



Universidade Estadual de Campinas

LCSI Faculdade de Engenharia Elétrica e de Computação
Departamento de Máquinas, Componentes e Sistemas Inteligentes
Laboratório de Controle e Sistemas Inteligentes

Modelagem de Processos de Acumulação de Biomassa e de Açúcar da Cana-de-açúcar via Sistemas Nebulosos

Autor: André Pereira de Godoy

Orientador: Prof. Dr. Gilmar Barreto

Co-orientador: Prof. Dr. Ginalber Luiz de Oliveira Serra

Dissertação de Mestrado apresentada à Faculdade de Engenharia Elétrica e de Computação como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: **Automação**.

Banca Examinadora

Celso Pascoli Bottura, Prof. Dr. DMCSI/FEEC/UNICAMP
Fábio Cesar da Silva, Dr. CNPTIA/EMBRAPA
Fernando José Von Zuben, Prof. Dr. DCA/FEEC/UNICAMP

Campinas, SP

25 de Maio de 2007

FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA E ARQUITETURA - BAE - UNICAMP

G548m Godoy, André Pereira de
Modelagem de processos de acumulação de biomassa e de
açúcar da cana-de-açúcar via sistemas nebulosos / André
Pereira de Godoy. --Campinas, SP: [s.n.], 2007.

Orientadores: Gilmar Barreto, Ginalber Luiz de Oliveira
Serra

Dissertação (Mestrado) - Universidade Estadual de
Campinas, Faculdade de Engenharia Elétrica e de
Computação.

1. Açúcar. 2. Cana-de-açúcar. 3. Biomassa. 4. Sistemas
nebulosos. 5. Modelos matemáticos. 6. Análise de sistemas.
7. Simulação por computador. I. Barreto, Gilmar. II. Serra,
Ginalber Luiz de Oliveira. III. Universidade Estadual de
Campinas. Faculdade de Engenharia Elétrica e de
Computação. IV. Título.

Título em Inglês: Modelling of biomass and sugar accumulation processes of sugarcane
by fuzzy systems

Palavras-chave em Inglês: Fuzzy systems identification, Takagi-Sugeno model,
Agricultural modeling, Linear systems identification, Linear
analysis, QCANE model

Área de concentração: Automação

Titulação: Mestre em Engenharia Elétrica

Banca examinadora: Celso Pascoli Bottura, Fábio César da Silva e Fernando José Von
Zuben

Data da defesa: 25/05/2007

Programa de Pós-Graduação: Engenharia Elétrica

Resumo

Este estudo objetiva identificar e ajustar um modelo nebuloso (*Fuzzy*) para a predição de um passo a frente dos processos de acumulação de biomassa e de açúcar da cana-de-açúcar com índices de erro inferiores aos obtidos pelo modelo QCANE. Os processos fisiológicos de acumulação da cana-de-açúcar são estudados para determinação dos fatores mais influentes a serem tratados no procedimento de identificação do modelo. Algumas técnicas de identificação disponíveis são estudadas e experimentos computacionais são realizados para selecionar e avaliar a representação matemática e a estrutura de modelo mais adequadas. Durante o procedimento de identificação procura-se obter modelo com o menor número de parâmetros possível, que permita ao usuário compreender de forma mais clara o resultado da simulação do modelo. Para estes processos são apresentados resultados para modelos contínuos, modelos ARX e modelos nebulosos discretos. A opção pela utilização dos modelos nebulosos para estes processos deve-se a expectativa confirmada de que esta estrutura matemática obtivesse um melhor desempenho nas predições utilizando uma quantidade reduzida de parâmetros. Os resultados computacionais indicam a obtenção de respostas mais precisas e exatas para os modelos nebulosos do que para o modelo QCANE, tido como o modelo mais preciso da literatura para estimação de acumulação de biomassa e de açúcar na cana-de-açúcar, em todos os aspectos desejados para este trabalho.

Palavras-chave: Identificação de sistemas nebulosos, modelo Takagi-Sugeno, modelagem agrícola, identificação de sistemas lineares, análises de modelos lineares, modelo QCANE.

Abstract

The aim of this master thesis is to identify and adjust a fuzzy model for the one step ahead prediction of the process of biomass and sugar accumulation of the sugarcane with a level of errors inferior to those gotten by the QCANE model. The physiological processes of accumulation in sugar cane are studied for determination of the most influent factors to be dealt within the procedure of model identification. Some available identification techniques are studied and computer experiments are done to select and evaluate the mathematical representation and the structure of a more suitable model. During the process of identification, the search is for a model with a smaller number of parameters, that allows the user to understand in a simple, clear way, the result of the simulation of the model. To these processes results for continuous, ARX and discrete fuzzy models are presented. The option for the use of the fuzzy model for these processes is due to confirmation of the expectation that this mathematical structure could have a better performance in the prediction using a reduced amount of parameters. The computer results indicate the obtention of more accurate and precise answers to the fuzzy models than to the QCANE model considered the most precise model from the literature

in biomass and sugar accumulation of the sugar cane estimation according to all the aspects set for this work.

Keywords: fuzzy systems identification, Takagi- Sugeno model, agricultural modeling, linear systems identification, linear model analysis, QCANE model

Aos meus pais, familiares e amigos

Agradecimentos

Ao meu orientador, Professor Dr. Gilmar Barreto, sou grato pela orientação e por me instigar a sempre olhar além do meu trabalho, buscando sempre um objetivo maior.

Aos Professores da Faculdade de Engenharia Elétrica e de Computação, dentre os quais os Professores Celso Pascoli Bottura, Wagner Cardori do Amaral, João Bosco Ribeiro do Val, Fernando José Von Zuben, pela disponibilidade em ajudar, esclarecer minhas dúvidas e me aconselhar durante minha trajetória na pós-graduação.

Ao colega e co-orientador Ginalber Luiz de Oliveira Serra pela motivação e pela assistência constante durante a realização deste trabalho, apesar da dificuldade da distância. Aos colegas Felipe de Melo Almeida e Amilcar José Pucciarelli pelas sugestões, apoio e companheirismo.

Aos demais colegas de pós-graduação, pelas críticas e sugestões.

À EMBRAPA Informática Agropecuária pelo apoio institucional e acadêmico para a construção desse trabalho. Agradeço em especial a cooperação e apoio do Doutor Fábio César da Silva, seu pesquisador.

Ao Professor da ESALQ - USP, Doutor Durval Dourado Neto, especialista na área de modelagem vegetal, pelas críticas comentários e observações sobre o trabalho.

Ao Professor Doutor De Li Liu pelo apoio em minha pesquisa fornecendo os dados e informações adicionais imprescindíveis para a conclusão deste trabalho. Estas informações representam para mim um voto de confiança por parte do Prof. Dr. Liu na execução deste trabalho.

À minha família pelo apoio incondicional durante esta jornada, além do constante incentivo para me dedicar aos estudos. Em especial, ao meu pai que sempre me instigou à pesquisa e estudo, e à minha mãe, também amiga e confidente, pelo apoio, carinho, amor e puxões de orelha.

À CAPES, pelo apoio financeiro.

Sumário

Lista de Figuras	xvii
Lista de Tabelas	xxiii
Glossário	xxvii
Lista de Unidades e Notações	xxvii
Trabalhos Publicados pelo Autor	xxix
1 História e Economia da Cana-de-açúcar	1
1.1 História da cultura de cana-de-açúcar	1
1.2 Importância econômica e perspectivas	8
1.3 Hipótese Científica	13
1.4 Objetivos do trabalho	14
2 Morfologia, Cultivo e Técnicas de Amostragem da Cana-de-açúcar	17
2.1 A cana-de-açúcar	17
2.1.1 Composição morfológica e anatômica	18
2.1.1.1 Folha	18
2.1.1.2 Flor	19
2.1.1.3 Colmo	20
2.1.1.4 Rizomas	23
2.1.1.5 Raízes	24
2.1.2 Fatores produtivos	27

2.1.3	Ciclo da cultura	28
2.2	Operacional agrícola	31
2.2.1	Seleção dos Cultivares	31
2.2.2	Preparo do solo	32
2.2.3	Calagem	33
2.2.4	Adubação	34
2.2.5	Plantio	36
2.2.6	Tratos culturais	36
2.2.7	Maturadores Químicos	38
2.2.8	Ponto de colheita	39
2.2.9	Colheita	40
2.2.10	Operação de corte	40
2.2.11	Transporte, pesagem, descarregamento e estocagem	40
2.3	Medidas e Processos de Amostragem	41
2.3.1	Amostragem de colmos	41
2.3.1.1	Amostragem racional das parcelas para determinar o ponto de maturidade	42
2.3.1.2	Parcelamento dos Campos de cana-de-açúcar	42
2.3.1.3	Processo de análise das amostras	45
3	Sistemas nebulosos	47
3.1	Introdução	47
3.2	Modelos Nebulosos Lingüísticos	48
3.2.1	Termos e variáveis lingüísticas	49
3.2.2	Proposições antecedentes	51
3.2.3	Inferência em Modelos Lingüísticos	51
3.2.4	Defuzzificação	54
3.3	Modelos <i>Singleton</i>	55
3.4	Modelos Takagi-Sugeno	56
3.4.1	Inferência no modelo TS	58

3.5	Construção de Modelos Nebulosos TS	59
3.5.1	Identificação da estrutura	60
3.5.2	Identificação dos parâmetros	61
3.6	Algoritmo de Agrupamento	61
3.6.1	Definição de Agrupamentos	62
3.6.2	Algoritmo de agrupamento <i>c-means</i>	62
3.6.2.1	A função objetivo <i>c-means</i>	62
3.6.3	Algoritmo <i>c-means</i> nebuloso	63
3.6.4	Algoritmo de agrupamento de Gustafson-Kessel	64
3.7	O problema da regressão não-linear	66
3.8	Identificação pelo Espaço Produto	67
3.9	Construção de modelos a partir das partições nebulosas	69
3.9.1	Geração das funções de pertinência do antecedente	70
3.9.1.1	Projeção ortonormal nos eixos	70
3.9.1.2	Projeção dos autovalores.	73
3.9.1.3	Parametrização da função de pertinência	74
3.9.1.4	Funções de pertinência do antecedente multidimensionais	74
3.9.2	Estimando os parâmetros do conseqüente	75
3.9.2.1	Computando os parâmetros do conseqüente pelo método de mínimos quadrados total.	75
3.9.2.2	Estimando os parâmetros do conseqüente com o método de mínimos quadrados ordinário	77
3.9.2.3	Um conjunto de problemas de mínimos quadrados ponderado	78
3.9.2.4	Método de mínimos quadrados global	78
4	Modelagem e Identificação da Cana-de-açúcar	81
4.1	Introdução	81
4.2	Modelagem dos sistemas agrícolas	81
4.2.1	Definição de modelo	82
4.2.2	Complexidade dos sistemas agrícolas	83
4.3	Modelos na agricultura	85

4.3.1	Características de modelos de culturas	85
4.3.2	Modelos Estatísticos	86
4.3.3	Modelos Mecanísticos	86
4.3.4	Modelos mecanísticos versus modelos estatísticos	87
4.3.5	Modelos Dinâmicos e Estáticos	88
4.3.6	Modelos Determinísticos e Estocásticos	89
4.3.7	Simulação e otimização de modelos	91
4.4	Modelagem mecanística aplicada à cana-de-açúcar	91
4.4.1	A história dos modelos e seus conceitos	93
4.4.1.1	O modelo de simulação APSIM-sugarcane	93
4.4.1.2	O modelo CANEGRO	94
4.4.1.3	O modelo de simulação da cana-de-açúcar QCANE	97
4.4.1.4	Contribuição Nacional	98
4.4.2	Modelos nebulosos aplicados na agricultura	100
4.5	Identificação de Sistemas	101
4.5.1	Experimentação e aquisição dos dados	102
4.5.1.1	Sinais de teste	102
4.5.1.2	Seleção do período de amostragem para a aquisição de dados	104
4.5.1.3	Ruído nos dados	105
4.5.1.4	Detecção de não-linearidades	106
4.5.2	Escolha da representação matemática	106
4.5.2.1	A série de Volterra	107
4.5.2.2	Modelos de Hammerstein e de Wiener	107
4.5.2.3	Funções de Base Radial	107
4.5.2.4	Redes neurais	108
4.5.2.5	Modelos Contínuos de Processos	109
4.5.2.6	Modelos discretos	110
4.5.2.7	Modelo FIR	110
4.5.2.8	Modelo ARX	111

4.5.2.9	Modelo ARX multivariável	111
4.5.2.10	Modelo ARMAX	113
4.5.2.11	Modelo Nebuloso Discreto NARX	113
4.5.3	Estruturas de modelos	114
4.5.4	Validação de modelos	115
4.6	Uso de modelos agrícolas e suas limitações	117
4.6.1	Limitação dos modelos	117
4.6.2	Uso de modelos	118
5	Modelagem dos Processos de Acumulação de Biomassa e de Açúcar da Cana-de-açúcar	121
5.1	Introdução	121
5.2	Conjunto de dados	121
5.3	Pré-processamento dos dados	129
5.3.1	Determinação do período de amostragem	129
5.3.2	Detecção de não-linearidades	130
5.4	Identificação com Modelos Lineares	132
5.4.1	Modelo ARX	132
5.4.2	Modelos contínuos de processos	134
5.5	Identificação com Modelos Nebulosos	139
5.5.1	Métodos de agrupamento	139
5.5.2	Extração das funções de pertinência	147
5.5.3	Avaliação dos conseqüentes e do modelo completo	153
5.5.4	Extensão dos resultados	166
5.5.5	Associação de valores lingüísticos e descrição da semântica do modelo nebuloso	173
5.6	Conclusões	176
6	Conclusões	177
6.1	Trabalhos futuros	178
	Referências bibliográficas	180

A	Teoria de Sistemas Nebulosos, Método de Computação de Mínimos Quadrados Totais e Funções de Correlação	189
A.1	Conceitos básicos da teoria dos conjuntos nebulosos	189
A.1.1	Conjuntos nebulosos	189
A.1.2	Funções de pertinência	190
A.1.3	Definições básicas	190
A.1.4	Operações nos conjuntos nebuloso	192
A.1.5	Relações nebulosas	194
A.1.6	Projeções e extensões cilíndricas	194
A.2	Demonstração da computação dos parâmetros do conseqüente pelo método de mínimos quadrados total	195
A.3	Utilização de gráficos de correlação	197
B	Modelo QCANE	203
B.1	Introdução	203
B.2	Descrição do modelo	203
B.2.1	Considerações gerais	204
B.2.2	Acumulação de matéria seca, fibra e açúcar	210
B.2.3	Fotossíntese	211
B.2.4	Respiração de crescimento e de manutenção	214
B.2.5	Estágios fenológicos	215
B.2.6	Particionamento dos fotossintetizados	216
B.2.7	Crescimento, acumulação de açúcar na cana e senescência	218
B.2.7.1	Folha	218
B.2.7.2	Ponteiro	220
B.2.7.3	Colmo	221
B.2.7.4	Raiz	222
B.2.7.5	Relação entre a sacarose e os açúcares redutores	222
C	Procedimento de análise laboratorial de amostras	225
C.1	Introdução	225

C.2	Conservação das amostras	225
C.2.1	Anticépticos	225
C.2.2	Refrigeração	226
C.3	Processo de análise da cana-de-açúcar - Método de Payne	226
C.3.1	Recepção da amostra de cana-de-açúcar	226
C.3.2	Análise de Fibra	226
C.3.3	Determinação do Brix	227
C.3.4	Determinação do Pol	228
C.3.5	Determinação da Pureza Aparente do Caldo -PAp	228
C.3.6	Determinação dos Açúcares Redutores - AR	228
C.4	Observações	230

Lista de Figuras

1.1	Mercado mundial de açúcar do período de 1994/1995 até 2005/2006	9
2.1	Foto da inflorescência da cana-de-açúcar. Fonte: (SILVA; CESAR, 2003)	19
2.2	Amostras de colmo demonstrando a evolução do processo de isoporização. Fonte: (SILVA; CESAR, 2003)	19
2.3	Foto do colmo sem indução ao florescimento. Fonte: Nunes Junior, D. citado por (SILVA; CESAR; SILVA, 2003)	20
2.4	Foto do colmo com indução ao florescimento. Fonte: Nunes Junior, D. citado por (SILVA; CESAR; SILVA, 2003)	20
2.5	Ilustração da morforlogia do no	21
2.6	Ilustração da morforlogia do colmo	21
2.7	Corte transversal e parcial de um internódio. Fonte: (CESAR; SILVA, 1993b)	21
2.8	Distribuição da acumulação de açúcar ao longo do colmo. Fonte: adaptados de (CESAR; SILVA, 1993b) e (SILVA; CESAR; SILVA, 2003)	23
2.9	Formação do sistema radicular a partir do colmo semente. Fonte: adaptado de King (1948), citado por (SILVA; CESAR; SILVA, 2003).	25
2.10	Sistema radicular da cana-planta. Fonte: (COSTA et al., 2005)	25
2.11	Sistema radicular da cana-soca. Fonte: (COSTA et al., 2005)	25
2.12	Perfil da distribuição das raízes em quatro horizontes de dois cultivares. Fonte: (COSTA et al., 2005)	26
2.13	Fases do desenvolvimento da cana de açúcar. Fonte: PLANALSUCAR, adaptador por (SILVA; CESAR; SILVA, 2003)	29
2.14	Ilustração dos ciclos da cultura da cana-de-açúcar (implantação, regime e reforma). Fonte: Fernandes (s.d.), citado em (CASAGRANDE, 1991)	30
2.15	Comportamento das três classes de cana-de-açúcar quanto ao PUI. Fonte: (SILVA; CESAR; CHAVES, 2003)	32

2.16	Plantio de cana-de-açúcar	37
2.17	Definição esquemática dos pontos de amostragem em campo de cultivo de cana-de-açúcar	43
2.18	Fluxograma dos procedimentos laboratoriais básicos.	46
3.1	Diagrama esquemático de um sistema nebuloso genérico	49
3.2	Exemplo de uma variável lingüística “temperatura” com três termos	50
3.3	Produto cartesiano dos conjuntos nebulosos de entrada e saída para o caso de um sistema Mamdani	53
3.4	Mapeamento do espaço nebuloso do antecedente e do conseqüente	59
3.5	Representação do hiperelipsóide definido por cada agrupamento do algoritmo GK	66
3.6	Identificação pelo método de agrupamentos.	70
3.7	Interpretação das projeções ortonormais para um modelo nebuloso TS	71
3.8	Funções de pertinência obtidas diretamente da projeção ortonormal nos eixos versus a função multivariada parametrizada	72
3.9	Erro na reconstrução do agrupamento nebuloso	72
3.10	Para cada regra i a matriz H_i transforma o antecedente original	73
3.11	A posição e a orientação do i -ésimo modelo local linear	76
4.1	Níveis considerados em um modelo de cana-de-açúcar	84
4.2	Foto aérea da cultura de cana-de-açúcar mostrando falhas de plantio ao longo do terreno	84
4.3	Diagrama da estruturação dos modelos hídricos de camada e de vasos comunicantes	95
4.4	Diagrama esquemático de representação do CANEGRO	96
4.5	Diagrama de fluxo do modelo CANEGRO destacando em cinza claro as variáveis de saída e em cinza escuro as entradas, explicitando os processos que as interrelacionam	97
4.6	Representação esquemática do modelo QCANE.	99
4.7	Fluxograma do procedimento de identificação	103
5.1	Dados de entradas do modelo	122
5.2	Irrigação por sulcos ou inundação	123
5.3	Dados da acumulação de matéria seca de colmo da variedade Q138	124
5.4	Dados da acumulação de açúcar da variedade Q138	125

5.5	Dados da acumulação de fibra na variedade para Q138	125
5.6	Dados da acumulação de matéria seca de colmo da variedade Q141	126
5.7	Dados da acumulação de açúcar da variedade Q141	127
5.8	Dados da acumulação de fibra na variedade para Q141	127
5.9	Gráficos com os dados reamostrados de PS para a variedade Q138	131
5.10	Curvas da covariância cruzada para os dados dos ensaios da variedade Q138	132
5.11	Curvas com as previsões do Modelo ARX SISO considerando a Radiação Solar como a variável de entrada	134
5.12	Curvas com as previsões do Modelo ARX SISO considerando a Temperatura Média como a variável de entrada	135
5.13	Resposta do modelo de processo composto por um integrador e um atraso	136
5.14	Resultado do Algoritmo de Agrupamento GK considerando 2 centros, os (●) em azul são os dados e os (*) são os centros dos agrupamentos, e as curvas são os α -cortes (faixas de pertinência).	141
5.15	Resultado do Algoritmo de Agrupamento GK considerando 3 centros, os (●) em azul são os dados e os (*) são os centros dos agrupamentos, e as curvas são os α -cortes.	141
5.16	Resultado do Algoritmo de Agrupamento GK considerando 4 centros, os (●) em azul são os dados e os (*) são os centros dos agrupamentos, e as curvas são os α -cortes.	142
5.17	Resultado do Algoritmo de Agrupamento <i>c-means</i> considerando 2 centros, os (●) em azul são os dados e os (*) são os centros dos agrupamentos, e as curvas são os α -cortes.	143
5.18	Resultado do Algoritmo de Agrupamento <i>c-means</i> considerando 3 centros, os (●) em azul são os dados e os (*) são os centros dos agrupamentos, e as curvas são os α -cortes.	143
5.19	Resultado do Algoritmo de Agrupamento <i>c-means</i> considerando 4 centros, os (●) em azul são os dados e os (*) são os centros dos agrupamentos, e as curvas são os α -cortes.	144
5.20	Resultado do Algoritmo de Agrupamento <i>c-means</i> considerando 5 centros, os (●) em azul são os dados e os (*) são os centros dos agrupamentos, e as curvas são os α -cortes.	145
5.21	Histograma das coordenadas dos centros obtidos pelo Algoritmo <i>c-means</i> sobre o eixo do PS para cada centro considerando 7 faixas de frequência.	145
5.22	Histograma das coordenadas dos centros obtidos pelo Algoritmo <i>c-means</i> sobre o eixo do PS para cada centro considerando 7 faixas de frequência.	146
5.23	Histograma das coordenadas dos centros obtidos pelo Algoritmo GK sobre o eixo do PS para cada centro considerando 7 faixas de frequência.	146
5.24	Histograma das coordenadas dos centros obtidos pelo Algoritmo GK sobre o eixo da Temperatura Média para cada centro considerando 7 faixas de frequência.	147

5.25	Funções de pertinência trapezoidais extraídas a partir dos Agrupamentos determinados pelo Algoritmo GK	149
5.26	Funções de pertinência exponenciais extraídas a partir dos Agrupamentos determinados pelo Algoritmo GK	149
5.27	Funções de pertinência trapezoidais extraídas a partir dos Agrupamentos determinados pelo Algoritmo <i>c-means</i>	150
5.28	Funções de pertinência exponenciais extraídas a partir dos Agrupamentos determinados pelo Algoritmo <i>c-means</i>	150
5.29	Funções de pertinência trapezoidais extraídas a partir dos Agrupamentos determinados pelo Algoritmo <i>c-means</i>	151
5.30	Funções de pertinência exponenciais extraídas a partir dos Agrupamentos determinados pelo Algoritmo <i>c-means</i>	152
5.31	Histograma dos parâmetros da função de pertinência extraída a partir do agrupamento de 3 centros obtidos pelo Algoritmo <i>c-means</i> considerando 7 faixas de frequência. . .	152
5.32	Os resultados de simulação dos modelos nebulosos da acumulação de Peso Seco (AG2cm-FPtp-MCmg e AG2cm-FPexp-MCmg) ajustados pelo método MQG: na figura superior a direita as função de pertinência são trapezoidais e na figura superior a esquerda são exponenciais.	157
5.33	Simulações dos modelos nebulosos da acumulação de Peso Seco com funções de pertinência exponenciais: na figura superior a direita os parâmetros do conseqüente foram ajustados pelo MQG e na superior a esquerda pelo MQP.	159
5.34	Nestas simulações as funções de pertinência (3) são exponenciais, na figura superior a direita está a resposta do modelo com os parâmetros do conseqüente determinados por MQG e à esquerda, por MQP.	160
5.35	Simulação do Modelo Nebuloso AG3gk-FPexp-MCml com a base de regras otimizada para os quatro ensaios com um passo de predição Q141.	164
5.36	Simulação do Modelo Nebuloso AG3gk-FPexp-MCml com a base de regras modificada para os quatro ensaios com um passo de predição aplicado a variedade Q141. .	165
5.37	Funcionamento do modelo nebuloso para o Peso Seco ajustado para a variedade Q138	166
A.1	Exemplo de uma projeção	195
A.2	Função de correlação em malhar aberta	198
A.3	Função de correlação	199
A.4	Função de correlação	199
A.5	Função de correlação entrada/saída e resposta do sistema com um termo integrador .	200

A.6	Função de correlação entrada/saída e resposta do sistema com um termo integrador à um sinal senoidal adicionado de uma constante	200
A.7	Função de correlação entrada/saída e resposta do sistema com um termo integrador à um sinal senoidal defasado	201
B.1	Representação esquemática do modelo QCANE.	204
B.2	Proporção do Açúcar (A) e Fibras (F) nas folhas da cana-de-açúcar em relação ao Peso Seco (PS) total	206
B.3	Proporção do Açúcar (A) e Fibras (F) nos ponteiros da cana-de-açúcar em relação ao Peso Seco (PS) total	206
B.4	Proporção do Açúcar (A) e Fibras (F) nos colmos da cana-de-açúcar em relação ao Peso Seco (PS) total	207
B.5	Estágios considerados no QCANE. Fonte: PLANALSUCAR, adaptado por (CESAR; SILVA, 1993b)	216

Lista de Tabelas

1.1	Comparação da área de alguns países com relação a área de cana-de-açúcar plantada no Brasil	8
1.2	Dados da área cultivada com cana-de-açúcar ($A, [000 \times ha]$) da produção ($P, [1000 \times ton]$) e da produtividade por área ($P/A, [ton/ha]$) de alguns países. Fonte: FAOStat Database 2005	11
1.3	Comparação da produção de açúcar ($PA, [1000 \times ton]$), índice de recuperação de açúcar ($AR, \%$) e produtividade de açúcar ($Prod.A, [ton/ha]$) entre vários países Fonte: Indian Sugar, December 2003 Vol. 53, No.9	12
2.1	Tabela com o critério de adubação da cana-planta	34
2.2	Tabela com o critério de adubação da cana-soca	35
2.3	Tabela para corrigir deficiência de Cobre e Zinco no plantio	35
2.4	Critério para o índice de maturação e colheita da cana-de-açúcar.	39
3.1	Classificação da Identificação Nebulosa	60
4.1	Níveis hierárquicos de organização	83
5.1	Os atrasos mínimos, em dias, de cada ensaio e variedade determinados através dos gráficos de correlação	129
5.2	Faixa dos valores do fator de decimação para o Peso Seco	130
5.3	Faixas do valor do fator de decimação para a Fibra e o Açúcar.	131
5.4	Avaliação dos erros para os modelos ARX para a predição de acumulação de Peso Seco considerando a radiação e a temperatura média, respectivamente como variáveis de entrada.	135
5.5	Avaliação de duas estruturas contínuas de modelos de processos considerando a Temperatura Média como entrada e o PS como saída	137

5.6	Avaliação de duas estruturas contínuas para modelos de processos considerando a Radiação Solar como entrada e o PS como saída	138
5.7	Parâmetros dos modelos contínuos	139
5.8	Exemplo de uma base de regras considerando 3 funções de pertinência para cada uma das duas variáveis de entrada	154
5.9	Exemplo de uma base de regras incompleta considerando 3 funções de pertinência para cada uma das duas variáveis de entrada	154
5.10	Estruturas nebulosas a serem avaliadas na estimação por métodos de mínimos quadrados.	155
5.11	Sistema de codificação das características dos modelos nebulosos	156
5.12	Avaliação dos erros para os modelos nebulosos da acumulação de Peso Seco AG2cm-FPtp-MCmg e AG2cm-FPexp-MCmg.	157
5.13	Avaliação dos erros para o modelo nebuloso da acumulação de Peso Seco AG2cm-FPtp-MCml e AG2cm-FPexp-MCml.	158
5.14	Avaliação dos erros para os modelos nebulosos de acumulação de Peso Seco, AG2cm-FPexp-MCmg e AG2cm-FPexp-MCml.	159
5.15	Avaliação dos erros para os modelos nebulosos de acumulação de Peso Seco AG3cm-FPtp-MCml e AG3cm-FPexp-MCml)	160
5.16	Avaliação dos erros para os modelos nebulosos de acumulação de Peso Seco AG3cm-FPexp-MCmg e AG3cm-FPexp-MCml.	161
5.17	Avaliação dos erros para os modelo nebulosos de acumulação de Peso Seco AG3gk-FPexp-MCmg e AG3gk-FPexp-MCml.	162
5.18	Comparação das diferenças dos valores dos erros dos modelos GK (AG3gk-FPexp-MCmg e AG3gk-FPexp-MCml) em relação aos modelos <i>c-means</i> (AG3cm-FPexp-MCmg e AG3cm-FPexp-MCml, respectivamente).	163
5.19	Avaliação do modelo AG3gk-FPexp-MCml com a base de regras otimizada.	164
5.20	Parâmetros das funções antecedentes do Peso Seco (y_{k-1}) dos modelos nebulosos para as variedades Q138 e Q141	167
5.21	Parâmetros das funções antecedentes da Temperatura Média (u) dos modelos nebulosos para as variedades Q138 e Q141	168
5.22	Parâmetros dos modelos nebulosos para as variedades Q138 e Q141	168
5.23	Avaliação do modelo AG3gk-FPexp-MCml com a base de regras otimizada para a variedade de cana-de-açúcar Q141.	169
5.24	Avaliação dos erros dos modelos nebulosos com a estrutura AG3gk-FPexp-MCml para predição da acumulação de Açúcar.	170

5.25	Avaliação dos erros dos modelos nebulosos com a estrutura AG3gk-FPexp-MCml para predição da acumulação de Açúcar.	171
5.26	Comparação do erros entre os modelos nebulosos e o modelo QCANE considerando o critério RMSE	174
B.1	Constantes usadas no modelo	209
C.1	Quadro com os índices de diluição para a solução de EDTA	229

Lista de Unidades e Notações

ha	- hectare, ou 10.000[m ²]
km ²	- kilometros quadrados, ou 1.000.000 [m ²]
m	- metros
ml	- mililitro
cm	- centímetros
ton	- toneladas
kg	- kilograma
g	- grama
<i>n</i>	- número de dias
°C	- graus Celcius
h	- horas
<i>mm</i>	- litros por metro quadrado (medida para a quantidade de chuva)
IAF	- índice de área foliar
MST	- matéria seca total[kg/m ²]
MS	- matéria seca
F _b	- fotossíntese bruta
P	- produção
P _p	- produção potencial
S _m	- respiração de manutenção
<i>r_{max}</i>	- respiração máxima
rRMSE	- raiz quadrática do erro quadrático médio relativo
RMSE	- raiz quadrática do erro quadrático médio
VAF	- variância levada em conta
\mathcal{M}	- conjunto de modelos
$\mathcal{M}(\theta)$	- um modelo correspondente ao vetor de parâmetros θ
θ	- vetor de parâmetros de uma dada estrutura de modelo
MQG	- Mínimos Quadrados Global
MQP	- Mínimos Quadrados Ponderado
PS	- Peso seco [g m ⁻²]
$\gamma(i)$	- Grau de preenchimento da Regra <i>i</i>
$\sigma^2(y(t))$	- Variância da variável <i>y</i>
σ	- Taxas das massas moleculares CH ₂ O e de CO ₂
ω	- frequência [rad s ⁻¹]
ω_n	- frequência natural não amortecida de um sistema dinâmico contínuo [rad s ⁻¹]

Trabalhos Publicados Pelo Autor

1. A. P. Godoy, G.L.O. Serra, G. Barreto, Controle Multivariável Nebuloso Genético Multiobjetivo, *DIN-CON*, Bauru, 2005.
2. F.C. Silva, A.F. Bergamasco, L.H. Rodrigues, A.P. Godoy, P.C.O. Trivelin, Manejo de N Fertilizantes para a cana-de-açúcar com colheita crua, no contexto ecológico, por um modelo de simulação, *EHWC - Environmental and Health World Congress*, Santos, 2006.
3. A.P. Godoy, G. Barreto, F. C. Silva, Modelo nebuloso para a estimativa de produtividade da cana-de-açúcar, *CONAE - Conferência Internacional de Agroenergia*, Londrina, Dezembro, 2006.
4. A. P. Godoy, G. Barreto, F. C. Silva. Análise de modelos e metodologias lineares e nebulosos para a estimativa de produtividade da cana-de-açúcar, *ICECE'2007 - International Conference on Engineering and Computer Education*, Santos, São Paulo, Brasil, Março, 2007.

Capítulo 1

História e Economia da Cana-de-açúcar

O sistema de produção de cana-de-açúcar vem sofrendo mudanças profundas, de âmbitos tecnológico e social, procurando se adaptar às demandas de produção com alta produtividade, competitividade e respeito ao meio ambiente. Dentro desse contexto, um sistema de planejamento das atividades agroindustriais faz-se necessário para viabilizar o desenvolvimento das atividades sucroalcooleiras. O ato de planejar envolve a elaboração de um conjunto de ações a serem desenvolvidas para o cumprimento de um objetivo. Dessa forma é importante ao planejamento poder prever os resultados das ações no futuro. Assim, um modelo que permita prever, dentro de um determinado intervalo de tempo, os resultados produtivos, se torna uma ferramenta fundamental para o planejamento das atividades agroindustriais do setor sucroalcooleiro.

Neste capítulo é apresentada a história da cana-de-açúcar, situando a trajetória desta cultura. Posteriormente são ressaltados sua importância econômica e planos para o desenvolvimento desta cultura. Finalmente, se estabelecem os objetivos deste trabalho.

1.1 História da cultura de cana-de-açúcar

O passado da cana-de-açúcar não é plenamente conhecido e a sua presença nos lares sob a forma de adoçante é recente. A palavra que originou o nome açúcar é, provavelmente, “grão”, “sarkar”, em sânscrito.

Não se pode definir com precisão a época do surgimento da cana-de-açúcar no mundo, tampouco dizer, com exatidão, seu berço geográfico, principalmente devido à quantidade de gramíneas híbridas existentes e à falta de documentação a respeito.

No leste da Índia, o açúcar era chamado “shekar”, enquanto os povos árabes o conheciam como “al zucar”, que se transformou no espanhol “azucar”, e daí, “açúcar”, em português. Na França, o açúcar é chamado de “sucre” e, na Alemanha, de “zucker”, daí o inglês “sugar”.

Alguns pesquisadores admitem que a cana-de-açúcar tenha surgido primeiramente na Polinésia; outros arriscam a Melanésia, mais precisamente a Papua Nova Guiné, como o primeiro local de ocorrência e registro da gramínea. Para esses estudiosos, a primeira aparição da cana no mundo se deu há 6 mil anos. Nos 2 mil anos subsequentes, já haviam traços na Indonésia, nas Filipinas e no norte da África.

A cana foi introduzida na China por volta de 300 a.C. e o açúcar cru já era produzido em 200 a.C. Porém, só a partir de 500 d.C. o produto começou a ser comercializado. Há documentação sobre a expansão ocidental do artigo raro, que já era plantado na Índia em 510 a.C., de acordo com as anotações da expedição militar persa sob o comando do imperador Dario. A cana e o seu doce caldo foram mantidos em segredo, já que os povos distantes do comércio entre os asiáticos pagavam altas somas em troca de produtos luxuosos. E o açúcar era um deles.

A comprovação do consumo da planta na Índia veio em 327 a.C., quando o almirante de Alexandre “O Grande”, Nearchos, relatou ter encontrado “uma planta que faz o mel sem abelhas”. A observação dos hábitos do povo hindu, que mastigava a gramínea, fez com que o filósofo grego Teofrasto, em 287 a.C., descrevesse a maravilha como “o mel que está em um bastão”.

O primeiro processo de produção do açúcar de cana, que consistia em esmagar e ferver o bastão para dar origem ao melaço, foi registrado no ano 300 d.C. em um documento religioso hindu.

A cana-de-açúcar espalhou-se em direção ao oeste, sendo plantada na Pérsia por volta de 500 d.C. O próximo passo migratório da planta se deu mais de cem anos depois, em decorrência das invasões árabes motivadas pelo profeta Maomé - alguns anos antes de sua morte, em 632 - para a conversão do mundo ao Islã.

Em uma das incursões que levaram à conquista da Pérsia, os exércitos maometanos encontraram a cana e adotaram seu cultivo. Seu nome passou a ser “cana persa” e, em 640, já era cultivada no Mediterrâneo. A comercialização do açúcar a partir de 700 enriqueceu os árabes e o produto da cana entrou na lista de preciosidades a que os países ocidentais quase não tinham acesso.

A partir de 710 d.C., os árabes, depois de conquistar o Egito, aproveitaram-se da química egípcia para tirar lucros ainda mais elevados do plantio e da comercialização do açúcar, utilizando o dinheiro obtido com o produto para a compra de outras especiarias igualmente raras.

A cultura da cana-de-açúcar continuou a se desenvolver rumo ao Ocidente, passando pela África

do Norte até alcançar o Marrocos. Depois, cruzou o Mediterrâneo em direção ao sul da Espanha, por volta de 755, e à Sicília em 950. Continuou expandindo-se pelo litoral sul do Mediterrâneo e depois estabeleceu-se em outras localidades fora da costa atlântica africana.

O ocidente europeu só conheceu a cana no século XI, quando os cruzados retornaram dos países árabes com diversas especiarias, inclusive o “mel pagão”.

O primeiro registro da chegada do açúcar na Inglaterra é de 1099 e, em 1150, a Espanha já investia em uma florescente indústria canavieira. No ano de 1176, há a primeira referência histórica à massara (prensa), utilizada para moer a cana. Uma outra técnica de produção, a roda vertical, surgiu na China do século XII.

Nos séculos seguintes, houve um reforço do comércio entre o Leste Europeu e a Europa Ocidental, inclusive com a importação de açúcar. Porém, os maiores países consumidores ainda buscavam uma alternativa, já que os preços do produto atingiam patamares quase inaceitáveis de comercialização.

Em 1319, um quilo de açúcar valia, aproximadamente, US\$ 100. Isso manteve o status de artigo de luxo atribuído ao produto da cana e, mais tarde, motivou o aproveitamento de colônias conquistadas para a implantação de cultivares da cana-de-açúcar.

A busca por riquezas, entre elas as especiarias, levou europeus - principalmente os da Península Ibérica - a voltar os olhos para terras distantes não só do oriente. Após a conquista de Ceuta, importante entreposto comercial do norte da África, em 1415, o príncipe português D. Henrique decidiu descobrir que terras havia além das Ilhas Canárias. Assim começou a experiência colonial lusitana, com a ocupação das ilhas dos Açores, Madeira e Porto Santo, divididas em capitânicas hereditárias, modelo administrativo posteriormente exportado para o Brasil.

Em 1425, D. Henrique mandou buscar na Sicília as primeiras mudas de cana-de-açúcar, as quais foram plantadas na Ilha da Madeira. Começou, assim, a formação dos primeiros canaviais do Atlântico, que chegaram às Canárias, Cabo Verde e Açores entre 1480 e 1515.

No século XV, todo o açúcar produzido na Europa, mesmo em pequenas quantidades, era refinado em Veneza e isso anulava a possibilidade de diminuição de custos de transporte equivalente a produtos utilizados para a alimentação. Mesmo com os plantios recentes das metrópoles europeias, o refino do açúcar ainda era um entrave.

A primeira inserção da cana no Novo Mundo deveu-se a Cristóvão Colombo, levada em sua segunda viagem marítima, em 1493, e plantada na República Dominicana, na ilha de La Española, nas proximidades do povoado de La Isabela, ao norte, e no Haiti. Daí, a gramínea expandiu-se para

Cuba (1516) e México (1520). O primeiro engenho do continente foi instalado em La Española, em 1516.

O cultivo de cana-de-açúcar teve seu início no Brasil já nos primeiros anos após o descobrimento. Martin Afonso de Sousa trouxe, em 1532, as primeiras mudas oriundas da Ilha de Madeira, e as plantou na Capitania de São Vicente, próximo a cidade de Santos - SP, e o engenho recebeu o nome de São Jorge dos Erasmos. Dois anos mais tarde, Jerônimo de Albuquerque, trouxe mudas também da Ilha de Madeira, dando início a lavoura de cana na Capitania de Pernambuco, e implantou em Olinda o Engenho Nossa Senhora da Ajuda. A partir desses dois locais, o cultivo de cana se irradiou para todo litoral brasileiro, Alagoas, Sergipe, Bahia e Rio de Janeiro. Era o início do primeiro ciclo econômico brasileiro, o “Ciclo da Cana-de-Açúcar”. Para os colonizadores portugueses, o problema era a mão-de-obra, questão resolvida com a escravidão de africanos e índios. Os negros começaram a chegar ao Brasil em 1512.

A lavoura da cana-de-açúcar era realizada em toda a América. Ao norte, o primeiro moinho foi introduzido em 1535. Colômbia, Venezuela, Porto Rico e Peru também se transformaram em terras para o plantio nesta época.

Em 1600, as lavouras e indústrias da cana do Novo Mundo já haviam se tornado o investimento mais lucrativo do globo e o Brasil tornou-se o maior produtor de açúcar do mundo. Em 1613, o novo engenho de três cilindros foi implantado no Brasil, o que consolidou sua posição de liderança como produtor.

Com o domínio português, coube à Espanha encontrar lugares em que a cana pudesse se desenvolver. O local escolhido foi Cuba, que se transformou no único concorrente importante do açúcar brasileiro. Nessa época, os aumentos de produção ocorriam conforme a ampliação das terras para o plantio.

Os investimentos ingleses na cultura de cana tiveram êxito na Jamaica, onde, em 1650, foi criado um sistema de fornalha onde o aproveitamento de lenha era maior, com a substituição do aquecimento a vapor por uma fornalha de aquecimento direto como fonte de calor do processo. Esta montagem, posteriormente, recebeu o nome de “trem jamaicano”, tendo sido a solução mais eficiente para a época, (YOSHINAGA, 2006). Concomitantemente, aproveitou-se o bagaço da cana-de-açúcar como combustível. Em 1768, também na Jamaica, foi introduzida a primeira moenda movida a vapor, pelos ingleses. Essas inovações tecnológicas difundiram-se primeiro nas Antilhas inglesas, a partir da década de oitenta do século XVII, e só depois atingiram as demais áreas açucareiras.

No século XVII, a invasão dos holandeses, em Pernambuco, trouxe grande desenvolvimento para a indústria açucareira da Capitania, superando mesmo as Ilhas de Java, tornando assim uma referência

nessa época. A Região Nordeste na época teve um maior desenvolvimento que a paulista, favorecida pela maior proximidade com o continente europeu, e as favoráveis condições de clima e solo. Com a expulsão dos holandeses no século XVIII e tendo eles se estabelecido no Suriname e Antilhas produzindo açúcar, a indústria brasileira entrou em declínio, mas se recuperou no final desse século.

A invenção do “trem jamaicano” colocou mais um grande produtor no mercado: os ingleses. Com o aumento da produção e da demanda, a Grã-Bretanha começou a utilizar suas colônias de Jamaica e Barbados para diminuir sua dependência do produto importado e rivalizar com Portugal e Espanha no mercado de açúcar. Em 1806, tem início o uso do “trem jamaicano” no Brasil.

Enquanto isso, o número de subprodutos da cana se multiplicou e variedades cristalinas de açúcar, rum e melaço foram desenvolvidas. Cada parte do mundo passou a dispor de tipos de cana que se adaptassem às preferências de sua população. Diferentes níveis de pureza, cor e forma do grão de açúcar surgiram.

O maior centro de negócios do açúcar no século XVII ficava na cidade de Amsterdã, Holanda, que refinava o açúcar brasileiro. O açúcar refinado era então distribuído por toda Europa, passando principalmente por Veneza. Na época em que Veneza, o maior centro comercial do ocidente, ditava os custos e as formas de refino, os holandeses possuíam a maior estrutura de refino do globo, pelo número elevado de refinarias, que passava de mil.

Em 1747, o químico alemão Andreas Marggraf descobriu, com base em experiências do francês Olivier de Serres, que era possível retirar açúcar da beterraba, mas o custo de produção excedia em muito o da cana. Cinquenta anos mais tarde, Franz Carl Achard, um estudante das teorias de Marggraf, repetiu a experiência e fundou a primeira fábrica de açúcar de beterraba em Kunern, na Alemanha, em 1801.

Com a descoberta de novas plantas que dariam origem ao açúcar e com o bloqueio continental estabelecido por Napoleão Bonaparte, em 1806, que obstruiu a importação dos Países Baixos, a Holanda perdeu sua posição de destaque no refino do açúcar no século XIX. A França passou a financiar fortemente o desenvolvimento de outras tecnologias para extração do açúcar da beterraba a partir de 1812. Na França e na Alemanha, essa cultura se expandiu e, na metade do século XIX, já existiam variedades da beterraba desenvolvidas para o aumento da produção de açúcar.

A cultura da cana-de-açúcar continuava em expansão sendo introduzida nos EUA, na Louisiana, em 1751, no Havaí, em 1802, e na Austrália, em 1823. No Brasil também foram criadas outras técnicas de extração, como o engenho a vapor, implantado em 1815, na Ilha de Itaparica e os cilindros de ferro, utilizados a partir de 1837. A produção de papel também foi beneficiada com a agrindústria da cana-de-açúcar, com base no aproveitamento do bagaço, técnica implementada na Martinica, em

1838, (YOSHINAGA, 2006).

O aumento de colônias concorrentes no mercado produtor de açúcar e a maior disponibilidade de refinarias, inclusive na Grã-Bretanha, no século XVIII e além, fizeram com que o preço do açúcar caísse, transformando o produto em nutriente básico para a alimentação.

Porém, com as revoltas que levaram à independência de diversas colônias produtoras, com prejuízos para as plantações, e com o declínio da cultura da cana no Brasil, após a ascensão holandesa, sobretudo nas Antilhas, Cuba tomou a liderança na cultura da cana e, por estar mais próxima da Europa, transformou-se em centro produtor privilegiado.

O modelo escravista foi sendo abolido no mundo todo no século XIX, o que forçou os produtores a investir em novas técnicas de produção, tecnologias e infra-estrutura. Quem manteve o modelo antigo, como o Brasil, acabou sendo suplantado por outras nações produtoras e não teve condições de competir.

No Brasil, a substituição da mão-de-obra escrava pela tecnologia trouxe ganhos de produtividade, com a adoção do processo de centrifugação e a transformação de engenhos em usinas.

Para contornar a crise provocada pela multiplicação de centros produtores e refinarias, em 1933 foi criado no Brasil o Instituto do Açúcar e do Alcool (IAA), cuja principal função era controlar a produção para manter os preços em níveis adequados, ou seja, cada usina só poderia produzir dentro de uma quota preestabelecida.

A dispersão do açúcar pelo mundo, a ineficácia de medidas que assegurassem uma posição melhor para a produção brasileira e a primeira crise do petróleo, em 1973, levaram o setor sucroalcooleiro do País a uma alternativa singular. Com a experiência acumulada da produção e do uso de álcool combustível como alternativa para diminuir sua vulnerabilidade energética, em 1975, o governo criou o Programa Nacional do Alcool (Proálcool), que diversificou a indústria açucareira com grandes investimentos apoiados pelo Banco Mundial, possibilitando a ampliação da área plantada com cana-de-açúcar e a implantação de destilarias de álcool.

Com o desenvolvimento da engenharia nacional, após o segundo choque do petróleo, em 1979, surgiram os motores especialmente desenvolvidos para funcionar com álcool hidratado. Em 1984, os carros a álcool respondiam por 94,4% da produção das montadoras.

Desde 1986, no entanto, o arrefecimento da crise do petróleo e as políticas econômicas internas de contenção de tarifas públicas para limitar a inflação, fizeram com que o governo contribuísse decisivamente para o início de uma curva descendente de produção de carros a álcool. Por omissão ou falha operacional, o governo não foi capaz de resolver problemas logísticos, o que provocou uma

crise localizada de abastecimento em 1989. A indústria automobilística inverteu a curva de produção de carros a álcool, e a participação anual desses veículos na frota nacional caiu para 1,02% em 2001.

A preocupação com a mudança do clima no mundo, que ganhou ênfase depois da Cúpula da Terra, ou Rio-92, aumentou o interesse no álcool combustível em países como Índia, China, Austrália, Japão, Coréia do Sul etc. Nos Estados Unidos, o uso do álcool, principalmente de milho, vem ganhando espaço como aditivo da gasolina em substituição ao MTBE¹, derivado do petróleo, para evitar a contaminação das águas subterrâneas. O uso do álcool combustível mantém o Brasil como o maior produtor e exportador de álcool e açúcar.

A queda da demanda por álcool hidratado foi compensada pelo maior uso do álcool anidro misturado à gasolina, que acompanhou o crescimento da frota brasileira de veículos leves. Em mais de 25 anos de história de utilização do álcool em larga escala, o Brasil desenvolveu tecnologia de motores e logística de transporte e distribuição do produto únicas no mundo, uma rede de mais de 28 mil postos com bombas de álcool hidratado para abastecer cerca de 3 milhões de veículos, 20% da frota nacional. Em março de 2003, foi lançado o carro “*flex-fuel*”, movido a álcool, a gasolina e a qualquer mistura entre os dois, que tem conquistado cada vez mais consumidores.

O Brasil planta mais de 5 milhões de hectares de cana em menos de 1% das suas áreas cultiváveis. O País é o maior produtor mundial, seguido por Índia, Tailândia e Austrália. Planta-se cana no Centro-Sul e no Norte-Nordeste, permitindo dois períodos de safra. Produz-se, portanto, o ano todo, açúcar, álcool anidro (aditivo para gasolina) e álcool hidratado para os mercados interno e externo, com dinâmica de preços e demanda diferentes.

Atender esses mercados requer planejamento e gestão. Por séculos, isso foi feito pelo governo. A partir da década de 90, em processo concluído em 1999, a responsabilidade foi repassada integralmente ao setor privado.

Hoje, prevalece o regime de livre mercado, sem subsídios, com os preços de açúcar e álcool definidos conforme as oscilações de oferta e demanda. Os preços da cana dependem da qualidade da matéria-prima, dos preços efetivos obtidos pelos produtores e da sua participação porcentual no preço final dos produtos.

Para gerenciar e equilibrar produção e demandas setoriais, a iniciativa privada tem procurado criar instrumentos de mercado, como operações futuras, e desenvolver novas oportunidades para o açúcar

¹MTBE (Metil Tert-Butil Éter) - Líquido inflamável usado como aditivo na gasolina sem chumbo para melhorar a combustão do motor. É resultado da mistura de Isobutileno e Metanol. Quando liberado na atmosfera o MTBE contamina água e solo subsuperficiais e pode permanecer longos períodos em águas subterâneas, ligando-se às moléculas de água e também se acumulando nos sedimentos. A ingestão ou inalação causa náuseas, irritação das vias respiratórias e alterações no sistema nervoso. Fonte: Agência de Proteção Ambiental dos Estados Unidos (EPA)

e álcool, por meio da queda das barreiras protecionistas e do empenho em transformar o álcool numa “commodity” ambiental.

1.2 Importância econômica e perspectivas

A importância econômica da cana-de-açúcar para o Brasil é incontestável, ocupando uma área plantada de 5,6 milhões de hectares², (IBGE, 2005), Tabela 1.1, na produção de bio-combustível ou na geração de divisas pela exportação de açúcar; esta área é maior do que a de muitos países como pode ser visto na Tabela 1.1. Na safra brasileira 2005/2006 foram produzidos 26,6 milhões de toneladas de açúcar e 14,8 bilhões de litros de álcool-etanol, (UNICA, 2006). As exportações de açúcar da safra 2003/2004 representaram um acréscimo à balança comercial de 2,3 bilhões de dólares.

País	Área [km ²]
Portugal	92391
Área plantada de cana-de-açúcar no Brasil	56234
Costa Rica	51100
Dinamarca	43094
Holanda	41528
Jamaica	10991

Tab. 1.1: Comparação da área de alguns países com relação a área de cana-de-açúcar plantada no Brasil

A elevação dos preços no mercado externo e a forte demanda internacional por açúcar e álcool fizeram com que o Brasil arrecadasse US\$ 6,2 bilhões com as vendas externas desses produtos até outubro de 2006, ficando próximas a US\$ 8 bilhões no ano. As receitas com álcool atingiram US\$ 1,3 bilhão neste ano, 121% a mais do que em idêntico período de 2005.

A produção mundial de açúcar, segundo a USDA - FSA (*United States Department of Agriculture - Foreign Agricultural Services*), para o período de 2007/2008 está prevista para 163,3 milhões de toneladas,² 2 milhões acima do valor revisado para 2006/2007. O consumo está previsto para 149,4 milhões de toneladas, 0,51 milhões acima do ano anterior. As exportações foram projetadas em 50,8 milhões de toneladas, 2,1 milhões acima do período anterior e os estoques para o final do período foram estimados em 45 milhões, uma redução de 3,6 milhões de toneladas em relação ao período

²1 hectare equivale a 0,01 quilômetro quadrado

anterior, como mostra a Figura 1.1. O Brasil é responsável por aproximadamente 20% da produção mundial de açúcar da previsão de 2007/2008 e por cerca de 42% das exportações mundiais. Cerca de metade da produção de cana-de-açúcar brasileira é dedicada à produção do álcool.

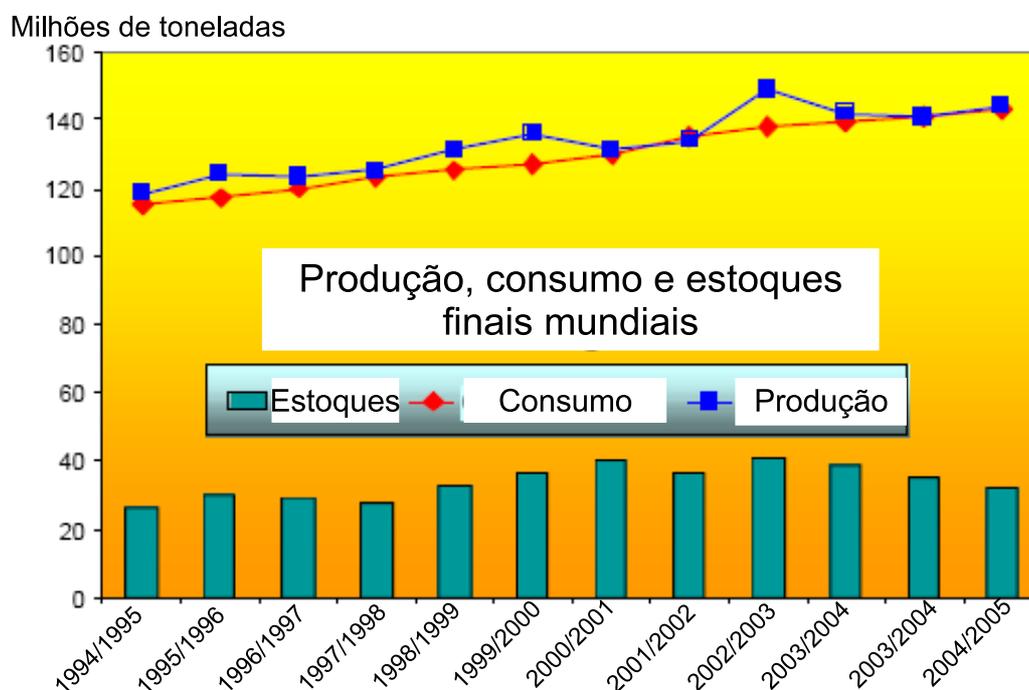


Fig. 1.1: Mercado mundial de açúcar do período de 1994/1995 até 2005/2006

Qualquer que seja a matéria-prima (cana-de-açúcar, beterraba, milho etc.) da qual se extraia açúcar e álcool, o setor sucroalcooleiro do Brasil é um dos mais competitivos do mundo. Graças ao elevado teor de fibra, que lhe confere independência em relação à energia externa, a cana-de-açúcar apresenta, em termos energéticos, claras vantagens competitivas na comparação com outras culturas. Segundo dados da FAO (*Food and Agriculture Organization*, órgão ligado as Nações Unidas), Tabela 1.2, observa-se em negrito os dados referentes à produtividade brasileira ao longo de 2000 até 2004, assim como os de outras nações. Comparando estes dados com os da Austrália, México e USA, também, em negrito, nota-se que apesar da grande produção brasileira, ainda há margem para aumento de sua produtividade. Em relação à produtividade de açúcar, os dados da Tabela 1.3, o Brasil ocupa uma posição inferior a Austrália. Entretanto, a produtividade agroindustrial teve nos últimos anos significativa evolução (Tabelas 1.2 e 1.3). Na região Centro-Sul, que responde por 85% da produção brasileira, a média de produtividade oscila entre 78 e 80 toneladas por hectare (a média nacional oscila entre 68 a 75 toneladas por hectares, (IBGE, 2005)), em ciclo de cinco cortes, Tabela 1.2. Em São Paulo, responsável por cerca de 60% da produção nacional e pelo desenvolvimento tecnológico, a

média está ao redor de 82 a 86 toneladas por hectare, também em cinco anos. A qualidade da matéria-prima, em São Paulo e no Centro-Sul, medida pela sacarose contida na planta, está entre 14 e 15,5% de pol³, o que equivale ao rendimento médio de 140 a 145 [kg] de açúcares totais por tonelada de cana, Tabela 1.3. Para o álcool, isso significa rendimento entre 80 e 85 litros por tonelada. Dessa forma pode ser verificado que o aumento da produtividade nacional deve-se em grande parte à evolução tecnológica, principalmente no estado de São Paulo. O aumento da capacidade técnica brasileira permite melhorar o aproveitamento dos recursos, como já acontece no Estado de São Paulo, com índices de produtividade compatíveis com os de Austrália e USA.

No Brasil, e entre os associados da União da Agroindústria Canavieira de São Paulo (UNICA), a melhoria tecnológica para os próximos cinco anos deverá concentrar-se nos seguintes aspectos:

1. Desenvolver novas variedades de cana-de-açúcar com altos índices de produtividade, cada vez mais adaptadas ao clima, tipo de solo e sistema de corte (manual ou mecanizado) e cada vez mais resistentes a pragas e com maior concentração de sacarose;
2. Utilizar insumos modernos, melhorar o sistema de transporte e mecanização da lavoura;
3. Melhorar a extração do caldo e diminuir as perdas no processo;
4. Melhorar os processos de planejamento e controle da produção;
5. Minimizar o uso de produtos químicos no processo industrial de fabricação de açúcar e álcool;
6. Inovar o processo de produção de açúcar e álcool;
7. Gerenciar a produção com o objetivo de aumentar a produção de açúcar e álcool;
8. Co-gerar energia elétrica (UNICA, 2006).

A modelagem nebulosa para predição dos processos de acumulação de biomassa e de açúcar da cana-de-açúcar com base em dados climáticos obtida neste trabalho está em convergência com algumas das metas do setor sucroalcooleiro. As contribuições que a modelagem proposta pode fornecer em relação as metas anteriores são:

No item 1 - ela pode ser utilizada para comparações de novas variedades. Um modelo tem como característica a capacidade de compactar informação sobre a dinâmica do processo simplificando o procedimento de comparação.

³polarização - método tradicionalmente empregado para determinar a quantidade de sacarose no caldo de cana-de-açúcar industrial. Esta técnica se baseia na propriedade que algumas substância químicas possuem de desviar o plano da luz polarizada em uma dada direção do plano da luz, (FILHO, 2003)

País	Elemento	Anos					Média
		2000	2001	2002	2003	2004	
Argentina	A	280	292	294	295	305	293
	P/A	66	65	65	65	64	65
	P	18400	19050	19250	19250	19500	19090
Austrália	A	419	411	417	423	415	417
	P/A	91	76	77	90	89	85
	P	38165	31228	32260	37968	36892	35303
Brasil	A	4846	4958	5100	5337	5455	5139
	P/A	68	70	71	73	75	71
	P	327705	345942	363721	389849	411010	367645
China	A	1189	1281	1421	1433	1316	1328
	P/A	58	61	65	64	71	64
	P	69299	77966	92203	92039	93200	84941
Cuba	A	1041	1007	1041	654	700	889
	P/A	35	32	33	35	34	34
	P	36400	32100	34700	22902	24000	30020
Índia	A	4220	4316	4412	4608	4100	4331
	P/A	71	69	67	61	60	66
	P	299230	295956	297208	281600	244800	283759
México	A	618	624	632	639	639	630
	P/A	71	76	72	71	71	72
	P	44100	47250	45635	45127	45127	45448
USA	A	418	416	414	402	389	408
	P/A	78	75	78	76	71	76
	P	32762	31377	32253	30715	27501	30922
África do Sul	A	322	322	325	325	305	320
	P/A	74	66	71	63	63	67
	P	23876	21157	23013	20419	19292	21551

Tab. 1.2: Dados da área cultivada com cana-de-açúcar (A, [000 × ha]) da produção (P, [1000 × ton]) e da produtividade por área (P/A, [ton/ha]) de alguns países. Fonte: FAOStat Database 2005

País	Parâmetro	Safras							
		90-91	91-92	92-93	93-94	94-95	95-96	96-97	97-98
Austrália	PA	3606	3192	4367	4412	5196	5049	5491	5650
	AR	14,3	15	14,9	13,8	14,9	13,5	13,8	13,8
	Prod.A	10,64	9,36	12,88	12,98	14,24	13,18	13,66	13,71
Brasil	PA	7900	9200	9800	9930	12500	13700	14650	14800
	AR	10,5	10,6	10,9	10,9	11,4	14,7	14,5	14,1
	Prod.A	6,75	6,72	6,53	6,62	7,14	8,78	9,54	9,43
China	PA	5243	6677	6650	5380	4900	5283	5685	5760
	AR	9,1	9,8	9,1	8,5	8,1	8,1	8,3	8,3
	Prod.A	5,2	5,74	5,34	4,94	4,73	5,15	5,44	5,43
Cuba	PA	7620	7030	4280	4000	3300	4450	4400	4500
	AR	11,3	11,3	9,1	8,7	8,5	9,8	9,8	9,9
	Prod.A	5,64	5,21	3,72	3,48	2,54	3,42	3,38	3,46
Índia	PA	13707	15249	12456	11660	16410	18225	14686	13650
	AR	10,1	10,2	10	10	10,3	9,9	9,9	10
	Prod.A	6,62	6,75	6,26	6,7	7,33	7,14	6,93	6,83
Indonésia	PA	2120	2250	2300	2480	2450	2090	2095	2150
	AR	7,6	8	7,2	7,5	8	7	7,3	7,4
	Prod.A	5,81	5,84	5,69	5,98	6,05	5,23	5,17	5,44
U.S.A.	PA	2767	3078	3068	3189	3073	3102	2880	2880
	AR	11,5	11,7	11,7	12	12,1	12	11,7	11,9
	Prod.A	9,41	8,95	8,69	8,83	8,77	8,86	8,65	8,37

Tab. 1.3: Comparação da produção de açúcar (PA,[1000 × ton]), índice de recuperação de açúcar (AR,%) e produtividade de açúcar (Prod.A,[ton/ha]) entre vários países Fonte:Indian Sugar, December 2003 Vol. 53, No.9

No item 4 - ela auxilia no planejamento e controle da produção fornecendo previsões confiáveis sobre a quantidade e a qualidade da matéria prima. Isto permite às indústrias traçar as estratégias de planejamento mais adequadas.

No item 7 - ela auxilia no gerenciamento da produção para uma maior produção de açúcar e álcool por permitir prever o ponto de acumulação de açúcar na cana-de-açúcar, o que afeta diretamente a produção de açúcar e álcool.

No item 8 - ela auxilia na atividade de co-geração de energia por permitir prever as quantidades de biomassa (fibra) disponíveis para alimentação das caldeiras.

As perspectivas tanto do governo, quanto da própria agroindústria, são de expansão da atividade com a inserção de novos mercados internacionais em busca de combustíveis mais limpos e, desta forma, espera-se que este trabalho possa de alguma forma ajudar a atingir este objetivo.

