.
- LAMBERT, J.R. & REICOVSKY, D.C. 1984. Dynamics of water in Zea mays, L.: sensitivity analysis of TROIKA. Transactions of the ASAE, Saint Joseph, 27(1): 117-24, Jan./Feb.
- LEVANTAMENTO de reconhecimento dos solos do estado do Rio Grande do Sul. 1973. Recife, Divisão de Pesquisa pedológica. 431p. (Boletim Técnico, 30).
- LORBER, M. & HAITH, D.A. 1981. A corn yield model for operational planning and management. Transactions of the ASAE, Saint Joseph,
- MALUF, J.R.T.; CUNHA, G.R.; SILVA, A.V. 1980. Agroclimatologia do estado do Rio Grande do Sul: I. Comparação entre unidades térmicas acumuladas calculadas em função das temperaturas média diária e média mensal. Agronomia Sulriograndense, Porto Alegre, 16(2): 283-311.
- MALUF, J.R.T.; MATZENAUER, R.; CUNHA, G.R.; WESTPHALEN, S.L. 1983. Agroclimatologia do estado do Rio Grande do Sul: II. Zoneamento agroclimático da cultura do milho (Zea mays, L.). IPAGRO Informa, Porto Alegre, (26): 3-15.

- MALUF, J.R.T.; MATZENAUER, R.; WESTPHALEN, S.L.; CUNHA, G.R.; SUTILI, V.R. 1986. Zoneamento agroclimático da cultura do milho (*Zea mays*, L.) para o estado do Rio Grande do Sul. Agronomia Sulriograndense, Porto Alegre, 22(2): 261-85.
- MINITAB Statistical Software; reference manual - release 6.1. 1988. Boston, Minitab. 341p.
- MOREY, R.V. & GILLEY, J.R. 1973. A simulation model for evaluating irrigation management practices. Transactions of the ASAE, Saint Joseph, 16(5): 979-83, Sep./Oct.
- MOREY, R.V.; GILLEY, J.R.; BERGSRUD, F.G.; DIRKZWAGER, L.R. 1980. Yield response of corn related to soil moisture. Transactions of the ASAE, Saint Joseph, 23(5): 1165-70, Sep./Oct.
- MOTA, F.S.; BEIRSDORF, M.I.C.; GARCEZ, J.R.B. 1973-74. Zoneamento agroclimático do Rio Grande do Sul e Santa Catarina. Pelotas, IPEAS. 2v. (IPEAS. Circular 50).
- MUSICK, J.T. & DUSEK, D.A. 1971. Grain sorghum response to number, timing and size of irrigations in the Southern High Plains. Transactions of the ASAE, Saint Joseph, 14(3): 401-4, 410, May/June.
- MUSICK, J.T. & DUSEK, D.A. 1980. Irrigated corn yield response to water. Transactions of the ASAE, Saint Joseph, 23(1): 92-8, 103, Jan./Feb.
- MUSICK, J.T.; NEW, L.L.; DUSEK, D.A. 1976. Soil water depletion-yield relationships of irrigated sorghum, wheat and soybeans. Transactions of the ASAE, Saint Joseph, 19(3): 489-93, May/June.
- RAO, N.H.; SHARMA, P.B.S.; CHANDER, S. 1988. A simple dated water-production function for use in irrigated agriculture. Agricultural Water Management, Amsterdam, 13: 25-32.

- ROTUNNO, I.S. 1988. Utilização da função de produção na estimativa do déficit hídrico da cultura do milho no município de Taquarí-RS. Porto Alegre. 16f. Trabalho apresentado no curso de Pós-graduação em Recursos Hídricos e Saneamento da UFRGS.
- RYAN, B.F.; JOINER, B.L.; RYAN, T.A., Jr. 1985. Minitab handbook. 2.ed. Boston, PWS-Kent. 379p.
- SCHNEIDER, A.D.; MUSICK, J.T.; DUSEK, D.A. 1969. Efficient wheat irrigation with limited water. Transactions of the ASAE, Saint Joseph, 12(1):23-6, Jan./Feb.
- SCHWARZBACH, M.S.R. 1988. Estudo comparativo do comportamento hidrológico de bacias situadas na região sul e no nordeste semi árido do Brasil. Porto Alegre, UFRGS-Curso de Pós-graduação em Recursos Hídricos e Saneamento. 160f. Diss. Mestr. Engenharia Civil.
- SILVA, M.T.B.; TORRES, L.A.M.; CAMPOS, A.E. 1985. Bioecologia e efeito de Spodoptera frugiperda (Smith & Abott, 1797) sobre o rendimento do milho semeado em diversas épocas. In: REUNIÃO TÉCNICA ANUAL DO MILHO, 30., Porto Alegre, 1985. Ata. Porto Alegre, IPAGRO. p.353- 9.
- SIMAS, J.R. 1988. Política nacional de irrigação - perspectivas para o ano 2000 - demandas energéticas e hídricas. s.l., DNOCS. 34p. Palestra proferida no VIII Congresso Nacional de Irrigação e Drenagem, Florianópolis, 10 Out. 1988.
- STEWART, J.I. & HAGAN, R.M. 1973. Functions to predict effects of crop water deficits. Journal of the Irrigation and Drainage Division. American Society of Civil Engineers, New York, 99(4): 421-39, Dec.
- SUTILI, V.R.; MATZENAUER, R.; BERLATO, M.A. 1977. Épocas de semeadura de milho para o Rio Grande do Sul. In: REUNIÃO TÉCNICA ANUAL DO MILHO, 22., E DO SORGO GRANÍFERO, 6., Porto Alegre, 1977. Ata. Porto Alegre, IPAGRO. p.19-31.

TSCHESCHKE, P.D. & GILLEY, J.R. 1979. Status and verification of Nebraska's corn growth model-CORNGRO. Transactions of the ASAE, Saint Joseph, 22(6): 1329-37, Nov./Dec.

WRIGHT, J.L. & JENSEN, M.E. 1978. Development and evaluation of evapotranspiration models for irrigation scheduling. Transactions of the ASAE, Saint Joseph, 21(1): 88-92, 96, Jan./Feb.

YARON, D. 1971. Estimation and use of water production functions in crops. Journal of the Irrigation and Drainage Division. American Society of Civil Engineers, New York, 97(2): 291-303, June.