1.3 Hipótese Científica

Este trabalho considerou como base teórica um modelo para a simulação da acumulação de biomassa e açúcar denominado QCANE, apresentado em detalhes no Apêndice B. A escolha deste modelo se deve ao fato de ser considerado o mais preciso da atualidade, segundo O'Leary. Este modelo é composto por um amplo conjunto de equações (68 no total) que necessitam de 60 parâmetros para operar corretamente. Vários parâmetros foram ajustados baseados em experimentos e outros obtidos de estudos fisiológicos anteriores. A resposta de simulação deste modelo depende de uma quantidade elevada e complexa de iterações o que dificulta sua interpretação pelo usuário, o que também foi apontado por O'Leary em (O'LEARY, 2000).

O modelo simula duas variedades de cana-de-açúcar a Q141 e Q138. Para cada uma destas variedades, o modelo apresenta 9 parâmetros de ajuste. Todos parâmetros deste modelo foram obtidos a partir de diversos estudos que tomaram como base variedades cultivadas na Austrália e na África do Sul, que apresentam condições climáticas subtropicais essencialmente. Devido a este cenário não se pode considerar que este modelo possa ser ajustado às condições brasileiras apenas com o ajuste para as variedades e somente o ajuste das variedades já consumiria uma grande esforço. Dessa forma, consideramos que a obtenção, por procedimento de modelagem via identificação, resultaria, como proposto neste estudo, em um modelo mais simplificado e adequado às condições brasileiras.

O procedimento de identificação envolve diversas etapas. A etapa da escolha da representação matemática do modelo pode exigir atenção particular, ao buscar avaliar qual das representações po-

deria ser mais adequada. Dentre as representações matemáticas apresentadas na literatura para a representação do modelo, uma atenção especial deve ser dedicada aos sistemas nebulosos, que são aproximadores universais de funções. Além disto, esta representação matemática tem como uma de suas características a capacidade de associar valores lingüísticos às suas variáveis, o que permite uma interpretação da resposta da simulação diferentemente de outros sistemas, como redes neurais. Devido à estas características e aos resultados bem sucedidos apresentados na literatura, (SERRA, 2005), julga-se que esta representação poderá ser apropriada para obter modelo com número menor de parâmetros, que fornecerá ao usuário melhor compreensão dos resultados de sua simulação e com erros similares ou menores que o modelo QCANE.

Sinteticamente, este trabalho considera, pelo que foi apresentado anteriormente, como hipóteses científicas, tendo como referência o modelo QCANE:

- o procedimento de identificação a ser aplicado na modelagem dos processos de acumulação da cana-de-açúcar deve obter modelo com menor quantidade de parâmetros, mantendo ou reduzindo os níveis de erro.
- a representação matemática mais adequada dos processos de acumulação de biomassa e de açúcar da cana-de-açúcar deve permitir ao usuário melhor compreensão da resposta do modelo.

1.4 Objetivos do trabalho

O objetivo do trabalho é determinar um modelo matemático para prever um passo a frente a acumulação de biomassa e de açúcar da cana-de-açúcar, atendendo aos seguintes critérios:

1. confiabilidade: indicando precisão e exatidão nas predições realizadas pelo modelos.
2. simplicidade: o modelo deve utilizar o menor número de variáveis possível;
3. suscetibilidade a interpretação: permitindo que as respostas do modelo sejam compreendidas por pessoal não técnico;

O modelo proposto deve ser confiável, pois seus usuários, por exemplo, fazendeiros e usineiros, irão planejar suas atividades baseados nas suas predições. Dessa forma, os erros do modelo irão representar prejuízos econômicos para os seus usuários.

O modelo proposto deve ser simples para que a coleta dos dados necessários à sua simulação não tenha custos elevados. Um custo muito elevado para a simulação do modelo pode tornar inviável sua utilização comercial.

O modelo proposto deve ser suscetível à interpretação da sua resposta de simulação de forma a estabelecer uma relação de confiança psicológica com o seu usuário. Um usuário de qualquer modelo sente desconforto ao utilizar qualquer modelo sobre o qual não tenha compreensão. Além disso, a interpretação da resposta permite ao usuário identificar problemas ao gerar simulação com uma resposta fora das proporções do mundo real.

O modelo proposto deve ser obtido através de procedimento de identificação considerando fundamentos teóricos apresentados na literatura utilizada (Capítulo 4). Na revisão teórica deve ser dada especial atenção aos modelos nebulosos, Capítulo 3. No procedimento de identificação devem ser avaliados modelos lineares contínuos e discretos e finalmente os modelos nebulosos.

O modelo obtido no final do procedimento de identificação será trabalhado com base nos conhecimentos teóricos que contribuam para sua qualidade e utilidade.

Na modelagem devem ser utilizados os dados fornecidos pelo Professor De Li Liu, (LIU; BULL, 2001) para duas variedades de cana-de-açúcar cultivadas na Austrália: a Q138 e Q141. Ela deve utilizar o conjunto de dados de forma a obter um modelo com o índice de erros menor do que o do QCANE.

Os modelos obtidos no procedimento de identificação devem ser avaliados pelos critérios de validação estabelecidos na Seção 4.5.4, descartando os piores resultados e sua seleção também deve levar em conta os objetivos aqui estabelecidos.

Capítulo 2

Morfologia, Cultivo e Técnicas de Amostragem da Cana-de-açúcar

Neste capítulo descreve-se a morfologia e a anatomia da cana-de-açúcar, os processos de cultivo praticados e os procedimentos de amostragem utilizados para levantar dados da cultura de cana-de-açúcar fundamentais, para viabilizar a modelagem a ser realizada.

A função deste capítulo é fornecer uma visão global sobre a cana-de-açúcar e o sistema de produção desta planta. Procurou-se apresentar sempre que possível as notações técnicas da área agrícola relacionadas a essa cultura.

2.1 A cana-de-açúcar

A cana-de-açúcar é uma gramínea perene de clima tropical e semi-tropical. A cana-de-açúcar é cultivada, mundialmente, numa extensa área territorial, compreendida entre os paralelos 35° de latitudes Norte e Sul. As melhores produtividades são obtidas em regiões quentes. O clima ideal para atingir as maiores concentrações de sacarose é aquele que apresenta duas estações distintas, uma quente e úmida, para proporcionar a germinação, perfilhamento e desenvolvimento vegetativo (Figura 2.13), seguido de outra fria e seca, para promover a maturação e conseqüente acúmulo de sacarose nos colmos (Figura 2.13). A cana-de-açúcar madura pode ter de 3 a 6 metros de altura.

Solos profundos, pesados, bem estruturados, férteis, com boa capacidade de retenção hídrica são os ideais para a cana-de-açúcar que, devido à sua rusticidade, se desenvolve satisfatoriamente em solos arenosos e menos férteis, como os de cerrado. Solos rasos, isto é, com camada impermeável

superficial ou mal drenados, não devem ser indicados para a cana-de-açúcar.

A cana-de-açúcar é suscetível a mais de 60 doenças, mas nenhuma ocorre mundialmente. Variedades regionais são feitas para resistir a tipos específicos de doenças, e programas de melhoramento extensivos continuam a produzir novas variedades adaptadas a maioria das principais áreas produtoras do mundo.

A propagação da cana-de-açúcar na agricultura se faz assexuadamente, isto é, através de colmos sementes que, pela brotação de suas gemas, dão origem aos colmos primários e destes surgirão os secundários, depois os terciários, até a formação da touceira. O número de colmos industriais por touceira varia de 8 a 20 para as condições de cultivo brasileiras, dependendo da variedade e da fertilidade do solo.

Nas culturas semi-mecanizadas, que constituem a maioria das nossas explorações, para trabalhar com segurança, a declividade máxima deverá estar em torno de 12% ; declividades acima desse limite apresentam restrições às práticas mecânicas. Para culturas mecanizadas, com adoção de colheitadeiras automotrizes, o limite máximo de declividade cai para 8 a 10%.

2.1.1 Composição morfológica e anatômica

O sistema da cana-de-açúcar é desmembrado em duas regiões: a região aérea que compreende todas as partes da planta acima do solo e a parte subterrânea composta das partes da planta dentro do solo. Os componentes da região subterrânea são as raízes e o rizoma, e os da região aérea são os colmos, as folhas e as flores.

Vamos detalhar cada componente nas seções a seguir, com maior destaque para o colmo.

2.1.1.1 Folha

A folha da cana é constituída de duas partes: a bainha e a folha propriamente dita. A sua distribuição no colmo é alternada, sendo através da bainha que ela se fixa no nó.

A lâmina da folha pode ter um comprimento de 60-150 [cm] e uma largura de 2,5 a 10 [cm]. É através das folhas que a planta executa suas funções de transpiração, respiração e fotossíntese.

2.1.1.2 Flor

A inflorescência da cana-de-açúcar é em forma de panícula de tamanho e conformação que variam de cultivar para cultivar. Na Figura 2.1 podem ser vistas as inflorescências da cana-de-açúcar. A coloração é, em geral, ligeiramente canela-prateada e de forma piramidal. Essa inflorescência possui um tecido seco praticamente isento de caldo. Quando a inflorescência é moída junto com o colmo, esta absorve caldo, gerando maior quantidade de bagaço e elevando as perdas de açúcar nesse material. Esse problema se agrava ainda mais em cultivares que mesmo antes da emissão da panícula dá início ao processo de isoporização dos colmos.



Fig. 2.1: Foto da inflorescência da cana-de-açúcar. Fonte: (SILVA; CESAR, 2003)

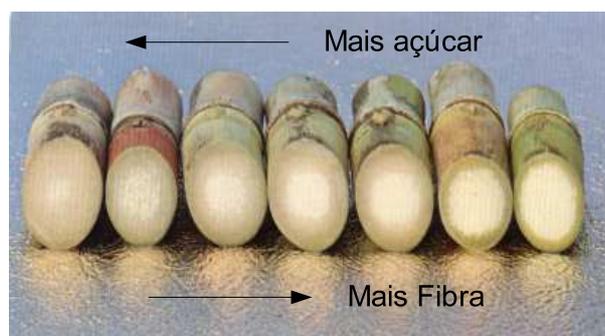


Fig. 2.2: Amostras de colmo demonstrando a evolução do processo de isoporização. Fonte: (SILVA; CESAR, 2003)

O processo de isoporização na cana-de-açúcar torna os colmos mais fibrosos e reduz o peso, resultando em menor produtividade por unidade de área de matéria seca e de açúcar. Este processo pode ser observado na Figura 2.2 que mostra a isoporização gradual do colmo.

O florescimento ocorre sob condições climáticas especiais. Quando as temperaturas mínimas noturnas são maiores que 18[°C] e as diurnas que 31[°C], por 15 a 20 dias no período de janeiro a março e seguidas por período escuro (11:30 e 12:00 h), o florescimento será induzido. Como consequência, cessa o crescimento do colmo pela conversão da gema apical em inflorescência, como pode ser observado pelas Figuras 2.4 e 2.3. Na maturação da flor, há um estímulo para a brotação das gemas laterais, devido a ausência da gema apical, o que resulta em consumo de açúcar. (SILVA; CESAR, 2003)



Fig. 2.3: Foto do colmo sem indução ao florescimento. Fonte: Nunes Junior, D. citado por (SILVA; CESAR; SILVA, 2003)



Fig. 2.4: Foto do colmo com indução ao florescimento. Fonte: Nunes Junior, D. citado por (SILVA; CESAR; SILVA, 2003)

A flor é hermafrodita. Por muito tempo pensou-se que a cana não produzisse sementes, mas em 1855, Soltwedel, conseguiu propagar a espécie *Saccharum spontaneum* por semente. Desde então, os geneticistas têm-se utilizado dessa característica para efetuar cruzamentos e seleção que visam a obtenção de novos cultivares que ofereçam melhores produtividades e resistência às doenças e pragas.

2.1.1.3 Colmo

O colmo representa a parte de maior interesse, é formado por gomos que são constituídos por nós, e entrenós, como mostra a Figura 2.8. O nó é a região onde se insere a bainha da folha e mais a zona radicular. A zona radicular inclui a gema e os pontos de protoraízes. O meristema intercalar é a região onde as células são capazes de, por divisão, produzir o alongamento do entrenó. O entrenó, também chamado de internódio, vai de um nó a outro. Quando a cana-de-açúcar está madura os colmos podem medir de 2,5 a 7,5 [cm] de diâmetro.

As funções do colmo são as seguintes:

- a** - suportar as folhas e as partes florais;
- b** - conduzir água e os nutrientes do solo, às folhas, onde os alimentos da planta são sintetizados;
- c** - translocar os alimentos manufaturados para outra parte da planta e,

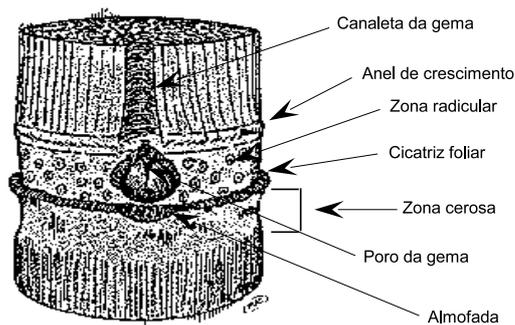


Fig. 2.5: Visão detalhada do nó. Fonte: Silva et al (2003)

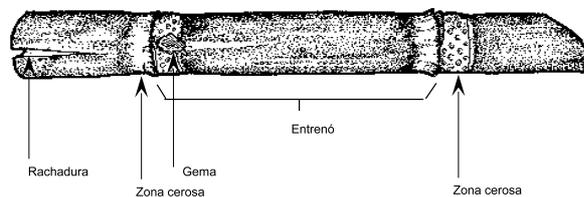


Fig. 2.6: Visão detalhada do colmo. Fonte: Silva et al (2003)

d - armazenar açúcar e outros materiais.

Quando se efetua um corte transversal no entrenó, como pode ser observado na Figura 2.7, verifica-se que a parte mais exterior, o cortéx, é formado por várias camadas de células lignificadas de paredes grossas. Essa capa dá resistência ao colmo, como também serve de proteção aos tecidos interiores, que são formados pelos feixes vasculares e pelo tecido fundamental ou parênquimatoso. A cor do colmo é dada por pigmentos, os quais estão nas células mais externas da epiderme. As cores dos colmos vão do quase branco para o amarelo para verde, roxo, vermelho, ou violeta. O tecido fundamental é o composto de células curtas e frouxas, as quais são praticamente iguais, em todos os sentidos, pois são células isodiamétricas.

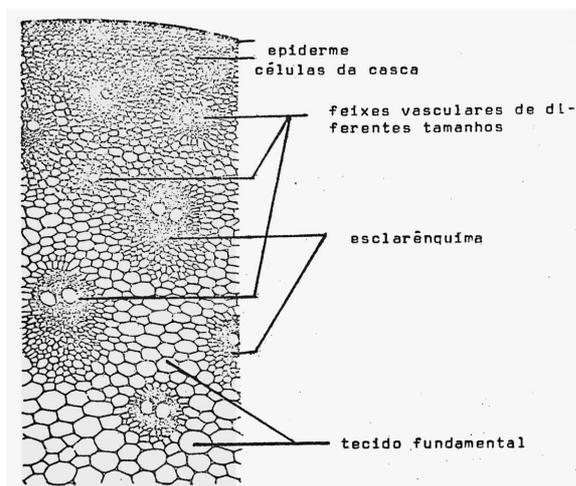


Fig. 2.7: Corte transversal e parcial de um internódio. Fonte: (CESAR; SILVA, 1993b)

Os feixes fibro-vasculares estão distribuídos através do tecido fundamental ou parênquimatoso. A

maior concentração desses vasos está na periferia do colmo, no centro estão os vasos de maior diâmetro. Esses vasos são os responsáveis pelo transporte dentro da cana. Os que transportam seiva bruta são chamados de xilema e os de seiva elaborada, floema. No internódio, os feixes fibro-vasculares são paralelos, porém, nos nós eles se ramificam, dirigindo-se para o colmo seguinte, para as folhas, para as gemas e para as raízes primordiais; sendo assim, esta região se apresenta com maior concentração de fibra, o que lhe confere maior dureza.

Os vasos vasculares estão rodeados pelo parênquima, que é formado por células de armazenamento. As células que estão próximas aos vasos são esclerenquimatosas, sendo que, aquelas que rodeiam o floema têm paredes mais grossas do que as do xilema.

As células do parênquima são as de maior valor para a indústria sucroalcooleira, pois, elas contêm a maior parte do caldo que contém o açúcar.

Desta forma distingue-se nos colmos três componentes: o tecido fundamental ou parenquimatoso, os feixes fibro-vasculares e os feixes fibrosos do córtex.

Do ponto de vista industrial, pode-se dizer que o colmo compõe-se de 25% de partes duras e de 75% de partes moles, em função da sua resistência mecânica. O teor de fibra das partes duras está em torno de 75% e a porcentagem do caldo corresponde a 25%, que equivale a 20% do caldo total por colmo. Nas partes moles encontram-se os 80% restantes do caldo total, as quais possuem 8% de fibra e 92% de caldo (as porcentagens mencionadas representam aproximações médias). A importância prática de separação do caldo dos tecidos do colmo está relacionada à tecnologia de moagem, que tem de lidar simultaneamente com as partes de maior e menor resistência mecânica. Disso, resulta que o caldo das partes moles é mais fácil de se extrair e apresenta maior concentração de açúcares, quando comparado ao caldo retido pelas partes duras. A Figura 2.8 mostra a distribuição dos açúcares ao longo do colmo da cana-de-açúcar dado pelo indicador Brix ¹.

A composição química e tecnológica do colmo da cana-de-açúcar, (SILVA; CESAR; SILVA, 2003) é:

- Fibra (9-16%)
 - Celulose
 - Pentosanas (xilana, arabana, etc.)

¹Brix é a medida da concentração de sólidos dissolvidos em uma solução. No caso de soluções que envolvem apenas uma substância, como é o caso de um xarope de sacarose, o brix será igual ao percentual de açúcar ou da substância em questão. Para xaropes de sacarose, é possível estabelecer inclusive tabelas de concentrações pré-definidas em função do brix. Além disso, dentro do conceito de brix, pode-se aferir densímetros com escalas baseadas na concentração de açúcar ou de qualquer outra substância, para soluções genuínas.

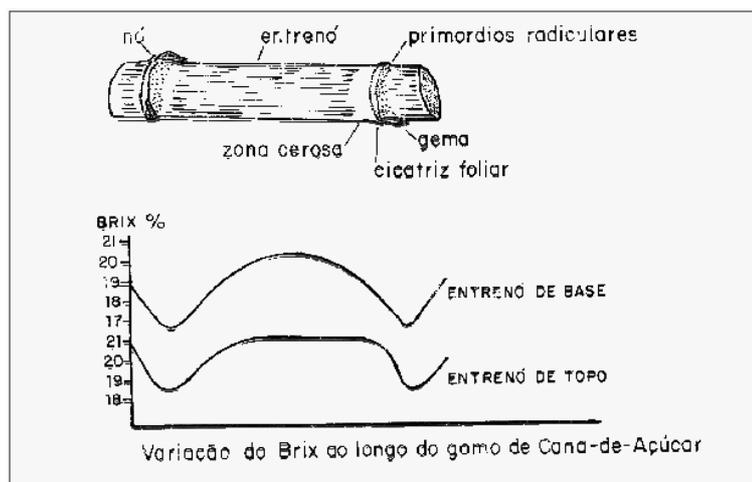


Fig. 2.8: Distribuição da acumulação de açúcar ao longo do colmo. Fonte: adaptados de (CESAR; SILVA, 1993b) e (SILVA; CESAR; SILVA, 2003)

- Lignina
- Caldo (84-91%)
 - água (75-82%)
 - sólidos solúveis (18-25%)
 - açúcares (15,5-24%)
 - * sacarose(14,5-24%)
 - * glicose(0,2-1%)
 - * frutose(0,0-0,5%)
 - sólidos solúveis
 - * orgânicos(0,8-1,8%)
 - * inorgânicos(0,2-0,7%)

2.1.1.4 Rizomas

Os rizomas se assemelham a colmos subterrâneos, com entrenós bastante reduzidos. Após a colheita da cana, as gemas dos rizomas brotam, dando origem a uma nova touceira.

2.1.1.5 Raízes

As raízes da cana-de-açúcar são classificadas como raízes do tolete (ou de fixação) e raízes dos perfilhos, como mostra a Figura 2.9. As raízes do tolete se originam nos primórdios radiculares do tolete de plantio, são delgadas e muito ramificadas. As raízes de perfilho primário originam-se a partir dos primórdios radiculares do perfilho sendo mais espessas, com coloração mais clara e menos ramificadas. A Figura 2.9 mostra a formação dos dois tipos de raízes.

No período ente o plantio e a formação de raízes do perfilho, as raízes do tolete promovem a absorção de água e nutrientes. A funcionalidade das raízes de tolete diminui na medida em que as raízes de perfilho são formadas. Dentre as funções das raízes, destacam-se a absorção de água e nutrientes, além da sustentação das plantas. As raízes de perfilho também apresentam funcionalidade por tempo limitado. Na medida que as raízes mais velhas morrem novas são formadas, assim, o sistema radicular está em contínua renovação. A cada novo perfilho se formam novas raízes de colmo. As raízes novas são de coloração clara e túrgidas, conforme as raízes tornam-se velhas, ficam escuras e flácidas (DILLEWIJN, 1952).

O primeiro período de crescimento vegetativo do ciclo de desenvolvimento da cana-de-açúcar (Seção 2.1.3) depende do sistema radicular proveniente do tolete de plantio ou das reservas do rizoma. Com o desenvolvimento, novas raízes são emitidas e substituem gradualmente as raízes que permanecem vivas por 90 a 120 dias, (FERNANDES, 1985). Um novo sistema radicular da cana-de-açúcar é formado concomitante à brotação da cana-de-açúcar, (CASAGRANDE, 1991).

As Figuras 2.10 e 2.11 apresentam a variação da estrutura e volume das raízes para cana-planta e cana-soca, Seção 2.1.3. As raízes da cana-de-açúcar são do tipo fasciculado e a sua maior densidade se apresenta nos primeiros 50 [cm] de profundidade do solo. Entretanto, já foi constatado, em (BALL-COELHO et al., 1992), raízes de cana a uma profundidade de 4 [m], mas para cana-soca.

Em condições de campo, as raízes das plantas apresentam grande variabilidade de desenvolvimento e isto se deve tanto às características ambientais quanto às morfológicas. Apesar da grande variabilidade, o desenvolvimento não é aleatório. Tal desenvolvimento pode ocorrer como consequência da variação na concentração de nutrientes na solução do solo, da temperatura ou do impedimento mecânico. Há ampla evidência de diferenças intervarietais no crescimento das raízes, (RUSSELL, 1977). Apesar das evidências do controle gênico em características de enraizamento, esse não tem sido o objetivos de programas de melhoramento genético, (COSTA, 2005). A Figura 2.12 apresenta variação do comportamento do perfil de raízes para um conjunto de duas variedades.

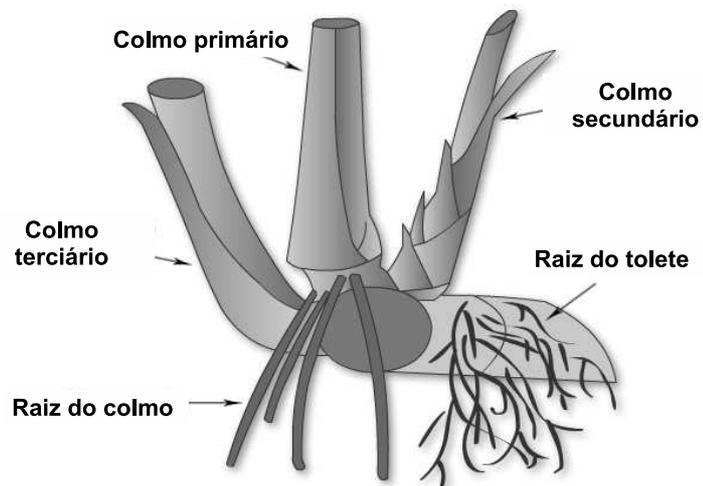


Fig. 2.9: Formação do sistema radicular a partir do colmo semente. Fonte: adaptado de King (1948), citado por (SILVA; CESAR; SILVA, 2003).

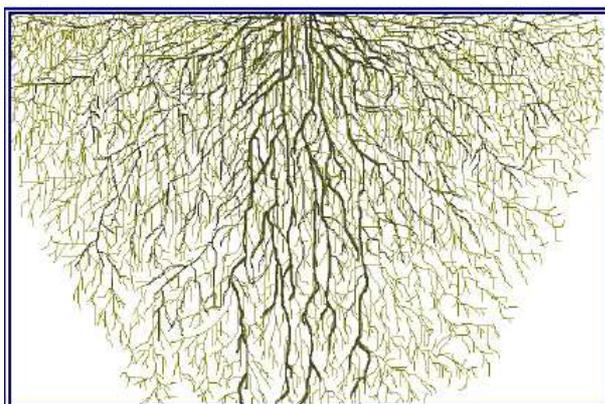


Fig. 2.10: Sistema radicular da cana-planta. Fonte: (COSTA et al., 2005)

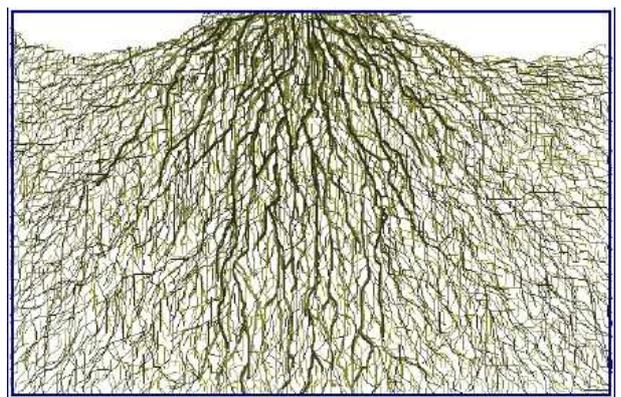


Fig. 2.11: Sistema radicular da cana-soca. Fonte: (COSTA et al., 2005)

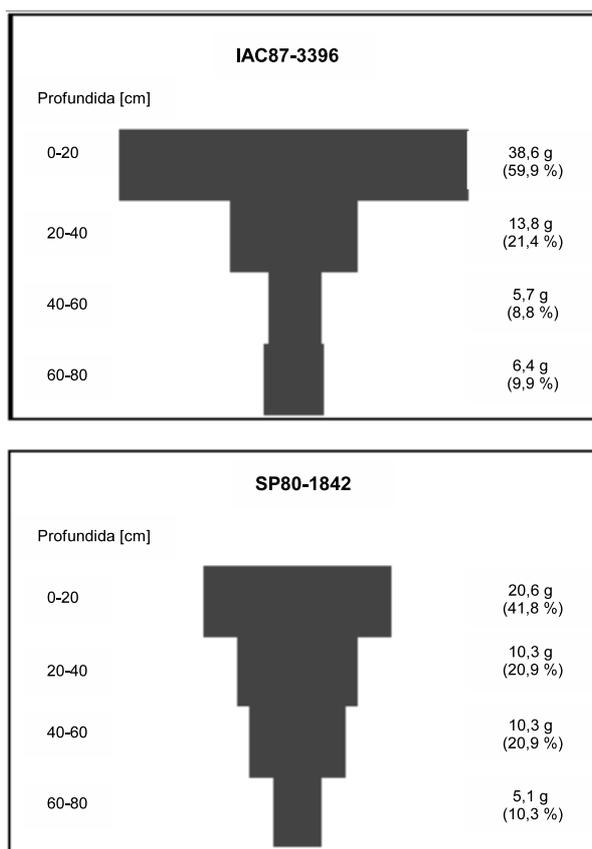


Fig. 2.12: Perfil da distribuição das raízes em quatro horizontes de dois cultivares. Fonte: (COSTA et al., 2005)

2.1.2 Fatores produtivos

Informações referentes ao comportamento futuro da cultura da cana-de-açúcar em termos de maturação (acúmulo de sacarose), podem definir o manejo de variedades e até a época ideal de colheita. A colheita de cana tem como diretriz a retirada do campo de cultivo de colmos com o maior conteúdo possível de sacarose, em maturação fisiológica completa ou bastante avançada. A capacidade de acumulação de açúcar nos colmos, em condições naturais, depende da associação de alguns fatores que induzirão a cana-de-açúcar a acumular sacarose nos colmos, (GHELLER, 1999). Individualmente, os fatores são:

- a) **Umidade do solo** , que proporciona a absorção dos nutrientes do solo, fundamentais para o desenvolvimento das plantas e em última instância produção de açúcar. A diminuição da umidade no solo, ou uma seca moderada, reduz o crescimento dos entrenós mais jovens e favorece o acúmulo de açúcares nos colmos;
- b) **Temperatura** , é o fator climático de maior importância para a maturação fisiológica da cana, porque além de afetar a absorção de água e nutrientes através do fluxo da transpiração, é um condicionante não controlável. Para que ocorram os maiores acúmulos de açúcar pela cana-de-açúcar são necessárias oscilações de temperatura associadas a períodos de seca moderada;
- c) **Luminosidade** , diretamente ligada ao processo de síntese fotossintética e cuja fonte de energia é a radiação solar. A redução na luminosidade determina menor armazenamento de açúcares e acumulação de amido nas folhas, portanto altera todo o processo de síntese, prejudicando a eficiência das plantas de cana-de-açúcar.
- d) **Nutrientes minerais** , influenciam a maturação da cana de acordo com a época em que estão disponíveis às plantas. Assim, as ofertas tardias de nitrogênio favorecem o desenvolvimento vegetativo ao invés do acúmulo de sacarose desejado para esta fase da cultura. O nitrogênio é crucial para a cana-de-açúcar no período de formação da cultura, ou seja, no estágio que se inicia imediatamente após a germinação e termina no fechamento do canavial, o que normalmente ocorre em torno de 3 a 5 meses. É nessa época que se dá a formação dos perfilhos e, para tanto, é necessária suficiente disponibilidade de nitrogênio no solo. Aproximadamente a partir do fechamento do canavial, a cultura entra num período de crescimento acelerado, desde que haja boas condições de temperatura e umidade. Se o nível de nitrogênio no solo e, conseqüentemente, na cultura, durante o estágio de formação, é baixo, o número de perfilhos que participará do crescimento acelerado também é baixo. Posteriormente, mesmo que haja formação de outros perfilhos, estes não terão condições de serem aproveitados para a moagem na época da colheita;

e) **Floração** , a transformação da gema apical de vegetativa para reprodutiva, em resposta aos fatores ambientais, interrompe a formação de novos entrenós, impede parcialmente o crescimento da planta, e proporciona condições para o acúmulo de sacarose.

2.1.3 Ciclo da cultura

A cana-de-açúcar é uma cultura semi-perene conseqüentemente tem por característica viver por mais de 3 anos, porém pode ser colhida, de acordo com seu padrão agroindustrial (precoce, média e tardia), entre 12 meses a 18 meses. Podemos verificar que a cana-de-açúcar possui um ciclo relacionado com o desenvolvimento até o período de colheita, denominado ciclo safra, ou safra. E outro relacionado ao seu período de plantio até a remoção da cultura do campo, denominado de período agrícola.

A cada colheita a cana-de-açúcar realizada a cana-de-açúcar deve reiniciar o seu ciclo de desenvolvimento fenológico. O ciclo que envolve cada colheita é definido como safra, ou ciclo safra. Ao longo de várias safras vai ocorrendo uma redução da produtividade, associada ao desgaste do solo e redução da capacidade de absorção de nutrientes pela raiz como pode ser observado na Seção 2.1.1. No estado de São Paulo, em média são utilizadas 5 safras.

O período da implementação do canavial, ou plantio da cana-de-açúcar, até o corte é denominado ciclo da “cana-planta”. Os ciclos safra seguintes são denominados ciclos da “cana-soca”. Usualmente, a duração do período de um ciclo de cana-planta é mais longo do que o ciclo da cana-soca, devido a necessidade de formação do sistema radicular e do rizoma no solo. A produtividade, em condições normais de cultivo, é maior no ciclo cana-planta e se reduz nos ciclos cana-soca subseqüentes. A dinâmica de desenvolvimento da cana-de-açúcar varia muito entre estes dois ciclos, devido ao rizoma estar estabelecido no campo.

Ciclo safra da cana-de-açúcar

A safra compreende o desenvolvimento da cana-de-açúcar, plantiou ou brota, até a colheita, ou corte. O desenvolvimento da cana-de-açúcar pode ser dividido em 4 estágios fenológicos, conforme pode ser observado na Figura 2.13. A descrição de cada estágios fenológicos é dada a seguir:

1. Estabelecimento da cultura: neste estágio é importante que a temperatura do solo esteja acima de 15 [°C] (temperatura base desta fase);

2. Vegetativo: para ocorrer o desenvolvimento da planta neste estágio é importante que a planta tenha disponibilidade hídrica, temperaturas médias do ar acima de 10 [°C] (temperatura base desta fase) e radiação solar;
3. Formação da produção: neste estágio o fator mais importante, como mencionado na Seção 2.1.2, é a temperatura, que idealmente seria de 21 [°C], ou mantendo-se acima de 15,5 [°C] e abaixo de 31 [°C].
4. Maturação: neste estágio a temperatura é importante e deve estar abaixo de 21[°C] e deve ocorrer uma ligeira deficiência hídrica.

Nos estágios 1 e 2 o crescimento é lento sendo que a planta acumula pouca massa seca, composta principalmente de fibra. No estágio 3 o crescimento é rápido e a planta acumula cerca de 70 a 80% da matéria seca total, sendo que nestes estágio ocorre uma transição de uma maior acumulação de fibra para uma maior acumulação de açúcar. Por fim, no estágio 4 o crescimento volta a ser lento acumulando cerca de 10% da matéria seca total, sendo que a maior parte da massa acumulada nesse período é açúcar.

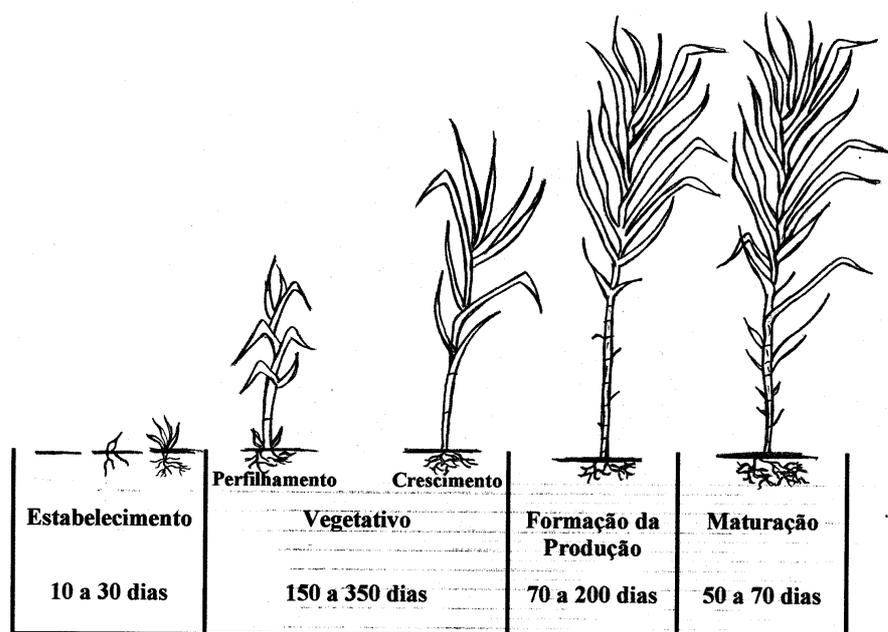


Fig. 2.13: Fases do desenvolvimento da cana de açúcar. Fonte: PLANALSUCAR, adaptador por (SILVA; CESAR; SILVA, 2003)

Após a cana ter atingido seu ponto de maturação, na Seção 2.2.8, ocorre a colheita da cana, como descrito na Seções 2.2.9, 2.2.10 e 2.2.11, caracterizando o final de um ciclo safra. A operação de colheita envolve a remoção da parte aérea da cana-de-açúcar, deixando o rizoma e as raízes no campo. A partir do rizoma irão brotar novos perfilhos, estágio 1, reiniciando o novo ciclo safra. Dessa forma para um plantio da cana-de-açúcar obtém-se vários ciclos agrícolas.

Ciclo agrícola da cana-de-açúcar

O ciclo agrícola se estende desde o plantio da cana-de-açúcar até a último ciclo safra, ou cana-soca, no qual ocorre manejo da terra (com a extração dos rizomas e raízes). O manejo indicado é, normalmente, a rotação de culturas por 1 ou 2 anos, porém atualmente outras técnicas de conservação do solos estão sendo difundidas. O número de ciclos safra é determinado pela queda gradativa da produtividade que depende das condições climáticas durante o período, das condições do solo e da variedade; a média na indústria sucroalcooleira é de 5 ciclos safras para se realizar a reforma. O fator que mais influencia a redução da produtividade ao longo dos ciclos agrícolas é a redução da funcionalidade das raízes ao longo do tempo, sendo que o comportamento da distribuição das raízes varia muito para cada variedade como foi visto na Figura 2.12, e argumentado em (COSTA, 2005). Os ciclos da cultura da cana-de-açúcar são ilustrados na Figura 2.14.

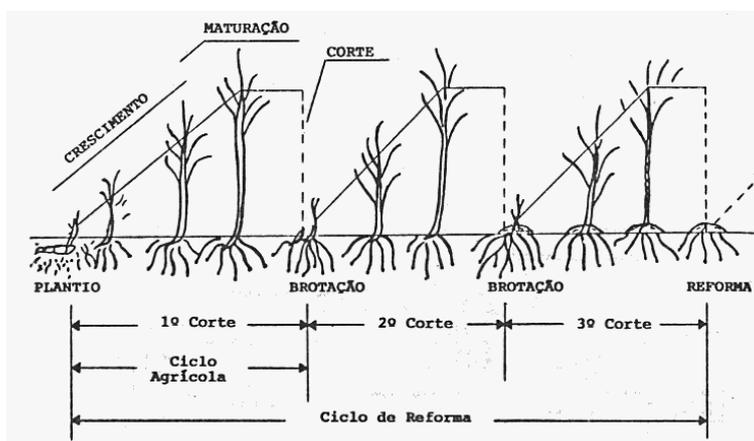


Fig. 2.14: Ilustração dos ciclos da cultura da cana-de-açúcar (implantação, regime e reforma). Fonte: Fernandes (s.d.), citado em (CASAGRANDE, 1991)

2.2 Operacional agrícola

O cultivo agroindustrial de cana-de-açúcar envolve diversas atividades que devem ocorrer em instantes diferentes de tempo. A seleção dos cultivares ocorre no início do ciclo agrícola, sendo uma etapa extremamente estratégica para a indústria, seguida do plantio. O preparo do solo, a calagem e adubação ocorrem no início de cada ciclo de safra e garantem condições adequadas para o desenvolvimento da cana-de-açúcar. Os tratos culturais são as atividades de manutenção dos canaviais em condições adequadas, visando principalmente o controle de pragas e doenças. O uso dos maturadores químicos e a determinação do ponto de colheita são atividades que ocorrem no final do ciclo safra buscando trabalhar o canavial para obter os melhores acúmulo de açúcar pela planta. Fora a colheita, o transporte, a pesagem, o descarregamento e a armazenagem são operações realizadas fora do campo mas são determinantes para manter a qualidade dos colmos. Cada atividade do ciclo agrícola é descrita a seguir.

2.2.1 Seleção dos Cultivares

Um dos pontos que merece especial atenção do agricultor é a escolha do cultivar para plantio. Isso não só pela sua importância econômica, como geradora de massa verde e riqueza em açúcar, mas também pelo seu processo dinâmico, pois anualmente surgem novas variedades, sempre com melhorias tecnológicas quando comparadas com aquelas que estão sendo cultivadas. Estas melhorias estão usualmente associadas a aumento da capacidade produtiva e resistência a pragas. Dentre as várias maneiras para classificação dos cultivares de cana, a mais prática é quanto à época da colheita. Quando apresentarem longo Período de Utilização Industrial (PUI), a indicação de alguns cultivares ocorrerá para mais de uma época permitindo dispor matéria prima para um período de tempo maior. O comportamento dos três grupos básicos: precoces, médias e tardias é mostrado na Figura 2.15.

Existem uma grande quantidade de variedades de cana-de-açúcar disponíveis, porém vamos destacar as variedades desenvolvidas pelos 3 principais centros de pesquisa brasileiros. A sigla SP representa as variedades desenvolvidas pelo CTC (Centro de Tecnologia Canavieira - antigo Cooperçúcar), a sigla RB significa República do Brasil e representa as variedades desenvolvidas pela UFSCar/CCA, a sigla IAC refere-se às variedades do Instituto Agrônomo de Campinas. As variedades de cana-de-açúcar mais cultivadas no Estado de São Paulo são as RBs.

Os cultivares mais indicados para São Paulo e Estados limítrofes, segundo (SILVA; CESAR; CHAVES, 2003), atualmente são:

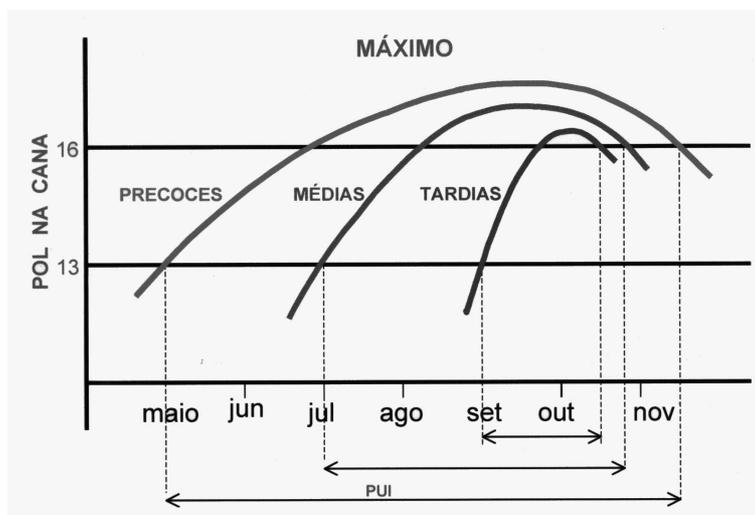


Fig. 2.15: Comportamento das três classes de cana-de-açúcar quanto ao PUI. Fonte: (SILVA; CESAR; CHAVES, 2003)

- para início de safra: SP80-3250, SP80-1842, RB76-5418, RB83-5486, RB85-5453 e RB83-5054
- para meio de safra: SP79-1011, SP80-1816, RB85-5113 e RB85-5536
- para fim de safra: SP79-1011, SP79-2313, SP79-6192, RB72-454, RB78-5148, RB80-6043 e RB84-5257

Os cultivares SP79-2313, RB72-454, RB78-5148, RB80-6043 e RB83-5486 caracterizam-se pela baixa exigência em fertilidade de solo.

2.2.2 Preparo do solo

Tendo a cana-de-açúcar um sistema radicular profundo, um ciclo vegetativo econômico de quatro anos e meio ou mais e uma intensa mecanização que se processa durante esse longo tempo de permanência da cultura no terreno, o preparo do solo deve ser profundo e esmerado. Convém salientar que as unidades sucroalcooleiras não seguem uma linha uniforme de preparo do solo, tendo cada uma seu sistema próprio, variação essa que ocorre em função do tipo de solo predominante e da disponibilidade de máquinas e implementos.

No preparo do solo, considera-se duas situações distintas:

- a cana vai ser implantada pela primeira vez;
- o terreno já se encontra ocupado com cana.

No primeiro caso, faz-se uma aração profunda, com antecedência do plantio, visando à destruição, incorporação e decomposição dos restos culturais existentes, seguida de gradagem, com o objetivo de completar a primeira operação. Em solos argilosos é normal a existência de uma camada impermeável, a qual pode ser detectada através de trincheiras abertas no perfil do solo, ou pelo penetrômetro.

Constatada a compactação do solo, seu rompimento se faz através de subsolagem, que só é aconselhada quando a camada adensada se localizar a uma profundidade entre 20 e 50 [cm] da superfície e com solo seco.

Nas vésperas do plantio, faz-se nova gradagem, visando ao acabamento do preparo do terreno e à eliminação de ervas daninhas.

Na segunda situação, onde a cultura da cana já se encontra instalada, o primeiro passo é a destruição da soqueira, que deve ser realizada logo após a colheita. Essa operação pode ser feita por meio de aração rasa (15-20 [cm]) nas linhas de cana, seguidas de gradagem ou através de gradagem pesada, enxada rotativa ou uso de herbicida.

Se confirmada a compactação do solo, a subsolagem torna-se necessária. Nas vésperas do plantio procede-se a uma aração profunda (25-30 [cm]), por meio de arado ou grade pesada. Seguem-se as gradagens necessárias, visando manter o terreno destorreado e apto ao plantio.

Devido à facilidade de transporte, à menor regulagem e ao maior rendimento operacional, há uma tendência das grades pesadas substituírem o arado, (ANDRADE; CARDOSO, 2004).

2.2.3 Calagem

A necessidade de aplicação de calcário é determinada pela análise química do solo, devendo ser utilizada para elevar a saturação por bases a 60%. Se o teor de magnésio for baixo, dar preferência ao calcário dolomítico.

O calcário deve ser aplicado o mais uniforme possível sobre o solo. A época mais indicada para aplicação do calcário vai desde o último corte da cana, durante a reforma do canavial, até antes da última gradagem de preparo do terreno. Dentro desse período, quanto mais cedo executada maior será sua eficiência, (CANTARELLA; QUAGGIO; FURLANI, 1996).

Existem duas épocas de plantio para a região Centro-Sul do Brasil: setembro-outubro e janeiro a março. Setembro-outubro não é a época mais recomendada, sendo indicada em casos de necessidade urgente de matéria prima, quer por recente instalação ou ampliação do setor industrial, quer por comprometimento de safra devido à ocorrência de adversidade climática. Plantios efetuados nessa época propiciam menor produtividade agrícola e expõem a lavoura à maior incidência de ervas daninhas, pragas, assoreamento dos sulcos e retardam a próxima colheita.

2.2.4 Adubação

Para a cana de açúcar há a necessidade de considerar duas situações distintas, adubação para cana-planta e para soqueiras (cana-soca), sendo que, em ambas, a quantificação será determinada pela análise do solo, seguindo as recomendações (CANTARELLA; QUAGGIO; FURLANI, 1996).

Para cana-planta, o fertilizante deverá ser aplicado no fundo do sulco de plantio, após a sua abertura, ou por meio de adubadeiras conjugadas aos sulcadores em operação dupla.

Na Tabela 2.1 a seguir são indicadas as quantidades de nitrogênio, fósforo e potássio a serem aplicadas com base na análise do solo e de acordo com a produtividade esperada, (CANTARELLA; QUAGGIO; FURLANI, 1996).

Produtividade esperada [ton/ha]	Nitrogênio N,[kg/ha]	P resina, [mg/dm ³]			
		0-6	7-15	16-40	>40
		P ₂ O ₅ , [kg/ha]			
<100	30	180	100	60	40
100 - 150	30	180	120	80	60
>150	30	*	140	100	80

Produtividade esperada [ton/ha]	K+ trocável, [mmol/dm ³]				
	0-0,7	0,8-1,5	1,6-3,0	3,1-6,0	>6,0
	K ₂ O ₃ , [kg/ha]				
<100	100	80	40	40	0
100 - 150	150	120	80	60	0
>150	200	160	120	80	0

Tab. 2.1: Tabela com o critério de adubação da cana-planta

Aplicar mais 30 a 60 [kg/ha] de N, em cobertura, durante o mês de abril; em solo arenoso dividir a cobertura, aplicando metade do N em abril e a outra metade em setembro - outubro.

Adubações pesadas de K₂O devem ser parceladas, colocando no sulco de plantio até 100 [kg/ha]

e o restante juntamente com o N em cobertura, durante o mês de abril.

Para soqueira, a adubação deve ser feita durante os primeiros tratos culturais, em ambos os lados da linha de cana; quando aplicada superficialmente, deve ser bem misturada com a terra ou alocada até a profundidade de 15 [cm].

Na adubação mineral da cana-soca aplicar as indicações da Tabela 2.2, segundo (CANTARELLA; QUAGGIO; FURLANI, 1996), a seguir, observando os resultados da análise de solo e de acordo com a produtividade esperada.

Produtividade esperada [ton/ha]	Nitrogênio N, [kg/ha]	P resina, [mg/dm ³]		K+ trocável, [mmol/dm ³]		
		<15	>15	0-1,5	1,5-3,0	>3,0
		P ₂ O ₅ , [kg/ha]		K ₂ O ₃ , [kg/ha]		
<60	60	30	0	90	60	30
60 - 80	80	30	0	110	80	50
80 - 100	100	30	0	130	100	70
>100	120	30	0	150	120	90

Tab. 2.2: Tabela com o critério de adubação da cana-soca

Aplicar os adubos ao lado das linhas de cana, superficialmente e misturado ao solo, no máximo a 10 [cm] de profundidade.

Se for constatada deficiência de cobre ou de zinco, de acordo com a análise do solo, aplicar os nutrientes com a adubação de plantio, nas quantidades indicadas na Tabela 2.3, segundo (CANTARELLA; QUAGGIO; FURLANI, 1996), seguir:

Zinco no solo [mg/d ³]	Zn [kg/ha]	Cobre no solo [mg/dm ³]	Cu [kg/ha]
0-0,5	5	0-0,2	4
>0,5	0	>0,2	0

Tab. 2.3: Tabela para corrigir deficiência de Cobre e Zinco no plantio

Adubação com resíduos da agroindústria

Atualmente há uma tendência em substituir a adubação química da cana do ciclo-soca pela aplicação de vinhaça, cuja quantidade por hectare depende da composição química da vinhaça e da necessidade da lavoura em nutrientes.

As aplicações com vinhaça no campo utilizam os sistemas básicos de irrigação que são: por infiltração, por veículos e por aspersão, sendo que para cada sistema existe a necessidade de algumas modificações para o uso com vinhaça.

A torta de filtro (úmida) pode ser aplicada em área total (80-100 [ton/ha]), em pré-plantio, no sulco de plantio (15-30 [ton/ha]) ou nas entrelinhas (40-50 [ton/ha]). Metade do fósforo aí contido pode ser deduzido da adubação fosfatada recomendada.

2.2.5 Plantio

O plantio da cana de “ano e meio” é feito de janeiro a março, sendo recomendado tecnicamente. Além de não apresentar os inconvenientes da outra época, permite um melhor aproveitamento do terreno com plantio de outras culturas. Em regiões quentes, como o oeste do Estado de São Paulo, essa época pode ser estendida para os meses subseqüentes, desde que haja umidade suficiente.

O espaçamento entre os sulcos de plantio é de 1,40 [m], sua profundidade de 20 a 25 [cm] e a largura é proporcionada pela abertura das asas do sulcador num ângulo de 45°, com pequenas variações para mais ou para menos, dependendo da textura do solo. O espaçamento entre as linhas de plantio, recebe o nome de *rua*, no jargão agrícola.

Os colmos com idade de 10 a 12 meses são colocados no fundo do sulco, sempre cruzando a ponta do colmo anterior com o pé do seguinte e picados, com podão, em toletes de aproximadamente três gemas. A Figura 2.16 mostra o plantio de cana-de-açúcar em uma área comercial, na qual podem ser observadas as linhas com os colmos utilizados como sementes.

A densidade do plantio é em torno de 12 gemas por metro linear de sulco, que, dependendo da variedade e do seu desenvolvimento vegetativo, corresponde a um gasto de 7-10 [ton/ha].

Os toletes são cobertos com uma camada de terra de 7 [cm], que deve ser ligeiramente compactada. Dependendo do tipo de solo e das condições climáticas reinantes, pode haver uma variação na espessura dessa camada.

2.2.6 Tratos culturais

Os tratos culturais na cana-planta limitam-se apenas ao controle das ervas daninhas, adubação em cobertura e adoção de uma vigilância fitossanitária para controlar a incidência do carvão. A adubação em cobertura já foi vista na Seção 2.2.4 e a vigilância fitossanitária será comentada em doenças e seu controle.

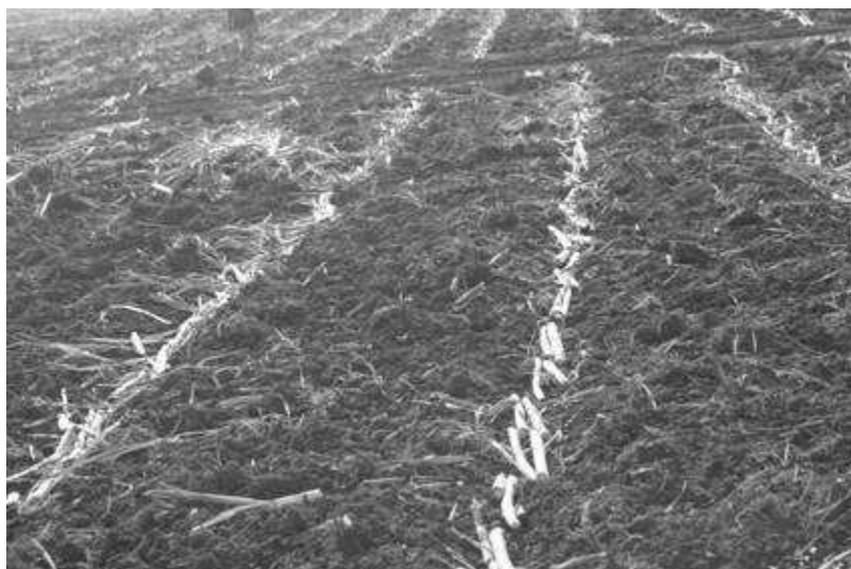


Fig. 2.16: Plantio de cana-de-açúcar

O período crítico da cultura, devido à concorrência de ervas daninhas, vai da emergência aos 90 dias de idade. O controle mais eficiente às ervas, nesse período, é o químico, através da aplicação de herbicidas em pré-emergência, logo após o plantio e em área total. Dependendo das condições de aplicação, infestação da gleba e eficiência do praguicida, há necessidade de uma ou mais carpas mecânicas e catação manual até o fechamento da lavoura. A partir daí a infestação de ervas é praticamente nula.

Outro método é a combinação de carpas mecânicas e manuais. Instalada a cultura, após o surgimento do mato, procede-se seu controle mecanicamente, com o emprego de cultivadores de disco ou de enxadas junto às entrelinhas, sendo complementado com carpa manual nas linhas de plantio, evitando, assim, o assoreamento do sulco. Essa operação é repetida quantas vezes forem necessárias; normalmente três controles são suficientes.

A cana do ciclo cana-soca, ou soqueira, exige enleiramento da “palhada²”, permeabilização³ do solo, controle das ervas daninhas, adubação e vigilância sanitária. Após a colheita da cana, ficam no terreno restos de palha, folhas e pontas, cuja permanência prejudica a nova brotação e dificulta os tratos culturais. A maneira de eliminar esse material (palhada) seria a queima pelo fogo, porém essa prática não é indicada devido aos inconvenientes que ela acarreta, como falhas na brotação futura, perdas de umidade e matéria orgânica do solo e quebra do equilíbrio biológico.

²Palhada é uma composição dos restos culturais após o corte sem queima. Os elementos que compõem a palhada são folhas secas, folhas verdes e ponteiros

³A permeabilização é feita através de um gradiente leve para facilitar a absorção de água e nutrientes pelo solo

O enleiramento consiste no amontoamento em uma rua do palhada deixando duas, quatro ou seis ruas livres, dependendo da quantidade desse material. É realizado por enleiradeira tipo Lely, implemento leve com pouca exigência de potência.

Após a retirada da cana, o solo fica superficialmente compactado e impermeável à penetração de água, ar e fertilizantes. Visando à permeabilização do solo e controle das ervas daninhas iniciais, diversos métodos e implementos podem ser usados.

Existem no mercado implementos dotados de hastes semi-subsoladoras ou escarificadoras, adubadeiras e cultivadores que realizam simultaneamente operações de escarificação, adubação, cultivo e preparo do terreno para receber a carpa química, exigindo, para tanto, tratores de aproximadamente 90 HPs. Normalmente, essa prática, conhecida como operação tríplice, seguida do cultivo químico, é suficiente para manter a soqueira limpa.

Além desse sistema, o emprego de cultivadores ou enxadas rotativas com tração animal ou mecânica apresenta bons resultados. Devido ao rápido crescimento das soqueiras, o número de carpas exigidos é menor que o da cana planta.

2.2.7 Maturadores Químicos

Maturadores químicos são produtos químicos que tem a propriedade de paralisar o desenvolvimento da cana induzindo a translocação e o armazenamento dos açúcares. Os maturadores químicos vêm sendo utilizados como um instrumento auxiliar no planejamento da colheita e no manejo varietal. Muitos compostos apresentam, ainda, ação dessecante, favorecendo a queima e diminuindo, portanto, as impurezas vegetais. Há uma ação inibidora do florescimento, em alguns casos, viabilizando a utilização de variedades com este comportamento, (CESAR; SILVA, 1993a).

Os produtos tradicionalmente usados como maturadores da cana-de-açúcar pertencem ao grupo dos inibidores de crescimento ou ao grupo de compostos com ação herbicida, como a hidrazida maleica, chlormequat (cloreto de 2-cloroetiltrimetilamônio), mefluidide, 2,4-D (ácido 2, 4-diclofenoxiacético), dalapon, pentaclorofenol, monuron, diuron, TBA (ácido 2, 3, 6-triclorobenzóico), N bisfosfometilglicina, glifosato (fosfometilglicina), ethephon (ácido 2-cloro-etil fosfônico), fluazifop-butil, sulfometuron-metil e, mais recentemente, o trinexapac-etil, (RODRIGUES, 1995). Estudos sobre a época de aplicação e dosagens vêm sendo conduzidos com o objetivo de aperfeiçoar a metodologia de manejo desses produtos, que podem representar acréscimos superiores a 10% no teor de sacarose (CAPUTO, 2006).

2.2.8 Ponto de colheita

O ponto de maturação pode ser determinado pelo refratômetro de campo e complementado pela análise de laboratório. Com a adoção do sistema de pagamento pelo teor de sacarose, há necessidade de o produtor conciliar alta produtividade agrícola com elevado teor de sacarose na época da colheita.

O refratômetro fornece diretamente a porcentagem de sólidos solúveis do caldo (Brix). O Brix esta estreitamente correlacionado ao teor de sacarose da cana.

A maturação ocorre do colmo da base, mais próximo ao solo, para o colmo do ápice, mais próximo as folhas verdes. A cana imatura apresenta valores bastante distintos nestas posições. Durante o processo de maturação estes valores ficam mais próximos. Assim, o critério mais racional de estimar a maturação pelo refratômetro de campo é pelo índice de maturação (IM), que fornece o quociente da relação.

$$IM = \frac{\text{Brix colmo superior}}{\text{Brix colmo inferior}} \quad (2.1)$$

Admitem-se para a cana-de-açúcar, os seguintes estágios de maturação:

IM	Estágio de maturação
< 0,6	cana verde
0,6 - 0,85	cana em maturação
0,85 - 1,0	cana madura
> 1,0	cana em declínio de maturação

Tab. 2.4: Critério para o índice de maturação e colheita da cana-de-açúcar.

As determinações tecnológicas em laboratório (Brix, Pol⁴, açúcares redutores⁵ e pureza⁶) fornecem dados mais precisos da maturação, sendo, a rigor, uma confirmação do refratômetro de campo, (RODRIGUES, 1995) e (CESAR; SILVA, 1993a).

⁴Porcentagem, em peso, de sacarose aparente ou a soma algébrica dos desvios provocados no plano de polarização pelas substâncias opticamente ativas (açúcares), contidos nos produtos da usina (caldo), por leitura direta. Na prática, quantidade de sacarose encontrada em 100 [g] da solução. Assim, quando uma solução tem Pol de 14, quer dizer que em 100 [g] desta solução temos 14 [g] de sacarose. Determinada em sacarímetro.

⁵Todos os açúcares (monossacarídeos) que têm a propriedade de reduzir o cobre das soluções cupro-alcalinas (licor de Fehling). No caldo da cana, são a glicose e a levulose. Além da quantidade normalmente existente na cana, se formam na fabricação do açúcar, pelo desdobramento da molécula de sacarose, sob a ação de ácidos diluídos e calor.

⁶Relação percentual entre o Pol e o Brix determinando a quantidade percentual de açúcares no caldo

2.2.9 Colheita

No Brasil a colheita inicia-se em maio e em algumas unidades sucroalcooleiras em abril, prolongando-se até novembro, período em que a planta atinge o ponto de maturação. Sempre que possível, deve-se antecipar o fim da safra, por ser um período bastante chuvoso, que dificulta o transporte de matéria prima e faz cair o rendimento industrial.

2.2.10 Operação de corte

O corte pode ser manual, com um rendimento médio de 5 a 6 [ton(homem)/dia], ou mecânico, através de colheitadeiras. Existem basicamente dois tipos: colheitadeira para cana inteira, com rendimento operacional médio em condições normais de 20 [ton/h], e colheitadeiras para cana picada (automotrizes), com rendimento de 15 a 20 [ton/h].

Após o corte, a cana-de-açúcar deve ser transportada o mais rápido possível ao setor industrial, por meio de caminhão ou carreta tracionada por trator.

2.2.11 Transporte, pesagem, descarregamento e estocagem

O transporte da cana até a usina, no Brasil, é predominantemente do tipo rodoviário, com o emprego de caminhões que carregam cana inteira (colheita manual) ou picada em toletes de 20 a 25 [cm] (colheita mecânica). Os caminhões são pesados antes e após o descarregamento, obtendo-se o peso real da cana pela diferença entre as duas medidas. Algumas cargas são aleatoriamente selecionadas e amostradas, para posterior determinação, em laboratório, do teor de sacarose na matéria-prima. O objetivo da pesagem é possibilitar o controle agrícola, o pagamento do transporte, o controle de moagem, o cálculo do rendimento industrial e, juntamente com o teor de sacarose na cana, efetuar o pagamento da mesma.

A cana estocada em pátio é normalmente descarregada nas mesas alimentadoras por tratores com rastelos, enquanto a cana estocada no barracão é descarregada nas mesas, através de pontes rolantes, equipadas com garras hidráulicas. Prevendo-se eventuais falhas no sistema de transporte e a interrupção do mesmo durante o período da noite, procura-se manter certa quantidade de cana em estoque em barracões cobertos ou em pátios abertos.

A cana estocada deve ser renovada em curtos espaços de tempo, visando à redução de perdas de açúcar por decomposição bacteriológica. A cana picada, que não deve ser estocada, é descarregada

diretamente nas esteiras. O descarregamento direto pode ser feito com o uso de pontes rolantes equipadas com garras hidráulicas, guindastes do tipo *hillo* e, no caso de cana picada, através de um tombador hidráulico para basculamento lateral dos caminhões.

2.3 Medidas e Processos de Amostragem

Os conceitos básicos relativos as medidas e ao procedimento de amostragem para a cultura da cana-de-açúcar são tratados nesta seção. As dificuldades na obtenção de dados da cultura de cana-de-açúcar são abordadas.

2.3.1 Amostragem de colmos

A amostra de colmos de cana-de-açúcar para qualquer ensaio, é a parte da experimentação mais preponderante para os resultados obtidos em laboratório. Uma amostra representativa de uma parcela de colmo, será aquela que exprime o máximo da realidade em qualidade ou riqueza de açúcar.

Quando desejamos determinar o ponto de maturação de uma parcela de cana-de-açúcar, a amostra deve ser a mais representativa possível do talhão ou parcela de cana-de-açúcar, para evitar depois os resultados errados de laboratório. Os agrônomos encarregados da responsabilidade da matéria-prima, entrando na usina ou na maturação da cana-de-açúcar, devem pensar mais em açúcar do que em cana-de-açúcar. Em várias regiões açucareiras encontramos na mesma touceira, filiações de diferentes idades: 14 meses, 12 meses e 8 meses.

Neste caso, a riqueza de açúcar nos colmos de diferentes idades não será a mesma, principalmente no início da safra. Essa irregularidade da idade das canas de uma mesma touceira, prejudicará também o ponto de maturação, porque todas os colmos não estarão maduros no mesmo período da safra. Quando esses colmos forem cortados o Pol, o Brix e a Pureza serão menores, os açúcares redutores serão maiores, o rendimento será mais baixo.

A filiação ou perfiliação da cana-de-açúcar em uma touceira é um importante problema da agronomia açucareira para maiores lucros nas usinas açucareiras. Para evitar dúvidas quanto a exatidão dos resultados da análise dos colmos, será apresentado um método de colheita de amostras de colmos em parcelas.

2.3.1.1 Amostragem racional das parcelas para determinar o ponto de maturidade

As amostras dos colmos que devem ser escolhidos nas parcelas para determinar o ponto de maturação ou açúcar provável ou também açúcar hectare é um ponto de suma importância da experimentação, porque a amostra é a base da determinação correta da maturação da cana-de-açúcar.

Se a amostra não é bem representativa da parcela, do ponto de vista da idade dos perfilhos, todos os resultados do laboratório não serão uma representação próxima à realidade.

2.3.1.2 Parcelamento dos Campos de cana-de-açúcar

Cada usina tem um levantamento particular dos campos de cana-de-açúcar, geralmente os canaviais são divididos em fazendas de 100 a 500 [ha], cada fazenda é dividida em talhões de características nem sempre uniformes.

Devemos tomar uma unidade para colher amostras, essa unidade será um hectare ou múltiplos, conforme mostra a Figura 2.17. Elimina-se 10 [m] sobre cada lateral do quadrado como borda. Restando 80 [m] úteis para poder coletar a amostra de colmos.

Determina-se e marca-se 9 lugares de 10 [m] sobre uma linha de cana-de-açúcar. Por exemplo: lugares A, B, C, D, E, F, G, H e I. Deve-se indicar por meio de sinais esses mesmo lugares para escolher a cada 10 dias amostras no mesmo lugar.

As amostras devem ser composta de 30 canas cortadas rente ao solo e até o ponto da primeira folha verde presa ao colmo, representativa de cada um dos lotes A, B, C, D e E da seguinte maneira:

- 10 canas do perfilhamento primário (mais compridas);
- 10 canas do perfilhamento secundário (comprimento intermediário);
- 10 canas do perfilhamento terciário (mais curtas).

Então o total de amostras de uma parcela resulta na coleta de 270 canas; considerando um peso aproximado de 3 [kg] para cada cana, temos que o peso total da coleta deve ter por volta de 810 [kg]. Este material será reamostrado para evitar o transporte de uma quantidade elevada de material para o laboratório. O novo lote terá 30 canas e será sub-amostrado da seguinte forma:

- As 30 canas repartidas no chão em 3 sub-amostras de 10 canas.

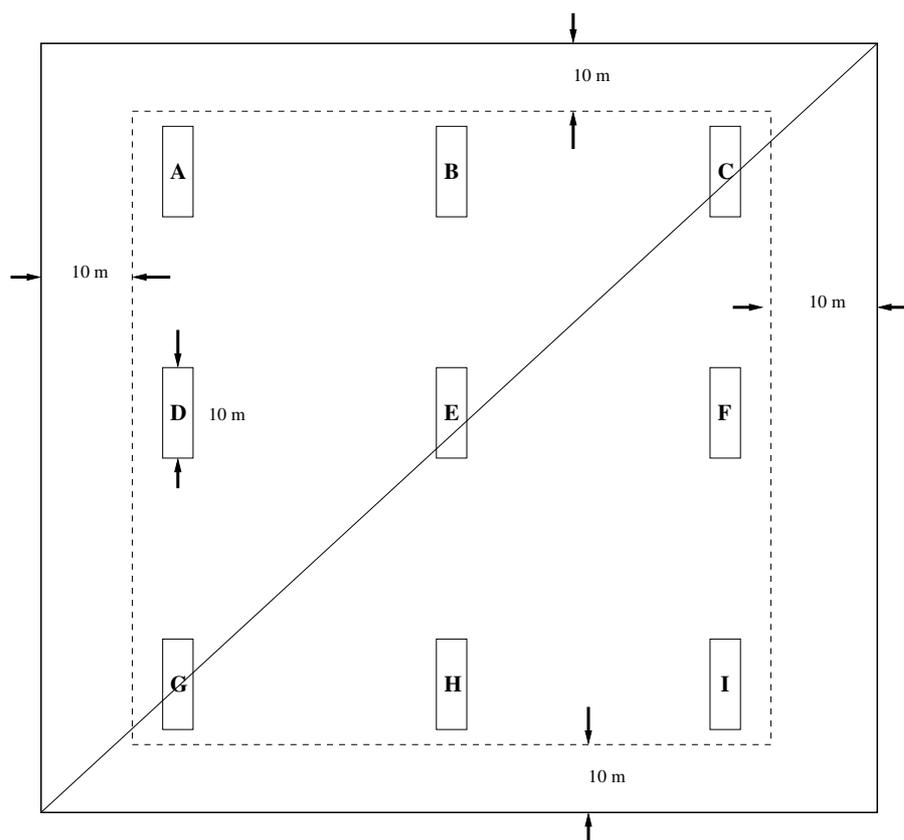


Fig. 2.17: Definição esquemática dos pontos de amostragem em campo de cultivo de cana-de-açúcar

1. 10 canas do perfilhamento primário (mais compridas);
 2. 10 canas do perfilhamento secundário (comprimento intermediário);
 3. 10 canas do perfilhamento terciário (mais curtas).
- Tomar 3 canas da sub-amostra lote 1, subdividindo cada cana em 3 partes, tomando as partes superiores (as que estavam mais próximas das folhas, normalmente mais finas).
 - Tomar 3 canas da sub-amostra lote 2, subdividindo cada cana em 3 partes, tomando as partes intermediárias.
 - Tomar 3 canas da sub-amostra lote 3, subdividindo cada cana em 3 partes, tomando as partes inferiores (mais próximas ao solo, normalmente mais grossas).

A décima cana será excluída da amostra.

Agrupando-se as 3 partes da sub-amostra temos 9, que pesam aproximadamente 1 [kg] cada para um lote, assim a soma de todas as sub-amostras da parcela resulta num total de 27 [kg], e para todos os lotes da parcela somam 243 [kg] de cana, a qual será a amostra representativa de 1 [ha], 10 [ha] ou 100 [ha] a ser analisada no laboratório.

As amostras devem ser etiquetadas para que possam ser identificadas e registradas adequadamente. Algumas informações normalmente contidas em etiquetas são:

- Fazenda;
- Parcela ou talhão;
- Dia da amostra;
- Idade da cana;
- Variedade;
- Informações sobre tratamento em caso de experimentos, entre outras.

As primeiras amostras, usualmente, são tomadas dois meses antes do início do período de colheita. Posteriormente, a cada 10 dias depois da primeira amostra deverá ser escolhida a segunda amostra das mesmas parcelas e dos mesmos lugares demarcados (A, B, C, D, ...) e repetidas 6 a 8 vezes até o início da safra.

Os resultados servem para estabelecer graficamente os pontos significativos que darão o ponto de maturidade da parcela ou do talhão de cana-de-açúcar. O procedimento para elaboração dos gráficos que permitem determinar as datas mais propícias das parcelas à serem cortadas no início e durante o período da safra, estão descritos em (ALAGOAS, 1975).

O trabalho mais importante é o parcelamento dos canaviais, em lotes, quadras e talhões para termos a amostra representativa do talhão à cortar.

2.3.1.3 Processo de análise das amostras

Os procedimentos de recepção das amostras nas Usinas, ou nos centros de análise, assim como o procedimento de análise das amostras tende a variar de região para região. Estes procedimentos são regulamentados por órgãos estaduais, no estado de São Paulo as normas são definidas pela Câmara Técnica e Econômica (CANATEC). A regulamentação dos procedimentos analíticos é necessário, pois o pagamento aos produtores pelo fornecimento de cana-de-açúcar é realizado baseado nas análises laboratoriais da cana-de-açúcar amostrada na recepção das Usinas.

O procedimento de análise estudado neste trabalho é apresentado em detalhes no Apêndice C. Apesar de existirem vários procedimentos de análise, todos seguem um conjunto de etapas que estão apresentadas na Figura 2.18 na forma de fluxograma.

Na etapa de recepção e conservação, as amostras, obtidas do campo como descrito anteriormente, são acondicionadas para a conservação até a utilização na próxima etapa. Cada amostra é triturada homogeneizando a amostra para em seguida se reamostrar o material, visando a redução da quantidade de material a ser analisado. Novamente, o material é re-amostrado, ao entrar no laboratório, para reduzir a quantidade de material a ser analisado, devido aos custos e à duração das análises realizadas. O material final é então decomposto através de um processo de trituração que reduz o material no menor tamanho de partícula possível. Na seqüência, separa-se a fibra e o caldo, determinando-se a porcentagem de fibra do material. O caldo então é analisado para a determinação dos índices de Brix, de Pol e de Açúcares Redutores (AR). Finalmente, os resultados de cada etapa são agrupados e os cálculos remanescentes são realizados finalizando o relatório laboratorial de análise técnica da cana-de-açúcar amostrada.

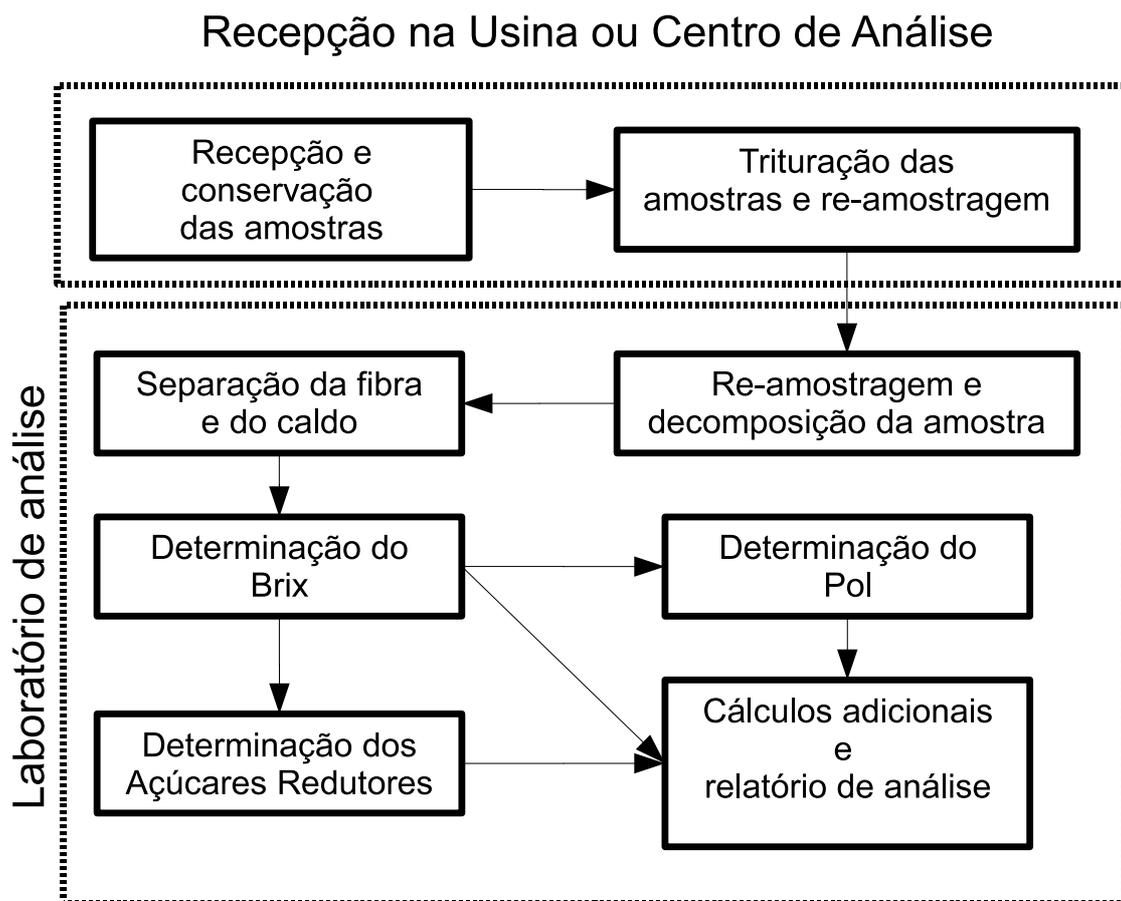


Fig. 2.18: Fluxograma dos procedimentos laboratoriais básicos.

Capítulo 3

Sistemas nebulosos

3.1 Introdução

Os conceitos dos conjuntos nebulosos e da lógica nebulosa podem ser empregados para modelar sistemas de várias formas. Exemplos de sistemas nebulosos são os sistemas baseados em regras (ZADEH, 1973), os modelos de regressão nebulosos (TANAKA; UEJIMA; ASAI, 1982), ou os modelos usando estruturas celulares (SMITH; NOKLEBY; COMER, 1994). Este trabalho está focado em sistemas nebulosos baseados em regras, por exemplo sistemas onde as relações entre as variáveis são representadas por meio de regras nebulosas da forma:

$$\text{Se proposição antecedente Então proposição conseqüente} \quad (3.1)$$

Dependendo de uma estrutura particular da proposição do conseqüente, três tipos de modelo são distinguidos:

- *Modelo lingüístico*(MAMDANI, 1977), onde tanto o antecedente quanto o conseqüente são proposições nebulosas.
- *Modelos relacionais*(PEDRYCZ, 1984), o qual pode ser considerado como uma generalização do modelo lingüístico, permitindo a uma proposição antecedente particular estar associada com várias proposições conseqüentes diferentes através de uma relação nebulosa.
- *Modelo Takagi-Sugeno*(TAKAGI; SUGENO, 1985), onde o conseqüente é uma função das variáveis do antecedente ao invés de uma proposição.

3.2 Modelos Nebulosos Lingüísticos

Nos modelos nebulosos lingüísticos (também chamados de modelos Mamdani), tanto a proposição antecedente quanto a conseqüente são formadas por relações nebulosas. As variáveis do modelo lingüístico têm um termo semântico associado que, usualmente, está relacionado a natureza da variável, como por exemplo, temperatura ou radiação solar. As regras dos modelos lingüísticos são denominadas regras lingüísticas nebulosas, e a sua forma é expressa como:

$$R_i: \text{ Se } x \text{ é } A_i \text{ então } y \text{ é } B_i, \quad i = 1, 2, \dots, K \quad (3.2)$$

onde x é a variável antecedente, e que representa a entrada do sistema nebuloso, e y é a variável do conseqüente que representa a saída do sistema nebuloso. Na maioria dos casos, se trabalha com um vetor de valores reais de entrada e de saída: $\mathbf{x} \in X \subset \mathbb{R}^p$ e $\mathbf{y} \in Y \subset \mathbb{R}^q$. As variáveis do antecedente e do conseqüente, geralmente, têm valores lingüísticos atribuídos, conforme será apresentado na Seção 3.2.1, a seguir. Neste caso, $x \in \mathcal{F}(X)$ e $y \in \mathcal{F}(Y)$, onde $\mathcal{F}(X)$ é o conjunto de todas as partições nebulosas de X . A_i e B_i são termos lingüísticos associados às funções de pertinência multivariadas $\mu_{A_i}(x) : X \rightarrow [0, 1]$ e $\mu_{B_i}(y) : Y \rightarrow [0, 1]$ que são o mapeamento dos conjuntos nebulosos. Finalmente, K denota o número de regras do modelo.

O conjunto nebuloso A_i define a região do espaço de entrada, para a qual se mantem a respectiva proposição conseqüente. Ao invés de usar conjuntos nebulosos multidimensionais, é mais conveniente considerar as proposições como variáveis escalares e gerar composições, para representar as regras, por meio de operadores lógicos, (SERRA, 2005). As proposições nebulosas lingüísticas contêm significados para cada variável, como “baixa temperatura”, “alta pressão”, etc. Isto permite a interpretação do modelo nebuloso pelo uso da linguagem natural.

As funções de pertinência para os termos lingüísticos são definidas na “base de dados”. A base de regras compõem a “base de conhecimento” do sistema nebuloso e determina as relações entre as variáveis de entrada e de saída. O mapeamento das relações entre as entradas e as saídas é realizado pelo “mecanismo de inferência nebuloso” que, dados a base de conhecimento e um valor de entrada, resulta na resposta do sistema na forma de um valor de saída. Na maioria das aplicações de engenharia, as entradas e saídas são valores numéricos, ao invés de conjuntos nebulosos. Dessa forma, o sistema nebuloso deve ter interfaces de conversão, a interface de “fuzzificação” e a de “defuzzificação”. Um diagrama esquemático da estrutura do sistema nebuloso geral esta apresentado na Figura 3.1.

Um exemplo de modelo NARX (apresentado na Seção 4.5.2) é:

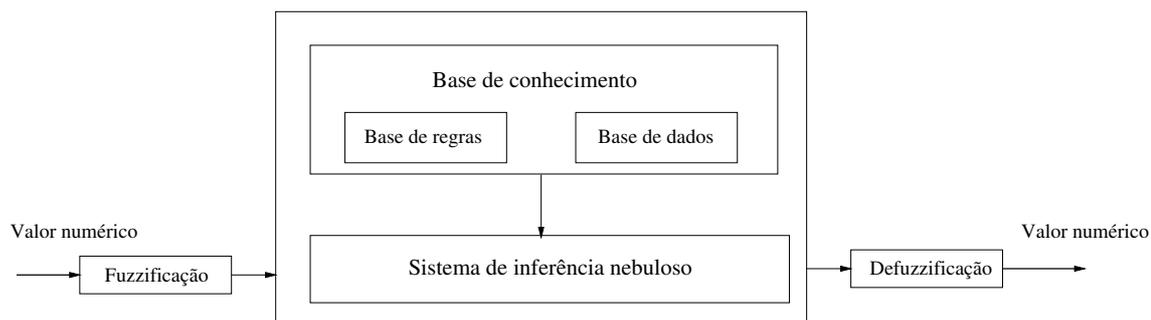


Fig. 3.1: Diagrama esquemático de um sistema nebuloso genérico

$$R_i: \text{Se } y(k) \text{ é } A_{i1} \text{ e } \dots \text{ e } y(k - n_y + 1) \text{ é } A_{in_y} \text{ e } u(k) \text{ é } B_{i1} \text{ e } \dots \\ \dots \text{ e } u(k - n_u + 1) \text{ é } B_{in_u} \text{ então } y(k + 1) \text{ é } C_i \quad (3.3)$$

, onde as variáveis de entrada do sistema são compostas pela entrada atual mais suas regressões $u(k), u(k - 1), \dots$ e pelas regressões da variável de saída, $y(k), y(k - 1), \dots$, que se deseja prever: $y(k + 1)$.

3.2.1 Termos e variáveis lingüísticas

Os termos lingüísticos são termos semânticos atribuídos aos conjuntos nebulosos de uma dada variável. Estes termos podem ser vistos como valores qualitativos (grânulos de informação) usados para descrever a relação dada pelas regras lingüísticas para fortalecer a semântica do modelo. Tipicamente, um conjunto de N termos lingüísticos $\mathcal{A} = \{A_1, A_2, \dots, A_N\}$ é definido no domínio de uma dada variável escalar x . Uma variável lingüística L é definida como uma quintúpla de atributos:

$$L = (x, \mathcal{A}, X, g, m), \quad (3.4)$$

onde x é a variável base, \mathcal{A} é conjunto dos termos lingüísticos de x , ou conjuntos nebulosos de x , X é o domínio (universo do discurso) da variável base, g é a regra sintática de geração do termo lingüístico e m é a regra semântica que designa cada termo lingüístico para o seu significado (conjunto nebuloso em X). A Figura 3.2 mostra um exemplo de uma variável lingüística “temperatura” com seus três termos “baixo”, “médio” e “alto”. A variável base é a temperatura dada nas apropriadas unidades físicas.

Usualmente é necessário que o termo lingüístico satisfaça propriedades de “cobertura” e “sonori-

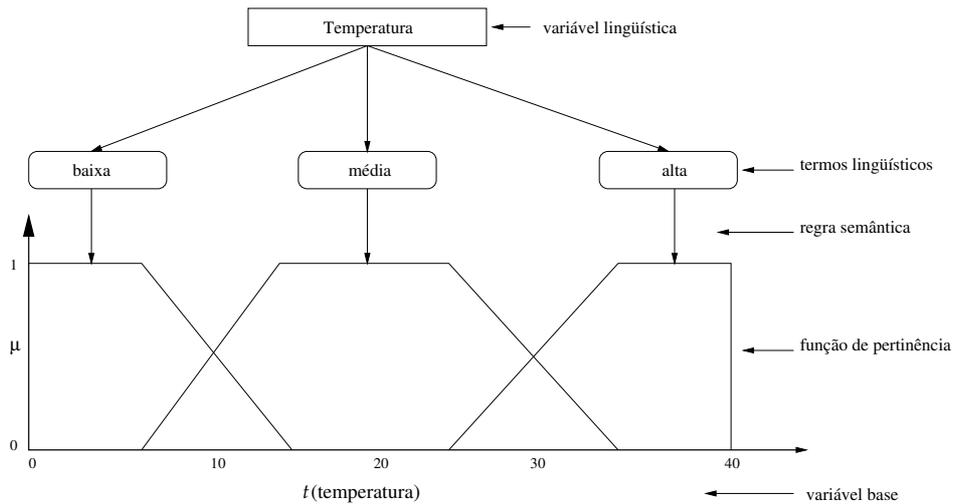


Fig. 3.2: Exemplo de uma variável linguística “temperatura” com três termos

dade semântica” (PEDRYCS; GOMIDE, 1998). Cobertura significa que cada elemento é designado para pelo menos um conjunto nebuloso com um grau de pertinência não nulo, por exemplo,

$$\forall x, \exists i, \mu_{A_i}(x) > 0. \quad (3.5)$$

A sonoridade semântica significa que o termo linguístico associado ao conjunto nebuloso permite estabelecer uma relação semântica, ou seja, que o termo tenha um significado semântico apropriado dado o sistema que o modelo linguístico representa. Por exemplo, o termo linguístico alto associado a variável temperatura da Figura 3.2 é apropriado quando se considera que o modelo linguístico representa um sistema de aquecimento de um chuveiro. Mas não seria um termo apropriado se a variável temperatura fosse componente de um modelo linguístico de uma caldeira.

Normalmente, A_i são funções convexas e normais (Apêndice A), suficientemente separadas, e o número N de subconjuntos é pequeno (no máximo de 9). O número de termos linguísticos, e a forma particular e a sobreposição das funções de pertinência estão relacionadas com a granularidade do processamento da informação pelo sistema nebuloso e também ao nível de precisão com o qual um dado sistema pode ser representado pelo modelo nebuloso.

As funções de pertinência podem ser definidas pelo projetista do modelo (um especialista), usando conhecimento a priori, ou pela experimentação (tentativa e erro). No caso de um projetista, as funções de pertinência são projetadas de forma que elas representem o conhecimento do especialista em termos linguísticos no contexto da modelagem. Quando os dados de entrada e saída de um sistema em estudo estão disponíveis, metodologias para construir as funções de pertinência a partir dos dados

podem ser aplicadas.

3.2.2 Proposições antecedentes

As proposições antecedentes contêm conjuntos nebulosos definidos tanto diretamente no domínio X , como na regra dada pela Equação 3.2. As regras são, freqüentemente, representadas na forma decomposta, com o antecedente definido como uma combinação de proposições nebulosas simples sobre os componentes individuais x_i do vetor x . Os operadores lógicos de conjunção, disjunção e negação (complemento) podem ser usados para construir uma desejada composição, por exemplo:

$$R_i: \text{ Se } x \text{ é } A_{i1} \text{ ou } x_2 \text{ é } A_{i2} \text{ e } x_3 \text{ não é } A_{i3} \text{ então } y \text{ é } B_i. \quad (3.6)$$

Neste caso, conjuntos nebulosos uni-dimensionais são definidos para cada componente do vetor do antecedente. O grau de preenchimento da regra é computado usando a apropriada t-norma, s-norma (t-conorma) e o operador de complemento, por exemplo:

$$\beta_i = \mu_{A_{i1}}(x_1) \vee \mu_{A_{i2}} \wedge (1 - \mu_{A_{i3}(x_3)}), \quad (3.7)$$

onde o operador de máximo (\vee) representa a disjunção (**ou**), o operador de mínimo (\wedge) representa a conjunção (**e**), e $1 - \mu$ é o complemento (negação, **não**). A proposição mais comum é a forma de conjunção dada por:

$$R_i : \text{ Se } x_1 \text{ é } A_{i1} \text{ e } x_2 \text{ é } A_{i2} \text{ e } \dots \text{ e } x_p \text{ é } A_{ip} \text{ então } y \text{ é } B_i, \quad (3.8)$$

com o grau de preenchimento β_i da regra R_i dado pelo operador de conjunção (t-norma), como o mínimo:

$$\beta_i = \mu_{A_{i1}}(x_1) \wedge \mu_{A_{i2}}(x_2) \wedge \dots \wedge \mu_{A_{ip}}(x_p) \quad (3.9)$$

3.2.3 Inferência em Modelos Lingüísticos

A inferência em modelos nebulosos baseados em regras é definida como o processo para determinar um conjunto nebuloso de saída dadas as regras e as entradas. O mecanismo de inferência no modelo lingüístico é baseado na composição de regras de inferência (MAMDANI, 1977). Por simplicidade, considere uma única regra com as variáveis escalares do antecedente e do conseqüente:

$$\text{Se } x \text{ é } A \text{ então } y \text{ é } B. \quad (3.10)$$

Esta regra pode ser reescrita com uma relação nebulosa $R : (X \times Y) \rightarrow [0, 1]$, calculada por

$$\mu_R(x, y) = I(\mu_A(x), \mu_B(y)), \quad (3.11)$$

onde o operador I pode também ser escrito como uma implicação nebulosa, ou um operador de conjunção (uma t-norma). Um exemplo de implicação é a de Lukasiewicz dada por:

$$I(\mu_A(x), \mu_B(y)) = \min(1, 1 - \mu_A(x) + \mu_B(y)). \quad (3.12)$$

Uma das t-normas bem conhecida é a do mínimo, freqüentemente, chamada de “implicação” Mamdani,

$$I(\mu_A(x), \mu_B(y)) = \min(\mu_A(x), \mu_B(y)), \quad (3.13)$$

outra é a do produto, também conhecida como a “implicação” Larsen,

$$I(\mu_A(x), \mu_B(y)) = \mu_A(x) \bullet \mu_B(y). \quad (3.14)$$

Enquanto implicações nebulosas representam relações unidirecionais “ A implica B ”, as regras codificadas por t-normas devem ser interpretadas como relações não direcionais “se é verdade que A mantém e B mantém”.

Dada a regra “Se x é A então y é B ” e o fato de “ x é A ” é verdadeiro, o conjunto nebuloso de saída B' é obtido pela composição relacional de max-t, (KLIR; YUAN, 1995):

$$B' = A' \circ R \quad (3.15)$$

Para a t-norma mínimo, da Equação 3.13, a composição max-min é obtida :

$$\mu_{B'}(y) = \max_x \min_{x,y}(\mu_{A'}(x), \mu_R(x, y)). \quad (3.16)$$

Toda a base de regras é representada pela agregação das relações das regras individuais em uma

única relação nebulosa. Denota-se por R_i a relação nebulosa correspondente a i -ésima regra, onde cada R_i é computado por implicações, a relação R para toda a base de regras é obtida pela agregação individual das relações R_i por meio da interseção:

$$R = \bigcap_{i=1}^K R_i. \quad (3.17)$$

Para I sendo uma t-norma, a relação de agregação R é computada com a união das relações individuais R_i :

$$R = \bigcup_{i=1}^K R_i. \quad (3.18)$$

O conjunto nebuloso de saída B' é inferido da mesma forma que para o caso de uma regra, pelo uso da regra de composição de inferência 3.15. A representação de um sistema pela relação nebulosa pode ser realizada por um grafo nebuloso, por exemplo a união dos conjuntos nebulosos no produto cartesiano dos espaços das variáveis do antecedente e do conseqüente. No grafo nebuloso apresentado na Figura 3.3, a união (Equação 3.18) de cada regra (Equação 3.10) modela na forma nebulosa a função f .

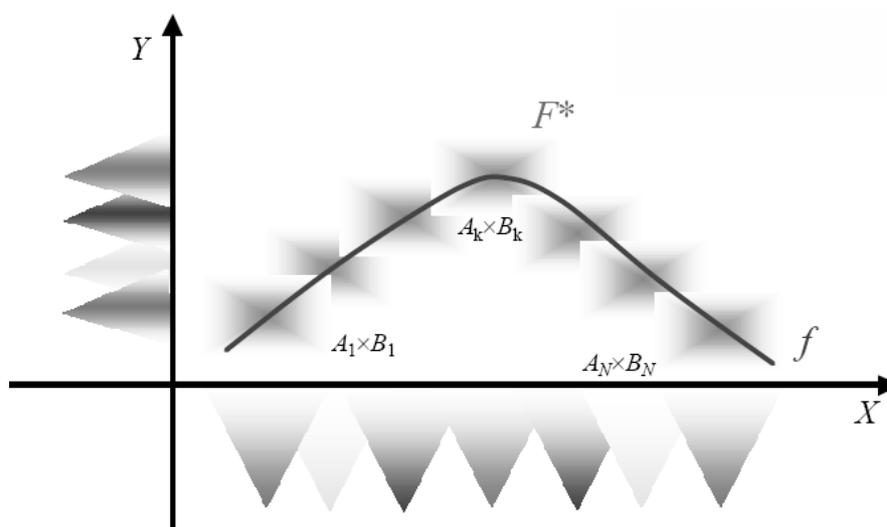


Fig. 3.3: Produto cartesiano dos conjuntos nebulosos de entrada e saída para o caso de um sistema Mamdani

A relação nebulosa R , definida sobre o produto cartesiano das variáveis do sistema $X_1 \times X_2 \times$

$\dots \times X_p \times Y$, pode ser referida como uma distribuição de possibilidades (restrita) das diferentes combinações entrada e saída. Um α -corte de R pode ser interpretado como um conjunto de combinações entrada-saída possível para um grau maior ou igual à α , Apêndice A.

3.2.4 Defuzzificação

O resultado da inferência nebulosa é um conjunto nebuloso B' . Se um valor de saída incisiva (numérica) é necessário, a saída nebulosa deve ser defuzzificada. A defuzzificação é uma transformação que substitui o conjunto nebuloso por um único valor representativo daquele conjunto. Os dois mais comuns métodos de defuzzificação são: Centro de gravidade (COG - “*Center Of Gravity*”) e Média do máximo (MOM - “*Mean Of Maxima*”) (BABUSKA, 1998).

O método do COG calcula numericamente a coordenada y do centro de gravidade do conjunto nebuloso B' :

$$cog(B') = \frac{\sum_{q=1}^{N_q} \mu_{B'}(y_q) y_q}{\sum_{q=1}^{N_q} \mu_{B'}(y_q)}, \quad (3.19)$$

onde N_q é o número dos valores discretizados y_q em Y . O método MOM computa a média do intervalo com o maior grau de pertinência:

$$mom(B') = \text{média}\{y | \mu_{B'}(y) = \max_{y \in Y} \mu_{B'}(y)\}. \quad (3.20)$$

O método COG é usado com a inferência Mamdani max-min, por realizar a interpolação entre os conseqüentes, na proporção da altura dos conjuntos individuais do conseqüente. Isto é necessário, pois como o método de inferência de Mamdani por si só não interpola, o uso do método MOM neste caso resultaria em uma saída com degraus.

Para garantir a integração numérica no método COG, uma modificação dessa abordagem chamada de defuzzificação por média nebulosa é freqüentemente usada. Os conjuntos nebulosos do conseqüente são primeiramente defuzzificados, de forma a obter os valores incisivos representativos de cada conjunto nebuloso, usando por exemplo o MOM: $b_j = mom(B_j)$. Um valor de saída incisiva é então computado tomando-se a média ponderada dos b_j :

$$y_0 = \frac{\sum_{j=1}^M \gamma_j b_j}{\sum_{j=1}^M \gamma_j}, \quad (3.21)$$

onde M é o número de conjuntos nebulosos em B_j e γ_j é o grau máximo de preenchimento de β_j sobre todas as regras com o conseqüente B_j . Em termos do conjunto nebuloso agregado B' , dado por 3.16, γ_j pode ser expresso por $\gamma_j = \mu_{B'}(b_j)$. Este método assegura uma interpolação entre os b_j , permitindo que as funções de pertinência do antecedente sejam lineares por partes. Este não é o caso do método COG, o qual introduz uma não-linearidade, dependendo da forma das funções do conseqüente. Devido a defuzzificação individual ser feita “*off-line*”, a forma e a sobreposição dos conjuntos nebulosos do conseqüente não têm influência, e estes conjuntos podem ser diretamente trocados por valores defuzzificados (“*singletons*”). De maneira a pelo menos levar em conta as diferenças entre os conjuntos nebulosos do conseqüente, a defuzzificação da média-nebulosa ponderada pode ser aplicada:

$$y_0 = \frac{\sum_{j=1}^M \gamma_j S_j b_j}{\sum_{j=1}^M \gamma_j S_j}, \quad (3.22)$$

onde S_j é a área sobre a função de pertinência B' . Uma vantagem dos métodos de média-nebulosa 3.21 e 3.22 é que o parâmetro b_j pode ser estimado por técnicas de estimação linear.

3.3 Modelos *Singleton*

Como mencionado acima, os conjuntos nebulosos do conseqüente B_i do modelo lingüístico podem ser reduzidos a *singletons* nebulosos e representados como números reais b_j :

$$R_i: \text{ Se } x \text{ é } A_i \text{ então } y = b_i. \quad (3.23)$$

Este modelo é chamado de modelo *singleton*. Ao contrário dos termos conseqüentes no modelo lingüístico, o número de *singletons* distintos na base de regras não é, usualmente, limitado; por exemplo cada regra pode conter seu próprio conseqüente *singleton*. Para o modelo *singleton*, a defuzzificação COG fica reduzida ao método da média-nebulosa:

$$y_0 = \frac{\sum_{i=1}^K \beta_i b_i}{\sum_{i=1}^K \beta_i}, \quad (3.24)$$

Note que aqui todas as K regras contribuem para a defuzzificação, ao contrário do método dado pela Equação 3.21. Isto significa que se duas regras que têm o mesmo conseqüente *singleton* são ativadas, este *singleton* terá uma maior influência na média ponderada dada pela Equação 3.24.

Quando utilizamos a Equação 3.21, cada conseqüente deveria ser computado apenas uma vez com um peso equivalente ao maior de dois graus de preenchimento. Note que o modelo *singleton* pode também ser considerado como um caso especial do modelo Takagi-Sugeno, apresentado na Seção 3.4.

Uma vantagem do modelo *singleton* sobre o modelo lingüístico é que os parâmetros do conseqüente b_i podem facilmente ser estimados a partir dos dados, usando a técnica dos mínimos quadrados. O modelo *singleton* nebuloso pertence à classe de funções de aproximação geral, chamadas de funções de expansão de base, tomando a forma:

$$y = \sum_{i=1}^K \phi_i(x) b_i. \quad (3.25)$$

Redes neurais de funções de base radial, ou modelos de “*spline*” também pertencem a essa classe de sistemas. Nos modelos *singleton*, as funções de base $\phi_i(x)$ são dadas por graus (normalizados) de preenchimento das regras antecedentes e as constantes b_j são os conseqüentes. Este modelo tem propriedade de um aproximador geral de funções, (KOSKO, 1994).

3.4 Modelos Takagi-Sugeno

Um modelo baseado em regras apropriado para a aproximação de um grande classe de sistemas não-lineares foi introduzido por (TAKAGI; SUGENO, 1985). No modelo nebuloso Takagi-Sugeno (TS), os conseqüentes das regras são funções incisivas das entradas do modelo:

$$R_i : \text{Se } x \text{ é } A_i \text{ então } y_i = f_i(x) \quad i = 1, 2, \dots, K, \quad (3.26)$$

onde $x \in \mathbb{R}^p$ é a variável de entrada (antecedente) e $y_i \in \mathbb{R}$ é a variável de saída (conseqüente), R_i denota a i -ésima regra, e K é o número de regras na base de regras. A_i é o conjunto nebuloso do antecedente da i -ésima regra, definida pela função de pertinência :

$$\mu_{A_i}(x) : \mathbb{R}^p \rightarrow [0, 1] \quad (3.27)$$

Assim como no modelo lingüístico, a proposição antecedente “ x é A_i ” é usualmente expressa como uma combinação lógica de proposições simples com conjuntos nebulosos monovariáveis definidos para os componentes individuais de x , freqüentemente na forma de conjunções:

$$R_i : \text{Se } x_1 \text{ é } A_{i1} \text{ e } x_2 \text{ é } A_{2i} \text{ então } y_i = f_i(x) \quad i = 1, 2, \dots, K. \quad (3.28)$$

As funções do conseqüente f_i são tipicamente escolhidas como partes de uma função parametrizada adequada, cuja estrutura mantém-se igual em todas as regras e apenas os parâmetros variam. Uma parametrização muito utilizada é a chamada de forma linear afim:

$$y_i = a_i^T x + b_i, \quad (3.29)$$

onde a_i é o vetor de parâmetros e b_i é um escalar de “offset”, ou polarização. Este modelo é chamado de modelo TS afim. Os conseqüentes do modelo TS afim são hiperplanos em \mathbb{R}^{p+1} . O antecedente de cada regra define uma região (nebulosa) válida para o correspondente modelo conseqüente (linear). O modelo global é composto como uma concatenação dos modelos locais, e pode ser visto como uma aproximação por partes suavizada.

Um caso especial das funções do conseqüente ocorre quando $b_i = 0$, $i = 1, \dots, K$. Então, o modelo é chamado de modelo TS homogêneo:

$$R_i : \text{Se } x \text{ é } A_i \text{ então } y_i = a_i^T x, \quad i = 1, 2, \dots, K. \quad (3.30)$$

Este modelo possui maiores limitações da capacidade de aproximação do que os modelos TS afim, (FANTUZZI; ROVATTI, 1996). De qualquer forma, a falta do termo de offset facilita o projeto de controladores e análises de estabilidade baseados em sistemas TS homogêneos (TANAKA; SUGENO, 1992), devido ao fato do modelo poder ser analisado de maneira quase-linear.

Quando $a_i = 0$, $i = 1, \dots, K$, os conseqüentes do modelo da Equação 3.29 são funções constantes, e o modelo *singleton* é obtido:

$$\text{Se } x \text{ é } A_i \text{ então } y = b_i \quad (3.31)$$

Este modelo pode também ser visto como um caso especial do modelo lingüístico, onde o conjunto nebuloso do conseqüente foi reduzido a *singleton*.

3.4.1 Inferência no modelo TS

Antes que o valor de saída possa ser inferido, o grau de preenchimento do antecedente denotado por $\beta_i(x)$ deve ser computado. Para regras com antecedentes nebulosos multivariados dados pelas Equações 3.26 e 3.27, o grau de preenchimento é simplesmente igual ao grau de pertinência de uma dada entrada x , por exemplo, $\beta_i(x) = \mu_{A_i}(x)$. Quando conectores lógicos são usados, o grau de preenchimento do antecedente é computado como uma combinação dos graus de pertinência das proposições individuais usando o operador lógico nebuloso.

No modelo TS, a inferência é reduzida a uma simples expressão algébrica, similar à fórmula da média-nebulosa de defuzzificação (TAKAGI; SUGENO, 1985):

$$y = \frac{\sum_{i=1}^K \beta_i(x) y_i}{\sum_{i=1}^K \beta_i(x)} \quad (3.32)$$

Considerando que os conseqüentes no modelo TS como *singletons* são dependentes das entradas, devido à função linear, a Equação 3.32 pode ser visto como uma extensão direta da defuzzificação da média-nebulosa. Denotando o grau de preenchimento normalizado,

$$\lambda_i(x) = \frac{\beta_i(x)}{\sum_{i=1}^K \beta_j}, \quad (3.33)$$

o modelo TS afim com uma estrutura conseqüente comum pode ser expresso como um modelo pseudo-linear com parâmetros dependentes das entradas:

$$y = \left(\sum_{i=1}^K \lambda_i(x) a_i^T \right) x + \sum_{i=1}^K \lambda_i(x) b_i = a^T(x)x + b(x). \quad (3.34)$$

Os parâmetros $a(x)$ e $b(x)$ são combinações lineares convexas dos parâmetros a_i e b_i , por exemplo:

$$a(x) = \sum_{i=1}^K \lambda_i(x) a_i, \quad b(x) = \sum_{i=1}^K \lambda_i(x) b_i. \quad (3.35)$$

Um modelo TS pode ser considerado como um mapeamento a partir do espaço dos antecedentes para uma região convexa (politopo) no espaço dos parâmetros do sistema quasi-linear da Equação 3.34, como está mostrado esquematicamente na Figura 3.4, (SERRA, 2005; BABUSKA, 1998).

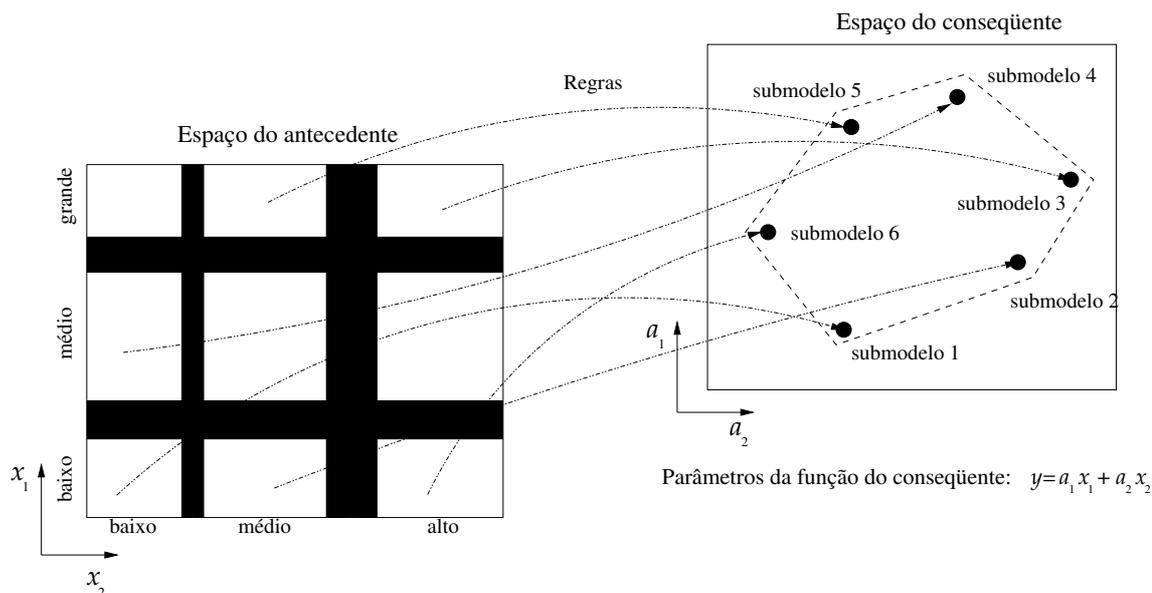


Fig. 3.4: Mapeamento do espaço nebuloso do antecedente e do conseqüente

3.5 Construção de Modelos Nebulosos TS

Este trabalho foca a criação de modelos nebulosos a partir do conjunto de dados, o que envolve métodos baseados na lógica nebulosa, na aproximação de raciocínio e também em idéias originadas da área de redes neurais, análise de dados e da identificação de sistemas lineares.

O potencial mais forte dos modelos nebulosos permanece na habilidade de combinar informações obtidas de dados com conhecimentos heurísticos expressos na forma de regras. As duas principais abordagens para a integração de conhecimento e de informações de dados em modelos nebulosos são:

- O modelo pode ser formulado por um conjunto de regras **Se - então** baseadas na experiência de um especialista sobre o sistema. As funções de pertinência também podem ser extraídas do conhecimento de especialistas, mas necessitam de uma abordagem estatística para serem geradas. O modelo inicialmente obtido pode ser ajustado por algum algoritmo de aprendizagem utilizando dados do sistema.
- O modelo pode ser formulado estabelecendo uma base de regras construída de um conjunto de dados numéricos e de uma escolha arbitrária do seu número e da forma das funções de pertinência. As regras e as funções de pertinência resultantes são extraídas por interpretação posterior do comportamento do sistema combinando com algum conhecimento adicional, através de termos lingüísticos. Os parâmetros do modelo são ajustados através da base de dados. Esta é a abordagem adotada neste trabalho.

A identificação de sistemas nebulosos pode ser dividida em duas partes: Identificação da estrutura e identificação dos parâmetros. A identificação da estrutura pode ser dividida em dois tipos, segundo (SUGENO; YASUKAWA, 1993), chamados de tipo I e tipo II, onde cada tipo é também dividido em dois subtipos, os quais podem ser observados na Tabela 3.1.

Estrutura I	a) entradas candidatas
	b) variáveis candidatas
Estrutura II	a) número de regras
	b) partição do espaço de entrada
Identificação dos parâmetros	

Tab. 3.1: Classificação da Identificação Nebulosa

3.5.1 Identificação da estrutura

De uma forma geral, a identificação da estrutura tem que resolver dois problemas: na Estrutura I: determinar as variáveis de entrada e na Estrutura II: encontrar as relações de entrada-saída. Na Estrutura Ia deve-se encontrar as variáveis candidatas a entrada, as quais devem ser restritas a um número finito, (ALMEIDA, 2005). Esta etapa da identificação tem um forte apelo à intuição do projetista. No caso de sistemas agrícolas, por exemplo, no sistema de cana-de-açúcar, podemos tomar como variáveis de entrada a temperatura, a radiação e a precipitação como a base de dados para o estudo do processo de acumulação de açúcar, contudo o projetista, pela experiência, pode determinar que apenas a temperatura seja utilizada como entrada.

Na identificação de estrutura Ib, dadas as entradas, investiga-se quais regressores destas variáveis fornecem mais informações sobre a resposta do sistema.

Geralmente, a identificação de Estrutura I ocorre na etapa do projeto de experimento, onde se selecionam as variáveis candidatas para explicar um determinado sistema. Esta seleção é feita baseada na experiência e intuição do pesquisador, sobre a influência das variáveis nas respostas do sistema, (ALMEIDA, 2005). Na experimentação agrícola é usual coletar num experimento um grande conjunto de dados sobre várias variáveis, e posteriormente aplicar a identificação de Estrutura Ia e Ib para determinar as variáveis e os seus regressores mais relevantes para a modelagem de algum aspecto do comportamento do sistema.

A identificação de Estrutura II, que determina as relações entrada-saída, também é dividida em dois subtipos IIa e IIb. Em IIa deve-se definir o número de regras do modelo nebuloso, e assim determinar as relações entre as entradas e saídas e a sua ordem. Nos modelos nebulosos compostos

por regras Se – então, o número de regras n corresponde à ordem. A determinação de n caracteriza a identificação de Estrutura IIa.

As regras são compostas de duas partes: a proposição antecedente e a conseqüente. Então as regras têm duas estruturas: antecedente e conseqüente. No modelo nebuloso TS, o antecedente e o conseqüente são dados pela Equação 3.29.

O espaço antecedente é particionado em espaços nebulosos, como pode ser visto na Figura 3.4. Esta partição é chamada de estrutura do antecedente, ou da premissa, nos modelos nebulosos. Então a identificação IIb implica determinar como o espaço de entrada será particionado, ou mapeado. O algoritmo de particionamento será apresentado na Seção 3.6.

3.5.2 Identificação dos parâmetros

Na identificação de sistemas lineares os parâmetros são os coeficientes da estrutura matemática do modelo. O modelo nebuloso possui parâmetros para as funções de pertinência dos antecedentes e para as funções lineares dos conseqüentes das regras. Os parâmetros das funções de pertinência são obtidos na identificação de estrutura IIb. Assim, a identificação de parâmetros de modelos nebulosos é a identificação dos parâmetros das funções lineares dos conseqüentes de cada regra.

O procedimento para a determinação dos parâmetros por técnicas tradicionais depende da utilização das funções de pertinência e das regras previamente determinadas. Porém, existem técnicas que utilizam algoritmos genéticos para compor modelos nebulosos completos automaticamente baseando-se apenas nos dados do sistema, como a desenvolvida por Delgado (DELGADO, 2002). O critério mais utilizado para a determinação dos parâmetros é o de erro na saída. O procedimento aqui adotado segue as etapas descritas anteriormente para deixar claro como o modelo nebuloso foi obtido.

3.6 Algoritmo de Agrupamento

Nesta seção abordamos os conceitos de agrupamento nebuloso, e como um algoritmo de agrupamento nebuloso pode servir para construir modelos nebulosos à partir de um conjunto de dados.

3.6.1 Definição de Agrupamentos

Várias definições de agrupamentos (“*Clusters*”) podem ser formuladas, dependendo do objetivo do agrupamento. Um agrupamento pode ser visto como um grupo de objetos que possuem características similares, assim um agrupamento representa um conjunto de objetos similares. Aqui compreende-se o termo “similaridade” como uma métrica matemática para a distância. A medida de distância é realizada entre os elementos do vetor de dados e os do vetor de protótipos, considerando uma formulação geométrica ou estatística. O protótipo de um agrupamento é um objeto que procura-se posicionar no espaço de forma que represente uma parte do conjunto de dados, segundo a formulação da métrica utilizada. A quantidade de protótipos pode ser determinada de forma automática por alguns algoritmos de classificação, ou partição automática, porém aqui o número de protótipos será determinado por tentativa e erro. Os algoritmos de agrupamento aqui utilizados são apresentados a seguir.

3.6.2 Algoritmo de agrupamento *c-means*

A maioria dos algoritmos para determinar agrupamentos nebulosos é baseada em uma otimização da função objetivo básica *c-means*, ou de alguma modificação desta.

3.6.2.1 A função objetivo *c-means*

Uma grande família de algoritmos para determinar agrupamentos nebulosos é baseada na minimização da função objetivo *c-means*:

$$J(Z; U, V) = \sum_{i=1}^c \sum_{k=1}^N (\mu_{ik})^m \|\mathbf{z}_k - \mathbf{v}_i\|_{\mathbf{A}}^2 \quad (3.36a)$$

onde

$$\mathbf{U} = [\mu_{ik}] \in M_{fc} \quad (3.36b)$$

$$M_{fc} = \left\{ \mathbf{U} \in R^{c \times N} \mid \mu_{ik} \in [0, 1], \forall i, k; \sum_{i=1}^c \mu_{ik} = 1, \forall k; 0 < \sum_{k=1}^N \mu_{ik} < N, \forall i \right\}$$

é uma partição nebulosa da matriz de dados $\mathbf{Z} = [\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_N]$,

$$\mathbf{V} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_c], \quad \mathbf{v}_i \in \mathbb{R}^n \quad (3.36c)$$

é um vetor dos protótipos dos agrupamentos (centros), a serem determinados;

A norma quadrática da distância é definida por:

$$D_{ik\mathbf{A}}^2 = \|\mathbf{z}_k - \mathbf{v}_i\|_{\mathbf{A}}^2 = (\mathbf{z}_k - \mathbf{v}_i)^T \mathbf{A} (\mathbf{z}_k - \mathbf{v}_i) \quad (3.36d)$$

e

$$m \in [1, \infty) \quad (3.36e)$$

é um expoente de ponderação o qual determina a nebulosidade dos agrupamentos resultantes (ZHANG, 2005). A medida de não-similaridade, dada pela Equação 3.36a, é a norma da distância euclidiana ao quadrado entre cada ponto dos dados \mathbf{z}_k e cada protótipo de agrupamento \mathbf{v}_i . Esta distância é ponderada pela exponenciação do grau de pertinência daquele ponto $(\mu_{ik})^m$. O valor da função de custo, dado pela Equação 3.36a, pode ser visto como uma medida da variância total de \mathbf{z}_k a partir de \mathbf{v}_i (BABUSKA, 1998).

3.6.3 Algoritmo *c-means* nebuloso

A minimização da Equação 3.36a representa um problema de otimização não-linear que pode ser resolvido usando uma variedade de métodos disponíveis, variando do método de minimização das coordenadas agrupadas, passando pelo recozimento simulado (“*simulated annealing*”), até algoritmos genéticos. O método mais popular, de qualquer forma, é uma simples iteração de Picard através das condições de primeira ordem para pontos estacionários da Equação 3.36a, conhecido como algoritmo *c-means* nebuloso, (PUCCIARELLI, 2005).

Os pontos estacionários da função objetivo, Equação 3.36a, podem ser encontrados juntando a restrição

$$\sum_{i=1}^c \mu_{ik} = 1, \quad 1 \leq k \leq N, \quad (3.37)$$

em J por meio dos multiplicadores de Lagrange:

$$\bar{J}(Z; U, V) = \sum_{i=1}^c \sum_{k=1}^N (\mu_{ik})^m D_{ik\mathbf{A}}^2 + \sum_{k=1}^N \lambda_k \left[\sum_{i=1}^c \mu_{ik} \right], \quad (3.38)$$

e pelo ajuste dos gradientes de \bar{J} com respeito a \mathbf{U} , \mathbf{V} e λ a zero. Se $D_{ik\mathbf{A}}^2 > 0$, $\forall i, k$ e $m > 1$, então $(\mathbf{U}, \mathbf{V}) \in M_{fc} \times \mathbb{R}^{n \times c}$. A Equação 3.38 pode ser minimizada somente se

$$\mu_{ik} = \frac{1}{\sum_{j=1}^c (D_{ik\mathbf{A}}/D_{jk\mathbf{A}})^{2/(m-1)}}, \quad 1 \leq i \leq c, \quad 1 \leq k \leq N, \quad (3.39a)$$

e

$$\mathbf{v}_i = \frac{\sum_{k=1}^N (\mu_{ik})^m \mathbf{z}_k}{\sum_{k=1}^N (\mu_{ik})^m}, \quad 1 \leq i \leq c. \quad (3.39b)$$

Observe que \mathbf{v}_i é uma média ponderada dos dados que pertencem ao agrupamento, onde os pesos são graus de pertinência. Por esta razão este método é chamado *c-means*.

3.6.4 Algoritmo de agrupamento de Gustafson-Kessel

O algoritmo de agrupamento de Gustafson-Kessel (GK) estendeu o algoritmo “*c-means*”, apresentado na seção anterior, empregando uma norma adaptativa da distância, de forma a detectar agrupamentos de diferentes formas geométricas nos dados. Cada agrupamento tem sua própria matriz de norma \mathbf{A}_i , a qual produz a seguinte norma do produto interno:

$$D_{ik\mathbf{A}_i}^2 = (\mathbf{z}_k - \mathbf{v}_i)^T \mathbf{A}_i (\mathbf{z}_k - \mathbf{v}_i). \quad (3.40)$$

As matrizes \mathbf{A}_i são usadas como variáveis de otimização na função *c-means*, então permitindo que cada agrupamento ajuste a norma da distância para a estrutura topológica local dos dados. Representando \mathbf{A} como um conjunto de matrizes: $\mathbf{A} = (\mathbf{A}_1, \mathbf{A}_2, \dots, \mathbf{A}_c)$, a função objetivo do algoritmo GK é definida por:

$$J(\mathbf{Z}|\mathbf{U}, \mathbf{V}, \mathbf{A}) = \sum_{i=1}^c \sum_{k=1}^N (\mu_{ik})^m D_{ik\mathbf{A}_i}^2, \quad (3.41)$$

onde $\mathbf{U} \in \mathbb{R}^{n \times c}$ e $m > 1$. A solução,

$$(\mathbf{U}, \mathbf{V}, \mathbf{A}) = \arg \min_{M_f \times \mathbb{R}^{n \times c} \times PD^n} J(\mathbf{Z}|\mathbf{U}, \mathbf{V}, \mathbf{A}), \quad (3.42)$$

estabelece pontos estacionários de J , onde PD^n representa o espaço das $n \times n$ matrizes definidas positivas (BABUSKA, 1998). A função objetivo não pode ser diretamente minimizada com respeito à \mathbf{A}_i , uma vez que esta função é linear em \mathbf{A}_i . J pode ser feito tão pequeno quanto se deseje tomando \mathbf{A}_i que seja o menos definida positiva quanto possível. Para obter uma solução factível, \mathbf{A}_i deve ser restringida de alguma maneira. Uma forma usual de obtê-la é restringir o determinante de \mathbf{A}_i . Permitindo à matriz \mathbf{A}_i variar com seu determinante fixado corresponde a otimização da forma do agrupamento enquanto seu volume se mantém constante:

$$|\mathbf{A}_i| = \rho_i, \rho_i > 0, \forall_i. \quad (3.43)$$

Usando o método do multiplicador de Lagrange, a expressão seguinte para \mathbf{A}_i é obtida:

$$\mathbf{A}_i = [\rho_i \det(\mathbf{F}_i)]^{1/n} \mathbf{F}_i^{-1}, \quad (3.44)$$

onde \mathbf{F}_i é a matriz de covariância nebulosa do i -ésimo agrupamento, definida por:

$$\mathbf{F}_i = \frac{\sum_{k=1}^N (\mu_{ik})^m (\mathbf{z}_k - \mathbf{v}_i)(\mathbf{z}_k - \mathbf{v}_i)^T}{\sum_{k=1}^N (\mu_{ik})^m} \quad (3.45)$$

A substituição das Equações 3.44 e 3.45 na 3.40 resulta na raiz quadrada da norma da distância generalizada de Mahalanobis entre \mathbf{z}_k e a média do agrupamento \mathbf{v}_i (IHRKE, 2004), onde a covariância é ponderada pelos graus de pertinência em \mathbf{U} , (ZHANG, 2005).

Comentários sobre o método de agrupamento GK:

1. A escolha de m tem a mesma implicação tanto no algoritmo GK quanto no *c-means*.
2. Sem um conhecimento a priori sobre a posição dos protótipos, o volume dos agrupamentos ρ_i é fixado em 1 para cada agrupamento.
3. Os auto-valores da estrutura da matriz de covariância dos agrupamentos fornece informação sobre a forma e a orientação do agrupamento. Os comprimentos dos eixos hiperbólicos dos agrupamentos são dados pelas raízes quadradas dos auto-valores de \mathbf{F}_i . Os subespaços lineares do espaço dos dados são representados por planos hiperelipsoidais, os quais podem ser vistos como hiperplanos.

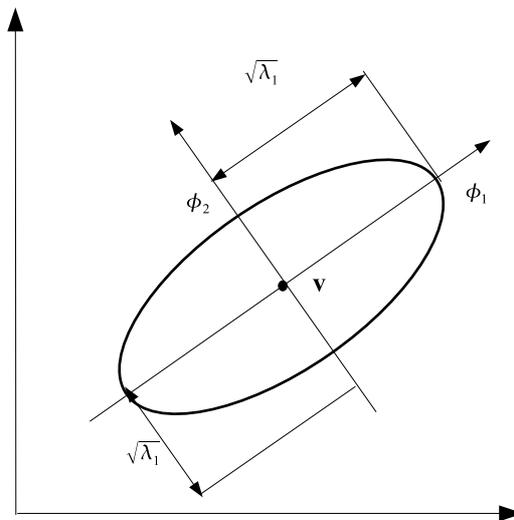


Fig. 3.5: Representação do hiperelipsóide definido por cada agrupamento do algoritmo GK

4. Uma vantagem do algoritmo GK sobre o *c-means* é que o GK pode detectar agrupamentos de diferentes formas e orientações sobre o conjunto de dados, no entanto exige um maior esforço computacional que o *c-means*, (PUCCIARELLI, 2005).

Neste trabalho, o critério de verificação da qualidade dos agrupamentos realizados será o das observações sobre os resultados e da qualidade das funções de pertinência obtidas destes agrupamentos. Não será adotado nenhum método de otimização das partições do espaço antecedente.

3.7 O problema da regressão não-linear

Os sistemas nebulosos são aproximadores universais de funções, e como tal podem ser aplicados aos problemas de regressão não-linear em geral. A regressão não-linear é a modelagem da dependência da resposta estática de uma variável, denominada regressando, $y \in Y \subset \mathbb{R}$ sobre o vetor de regressão $\mathbf{x} = [x_1, \dots, x_p]^T$ no domínio de $X \subset \mathbb{R}^p$. Os elementos do vetor regressor são chamados de regressores e o domínio X é chamado de espaço regressor. O sistema que gera os dados é expresso por:

$$y \approx f(x). \quad (3.46)$$

A função determinística $f(\cdot)$ captura as dependências de y em x , e \approx reflete o fato de que y não será uma função exata de x . A motivação da regressão é o uso de dados para a construção de uma

função $g(x)$ que pode servir como uma aproximação razoável de $f(x)$ não somente para o conjunto de dados, mas para todo o domínio de X . A definição de “aproximação razoável” depende do propósito do modelo construído. Se o motivo principal da modelagem é prever y , a exatidão é o critério mais relevante. A falta de exatidão é usualmente definida como a integral do erro:

$$I = \int_X \|f(x) - g(x)\| dx, \quad (3.47)$$

Para todo o domínio de X . Em geral, este erro não pode ser computado, uma vez que o valor de f é conhecido apenas para o conjunto de pontos disponíveis. Então, a média do erro de predição sobre os dados é freqüentemente usada

$$J = \frac{1}{N} \sum_{i=1}^N \|f(x_i) - g(x_i)\|, \quad (3.48)$$

onde N representa o número de amostras. A determinação do mínimo de I da Equação 3.47 implica no melhor modelo possível com a estrutura selecionada. No entanto, este não é o caso para J , que garante apenas que o modelo se ajusta aos dados disponíveis com o menor erro. Um passo extra de validação é então necessário, para determinar o melhor modelo sobre toda a região de interesse X . Neste estudo os modelos serão avaliados segundo os critérios da Seção 4.5.4.

Além da exatidão das predições, o objetivo pode ser obter um modelo que possa ser usado para analisar e entender as propriedades do sistema real que gerou os dados. Um forte potencial dos modelos nebulosos é que descrevem sistemas como uma coleção de submodelos locais que são expressados em regras. Estas regras podem ser formuladas usando linguagem natural, e como tal podem ser mais compreensíveis do que expressões matemática complicadas.

Existem muitas possibilidades para a escolha dos regressores na identificação não-linear. A estrutura de modelo NARX é freqüentemente usada em muitos métodos de identificação não-lineares, tais como redes neuro-nebulosas, funções de base radial e modelos nebulosos, (SERRA; BOTTURA, 2007) e (SERRA, 2005). Na seção 4.5.2 apresentamos esta estrutura entre outras.

3.8 Identificação pelo Espaço Produto

O princípio da identificação pelo agrupamento do produto dos espaços ou espaço produto, que é o produto cartesiano $X \times Y$ dos espaços de entrada X e de saída Y , é aproximar o problema de regressão não-linear pela decomposição em vários sub-problemas lineares locais. Esta abordagem tem várias

vantagens em comparação com modelos de regressão não-lineares globais, como as redes neurais. A estrutura do modelo é fácil de entender e interpretar, tanto qualitativamente quanto quantitativamente. Vários tipos de conhecimento podem ser integrados no modelo, incluindo conhecimento empírico, dados medidos e modelos mecânicos disponíveis.

O agrupamento nebuloso é aplicado no produto dos espaços dos regressores X com o da variável dependente Y : $X \times Y$. Toma-se \mathbf{X} denotado por uma matriz $\mathbb{R}^{N \times p}$, tendo os vetores de regressão \mathbf{x}_k^T em suas colunas, e denota-se \mathbf{y} o vetor coluna em \mathbb{R}^N , contendo as variáveis dependentes y_k :

$$\mathbf{X} = \begin{bmatrix} x_1^T \\ x_2^T \\ \dots \\ x_N^T \end{bmatrix}, \quad \mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_N \end{bmatrix} \quad (3.49)$$

onde N representa o número de amostras, p é a dimensão do vetor de regressão. Para um modelo entrada-saída de um sistema dinâmico, a matriz \mathbf{X} contém versões deslocadas dos vetores de dados de entrada e saída. Como um exemplo, vamos considerar um modelo NARX (apresentado na Seção 4.5.2) de segunda ordem $y(k) = g(y(k-1), y(k-2), u(k), u(k-1))$, e um conjunto de medidas disponíveis $S = (u(j), y(j)) | j = 1, 2, \dots, N_d$; a matriz de regressão e a variável dependente são:

$$\mathbf{X} = \begin{bmatrix} y_2 & y_1 & u_2 & u_1 \\ y_3 & y_2 & u_3 & u_2 \\ \vdots & \vdots & \vdots & \vdots \\ y_{N_d-2} & y_{N_d-3} & u_{N_d-1} & u_{N_d-3} \end{bmatrix}, \quad \mathbf{y} = \begin{bmatrix} y_3 \\ y_4 \\ \dots \\ y_{N_d} \end{bmatrix} \quad (3.50)$$

Neste exemplo, $N = N_d - 2$. A decomposição do mapeamento linear global em um conjunto de modelos lineares é baseada na interpretação geométrica do problema de regressão. A função não-linear desconhecida $y \approx f(x)$ representa uma superfície no espaço produto: $(X \times Y) \subset \mathbb{R}^{p+1}$. Esta é chamada superfície de regressão.

Os dados disponíveis representam uma amostra da superfície de regressão. Pelo agrupamento dos dados, modelos lineares locais podem ser encontrados para aproximar a superfície de regressão. O conjunto (matriz) de dados a ser agrupado, denotado por \mathbf{Z} , é construído pela concatenação da matriz de dados do regressor \mathbf{X} com a variável dependente \mathbf{y} :

$$\mathbf{Z}^T = [\mathbf{X}, \mathbf{y}]. \quad (3.51)$$

Este conjunto de dados é um subconjunto do produto cartesiano de $X \times Y$, definido por uma relação funcional não-linear dada pela Equação 3.46:

$$\mathbf{Z} \subset X \times Y \text{ tal que } y \approx f(\mathbf{X}) \quad (3.52)$$

O conjunto de dados \mathbf{Z} é particionado em subconjuntos nebulosos pelo algoritmo de agrupamento capaz de detectar as sub-estruturas lineares nos dados.

As pertinências de cada amostra nos agrupamentos são descritas pela matriz de partição nebulosa. Cada agrupamento é caracterizado por seu centro e pela sua matriz de covariância, a qual representa a variância dos dados no cluster. O algoritmo de agrupamento \mathcal{C} pode ser tratado pelo mapeamento $\mathcal{C} : (Z \times \mathbb{N}) \leftarrow (M_{fc} \times \mathbb{R}^{n \times c} \times PD^n)$:

$$(\mathbf{U}, \mathbf{V}, \mathbf{F}) = \mathcal{C}(\mathbf{Z}, c | \mathbf{U}^0, m, \epsilon), \quad (3.53)$$

onde c é o número de agrupamentos, \mathbf{U}^0 é a matriz de partição inicial e m, ϵ são parâmetros do algoritmo de agrupamento, observar a Seção 3.6. A matriz de partição \mathbf{U} contém os graus de pertinência dos dados no agrupamento com o vetor de protótipos \mathbf{V} .

A matriz de covariância \mathbf{F}_i cobre a informação sobre a forma e orientação do i -ésimo agrupamento. O j -ésimo autovalor e o j -ésimo autovetor de \mathbf{F}_i são denotados por λ_{ij} e ϕ_{ij} respectivamente. Os autovalores da matriz de covariância \mathbf{F}_i são arranjados tal que:

$$\lambda_{i1} \geq \lambda_{i2} \geq \dots \lambda_{in}, \quad (3.54)$$

e os autovetores são denominados correspondentemente. Os autovalores ϕ_{i1} até ϕ_{in-1} estendem o i -ésimo subespaço linear do agrupamento e o n -ésimo autovetor ϕ_{in} é a normal do subespaço linear. Uma vez que λ_{in} é o menor autovalor, ϕ_{in} é chamado de menor autovetor.

3.9 Construção de modelos a partir das partições nebulosas

Como mostrado na Seção anterior, um algoritmo de agrupamento nebuloso pode ser aplicado para aproximar um conjunto de dados por modelos lineares. Cada agrupamento nebuloso representa uma

partição do espaço e para esta região do espaço será determinado um modelo linear. A partição costuma ser representada por uma função multivariada, denominada função de pertinência, para facilitar a utilização computacional do modelo evitando a utilização de uma base de dados com dimensões elevadas. As funções lineares são obtidas na seqüência finalizando o procedimento de construção do modelo nebuloso. Esta seção apresenta as técnicas para a construção de modelos nebulosos TS a partir das partições obtidas pelo agrupamento do produto dos espaços.

3.9.1 Geração das funções de pertinência do antecedente

As funções de pertinência do antecedente podem ser obtidas através de uma técnica de projeção dos agrupamentos nebulosos nos eixos de cada variável para posteriormente se ajustar uma função multivariada para representar cada uma destas projeções.

3.9.1.1 Projeção ortonormal nos eixos

Este método projeta a matriz de partição nebulosa sobre os eixos das variáveis antecedentes x_j , $i \leq j \leq p$, como mostra a Figura 3.6. A projeção ortonormal, como pode ser observado na Figura 3.6, permite obter uma interpretação direta das regras, para modelos nebulosos do tipo Mamdani. A interpretação das projeções, no caso dos modelos TS pode ser vista na Figura 3.7.

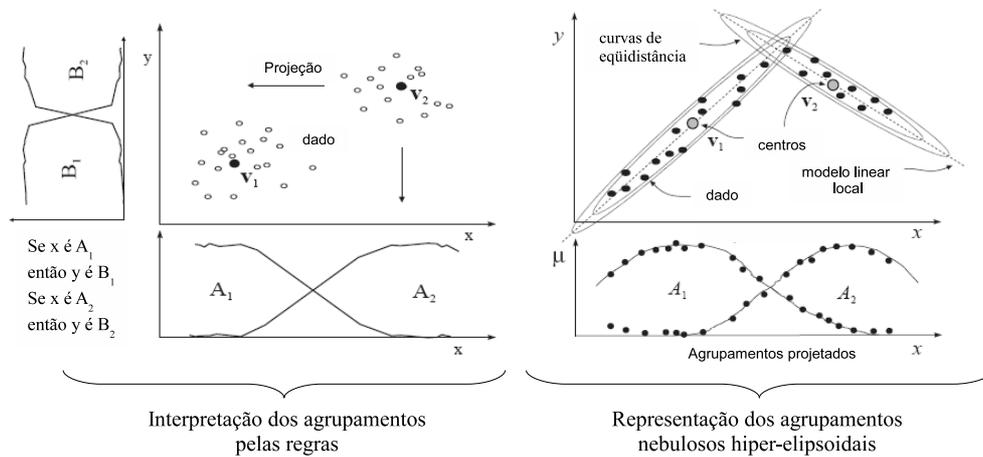


Fig. 3.6: Identificação pelo método de agrupamentos.

As regras TS são então expressas na forma:

$$R_i : \text{Se } x_1 \text{ é } A_{i1} \text{ e } \dots \text{ e } x_p \text{ é } A_{ip} \text{ então } y_i = a_i^T \mathbf{x} + b_i, \quad i = 1, \dots, K, \quad (3.55)$$

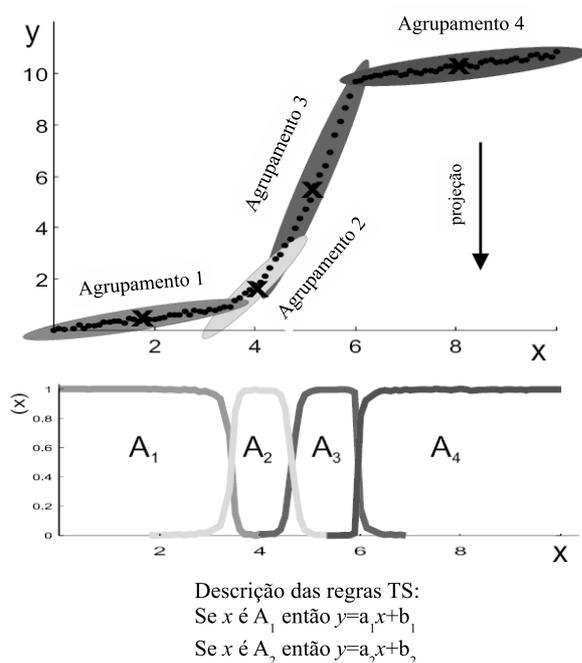


Fig. 3.7: Interpretação das projeções ortonormais para um modelo nebuloso TS

Para obter as funções de pertinência para os conjuntos nebulosos A_{ij} , o conjunto nebuloso multidimensional definido pontualmente na i -ésima linha da matriz de partição é projetado sobre os regressores x_j por:

$$\mu_{A_{ij}}(x_{jk}) = \text{proj}_j(\mu_{ik}). \quad (3.56)$$

A definição do operador de projeção está no Apêndice A na Seção A.1.6. A partir do conjunto nebuloso A_{ij} ajusta-se uma função paramétrica para se sobrepôr aos conjuntos com algum algoritmo de otimização. A função paramétrica passa a representar os conjuntos nebulosos como na Equação 3.55, como mostra a Figura 3.8, simplificando a quantidade de dados armazenados na base de dados do modelo nebuloso.

Quando se calcula o grau de preenchimento $\beta_i(\mathbf{x})$ da i -ésima regra, o agrupamento original no produto dos espaços antecedente é reconstruído ao aplicar o operador de intersecção no produto cartesiano das variáveis antecedente:

$$\beta_i(\mathbf{x}) = \mu_{A_{i1}}(x_1) \wedge \mu_{A_{i2}}(x_2) \wedge \dots \wedge \mu_{A_{ip}}(x_p) \quad (3.57)$$

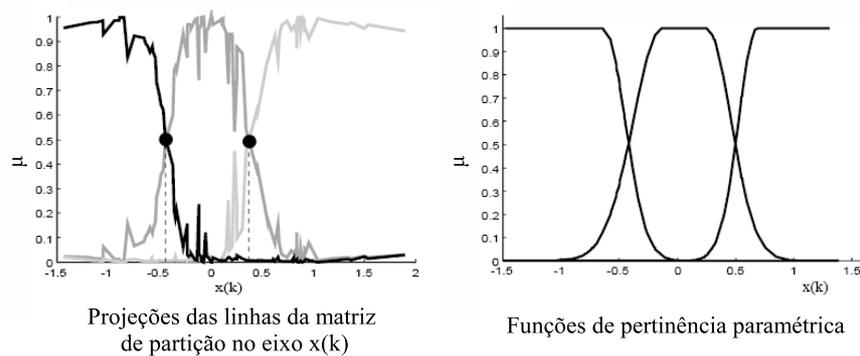


Fig. 3.8: Funções de pertinência obtidas diretamente da projeção ortonormal nos eixos versus a função multivariada parametrizada

Esta reconstrução não é geralmente exata, e leva a erros na decomposição no caso onde os agrupamentos são oblíquos aos eixos, como os obtidos pelo algoritmo GK, como pode ser observado na Figura 3.9 onde a área clara dentro do retângulo corresponde ao agrupamento original.

Além do fato de que através da projeção ortonormal dos eixos alguma informação pode ser perdida, este método é útil, na medida que provê a possibilidade de interpretar o modelo usando os regressores diretamente.

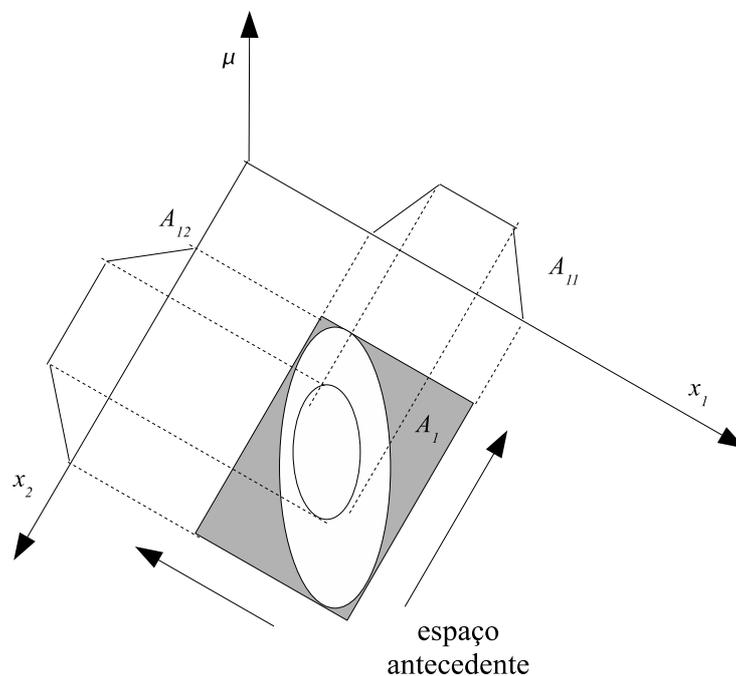


Fig. 3.9: Erro na reconstrução do agrupamento nebuloso

3.9.1.2 Projeção dos autovalores.

O erro gerado pelo método da projeção ortonormal na reconstrução do agrupamento nebuloso, o erro da decomposição, pode ser reduzido através da projeção dos autovetores da matriz de covariância de cada agrupamento, que fornece informações sobre a orientação deste agrupamento. Vamos denotar por F^x a partição da matriz de covariância do agrupamento, correspondente ao regressor x :

$$F^x = [f_{ij}], \quad 1 \leq i, j \leq p, \quad (3.58)$$

onde p é a dimensão do regressor x . Os autovetores unitários de F^x constituem uma base ortonormal orientada nas direções dos eixos do agrupamento elipsoidal. A matriz de regressão X é projetada sobre estas novas bases por:

$$X'_i = XH_i, \quad (3.59)$$

onde $H_i \in \mathfrak{R}^{p \times p}$ é a matriz de projeção tendo os autovetores unitários de F^x_i em suas colunas. Em geral, cada agrupamento vai ter sua própria matriz de projeção. Conseqüentemente, cada regra vai ter variáveis antecedentes diferentes, calculadas como uma combinação linear dos regressores:

$$R_i : \text{Se } x'_{i1} \text{ é } A_{i1} \text{ e } \dots \text{ e } x'_{ip} \text{ é } A_{ip} \text{ então } y_i = a_i^T x'_i + b_i, \quad i = 1, \dots, K. \quad (3.60)$$

Esta transformação é similar a análise de componentes principais, e pode ser vista como um tipo de pré-processamento de dados para cada regra, como esta ilustrado na Figura 3.10.

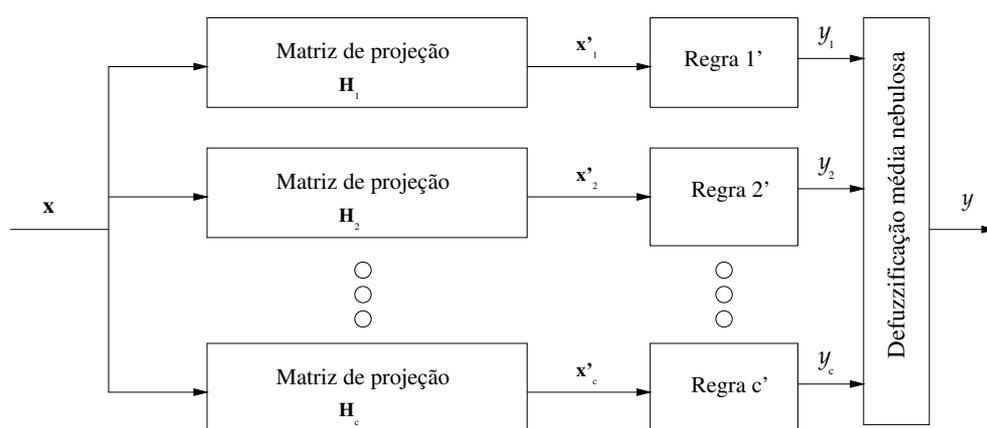


Fig. 3.10: Para cada regra i a matriz H_i transforma o antecedente original

3.9.1.3 Parametrização da função de pertinência

A projeção da i -ésima linha μ_i da matriz de partição nebulosa \mathbf{U} sobre o eixo da variável antecedente x_j , é uma definição pontual do conjunto nebuloso A_{ij} para os dados que pertencem à A_{ij} . Para obter um modelo de predição, as funções de pertinência antecedentes devem ser expressas na forma que permita o cálculo computacional dos graus de pertinência mesmo para os dados que não estiverem contidos no conjunto de dados \mathbf{Z} . Isto é alcançado pelo mapeamento do conjunto A_{ij} por alguma função paramétrica adequada que depois de ajustada será a função de pertinência para A_{ij} .

A função de pertinência exponencial por partes (Apêndice A.4), por exemplo, é adequada para a representação acurada das formas dos agrupamentos. Esta função é ajustada de forma a envolver a projeção dos dados por algum algoritmo de otimização que modifica os seus parâmetros. A vantagem deste método sobre uma função multidimensional, descrita a seguir, é que a função de pertinência projetada pode sempre ser aproximada tal que conjuntos nebulosos convexos sejam obtidos.

Uma desvantagem da projeção dos autovetores é que a interpretação dos antecedentes das regras é perdida pela transformação linear dos regressores originais pelas novas variáveis x'_i . De qualquer forma, a projeção dos autovetores pode levar à redução da dimensão do antecedente, e fornecer informações sobre a natureza das não-linearidades do sistema nos casos quando todos ou alguns dos autovetores são iguais. Neste caso, a projeção global da matriz \mathbf{H} é obtida, a qual sugere uma nova estrutura de modelo com a transformação das variáveis antecedentes.

3.9.1.4 Funções de pertinência do antecedente multidimensionais

Nesta abordagem, as funções de pertinência do antecedente são representadas analiticamente pela computação da inversa da distância do agrupamento protótipo. Os graus de pertinência são computados diretamente para todo o vetor de entrada (sem decomposição). Os antecedentes das regras TS são simplesmente proposições com conjuntos nebuloso multidimensionais dados pela Equação 3.26, e $\beta_i = \mu_{A_i}(x)$.

Relembrando que $\mathbf{F}^x = [f_{ij}]$, $1 \leq i, j \leq p$, inclui todas menos a última coluna da matriz de covariância do agrupamento, a correspondente matriz normalizada é dada por:

$$A_i^x = [\rho_i \det(\mathbf{F}_i^x)]^{1/p} (\mathbf{F}_i^x)^{-1}. \quad (3.61)$$

Tomando a projeção do centro do agrupamento $\mathbf{v}_i^x = [v_{i1}, \dots, v_{ip}]^T$ em X . A norma do produto interno

$$D_{A_i^x} = (\mathbf{x} - \mathbf{v}_i^x)^T \mathbf{A}_i^x (\mathbf{x} - \mathbf{v}_i^x). \quad (3.62)$$

mede a distância do vetor antecedente \mathbf{x} ao centro do agrupamento \mathbf{v}_i^x . Para transformar a distância em um grau de pertinência, algum tipo de inversão deve ser aplicada.

Esta abordagem não formaliza uma função explícita, como as funções paramétricas e necessita de um esforço computacional extra para determinar o grau de preenchimento das regras.

3.9.2 Estimando os parâmetros do conseqüente

Existem vários métodos para se obter os parâmetros do conseqüente. Baseando-se na interpretação geométrica do modelo TS, os parâmetros do conseqüente podem ser diretamente computados a partir dos protótipos dos agrupamentos e dos menores autovetores das matrizes de covariância dos agrupamentos, no caso dos agrupamentos obtidos pelo Algoritmo GK. Este método supõe que os erros estão presentes tanto nos regressores quanto na variável dependente, e corresponde a solução de mínimos quadrados total das linearizações locais em torno dos centros dos agrupamentos, como será apresentado nesta seção.

Um conjunto de parâmetros ótimos com respeito a saída do modelo também pode ser estimado a partir do conjunto dos dados de identificação pelo método de mínimos quadrados. Esta abordagem pode ser formulada como um problema de minimização do total dos erros de predição usando a fórmula da defuzzificação TS, Equação 3.73 ou minimizando os erros de predição de cada modelo local individualmente, resolvendo um conjunto c de problemas de mínimos quadrados ponderado independentes. Se o modelo deve servir como um preditor, o método de mínimos quadrados global é usualmente preferido, por obter o erro mínimo de predição.

3.9.2.1 Computando os parâmetros do conseqüente pelo método de mínimos quadrados total.

Os parâmetros do conseqüente a_i e b_i do modelo TS afim 3.26 podem ser obtidos da estrutura geométrica dos agrupamentos. Suponha que a coleção de agrupamentos c aproxima a superfície de regressão. Estes agrupamentos podem ser aproximados considerando subespaços lineares p -dimensionais. O autovetor ϕ_{in} , corresponde ao menor autovalor λ_{in} , que determina um vetor normal para o hiperplano expandido pelos autovetores remanescentes daquele agrupamentos (Figura 3.11).

Para simplificar a notação, o menor autovetor do i -ésimo agrupamento será denotado por ϕ_i , omitindo o subscrito n . Relembrando que $\mathbf{z}^T = [\mathbf{x}^T, y]$ é o vetor de dados e \mathbf{v}_i é o protótipo do

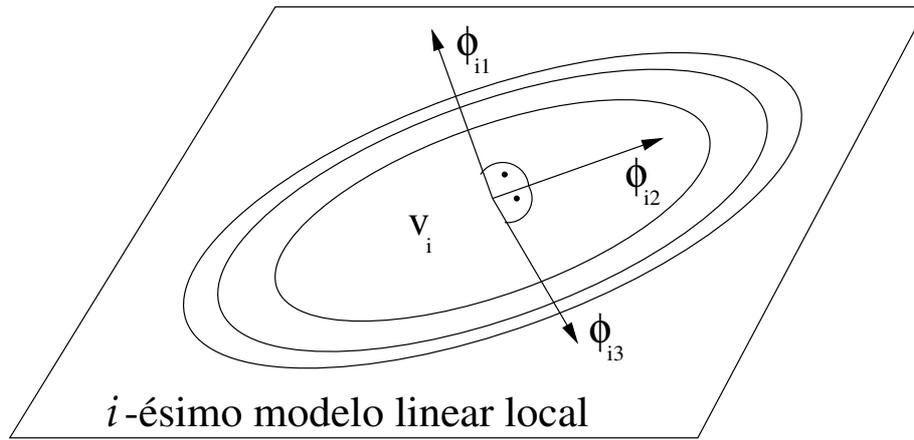


Fig. 3.11: A posição e a orientação do i -ésimo modelo linear local

agrupamento, a forma normal implícita do hiperplano do conseqüente é dada por:

$$\phi_i^T (\mathbf{z} - \mathbf{v}_i) = 0. \quad (3.63)$$

Esta expressão estabelece que o produto interno do vetor normal ϕ_i com qualquer vetor pertencendo ao hiperplano é igual a zero. Para a seguinte discussão, é conveniente a partição do protótipo \mathbf{v}_i em um vetor \mathbf{v}_i^x correspondendo ao regressor \mathbf{x} , e um escalar v_i^y correspondente a variável dependente y : $\mathbf{v}_i^T = [(\mathbf{v}_i^x)^T, v_i^y]$. O menor autovetor é particionado da mesma forma como o centro do agrupamento, p.e.: $\phi_i^T = [(\phi_i^x)^T, \phi_i^y]$. A Equação 3.63 pode agora ser escrita como:

$$[(\phi_i^x)^T, \phi_i^y][\mathbf{x}^T, y]^T - [(\mathbf{v}_i^x)^T, v_i^y] = 0 \quad (3.64)$$

Aplicando o produto interno resulta na seguinte igualdade:

$$(\phi_i^x)^T (\mathbf{x} - \mathbf{v}_i^x) + \phi_i^y (y - v_i^y) = 0 \quad (3.65)$$

a partir da qual, pela manipulação algébrica, se obtém uma equação explícita para o hiperplano:

$$y = \underbrace{\frac{-1}{\phi_i^y} (\phi_i^x)^T}_{\mathbf{a}_i^T} \mathbf{x} + \underbrace{\frac{1}{\phi_i^y} \phi_i^T \mathbf{v}_i}_{b_i}. \quad (3.66)$$

Comparando a equação acima com o conseqüente afim da regra da Equação 3.26, as equações de \mathbf{a}_i^T e b_i são obtidas diretamente:

$$\mathbf{a}_i = \frac{-1}{\phi_i^y} \phi_i^x = \frac{-1}{\phi_{ip+1}^y} [\phi_{i1}, \phi_{i2}, \dots, \phi_{ip}]^T, \quad (3.67a)$$

$$b_i = \frac{1}{\phi_i^y} \phi_i^T \mathbf{v}_i. \quad (3.67b)$$

Mesmo que estas equações tenham sido derivadas de maneira intuitiva a partir da interpretação geométrica dos agrupamentos, pode ser mostrado que \mathbf{a}_i , dado pela Equação 3.67a, é obtida como solução do problema de mínimos quadrados ponderado total definido nas proximidades do centro do agrupamento \mathbf{v}_i . Os pesos são os graus de pertinência contidos na i -ésima linha da matriz de partição nebulosa. Então \mathbf{v}_i pode ser visto como um ponto de operação local do modelo. Para obter o modelo da forma linear afim usado nas regras TS (Equação 3.26), o parâmetro de polarização b_i é calculado usando as estimativas de \mathbf{a}_i e do centro do agrupamento \mathbf{v}_i . Isto é mostrado no Apêndice A.2 onde se obtêm uma expressão equivalente a Equação 3.67b.

3.9.2.2 Estimando os parâmetros do consequente com o método de mínimos quadrados ordinário

Existem duas abordagens para estimar os parâmetros do consequente \mathbf{a}_i, b_i pela técnica ordinária de mínimos quadrados:

1. Solucionar c problemas independentes de mínimos quadrados ponderado, um para cada agrupamento. Esta abordagem é independente do método de defuzzificação usado, como este estima os parâmetros para cada modelo separadamente.
2. Solucionar o problema de mínimos quadrados global a partir da fórmula de defuzzificação de média ponderada (Equação 3.73). Esta abordagem resulta no preditor com o erro mínimo.

Os dados de identificação e os graus de pertinência das partições nebulosas são arranjados nas seguintes matrizes:

$$\mathbf{X} = \begin{bmatrix} \mathbf{x}_1^T \\ \mathbf{x}_2^T \\ \vdots \\ \mathbf{x}_N^T \end{bmatrix}, \quad \mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix}, \quad \mathbf{W}_i = \begin{bmatrix} \mu_{i1} & 0 & \dots & 0 \\ 0 & \mu_{i2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \mu_{iN} \end{bmatrix}. \quad (3.68)$$

Os parâmetros do conseqüente da regra pertencendo ao i -ésimo agrupamento, \mathbf{a}_i e b_i são concatenados em um único vetor de parâmetros θ_i :

$$\theta_i = [\mathbf{a}_i^T, b_i]^T. \quad (3.69)$$

Adicionando uma coluna unitária a \mathbf{X} resulta na extensão da matriz de regressão \mathbf{X}_e :

$$\mathbf{X}_e = [\mathbf{X}, 1]. \quad (3.70)$$

3.9.2.3 Um conjunto de problemas de mínimos quadrados ponderado

Supondo que cada agrupamento represente um modelo linear local do sistema, os vetores de parâmetros do conseqüente $\theta_i, i = 1, 2, \dots, c$, podem ser estimados independentemente pelo método de mínimos quadrados ponderado. Os graus de pertinência $\mu_{i,k}$ da matriz de partição nebulosa servem como pesos expressando a relevância do par de dados (\mathbf{x}_k, y_k) para o modelo local. Se as colunas de \mathbf{X}_e são linearmente independentes e $\mu_{i,k} > 0$ para $1 \leq k \leq N$, então

$$\theta_i = [\mathbf{X}_e^T \mathbf{W}_i \mathbf{X}_e]^{-1} \mathbf{X}_e^T \mathbf{W}_i \mathbf{y} \quad (3.71)$$

é a solução de mínimos quadrados de $\mathbf{y} = \mathbf{X}_e \theta + \epsilon$, onde o k -ésimo par de dados (\mathbf{x}_k, y_k) é ponderado pelo $\mu_{i,k}$. Os parâmetros \mathbf{a}_i e b_i são dados por:

$$\mathbf{a}_i = [\theta_1, \theta_2, \dots, \theta_p], \quad b_i = \theta_{p+1}. \quad (3.72)$$

3.9.2.4 Método de mínimos quadrados global

A abordagem do método de mínimos quadrados ponderado resulta numa estimativa ótima dos parâmetros dos modelos locais, mas não resulta em um modelo TS ótimo em termos do mínimo erro de predição. Para obter um preditor global ótimo, a agregação das regras tem que ser levada em conta. Quando estamos usando a formula de defuzzificação da média nebulosa:

$$y = \frac{\sum_{i=1}^K \beta_i(\mathbf{x}) [\mathbf{a}_i^T \mathbf{x} + b_i]}{\sum_{i=1}^K \beta_i(\mathbf{x})}, \quad (3.73)$$

os parâmetros do conseqüente podem ser estimados resolvendo o problema de mínimos quadrados. O grau de preenchimento da i -ésima regra β_{ik} é obtido a partir da matriz de partição \mathbf{U} , mas a situação é ligeiramente mais complicada do que no caso da abordagem dos mínimos quadrados ponderado locais. Relembrando que cada linha da matriz \mathbf{U} contem a definição pontual da função de pertinência dos dados no produto dos espaços $X \times Y$, para obter uma definição pontual da função de pertinência A_i no espaço antecedente X , a i -ésima linha de \mathbf{U} tem de ser projetada sobre o espaço antecedente:

$$\beta_{ik} = \text{proj}_{N_p}(\mu_{ik}), \quad k = 1, \dots, N, \quad (3.74)$$

onde proj denota o operador de projeção (Apêndice A.1.6). O resultado desta projeção é que um conjunto de vetores repetidos \mathbf{x}_k nos dados são designados pelo grau máximo de pertinência a partir deste conjunto. Outra possibilidade é calcular os graus de preenchimento depois gerar as funções de pertinência do antecedente, as quais podem particularmente compensar o erro da decomposição.

Para obter a Equação 3.73 na forma matricial, todos os N pares de dados e os graus de pertinência normalizados de cada regra (Equação 3.33) são arranjados nas seguintes matrizes.

$$\mathbf{X} = \begin{bmatrix} \mathbf{x}_1^T \\ \mathbf{x}_2^T \\ \vdots \\ \mathbf{x}_N^T \end{bmatrix}, \quad \mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix}, \quad \mathbf{\Gamma}_i = \begin{bmatrix} \gamma_{i1} & 0 & \dots & 0 \\ 0 & \gamma_{i2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \gamma_{iN} \end{bmatrix}, \quad i = 1, \dots, c. \quad (3.75)$$

A matriz denotada por \mathbf{X}' em $\mathbb{R}^{N \times cN}$ é composta a partir das matrizes $\mathbf{\Gamma}_i$ e \mathbf{X}_e

$$\mathbf{X}' = [\mathbf{\Gamma}_1 \mathbf{X}_e, \mathbf{\Gamma}_2 \mathbf{X}_e, \dots, \mathbf{\Gamma}_c \mathbf{X}_e], \quad (3.76)$$

onde \mathbf{X}_e é dado pela Equação 3.70. Denota-se θ' o vetor em $\mathbb{R}^{c(p+1)}$ dado por

$$\theta' = [\theta_1^T, \theta_2^T, \dots, \theta_c^T]^T, \quad (3.77)$$

onde $\theta_i = [\mathbf{a}_i^T, b_i]^T$ para $1 \leq i \leq c$. O problema de mínimos quadrados resultante, $\mathbf{y} = \mathbf{X}'\theta' + \epsilon$, tem a solução:

$$\theta' = [(\mathbf{X}')^T \mathbf{X}']^{-1} (\mathbf{X}')^T \mathbf{y}. \quad (3.78)$$

A partir da Equação 3.77 os parâmetros \mathbf{a}_i e b_i são obtidos por:

$$\mathbf{a}_i = [\theta'_{q+1}, \theta'_{q+2}, \dots, \theta'_{q+p}] \quad b_i = [\theta_{q+p+1}], \quad \text{com } q = (i - 1)(p + 1). \quad (3.79)$$

O método dos mínimos quadrados global resulta no preditor de erro mínimo, e é adequado para derivar modelos de predição. Para o propósito de interpretação local e análises do modelo TS, é preferível a abordagem de mínimos quadrados ponderado.

Capítulo 4

Modelagem e Identificação da Cana-de-açúcar

4.1 Introdução

Neste capítulo são abordados tópicos referentes a teoria de modelagem e identificação de sistemas aplicados à agricultura. As principais definições teóricas, referentes as áreas de modelagem e identificação, são apresentadas. Aborda-se as classes de modelos principalmente utilizadas em modelagem agrícola. Serão introduzidos os conceitos e as metodologias básicas de identificação de sistemas e de sistemas nebulosos que são utilizados neste trabalho.

4.2 Modelagem dos sistemas agrícolas

A modelagem de sistemas agrícolas é importante por oferecer uma forma prática para incorporar os resultados da experimentação agrícola, compactando um amplo conjunto de informações, servindo assim, como um meio de transmissão de tecnologia. Os modelos podem ser implementados através de programas que possam ser utilizados por agricultores, pesquisadores e agroindústrias. As simulações computacionais permitem avaliar várias condições de produção agrícola considerando várias condições ambientais possíveis. As simulações da produção, considerando várias condições ambientais, permitem ao produtor determinar as melhores culturas e formas de manejo para reduzir os prejuízos devido a condições adversas de cultivo. Além disso, os modelos agrícolas permitem determinar os riscos envolvidos para as culturas em cada região agrícola auxiliando o planejamento de políticas

públicas de seguros.

4.2.1 Definição de modelo

Neste trabalho entende-se como modelo a representação matemática de um sistema “ *Em outros contextos o “modelo” não precisa ser matemático, como por exemplo, a maquete de um prédio. Por ser um análogo matemático do sistema, espera-se que o modelo seja representativo das principais características do sistema real. No contexto da identificação, o modelo é aquilo obtido para representar o sistema real.*”(AGUIRRE, 2000).

O objetivo deste trabalho é determinar um modelo para a predição a um passo a frente dos processos de acumulação de biomassa e de açúcar da cana-de-açúcar. O sistema que está sendo modelado é, então, a cana-de-açúcar. As variáveis desse sistema sobre as quais desejamos obter um modelo são:

- a massa acumulada de biomassa, ou fibra, dos colmos

- a massa acumulada de açúcar dos colmos e
 - a massa seca acumulada total dos colmos.

As variáveis da massa acumulada pelo colmo foram escolhidas por serem as de maior interesse para o setor sucroalcooleiro. A massa seca acumulada total dos colmos foi colocada como um sub-item da acumulação de fibra e de açúcar, pois, o peso seco total dos colmos da cana-de-açúcar é principalmente composto de fibra e açúcar, como foi visto na Seção 2.1.1.3. Contudo, este trabalho irá inicialmente aplicar o procedimento de identificação considerando os dados da massa seca acumulada total, devido a maior quantidade de dados disponíveis, como será mostrado no Capítulo 5.

A determinação da estrutura matemática e dos parâmetros do modelo é realizada exclusivamente considerando-se o conjunto de dados de entrada/saída do sistema, caracterizando-se o procedimento de identificação do tipo caixa preta, (AGUIRRE, 2000). As técnicas para obter (identificar) modelos de sistemas dinâmicos, a partir do conjunto de dados do sistemas, foram estudadas, implementadas computacionalmente e utilizadas neste trabalho.

O procedimento de identificação aqui utilizado está descrito com maiores detalhes na seção 4.5.

4.2.2 Complexidade dos sistemas agrícolas

Os sistemas agrícolas são caracterizados por terem vários níveis organizacionais, Tabela 4.1. Assim como o sistema político é organizado em níveis hierárquicos como governo federal, governo estadual e governo municipal, os sistemas agrícolas são organizados, partindo de um componente individual, como uma simples célula vegetal ou animal, subindo na hierarquia até fazendas ou uma região agrícola completa. Um vez que todo sistema agrícola está baseado na produção vegetal, sendo então, composto por plantas, o nível de maior interesse para o modelamento de sistemas agrícolas é a planta. Modelos para representar as reações e interações de tecidos e órgãos da planta são combinados para formar uma modelo global da planta. Posteriormente este modelo é extrapolado para níveis hierárquicos superiores, como para uma fazenda. Estendendo este conceito de níveis hierárquicos para um modelo de cana-de-açúcar, obtêm-se uma estrutura conforme a Tabela 4.1.

Nível	Descrição do nível
...	...
...	Fazenda
...	...
i+1	Coleção de organismos (cultura)
i	Organismo (planta)
i-1	Orgãos (folhas, colmos,...)
...	Células
...	...
...	Nutrientes
...	...

Tab. 4.1: Níveis hierárquicos de organização

Mesmo depois de definidos os limites do sistema para focar a planta, deve-se integrar conhecimentos de um amplo espectro de disciplinas como biologia, física, química, economia e matemática, e especificar interações de diferentes naturezas, chamadas, físicas (por exemplo: clima, radiação, e umidade no solo), químicas (por exemplo: concentração de CO_2 , nutrientes), biológicas (por exemplo: pragas, doenças e ervas daninhas). A complexidade do sistema é aumentada pelas variabilidades espaciais¹ e temporal em termos de características de solo e clima, diversidade genética e uma grande faixa de opções de manejo adotadas nas fazendas. A Figura 4.2 mostra este efeito espacial mostrando falhas do plantio de cana-de-açúcar indicando que deve-se obter uma baixa quantidade de biomassa de colmos por área de cultivo, devido a baixa densidade de plantas. Estas falhas podem ter ocorrido por qualquer um dos fatores mencionados acima.

¹Variabilidade espacial significa que ao longo de uma dada área de cultivo existem variações na composição do solo, curvaturas do terreno e na genética das plantas que refletem em variações da produção ao longo do terreno (BATCHELOR; BASSO; PAZ, 2002)

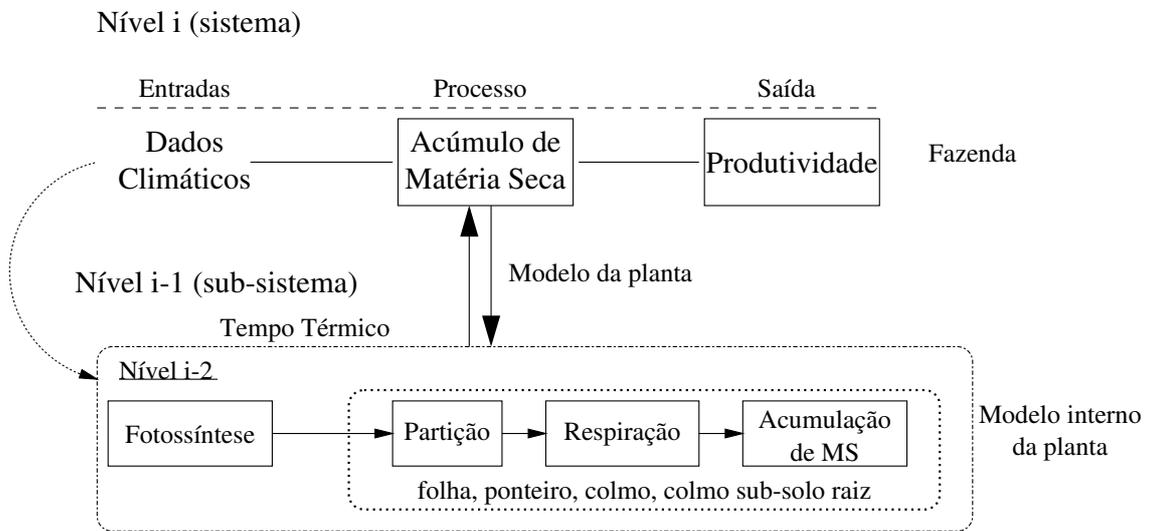


Fig. 4.1: Níveis considerados em um modelo de cana-de-açúcar

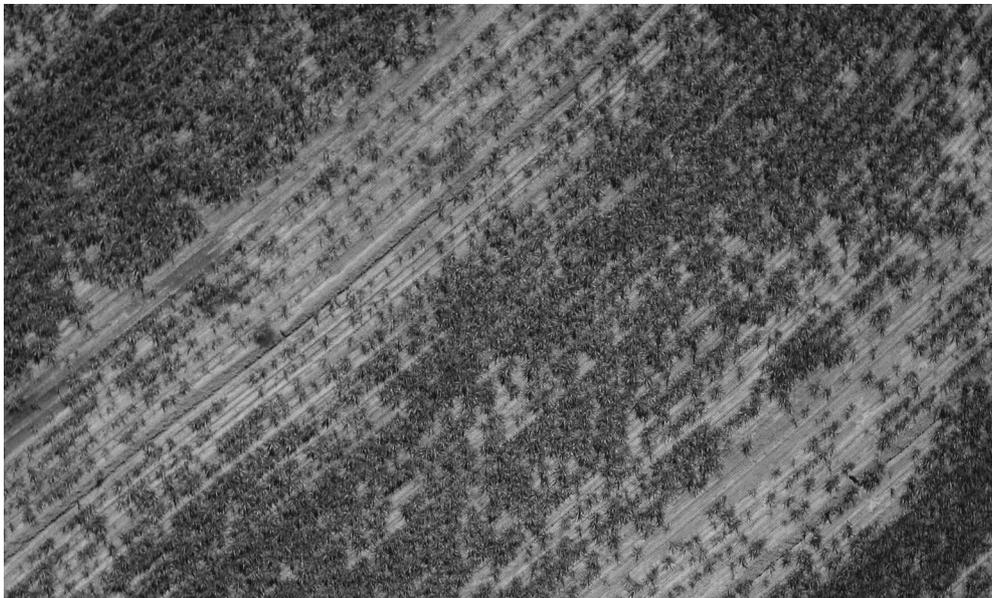


Fig. 4.2: Foto aérea da cultura de cana-de-açúcar mostrando falhas de plantio ao longo do terreno

4.3 Modelos na agricultura

Os modelos agrícolas são equações matemáticas que representam as reações que ocorrem dentro da planta e as interações entre a planta e o meio ambiente. Devido a complexidade deste sistema e ao estado incompleto do conhecimento presente, torna-se impossível representar completamente o sistema em termos matemáticos e por isto, modelos agrícolas são imagens bastante simplificadas da realidade. Ao contrário dos campos da engenharia e da física, modelos universais não existem dentro do setor agrícola.

Modelos são construídos para propósitos específicos e o nível de complexidade adequadamente adotado. Inevitavelmente, diferentes modelos são construídos para diferentes subsistemas e vários modelos podem ser construídos para simular uma cultura em particular ou um aspecto particular do sistema de produção.

4.3.1 Características de modelos de culturas

O principal objetivo da construção de um modelo de cultura é obter uma estimativa da produção que pode ser colhida (econômica). De acordo com a quantidade de dados e conhecimento que estão disponíveis sobre um campo em particular, modelos com diferentes níveis de complexidade são desenvolvidos.

Os modelos desenvolvidos apresentam características semelhantes entre si que permitem agrupá-los em categorias entre as quais destacamos:

- Modelos estatísticos;
- Modelos mecanísticos;
- Modelos estáticos;
- Modelos dinâmicos;
- Modelos determinísticos;
- Modelos estocásticos.

Estas categorias de modelos citadas são as mais utilizadas na modelagem de sistemas agrícolas, e são descritas a seguir. Para maiores informações sobre análise dinâmica de sistemas é indicada a leitura de (BOTTURA, 1982).

4.3.2 Modelos Estatísticos

Modelos estatísticos são descrições diretas a partir de dados observados e são geralmente expressos como equações de regressão e são usados, geralmente, para estimar a produtividade final de determinada cultura. Exemplos destes modelos incluem a resposta da produtividade da cultura para a aplicação de fertilizantes, a relação entre área foliar e tamanho da folha em algumas das espécies de planta e a relação entre altura do colmo sozinho ou acoplado com o número de colmos e/ou diâmetro médio dos colmos e a produtividade final da cana-de-açúcar.

Um procedimento para a modelagem estatística é descrito a seguir:

1. Coletar dados do processo;
2. Especificar a estrutura de correlação entre as variáveis, por exemplo, modelos polinômiais, séries temporais, modelos nebulosos;
3. Usar técnicas numéricas para determinar os parâmetros da estrutura de tal maneira que a correlação do modelo com os dados coletados no Item 1 seja maximizada.
4. Validar o modelo com um conjunto de dados diferente dos utilizados no Item 3 no passo anterior.
5. Retornar para o Item 2, se o modelo não for satisfatório.

A modelagem estatística depende da disponibilidade dos dados para a construção e validação do modelo, não exigindo conhecimento do processo. Este tipo de modelagem utiliza dados de entrada e/ou saída.

Estes modelos são utilizados para interpolação, no entanto deve-se evitar extrapolações. Por exemplo, a relação de uso eficiente da água pela cana-de-açúcar com a produtividade de biomassa pode não se manter sobre condições de restrição de nutrientes.

Os modelos estatísticos são o foco desse trabalho e vamos abordar este procedimento de modelagem formalmente na Seção 4.5.

4.3.3 Modelos Mecanísticos

Modelos mecanísticos são aqueles baseados na compreensão de processos químicos, físicos e biológicos que governam o comportamento do processo, descrevendo o sistema em termos de sub-níveis (modelo interno da planta, Figura 4.1). Os níveis de processo mais baixos (processos mais elementares) também são descritos por modelos.

Os modelos inferiores na hierarquia (abaixo da hierarquia da planta) têm a habilidade de imitar os processos físicos, químicos e biológicos e utilizam leis fundamentais, por exemplo:

- Equações de continuidade, para descrever os processos internos da cana-de-açúcar;
- Equações de balanço que descrevem a conservação de energia, de carbono e hídrica, como no CANEGRO (Figura 4.4).

Um procedimento para a modelagem mecanística é descrito a seguir:

- Usar conhecimentos fundamentais das interações entre as variáveis do processo para definir a estrutura do modelo;
- Executar experimentos para determinar os parâmetros do modelo;
- Coletar dados do processo para validar o modelo;
- Reiniciar o processo e re-examinar o conhecimento do processo, se o modelo não for satisfatório.

A modelagem mecanística utiliza poucos dados para o desenvolvimento do modelo e por exemplo, no caso da cultura da cana-de-açúcar, um modelo mecanístico desenvolvido com dados de uma região experimental pode apresentar resultados satisfatórios para outras regiões, se as constantes dos processos elementares forem adequadamente ajustadas.

A modelagem mecanística, no entanto, requer a compreensão dos processos físicos, químicos e biológicos. Usualmente, um modelo mecanístico para sistemas agrícolas requer o conhecimento sobre uma quantidade elevada de processos elementares relacionados a cultura o que nem sempre é possível, e dessa forma a sua elaboração não é trivial. A maioria dos modelos de cana-de-açúcar estão nesta categoria, contudo, apresentam em sua composição algum modelo de processo mais elementar (modelo de nível inferior, por exemplo partição dos fotossintetizados) obtido de forma estatística.

4.3.4 Modelos mecanísticos versus modelos estatísticos

Os modelos mecanísticos, quando disponíveis, podem fornecer previsões mais realistas, quando o modelamento capturou os processos elementares mais influentes no comportamento do sistema. Por exemplo, um modelo mecanístico, adequadamente constituído e testado, oferece a oportunidade de simular as conseqüências na produtividade, devido a diversas causas, tais como:

- variação da produção de biomassa de colmos de cana-de-açúcar pela quantidade de fertilizante aplicada,
- redução da taxa de irrigação,
- mudanças no índice de absorção radiação solar.

Os modelos estatísticos são obtidos a partir do conjunto de dados entrada/saída e os parâmetros estimados. Diferentemente do modelo mecânico, não é aconselhável realizar simulações fora das condições dos experimentos que geraram o modelo. O projeto de processos, como destiladores, gaseificadores e caldeiras, usualmente, utiliza modelos mecânicos na sua concepção por serem, usualmente, válidos para extrapolações além das condições normais de operação desejada. Os modelos estatísticos são, freqüentemente, usados para o projeto de controle de processos, pois estes modelos costumam conter uma quantidade menor de parâmetros e capturam a essência do comportamento das variáveis de interesse do sistema. O controle baseado em modelos estatísticos necessita que o modelo represente o comportamento do processo com índices de erro dentro das condições de projeto.

O custo da modelagem é outra importante comparação entre as duas abordagens. A modelagem mecânica, devido à complexidade de muitos processos, é onerosa em termos de trabalho e pesquisa. A abordagem da modelagem mecânica exige um exame detalhado dos processos fundamentais do comportamento do modelo. O conhecimento do comportamento do processo dado por uma modelagem mecânica compensa o investimento realizado durante sua elaboração.

Neste trabalho buscamos modelar o processo de acumulação de biomassa, fibra e açúcar da cana-de-açúcar adotando procedimentos estatísticos apresentados nas seções seguintes. A estrutura do modelo nebuloso será o foco das simulações e dos resultados computacionais. Esta estrutura permite explorar as relações causa-efeito entre as variáveis através dos termos lingüísticos associados e da regras através de um sistema de inferência do modelo nebuloso, como apresentada no Capítulo 3.

4.3.5 Modelos Dinâmicos e Estáticos

Modelos estáticos relacionam variáveis sem considerar sua dependência temporal e são normalmente descritos por equações algébricas. Modelos dinâmicos levam em consideração a evolução temporal das variáveis. A representação desses modelos é composta por equações diferenciais (ou, a diferenças para a representação discreta no tempo), podendo incluir equações algébricas. Um sistema real pode ser descrito por um modelo estático quando suas variações no tempo não são relevantes, pois todo sistema real é dinâmico. O modelo estático é útil quando a dinâmica de um sistema esta fora da escala de tempo de interesse.

Uma estrutura geral de um modelo dinâmico pode ser representada por uma equação diferencial:

$$\frac{dy}{dt} = f(y), \quad (4.1)$$

onde: y = um atributo do sistema (matéria seca acumulada ou quantidade de grãos colhidas)

t = variável tempo

f = alguma função, possivelmente de y , t , e outros parâmetros.

A Equação 4.1 é a representação mais comum na modelagem de sistemas agrícolas e indica a taxa de variação de uma variável, como por exemplo o incremento de biomassa de colmo na cana-de-açúcar. O modelo da cultura de cana-de-açúcar envolve um conjunto de equações diferenciais como as apresentadas por Liu (LIU; BULL, 2001), Apêndice B.

A Equação 4.1 pode ser integrada resultando no acumulado das variações do sistema no intervalo de tempo considerado. Para algum intervalo de tempo é possível que a taxa de um sistema torne-se zero tal que a derivada seja zero e dessa forma a função seja zero, e o modelo seja estático para o intervalo de tempo considerado (THORNLEY; FRANCE, 1976).

4.3.6 Modelos Determinísticos e Estocásticos

Modelos determinísticos fornecem um resultado fixo e precisamente reproduzido para um determinado conjunto de entradas. Este tipo de modelo não considera as incertezas presentes em um sistema real. Modelos determinísticos aplicados à sistemas agrícolas são, freqüentemente, descritos por um conjunto de equações diferenciais (caso contínuo). Estes são apropriados quando as proporções do sistema são grandes², e pode-se supor que as variações estatísticas do comportamento do sistema não são significantes, por exemplo, modelo para produção regional onde as variações pontuais de produção pouco alteram os valores médios. Para sistemas biológicos, usualmente, esta suposição não é válida.

Um modelo estocástico é uma representação matemática de uma ou mais variáveis que tem um comportamento aleatório. O termo estocástico vem do grego e significa conjecturar, supor ou adivinhar. Esse termo também é usado como sinônimo de processo aleatório. Um modelo estocástico pode ter diferentes respostas partindo das mesmas condições iniciais diferentemente de um modelo determinístico.

²Um sistema agrícola é considerado grande quando suas dimensões são tão grandes que as variações de produtividade pontuais se cancelam não afetando a média. Por exemplo, na região de Ribeirão Preto, existem 14 usinas e a alteração na produtividade de um talhão em uma usina não altera a produtividade média da região. Isto retrata o problema de escala para a aplicação de um modelo.

Os modelos estocásticos são usados quando as proporções do sistema são pequenas³ ou quando existem razões para esperar eventos inesperados que tenham uma influência importante no comportamento do sistema, como uma nova praga ou um período de seca prolongado. Um modelo estocástico, freqüentemente, é mais apropriado quando se considera a representação discreta das variáveis. Modelos de cultura que trabalham com simuladores climáticos consideram variáveis aleatórias, como por exemplo, ocorrência de chuvas em certas na área de cultivo de cana-de-açúcar.

Nos sistemas agrícolas, as observações das variáveis apresentam dispersões, independentemente, das dimensões das áreas de cultivo envolvidas. Estas dispersões são propriedades intrínsecas de sistemas biológicos. As dispersões das observações são freqüentemente afetadas por inúmeros fatores que não são modelados explicitamente e, no entanto, acabam influenciando o resultado do modelo (BATCHELOR; BASSO; PAZ, 2002). As dispersões das observações podem ser modeladas, no entanto, aumentam a complexidade do modelo o que torna esta modelagem inviável pelo aumento do número de variáveis e pelo custo computacional e de amostragem. O processo de modelagem deve considerar a dificuldade para observar as variáveis do sistema (Figura 4.2), devido a distribuição espacial do sistema.

Um modelo determinístico pode ser utilizado para representar um sistema biológico, ao invés de um modelo estocástico, associando um termo para incorporar os erros das medições das variáveis. Tais modelos são chamados modelos de regressão com erro explícito, ou modelos de regressão de erro na equação, (AGUIRRE, 2000, pg 108):

$$y_i = f(u_i) + \xi_i \quad (4.2)$$

A parte determinística é expressa pela função $f()$ e o termo estocástico é representado como um erro $\bar{\xi}$ associado às variações nas medições, e (y_i, u_i) são as variáveis de saída e de entrada. O termo estocástico, usualmente, é considerado com densidade normal de distribuição, com média zero e variância fixa.

As dispersões podem ser interpretadas como um ruído associado às medidas. Nos sistemas agrícolas estas dispersões vêm do processo de amostragem, devido à variabilidade espacial. As dispersões são associadas a erros nas medidas; usualmente, em sistemas biológicos isto não é válido pois, as variações nos dados são muito maiores que a incerteza relativa ao processo de amostragem, (BATCHELOR; BASSO; PAZ, 2002).

³Um sistema agrícola é considerado pequeno quando a variação das parcelas que o compõem altera a sua produtividade média da usina. Por exemplo, numa fazenda composta por cinco talhões idênticos, a alteração na produtividade de apenas um talhão altera a produtividade média da fazenda.

Modelos estocásticos que consideram as dispersões dos dados para sistemas agrícolas são sofisticados e estão em fase inicial de estudos, (ASSIS, 2004).

4.3.7 Simulação e otimização de modelos

A partir de dados de entrada/saída de processos de sistemas agrícolas são desenvolvidos modelos matemáticos que são utilizados para simulação destes processos. Na modelagem agrícola estes modelos são usualmente determinísticos e mecânicos.

Aplicações que exigem ajustes de longo prazo na agricultura, competição regional, estudos de transportes, sistemas integrados de produção e distribuição, políticas de seguros, adoção de tecnologia, reestruturação industrial e recursos naturais utilizam técnicas de programação linear e não-linear.

No entanto a otimização de modelos não permite a incorporação de detalhes biológicos e é pobre na representação da realidade. A abordagem de simulação utilizando dados de entrada/saída de sistemas agrícolas tem sido reportada como uma opção viável em relação aos modelos de otimização.

Os modelos agrícolas utilizam em suas simulações aspectos da variabilidade relacionados com as variações do solo e do clima. Uma característica da modelagem de sistemas agrícolas é a necessidade de uma grande quantidade de dados de entrada disponíveis para sua elaboração, calibração e simulação. Os modelos agrícolas oferecem a possibilidade de simular opções de manejo, por exemplo adubação em períodos diversos do plantio, possibilitando adotar a estratégia de gerenciamento mais produtiva a baixo custo em relação a experimentação convencional. A maioria dos modelos agrícolas que são usados para estimar a produtividade de safra estão nesta categoria.

4.4 Modelagem mecânica aplicada à cana-de-açúcar

A agroindústria sucroalcooleira utiliza modelos em diversas aplicações. Dentre as aplicações relacionadas com a produção de cana-de-açúcar se destacam:

- na área de bioquímica: a utilização de modelos para simular as reações bioquímicas da planta, como a armazenagem da sacarose;
- na área de agronomia: a utilização de modelos para estimar a resposta da cultura à diferentes manejos;

- na área de fisiologia: a utilização do modelamento para caracterizar o desenvolvimento e a interação dos componentes da planta mediante os fatores ambientais;
- na área de manejo de pragas: a utilização de modelo para simular o desenvolvimento e disseminação de pragas, caracterizando os fatores potencializadores de pragas, para traçar estratégias de controle.

A acumulação de sacarose é afetada pela variação climática ano-a-ano e local-a-local, pelas práticas de manejo e pelo solo. A melhoria da precisão e da exatidão dos resultados computacionais para esta variável são de grande interesse agrícola, (ROBERTSON; MUCHOW, 1994). O melhoramento da precisão e da exatidão da predição da acumulação de sacarose irá melhorar a eficiência da colheita e moagem de cana-de-açúcar pela indústria, (CESAR; SILVA, 1993b).

Existem dois principais modelos de simulação de cana-de-açúcar correntemente em uso através do mundo, excluindo os numerosos modelos de regressão utilizados em locais específicos de estudo. Os modelos são:

- APSIM (*Agricultural Production System sIMulator*)- *sugarcane*, modelo desenvolvido pela unidade de pesquisa de sistemas de produção agrícola CSIRO (*Commonwealth Scientific and Industrial Research Organisation*) (O'LEARY et al., 1999).
- CANEGRO (*sugarCANE GROwth model*) desenvolvido pela associação sul africana do açúcar (INMAN-BAMBER, 1995). O modelo CANEGRO foi incluído no Sistema para Suporte a Decisão de Transferência de Agrotecnologia ("*Decision Support System for Agrotechnology Transfer, DSSAT version 3.1*"); uma plataforma computacional (*suite* - conjunto de aplicativos) de modelos, e assim, o CANEGRO Versão 3.1 tem sido usado através das Américas, da África e da Ásia.

Estes dois modelos são desenvolvidos independentemente e têm origens similares baseadas em antigos modelos; maiores detalhes sobre estes modelos estão apresentados nas seções a seguir. Existe outro modelo menos difundido que vem sendo desenvolvido recentemente na Austrália: QCANE (Q é das duas variedades de Queensland, Austrália simuladas por este modelo Q138 e Q141 e CANE vêm de *sugarCANE*), (LIU; KINGSTONE, 1994; LIU; BULL, 2001) que partiu da base conceitual de (BULL; TOVEY, 1974). Este modelo tem características interessantes quando comparado com o CANEGRO e o APSIM.

4.4.1 A história dos modelos e seus conceitos

4.4.1.1 O modelo de simulação APSIM-sugarcane

O APSIM é formado por um conjunto de programas modulares, onde cada módulo simula uma parte do sistema agrícola, como por exemplo, um simulador de erosão, um simulador do ciclo de nitrogênio entre outros. Dessa forma cada módulo é formado pelos modelos referentes a cada parte do sistema agrícola. Os módulos são executados conforme as especificações requisitadas pelo usuário.

O APSIM pertence a uma linha de simulação que desmembra os processos do solo e da cultura que é simulada. No caso da opção pela simulação iterativa especial, as simulações entre os processos ocorrem conforme especificado pelo usuário. O sistema APSIM é agronomicamente centrado no solo. Os módulos de cultura são inseridos como opcionais após a escolha do módulo de solo. O APSIM-*sugarcane* representa o modelo da cana-de-açúcar que segue a estrutura de outros módulos de cultura no APSIM, mas as características específicas da cultura são definidas em uma tabela de variáveis de entrada, algumas das quais são consideradas constantes.

O primeiro modelo de cana-de-açúcar amplamente distribuído foi o modelo australiano AUS-CANE (*AUStralian sugarCANE modelo*)(JONES et al., 1989), desenvolvido a partir do EPIC (WILLIAMS; JONES; DYKE, 1984). O EPIC (*Erosion Productivity Impact Calculator*) foi desenvolvido para lidar com a erosão do solo, determinar a produtividade da cultura e considerar alguns aspectos econômicos. O AUSCANE foi considerado fraco na representação dos aspectos biológicos da cana-de-açúcar e é composto de um código computacional não estruturado. O AUSCANE foi utilizado para a construção de um novo módulo para o APSIM, agora chamado APSIM-*sugarcane* (O'LEARY et al., 1999), associado com a modelagem da água no solo e do nitrogênio que estavam operando para o APSRU (*Agricultural Production Systems Research Unit*), desenvolvido por (PROBERT et al., 1998), e gera melhores resultados. O modelo é considerado simples baseado em conceitos fisiologicamente elementares que oferecem uma redução da complexidade de cada processo.

O modelo APSIM-*sugarcane* simula a fixação diária de carbono (C) a partir da atmosfera utilizando os conceitos da teoria do Uso da Eficiente da Radiação (UER) desconsiderando os efeitos da eficiência da transpiração. Valores diferentes do UER são usados para o ciclo da cana-planta e o ciclo da cana-soca, mas mantêm os mesmos coeficientes de extinção⁴ e de transpiração para os dois ciclos. Os valores do UER são reduzidos para condições sub-ótimas e com restrições de nitrogênio. Os valores de área foliar são específicos para cada variedade e determinados pelo tempo térmico, pela quantidade de biomassa e pela demanda energética da planta. Os valores da área foliar são usa-

⁴Coeficiente que determina a redução da intensidade luminosa em uma cobertura vegetal, assim a conseqüente interceptação de luz pela mesma.

dos para calcular a radiação solar interceptada pela planta. Em condições agronômicas normais, a produção de fotossintetizados é particionada entre as folhas, os ponteiros, os colmos e as raízes por um conjunto de frações constantes para cada fase fenológica. Os índices de deficiências hídrica, de nitrogênio e térmica são aplicados a partição dos fotossintetizados. O APSIM-*sugarcane* altera a partição dos fotossintetizados nos colmos para cada variedade permitindo simular diferentes valores de concentrações de sacarose dos vários cultivares disponíveis.

O APSIM-*sugarcane* é o único modelo que simula o conteúdo de água no colmo, considerando a matéria seca estrutural do colmo (fibra) e o tempo térmico. Não existe uma relação direta entre o conteúdo de água nos colmos, o conteúdo de água no solo e a transpiração da cultura. O propósito dessa variável é simular a produção de colmo e a concentração de sacarose com base na massa úmida, assim como, é feito rotineiramente em usinas sucroalcooleiras. Desse forma, este modelo apresenta uma inovação na modelagem da cana-de-açúcar. Ele contém apenas expressões algébricas para a manipulação das variáveis envolvidas.

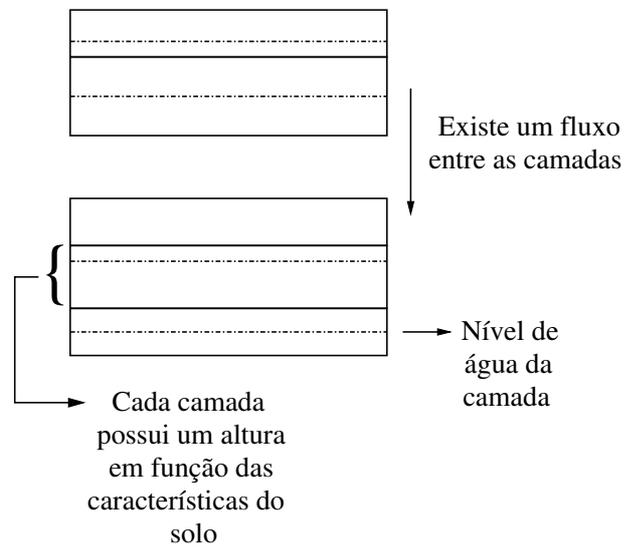
A deficiência hídrica é simulada no APSIM-*sugarcane* pela adaptação do modelo CERES, (JONES et al., 1989). Este modelo reduz a expansão da área foliar antecipadamente, e mais severamente, do que o crescimento da planta. Isto é calculado pelas diferentes proporções entre a expansão da área foliar e o crescimento em relação ao suplemento de água no solo. A simulação do conteúdo de água no solo, do APSIM, é realizada pelo cálculo do balanço hídrico, através de um modelo de camadas sucessivas ou de um modelo de vasos comunicantes, como mostra a Figura 4.3, mas um modelo de Penman-Montieh também está disponível (ALLEN et al., 1990).

Os efeitos da deficiência de nitrogênio no solo sobre o crescimento da cana-de-açúcar são tratados no APSIM-*sugarcane* por uma abordagem similar a utilizada nos modelos CERES. Esta abordagem determina a demanda de nitrogênio (N) da cana-de-açúcar com base no crescimento e os suplementos da planta definidos pela concentração de absorção de N máxima, crítica e mínima para a cultura. A absorção de N a partir do solo é simulada através de um processo de fluxo passivo associado a transpiração e de um processo de absorção ativa.

4.4.1.2 O modelo CANEGRO

As origens do modelo CANEGRO datam do começo dos anos de 1970 com o desenvolvimento de equações de fotossíntese e respiração para a cana-de-açúcar no “*Department of Theoretical Production Ecology, Agricultural University*”, Wageningen, Holanda. Inicialmente os modelos de respiração e fotossíntese foram agrupados em um único modelo de simulação denominado CANESIM em 1991, na Estação Experimental da Associação Sul Africana de Açúcar (*South African Sugar Associ-*

Modelo de Camadas



Modelo de Vasos Comunicantes

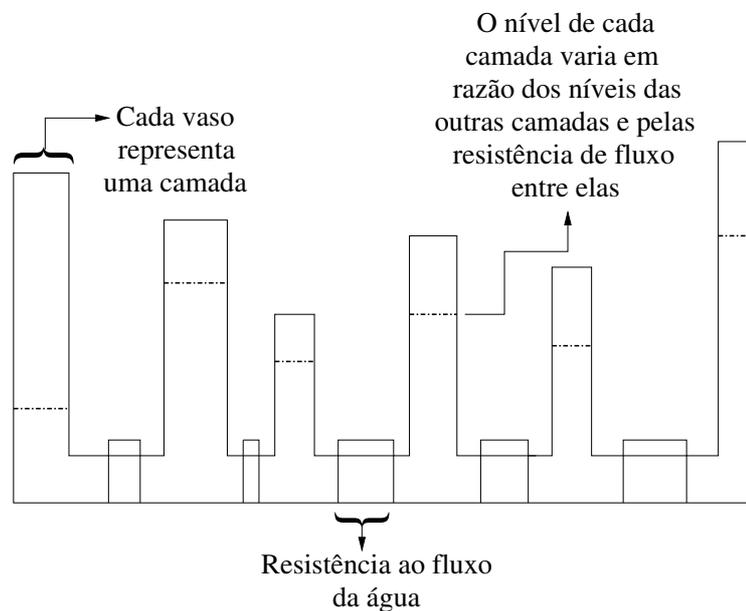


Fig. 4.3: Diagrama da estruturação dos modelos hídricos de camada e de vasos comunicantes

ation Experiment Estation, SASEX) (INMAN-BAMBER, 1991). Posteriormente foram adicionados os cálculos da fotossíntese por área de folha, da eficiência quântica e da respiração de crescimento e de manutenção. Os efeitos diretos da temperatura na fotossíntese não foram incluídos. Os cálculos do balanço hídrico também foram aperfeiçoados incluindo a evapotranspiração potencial de Penman-Montieh (INMAM-BAMBER; CULVERWELL; MCGLINCHEY, 1993), adaptada do balanço hídrico do modelo CROPGRO, e interceptação da chuva pela cobertura (O'LEARY, 2000). Os parâmetros fenológicos para o desenvolvimento das folhas e do perfilhamento também foram incorporados, assim como, os fatores de partição dos fotossintetizados para as raízes. O modelo é composto por um balanço de carbono, por uma função de desenvolvimento da cultura, e de outros modelos para a simulação de água e energia. É importante notar que, até o momento, o modelo é limitado a radiação, água e temperatura da biomassa da cana-de-açúcar, sem contabilizar os efeitos da nutrição (INMAM-BAMBER, 1994; INMAN-BAMBER, 1995). O diagrama funcional do CANEGRO é apresentado na Figura 4.5. Uma representação simplificada, considerando as entradas e saídas deste modelo é apresentada na Figura 4.4.

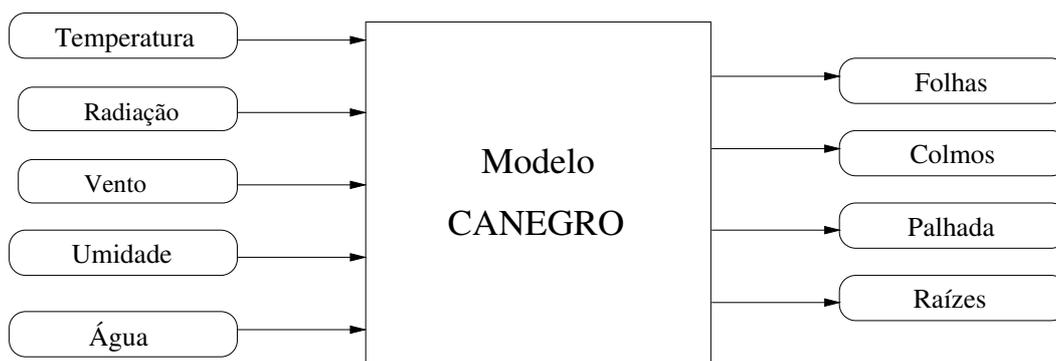


Fig. 4.4: Diagrama esquemático de representação do CANEGRO

Um dos objetivos principais do desenvolvimento do CANEGRO foi auxiliar a determinar a idade de colheita ótima na África do Sul, devido ao alastramento da infestação da *Eldana saccharina* cujas larvas atacavam principalmente os colmos maduros (com alta concentração de açúcares); dessa forma, a inclusão da simulação de sacarose no modelo foi recentemente desenvolvida. Em 1994, este modelo mostrou um desempenho razoável na simulação da produção de sacarose em uma comparação gráfica dos dados observados para duas localizações na África do Sul, segundo (INMAM-BAMBER, 1994).

O acúmulo de sacarose em relação a quantidade de biomassa é simulado com base em dados experimentais, dessa forma limitada as condições ambientais dos locais dos experimentos. Houve tentativas de se elaborar um modelo mecanístico, mas sem sucesso, devido ao pouco conhecimento sobre os mecanismos relacionados à partição dos fotossintetizados na cana-de-açúcar e ao acúmulo de sacarose pelos colmos. Novos estudos estão sendo realizados na África do Sul, para modelar os

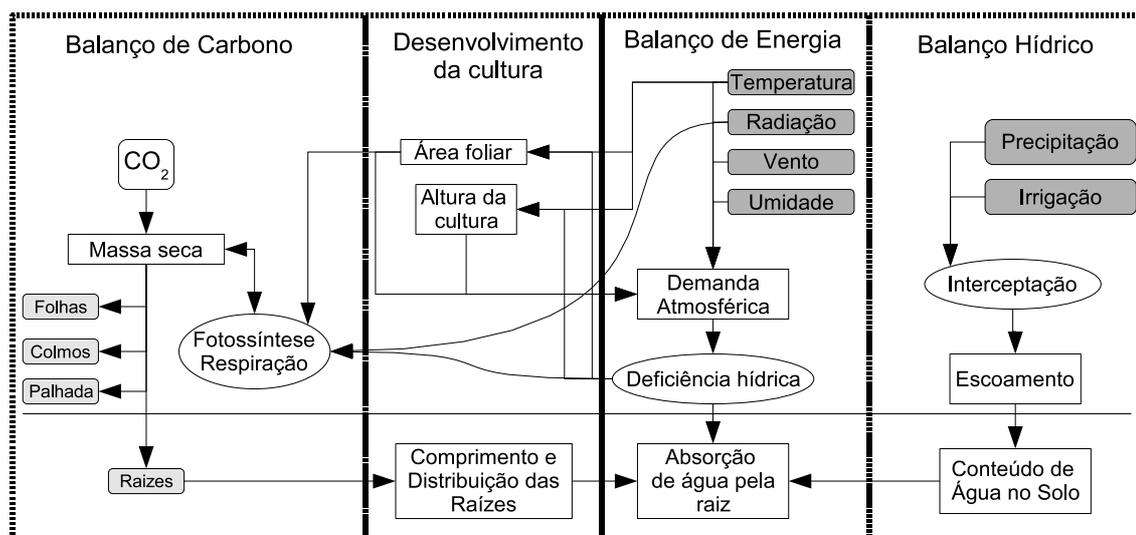


Fig. 4.5: Diagrama de fluxo do modelo CANEGRO destacando em cinza claro as variáveis de saída e em cinza escuro as entradas, explicitando os processos que as interrelacionam

mecanismos de acumulação de sacarose.

O modelo CANEGRO tem duas versões:

- Simulação exclusiva da SASEX interativa para múltiplos anos (cana-planta, cana-soca).
- Módulo de cana-de-açúcar do DSSAT acoplado ao modelo de nitrogênio solo/planta a partir do modelo CERES-*maize* (JONES et al., 1986). Este modelo de qualquer forma, não foi validado com deficiência de nitrogênio no solo ou na cultura.

Estudos recentes avaliam a resposta do crescimento e desenvolvimento da cana-de-açúcar, sob condições de deficiência de nitrogênio (SINGLES; DONALDSON; SMIT, 2005).

4.4.1.3 O modelo de simulação da cana-de-açúcar QCANE

O modelo QCANE é resultado de um projeto iniciado pela Agência das Estações Experimentais na Queensland, Austrália, para estudar a evolução diária dos processos fisiológicos da cana-de-açúcar. Uma forte ênfase foi aplicada para a modelagem da fotossíntese, da respiração e da partição dos fotossintetizados. O modelo considera um arranjo mais formal dos estados da biomassa. Considera-se quatro componentes principais para a planta que são as folhas verdes, o ponteiro, os colmos e raízes, e para cada um destes a produção diária de fotossintetizados é particionada. Em cada componente é determinada a composição entre fibra e açúcar a partir da massa seca, resultando em oito saídas,

além de conter a senescência para as folhas, ponteiro e raiz que compõem as 11 variáveis de saída do modelo. O açúcar acumulado total dos colmos é particionado entre sacarose e açúcares redutores os quais indicam a qualidade industrial dos colmos, resultando no total de 13 variáveis de saída. Uma característica chave desse modelo é o papel central da sacarose como acumulador de carbono para suplementar o carbono estrutural e manutenção das atividades biológicas diárias requeridas pela planta, Figura 4.6. Uma versão do QCANE que inclui os efeitos do déficit de água e do déficit de nitrogênio está em desenvolvimento⁵.

A fotossíntese diária bruta é determinada a partir da interceptação da radiação fotossinteticamente ativa e da temperatura, calibrada com dados experimentais. A respiração é dividida em porções para manutenção e crescimento. A taxa da respiração de crescimento é proporcional a respiração de manutenção. A respiração de manutenção é determinada como função da massa seca acumulada e da temperatura, para cada parte da planta. Trabalhos recentes têm sido conduzidos por vários pesquisadores para determinar as taxas de respiração da cana-de-açúcar. O modelo QCANE aloca os fotossintetizados como função do crescimento diário, do estágio de crescimento, e da temperatura para a composição de cada variável de saída.

Os fotossintetizados são distribuídos pela planta descontando a respiração de manutenção e a respiração de crescimento; o excedente vai para o armazenamento na forma de sacarose. O modelo de partição dos fotossintetizados armazena mais sacarose quando a temperatura é baixa e a radiação é alta. O comportamento do armazenamento tem uma tendência inversa a da temperatura, pois o armazenamento decresce na medida que a temperatura aumenta e o inverso é válido, pois o aumento da temperatura gera um aumento da respiração de manutenção.

Um conceito interessante neste modelo é que o incremento de área foliar é determinado, após um dado tempo térmico, a partir da partição dos fotossintetizados e de uma área foliar inicial, (CARRBERRY; MUCHOW; HAMMER, 1993). O modelo simula duas variedades de cana-de-açúcar australianas: Q138 e Q141. O diagrama apresentado na Figura 4.6 representa o conjunto de entradas e saídas do modelo QCANE.

4.4.1.4 Contribuição Nacional

O Brasil é o maior produtor mundial de cana-de-açúcar e para manter tal posição são realizados continuamente o desenvolvimento de técnicas de manejo da cultura, pesquisas científicas sobre os processos fisiológicos e para a modelagem da cultura. Os modelos matemáticos-fisiológicos disponí-

⁵Informação obtida em correspondência pessoal com o Prof. Dr. De Li Liu do "NSW Agriculture, Wagga Wagga Agricultural Institute" do dia 25/07/2006

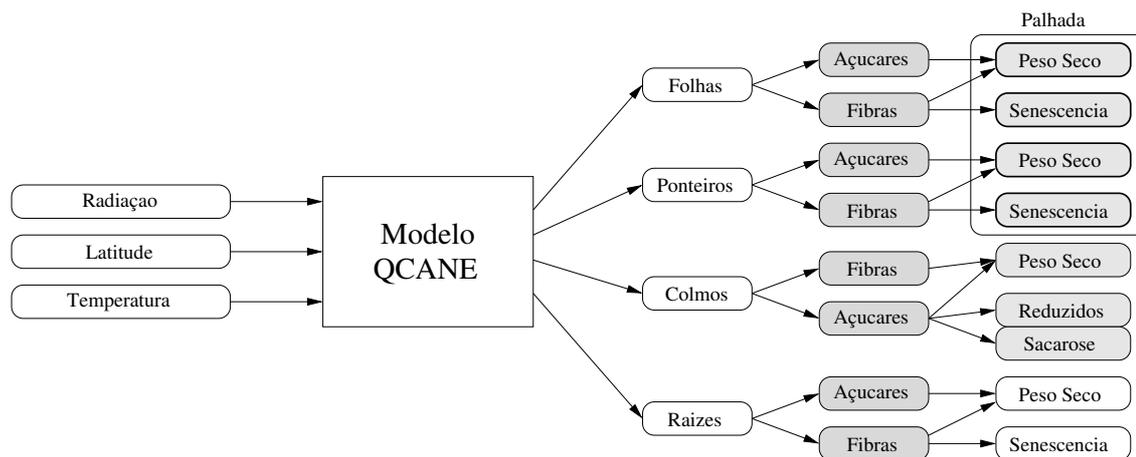


Fig. 4.6: Representação esquemática do modelo QCANE.

veis tratam da quantidade de biomassa acumulada e são:

- **Simulação do acúmulo de matéria seca na cana-de-açúcar:** Este modelo utiliza como parâmetro de crescimento, o índice de área foliar, que é um ótimo indicador de crescimento e produtividade da cana-de-açúcar. Cada colmo produz uma nova folha a cada 10 dias aproximadamente, e devido a senescência e queda das folhas mais velhas, observa-se um número, praticamente constante, de 8 a 10 folhas por colmo após o fechamento da cobertura. Por isso, o comportamento do desenvolvimento do Índice de Área Foliar (IAF), durante o ciclo da cultura, é de extrema importância para os estudos de crescimento e produção, (MACHADO, 1981).
- **Simulação do condicionamento climático da cana-de-açúcar:** Este modelo utiliza medidas regulares de elementos do clima para estimar o desempenho da cultura, especialmente o acúmulo de matéria seca durante o ciclo. Os resultados desse estudo determinam um conjunto de critérios e funções requeridas para avaliar a evolução dos estágios fenológicos tais como: a germinação e estabelecimento, a formação e a renovação das folhas, a morte dos colmos por competição, e o acúmulo de matéria seca considerando as variações da fotossíntese e da respiração. Os elementos de clima utilizados, neste trabalho, são a insolação e a temperatura do ar, juntamente com dados climatológicos como foto-período e a radiação no topo da atmosfera. A disponibilidade de água é considerada ideal, pois o modelo simula a produção potencial. As constantes das equações são obtidas adaptando-se os resultados de pesquisas disponíveis na literatura, (BARBIERI, 1993).
- **Simulação diária do balanço de carbono de uma comunidade vegetal:** Este modelo simula uma área de cultivo considerando uma dada densidade de plantas, utilizando conceitos

de respiração de crescimento e de manutenção, integrando-os com a fotossíntese para avaliar o crescimento da cultura. Através da simulação da massa seca dos colmos e das folhas pode-se determinar a quantidades e a distribuição do carbono fixado pelas plantas, numa dada área. Foram integrados três processos que normalmente são estudados em separado: crescimento (acumulação de biomassa), fotossíntese e respiração, em uma única equação, em torno da qual foi idealizado o modelo matemático do crescimento e desenvolvimento da cana-de-açúcar, (PEREIRA, 1987).

Todos esses modelos correlacionam os dados meteorológicos com a produção e rendimento da cultura, e têm contribuído muito para a compreensão dos mecanismos fisiológicos, e para avaliações qualitativas e quantitativas dos sistemas de plantio (LISSON et al., 2005).

4.4.2 Modelos nebulosos aplicados na agricultura

Os mecanismos de reações biológicas e o controle destas em sistemas vivo são complexos, não-lineares, e variantes no tempo (YAMAKAWA, 1992). Além disso as características da biomassa (por exemplo: folhas, colmos ou frutas) são afetadas pelo ambiente causando adaptações das reações bioquímicas do sistema. As adaptações dos sistemas biológicos não são fáceis de descrever através de equações matemáticas. As características da biomassa, em muitos casos, não são medidas diretamente e somente informações brutas do sistema estão disponíveis. A abordagem de sistemas nebulosos provê um quadro adequado para modelar este tipo de sistemas devido a sua habilidade de lidar com “*conhecimento fragmentado, incerto, qualitativo e misturado, freqüente em sistemas biológicos*” (KONSTANTINOV; YOSHIDA, 1992). Descrições de alguns casos de modelagem nebulosa, e de controle de sistema nebulosos aplicados a sistemas biológicos são apresentadas a seguir.

Um modelo nebuloso para a fotossíntese do tomateiro em estufas, considerando a temperatura ambiente, a concentração de CO₂, a densidade do fluxo de luz, a distribuição das folhas na cobertura da planta e os efeitos de sombreamento foi citado em (CENTER; VERMA, 1998). As saídas do modelo nebuloso do total de fotossintetizados para os vários estágios de crescimento e condições ambientais foram determinadas como sendo representativas dos campos experimentais da Florida, U.S.A.

A indústria da fermentação é uma das primeiras a reconhecer o potencial do controle nebuloso para processos biológicos (KONSTANTINOV; YOSHIDA, 1992; DOHNAL, 1985). Um modelo nebuloso foi desenvolvido para identificar as etapas do processo de fermentação considerando os processos fisiológicos do fermento e este modelo foi usado em um sistema de controle distribuído

desenvolvido por (KONSTANTINOV; YOSHIDA, 1990, 1989).

Uma aplicação muito importante dos sistemas nebulosos na agricultura é a delimitação de zonas agroecológicas. Como a produtividade agrícola de uma área geográfica depende de muitos fatores (características terrestres e inerentes ao solo, restrições climáticas, comportamento humano, manejo da cultura e normas culturais), as zonas agroecológicas foram propostas para representar estes fatores ambientais e culturais destacando as culturas com os melhores potenciais produtivos em cada área, visando a sustentabilidade da atividade agrícola. Um sistema automático de delimitação das zonas agroecológicas baseado em lógica nebulosa foi proposto por (LIU; SAMAL, 2002). Esta abordagem busca incorporar a variabilidade e a incerteza dos parâmetros de delimitação, inerentes ao processo.

Outros exemplos da aplicação de modelos nebulosos incluem um modelo para predição de efeitos de múltiplas restrições (estresses) ao crescimento das árvores (SCHMOLDT, 1991) e uma proposta de organização de conhecimento da bioengenharia com modelos nebulosos que podem ser usados para a predição (DOHNAL, 1985).

4.5 Identificação de Sistemas

Identificação de sistemas é uma das técnicas aplicadas na modelagem de sistemas dinâmicos quando o conhecimento prévio sobre o sistema a ser modelado é insuficiente ou não está disponível. Apresenta-se, também, como uma alternativa menos dispendiosa de tempo na modelagem de sistemas complexos, em comparação às técnicas de modelagem mecânicas (Seção 4.3.3). As técnicas de identificação de sistemas utilizam procedimentos de natureza essencialmente numérica que derivam o modelo a partir de um conjunto de dados obtido do sistema.

Os primeiros estudos de modelagem de sistemas dinâmicos, utilizando métodos de identificação, foram aplicados a sistemas linearizados devido a limitações teóricas e computacionais vigentes na época. Atualmente, estas dificuldades têm sido superadas, tendo surgido um grande número de trabalhos teóricos e práticos aplicados na área de identificação não-linear. No Brasil, o interesse pela identificação de sistemas não-lineares tem se manifestado através de um significativo número de trabalhos.

O problema de identificação de sistemas pode ser dividido nas seguintes etapas principais:

- Experimentação e aquisição de dados do sistema;
- Avaliação do conjunto de dados;

- Escolha da representação matemática e detecção da estrutura do modelo;
- Estimação dos parâmetros do modelo;
- Validação do modelo identificado;

A metodologia de identificação de sistemas, segundo a divisão de etapas descritas acima, é válida para derivação de modelos lineares e não lineares. Ela pode ser aplicada na identificação de sistemas com uma entrada e uma saída (“*Single Input Single Output - SISO*”) ou para sistemas com múltiplas entradas e múltiplas saídas (“*Multiple Inputs Multiple Outputs - MIMO*”), ou ainda suas variantes SIMO (“*Single Input Multiple Outputs*”) e MISO (“*Multiple Inputs Single Output*”). A Figura 4.7 mostra o fluxograma dos procedimentos de identificação.

Nas seções seguintes são descritos os procedimentos relativos a cada uma das etapas do problema de identificação de sistemas.

4.5.1 Experimentação e aquisição dos dados

A experimentação e a aquisição dos dados do sistema são etapas simultâneas do procedimento de identificação. A seleção de sinais de teste aplicados nas entradas do sistema e a coleta dos sinais das variáveis de interesse compõem a montagem e elaboração do experimento. Os dados de entrada e saída formam um conjunto de dados do qual são retiradas informações utilizadas na modelagem do sistema. Normalmente, a quantidade de informações fornecida pelos dados sobre a dinâmica do sistema está condicionada a um bom planejamento e execução desta etapa.

Na experimentação agrícola é possível apenas atuar apenas sobre algumas variáveis do sistema, pois os experimentos necessitam ser realizados em testes de campos para poderem ser considerados significativos. Além disso, o ciclo de desenvolvimento da cana-de-açúcar é longo, o que exige, conseqüentemente, excitar as variáveis de entrada durante longos períodos de tempo para poder verificar alterações no comportamento da planta. Na seqüência serão abordados os sinais de teste e o procedimento de seleção do período de amostragem para a aquisição dos dados, posteriormente serão expostas abordagens para tratar os ruídos nos dados e detectar as não linearidades do sistema.

4.5.1.1 Sinais de teste

Os sinais mais empregados nos métodos de identificação determinística e estocástica são: o degrau, o senoidal, o sinal binário pseudo-aleatório (“*Pseudo Random Binary Signal*”, PRBS) e o ruído

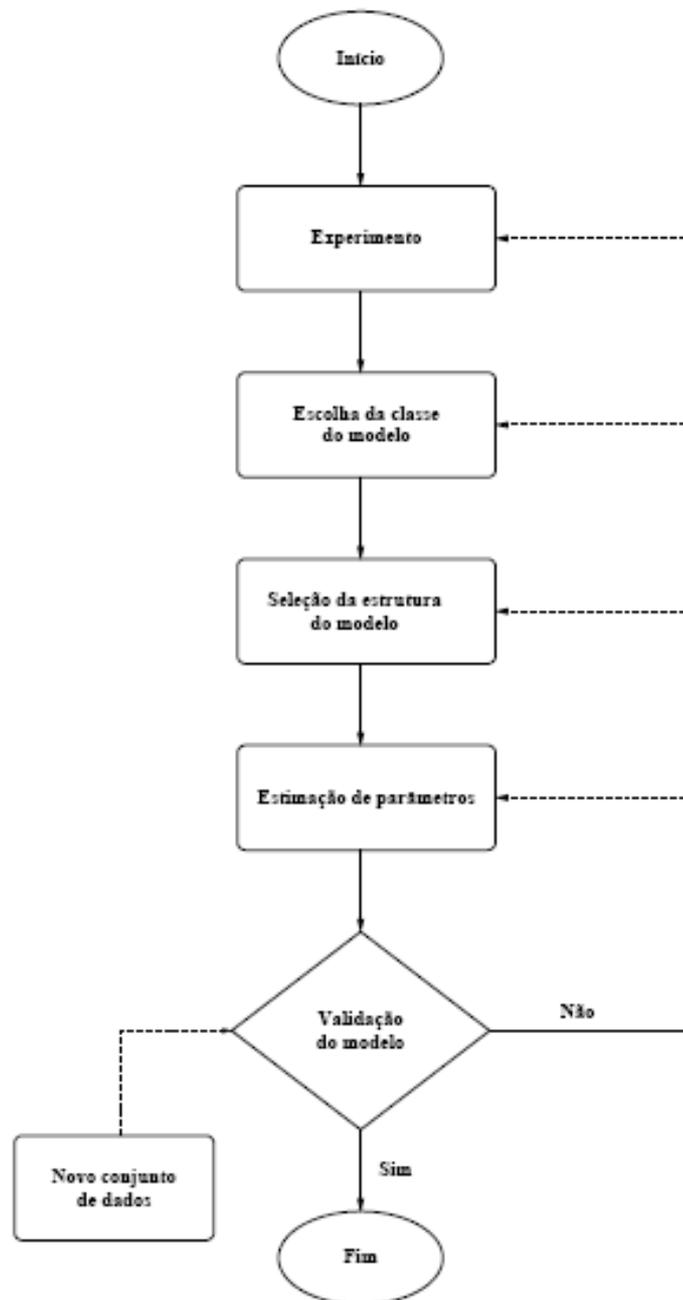


Fig. 4.7: Fluxograma do procedimento de identificação

branco gaussiano.

No planejamento dos testes do sistema devem ser selecionados sinais que possuam um espectro de frequências que excitem todas as dinâmicas de interesse na modelagem do sistema. Desconsiderar este fato pode conduzir a modelos que se ajustem bem aos dados mas com pequena capacidade de predição.

4.5.1.2 Seleção do período de amostragem para a aquisição de dados

Grande parte dos sistemas reais são contínuos. Em várias aplicações científicas e tecnológicas é necessário, entretanto amostrar o sinal de interesse. O período entre as amostras é chamado de período ou intervalo de amostragem, t_s .

Na execução do procedimento de aquisição de dados deve-se selecionar criteriosamente o t_s , de forma a proporcionar uma captação de qualidade das informações sobre o sistema, permitindo que o sinal amostrado possua as características fundamentais do sinal original. Na prática, costuma-se amostrar de 5 a 10 vezes o valor da frequência que mais excita o sistema, contudo na prática, normalmente, não se conhece esta frequência a priori.

A estimação dos parâmetros poderá se tornar mal condicionada numericamente se o intervalo de amostragem for muito curto. Visto que a matriz de regressores é composta de elementos que incluem valores amostrados de entrada e saída para passos de tempo determinados, por exemplo, $y((k-1)t_s)$, $y((k-2)t_s)$, ... e $u((k-1)t_s)$, $u((k-2)t_s)$, ... quando $t_s \rightarrow 0$, $y((k-1)t_s) \approx y((k-2)t_s)$, assim as colunas da matriz de regressores tendem a se tornar linearmente dependentes, conseqüentemente redundantes para o processo de identificação.

Considera-se que os dados $y^*(k)$ são amostrados em um intervalo de tempo muito menor do que o necessário. Costuma-se denominar estes dados de superamostrados. Deve-se decimar os dados amostrados $y^*(k)$ gerando os dados de trabalho $y(k)$ adequadamente amostrados, determinando-se o fator de decimação $\Delta \in \mathbb{N}$, tal que $y(k) = y^*(\Delta k)$. Necessita-se verificar o grau de correlação entre as observações adjacentes de $y^*(k)$. Ressalta-se que quanto mais redundantes duas medidas consecutivas de $y^*(k)$ forem, maior será sua correlação.

Para a quantificação dos efeitos causados pela superamostragem do sinal $y^*(k)$, são calculadas as

seguintes funções de autocovariância

$$r_{y^*} = E \left[(y^*(k) - \overline{y^*(k)})(y^*(k - \tau) - \overline{y^*(k)}) \right] \quad (4.3a)$$

$$r_{y^{*2}} = E \left[(y^{*2}(k) - \overline{y^{*2}(k)})(y^{*2}(k - \tau) - \overline{y^{*2}(k)}) \right], \quad (4.3b)$$

onde τ representa um atraso, $\overline{y^*(k)}$ representa o valor médio de $y^*(k)$. O objetivo de usar $r_{y^{*2}}$, além de r_{y^*} , é detectar algumas correlações não-lineares que os dados por acaso possam conter. A escolha do fator de decimação Δ pode ser feita da seguinte maneira:

- Dado o sinal superamostrado $y^*(k)$, determinando as funções dadas pelas Equações 4.3a e 4.3b
- Determina-se os valores de atraso $\tau^* [t_s]$ e $\tau^{*2} [t_s]$ nos quais ocorrem os primeiros mínimos das funções da autocovariância (Equações 4.3a e 4.3b). O menor desses mínimos será o valor de trabalho dado por $\tau_m^* = \min[\tau^*, \tau^{*2}]$
- Escolhe-se Δ de forma que as funções de autocovariância do sinal decimado $y(k) = y^*(\Delta k)$ satisfaçam

$$10 \leq \tau_m \leq 20, \quad (4.4)$$

sendo que $\tau_m [t_s]$ é definido para o sinal decimado $y(k)$ de maneira análoga a τ_m^* para o sinal original $y^*(k)$.

O limites inferior e superior da Equação 4.4 podem ser relaxados para 5 e 25 $[t_s]$, respectivamente, (NEPOMUCENO, 2002).

Deve ser observado que com exceção do fator de escala no eixo de atrasos, dado por Δ , as funções de autocovariância de $y(k)$ e $y^*(k)$ são iguais. Assim, se τ_m satisfizer a Equação 4.4, então $10\Delta \leq \tau_m^* \leq 20\Delta$. Por exemplo, se $\tau_m^* \approx 150$, as taxas de decimação estão na faixa $7 \leq \tau_m \leq 15 [t_s]$ que pode ser escolhida para gerar o sinal de trabalho $y(k)$ (AGUIRRE, 2000, pg. 368-372).

4.5.1.3 Ruído nos dados

Os efeitos de ruídos nos dados coletados do sistema podem ser reduzidos através de técnicas de processamento de sinais. Algumas dessas técnicas implementam a filtragem digital dos dados utilizados nos algoritmos computacionais. Basicamente, estes algoritmos realizam operações aritméticas sobre o conjunto de dados segundo uma função estabelecida para o tipo de filtragem que se deseja obter.

4.5.1.4 Detecção de não-linearidades

Os dados de identificação devem passar por testes de detecção de não-linearidades. Esses testes verificam, dentro de um limite de confiança pré-determinado, se o sistema possui algumas características próprias dos sistemas lineares. Caso não sejam verificadas essas propriedades, é necessária a utilização de modelos não-lineares para representar as características deste sistema.

Um dos algoritmos mais simples para testar a linearidade dos dados, consiste em realizar dois testes independentes no sistema a ser modelado com dois sinais de entrada $u_1(t)$ e $u_2(t)$ gerando as respostas $y_1(t)$ e $y_2(t)$, respectivamente. Na seqüência, verifica-se $u_1(t) - u_2(t)$ é equivalente a $y_1(t) - y_2(t)$, $\forall t$ (princípio da superposição).

Um outro procedimento consiste em calcular a função de auto-correlação:

$$r_{y'y'^2} = E[y'(k + \tau)y'^2(k)], \quad (4.5)$$

, onde $r_{y'y'^2}$ é a função de covariância cruzada entre as seqüências de dados y' e y'^2 , $E[\]$ é a esperança matemática, sendo que y' é a variável de interesse ajustada como a seguir:

$$y' = \frac{(y - E[y])}{\sigma^2(y)},$$

, onde $\sigma^2(y(k))$ é a variância de y .

Portanto, $r_{y'y'^2}(\tau) = 0, \forall \tau$ se o sistema for linear. Este método de detecção de não-linearidades foi proposto por Haber em (HABER, 1985) e citado por Cassini em (CASSINI, 1999).

4.5.2 Escolha da representação matemática

A escolha da representação não tem sido uma etapa cumprida criteriosamente na identificação de sistemas dinâmicos não-lineares. Tal ausência pode ser em parte justificada pela falta de estudos consistentes a respeito das características de cada representação.

Há uma grande variedade de representações não lineares que, pelo menos em princípio, podem ser utilizadas na identificação de sistemas. As seções seguintes apresentam de forma muito breve algumas representações estudadas nos últimos anos.

4.5.2.1 A série de Volterra

A saída $y(t)$ de um sistema não-linear com entrada $u(t)$ pode ser representada pela chamada série de Volterra definida como:

$$y(t) = \sum_{j=1}^{\infty} \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} h_j(\tau_1, \dots, \tau_j) \prod_{i=1}^j u(t - \tau_i) d\tau_i, \quad (4.6)$$

sendo que a função h_j é denominada “kernel”, ou núcleo e claramente é generalização não-linear da resposta ao impulso $h_j(t)$.

Uma dificuldade prática da aplicação da série de Volterra na identificação de sistemas é que, mesmo para sistemas “pouco” não-lineares, o número de parâmetros a determinar é muito grande. A grande necessidade de parâmetros é consequência da série de Volterra tentar explicar a saída $y(t)$ apenas em função da entrada. Uma forma de reduzir o número de parâmetros é utilizar valores da própria saída, além de valores da entrada, para determinar $y(t)$, ou seja, utilizar a recorrência ou auto-regressão da saída.

4.5.2.2 Modelos de Hammerstein e de Wiener

Os modelos de Hammerstein e de Wiener são composições de um modelo dinâmico linear⁶ $H(s)$ com uma função estática não-linear $f(\cdot)$ em cascata. No caso do modelo de Hammerstein, a não-linearidade estática precede o modelo dinâmico linear, ou seja,

$$U^*(s) = f(U(s)); \text{ e } Y(s) = H(s)U^*(s). \quad (4.7)$$

No caso do modelo de Wiener, o modelo dinâmico linear precede a não linearidade estática, isto é,

$$Y^*(s) = H(s)U(s); \text{ e } Y(s) = f(Y^*(s)). \quad (4.8)$$

4.5.2.3 Funções de Base Radial

As funções de base radial (RBF- “*Radial Basis Functions*”) são um mapeamento do tipo,

⁶Um modelo dinâmico nas representações de Hammerstein e de Wiener é normalmente descrito no domínio da frequência s . $H(s)$ é a transformada de Laplace da resposta ao impulso $h(t)$

$$y = f(\mathbf{x}) = \omega_0 + \sum_i \omega_i \phi(\|\mathbf{x} - \mathbf{c}_i\|), \quad (4.9)$$

onde $\mathbf{x} \in \mathbb{R}^n$, $\|\cdot\|$ é a norma euclidiana, $\omega_i \in \mathbb{R}$ são os pesos, $\mathbf{c}_i \in \mathbb{R}^n$ são os centros e $\phi_i : \mathbb{R}^+ \rightarrow \mathbb{R}$ é uma função, normalmente escolhida a priori, como por exemplo:

$$\phi_i(\|\mathbf{x} - \mathbf{c}_i\|) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{c}_i\|^2}{\sigma_i^2}\right), \quad (4.10)$$

onde σ_i é a constante de dispersão. A função dada pela Equação 4.10 é chamada gaussiana. Várias outras funções são utilizadas, tais como linear, cúbica e multiquadrática (HAYKIN, 1999).

Essa representação pode ser interpretada como uma técnica de interpolação global com boas propriedades locais. As funções de base radial são casos particulares de redes neurais, mas são lineares nos parâmetros ω_i , ao contrário das redes neurais (HAYKIN, 1999).

4.5.2.4 Redes neurais

As redes neurais são compostas por camadas de “neurônios” interconectados. A saída de um único neurônio com n entradas é do tipo

$$y(x) = f\left(\sum_n \omega_j x_j + b\right), \quad (4.11)$$

onde o b é o termo de polarização (também chamado de “bias”) e f é chamada de função de ativação. Há vários tipos de função de ativação sendo que uma das funções mais usadas é a sigmoíde, descrita por:

$$f(z) = \frac{1}{1 + e^{-z}}. \quad (4.12)$$

Nota-se que, normalmente, as redes neurais são compostas por múltiplas camadas; a saída de um neurônio mostrado pela Equação 4.11 é conectada à entrada de outro neurônio da camada subsequente. Assim a saída da rede será uma composição das funções de cada camada. Modelos que levam em conta termos auto-regressores e termos de entrada podem ser obtidos de maneira semelhante ao modelo descrito pela Equação 4.9.

A fim de estimar os parâmetros de uma rede neural multicamada são utilizados algoritmos de estimação não-linear, tais como o de retropropagação do erro (HAYKIN, 1999).

4.5.2.5 Modelos Contínuos de Processos

Modelos contínuos de processos são modelos simples classicamente utilizados para os processos industriais. Estes modelos podem ser funções de transferência contínuas simples de baixa ordem, pois para processos mais complexos outras representações são utilizadas. Estes modelos, usualmente, são SISO e empregados para descrever o comportamento de algumas classes de processos industriais. Maiores informações sobre as características e a análise de modelos dinâmicos podem ser encontradas em (BOTTURA, 1982).

Estes modelos são basicamente constituídos de “Ganho estático + Constante de tempo + Tempo de Atraso”. Eles podem ser representados por funções de transferência do tipo:

$$G(s) = K \frac{1 + t_z s}{(1 + t_{p1} s)(1 + t_{p2} s)} e^{-t_d s} \quad (4.13)$$

ou como um processo com uma integração (um pólo na origem) por exemplo:

$$G(s) = K \frac{1 + t_z s}{s(1 + t_{p1} s)(1 + t_{p2} s)} e^{-t_d s} \quad (4.14)$$

onde deve-se determinar o número de polos reais (usualmente, 0, 1, 2 ou 3), assim como, a presença de um zero no numerador, a presença de um termo integrador ($1/s$) e a presença do tempo de atraso (t_d). Além disso, um par de polos complexos pode substituir dois polos reais.

Modelos contínuos de processos podem ser representados por letras: P (para polos), D para o atraso de tempo, Z para zeros e I para integrador. Um número inteiro denota o número de polos logo após P .

Apresentamos alguns exemplos, a seguir:

- O modelo $P1$ tem a seguinte função de transferência:

$$G(s) = \frac{K}{1 + t_{p1} s} \quad (4.15)$$

- O modelo $P2DIZ$ tem a seguinte função de transferência:

$$G(s) = \frac{K(1 + t_z s)}{s(1 + t_{p1} s)(1 + t_{p2} s)} e^{-t_d s} \quad (4.16)$$

- O modelo *P0ID* tem a seguinte função de transferência:

$$G(s) = \frac{K}{s} e^{-t_d s} \quad (4.17)$$

4.5.2.6 Modelos discretos

Existem várias forma de representação para sistemas lineares discretos como pode ser observado em (LJUNG, 1999; SERRA, 2005). Será apresentada a estrutura geral para sistemas dinâmicos lineares discretos no tempo e algumas estruturas amplamente difundidas na literatura. Considere o modelo SISO geral:

$$A(q)y(k) = \frac{B(q)}{F(q)}u(k) + \frac{C(q)}{D(q)}e(k) \quad (4.18)$$

sendo q o operador deslocamento à frente⁷, de forma que $y(k+1) = qy(k)$, $e(k)$ é um ruído branco e $A(q)$, $B(q)$, $C(q)$, $D(q)$ e $F(q)$ os polinômios definidos a seguir:

$$\begin{aligned} A(q) &= 1 + a_1q^{-1} + \dots + a_{n_y}q^{-n_y}; \\ B(q) &= b_1q^{-1} + \dots + b_{n_u}q^{-n_u}; \\ C(q) &= 1 + c_1q^{-1} + \dots + c_{n_\xi}q^{-n_\xi}; \\ D(q) &= 1 + d_1q^{-1} + \dots + d_{n_d}q^{-n_d}; \\ F(q) &= 1 + f_1q^{-1} + \dots + f_{n_f}q^{-n_f}; \end{aligned} \quad (4.19)$$

A partir deste modelo geral são derivados vários modelos apresentados na literatura.

4.5.2.7 Modelo FIR

O modelo FIR (resposta finita ao impulso - “*Finite Impulse Response*”) pode ser obtido da Equação 4.18, tomando-se $A(q) = C(q) = D(q) = F(q) = 1$ e $B(q)$ um polinômio de ordem M , ou seja, $n_u = M$.

$$y(k) = B(q)u(k) + e(k) \quad (4.20)$$

⁷A definição do operador deslocamento à frente está apresentada juntamente com as razões de escolha desta notação em (BOTTURA, 1982)

Deve-se notar que, como $C(q)/D(q) = 1$, o ruído branco $e(k)$ é acrescentado na saída $y(k)$. O preditor da Equação 4.20 é expresso como

$$\hat{y}(k|\theta) = B(q, \hat{\theta})u(k) \quad (4.21)$$

4.5.2.8 Modelo ARX

O modelo auto-regressivo com entradas externas (“*AutoRegressive with eXogenous inputs*”) pode ser obtido a partir do modelo geral 4.18, tomando-se $C(q) = D(q) = F(q) = 1$, e $A(q)$ e $B(q)$ polinômios arbitrários, resultando na expressão:

$$A(q)y(k) = B(q)u(k) + e(k). \quad (4.22)$$

Uma vez que o ruído $e(k)$ aparece diretamente na equação, o modelo ARX é classificado como pertencendo a classe de modelos de *erro na equação*. O modelo dado pela Equação 4.22 pode ser reescrito da forma:

$$y(k) = \frac{B(q)}{A(q)}u(k) + v(k), \quad (4.23)$$

o que coloca em evidência as funções de transferência do sistema $H(q) = B(q)/A(q)$ e do ruído $C(q)/[D(q)A(q)] = 1/A(q)$. Observe que ao contrário do modelo FIR, o ruído que aparece adicionado à saída $v(k) = e(k)/A(q)$ não é branco. Assim, neste modelo o ruído é modelado como ruído branco filtrado por um filtro auto-regressivo. O preditor é obtido pela Equação 4.23 e dado por

$$\hat{y}(k|\theta) = B(q, \hat{\theta})u(k) + [1 - A(q, \hat{\theta})]y(k). \quad (4.24)$$

4.5.2.9 Modelo ARX multivariável

Considerando-se o caso em que o modelo tem p saídas e q entradas, uma possível representação multivariável de um modelo ARX é:

$$\mathbf{y}(k) + \mathbf{A}_1\mathbf{y}(k-1) \dots + \mathbf{A}_{n_y}\mathbf{y}(k-n_y) = \mathbf{B}_1\mathbf{u}(k-1) \dots + \mathbf{B}_{n_u}\mathbf{u}(k-n_u) + \mathbf{e}(k), \quad (4.25a)$$

sendo $\mathbf{A}_i \in \mathbb{R}^{p \times p}$ e $\mathbf{B}_i \in \mathbb{R}^{p \times r}$ e

$$\begin{aligned}\mathbf{y}(k) &= [y_1(k) \ y_2(k) \ \dots \ y_p(k)]^T \\ \mathbf{u}(k) &= [u_1(k) \ u_2(k) \ \dots \ u_r(k)]^T \\ \mathbf{e}(k) &= [e_1(k) \ e_2(k) \ \dots \ e_p(k)]^T.\end{aligned}$$

De forma análoga, aos polinômios escalares $A(q)$ e $B(q)$ das Equações 4.18 e 4.22, são aqui definidos os polinômios matriciais, ou seja, polinômios onde os parâmetros são matrizes:

$$\begin{aligned}\mathbf{A}(q) &= \mathbf{I} + \mathbf{A}_1 q^{-1} + \dots + \mathbf{A}_{n_y} q^{-n_y}; \\ \mathbf{B}(q) &= \mathbf{B}_1 q^{-1} + \dots + \mathbf{B}_{n_y} q^{-n_y}\end{aligned}$$

e podemos escrever o modelo ARX multivariável como

$$\mathbf{A}(q)\mathbf{y}(k) = \mathbf{B}(q)\mathbf{u}(k) + \mathbf{e}(k) \quad (4.25b)$$

A descrição detalhada sobre a representação de sistemas multivariáveis usando polinômios matriciais pode ser encontrada em (KAILATH, 1980). A realização mínima de sistemas multivariáveis não é única, ou seja, é possível modelos multivariáveis de mesma ordem dinâmica com diferente número de parâmetros. Outra representação para o modelo ARX, pode ser escrita como:

$$\mathbf{y}(k) = \Theta^T \psi(k-1) + \mathbf{e}(k), \quad (4.26)$$

sendo

$$\begin{aligned}\Theta &= [-\mathbf{A}_1 - \mathbf{A}_2 \dots - \mathbf{A}_{n_y} - \mathbf{B}_1 - \mathbf{B}_2 \dots - \mathbf{B}_{n_u}]^T \\ \psi(k-1) &= [\mathbf{y}^T(k-1) \ \dots \ \mathbf{y}^T(k-n_y) \ \mathbf{u}^T(k) \ \dots \ \mathbf{u}^T(k-n_u)].\end{aligned} \quad (4.27)$$

A Equação 4.26 pode ser interpretada como o conjunto de p regressões lineares que fazem uso do mesmo conjunto de regressores para explicar cada um dos p sinais.

4.5.2.10 Modelo ARMAX

O modelo auto-regressivo com média móvel e entradas exógenas (“*AutoRegressive Moving Average with eXogenous inputs*”) pode ser obtido a partir do modelo geral dado pela Equação 4.18, tomando-se $D(q) = F(q) = 1$ e $A(q)$, $B(q)$ e $C(q)$ polinômios arbitrários, resultando em

$$A(q)y(k) = B(q)u(k) + C(q)e(k), \quad (4.28)$$

ou, alternativamente,

$$\begin{aligned} y(k) &= \frac{B(q)}{A(q)}u(k) + \frac{C(q)}{A(q)}e(k) \\ y(k) &= H(q)u(k) + v(k), \end{aligned} \quad (4.29)$$

sendo $e(k)$ não branco. À semelhança do modelo ARX, o modelo ARMAX pertence a classe de modelos de erro na equação. Neste caso o erro na equação é modelado como um processo de média móvel, e o ruído adicionado à saída, $v(k)$, é modelado como um ruído branco filtrado por um filtro ARMA. O preditor da Equação 4.28 é dado por:

$$\hat{y}(k|\theta) = B(q, \hat{\theta})u(k) + [1 - A(q, \hat{\theta})]y(k) + [C(q, \hat{\theta}) - 1]e(k|\theta), \quad (4.30)$$

onde $e(k|\theta) = y(k) - \hat{y}(k|\theta)$ é o erro de predição ou resíduo. Devido a presença de $C(q, \hat{\theta})$, o preditor apresenta pólos, os quais devem estar dentro do círculo unitário para garantir a estabilidade do modelo.

4.5.2.11 Modelo Nebuloso Discreto NARX

O modelo nebuloso NARX (“*Nonlinear AutoRegressive with eXogenous inputs*”) estabelece uma relação não-linear entre a coleção de dados de entrada e saída passados e a saída predita presente:

$$\hat{y}(k|\theta) = g([y(k-1), \dots, y(k-n_y), u(k), \dots, u(k-n_u)], \hat{\theta}) \quad (4.31)$$

sendo k o instante de amostragem, n_y e n_u números inteiros relacionados à ordem do sistema, d o tempo de atraso. Em termos de regras, o modelo é dado por

R_i : Se y_{k-1} é A_1^i e ... u_k é G_1^i e ... e $u(k - n_u)$ é $G_{n_u}^i$

$$\text{Então } \hat{y}^i(k|\theta) = \sum_{j=1}^{n_y} \hat{a}_{i,j} y(k-j) + \sum_{j=1}^{n_u} \hat{b}_{i,j} u(k-n_u) + \hat{c}_i \quad (4.32)$$

onde os parâmetros $\hat{a}_{i,j}$, $\hat{b}_{i,j}$ e \hat{c}_i são os parâmetros do consequente a serem estimados. O preditor é dado por

$$\hat{y}(k|\theta) = \frac{\sum_{j=1}^{n_y} \beta_i(\mathbf{x}_k) y(k-j)}{\sum_{j=1}^{n_u} \beta_i(\mathbf{x}_k)} \quad (4.33)$$

ou

$$\hat{y}(k|\theta) = \sum_{i=1}^l \gamma_i(\mathbf{x}_k) \hat{y}_{k|\theta}^i, \quad (4.34)$$

com

$$\mathbf{x}_k = [y(k-1), \dots, y(k-n_y), u(k), \dots, u(k-n_u)], \quad (4.35)$$

onde $\beta_i(\mathbf{x}_k)$ é dado pela Equação 3.9 (SERRA, 2005).

4.5.3 Estruturas de modelos

Seja um conjunto \mathcal{M}^* de modelos de preditores $\hat{y}(k|\theta)$ candidatos : $\mathcal{M}^* = \{\hat{y}(k|\theta)\}$, onde θ é o vetor de parâmetros. A determinação da estrutura do modelo $\mathcal{M}(\theta)$ consiste na seleção dentro de um conjunto de modelos \mathcal{M}^* de uma dada representação matemática. O modelo selecionado é aquele que atende os requisitos para a aplicação desejada. O problema pode ser dividido em três subproblemas:

Primeiro - especificar o tipo de modelo a ser usado, ou seja, a estrutura matemática de representação do sistema real a ser usada, que pode ser genericamente expressa por:

$$\hat{y}(k|\theta) = g(\phi(k), \theta) \in \mathbb{R} \quad (4.36)$$

sendo $\hat{y}(k|\theta)$ o valor predito e $g(\phi(k), \theta)$ um modelo matemático tal como os apresentados nas Seções 4.5.2 e 3.4.

Quando a representação matemática for como a apresentada na Seção 3.4 e o sistema for do tipo MIMO, este será decomposto em um conjunto de modelos MISO (“*Mutiple Inputs Sin-*

gle Output”) acoplados. A razão é que esta abordagem é mais flexível se cada saída estiver associada com uma categoria diferente de não-linearidade;

Segundo - determinar as variáveis do modelo, o que implica nas dimensões do problema;

Terceiro - determinar os parâmetros do modelo.

No caso dos sistemas nebulosos TS o segundo e terceiro subproblemas foram discutidos na Seção 3.5.

4.5.4 Validação de modelos

Tendo um conjunto de modelos, é necessário verificar se eles incorporam ou não características de interesse do sistema original. Além disso, é interessante poder comparar os modelos entre si e decidir se há algum candidato significativamente melhor que os demais. Esta etapa é certamente subjetiva, sendo que o resultado da validação dependerá da aplicação pretendida para o modelo e da quantidade de informação disponível sobre o sistema original. Os testes de validação atuam como ferramenta de auxílio no refinamento dos modelos, revelando a presença de erros cometidos na realização dos procedimentos de identificação.

A ausência de algum termo importante no modelo pode provocar polarização dos parâmetros e o aparecimento de dinâmicas espúrias na simulação do modelo. Por essa razão, faz-se necessária a utilização de um critério para determinar se o modelo incorpora as características que lhe são exigidas. Neste trabalho foram considerados as seguintes critérios de validação:

- A raiz quadrática do erro quadrático médio relativo (“*relative Root Mean Squared Error - rRMSE*”) dada por:

$$rRMSE(\hat{y}) = \sqrt{\frac{\sum_{i=1}^{n_y} (\hat{y}_i - y_i)^2}{\sum_{i=1}^{n_y} (\hat{y}_i - \bar{y})^2}} \quad (4.37)$$

, onde \hat{y}_i é a predição da variável observada y pelo modelo e \bar{y} é a média da variável observada.

- A Variância Levada em Conta (VLC) ou “*Variance Accounted For*” (VAF), dada por:

$$VAF(\hat{y}) = 100\% \left(1 - \frac{\sigma^2(\hat{y} - \mathbf{y})}{\sigma^2(\hat{y})} \right) \quad (4.38)$$

, onde \hat{y} é o vetor das predições da variável vetorial \mathbf{y} .

- Os testes de correlação são apresentados e discutidos a seguir.

O procedimento de validação de modelos empíricos consiste em verificar as propriedades de entrada e saída do modelo. Para modelos lineares uma boa prática é a comparação dos diagramas de Bode com a variância do modelo traduzida em um intervalo de confiança, segundo (LJUNG, 1999).

Os testes de correlação com resíduos do modelo identificado detectam se a dinâmica do sistema foi adequadamente modelada. Em modelos lineares são feitos testes de correlação para verificar se os resíduos são brancos e não correlacionados entre si e com o sinal de entrada. Em modelos não lineares é necessária a realização de um conjunto de testes de correlação mais completo que detecte a presença de termos cruzados nos resíduos (BILLINGS; ZHU, 1994).

Na validação estatística de modelos não lineares SISO são normalmente verificadas as seguintes identidades:

$$\Phi_{\xi\xi}(\tau) = E [\xi(t - \tau)\xi(t)] = \delta(0) \quad (4.39)$$

$$\Phi_{u\xi}(\tau) = E [u(t - \tau)\xi(t)] = 0 \quad \forall \tau \quad (4.40)$$

$$\Phi_{\xi\xi(u)}(\tau) = E [\xi(t)\xi(t - 1 - \tau)u(t - 1 - \tau)] = 0 \quad \tau \geq 0 \quad (4.41)$$

$$\Phi_{u^2\xi} = E \left[\left(u^2(t - \tau) - \overline{u^2}(t) \right) \xi(t) \right] = 0 \quad \forall \tau \quad (4.42)$$

$$\Phi_{u^2\xi^2}(\tau) = E \left[\left(u^2(t - \tau) - \overline{u^2}(t) \right) \xi^2(t) \right] = 0 \quad \forall \tau \quad (4.43)$$

, onde $\delta(0)$ é a função delta de Kronecker.

Para um conjunto de dados de comprimento N , define-se um intervalo de confiança de 95%, dado por $\pm 1,96\sqrt{N}$. Se o modelo for não polarizado, os resíduos são brancos e as funções de correlação deverão permanecer dentro do intervalo de confiança de 95% de probabilidade. Qualquer correlação significativa será indicada por um ou mais pontos posicionados fora do intervalo de confiança de 95%.

Os testes de correlação utilizando os resíduos do modelo e os dados do sistema são facilmente calculáveis. Neste trabalho são adotadas a autocorrelação do erro (AutoCorr) dada pela Equação 4.39 e a correlação cruzada do erro com as entradas (Corr) dada pela Equação 4.40. O critério para

utilização de Corr e AutoCorr é a contabilização dos pontos fora do intervalo de confiança de 95% de probabilidade para cada função (4.39 e 4.40).

4.6 Uso de modelos agrícolas e suas limitações

Modelos agrícolas são desenvolvidos por pesquisadores para uma gama variada de usuários que incluem: criadores de animais, agrônomos, fazendeiros e desenvolvedores de políticas de mercados. Os modelos não são universais, assim o usuário tem que escolher o modelo apropriado de acordo com seus objetivos. O modelo sempre contém limitações intrínsecas ao seu processo de concepção que devem ser levadas em conta em uma escolha criteriosa. Desse forma a utilização do modelo deve ser feita dentro das próprias perspectivas de sua concepção para que o sucesso na aplicação seja obtido.

4.6.1 Limitação dos modelos

Os sistemas agrícolas são caracterizados por altos níveis de interação entre componentes que não são completamente compreendidas. Modelos são representações simplificadas da realidade resumindo as informações disponíveis e dessa forma permitem detectar com mais facilidade as lacunas de conhecimento. Para modelar os pontos desconhecido do sistema, o pesquisador usualmente adota equações simplificadas que descrevem extensivamente os subsistemas. As simplificações são adotadas de acordo com o propósito do modelo e ponto de vista do pesquisador, e então, são dotadas de um grau de subjetividade.

Os modelos que não são resultado de uma forte colaboração interdisciplinar são freqüentemente bons na área da especialidade do pesquisador, mas fracos em outras áreas. Neste sentido, este trabalho busca obter um modelo que forneça a possibilidade de oferecer conhecimento à outras áreas, além da área de identificação de sistemas, pela interpretação das respostas do sistema.

A qualidade do modelo está relacionada a qualidade dos dados científicos usados na desenvolvimento e validação do modelo. Neste trabalho apenas o procedimento de coleta dos dados climáticos foi explicitado, porém, nenhuma informação sobre os procedimentos experimentais para a coleta dos dados de campo foi fornecida pelo autor dos experimentos de campo.

A validação do modelo é realizada por simulações para condições diferentes dos experimentos que forneceram os dados para sua elaboração (por exemplo, troca da variedade a ser simulada) determinando a capacidade de generalização do modelo. A necessidade de verificar se o modelo é adequado ao propósito para o qual foi concebido decorre da necessidade de indicar as falhas do pro-

cedimento de modelagem e as características que não foram completamente incorporadas. Mesmo no modelamento mecanísticos isto ocorre, pois sempre existem erros na concepção e ajuste de modelos.

O desempenho do modelo é limitado pela qualidade e representatividade dos dados utilizados na elaboração do modelo. Os dados serão representativos o tanto quanto fornecerem informações sobre o comportamento do sistema a ser modelado. É comum em sistemas agrícolas se ter grandes volumes de dados relacionados ao crescimento e ao desenvolvimento da parte aérea das culturas, enquanto o volume de dados relacionados ao crescimento e desenvolvimento das raízes e das características do solo são menores. Assim, uma modelagem aplicada à estes dois conjuntos de dados simultaneamente, implica em aproximações, normalmente, levando a resultados errados, justificando o uso de uma abordagem modular.

A maioria dos modelos agrícolas necessita de dados meteorológicos confiáveis e completos. Os dados meteorológicos são obtidos de estações pontuais de coleta (estações), assim não há garantias de que representem as variações de uma determinada localização. Geralmente, os dados das variáveis climáticas mais comuns estão disponíveis. Se o conjunto de dados não tiver todas as variáveis necessárias para a estimação da fotossíntese e acumulação da biomassa, os dados pendentes devem ser estimados a partir das variáveis disponíveis, e ainda a base de dados pode estar incompleta, devido à falhas no equipamento de coleta, gerando “*gaps*”, dessa forma o desempenho dos modelos agrícolas varia com a qualidade das informações usadas para sua simulação (ALLEN et al., 1990).

Os usuários necessitam entender a estrutura do modelo escolhido, assim como, suas considerações, limitações e informações sobre o procedimento de simulação antes de iniciar qualquer aplicação. Por exemplo, um modelo como o QCANE (Apêndice B), desenvolvido para o crescimento da cana-de-açúcar em condições sem restrições, poderia levar a análises incorretas se usado para simular a produtividade em condições com restrições de água e de nitrogênio.

4.6.2 Uso de modelos

Os pontos expostos acima indicam muitas restrições para a modelagem de culturas e para a realização de simulações adequadas, mas a literatura recente indica o contrário. A participação do uso de modelos de simulação em aplicações como pesquisa, ensino, no gerenciamento de fazendas e recursos, análises de políticas e predição de produção tem aumentado. Um resumo dos benefícios potenciais que podem ser obtidos a partir do uso da abordagem da modelagem está descrito em (BOOTE; JONES; PICKERING, 1996). Estes autores agruparam as aplicações de modelos em três categorias denominadas: ferramentas de pesquisa, ferramentas de sistemas de gerenciamento de culturas, e ferramentas de análise de políticas. Cada categoria de aplicação contém sub-categorias que

são apresentadas a seguir:

- **Como ferramentas de pesquisa**

Compreensão de pesquisa: O desenvolvimento de modelos permite a integração dos conhecimentos multidisciplinares do sistema agrícola (biologia, química, climatologia, etc) permitindo identificar quais são os fatores mais influentes no comportamento do sistema e pode destacar os pontos deficientes sobre este conhecimento que devem ser esclarecidos.

Integração do conhecimento através de múltiplas disciplinas: A adoção de uma abordagem modular na codificação do modelo permite ao pesquisador capturar em sua pesquisa as disciplinas de maneira independente e que no estágio final integra o conhecimento no modelo.

Melhoramento da documentação de experimentos e organização dos dados: O desenvolvimento de modelos de simulação, teste e aplicação demanda o uso de uma grande quantidade de dados sobre as observações sistemáticas do sistema. A organização sistemática dos dados aumenta a eficiência da manipulação dos dados.

Melhoramento genético: Os modelos de simulação têm se tornado mais detalhados e mecânicos, e podem acompanhar melhor a dinâmica do sistema. A informação mais precisa pode ser obtida com respeito ao impacto de diferentes traços genéticos sobre a produtividade permite integrar os modelos de cultura em programas de melhoramentos genéticos.

Análises de produtividade: Quando um modelo é concebido com características fisiológicas, é possível realizar simulações corretas para ambientes, ou cenários diversos. O uso de vários modelos de simulação para avaliar a produtividade determinada pelos fatores climáticos em várias culturas foi mencionado por (BOOTE; JONES; PICKERING, 1996).

- **Como ferramentas para o sistema de gerenciamento de cultura**

Gerenciamento de culturas: As decisões de gerenciamento considerando as práticas culturais têm um impacto fundamental na produtividade. Os modelos de simulação permitem a especificação de opções de práticas de gerenciamento, oferecendo meios relativamente baratos para avaliar um grande número de estratégias que são muito caras se a experimentação tradicional fosse adotada.

Avaliação de riscos e suporte de investimento: Combinando simulações de produtividade para várias culturas em cada gleba de terra de uma propriedade e estimando as margens brutas de lucro de cada cultura, o risco econômico e a variabilidade relacionada ao clima podem

ser avaliados. Estes dados podem ser utilizados como uma ferramenta de suporte a decisão de investimento, permitindo avaliar qual cultura pode gerar os maiores lucros com o menor risco.

Negócios específicos para uma fazenda: A maximização do lucro pode ser alcançada simulando a produtividade de diversas culturas para cada mancha de solo (área composta por um tipo de solo) de uma fazenda o que permite determinar a máxima produtividade com os menores investimentos.

• Como ferramentas de análises de políticas

Melhores práticas de gerenciamento: Os modelos contendo componentes de lixiviação química⁸ e erosão podem ser usadas para determinar as melhores práticas agrícolas de longo prazo. Pois a erosão reduz produtividade do solo e contribui para o assoreamento dos rios e lixiviação causa a contaminação dos lençóis freáticos, ao longo do tempo.

Predição de produtividade: A predição de produtividade para indústrias sobre grandes áreas é importante para o produtor alocar recursos para a colheita e transporte da produção, agentes processadores (coordenação da moagem, no caso da cana-de-açúcar) assim como para as agências de mercado. Algumas técnicas usam registros meteorológicos com predições de dados para medir a produtividade através da indústria.

Introdução de uma nova cultura: A pesquisa agrícola está relacionada à pré-avaliação de sistemas de cultivo em uma região particular. Como os dados do crescimento e desenvolvimento de uma nova cultura em uma região podem não estar disponíveis, o desenvolvimento de um modelo baseado nos dados científicos coletados em outra localização e alguns conjuntos de dados coletados no novo local auxiliam a avaliar a variabilidade temporal na produtividade usando dados climáticos de longo prazo.

Mudanças climáticas globais e produção de culturas: Os níveis crescentes de CO₂ e outros gases estufa contribuem para o aquecimento global com as mudanças associadas as mudanças nos padrões de chuvas. Avaliar estes efeitos e mudanças na produtividade das culturas é importante para o produtor, assim como o é para o planejamento governamental.

⁸Lixiviação química é a passagem de uma solução através de um leito poroso ativo com o qual ela interage para extrair componentes solúveis.

Capítulo 5

Modelagem dos Processos de Acumulação de Biomassa e de Açúcar da Cana-de-açúcar

5.1 Introdução

Neste capítulo serão utilizados os conceitos e técnicas apresentados nos Capítulos 4 e 3 para construir os modelos para prever a acumulação de biomassa e de açúcar da cana-de-açúcar.

5.2 Conjunto de dados

Os conjuntos de dados utilizados são do Departamento das Estações Experimentais do Açúcar em Bundaberg (*Bundaberg SES-Station Experimental of Sugar*), na província de Queensland (Latitude 24,84° Sul e Longitude 152,43° Leste), Austrália. A opção pela utilização de dados de variedades de cana-de-açúcar cultivadas na Austrália se deve ao fato deste conjunto ter sido utilizado pelo Prof. De Li Liu para validar o modelo QCANE o qual, segundo O'Leary (O'LEARY, 2000), é o modelo mais preciso da atualidade. Dessa forma poderemos comparar os resultados obtidos neste trabalho com os resultados do modelo QCANE. Além disso, os experimentos sobre cana-de-açúcar no Brasil não possuem uma base central de dados, como na Austrália, estando fragmentados nas mãos dos pesquisadores e normalmente focados a objetivos específicos de cada pesquisa ou trabalho.

Os dados de radiação e temperatura, foram coletados em uma estação meteorológica a trezentos metros do campo experimental, apresentados na Figura 5.1. A temperatura média é a média entre as temperaturas máxima e mínima de um período de 24 horas. A temperatura tem uma relação direta

com a radiação solar como demonstrado em (ALLEN et al., 1990). Esta relação tem uma variação entre regiões costeiras e as do interior do continente.

Os dados da radiação solar utilizados pelo modelo são computados pela radiação que atingiu uma superfície perpendicular, em relação ao momento de maior incidência luminosa ao longo do fotoperíodo. As medidas de radiação sofrem influências de eventos externos no local de coleta, como a passagem de nuvens no céu. A radiação é a fonte de entrada de energia nos sistemas agrícolas afetando diretamente a umidade relativa do ar, a formação de ventos, a precipitação e a temperatura.

As amplitudes da variação sazonal de temperatura e radiação, em condições normais, são função da latitude. Assim quanto maiores forem as latitudes maiores serão as variações de temperatura e radiação.

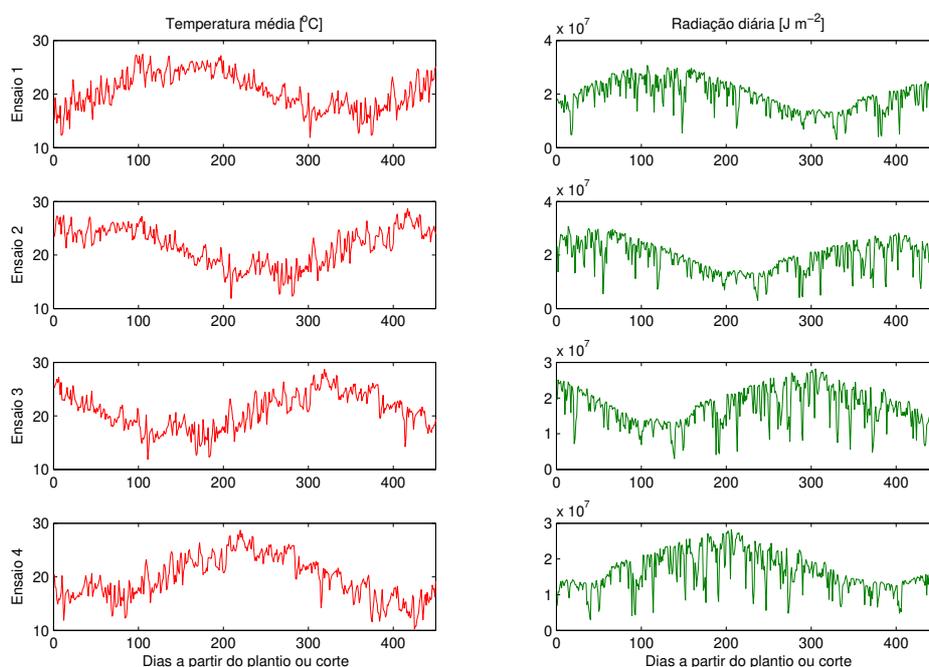


Fig. 5.1: Dados de entradas do modelo

O gráfico de correlação-cruzada entre os dados das duas variáveis de entrada indicou que poderia ser adotada apenas uma das duas variáveis, assim como em (CRUZ, 1998). As curvas de radiação solar apresentam variações mais intensas por serem mais suscetíveis a perturbações pontuais, as curvas da temperatura média, por sua vez, apresentam perturbações de menor intensidade do que a radiação pois, dependem de características regionais. Assim, as duas variáveis serão avaliadas individualmente no procedimento de identificação, posteriormente, podem vir a ser combinadas neste procedimento.

Um sistema de irrigação por sulcos (Figura 5.2), ou inundação, foi usado para garantir que não houvesse a deficiência hídrica. A umidade no solo era monitorada por uma ponta neutra para determinar quando esta irrigação deveria ser utilizada no campo experimental. As aplicações de fertilizantes e manejos culturais foram aplicados de maneira a prevenir limitações de nutrição ao crescimento da cultura e manter uma condição livre de pragas.

As condições estabelecidas para os experimentos, em que foram coletados os dados, visavam ser ideais para o crescimento da cultura de cana-de-açúcar. Dessa forma, o modelo baseado nestes dados irá determinar um modelo de predição da produtividade potencial, ou produtividade máxima, segundo os conceitos estabelecidos por *de Wit* e apresentados em (BOUMAN et al., 1996). Este tipo de modelo visa determinar os níveis de acumulação máxima de matéria seca, considerando apenas que as variações climáticas afetam o comportamento do desenvolvimento da cultura.

Os modelos de produtividade potencial máxima são utilizados na fase inicial de estudos de delimitação de zonas agroecológicas para determinar quais regiões têm condições climáticas de sustentar produtores de determinada cultura. A comparação do nível de produtividade potencial com o nível de produtividade economicamente viável determina quais regiões oferecem condições econômicas para cultivar determinada cultura. Quando a produtividade economicamente viável é acrescida de uma margem de risco é possível delimitar as regiões geográficas para uma determinada cultura em uma primeira aproximação do processo de delimitação de zonas agroecológicas.

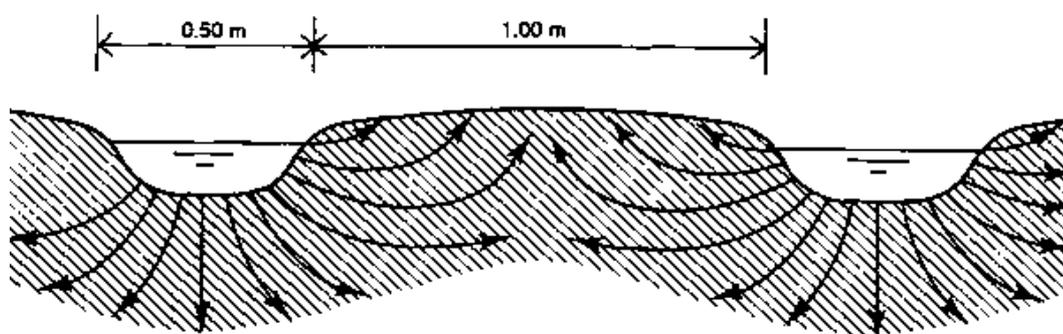


Fig. 5.2: Irrigação por sulcos ou inundação

Os dados da cana-de-açúcar foram obtidos pelo processo de amostragem destrutiva¹ e as variáveis amostradas foram: o Peso Seco acumulado total (PS), a massa acumulada de Fibra (F) e a massa acumulada de Açúcar (A), por unidade de área. Estas serão as variáveis de interesse, ou seja, que desejamos modelar. A amostragem ocorreu com maior frequência para o PS pelo menor custo asso-

¹Amostragem destrutiva ocorre quando ao retirar uma amostra de uma parcela esta amostra não pode ser reincorporada. Por exemplo, quando se retira um carro da linha de montagem para realizar um teste de colisão não se pode devolver este carro a linha de montagem, pois o carro foi destruído pelo teste realizado.

ciado a coleta dessa amostra. As amostras de F e A ocorreram em uma frequência menor, devido ao maior custo envolvido nas observações. Nos dois casos as amostras foram realizadas em intervalos irregulares de tempo. As informações sobre os procedimentos de análise e coleta do material em campo não foram divulgadas. Os dados de PS, F e A foram interpolados com funções gaussianas para estimar os valores destas variáveis no período entre as amostras, uma vez que os dados sobre as variáveis climáticas foram coletadas diariamente. As funções gaussianas são normalmente empregadas, direta ou indiretamente, nos modelos de cana-de-açúcar para modelar os dados de acumulação de massa da cana-de-açúcar (INMAN-BAMBER, 1995; JONES et al., 1986; O'LEARY et al., 1999; MACHADO, 1981).

Os dados utilizados neste trabalho são de duas variedades de cana-de-açúcar cultivadas na Austrália, a Q138 e a Q141, e as amostras destas variedades foram coletadas nos mesmos dias. Estes dados foram utilizados na validação do modelo QCANE (LIU; BULL, 2001). O modelo aqui proposto utiliza metade deste conjunto de dados para construir o modelo e a outra metade para sua validação. Assim, o modelo proposto pode ser comparado com o QCANE já que ambos são simulados com o mesmos dados de entrada e o critério de erro é avaliado com os mesmo dados de saída.

As Figuras de 5.3 a 5.5 apresentam os dados e as curvas interpoladas de PS, A e F, respectivamente, para a variedade Q138.

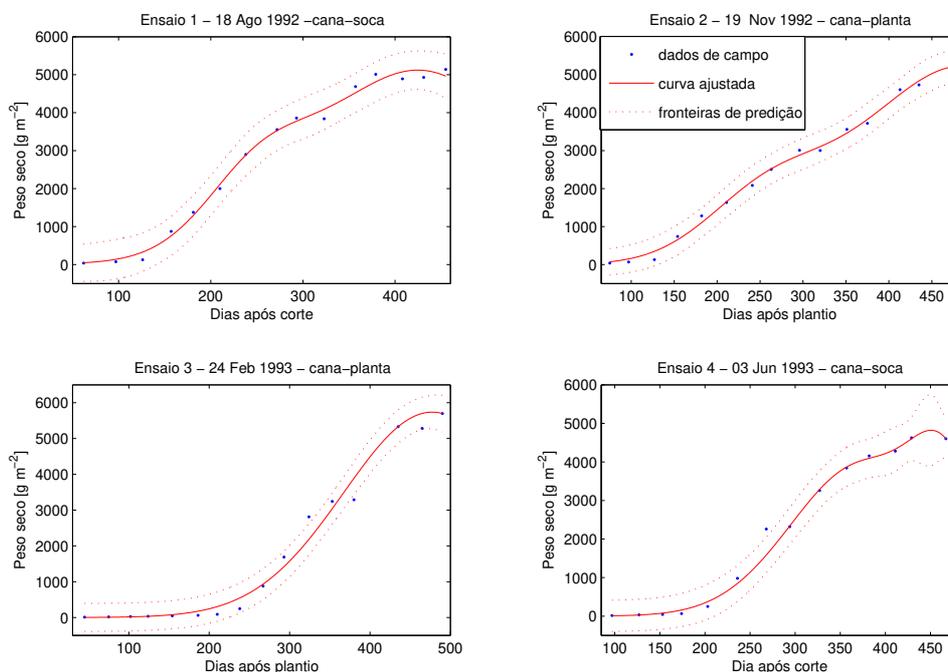


Fig. 5.3: Dados da acumulação de matéria seca de colmo da variedade Q138

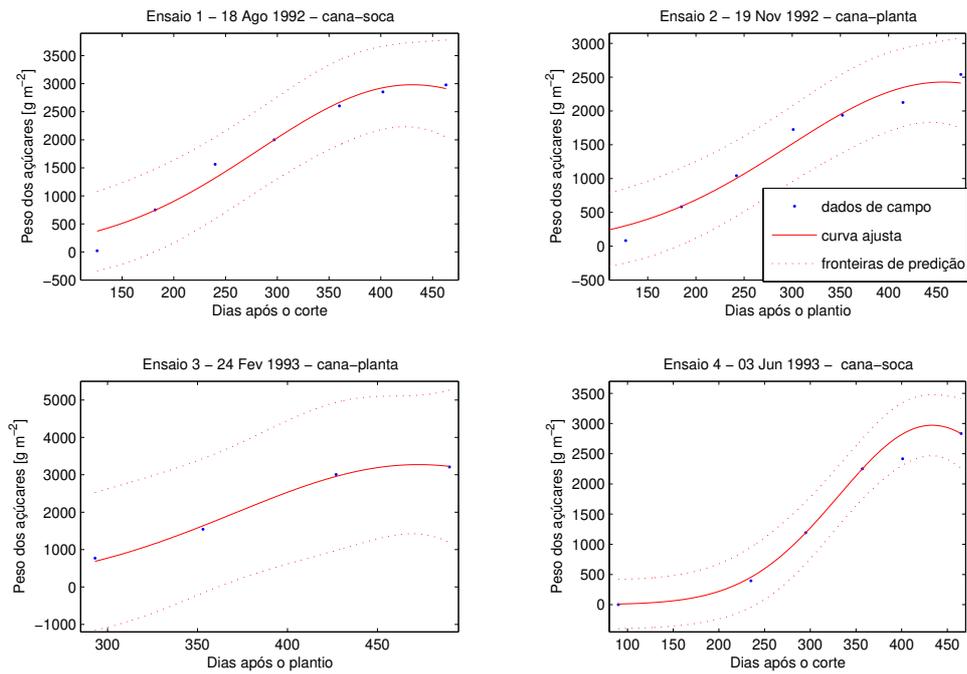


Fig. 5.4: Dados da acumulação de açúcar da variedade Q138

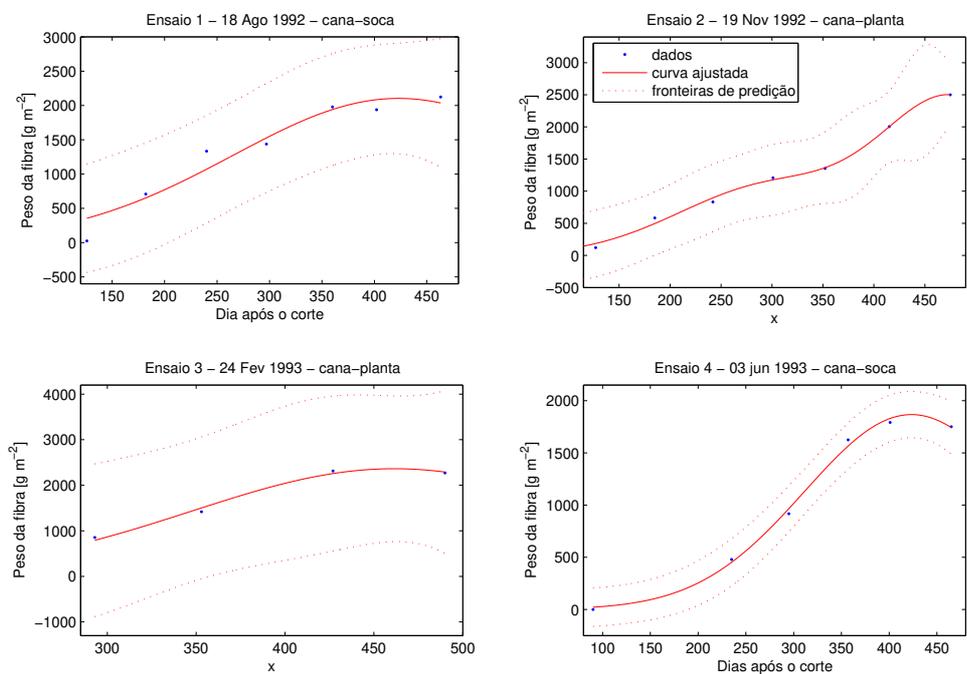


Fig. 5.5: Dados da acumulação de fibra na variedade para Q138

As Figuras de 5.6 a 5.8 apresentam os dados e as curvas interpoladas de PS, A e F, respectivamente, para a variedade Q141. A variedade Q138 apresenta um maior acúmulo de fibra do que a variedade Q141.

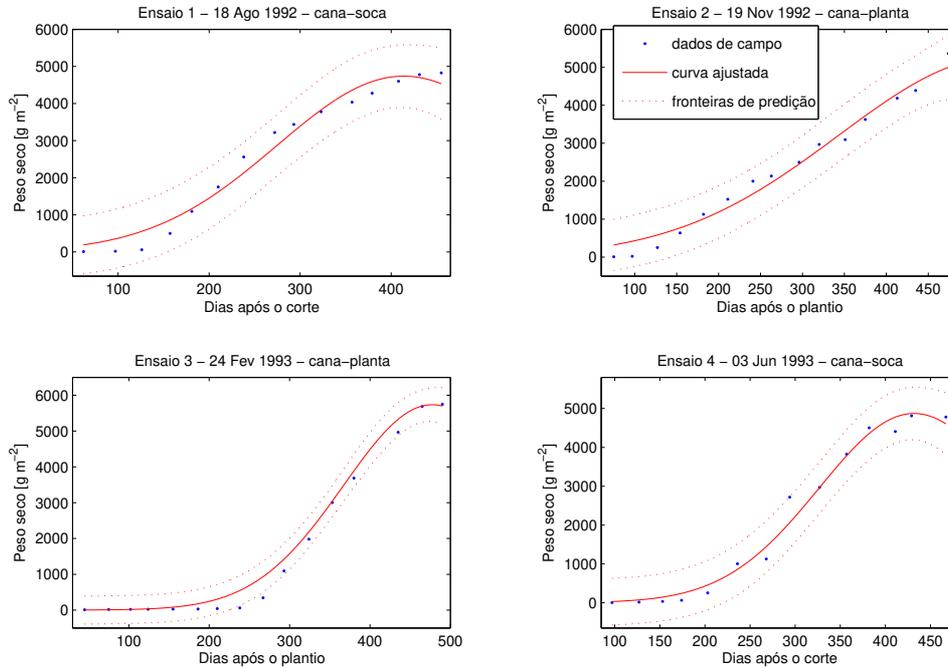


Fig. 5.6: Dados da acumulação de matéria seca de colmo da variedade Q141

Observando as curvas interpoladas de PS com relação as curvas de A e de F nota-se que os intervalos de confiança das curvas ajustadas de PS são menores, devido à maior quantidade de dados disponíveis. Dessa forma, os valores interpolados de PS são mais confiáveis do que os de A e de F. Então, a representação matemática do modelo e a sua estrutura serão determinados baseados nos dados do PS, e posteriormente o modelo para a fibra e a açúcar serão determinados usando a mesma estrutura e representação.

A escolha do uso dos dados de PS para determinar a representação matemática e a estrutura do modelo está fundamentada nos resultados de Liu (LIU; KINGSTON, 1993) e na composição tecnológica da cana-de-açúcar (CESAR; SILVA, 1993b). Esta literatura afirma e comprova que a composição do PS do colmo é expressa por:

$$PS = A + F + S, \tag{5.1}$$

onde *S* representa substâncias diversas presentes na composição do colmo. Além disto, estabelece

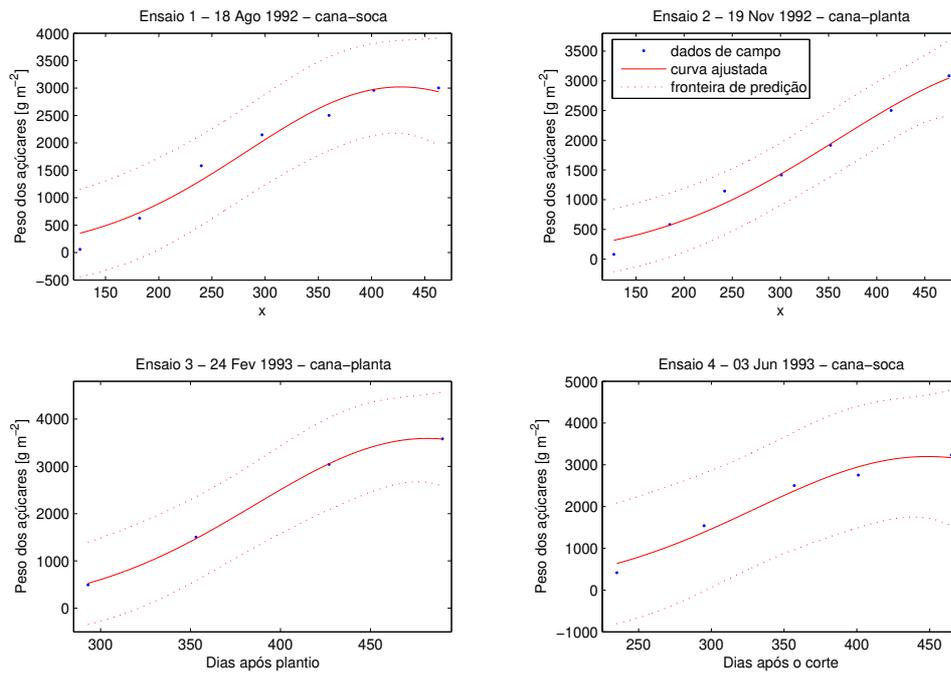


Fig. 5.7: Dados da acumulação de açúcar da variedade Q141

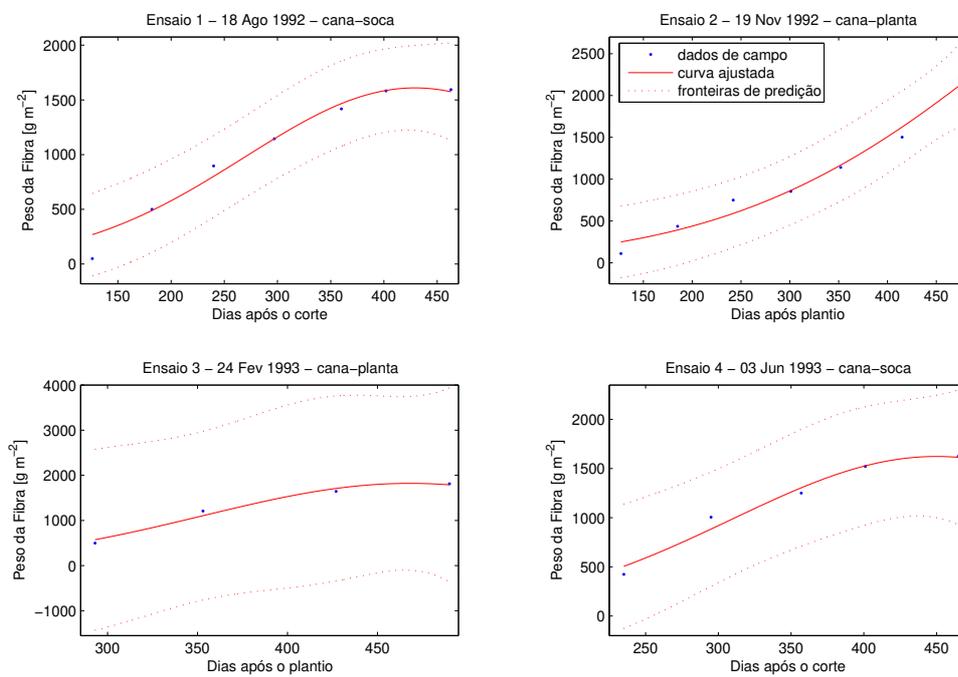


Fig. 5.8: Dados da acumulação de fibra na variedade para Q141

que a fração de S na composição do PS é pequena ($S \ll PS$), e dessa forma, o PS pode ser expresso por:

$$PS = gA + gF, \quad (5.2)$$

onde g pode ser considerado uma constante (LIU; KINGSTON, 1993). Dessa forma, a acumulação do PS seria uma combinação linear de A e F com pesos g . Então, está sendo considerado que a relação inversa também é válida, assim, a representação matemática e de estrutura do modelo adequados para o PS também são adequadas para o açúcar e para a fibra.

Os dados são correspondentes a 4 ensaios descritos a seguir:

Ensaio 1 - realizado para o primeiro corte da cana-de-açúcar com data de corte (início) em 18 de Agosto de 1992.

Ensaio 2 - realizado para um bloco plantado de cana-de-açúcar, com data de plantio (início) em 19 de Novembro de 1992.

Ensaio 3 - realizado para um bloco plantado de cana-de-açúcar, com data de plantio (início) em 24 de Fevereiro de 1993.

Ensaio 4 - realizado para o primeiro corte da cana-de-açúcar, com data de corte (início) em 03 de junho de 1993.

Para simplificar a nomenclatura iremos denominar cada conjunto por Ensaio indicando o seu número e a variedade correspondente.

Os conjuntos de dados dos Ensaios 2 e 4 serão utilizados para a determinação do modelo seguindo o procedimento de identificação. Estes ensaios representam situações de desenvolvimento opostas para a cana-de-açúcar: no Ensaio 2 a cana-de-açúcar foi plantada tendo um desenvolvimento inicial mais lento, porém o período favorece o desenvolvimento da cultura; no Ensaio 4 a cana-de-açúcar estava no ciclo soca, que costuma ter um desenvolvimento inicial mais rápido, porém o corte ocorreu no período de inverno que não favorece o desenvolvimento da cultura. Nos Ensaios 1 e 3 as situações climáticas são opostas às dos Ensaios 4 e 2, respectivamente. Dessa forma estes ensaios são adequados para verificar a capacidade de extrapolação do modelo.

5.3 Pré-processamento dos dados

5.3.1 Determinação do período de amostragem

Nota-se nas curvas dos dados de saída que o sistema apresenta um comportamento dinâmico lento com relação às variações dos dados de entrada do sistema. Então, convém verificar se o passo de tempo diário é adequado para modelar este sistema. Inicialmente se considerou os dados referentes ao PS das duas variedades e num segundo momento os dados de F e de A.

Os atrasos mínimo apresentados na Tabela 5.1 foram obtidos através das funções de autocovariância apresentadas na Seção 4.5.1.2.

	Variedades	
	Q138	Q141
Ensaio 1	270	285
Ensaio 2	289	304
Ensaio 3	300	305
Ensaio 4	276	289
Mínimo	276	285

Tab. 5.1: Os atrasos mínimos, em dias, de cada ensaio e variedade determinados através dos gráficos de correlação

Observando os valores da Tabela 5.1 verificou-se a necessidade de decimar o sinal amostrado para que o atraso mínimo esteja dentro da faixa adequada (AGUIRRE, 2000). Seguindo o procedimento da Seção 4.5.1.2 foram calculadas as faixas do fator de decimação Δ de cada variedade.

Devido ao fato dos quatro ensaios apresentarem uma variação pequena entre seus pontos de atraso mínimo, adotou-se o menor ponto de atraso mínimo entre os ensaios como o valor base para se determinar o fator de decimação.

Na Tabela 5.2 pode-se observar que as variedades Q141 e Q138 têm uma pequena diferença nos valores do fator de decimação. Isto se deve ao fato dessas duas variedades compartilharem o mesmo tempo de desenvolvimento. Provavelmente, a faixa de valores do fator de decimação deve apresentar maiores variações para variedades que tenham período de desenvolvimento mais curto.

O mesmo procedimento foi aplicado aos dados de F e A, resultando na Tabela 5.3. Pode ser observado que as faixas de valores do fator de decimação são semelhantes às do PS. Assim pode-se

Faixa de valores do fator Δ		
Variedade	Valor mínimo	Valor máximo
Q138	13,5	27
Q141	14,25	28,5

Faixa de valores relaxados do fator Δ		
Variedade	Valor mínimo	Valor máximo
Q138	6,7	36
Q141	7,1	38

Tab. 5.2: Faixa dos valores do fator de decimação para o Peso Seco

adotar uma taxa comum para todas as variáveis de interesse.

Considerando as faixas de valores para o fator de decimação, apresentados na Tabela 5.2 e 5.3, julgou-se 22 como o valor mais adequado para o fator de decimação. Este valor está dentro da faixa de valores permitidos para as duas variedades e para todas as variáveis. Um fator de decimação comum permite gerar um modelo na mesma base de tempo para as duas variedades.

Aplicando o fator de decimação no período de amostragem (1 dia) resulta num período de amostragem de 22 [dias]. Este período representa aproximadamente 3 semanas, assim o modelo proposto deve prever com uma antecedência de 22 dias as acumulações de PS, F e A pela cana-de-açúcar. Esta janela de tempo é conveniente por permitir organizar a programação das atividades sucroalcooleiras de campo.

A Figura 5.9 apresenta os dados do PS após a aplicação do fator de decimação para a variedade Q138, onde as cruzetas demarcam os pontos reamostrados. Resultados similares foram apresentados para a variedade Q141.

5.3.2 Detecção de não-linearidades

A detecção de comportamento não-linear nos dados foi realizada utilizando a Equação 4.5, da Seção 4.5.1.4. Foi verificada a presença de comportamento não-linear, segundo o critério estabelecido, na Seção 4.5.1.4, nos dados de todas as variáveis nos ensaios das duas variedades. Assim, pode ser afirmado que este sistema é não-linear.

Faixa de valores do fator Δ				
	Açúcar		Fibra	
Variedade	Valor mínimo	Valor máximo	Valor mínimo	Valor máximo
Q138	14,4	28,9	14,3	28,7
Q141	14,4	28,8	14,4	28,8

Faixa de valores relaxados do fator Δ				
	Açúcar		Fibra	
Variedade	Valor mínimo	Valor máximo	Valor mínimo	Valor máximo
Q138	7,4	38,5	7,2	39,6
Q141	7,4	38,5	7,4	38,5

Tab. 5.3: Faixas do valor do fator de decimação para a Fibra e o Açúcar.

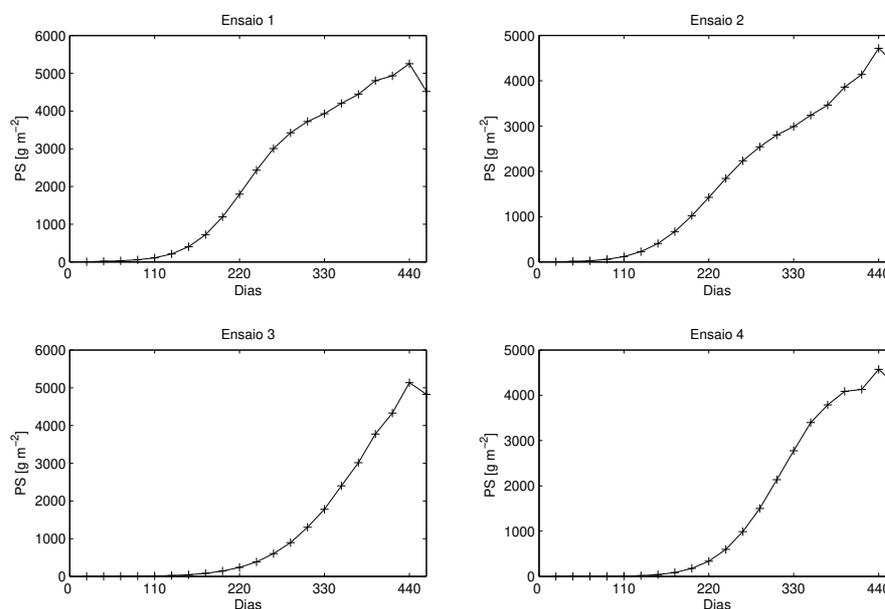


Fig. 5.9: Gráficos com os dados reamostrados de PS para a variedade Q138

As curvas da função de covariância cruzada para os dados de PS da variedade Q138 são apresentadas na Figura 5.10. Podemos observar que a condição de não-linearidade está presente em todos os gráficos.

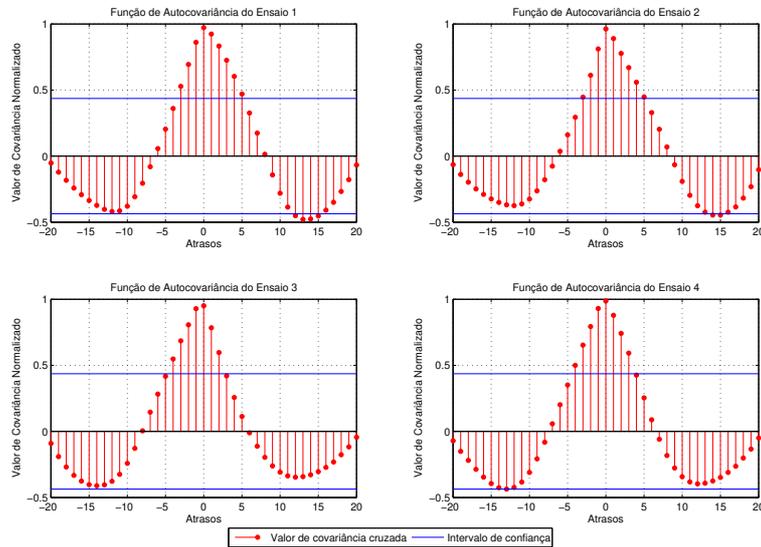


Fig. 5.10: Curvas da covariância cruzada para os dados dos ensaios da variedade Q138

Apesar do sistema conter características não-lineares, segundo os testes realizados, estes não indicam a intensidade deste comportamento não-linear. Dessa forma são realizados testes com as estruturas matemáticas de modelos contínuos de processos e modelos ARX para verificar se as não-linearidades deste sistema não permitem o uso de modelos lineares.

5.4 Identificação com Modelos Lineares

5.4.1 Modelo ARX

Inicialmente é avaliado o desempenho da representação matemática de modelos lineares ARX SISO (Seção 4.5.2.8) considerando o PS como variável de saída e a radiação, inicialmente, como variável de entrada e posteriormente, a temperatura.

Utilizou-se do critério AIC (“*Akaike’s Information Criterion*”) para a seleção da estrutura mais adequada; para mais detalhes (LJUNG, 1999, pg 505-507). Este critério foi utilizado através da rotina implementada nas ferramentas computacionais de identificação de sistemas disponíveis no Matlab©, e implementadas por Ljung, (LJUNG, 1999).

Durante as simulações verificou-se que devido às características não lineares presentes nos dados a utilização do critério AIC não é adequada. A seleção da melhor estrutura de modelo variava, durante as simulações, com o tamanho do conjunto de estruturas a serem avaliadas pelo critério. O conjunto de estruturas sugerido supunha que o melhor modelo deveria ter um polinômio $A(q)$ com a ordem variando de 1 à 8 e um polinômio $B(q)$ com a ordem variando na mesma faixa de valores e com um atraso de resposta entre 1 à 8 períodos de amostragem, gerando assim um conjunto de 512 estruturas possíveis. Quando o conjunto de estruturas candidatas é modificado, para qualquer uma das especificações, o critério determina uma estrutura ótima diferente pelo critério usado.

Aplicando o critério AIC para o conjunto de estruturas acima, seleciona-se a estrutura para o modelo ARX SISO considerando a Radiação como variável de entrada, com ordem 1 para $A(q)$, ordem 1 para $B(q)$ e com um atraso de 4 períodos de amostragem. Os parâmetros deste modelo são:

$$A(q) = 1 - 0,9939q^{-1}$$

$$B(q) = 1,729 \cdot 10^{-5}q^{-4}.$$

Este modelo é estável, porém está muito próximo das condições de limites para um sistema estável. Várias simulações foram realizadas e os modelos obtidos sempre apresentavam ou desempenhos de precisão inferior ou instabilidade no modelo obtido.

Para o modelo ARX SISO considerando a Temperatura Média como variável de entrada obteve-se a seguinte estrutura:

$$A(q) = 1 + 0,1029q^{-1} - 2,514q^{-2} + 1,38q^{-3}$$

$$B(q) = -44,72q^{-1} + 28,52q^{-2} + 24,48q^{-3}$$

Este modelo é instável tendo todos os pólos e zeros fora do círculo unitário que delimita a instabilidade do sistema. Em outras tentativas outras ordens de modelo foram determinadas, mas os melhores resultados não superaram os resultados do modelo ARX da radiação.

A Figura 5.11 mostra as predições do modelo ARX SISO considerando a Radiação Solar como variável de entrada (apresentado acima) e a Figura 5.12 mostra as predições do modelo ARX SISO considerando a Temperatura Média como variável de entrada (apresentado acima), considerando os dados da variedade Q138.

A avaliação de desempenho entre as estruturas será realizada baseadas nos critérios apresentados na Seção 4.5.4. A correlação cruzada do erro com a entrada (Corr) para todos os modelos e na

simulação de todos os ensaios foi zero, assim a aplicação deste critério não foi apresentada pois não apresentaria nenhuma distinção entre os modelos.

Nota-se que as previsões do modelo ARX construído considerando a Radiação, como variável de entrada, apresentou resultados melhores do que as do modelo construído com a Temperatura, como comprova a Tabela 5.4, nas condições de simulação computacional consideradas acima.

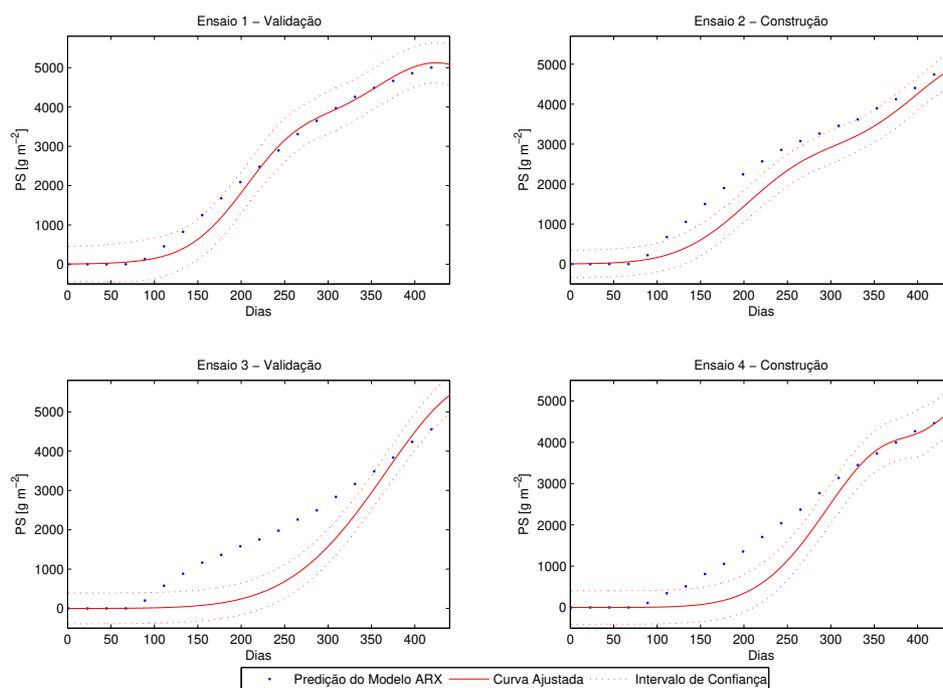


Fig. 5.11: Curvas com as previsões do Modelo ARX SISO considerando a Radiação Solar como a variável de entrada

Observando os resultados destes dois modelos e considerando os problemas em definir uma estrutura adequada para modelar o sistema proposto de forma sistemática, esta representação matemática foi considerada inapropriada para modelar o sistema proposto. Assim, outras representações matemáticas serão avaliadas para modelar o sistema proposto.

5.4.2 Modelos contínuos de processos

A representação matemática de modelos contínuos de processos também foi avaliada para representar os processos de acumulação de biomassa e de açúcar pela cana-de-açúcar, por duas razões principais: os elementos que compõem a estrutura deste modelo têm uma funcionalidade e um significado bem específicos o que facilita a seleção da estrutura desta representação; e os processos de

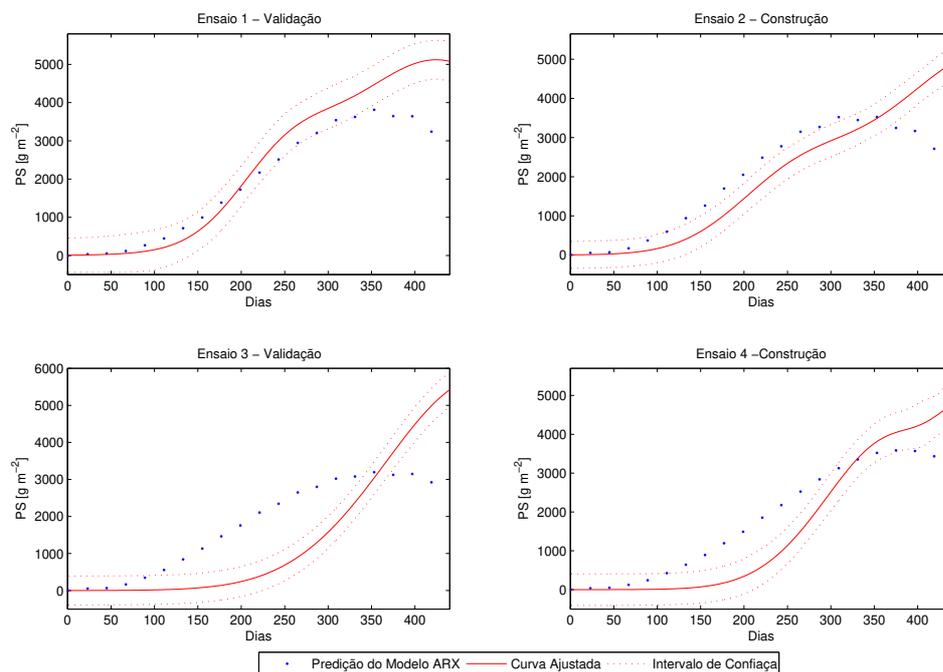


Fig. 5.12: Curvas com as previsões do Modelo ARX SISO considerando a Temperatura Média como a variável de entrada

		Modelo ARX SISO					
		Radiação			Temperatura Média		
Ensaio		rRMSE	VAF	Corr	rRMSE	VAF	Corr
Validação	1	0,2282	97,1	9	0,3421	89,7	7
	3	0,5529	83,2	8	0,7582	50,1	4
Construção	2	0,4541	90,0	9	0,5797	67,1	7
	4	0,3243	93,0	13	0,4676	79,6	10

Tab. 5.4: Avaliação dos erros para os modelos ARX para a predição de acumulação de Peso Seco considerando a radiação e a temperatura média, respectivamente como variáveis de entrada.

acumulação de massa pela cana-de-açúcar têm características similares ao elemento integrador que pode compor a estrutura de um modelo contínuo de processo. A suposição de que os processos de acumulação da cana-de-açúcar têm um modelo contínuo com um elemento integrador veio da observação da resposta dos gráficos de correlação com dados de modelos contínuos apresentados no Apêndice A, na Seção A.3.

Simulações foram realizadas considerando algumas composições de modelos contínuos de processos, nas quais todas continham o elemento integrador e o elemento atraso. A nomenclatura para a representação dos modelos foi apresentada na Seção 4.5.2.5.

A Figura 5.13 apresenta as simulações de um modelo contínuo considerando que o sistema poderia ser representado por apenas um integrador e um atraso, descrito pela Equação 4.17, considerando a Radiação como variável de entrada.

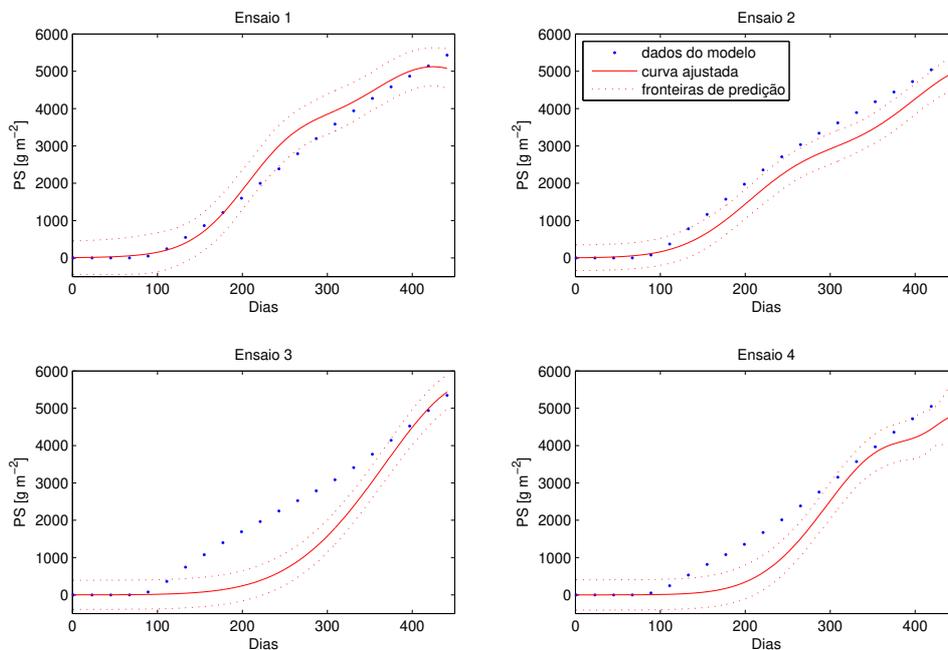


Fig. 5.13: Resposta do modelo de processo composto por um integrador e um atraso

Observa-se através das Figuras 5.13 e 5.11 que esta estrutura de modelo contínuo obteve um resultado próximo ao do modelo ARX, na aproximação da dinâmica do sistema. Foram avaliadas outras estruturas de modelos contínuos de processos para este sistema, na tentativa de obter o modelo com o melhor desempenho. A avaliação de desempenho entre as diferentes estruturas é baseada nos critérios apresentados na Seção 4.5.4. Assim, a partir dos resultados foram geradas as Tabelas 5.5 e 5.6.

A Tabela 5.7 apresenta os parâmetros dos modelos que foram simulados para determinar os resultados das Tabelas 5.5 e 5.6.

		Modelos de Processos			
		Variedades			
		Q138		Q141	
Modelos	Ensaio	rRMSE	VAF	rRMSE	VAF
P0ID	1	0,1460	98,4	0,6815	77,9
	2	0,2792	97,6	0,5114	78,8
	3	0,5280	87,1	0,1844	96,6
	4	0,3346	95,7	0,3550	94,2
$G(s) = \frac{K}{s} e^{-t_d s}$					
P1ID	1	0,2684	95,1	0,4445	85,9
	2	0,6228	89,0	0,8445	66,5
	3	0,7347	86,6	0,7785	82,0
	4	0,5691	91,9	0,5115	92,0
$G(s) = \frac{K}{s(1+t_p s)} e^{-t_d s}$					

Tab. 5.5: Avaliação de duas estruturas contínuas de modelos de processos considerando a Temperatura Média como entrada e o PS como saída

Observando os resultados dos critérios de avaliação apresentados nas Tabelas 5.5 e 5.6 verificou-se erros elevados para esta representação matemática, que podem ser percebidos através dos gráficos, uma vez que na grande maioria das simulações as curvas do modelo ficaram fora dos limites de confiança da curva ajustada. Então, foi comprovado que esta representação matemática não é adequada para representar o sistema.

Modelos		Modelos de Processos			
		Variedades			
		Q138		Q141	
Modelos	Ensaio	rRMSE	VAF	rRMSE	VAF
P0ID $G(s) = \frac{K}{s} e^{-t_d s}$	1	0,1604	97,5	0,3234	89,6
	2	0,2959	96,5	0,4245	85,2
	3	0,4160	90,5	0,3981	88,6
	4	0,2316	97,6	0,0972	99,2
P1ID $G(s) = \frac{K}{s(1+t_p s)} e^{-t_d s}$	1	0,2090	96,6	0,4445	85,9
	2	0,3758	95,2	0,8445	66,5
	3	0,4550	90,9	0,7785	82,0
	4	0,2861	97,0	0,5115	92,0

Tab. 5.6: Avaliação de duas estruturas contínuas para modelos de processos considerando a Radiação Solar como entrada e o PS como saída

		Modelos Contínuos de Processos	
		Q138	
		Radiação	Temperatura
POID			
$G(s) = \frac{K}{s} e^{-t_d s}$	K	$9,0 \cdot 10^{-7}$	0,7
	t_d	100,5	80,2
PIID			
$G(s) = \frac{K}{s(1+t_p s)} e^{-t_d s}$	K	$9,5 \cdot 10^{-7}$	1,1
	t_p	40,7	139,0
	t_d	62,4	0

		Q141	
		Radiação	Temperatura
POID			
$G(s) = \frac{K}{s} e^{-t_d s}$	K	$1,0 \cdot 10^{-6}$	1,2
	t_d	136,7	222,9
PIID			
$G(s) = \frac{K}{s(1+t_p s)} e^{-t_d s}$	K	-11,8	0,6
	t_p	$2,0 \cdot 10^8$	$1,0 \cdot 10^{-3}$
	t_d	351,2	660

Tab. 5.7: Parâmetros dos modelos contínuos

5.5 Identificação com Modelos Nebulosos

As análises das utilizações das representações matemáticas lineares discretas e contínuas indicaram que estas não são adequadas para modelar a dinâmica do sistema, pois as não-linearidades presentes inviabilizam o uso destas. Optou-se então pela representação matemática nebulosa para modelar este sistema, pelas características apresentadas no Capítulo 3.

O procedimento adotado para identificação de sistemas nebulosos é constituído de duas partes principais. Na primeira parte realiza-se a determinação e a avaliação dos agrupamentos nebulosos considerando os algoritmos de agrupamento (da Seção 3.6) e o conjunto de variáveis da entrada do modelo. Na segunda parte determinam-se os parâmetros do consequente do modelo e o desempenho do modelo nebuloso observando os critérios de validação.

5.5.1 Métodos de agrupamento

O desempenho dos métodos de agrupamento depende da seleção adequada das variáveis de entrada do modelo. Assim como realizado anteriormente, nesta etapa será considerada cada variável de

entrada de clima separadamente, porém será considerada uma retro-alimentação. Então o espaço de entrada é composto pela variável de saída defasada, devido à retro-alimentação, e por uma das duas variáveis climáticas.

Experimentos computacionais realizados considerando a Radiação Solar como variável climática de entrada indicaram problemas para modelar o sistema. Os dados desta variável contêm perturbações de intensidade elevada que não refletem nos dados do processo e por isso causam um mal condicionamento numérico na determinação dos consequentes. Então, optou-se por trabalhar apenas com Temperatura Média como a variável climática de entrada.

Os agrupamentos serão determinados considerando que o espaço antecedente é composto pelos dados de uma retro-alimentação simples, com apenas um atraso (y_{k-1}), e da Temperatura Média (u_k). A escolha de uma retro-alimentação simples foi baseada nas observações dos resultados obtidos com os modelos lineares discretos, nos quais verificou-se que um modelo com esta estrutura conseguia aproximar adequadamente alguns ensaios das duas variedades. Apesar dos modelos nebulosos terem características bem diferentes dos modelos lineares, a estrutura de um modelos linear razoável é sempre uma boa referência para a elaboração de um modelo nebuloso. A taxa de amostragem para esta estrutura de modelo será a mesma utilizada nas Seções 5.4.1 e 5.4.2 para podermos comparar os modelos obtidos nesta seção com os resultados anteriores.

Os resultados do Algoritmo de Agrupamento GK considerando 2, 3 e 4 centros de agrupamento são apresentados nas Figuras 5.14, 5.15 e 5.16.

No caso de 2 agrupamentos determinados pelo Algoritmo GK, apresentado na Figura 5.14, observa-se uma nítida partição da variável Temperatura Média considerando as projeções ortonormais dos centros sobre o eixo desta. Para a variável de retro-alimentação (y_{k-1}), ocorre uma sobreposição entre os dois agrupamentos considerando as projeções ortonormais sobre o eixo desta variável. Esta configuração dos agrupamentos será considerada para a extração das funções de pertinência e determinação dos coeficientes dos consequentes.

No caso de 3 agrupamentos determinados pelo Algoritmo GK, apresentado na Figura 5.15, observa-se que a projeção ortonormal de dois destes (superior esquerdo e diagonal central) pode resultar na sobreposição das funções de pertinência nos eixos de cada uma das duas variáveis, porém em menor intensidade do que no caso anterior. Esta configuração também será considerada nas próximas etapas do processo de determinação do modelo, devido à boa partição do espaço de entrada pelos agrupamentos.

No caso de 4 agrupamentos determinados pelo Algoritmo GK, apresentado na Figura 5.16, observa-se uma concentração destes no lado direito da figura e este resultado foi considerado ina-

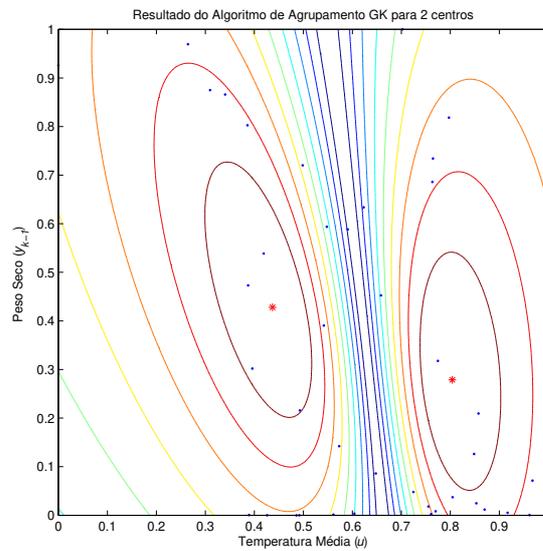


Fig. 5.14: Resultado do Algoritmo de Agrupamento GK considerando 2 centros, os (\bullet) em azul são os dados e os ($*$) são os centros dos agrupamentos, e as curvas são os α -cortes (faixas de pertinência).

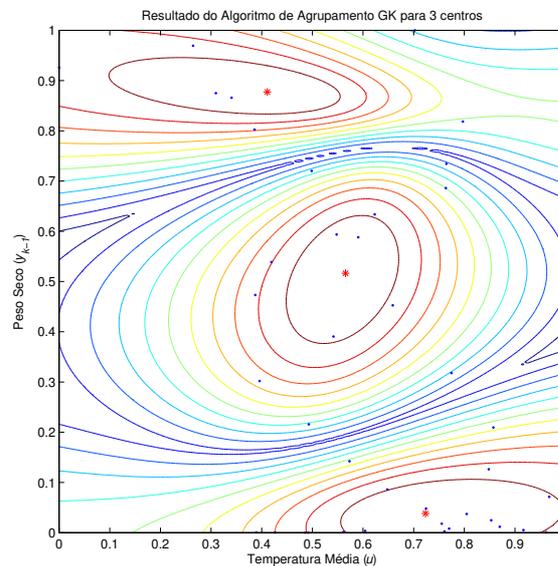


Fig. 5.15: Resultado do Algoritmo de Agrupamento GK considerando 3 centros, os (\bullet) em azul são os dados e os ($*$) são os centros dos agrupamentos, e as curvas são os α -cortes.

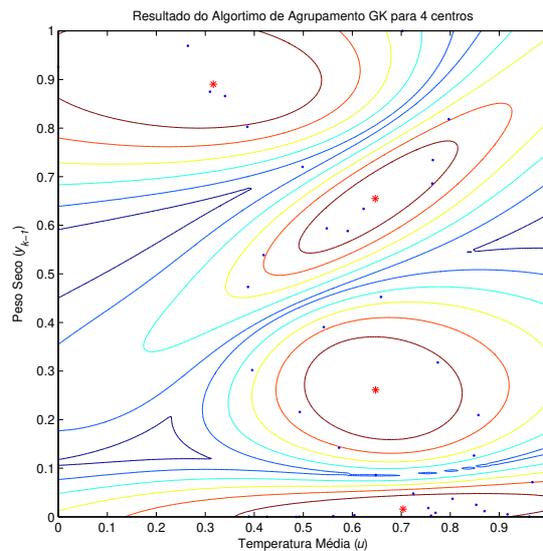


Fig. 5.16: Resultado do Algoritmo de Agrupamento GK considerando 4 centros, os (●) em azul são os dados e os (*) são os centros dos agrupamentos, e as curvas são os α -cortes.

dequado para a extração das funções de pertinência. As projeções ortonormais seriam sobrepostas no eixo da variável Temperatura Média e dessa forma inadequadas para os objetivos do modelo no que se refere à interpretabilidade.

O Algoritmo de Agrupamento *c-means* também foi utilizado para determinar os possíveis agrupamentos para os dados e os resultados estão apresentados nas Figuras 5.17, 5.18, 5.19 e 5.20.

No caso de 2 agrupamentos determinados pelo Algoritmo *c-means*, apresentado na Figura 5.17, observa-se uma partição diagonal do espaço antecedente. As projeções ortonormais sobre o eixo da Temperatura Média indicam uma sobreposição para estes agrupamentos. A forma dos agrupamentos deste algoritmo é circular. Adotamos esta configuração de agrupamentos para as próximas etapas nas quais serão comparadas as diferenças entre as funções de pertinência obtidas pelos agrupamentos.

No caso de 3 agrupamentos determinados pelo Algoritmo *c-means*, apresentado Figura 5.18, observa-se uma partição do espaço em 3 seções diagonais. As projeções ortonormais dos agrupamentos podem gerar uma sobreposição no eixo da Temperatura Média, contudo adotamos estes para a extração das funções de pertinência.

No caso de 4 agrupamentos determinados pelo Algoritmo *c-means*, apresentado na Figura 5.19, observa-se uma setorização nos quatro cantos do espaço antecedente. A desvantagem desta partição do espaço está na dificuldade de interpretação, devido ao maior número de funções de pertinência e conseqüentemente de regras que serão geradas. As projeções ortonormais podem acabar gerando so-

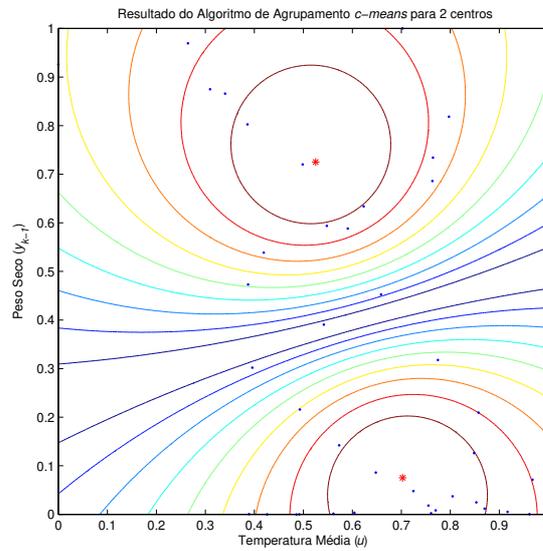


Fig. 5.17: Resultado do Algoritmo de Agrupamento *c-means* considerando 2 centros, os (●) em azul são os dados e os (*) são os centros dos agrupamentos, e as curvas são os α -cortes.

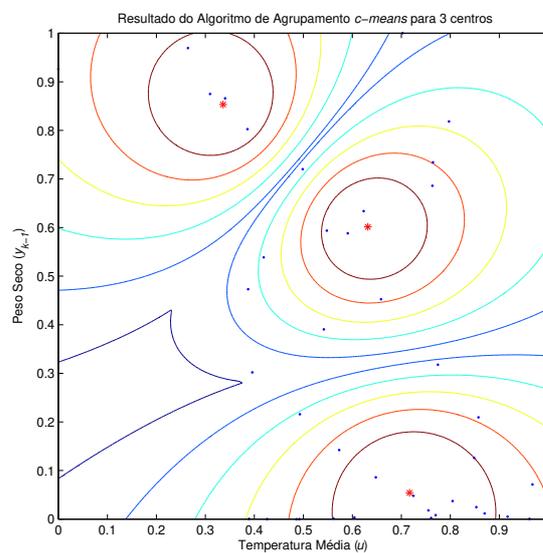


Fig. 5.18: Resultado do Algoritmo de Agrupamento *c-means* considerando 3 centros, os (●) em azul são os dados e os (*) são os centros dos agrupamentos, e as curvas são os α -cortes.

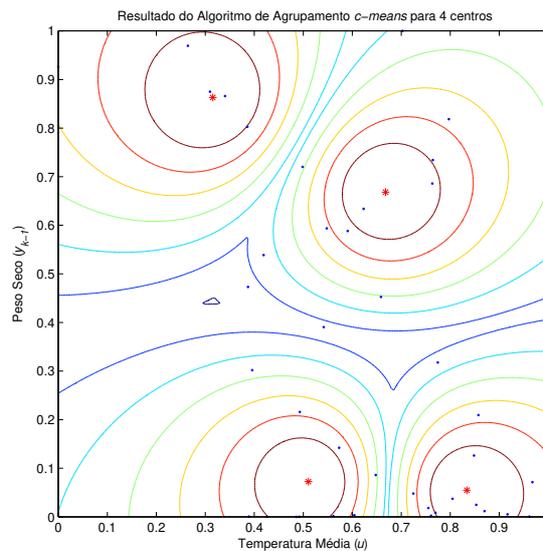


Fig. 5.19: Resultado do Algoritmo de Agrupamento *c-means* considerando 4 centros, os (●) em azul são os dados e os (*) são os centros dos agrupamentos, e as curvas são os α -cortes.

breposições sobre os eixos. Esta configuração dos centros será considerada para extração das funções de pertinência.

No caso de 5 agrupamentos determinados pelo Algoritmo *c-means*, apresentado na Figura 5.20, observa-se que o aumento do número de centros melhorou a simetria das partições do espaço antecedente. As projeções ortonormais neste caso vão acabar se sobrepondo em várias combinações para cada eixo e isto dificulta a interpretação do modelo. As funções de pertinência para este caso serão extraídas dos agrupamentos para verificar se ocorre a sobreposição.

Os Algoritmos *c-means* e GK foram simulados 40 vezes com o mesmo conjunto de dados e considerando um conjunto de 3 centros para os agrupamentos; em cada simulação foram utilizadas condições de inicialização diferentes. Os centros dos agrupamento de cada simulação foram armazenados. Cada centro possui um par de coordenadas para os eixos (y_{k-1}, u) . Quatro histogramas foram construídos considerando 7 faixas de frequência gerando as Figuras 5.21, 5.22, 5.23 e 5.24. Este histogramas indicam que os Algoritmos *c-means* e GK utilizados para determinar as partições do espaço antecedente não são sensíveis às condições de inicialização dos centros dos agrupamentos. Então, os agrupamentos utilizados são estatisticamente confiáveis.

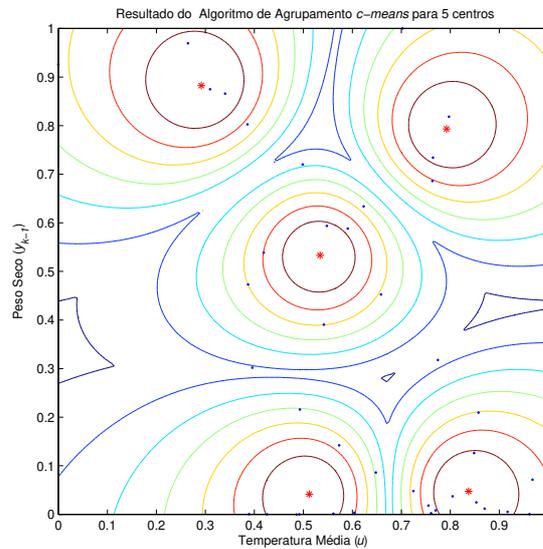


Fig. 5.20: Resultado do Algoritmo de Agrupamento *c-means* considerando 5 centros, os (●) em azul são os dados e os (*) são os centros dos agrupamentos, e as curvas são os α -cortes.

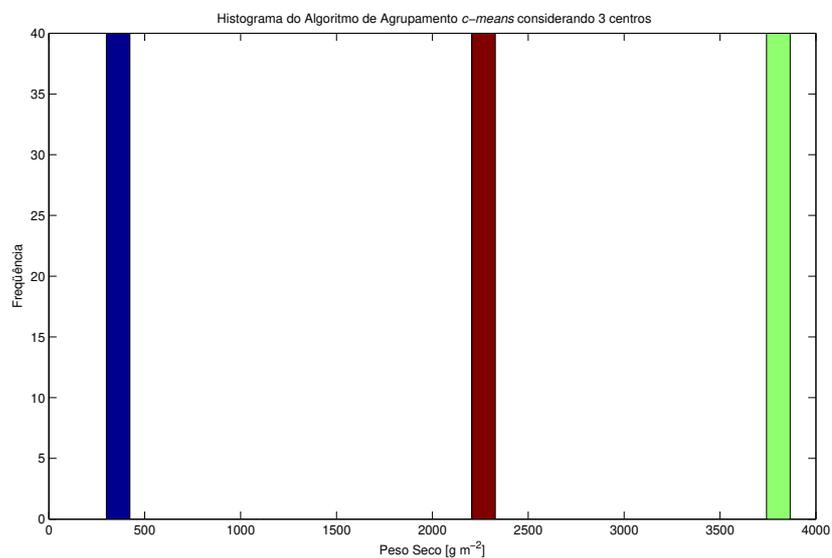


Fig. 5.21: Histograma das coordenadas dos centros obtidos pelo Algoritmo *c-means* sobre o eixo do PS para cada centro considerando 7 faixas de frequência.

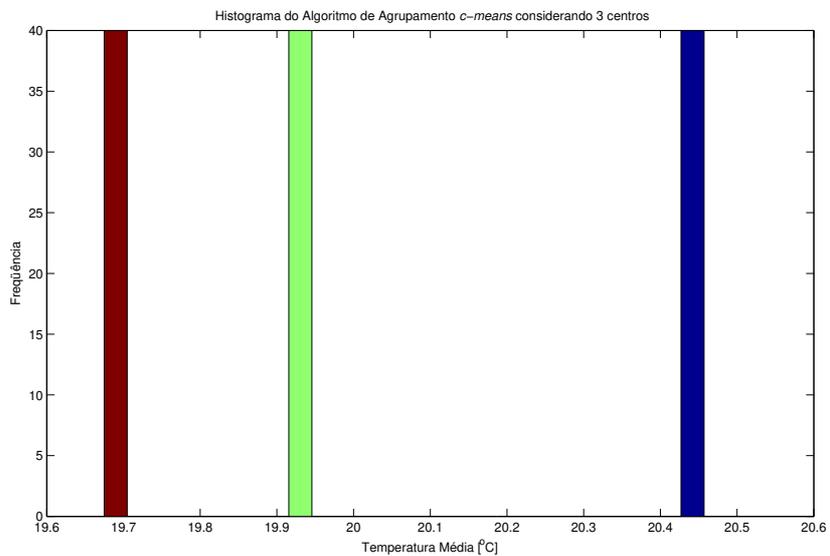


Fig. 5.22: Histograma das coordenadas dos centros obtidos pelo Algoritmo *c-means* sobre o eixo do PS para cada centro considerando 7 faixas de frequência.

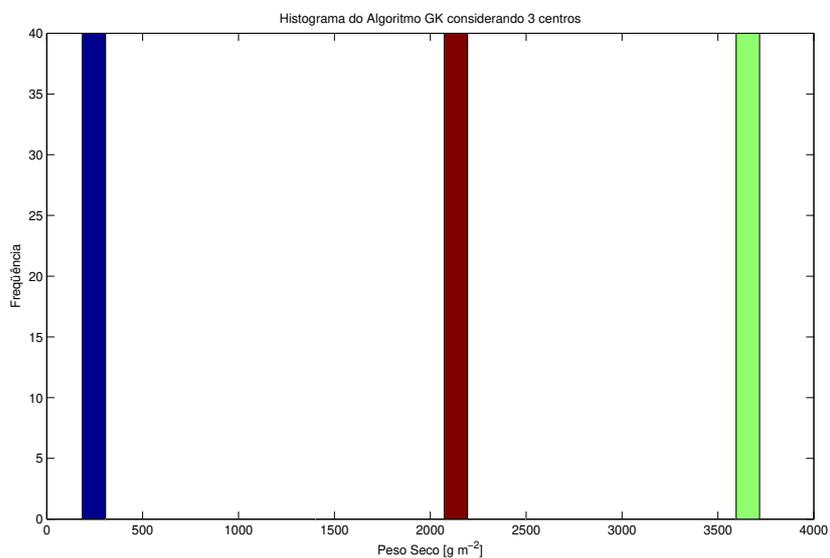


Fig. 5.23: Histograma das coordenadas dos centros obtidos pelo Algoritmo GK sobre o eixo do PS para cada centro considerando 7 faixas de frequência.

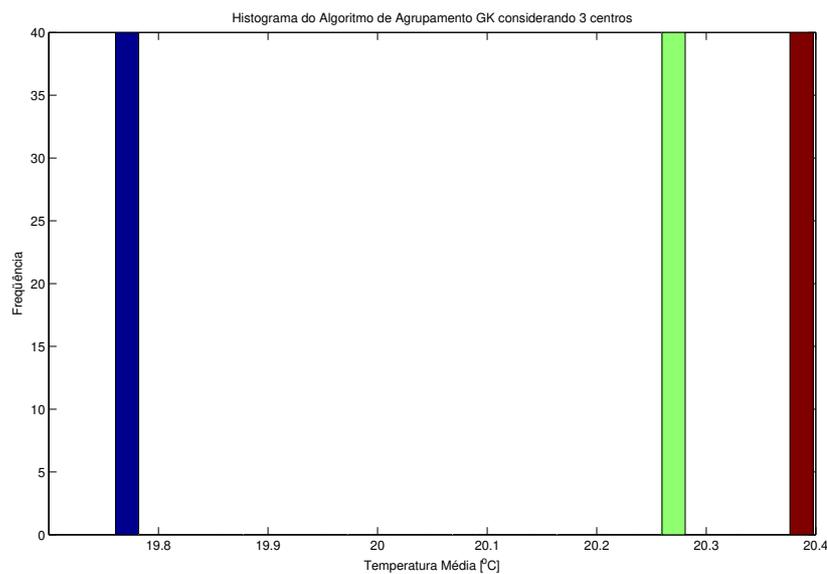


Fig. 5.24: Histograma das coordenadas dos centros obtidos pelo Algoritmo GK sobre o eixo da Temperatura Média para cada centro considerando 7 faixas de frequência.

5.5.2 Extração das funções de pertinência

A partir das projeções ortonormais dos dados em cada agrupamento nos eixos das variáveis do espaço antecedente, como descrito na Seção A.1.6 otem-se as funções de pertinência pelo ajuste de uma função paramétrica a estas projeções, como descrito na Seção 3.9.1. O ajuste dos parâmetros das funções paramétricas base é através de um algoritmo de otimização, seguindo um critério de ajuste. As funções base utilizadas são a trapezoidal e a exponencial por partes, apresentadas na Seção A.1.2.

A otimização dos parâmetros das funções base foi realizada para adequá-las às projeções dos agrupamentos da melhor forma possível. A função objetivo, ou de custo, mede a diferença da distância entre a curva projetada e a função base ajustada. Foram determinadas três formas para realizar esta comparação:

1. Ajuste em relação à base, ou seja à pertinência mínima. Esta opção visa fornecer o melhor ajuste da função base em relação aos limites mínimos de pertinência, ou seja aos menores α -cortes.
2. Ajuste em relação aos “ombros” da função base, ou seja do topo ao ponto no qual se inicia decaimento do grau de pertinência. Esta opção visa fornecer uma melhor ajuste para as pertinências máximas.

3. Ajuste do topo e “ombros” simultaneamente, ou seja busca o melhor ajuste para toda a curva. Esta opção leva em consideração os dois casos acima buscando otimizar todos os parâmetros da função base simultaneamente.

Neste trabalho será utilizada a terceira opção para o método de otimização que busca avaliar o ajuste de toda a função base em relação a projeção dos agrupamentos nebulosos. Esta opção terá que otimizar os quatro parâmetros referentes à função base utilizada. Uma desvantagem desse método está no fato de que os ajustes entre base e “ombros”, em certos casos são conflitantes e as funções base podem não aproximar adequadamente. A opção por uma das abordagens de otimização das funções se deve à quantidade explosiva de combinações geradas para serem analisadas, nesta etapa e nas posteriores, que iriam dificultar uma análise cuidadosa dos resultados.

A numeração das funções de pertinência obtidas se dará da esquerda para a direita do universo de discurso da variável. Assim, a função mais a esquerda terá o número 1 e a mais a direita o número máximo, que é igual ao número de agrupamentos.

O algoritmo de otimização utilizado para fazer o ajuste das funções base é o de busca direta do mínimo de funções multivariadas não restritas que não utiliza gradientes numéricos ou analíticos, que utiliza o método “*simplex*”, descrito por Lagarias em (LAGARIAS et al., 1998). O número máximo de execuções da função utilizado foi de 1000 e não foi especificada nenhuma tolerância.

Considerando inicialmente o caso de 2 e 3 agrupamentos para os algoritmos mencionados, apresentados nas Figuras 5.14, 5.15, 5.17 e 5.18, foram determinadas as funções de pertinência trapezoidais e exponenciais, respectivamente. As Figuras 5.25 e 5.26 apresentam as funções de pertinência extraídas dos agrupamentos determinados pelo Algoritmo GK e as Figuras 5.27 e 5.28 as funções de pertinência referentes ao Algoritmo *c-means*.

A partir das funções de pertinência extraídas do caso de 2 agrupamentos determinados pelo Algoritmo GK observou-se que foi confirmada a sobreposição das funções na variável de retro-alimentação (y_{k-1}) PS, tanto para a função base trapezoidal quanto para a exponencial. No caso de 3 agrupamentos para o mesmo algoritmo, nota-se que houve uma melhor disposição das funções de pertinência, em especial no caso exponencial, na Figura 5.26, devido a menor sobreposição das funções de pertinência. Frente a estes resultados optou-se por excluir a situação de 2 centros deste algoritmo nas análises subseqüentes.

As funções extraídas de 2 agrupamentos obtidos pelo Algoritmo *c-means* obtiveram a melhor distribuição no universo de discurso para as duas variáveis (universo de discurso para a Temperatura Média U , universo de discurso para o Peso Seco Y_{k-1}). No caso de 3 agrupamentos para o mesmo algoritmo, as funções extraídas foram similares as obtidas pelo Algoritmo GK na mesma condição.

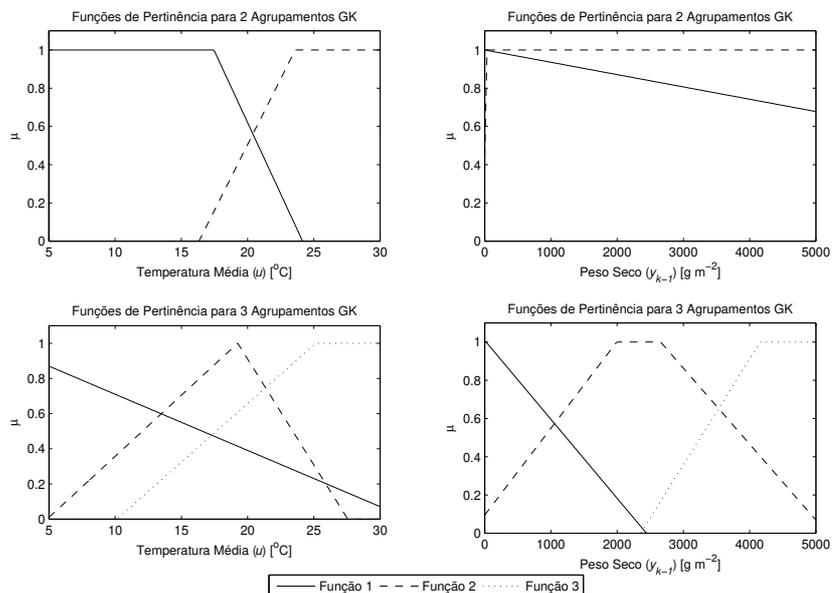


Fig. 5.25: Funções de pertinência trapezoidais extraídas a partir dos Agrupamentos determinados pelo Algoritmo GK

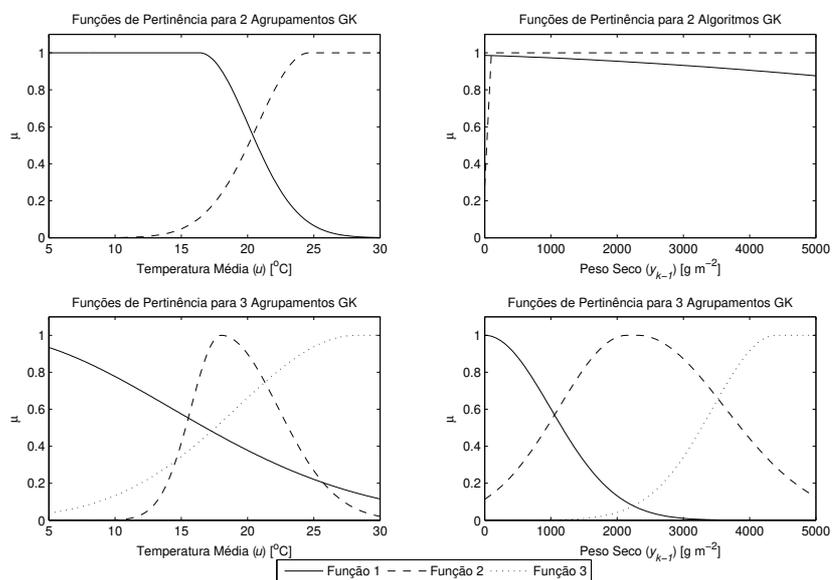


Fig. 5.26: Funções de pertinência exponenciais extraídas a partir dos Agrupamentos determinados pelo Algoritmo GK

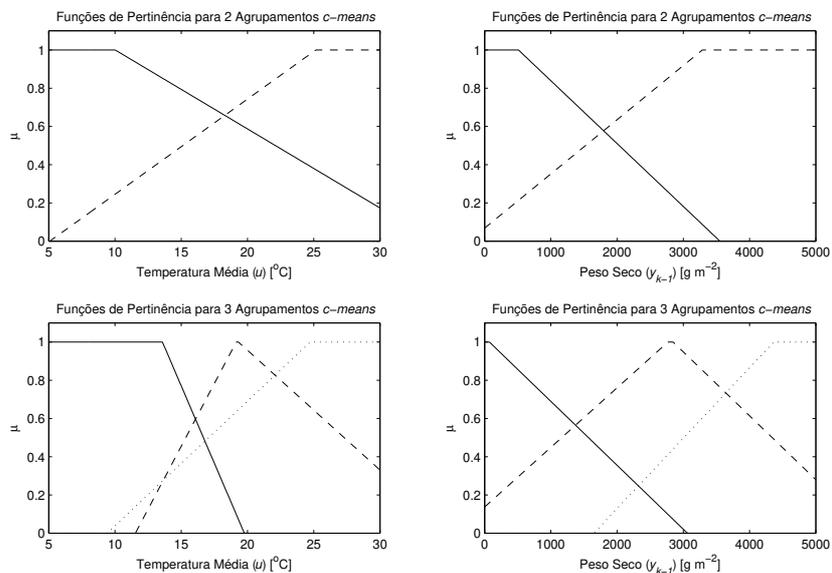


Fig. 5.27: Funções de pertinência trapezoidais extraídas a partir dos Agrupamentos determinados pelo Algoritmo *c-means*.

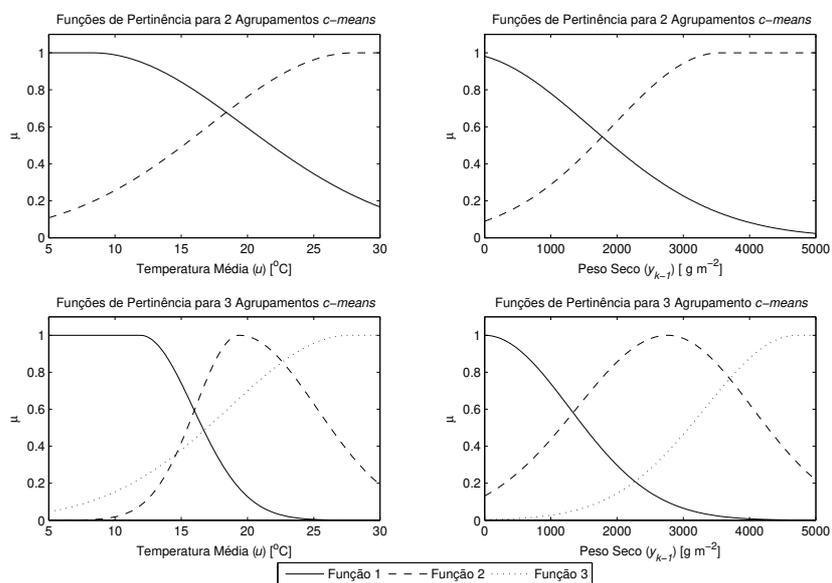


Fig. 5.28: Funções de pertinência exponenciais extraídas a partir dos Agrupamentos determinados pelo Algoritmo *c-means*.

Dessa forma os dois casos serão considerados nas etapas subseqüentes.

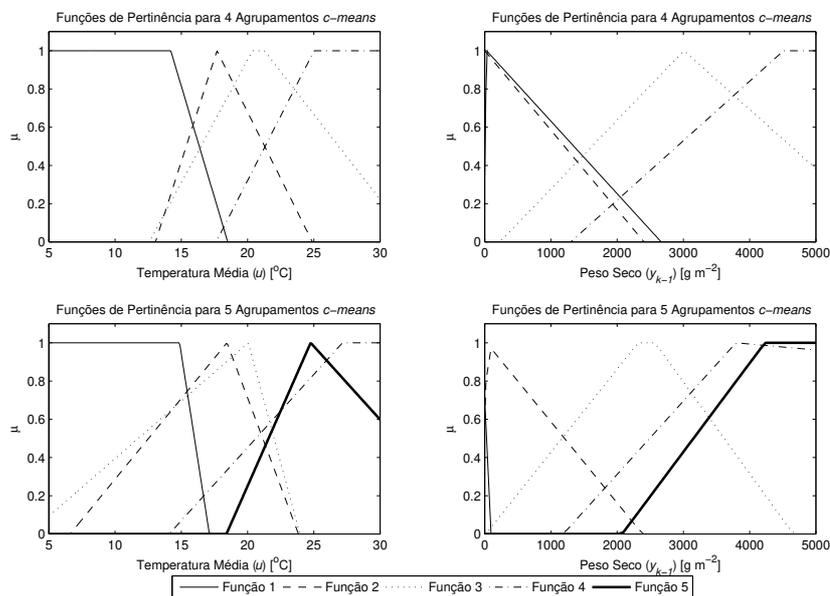


Fig. 5.29: Funções de pertinência trapezoidais extraídas a partir dos Agrupamentos determinados pelo Algoritmo *c-means*.

As extrações das funções de pertinência para o caso de 4 e 5 agrupamentos determinados pelo Algoritmo *c-means* são apresentadas nas Figuras 5.29 e 5.30. Nota-se que ocorreram várias sobreposições entre várias funções de pertinência como previsto anteriormente. No caso de 5 centros também ocorreu a determinação de funções de pertinência subnormais, ou seja com pertinência máxima menor que 1 (Definição 8, apresentada na Seção A.1.3). Considerando o número elevado de regras que seriam originadas da combinação destas funções e a sobreposição das mesmas, que contribuem para dificultar a interpretação do modelo, optou-se por descartar estas funções de pertinência nas análises subseqüentes.

Uma avaliação da variabilidade na determinação dos parâmetros das funções de pertinência a partir dos agrupamentos obtidos na Seção 5.5.1 foi realizada, utilizando o mesmo procedimento anterior. O histograma neste caso foi realizado considerando os quatro parâmetros da função trapezoidal 1 extraída das partições apresentadas na Figura 5.18. O resultado das extrações dos parâmetros é apresentado na Figura 5.31. Observa-se que as variações na determinação dos parâmetros foi mínima e pode-se considerar estes valores como os verdadeiros para o dado conjunto de dados.

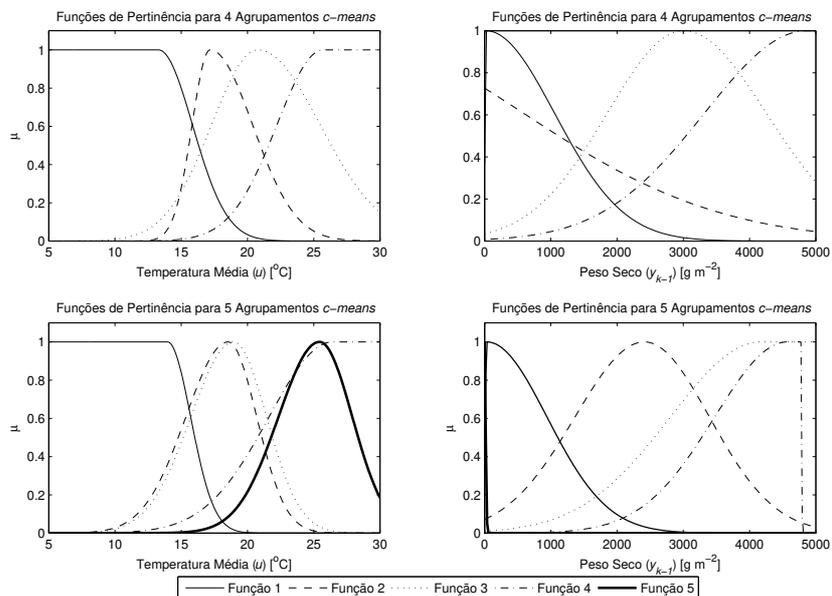


Fig. 5.30: Funções de pertinência exponenciais extraídas a partir dos Agrupamentos determinados pelo Algoritmo *c-means*.

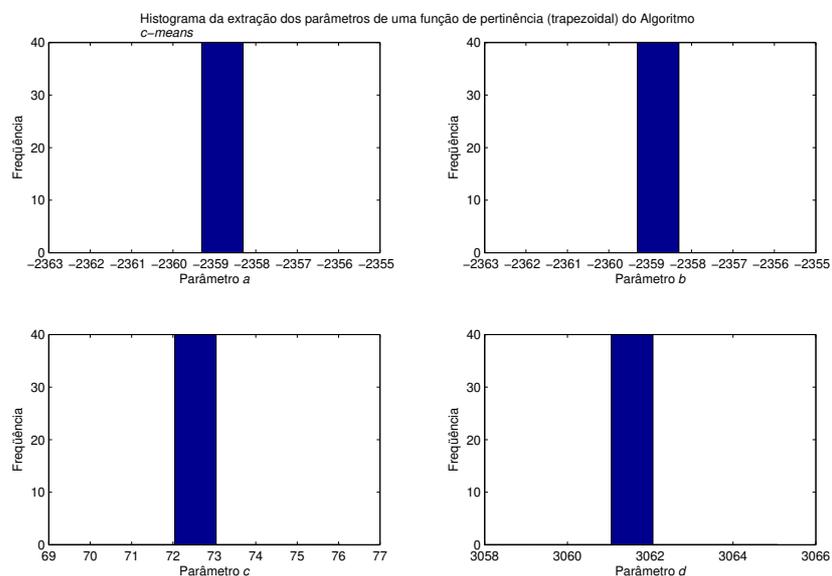


Fig. 5.31: Histograma dos parâmetros da função de pertinência extraída a partir do agrupamento de 3 centros obtidos pelo Algoritmo *c-means* considerando 7 faixas de frequência.

5.5.3 Avaliação dos conseqüentes e do modelo completo

Nesta etapa estabelecemos a base de regras do modelo considerando a combinação das funções de pertinência a partir das projeções dos agrupamentos. Os agrupamentos originalmente obtidos determinam as relações entre as funções de pertinência obtidas respeitando-se, assim, os agrupamentos iniciais. Posteriormente, são avaliadas outras possíveis combinações das funções de pertinência. As funções de pertinência obtidas e selecionadas, na Seção 5.5.2, juntamente com a base de regras são aqui utilizadas para determinar as funções lineares do conseqüente do modelo Takagi-Sugeno desejado.

A base de regras determina a relação entre as entradas e saídas do modelo, conseqüentemente o comportamento do sistema. Quando as funções de pertinência estão associadas com termos lingüísticos, a base de regras tem uma interpretação semântica associada a cada regra, ou seja, ao conhecimento do comportamento das variáveis em linguagem natural. Os termos lingüísticos são associados às funções de pertinência do modelo $\mathcal{M}(\theta)$, selecionado para representar o sistema considerando as características requeridas apresentadas na Seção 1.4.

A notação encontrada em grande parte da literatura de modelos nebulosos para a base de regras é dada na forma matricial, como apresentado na Tabela 5.8. Cada regra pode ser escrita por coordenadas, por exemplo, a Regra 3, da Tabela 5.8 pode ser dada por (3;1), ou seja:

$$R_3 : \text{Se } x_1 \text{ é } A_3 \text{ e } x_2 \text{ é } A_1 \text{ então } y_3 = f_3(x).$$

O par coordenado se refere as funções de pertinência que compõem a regra. Neste exemplo, pelas funções de pertinência 3 da variável X_1 e 1 da variável X_2 . Entretanto, o conjunto de regras nem sempre apresenta-se completo, ou seja composto por todas as combinações das funções de pertinência, como ocorre neste trabalho. Assim nestes caso a base de regras fica como apresentado na Tabela 5.9.

Neste estudo, para simplificar a apresentação das regras obtidas para os modelos nebulosos, serão apresentando os pares de coordenadas das combinações das funções de pertinência. Por exemplo, as regras para as funções de pertinência obtidas a partir de 2 agrupamentos determinados pelo Algoritmo *c-means*, Figura 5.27, são dadas por $\{[1;2],[2;1]\}$, onde a primeira coordenada é referente a variável de retro alimentação do Peso Seco (y_{k-1}) e a segunda à Temperatura Média (u).

As regras do modelo TS desejado são similares a regra expressa pela Equação 3.26, agora considerando como entrada a Temperatura Média (u) e o Peso Seco retro-alimentado (y_{k-1}). Assim, as regras do nosso modelo TS de trabalho são expressas como a seguir:

		Variável X_1		
		Função 1	Função 2	Função 3
Variável X_2	Função 1	Regra 1	Regra 2	Regra 3
	Função 2	Regra 4	Regra 5	Regra 6
	Função 3	Regra 7	Regra 8	Regra 9

Tab. 5.8: Exemplo de uma base de regras considerando 3 funções de pertinência para cada uma das duas variáveis de entrada

		Variável X_1		
		Função 1	Função 2	Função 3
Variável X_2	Função 1	Regra 1	-	-
	Função 2	-	Regra 2	-
	Função 3	-	Regra 3	Regra 4

Tab. 5.9: Exemplo de uma base de regras incompleta considerando 3 funções de pertinência para cada uma das duas variáveis de entrada

$$R_i : \text{Se } y_{k-1} \text{ é } A_i \text{ e } u \text{ é } B_i \text{ então } \hat{y}_i = \hat{a}_{i1} y_{k-1} + \hat{a}_{i2} u + \hat{b}_i \quad i = 1, 2, \dots, K, \quad (5.3)$$

o valor de K irá variar de acordo com a quantidade de funções de pertinência para as variáveis de entrada e as combinações entre estas. Os termos \hat{y} , \hat{a}_{i1} , \hat{a}_{i2} e \hat{b}_i se referem a Equação 4.32 que definiu a estrutura matemática do modelo de predição nebuloso.

A determinação dos parâmetros é realizada considerando as duas abordagens apresentadas na Seção 3.9.2: os métodos de Mínimos Quadrados Ponderado (MQP) e de Mínimos Quadrados Global (MQG). Lembrando que os Ensaios 2 e 4 são utilizados para o ajuste do modelo e os ensaios 1 e 3 para a validação. Partindo dos resultados obtidos na Seção 5.5.2 são avaliados os casos reunidos na Tabela 5.10.

Centros	Algoritmo	Função Base
2	<i>c-means</i>	Exponencial
		Trapezoidal
3	GK	Exponencial
		Trapezoidal
	<i>c-means</i>	Exponencial
		Trapezoidal

Tab. 5.10: Estruturas nebulosas a serem avaliadas na estimação por métodos de mínimos quadrados.

Os modelos nebulosos, nesta etapa, receberam denominações constituídas por codificações para facilitar a referência a estes durante a realização de comentários sobre os resultados. A codificação visa descrever, de forma sintética, as características da composição do modelo nebuloso. A Tabela 5.11 apresenta os códigos e seus significados para se interpretar as denominações atribuídas aos modelos. Por exemplo, pelos códigos da Tabela 5.11, o modelo gerado a partir das funções de pertinência trapezoidais extraídas de 3 agrupamentos nebulosos obtidos pelo Algoritmo GK e com conseqüentes determinados pelo método MQP é descrito pela seqüência de códigos : AG3gk-FPtp-MCml. Observe que a notação sintetiza e agiliza a descrição dos modelos.

Inicialmente avaliaram-se os modelos AG2cm-FPtp-MCmg e AG2cm-FPexp-MCmg, cujas funções de pertinência são apresentadas nas Figuras 5.27 e 5.28, respectivamente. Uma simulação com estes modelos foi realizada considerando o Ensaio 1 utilizado para a validação e o resultado é apresentado na Figura 5.32. Observa-se nesta figura que o modelo composto pelas funções de pertinência exponenciais apresentou predições mais próximas da curva ajustada do que o modelo com funções trapezoidais. Utilizando os critérios de validação estabelecidos na Seção 4.5.4 foi gerada a Tabela

Agrupamentos	
Código	Interpretação
AG2cm	2 agrupamentos obtidos pelo Algoritmo <i>c-means</i>
AG3gk	3 agrupamento obtidos pelo Algoritmo GK
AG3cm	3 agrupamentos obtidos pelo Algoritmo <i>c-means</i>

Funções de Pertinência	
Código	Interpretação
FPtp	Funções de pertinência trapezoidais
FPexp	Funções de pertinência exponenciais

Método de Estimação dos Conseqüentes	
Código	Interpretação
MCmg	Método MQG
MCml	Método MQP

Tab. 5.11: Sistema de codificação das características dos modelos nebulosos

5.12 na qual podemos notar que houve um melhor desempenho geral do modelo (AG2cm-FPexp-MCmg) que utiliza as funções de pertinência exponenciais com exceção para o Ensaio 4 para o qual houve uma piora pouco significativa nos resultado (da ordem 0,3% em relação ao modelo AG2cm-FPtp-MCmg). A base de regras em todas as simulações e de ambos os modelos foi {[1;2],[2;1]}, conforme estabelecido anteriormente.

A participação das regras na resposta do modelo está caracterizada na Figura 5.32, na qual podemos observar o grau de ativação de cada regra nos gráficos inferiores da figura e na parte superior os valores de cada regra (quando o grau de ativação, ou preenchimento, é superior a 0,5). A maior participação individual da regra na resposta indica que esta regra é muito significativa para a predição do modelo e no comportamento do mesmo.

As funções de pertinência trapezoidais apresentaram resultados inferiores as funções exponenciais mesmo quando o método de ajuste dos conseqüentes é o MQP, conforme simulações. Os resultados de avaliação dos erros das simulações dos modelos AG2cm-FPtp-MCml e AG2cm-FPexp-MCml são apresentados na Tabela 5.13.

Simulações comparativas dos modelos AG2cm-FPexp-MCmg e AG2cm-FPexp-MCml foram realizadas, visando comparar as capacidades de aproximação dos métodos MQG e MQP, respectiva-

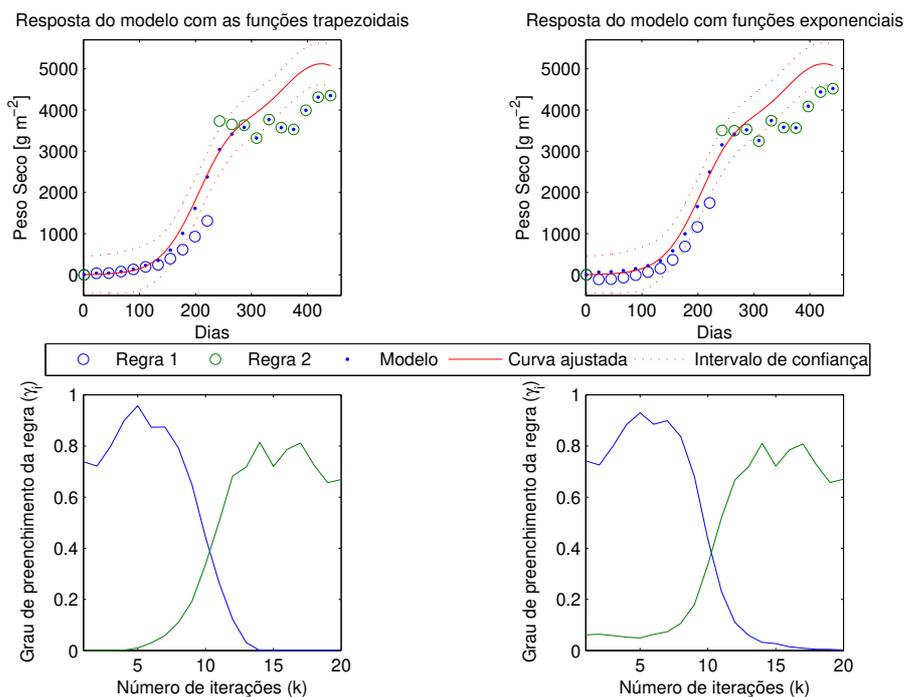


Fig. 5.32: Os resultados de simulação dos modelos nebulosos da acumulação de Peso Seco (AG2cm-FPtp-MCmg e AG2cm-FPexp-MCmg) ajustados pelo método MQG: na figura superior a direita as função de pertinência são trapezoidais e na figura superior a esquerda são exponenciais.

		Método MQG					
		Funções Trapezoidais			Funções Exponenciais		
	Ensaio	rRMSE	VAF	Corr	rRMSE	VAF	Corr
Validação	1	0,2530	95,9	4	0,2388	96,2	4
	3	0,2170	95,7	1	0,2072	95,9	0
Construção	2	0,1389	98,4	1	0,1326	98,5	2
	4	0,2849	93,9	5	0,2857	93,6	5

Tab. 5.12: Avaliação dos erros para os modelos nebulosos da acumulação de Peso Seco AG2cm-FPtp-MCmg e AG2cm-FPexp-MCmg.

		Método MQP					
		Funções Trapezoidais			Funções Exponenciais		
	Ensaio	rRMSE	VAF	Corr	rRMSE	VAF	Corr
Validação	1	0,1891	97,3	4	0,1699	97,9	3
	3	0,1520	97,7	2	0,1264	98,4	0
Construção	2	0,1634	97,5	5	0,1784	96,9	7
	4	0,2718	94,2	7	0,2525	95,0	7

Tab. 5.13: Avaliação dos erros para o modelo nebuloso da acumulação de Peso Seco AG2cm-FPtp-MCml e AG2cm-FPexp-MCml.

mente, para as funções de pertinência exponenciais. A avaliação dos erros foi realizada como anteriormente e os resultados estão apresentados na Tabela 5.14. O critério de erro AutoCorr foi descartado pois em todos os resultados o índice foi zero, sendo assim, este critério não é útil para distinguir os modelos quanto a sua qualidade. Os resultados da modelagem com os consequentes ajustados pelo método MQP tiveram maiores erros na etapa de construção do modelo, porém apresentaram as melhores resultados na etapa de validação. Este fato é também válido para as funções de pertinência trapezoidais como pode ser observado comparando-se as Tabelas 5.12 e 5.13.

Os resultados da simulação dos modelos (AG2cm-FPexp-MCmg e AG2cm-FPexp-MCml) são apresentados na Figura 5.33. Observa-se que os modelos locais, ou as regras, do modelo com os parâmetros do consequente determinados pelo método MQP se ajustam melhor a resposta do sistema do que o modelo com os consequentes determinados pelo método MQG.

Os resultados das Tabelas 5.12 e 5.13 indicam que para este sistema as formas das funções de pertinência mais apropriadas são as exponenciais, como pode ser confirmado pelas Tabelas 5.14 e 5.15. Apesar do critério Corr apresentar um aumento para a etapa de construção do modelo, houve uma redução deste critério na etapa de validação o que significa uma melhor performance na extração com a utilização destas funções. Pelos resultados obtidos, o método mais adequado para a determinar os parâmetros do consequente é o MQP. Este resultado será confirmado para os modelos construídos a partir de 3 agrupamentos.

Simulações realizadas utilizando os dados do Ensaio 1 e considerando os modelos nebulosos

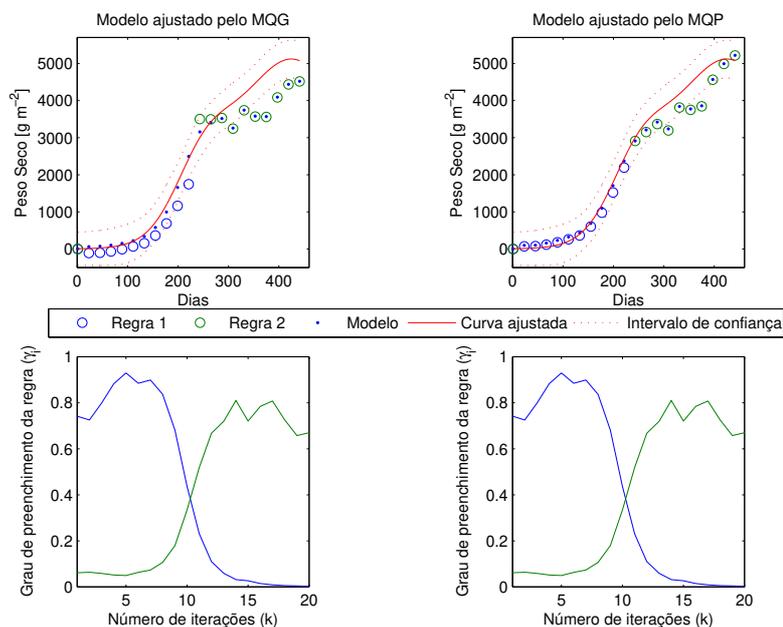


Fig. 5.33: Simulações dos modelos nebulosos da acumulação de Peso Seco com funções de pertinência exponenciais: na figura superior a direita os parâmetros do consequente foram ajustados pelo MQG e na superior a esquerda pelo MQP.

		Método MQG			Método MQP		
		Ensaios	rRMSE	VAF	Corr	rRMSE	VAF
Validação	1	0,2388	96,2	4	0,1699	97,9	3
	3	0,2072	95,9	0	0,1264	98,4	0
Construção	2	0,1326	98,5	2	0,1784	96,9	7
	4	0,2857	93,6	5	0,2525	95,0	7

Tab. 5.14: Avaliação dos erros para os modelos nebulosos de acumulação de Peso Seco, AG2cm-FPexp-MCmg e AG2cm-FPexp-MCml.

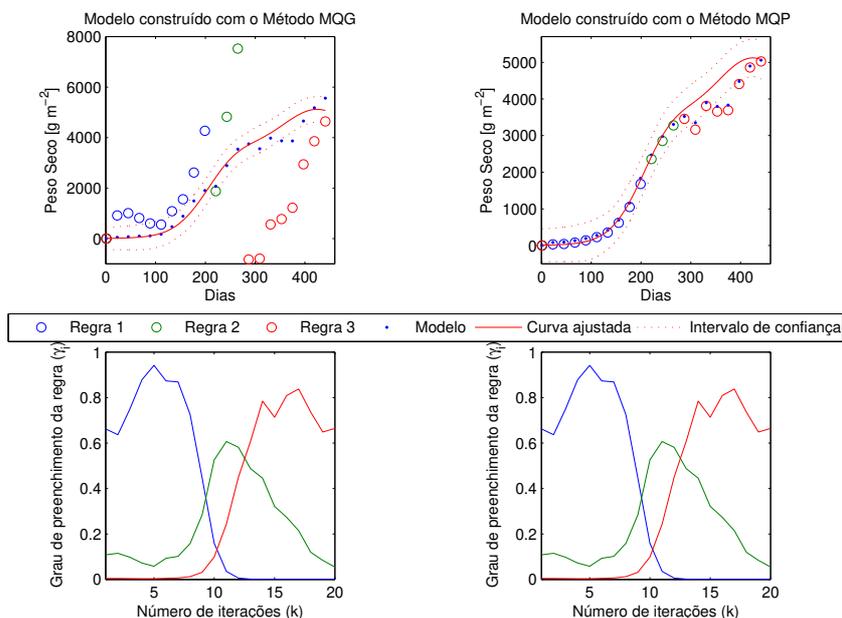


Fig. 5.34: Nestas simulações as funções de pertinência (3) são exponenciais, na figura superior a direita está a resposta do modelo com os parâmetros do consequente determinados por MQG e à esquerda, por MQP.

		Método MQP					
		Funções Trapezoidais			Funções Exponenciais		
	Ensaio	rRMSE	VAF	Corr	rRMSE	VAF	Corr
Validação	1	0,1824	97,5	5	0,1626	97,9	4
	3	0,1825	96,7	1	0,1519	97,7	2
Construção	2	0,1657	97,5	4	0,1732	97,3	5
	4	0,2543	94,7	6	0,2426	95,2	7

Tab. 5.15: Avaliação dos erros para os modelos nebulosos de acumulação de Peso Seco AG3cm-FPtp-MCml e AG3cm-FPexp-MCml)

para a acumulação de Peso Seco AG3cm-FPexp-MCmg e AG3cm-FPexp-MCml, com a base de regras {[1;3], [2;2], [3;1]}, são apresentadas na Figura 5.34, e confirmam o método MQP como o mais adequado para determinar os conseqüentes para um modelo mais complexo, por obter modelos locais mais representativos da resposta do sistema. Contudo, as avaliações de erro para os 4 ensaios, apresentadas na Tabela 5.16, indicam que o método MQP aplicado à um número maior de regras apresenta uma variação nos resultados que não permite estabelecer se houve ou não uma melhora. O aumento da Corr para o método MQP, apresentado na Tabela 5.16, indica um aumento da correlação do erro com as entradas indicando que o modelo não incorporou completamente a dinâmica do sistema (LJUNG, 1999).

		Método MQG			Método MQP		
		Ensaio	rRMSE	VAF	Corr	rRMSE	VAF
Validação	1	0,1568	97,7	1	0,1626	97,9	4
	3	0,1548	97,8	5	0,1519	97,7	2
Construção	2	0,1432	98,0	0	0,1732	97,3	5
	4	0,2542	94,4	5	0,2426	95,2	7

Tab. 5.16: Avaliação dos erros para os modelos nebulosos de acumulação de Peso Seco AG3cm-FPexp-MCmg e AG3cm-FPexp-MCml.

Utilizando as funções de pertinência, apresentadas na Figura 5.26, extraídas a partir de 3 agrupamentos GK, foram gerados dois modelos nebulosos (AG3gk-FPexp-MCmg e AG3gk-FPexp-MCml). No primeiro foi considerado o Método MQG para a determinação dos conseqüentes e no segundo o Método MQP. A diferença entre os modelos AG3gk-FPexp-MCmg e AG3gk-FPexp-MCml foi menor do que as obtidas pelos AG3cm-FPexp-MCmg e AG3cm-FPexp-MCml, como pode ser observado na comparação entre as Tabelas 5.16 e 5.17.

Os erros obtidos para os modelos AG3gk-FPexp-MCmg e AG3gk-FPexp-MCml, foram comparados com os obtidos pelos modelos AG3cm-FPexp-MCmg e AG3cm-FPexp-MCml, respectivamente. A avaliação dos erros entre os dois modelos, após a simulação com os conjuntos de dados, foi apresentada na Tabela 5.17. Os erros do modelo nebuloso que considera funções exponenciais extraídas de 3 agrupamentos determinado pelo algoritmo GK, independentemente do método para determi-

nar os parâmetros do conseqüente, foram menores (rRMSE e VAF), porém em relação ao critério de erro Corr houve um aumento. Isto ocorre devido ao problema de reconstrução, para este tipo de agrupamento, abordado na Seção 3.9.1.

		Método MQG			Método MQP			
		Ensaios	rRMSE	VAF	Corr	rRMSE	VAF	Corr
Validação	1		0,0989	99,1	1	0,1075	99,0	8
	3		0,1333	98,2	0	0,1295	98,3	0
Construção	2		0,0702	99,5	2	0,0514	99,7	4
	4		0,0916	99,2	0	0,1011	99,1	1

Tab. 5.17: Avaliação dos erros para os modelo nebulosos de acumulação de Peso Seco AG3gk-FPexp-MCmg e AG3gk-FPexp-MCml.

A partir deste ponto iremos considerar somente o modelo nebuloso cujas funções de pertinência exponenciais foram obtidas de 3 agrupamentos nebulosos determinados pelo Algoritmo GK e com os parâmetros do conseqüente determinados pelo método MQP, designado pelo código AG3gk-FPexp-MCml, pois este obteve os menores índices de erro nas avaliações anteriores. O método para determinar os parâmetros do conseqüente deste modelo permite que se tenham regras mais significativas, ou seja, regras que tenham suas participações bem definidas na resposta deste modelo. Assim, este modelo permite uma interpretação mais clara de suas respostas.

A base de regras dos modelos até o momento apenas considerou as projeções dos agrupamentos, a partir das quais foram construídas as funções de pertinência. Buscando melhorar o desempenho do modelo AG3gk-FPexp-MCml procurou-se determinar uma base de regras que melhorasse o desempenho do modelo e se possível reduzisse o número de regras. A redução da base de regras pode levar ao descarte de algumas das funções de pertinência.

Inicialmente, completamos a base de regras com todas as combinações possíveis, como na Tabela 5.8 e avaliamos o desempenho do modelo para esta base gerando os gráficos de ativação de cada regra e os índices de erro, registrando os resultados. No próximo passo, a regra com o menor grau de ativação das simulações é removida e re-avalia-se o desempenho do modelo que, se for superior é mantido para um próximo passo, senão o sistema original é restaurado e a segunda regra menos ativa

Ensaio	Método MQG		Método MQP	
	rRMSE (%)	VAF (%)	rRMSE (%)	VAF (%)
1	-36,9	1,4	-33,9	1,1
2	-13,9	0,4	-14,7	0,6
3	-42,1	1,5	-70,3	2,5
4	-64,2	5,1	-58,3	4,1
Média	-39,3	2,1	-28,5	2,1

Tab. 5.18: Comparação das diferenças dos valores dos erros dos modelos GK (AG3gk-FPexp-MCmg e AG3gk-FPexp-MCml) em relação aos modelos *c-means* (AG3cm-FPexp-MCmg e AG3cm-FPexp-MCml, respectivamente).

é removida e o sistema novamente avaliado. A remoção das regras ocorre até que não haja nenhuma melhora no desempenho do modelo com a redução das regras.

O resultado do procedimento de redução da base de regras descrito foi a seguinte base de regras: [1,2], [2,2]. Os resultados da avaliação dos erros estão apresentados na Tabela 5.19. Nota-se na tabela que houve uma redução do erro considerando os resultados de quando o modelo estava com base de regras baseada nos agrupamentos, da Tabela 5.17. Houve uma “distribuição” dos erros de Corr do modelo caracterizada na etapa de validação. O modelo AG3gk-FPexp-MCml considerando esta base de regras descarta a função de pertinência 3 do Peso Seco e as funções 1 e 3 para a variável Temperatura Média.

As simulações do Modelo AG3gk-FPexp-MCml com a base de dados modificada são apresentadas na Figura 5.35. Pode ser observado na figura que o modelo se ajustou bem ao comportamento do sistema. Todas as simulações até o momento utilizaram os dados de acumulação de massa referentes a variedade Q138. Dessa forma, os resultados são válidos apenas para esta variedade.

A estrutura do modelo nebuloso (AG3gk-FPexp-MCml) selecionada para a variedade Q138 foi utilizada para gerar um modelo para a variedade Q141, considerando a base de regras otimizada. O modelamento seguiu o mesmo procedimento utilizado para extrair as funções de pertinência e

		Modelo AG3gk-FPexp-MCml			
		Ensaios	rRMSE	VAF	Corr
Validação	1		0,0660	99,6	4
	3		0,0877	99,3	4
Construção	2		0,0517	99,7	5
	4		0,0678	99,6	10

Tab. 5.19: Avaliação do modelo AG3gk-FPexp-MCml com a base de regras otimizada.

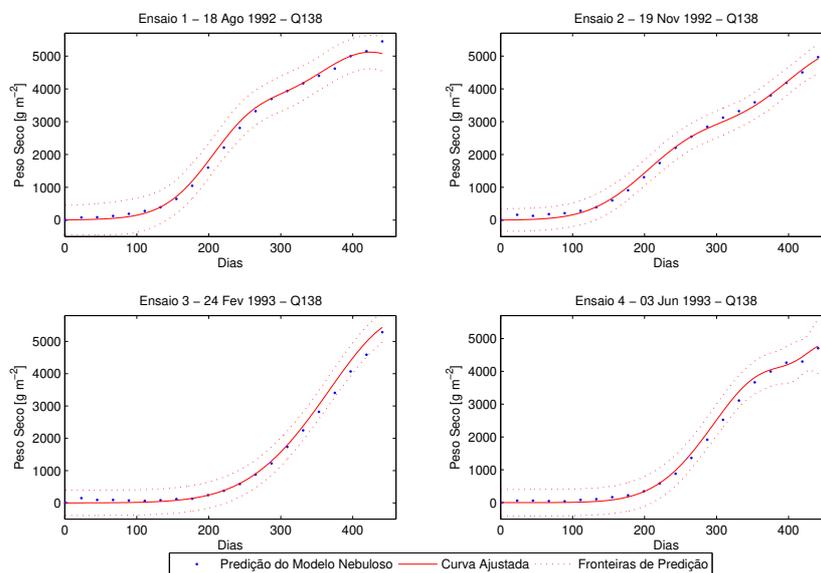


Fig. 5.35: Simulação do Modelo Nebuloso AG3gk-FPexp-MCml com a base de regras otimizada para os quatro ensaios com um passo de predição Q141.

determinar os parâmetros do conseqüente. Obtido o modelo, foram realizadas as simulações para cada ensaio gerando a Figura 5.36. O desempenho do modelo, pelo que pode ser observado nas figuras, pode ser considerado equivalente aos resultados apresentado na Figura 5.35. As predições de ambos os modelos se concentraram dentro do intervalo de confiança para a curva interpolada para cada ensaio.

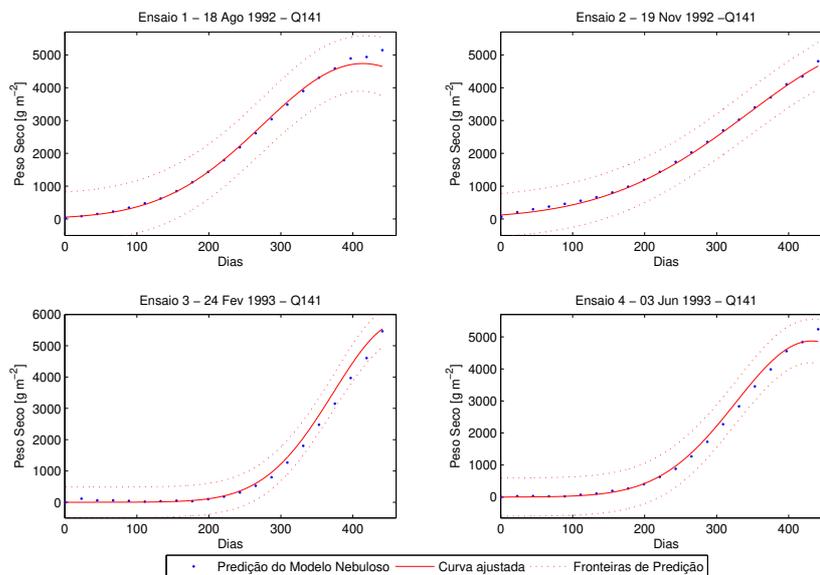


Fig. 5.36: Simulação do Modelo Nebuloso AG3gk-FPexp-MCml com a base de regras modificada para os quatro ensaios com um passo de predição aplicado a variedade Q141.

Os parâmetros referentes aos antecedentes determinados para cada variável e para cada variedade são apresentados nas Tabelas 5.20 e 5.21. A relação destes parâmetros com a função exponencial por partes, apresentada na Seção A.1.2, é expressa a seguir:

$$\begin{aligned}
 c_l &= b; & \omega_l &= b - a; \\
 c_r &= c; & \omega_r &= d - c.
 \end{aligned}
 \tag{5.4}$$

Note que a base de regras considera apenas as funções 1 e 2 referentes a variável Peso Seco (y_{k-1}) e a função 2 da Temperatura Média. Considerando as Equações 5.4 e os parâmetros apresentados nas Tabelas 5.21 e 5.20 pode se verificar que a maior diferença entre os modelos obtidos foi a função de pertinência 2 da Temperatura Média entre as variedades. As funções de pertinência do Peso Seco apresentaram variações em relação a ω_l e ω_r entre os modelos das duas variedades. A Figura 5.37 mostra como o modelo nebuloso para o Peso Seco da variedade Q138 opera para determinar os

valores de saída.

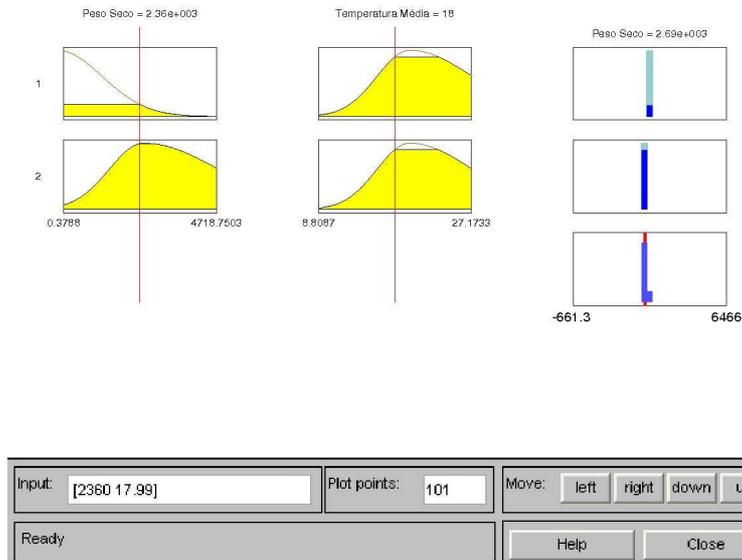


Fig. 5.37: Funcionamento do modelo nebuloso para o Peso Seco ajustado para a variedade Q138

Os parâmetros dos consequentes dos modelos para cada variedade são apresentados na Tabela 5.22. Observa-se que os valores dos parâmetros da Regra 1 são similares, mas para a Regra 2 os parâmetros são diferentes devido a \hat{a}_{22} e \hat{b}_2 . Isto se deve ao efeito diferenciado da variável Temperatura Média na acumulação de biomassa de cada variedade.

O procedimento para otimização da base de regras foi aplicado para o conjunto de dados da variedade Q141, considerando a estrutura AG3gk-FPexp-MCml. Foi constatado que a base de regras otimizada para a variedade Q138, $\{[1;2],[2;2]\}$, também é ótima para a variedade Q141. A avaliação dos erros do modelo AG3gk-FPexp-MCml aplicada ao conjunto de dados da variedade Q141 está apresentada na Tabela 5.23. Podemos observar que os erros do modelo ajustado com os conjuntos de dados desta variedade foram em média menores que os obtidos para o modelo da variedade Q138.

5.5.4 Extensão dos resultados

Na Seção 5.5.3, foi avaliada a capacidade da estrutura de modelo nebuloso AG3gk-FPexp-MCml de prever a acumulação de biomassa para a variedade Q138, e posteriormente avaliada a mesma capacidade para outra variedade, a Q141. O Professor Liu propõe em (LIU; KINGSTON, 1993) que os componentes principais do colmo, a fibra e o açúcar, são uma combinação linear do Peso Seco, como abordado na Seção 5.2. Se esta hipótese for válida, a estrutura do modelo AG3gk-FPexp-MCml pode ser utilizada para gerar um modelo para prever a acumulação de Fibra e de Açúcar pela

Peso Seco				
Modelo para a Q138				
Função	a	b	c	d
1	$-2,359 \cdot 10^3$	$-2,359 \cdot 10^3$	$-0,192 \cdot 10^3$	$4,975 \cdot 10^3$
2	$-1,490 \cdot 10^3$	$2,475 \cdot 10^3$	$2,475 \cdot 10^3$	$11,098 \cdot 10^3$
3	$0,214 \cdot 10^3$	$4,454 \cdot 10^3$	$7,078 \cdot 10^3$	$7,078 \cdot 10^3$

Modelo para a Q141				
1	$-2,482 \cdot 10^3$	$-2,482 \cdot 10^3$	$0,090 \cdot 10^3$	$5,739 \cdot 10^3$
2	$-0,883 \cdot 10^3$	$2,612 \cdot 10^3$	$2,612 \cdot 10^3$	$9,083 \cdot 10^3$
3	$0,585 \cdot 10^3$	$4,872 \cdot 10^3$	$7,451 \cdot 10^3$	$7,451 \cdot 10^3$

Tab. 5.20: Parâmetros das funções antecedentes do Peso Seco (y_{k-1}) dos modelos nebulosos para as variedades Q138 e Q141

Temperatura Média				
Modelo para a Q138				
Função	a	b	c	d
1	-0,4	-0,4	13,4	21,5
2	5,2	19,7	19,7	48,0
3	2,5	23,8	36,4	36,4

Modelo para a Q141				
1	-0,4	-0,4	14,1	19,7
2	6,5	21,9	36,4	36,4
3	11,1	17,8	17,8	78,0

Tab. 5.21: Parâmetros das funções antecedentes da Temperatura Média (u) dos modelos nebulosos para as variedades Q138 e Q141

Regra	Modelo para a Q138			Modelo para a Q141		
	\hat{a}_{i1}	\hat{a}_{i2}	\hat{b}_i	\hat{a}_{i1}	\hat{a}_{i2}	\hat{b}_i
1	1,21	11,55	-169,67	1,17	11,54	-183,97
2	0,95	15,51	126,00	0,97	1,67	406,85

Tab. 5.22: Parâmetros dos modelos nebulosos para as variedades Q138 e Q141

		Avaliação do modelo para a variedade Q141		
		Ensaio	rRMSE	VAF
Validação	1	0,0740	99,5	4
	3	0,1070	99,1	5
Construção	2	0,0382	99,9	0
	4	0,0764	99,5	4

Tab. 5.23: Avaliação do modelo AG3gk-FPexp-MCml com a base de regras otimizada para a variedade de cana-de-açúcar Q141.

cana-de-açúcar com a mesma margem de erro obtida para o Peso Seco.

Um modelo para a Fibra e o Açúcar de cada variedade foi gerado usando a base de dados otimizada e os dados dos Ensaio como especificado anteriormente (Ensaio 2 e 4 para construção e Ensaio 1 e 3 para validação). Uma avaliação dos erros foi realizada para os modelos de predição da acumulação de açúcar e fibra de cada variedade com o conjunto de dados e os resultados estão apresentados respectivamente nas Tabelas 5.24 e 5.25. O modelo para acumulação de açúcar para a variedade Q138 foi o que teve os maiores erros.

A acumulação de açúcar na cana-de-açúcar tende a ter um comportamento mais irregular, pois a quantidade de açúcar varia com condições ambientais. O açúcar armazenado na planta varia com o ritmo de crescimento da planta que depende principalmente da temperatura média. No entanto, pela pouca quantidade de dados disponíveis para esta componente não foi possível captar estas variações na quantidade de açúcar acumulada pela planta.

O modelo para a acumulação de fibra na cana-de-açúcar apresentou os menores índices de erro para ambas as variedades. Isto era esperado, uma vez que a fibra não apresenta variações negativas, pois a fibra é um material estrutural do colmo. A fibra constitui a estrutura do colmo e a sua acumulação determina a capacidade de armazenamento de açúcar do mesmo.

A hipótese considerada de que os erros dos modelos para a predição de acumulação de açúcar e fibra seriam próximos aos erros obtidos pelo modelo de predição da acumulação de Peso Seco da

		Modelo Q138 - Açúcar			
		Ensaio	rRMSE	VAF	Corr
Validação	1	0,0428	99,8	3	
	3	0,1112	99,1	4	
Construção	2	0,0497	99,8	0	
	4	0,0809	99,4	8	

		Modelo Q141 - Açúcar		
Validação	1	0,0635	99,6	5
	3	0,1142	99,0	4
Construção	2	0,0364	99,9	0
	4	0,0623	99,7	4

Tab. 5.24: Avaliação dos erros dos modelos nebulosos com a estrutura AG3gk-FPexp-MCml para predição da acumulação de Açúcar.

		Modelo Q138 - Fibra			
		Ensaio	rRMSE	VAF	Corr
Validação	1		0,0708	99,5	4
	3		0,0613	99,5	3
Construção	2		0,0690	99,7	3
	4		0,0650	99,6	4

		Modelo Q141 - Fibra			
Validação	1		0,0660	99,6	4
	3		0,0616	99,7	2
Construção	2		0,0348	99,9	0
	4		0,0415	99,9	0

Tab. 5.25: Avaliação dos erros dos modelos nebulosos com a estrutura AG3gk-FPexp-MCml para predição da acumulação de Açúcar.

cana-de-açúcar foi válida para ambas as variedades. Para a variedade Q141, em especial, os dados de PS puderam ser aproximados adequadamente pela combinação linear de F mais A durante o desenvolvimento da cultura. Isto se deve às melhores previsões realizadas pelo modelo de acumulação de açúcar. Apesar dos maiores erros do modelo para a previsão da acumulação de Açúcar para a variedade Q138, a combinação linear dos modelos de previsão da acumulação do Açúcar e da Fibra para determinar o Peso Seco acumulado também é válida para esta variedade.

Os resultados obtidos pelos modelos nebulosos, nas Tabelas 5.19, 5.23, 5.24 e 5.25 podem então ser comparados com o modelo QCANE (Seção B) uma vez que ambos compartilham da mesma base de dados. Na Tabela 5.26 apresentamos os erros obtidos pelos modelos nebulosos e pelo modelo QCANE, porém considerando como critério de erro a raiz quadrática do erro quadrático médio, que foi o mesmo critério utilizado por Liu, em (LIU; BULL, 2001).

Observamos que o modelo QCANE apresentou maiores variações dos erros entre as variedades que os modelos nebulosos. Numa comparação direta entre os modelos de cada componente e em cada variedade observou-se que:

- para a variedade Q141 a média do erro para o Peso Seco foi 53% menor para o modelo nebuloso em relação ao modelo QCANE. Os erros do Modelo QCANE em geral variaram mais para esta variedade. Provavelmente os parâmetros deste modelo para esta variedade não estão ajustados adequadamente;
- para a variedade Q141 a média do erro para o Açúcar foi 67% menor para o modelo nebuloso em relação ao modelo QCANE.
- para a variedade Q141 a média do erro para a Fibra foi 77% menor para o modelo nebuloso em relação ao modelo QCANE. Os resultados de simulação da acumulação de fibra e de açúcar são piores para esta variedade. A razão disto é que o balanço de carbono do modelo QCANE não está realizando a partição adequada do carbono assimilado;
- para a variedade Q138 a média do erro para o Peso Seco foi 35% menor para o modelo nebuloso em relação ao modelo QCANE. Este foi o resultado mais próximo entre os dois modelos o que indica um melhor ajuste para esta variedade, considerando a acumulação global de massa;
- para a variedade Q138 a média do erro para o Açúcar foi 73% menor para o modelo nebuloso em relação ao modelo QCANE. O modelo QCANE de uma forma geral não atingiu a exatidão do modelo nebuloso para a acumulação de açúcar, tido como seu ponto mais forte. Novamente, isto deve estar associado a problemas no balanço de carbono deste modelo;

- para a variedade Q138 a média do erro para a Fibra foi 51% menor para o modelo nebuloso em relação ao modelo QCANE. O modelo QCANE obteve respostas mais exatas para esta variedade sendo que esta variedade tende a acumular mais açúcar que a variedade Q141. Pode-se sustentar a hipótese de problemas nos coeficientes das equações de balanço de carbono deste modelo pelas variações entre as componentes da biomassa.

Deve-se destacar que os erros do modelo QCANE, assim como os deste trabalho foram computados em relação a uma curva que interpola os dados originais do sistema. Este trabalho optou por funções gaussianas para determinar a curva interpolada e em (LIU; BULL, 2001), o Professor Liu determinou sua curva interpolada por um método “*spline*”, não detalhado. Apesar destas diferenças para determinar os erros, as diferenças de desempenho dos modelos são tais que não podem ser justificadas apenas por diferenças na curva interpolada usada para determinar os erros. Assim pode-se estabelecer que os modelos nebulosos conseguiram representar adequadamente os processos de acumulação de biomassa e de açúcar da cana-de-açúcar, as as previsões destes modelos tem níveis baixos de erro.

5.5.5 Associação de valores lingüísticos e descrição da semântica do modelo nebuloso

A estrutura do modelo nebuloso obtido para representar os processos de acumulação de peso seco, de açúcar e de fibra da cana-de-açúcar, além da precisão numérica adequada devem incorporar os conhecimentos sobre estes processos. Isto deve ser feito para validar conceitualmente as respostas obtidas, além de demonstrar que os modelos nebulosos obtidos não são “caixas pretas”.

As funções de pertinência até o momento não continham nenhum termo lingüístico associado, como definido na Seção 3.2.1. A associação de termos lingüísticos as funções de pertinência permite uma leitura parcial das regras do modelo nebuloso TS. Esta interpretação parcial do modelo permite estabelecer relações entre os conceitos fisiológicos da cana-de-açúcar e dessa forma, avaliar se o modelo nebuloso está representando características conhecidas do comportamento da cana-de-açúcar.

Inicialmente, deve-se considerar a base de regras {[1;2], [2;2]} a qual nos restringe às funções de pertinência 1 e 2 do Peso Seco (y_{k-1}) e à função 2 da Temperatura Média (u), cujos os parâmetros estão apresentados nas Tabelas 5.20 e 5.21. Além disso a base de regras é composta por duas regras, cujos coeficientes estão apresentados na Tabela 5.22. Observando os coeficientes das regras nota-se que os parâmetros das variáveis dependentes são positivos, assim podemos entender as regras como funções lineares de crescimento, cada uma indicando um nível de crescimento associado à uma

Modelo Nebuloso			
Q138			
Ensaio	Peso Seco [g m ⁻²]	Açúcar [g m ⁻²]	Fibra [g m ⁻²]
1	130	46	53
2	85	41	49
3	157	113	49
4	120	88	46

Variedade Q141			
Ensaio	Peso Seco [g m ⁻²]	Açúcar [g m ⁻²]	Fibra [g m ⁻²]
1	130	70	37
2	57	32	19
3	193	118	37
4	139	71	24

Modelo QCANE			
Variedade Q138			
Ensaio	Peso Seco [g m ⁻²]	Açúcar [g m ⁻²]	Fibra [g m ⁻²]
1	191	158	135
2	192	197	83
3	208	404	78
4	165	291	132

Variedade Q141			
Ensaio	Peso Seco [g m ⁻²]	Açúcar [g m ⁻²]	Fibra [g m ⁻²]
1	241	120	220
2	180	92	124
3	416	545	147
4	252	426	72

Tab. 5.26: Comparação do erros entre os modelos nebulosos e o modelo QCANE considerando o critério RMSE

condição térmica.

Os estágios fenológicos da cana-de-açúcar, usualmente na literatura, estão associados a algum dos métodos de computação da acumulação térmica, como mostrado na Figura B.5 na Seção B.2.5. Isto se deve ao fato de poucos modelos trabalharem com retro-alimentação das estimativas de acumulação de massa e assim não terem estabelecido uma relação entre o peso em um instante de tempo anterior e o estágio fenológico da planta. No entanto, análises de correlações cruzadas entre um método de acumulação térmica presente em (BARBIERI, 1993) com o Peso Seco e o de Liu citado em (LIU; BULL, 2001) com o Peso Seco indicou uma forte relação linear entre estas pares. Assim, foi concluído que as funções obtidas para o Peso Seco representam dois estágios fenológicos para as variedades da cana-de-açúcar. Os estágios fenológicos determinados pelas funções de pertinência receberam aqui as denominações de Estágio Vegetativo e Formação de Produção para as funções 1 e 2, respectivamente.

A temperatura média conforme comentado na Seção 2.1.2 afeta a dinâmica dos processos físico-químicos da planta interferindo na dinâmica de crescimento, ou seja, acumulação de massa. A respiração de manutenção também é influenciada pela ação da temperatura, sendo que na medida que esta aumenta simultaneamente aumenta a taxa de respiração de manutenção o que acaba aumentando o consumo de fotossintetizados, reduzindo a quantidade que estará disponível para a planta armazenar ou utilizar na síntese de fibra. A respiração de manutenção é a parte da respiração da planta utilizada apenas para a manutenção das funções vitais (descrito em detalhes na Seção B.2.4). Assim podemos interpretar a função de pertinência para a temperatura média como a função que representa a melhor temperatura para o processo de acumulação modelado.

Baseado nas considerações sobre a representação de cada função de pertinência de dos consequentes, acima, as regras podem ser interpretadas da seguinte forma:

Regra 1 - Se a última predição do Peso Seco estava no Estágio Vegetativo e a Temperatura Média estava dentro da faixa que permite o crescimento, então a Função de Crescimento será $\hat{y}_k = \hat{a}_{11} \hat{y}_{k-1} + \hat{a}_{12}u + \hat{b}_1$

Regra 2 - Se a última predição do Peso Seco estava no Estágio de Formação da Produção e a Temperatura Média estava dentro da faixa que permite o crescimento, então a Função de Crescimento será $\hat{y}_k = \hat{a}_{21} \hat{y}_{k-1} + \hat{a}_{22}u + \hat{b}_2$

A semântica para a estrutura do modelo em questão estabelece que cada um dos estágios fenológicos possui um função linear de crescimento a qual é ativada pela temperatura média e a mudança

do estágio fenológico depende da massa acumulada. Assim, a temperatura atua como um regulador externo para o desempenho ótimo da função de crescimento da planta em cada estágio.

5.6 Conclusões

Neste capítulo aplicou-se a teoria de identificação de sistemas apresentada na Seção 4.5. Algumas estruturas de modelos lineares (Seção 4.5.2) foram inicialmente testadas para modelar o sistema, mas sem sucesso. Por fim, as estruturas de modelos nebulosos foram testadas, verificando-se mais apropriadas para o problema, como esperado (Seção 1.4). Além disso o modelo nebuloso apresentou resultados superiores ao modelo tradicional QCANE, comprovando a eficácia desta estrutura de modelo. Esta estrutura de modelo foi também adequada conceitualmente, refletindo fenômenos observados e comprovados. Então, os modelos determinados são considerados adequados quanto aos objetivos deste trabalho e deste capítulo.

Capítulo 6

Conclusões

O trabalho teve por objetivo propor identificar e ajustar um modelo nebuloso (*Fuzzy*) para a predição de um passo a frente dos processos de acumulação de biomassa e de açúcar da cana-de-açúcar com índices de erro inferiores aos obtidos pelo modelo QCANE.

A morfologia da planta foi estudada analisando os principais componentes e destacando suas funções e mudanças ao longo do seu desenvolvimento. Os processos fisiológicos de acumulação da cana-de-açúcar foram estudados determinando-se os fatores mais influentes para serem trabalhados no procedimento de identificação do modelo. Os procedimentos de coleta de amostras em campo e análise de material foram apresentados.

Algumas técnicas de identificação disponíveis foram estudadas para então, realizar-se experimentos computacionais para selecionar e avaliar a representação e a estrutura de modelo mais adequadas. Uma revisão teórica de sistemas nebulosos foi apresentada, destacando as metodologias para a construção deste tipo de sistema a partir de dados. Durante o procedimento de identificação procurou-se obter um modelo com o menor número de parâmetros possíveis, permitindo ao usuário deste modelo compreender, de forma mais clara que para o modelo QCANE, o resultado da simulação do modelo. O resultado deste foco na modelagem foi a determinação de um modelo nebuloso composto por apenas 18 parâmetros e por 5 funções estruturais, sendo que 6 parâmetros variam para os 3 processos de uma variedade, enquanto o modelo QCANE é composto por 60 parâmetros e mais de 68 funções. Assim, o modelo obtido conseguiu representar o sistema proposto com uma quantidade bem menor de parâmetros que a do QCANE.

Os conjuntos de dados foram avaliados segundo os critérios estudados, determinando um novo período de amostragem para o sistema. Durante o procedimento de identificação verificou-se que se deve adotar a temperatura ou a radiação como variáveis climáticas.

As representações matemáticas utilizadas durante o procedimento de identificação foram: modelos de processos contínuos, modelos de processos discretos (ARX) e modelos nebulosos. A utilização dos sistemas nebulosos para a modelagem destes processos obteve o melhor desempenho nas predições utilizando uma quantidade reduzida de parâmetros.

Os resultados computacionais indicaram que o modelo nebuloso obtido teve uma resposta mais precisa e exata que o modelo QCANE, tido como o modelo mais preciso da literatura para a estimativa de acumulação de biomassa e de açúcar da cana-de-açúcar. O modelo nebuloso proposto apresentou um desempenho entre 35% à 77% superior ao modelo QCANE para a variedade Q138 e de 53% a 77% superior para a variedade Q141.

Os resultados deste trabalho abrem uma nova perspectiva para a aplicação de sistemas nebulosos na modelagem do sistema de produção de cana-de-açúcar. Além disso, a metodologia utilizada pode ser aplicada para outras variedades, servindo como base para a elaboração de trabalhos futuros.

A simplicidade do modelo permitiu relacionar os conhecimentos sobre o comportamento fisiológico da planta às respostas de simulação do modelo. Isto levou a atribuição de termos lingüísticos as funções de pertinência e do conseqüente do modelo, viabilizando ao usuário do modelo interpretar as respostas deste.

O modelo nebuloso quando confrontado com o modelo QCANE apresentou resultados superiores quanto a aproximação do comportamento do sistema.

6.1 Trabalhos futuros

Neste trabalho os conjuntos de dados utilizados foram obtidos de campos experimentais de áreas de cana-de-açúcar com experimentos formulados para permitir o máximo crescimento da cultura. Assim, o modelo obtido neste trabalho é para prever o comportamento dos processos de acumulação em condições ideais de crescimento.

Nas condições normais de campo, o fator hídrico costuma ser o mais restritivo à produtividade da cana-de-açúcar, assim como de outras culturas. Outros fatores que também são restritivos costumam ser os nutrientes, principalmente fósforo e nitrogênio, mas no caso da agricultura brasileira a água é o principal fator restritivo. Ao considerar as reduções da produtividade por restrições hídricas da produtividade potencial obtem-se a produtividade real.

Na continuação pretendemos considerar os efeitos das variações hídricas na produtividade da cana-de-açúcar que correspondem à maior restrição ambiental ao desenvolvimento das culturas, em

especial a cana-de-açúcar. A introdução desta variável implica em lidar com variáveis relacionados ao solo, aumentando a complexidade do problema.

Outro ponto importante a ser trabalhado é a obtenção de dados de variedades nacionais de cana-de-açúcar tanto para a determinação de modelos nebulosos com a estrutura do atual quanto para a obtenção de estrutura de modelo de produção real.

Referências Bibliográficas

AGUIRRE, L. A. *Introdução à Identificação de Sistemas - Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais*. [S.l.]: Editora UFMG, 2000.

ALAGOAS, E. da estação experimental de cana-de-açúcar de. *Manual de técnicas de laboratório e fabricação de açúcar de cana*. [S.l.]: Instituto do Açúcar e Alcool, 1975.

ALLEN, R. G. et al. *FAO Irrigation and Drainage Paper No. 56 - Crop Evapotranspiration (guidelines for computing crop water requirements)*. Rome, Italy, May 1990.

ALMEIDA, F. M. *Identificação Multivariável de um Processo de Inceneração de Resíduos Líquidos Utilizando Modelos Nebulosos Takagi-Sugeno*. Dissertação (Mestrado) — Faculdade de Engenharia Elétrica e de Computação - UNICAMP, 2005.

ANDRADE, L.; CARDOSO, M. *Cultura da Cana-de-açúcar*. Lavras-MG, 2004.

ASSIS, J. P. *Modelo estocástico para estimação de produtividade potencial de milho em Piracicaba - SP*. Tese (Doutorado) — ESALQ-USP, 2004.

BABUSKA, R. *Fuzzy Modeling for control*. [S.l.]: Kluwer Academic Publisher, 1998.

BALL-COELHO, B. et al. Root dynamics in plant and ratoon crops of sugar cane. *Plant and Soil*, v. 142, p. 297–305, 1992.

BARBIERI, V. *Condicionamento climático da produtividade potencial da cana-de-açúcar (Sacharum spp.): um modelo matemático-fisiológico de estimativa*. Tese (Doutorado) — ESALQ/USP, 1993.

BATCHELOR, W. D.; BASSO, B.; PAZ, J. Examples of strategies to analyze spatial and temporal yield variability using crop models. *European Journal of Agronomy*, v. 18, p. 141–158, 2002.

BILLINGS, S.; ZHU, Q. Nonlinear model validation using correlation tests. *International Journal of Control*, v. 60, n. 6, p. 1107–1120, 1994.

- BOOTE, K. J.; JONES, J. W.; PICKERING, N. B. Potential uses and limitations of crop models. *Agronomy Journal*, v. 88, p. 704–716, 1996.
- BOTTURA, C. *Análise Linear de Sistemas*. [S.l.]: Editora Guanabara Dois, 1982.
- BOUMAN, B. A. M. et al. The “school of de wit” crop growth simulation models: A pedigree and historical overview. *Agricultural Systems*, v. 52, n. 2/3, p. 171–198, 1996.
- BULL, T.; TOVEY, D. A. Aspects of modelling sugarcane growth by computer simulation. *Proc. Int. Soc. Sugar Cane Technol.*, v. 15, p. 1021–1032, 1974.
- CANTARELLA, H.; QUAGGIO, J. A.; FURLANI, A. M. C. *IAC Boletim Técnico 100 - Recomendações de Adubação e Calagem para o Estado de São Paulo*. [S.l.], 1996.
- CAPUTO, M. M. *Indução da maturação por maturadores químicos e sua consequência na qualidade tecnológica de diferentes genótipos de cana-de-açúcar*. Dissertação (Mestrado) — ESALQ - USP, 2006.
- CARBERRY, P. S.; MUCHOW, R. C.; HAMMER, G. L. Modelling genotypic and environmental control of leaf area dynamics in grain sorghum. ii. individual leaf area. *Field Crops Research*, v. 33, p. 311–328, 1993.
- CASAGRANDE, A. A. *Tópicos de morfologia e fisiologia da cana-de-açúcar*. [S.l.], 1991.
- CASSINI, C. *Estimação Recursiva de Características Estáticas não-lineares utilizando modelos polinomiais NARMAX*. Dissertação (Mestrado) — Faculdade de Engenharia Elétrica - UFMG, 1999.
- CENTER, B.; VERMA, B. P. Fuzzy logic for biological and agricultural systems. *Artificial Intelligence Review*, v. 12, p. 231–255, 1998.
- CESAR, M.; SILVA, F. *A cana-de-açúcar como matéria prima para a indústria*. Piracicaba-SP, 1993.
- CESAR, M.; SILVA, F. *A cana-de-açúcar como matéria prima para a indústria sucroalcooleira*. [S.l.], 1993.
- CONSECANA. *Normas de avaliação da qualidade da cana-de-açúcar*. [S.l.], 2006. Disponível em: <www.unica.com.br/files/consecana/normaseprecos.pdf>.
- COSTA, M. et al. Variedades vs. adaptação ao solo vs. renovação do sistema radicular. In: *II Simpósio de tecnologia de Produção de Cana-de-açúcar*. Piracicaba: [s.n.], 2005.

- COSTA, M. C. G. *Distribuição e crescimento radicular em soqueiras de cana-de-açúcar: dois cultivares em solos com características distintas*. Tese (Doutorado) — ESALQ-USP, Julho 2005.
- CRUZ, J. C. G. *Identificação de uma torre de retificação de águas ácidas usando redes neurais artificiais*. Dissertação (Mestrado) — PPGEE, Universidade Federal de Minas Gerais, Belo Horizonte, MG, Agosto 1998.
- DELGADO, M. R. D. B. S. *Projeto automático de sistemas nebulosos: uma abordagem co-evolutiva*. Tese (Doutorado) — Faculdade de Engenharia Elétrica e de Computação - UNICAMP, 2002.
- DILLEWIJN, C. v. *Botany of Sugarcane*. [S.l.]: Waltham: chronica botanica, 1952.
- DOHNAL, M. Fuzzy bioengineering models. *Biotechnology and Bioengineering*, v. 27, p. 1146–1151, 1985.
- FANTUZZI, C.; ROVATTI, R. On the approximation capabilities of homogeneous takagi-sugeno modelo. In: *Proceedings Fifth IEEE International Conference on Fuzzy Systems*. [S.l.: s.n.], 1996. p. 1067–1072.
- FERNANDES, J. Observações sobre o sistema radicular da cana-de-açúcar. *Álcool & Açúcar*, v. 5, p. 51–52, 1985.
- FILHO, P. A. d. C. *Estudo Comparativo entre Técnicas de Inteligência Artificial e Modelos Lineares em Determinações Quantitativas no Infravermelho Próximo*. Tese (Doutorado) — Instituto de Química, Universidade Estadual de Campinas, 2003.
- GHELLER, A. C. A. Fatores que afetam o desempenho de maturadores e reguladores de crescimento em cana-de-açúcar. In: *Semana da cana-de-açúcar de Piracicaba*. [S.l.: s.n.], 1999. p. 16–19.
- GLOVER, J. The dark respiration of sugar-cane and loss of photosynthate during the growth of a crop. *Annals of Botany*, v. 37, p. 845–852, 1973.
- HABER, R. Nonlinearity tests for dynamic processes. In: *IFAC Symposium on Identification and System Parameter Estimation*. [S.l.: s.n.], 1985. p. 409–413.
- HAYKIN, S. *Neural networks - A Comprehensive Foundation*. Second. [S.l.]: Prentice Hall, 1999.
- HUFFEL, S. V. *The total least squares problem: computational aspects and analysis*. [S.l.]: SIAM, 1991. 300 p. (Frontiers of applied mathematics, v. 9).
- IBGE. *Cana-de-açúcar - Brasil*. Julho 2005. Internet. Disponível em:
<<http://www.agricultura.gov.br/pls/portal/url/ITEM/C90AF33B328ACEF5E0300801FD0AF5C8>>.

- IHRKE, I. *Some notes on ellipses*. [S.l.], January 2004. Disponível em: <http://www.mpi-inf.mpg.de/ihrke/software/ellipse_note.pdf>.
- INMAM-BAMBER, N. Effect of age and season on components of yield of sugarcane in south africa. In: *Proc. S. Afr. Sugarcane Technol. Assoc.* [S.l.: s.n.], 1994. p. 23–27.
- INMAM-BAMBER, N.; CULVERWELL, T. L.; MCGLINCHEY, M. Predicting yield responses to irrigation of sugarcane using a growth model and yield records. In: *Proc. S. Afr. Sugarcane Technol. Assoc.* [S.l.: s.n.], 1993. p. 66–72.
- INMAN-BAMBER, N. G. A growth model for sugarcane based on a simple carbon balance and cere-maize water balance. *South African Journal of Plant and Soil*, v. 8, p. 93–99, 1991.
- INMAN-BAMBER, N. G. Canegro: Its history, conceptual basis, present and future uses. In: ROBERTSON, M. J. (Ed.). *Research and Modelling Approaches to Assess Sugarcane Production Opportunities and Constraints*. [S.l.]: University of Queensland, 1995. p. 31–34.
- JONES, C. A. et al. Ceres-maize. In: _____. [S.l.]: Texas A & M University Press, 1986. cap. 4 Subroutine structure, p. 49–112.
- JONES, C. A. et al. *AUSCANE - Simulation Australian sugarcane whit EPIC*. [S.l.], 1989.
- KAILATH, T. *Linear Systems*. [S.l.]: Prentice Hall, 1980.
- KLIR, G.; YUAN, B. *Fuzzy Sets and Fuzzy Logic; Theory and applications*. [S.l.]: Pretenci Hall, 1995.
- KONSTANTINOV, K.; YOSHIDA, T. Physiological state control of fermentation processes. *Biotechnology and Bioengineering*, v. 33, p. 1145–1156, 1989.
- KONSTANTINOV, K.; YOSHIDA, T. A expert approach for control fermentation processes as variable structure plants. *Journal of Fermentation and Bioengineering*, v. 70, p. 48–57, 1990.
- KONSTANTINOV, K.; YOSHIDA, T. Knowledge-based control of fermentation processes. *Biotechnology and Bioengineering*, v. 39, p. 479–486, 1992.
- KOSKO, B. Fussy systems as a universal approximators. *IEEE Trans. Computers*, v. 43, p. 1329–1333, 1994.
- LAGARIAS, J. et al. Convergence properties of the nelder-mead simplex method in low dimensions. *SIAM Journal of Optimization*, v. 9, n. 1, p. 112–147, 1998.

- LISSON, S. et al. The historical and future contribution of crop physiology and modelling research to sugarcane production systems. *Field Crops Research*, v. 92, p. 321–335, 2005.
- LIU, D. Incorporating diurnal light variation and canopy light attenuation into analytical equations for calculating daily gross photosynthesis. *Ecological Modelling*, v. 93, p. 175–189, 1996.
- LIU, D.; KINGSTON, G. Variation of sugar and fibre components of dry matter in leaf, top and cane of sugarcane. *Proc. Aust. Soc. Sug. Cane Technol.*, v. 15, p. 352–359, 1993.
- LIU, D. L.; BULL, T. A. Simulation of biomass and sugar accumulation in sugarcane using a process-based model. *Ecological Modeling*, v. 144, p. 181–211, 2001.
- LIU, D. L.; KINGSTON, G.; BULL, T. A. A new technique for determining the thermal parameters of phenological development in sugarcane, including suboptimum and supra-optimum temperature regimes. *Agricultural and forest meteorology*, v. 90, p. 119–139, 1998.
- LIU, D. L.; KINGSTONE, G. Qcane: a simulation model of sugarcane growth and sugar accumulation. In: ROBERTSON, M. J. (Ed.). *Research and Modelling Approaches to Assess Sugarcane Production Opportunities*. University of Queensland, St. Lucia, Brisbane: [s.n.], 1994. p. 31–34.
- LIU, M.; SAMAL, A. A fuzzy clustering approach to delineate agroecozones. *Ecological Modelling*, v. 149, p. 215–228, 2002.
- LJUNG, L. *System Identification - Theory for the User*. [S.l.]: PRT Prentice Hall Information and Systems Sciences Series, 1999.
- MACHADO, E. C. *Um modelo matemático-fisiológico para simular o acúmulo de matéria seca na cultura de cana-de-açúcar (Sacharum spp.)*. Dissertação (Mestrado) — Instituto de biologia, UNICAMP, 1981.
- MAMDANI, E. Application of fuzzy logic to approximate reasoning using linguistic systems. *Fuzzy, Sets and Systems*, v. 26, p. 1182–1191, 1977.
- NEPOMUCENO, E. G. *Identificação Multiobjetivo de Sistemas Não-Lineares*. Dissertação (Mestrado) — UFMG, 2002.
- O'LEARY, G. J. A review of tree sugarcane simulation models with respect to their prediction of sucrose yield. *Field Crops Research*, v. 68, p. 97–111, 2000.

- O'LEARY, G. J. et al. Modeling sugarcane production systems i. development and performance of sugarcane module. *Field Crops Research*, v. 61, p. 253–271, 1999.
- PEDRYCS, W.; GOMIDE, F. *An Intoduction to Fuzzy Sets: Analysis and Design*. [S.l.]: MIT Press, 1998.
- PEDRYCZ, W. An identification algorithm in fuzzy relational systems. *Fuzzy Sets and Systems*, v. 13, p. 153–167, 1984.
- PEREIRA, A. R. Simulação do crescimento e da produtividade. In: *Simpósio sobre Manejo de Água na Agricultura*. Campinas: [s.n.], 1987. v. 17, p. 201–209.
- PROBERT, M. E. et al. Apsim's water and nitrogen modules and simulation of dynamics water and nitrogen systems. *Agric. Syst.*, v. 56, p. 1–28, 1998.
- PUCCIARELLI, A. J. *Modelagem de Séries Temporais Discretas Utilizando Modelo Nebuloso Takagi-Sugeno*. Dissertação (Mestrado) — Faculdade de Engenharia Elétrica e de Computação - UNICAMP, 2005.
- ROBERTSON, M. J.; MUCHOW, R. C. Future research challenges of efficient crop water use in sugarcane production. *Proc. ASSCT*, Townsvill, v. 16, p. 193–200, 1994.
- RODRIGUES, J. D. *FISIOLOGIA DA CANA-DE-AÇÚCAR*. [S.l.], 1995.
- RUSSELL, R. S. *Plant root systems: Their functions and interaction with the soil*. [S.l.]: McGraw-Hill, 1977. 290 p.
- SCHMOLDT, D. Simulation of plant physiological processes using fuzzy variables. *AI Applications*, v. 5, n. 4, p. 3–16, 1991.
- SERRA, G.; BOTTURA, C. An iv-qr algorithm for neuro-fuzzy multivariable on-line identification. *IEEE Transactions on Fuzzy Systems*, xx, p. xxx–xxx, 2007.
- SERRA, G. L. *Propostas de metodologias para Identificação e Controle Inteligentes*. Tese (Doutorado) — Faculdade de Engenharia Elétrica e de Computação - UNICAMP, Setembro 2005.
- SILVA, F.; CESAR, M. A. A.; SILVA, C. A. B. (Ed.). *Pequenas Indústrias Rurais de Cana-de-açúcar - Melado, Rapadura e Açúcar Mascavo*. [S.l.]: EMBRAPA, 2003.
- SILVA, F. C.; CESAR, M. *Guia para iniciação ao estudo da Agroindústria Sucroalcooleira*. 2003. CR-ROM.

- SILVA, F. C.; CESAR, M. A. A.; CHAVES, J. B. P. Qualidade da cana-de-açúcar como matéria prima. In: *Pequenas Indústrias Rurais de cana-de-açúcar, melado, rapadura e açúcar mascavo*. [S.l.]: Embrapa Comunicação para a Transferência de Tecnologia, 2003.
- SINGLES, A.; DONALDSON, R.; SMIT, M. Improving biomass production and partitioning in sugarcane: theory and practice. *Field Crops and Research*, v. 92, p. 291–303, 2005.
- SMITH, S.; NOKLEBY, B.; COMER, D. Fuzzy control systems. In: _____. [S.l.]: CRC Press, 1994. cap. A computational approach to fuzzy logic controller design and analysis using cell state of space methods, p. 398–427.
- SUGENO, M.; YASUKAWA, T. A fuzzy-logic-based approach to qualitative modeling. *IEEE Transactions on Fuzzy Systems*, v. 1, n. 1, p. 7–31, 1993.
- TAKAGI, T.; SUGENO, M. Fuzzy identification of systems and its application to modeling and control. *IEEE Transactions of Systems, Man, and Cybernetics*, v. 1, n. 15, p. 116–132, 1985.
- TANAKA, H.; UEJIMA, S.; ASAI, K. Linear regression analysis with fuzzy model. *IEEE Transactions of Systems, Man, and Cybernetics*, v. 6, n. 12, p. 903–907, 1982.
- TANAKA, K.; SUGENO, M. Stability analysis and design of fuzzy control systems. *Fuzzy Sets and Systems*, v. 42(2), p. 135–156, 1992.
- THORNLEY, J. H. M.; FRANCE, J. *Mathematical Models in Agriculture*. [S.l.]: Oxford University Press, 1976.
- UNICA. *Produção de cana- Brasil (em toneladas)*. 2006. Site. Disponível em: <<http://www.portalunica.com.br/portalunica/?Secao=referencia&SubSecao=estatisticas>>.
- WILLIAMS, J.; JONES, C. A.; DYKE, P. T. A modelling approach to determining the relationship between erosion and soil productivity. *Transactions ASAE*, v. 27, p. 129–144, 1984.
- YAMAKAWA, T. Fuzzy logic controller. *Journal of Biotechnology*, v. 24, p. 1–32, 1992.
- YOSHINAGA, E. M. S. *As Políticas de Exploração da Cana-de-açúcar no Brasil: da ocupação colonial à produção sucroalcooleira moderna*. Dissertação (Mestrado) — Universidade São Marcos, 2006.
- ZADEH, L. Outline of a new approach to the analysis of complex systems and decision processes. *IEEE Transaction of Systems, Man, and Cybernetics*, v. 1, n. 1, p. 28–44, 1973.
- ZHANG, H. *A Note on Fuzzy Clustering*. [S.l.], April 2005.

Apêndice A

Teoria de Sistemas Nebulosos, Método de Computação de Mínimos Quadrados Totais e Funções de Correlação

A.1 Conceitos básicos da teoria dos conjuntos nebulosos

Neste apêndice são apresentados conceitos da teoria dos conjuntos nebulosos, a demonstração da computação do método de mínimos quadrados total para determinar os parâmetros do conseqüente e por fim, algumas características dos gráficos de correlação de dados de sistemas contínuos.

A.1.1 Conjuntos nebulosos

Definição 1(Conjuntos nebulosos) Um conjunto nebuloso A sobre o universo de domínio X é definido pela função de pertinência $\mu_A(x)$ que mapeia a partir do universo X em um intervalo unitário:

$$\mu_A(x) : X \leftarrow [0, 1]. \quad (\text{A.1})$$

$\mathcal{F}(X)$ denota o conjuntos de todos os conjuntos nebulosos em X .

A teoria dos conjuntos nebulosos permite uma pertinência parcial de um elemento em um conjunto. Se o valor da função de pertinência $\mu_a(x)$, chamada de grau de pertinência, é $\mu_A(x) = 1$, x pertence ao conjunto nebuloso. Se $\mu_A(x) = 0$, x não pertence ao conjunto. Se o grau de pertinência

está entre 0 e 1, x é um membro parcial do conjunto nebuloso. Na literatura de conjuntos nebulosos, o termo “*crisp*” é freqüentemente usado para denotar quantidades não nebulosas, mas aqui adotou-se o termo valor incisivo.

A.1.2 Funções de pertinência

Em um conjunto discreto $X = \{x_i | i = 1, 2, \dots, n\}$, um conjunto nebuloso pode ser definido pela lista de pares ordenados: grau de pertinência/elemento do conjunto:

$$A = \{\mu_A(x_1)/x_1, \mu_A(x_2)/x_2, \dots, \mu_A(x_n)/x_n\}, \tag{A.2}$$

No domínio contínuo, conjuntos nebulosos são descritos analiticamente pela função de pertinência. Duas formas de função de pertinência gerais são:

Função de pertinência trapezoidal:

$$\mu(x; a, b, c, d) = \max \left(0, \min \left(\frac{x-a}{b-a}, 1, \frac{d-x}{d-c} \right) \right), \tag{A.3}$$

, onde a, b, c e d são coordenadas dos vértices do trapézio. Quando $b = 0$, uma função de pertinência triangular é obtida.

Função exponencial por partes:

$$\mu(x; c_l, c_r, \omega_l, \omega_r) = \begin{cases} \exp\left(-\left(\frac{x-c_l}{2\omega_l}\right)^2\right), & \text{se } x < c_l \\ \exp\left(-\left(\frac{x-c_r}{2\omega_r}\right)^2\right), & \text{se } x > c_r \\ 1, & \text{senão,} \end{cases} \tag{A.4}$$

onde c_l e c_r são os cotovelos esquerdo e direito respectivamente, e ω_l, ω_r são as amplitudes esquerda e direita, respectivamente. Para $c_l = c_r$ e $\omega_l = \omega_r$ a função Gaussiana é obtida.

A.1.3 Definições básicas

Definição 2(α -cortes) O α -corte A_α de um conjunto nebuloso A é um subconjunto do universo de X no qual todos os elementos têm um grau de pertinência maior ou igual à α :

$$A_\alpha = \{x | \mu_A(x) > \alpha\}, \alpha \in [0, 1]. \quad (\text{A.5})$$

O operador de α -corte é também denotado por α -corte(A, α).

Definição 3(conjunto nebuloso convexo) Um conjunto nebuloso definido em \mathbb{R}^n é convexo se cada um dos seus α -cortes é um conjunto convexo.

Definição 4(suporte) O suporte de um conjunto nebuloso A é um subconjunto incisivo de X no qual todos os elementos têm valores de pertinência diferentes de zero:

$$\text{supp}(A) = \{x | \mu_A(x) > 0\}. \quad (\text{A.6})$$

Definição 5(núcleo) O núcleo ou core de um conjunto nebuloso A é um subconjunto incisivo de X consistindo de todos os elementos com valores de pertinência iguais a 1:

$$\text{core}(A) = \{x | \mu_A(x) = 1\} \quad (\text{A.7})$$

Definição 6(cardinalidade) A cardinalidade de um conjunto nebuloso $A = \{\mu_A(x_i)/x_i | i = 1, 2, \dots, n\}$ é definida como a soma dos graus de pertinência:

$$|A| = \sum_{i=1}^n \mu_A(x_i). \quad (\text{A.8})$$

Definição 7(altura) A altura de um conjunto nebuloso A é o grau supremo de pertinência dos elementos em A , (PEDRYCS; GOMIDE, 1998):

$$\text{hgt}(A) = \sup_{x \in X} \mu_A(x). \quad (\text{A.9})$$

Definição 8(conjunto nebuloso normal) Um conjunto nebuloso A é normal se $\exists x \in X$ tal que $\mu_A(x) = 1$. O operador $\text{norm}(A)$ denota a normalização do conjunto nebuloso, p.e., $A' = \text{norm}(A) \Leftrightarrow \mu_{A'} = \mu_A(x)/\text{hgt}(A), \forall x$.

A.1.4 Operações nos conjuntos nebuloso

As definições das operações com conjuntos nebulosos são extensões das definições presentes na teoria dos conjuntos clássica. Nesta seção apresentamos as definições básicas de intersecção, união e complemento nebulosos, e as definições de algumas outras operações.

Definição 9(intersecção de conjuntos nebulosos) Tomando A e B como sendo dois conjuntos nebulosos em X , a intersecção de A e B é um conjunto nebuloso C , denotado $C = A \cap B$, tal que para cada $x \in X$:

$$\mu_C(x) = \min(\mu_A(x), \mu_B(x)). \quad (\text{A.10})$$

A operação de intersecção pode ser realizada utilizando as t -normas e é denotada por ' \wedge ', p.e., $\mu_C(x) = \mu_A(x) \wedge \mu_B(x)$. O operador de mínimo é a t -norma mais usada para esta operação.

Definição 10(união de conjuntos nebulosos) Tomando A e B como sendo dois conjuntos nebulosos em X . A união de A e B é um conjunto nebuloso C , denotado por $C = A \cup B$, tal que cada $x \in X$:

$$\mu_C(x) = \max(\mu_A(x), \mu_B(x)). \quad (\text{A.11})$$

A operação de união pode ser realizada utilizando as s -normas e é denotada por ' \vee ', p.e. $\mu_C(x) = \mu_A(x) \vee \mu_B(x)$. O operador de máximo é a s -norma mais usada para esta operação.

A intersecção nebulosa de dois conjuntos nebulosos pode ser especificada de uma forma mais geral pela operação binária sobre o intervalo unitário, p.e., para uma função da forma:

$$i : [0, 1] \times [0, 1] \leftarrow [0, 1]. \quad (\text{A.12})$$

Para que a função i seja qualificada como uma intersecção nebulosa, esta deve ter as propriedades apropriadas. Funções conhecidas como t -normas possuem estas propriedades requeridas pela intersecção. Similarmente, funções conhecidas como s -normas (ou, t -conormas) podem ser usadas para a união nebulosa.

Definição 11(t -norma/intersecção nebulosa) Uma t -norma i é uma operação binária sobre a unidade do intervalo que satisfaz pelo menos os seguintes axiomas para todo $a, b, c \in [0, 1]$:

$$i(a, 1) = a \text{ (condição de fronteira),} \quad (\text{A.13a})$$

$$b \leq c \text{ implica } i(a, b) \leq i(a, c) \text{ (monotonicidade),} \quad (\text{A.13b})$$

$$i(a, b) = i(b, a) \text{ (comutatividade),} \quad (\text{A.13c})$$

$$i(a, i(b, c)) = i(i(a, b), c) \text{ (associatividade).} \quad (\text{A.13d})$$

Algumas t -normas freqüentemente usadas são:

$$\text{intersecção padrão:} \quad i(a, b) = \min(a, b)$$

$$\text{produto algébrico:} \quad i(a, b) = a \cdot b$$

$$\text{intersecção de Lukasiewicz:} \quad i(a, b) = \max(0, a + b - 1)$$

Definição 12(s -norma/união nebulosa) Uma s -norma u é uma operação binária sobre a unidade do intervalo que satisfaz pelo menos os seguintes axiomas para todo $a, b, c \in [0, 1]$:

$$u(a, 0) = a \text{ (condição de fronteira),} \quad (\text{A.14a})$$

$$b \leq c \text{ implica } u(a, b) \leq u(a, c) \text{ (monotonicidade),} \quad (\text{A.14b})$$

$$u(a, b) = u(b, a) \text{ (comutatividade),} \quad (\text{A.14c})$$

$$u(a, u(b, c)) = u(u(a, b), c) \text{ (associatividade).} \quad (\text{A.14d})$$

Algumas s -normas freqüentemente usadas são:

$$\text{união padrão:} \quad u(a, b) = \max(a, b)$$

$$\text{soma algébrica:} \quad u(a, b) = a + b - a \cdot b$$

$$\text{união de Lukasiewicz:} \quad u(a, b) = \min(1, a + b)$$

Definição 13(complemento de um conjunto nebuloso) Tomando A como sendo um conjunto nebuloso em X , o complemento de A é um conjunto nebuloso, denotado por \bar{A} , tal que para cada $x \in X$:

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x). \quad (\text{A.15})$$

A.1.5 Relações nebulosas

Definição 14(*relações nebulosas*) Uma relação nebulosa n é qualquer mapeamento

$$R : X_1 \times X_2 \times \dots \times X_n \leftarrow [0, 1], \tag{A.16}$$

o qual designa um grau de pertinência para todos os n vetores (x_1, x_2, \dots, x_n) a partir do produto cartesiano $X_1 \times X_2 \times \dots \times X_n$.

Um relação nebulosa é, de fato, um conjunto nebuloso no plano cartesiano $X_1 \times X_2 \times \dots \times X_n$. Os graus de pertinência representam o grau de associação (correlação) ao longo dos elementos de diferentes domínios X_i . Para computar as implicações, R é convenientemente representado como um vetor n -dimensional: $R = [r_{i1, i2, \dots, in}]$.

A.1.6 Projeções e extensões cilíndricas

Definição 15(*universo n -dimensional*) Uma família $\mathcal{U} = (X^{(i)})_{i \in \mathbb{N}_n}$ de domínios não nulos X^i , $i = 1, 2, \dots, n$, $n \in \mathbb{N}$, é chamada um universo de dimensão n . $\mathbb{N}_n = \{1, 2, \dots, n\}$ é o índice do conjunto para este universo. Para qualquer índice de um subconjunto não vazio $I \subset \mathbb{N}_n$, o produto dos espaços é definido por:

$$X^I = \times_{i \in I} X^{(i)}$$

O produto dos espaços $X^{\mathbb{N}_n}$ é denotado por X por simplificação. Um conjunto nebuloso em um universo multidimensional é chamado de conjunto nebuloso multidimensional.

Definição 16(*projeção pontual*) Tomando $\mathcal{U} = (X^{(i)})_{i \in \mathbb{N}_n}$, sendo o universo de dimensão n e sendo \mathcal{C} , \mathcal{S} e \mathcal{T} os índices dos subconjuntos de \mathbb{N}_n que satisfazem as condições $\mathcal{T} = \mathcal{S} \cup \mathcal{C}$, $\mathcal{S} \cap \mathcal{C} = \emptyset$, a projeção pontual de $X^{\mathcal{T}}$ sobre $X^{\mathcal{S}}$ é o mapeamento $\text{red}_{\mathcal{S}}^{\mathcal{T}} : X^{\mathcal{T}} \leftarrow X^{\mathcal{S}}$ definido por:

$$\text{red}_{\mathcal{S}}^{\mathcal{T}}(x^{\mathcal{T}}) = x^{\mathcal{S}} \text{ com } (\forall i \in \mathcal{S} : (x^{\mathcal{S}})^{(i)} = (x^{\mathcal{T}})^{(i)}). \tag{A.17}$$

Definição 17(*projeção de um conjunto nebuloso*) Tomando $\mathcal{U} = (X^{(i)})_{i \in \mathbb{N}_n}$ sendo o universo do discurso de dimensão n , M um índice de conjunto com $\emptyset \neq M \subseteq \mathbb{N}_n$, a projeção de A sobre X^M é

o mapeamento $\text{proj}_M : \mathcal{F}(X) \leftarrow \mathcal{F}(X^M)$ definido por

$$\text{proj}_M(\mu(x)) = \sup \{ \mu(x') \mid x' \in X \wedge x = \text{red}_M^{N_n}(x') \}. \quad (\text{A.18})$$

Um exemplo da projeção a partir de \mathbb{R}^2 para \mathbb{R} é dado pela Figura A.1.

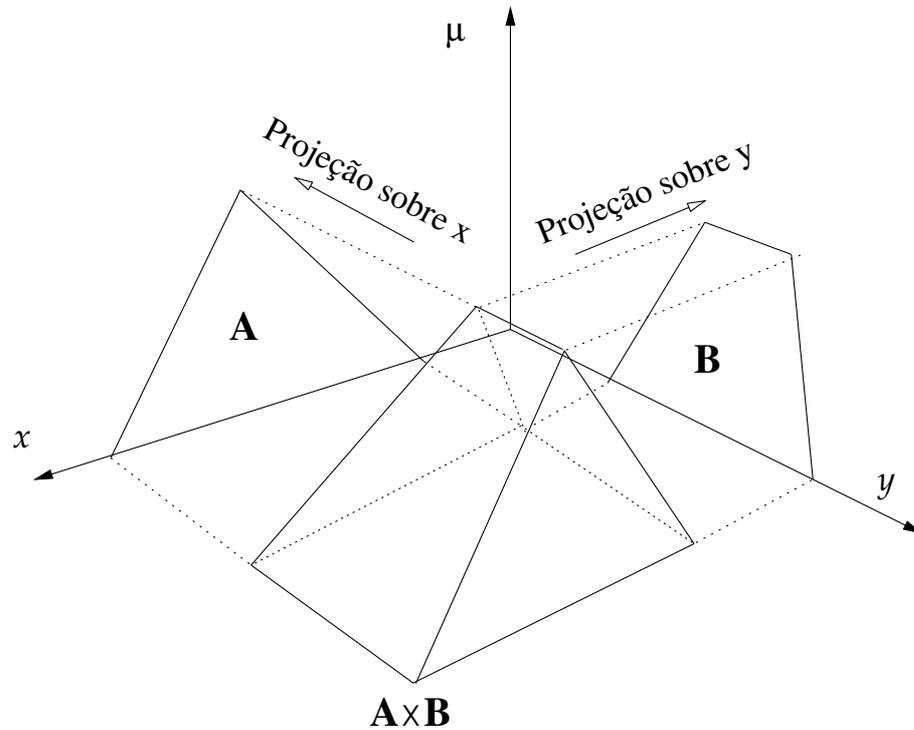


Fig. A.1: Exemplo de uma projeção

Definição 18(extensão cilíndrica de um conjunto nebuloso) Tomando $\mathcal{U} = (X^{(i)})_{i \in \mathbb{N}_n}$ como sendo um universo unitário de dimensão n . Fazendo M e N índices dos subconjuntos com $\emptyset \neq M \subseteq N \subseteq \mathbb{N}_n$, a extensão cilíndrica de A para X^N é o mapeamento $\text{ext}_M^N : \mathcal{F}(X^M) \leftarrow \mathcal{F}(X^N)$ definido por

$$\text{ext}_M^N(\mu(x)) = \mu(\text{ext}_M^N(x)). \quad (\text{A.19})$$

A.2 Demonstração da computação dos parâmetros do conseqüente pelo método de mínimos quadrados total

Primeiramente, para cada agrupamento, se transforma os dados pela subtração dos centros dos agrupamentos:

$$\Delta \mathbf{x}_k^i = \mathbf{x}_k - \mathbf{v}_i^x, \quad \Delta y_k^i = y_k - v_k^i. \quad (\text{A.20})$$

O centro do agrupamento \mathbf{v}_i agora torna-se a origem e o modelo local descrevendo o i -ésimo agrupamento pode ser dado na forma linear (homogênea) a partir de $\Delta y^i = a_i^T \Delta x^i$, ao invés da forma da Equação 3.26. Para expressar a relevância da variação de diferentes amostras de dados para o i -ésimo modelo local, os dados são ponderados por $\omega_{ik} = \sqrt{(\mu_{ik})^m}$:

$$\tilde{\mathbf{x}}_k^i = \omega_{ik} \Delta \mathbf{x}_k^i, \quad \tilde{y}_k^i = \omega_{ik} \Delta y_k^i. \quad (\text{A.21})$$

Para obter a formulação matricial do problema, se define a matriz $\tilde{\mathbf{X}}^i \in \mathbb{R}^{N \times p}$ e o vetor coluna $\tilde{\mathbf{y}}^i \in \mathbb{R}^N$, como a seguir:

$$\tilde{\mathbf{X}}^i = \begin{bmatrix} (\tilde{\mathbf{x}}_1^i)^T \\ (\tilde{\mathbf{x}}_2^i)^T \\ \vdots \\ (\tilde{\mathbf{x}}_N^i)^T \end{bmatrix}, \quad \tilde{\mathbf{y}}^i = \begin{bmatrix} \tilde{y}_1^i \\ \tilde{y}_2^i \\ \vdots \\ \tilde{y}_N^i \end{bmatrix}. \quad (\text{A.22})$$

Lema 1 *Seja o i -ésimo agrupamento aproximado por um modelo linear local na transformação de coordenadas: $\Delta y^i = a_i^T \Delta x^i$. Fazendo ϕ_i o menor autovetor do i -ésima matriz de covariância \mathbf{F}_i , o vetor de parâmetros \mathbf{a}_i pela Equação 3.67a, é a solução única do sistema linear*

$$\tilde{\mathbf{y}}^i \approx \tilde{\mathbf{X}}^i \mathbf{a}_i \quad (\text{A.23})$$

no sentido dos mínimos quadrados total.

Prova A prova é diretamente obtida do Teorema 2.6 de (HUFFEL, 1991), estabelecendo que a solução de mínimos quadrados ponderado total do problema A.23 é dada por:

$$\mathbf{a}_i = \frac{-1}{q_{p+1,p+1}^i} [q_{1,p+1}^i, q_{2,p+2}^i, \dots, q_{p,p+1}^i]^T, \quad (\text{A.24})$$

onde \mathbf{q}_{p+1}^i é a coluna da matrix \mathbf{Q}_2^i obtida pela decomposição diagonal em valores singulares (SVD) de $[\tilde{\mathbf{X}}^i, \tilde{\mathbf{y}}^i]$:

$$[\tilde{\mathbf{X}}^i, \tilde{\mathbf{y}}^i] = \mathbf{Q}_1^i \Sigma^i (\mathbf{Q}_2^i)^T, \quad (\text{A.25})$$

onde $\Sigma^i = \text{diag}(\sigma_1^i, \dots, \sigma_{p+1}^i)$ e os valores singulares são ordenados como $\sigma_1^i \geq \sigma_2^i \geq \dots \geq \sigma_{p+1}^i \geq 0$. Para qualquer matriz \mathbf{A} decomposta pela SVD em $\mathbf{A} = \mathbf{Q}_1 \Sigma (\mathbf{Q}_2)^T$, as colunas de \mathbf{Q}_2 são

autovetores unitários de $\mathbf{A}^T \mathbf{A}$. No nosso caso, $\mathbf{A} = [\tilde{\mathbf{X}}^i, \tilde{\mathbf{y}}^i]$ e

$$[\tilde{\mathbf{X}}^i, \tilde{\mathbf{y}}^i]^T [\tilde{\mathbf{X}}^i, \tilde{\mathbf{y}}^i] = \sum_{k=1}^N (\mu_{ik})^m (\mathbf{z}_k - \mathbf{v}_i)(\mathbf{z}_k - \mathbf{v}_i)^T = \mathbf{F}_i \sum_{k=1}^N (\mu_{ik})^m, \quad (\text{A.26})$$

onde a matriz \mathbf{F}_i é a matriz de covariância do agrupamento. O vetor \mathbf{q}_{p+1}^i é então o menor autovalor de \mathbf{F}_i . ■

Corolário 1 Para $c = 1$, \mathbf{a} é a solução do problemas padrão de mínimos quadrado ponderado total $\Delta y \approx \mathbf{a}^T \Delta \mathbf{X}$, uma vez que um único agrupamento resulta na partição degenerada $\mathbf{U} = \mathbf{1}^T$, \mathbf{v} é a média das amostras e \mathbf{F} é uma simples matriz de covariância.

Agora os parâmetros de polarização b_i do modelo conseqüente afim (Equação 3.26) são determinados. Na Equação A.21, o i -ésimo modelo linear local é dado por:

$$\begin{aligned} \Delta y^i &= \mathbf{a}_i^T \Delta \mathbf{x} \\ (y - v_i^y) &= \mathbf{a}_i^T (\mathbf{x} - \mathbf{v}_i^x) \\ y &= \mathbf{a}_i^T \mathbf{x} + v_i^y - \mathbf{a}_i^T \mathbf{v}_i^x \end{aligned} \quad (\text{A.27})$$

a partir do qual $b_i = v_i^y - \mathbf{a}_i^T \mathbf{v}_i^x$. Pela substituição de \mathbf{a}_i^T a partir de 3.67b, a seguinte expressão é obtida:

$$\begin{aligned} b_i &= v_i^y + \frac{1}{\phi_i^y} (\phi_i^y)^T v_i^x \\ &= \frac{1}{\phi_i^y} (\phi_i^y v_i^y + (\phi_i^y)^T v_i^x) \\ &= \frac{1}{\phi_i^y} \phi_i^T \mathbf{v}_i. \end{aligned} \quad (\text{A.28})$$

a qual é equivalente a Equação 3.67b.

A.3 Utilização de gráficos de correlação

A função de correlação entre os sinais de entrada e saída de um sistema indica a dependência temporal entre os sinais de entrada e saída, fornecendo informações sobre a dinâmica do sistema. Esta função é muito útil quando, em um sistema multivariável, se deseja selecionar as variáveis mais

relevantes ao comportamento dinâmico. Usualmente, no processo de modelagem de sistemas multivariados, as variáveis de saída do sistema já são definidas na fase experimental, assim, apenas as variáveis de entrada passam pelo processo de seleção.

Utilizando o sistema dinâmico

$$G(s) = \frac{\omega_n^2}{s^2 + 2\sigma\omega_n s + \omega_n^2} \exp^{-t_d s}, \tag{A.29}$$

onde t_d é o tempo de atraso (ou, morto) do sistema, de 100 [sec], ω_n é a frequência natural não amortecida do sistema, de 0,046 [rad/s] e σ é o fator de amortecimento, de 0,834, para realizar simulações, em malha aberta, usando os sinais de entrada mais relevantes dentro do contexto deste trabalho.

Utilizando um sinal degrau com chaveamento em 500 [sec] como entrada foi obtida a resposta apresentada na Figura A.2. Nesta figura pode ser observado um pico no ponto de atraso de 100 [sec], devido ao tempo de atraso do sistema.

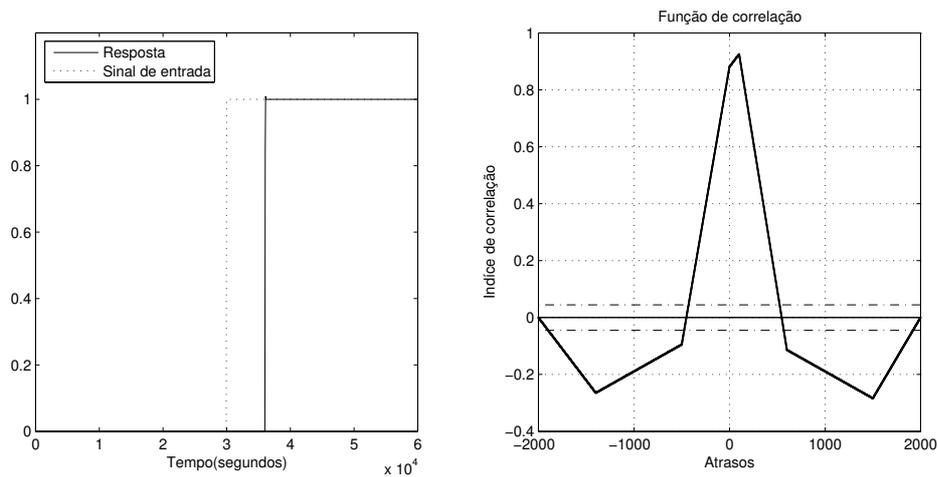


Fig. A.2: Função de correlação em malha aberta

Observa-se na Figura 5.1 que os sinais de entrada do sistema estudado têm características de senóides adicionadas de uma constante. Assim, simulou-se a resposta do sistema para tais sinais para posteriormente se analisar as características das curvas da função de correlação.

A Figura A.3 apresenta a resposta do sistema excitado com um sinal de entrada senoidal dado por

$$u(t) = \sin(\omega t) + 1,25, \quad \omega = 0.004[\text{rad/s}] \text{ e } t = 0 \rightarrow 2000[\text{sec}] \tag{A.30}$$

e a, respectiva, curva da função de correlação. A Figura A.4 avaliou o efeito da defasagem angular do sinal de entrada na resposta do sistema e na curva de correlação. Foi aplicado um sinal dado por

$$u(t) = \sin(\omega t + \pi/2) + 1,25. \quad (\text{A.31})$$

Pode se notar que a defasagem angular no sinal de entrada, neste caso, não altera a correlação entre os sinais.

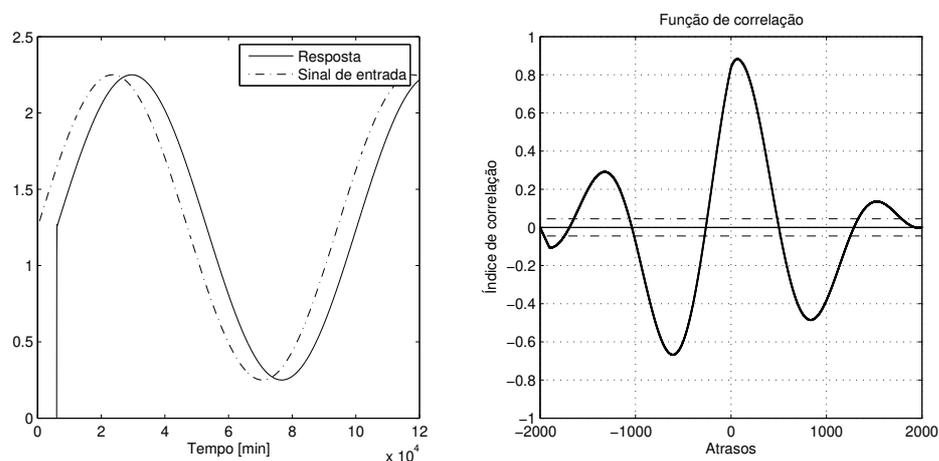


Fig. A.3: Função de correlação

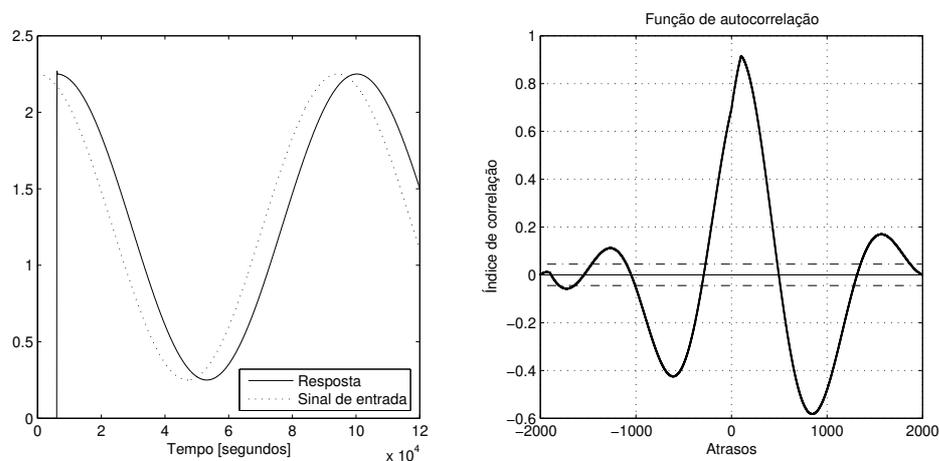


Fig. A.4: Função de correlação

O processo de acumulação de biomassa pela cana-de-açúcar pode ser aproximado inicialmente por um integrador. Assim, inseriu-se um termo integrador no sistema, resultando em

$$G(s) = \frac{\omega^2}{s(s^2 + 2\sigma\omega s + \omega^2)} \exp^{-t_d s}, \quad (\text{A.32})$$

mantendo-se os parâmetros. Aplicando-se o mesmo degrau anterior obtivemos a Figura A.5. Nota-se

que houve uma distorção da curva da função de correlação, mas ainda se manteve o pico para o atraso de 100 [min].

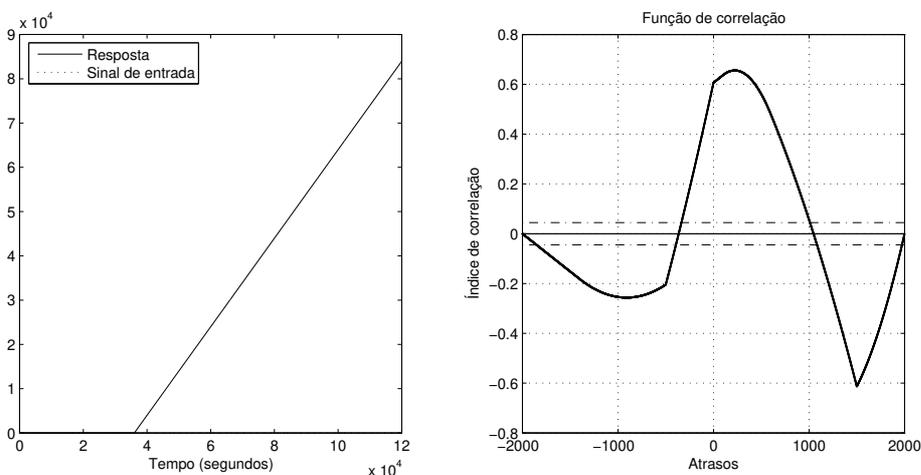


Fig. A.5: Função de correlação entrada/saída e resposta do sistema com um termo integrador

Considerando os sinais senoidais pelo motivo já mencionado, aplicando-se o sinal senoidal da Equação A.30 no sistema com um termo integrador obteve-se a resposta apresentada na Figura A.6. Posteriormente o sinal senoidal defasado da Equação A.31 foi aplicado e o resultado foi apresentado na Figura A.7, onde a defasagem afetou o resultado da função de correlação. Considerando outras defasagens angulares em diversas simulações não se conseguiu determinar um critério para se extrair nenhuma informação da função de correlação entre saída e entrada para este tipo de sistema.

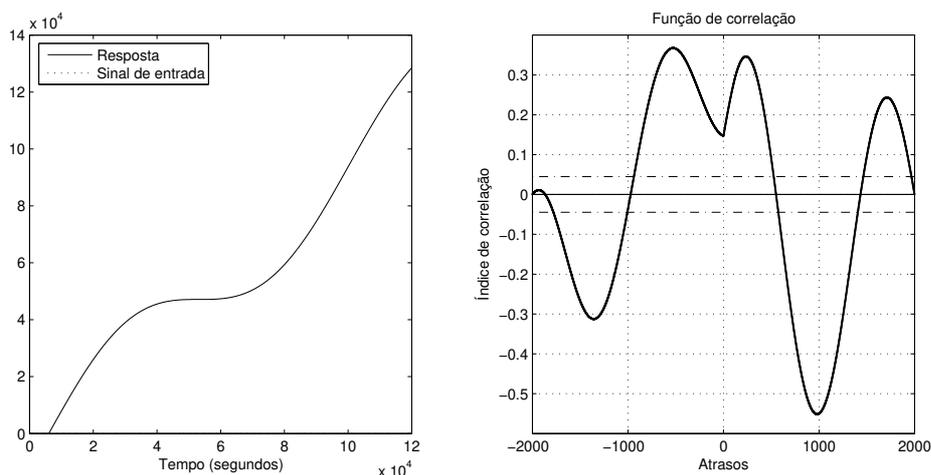


Fig. A.6: Função de correlação entrada/saída e resposta do sistema com um termo integrador à um sinal senoidal adicionado de uma constante

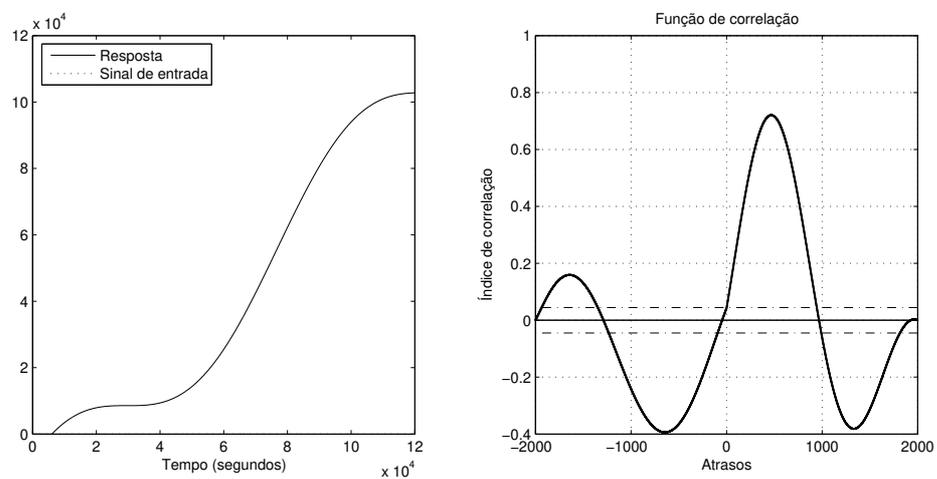


Fig. A.7: Função de correlação entrada/saída e resposta do sistema com um termo integrador à um sinal senoidal defasado

Apêndice B

Modelo QCANE

B.1 Introdução

O QCANE simula o crescimento e a acumulação de açúcar diariamente e difere dos outros modelos de cana-de-açúcar pelo forte embasamento conceitual sobre os processos fisiológicos. O QCANE integra os processos de formação da cobertura, fotossíntese e partição dos carboidratos para os organismos da planta. Os processos de crescimento, de respiração e de acumulação de açúcar de cada componente da planta são simulados.

A ênfase deste modelo está na utilização dos conhecimentos fisiológicos utilizados para compor cada uma das funções do modelo. Este modelo foi testado com dados de ambientes tropicais e subtropicais na Austrália e apresenta os melhores resultados da literatura (O'LEARY, 2000). Os modelos de balanço hídrico e de nitrogênio no QCANE, são adaptações a partir do CERES-Maize, e não serão tratados neste trabalho.

B.2 Descrição do modelo

O QCANE foi construído incorporando conhecimentos sobre os processos ecofisiológicos envolvidos no crescimento e desenvolvimento da cana-de-açúcar. O processo de crescimento está relacionado ao desenvolvimento fenológico e às condições ambientais. A fotossíntese é simulada após considerar as variações do período de insolação (fotoperíodo), a atenuação da luz pela cobertura vegetal, as influências da concentração de nitrogênio nas folhas e da temperatura. A respiração é calculada como função da biomassa acumulada e da temperatura. O modelo usa valores diários de

radiação solar, temperatura, dia do ano e latitude. As mudanças de temperatura sazonais e o sombreamento nas camadas inferiores da cobertura são usadas para determinar a senescência das folhas e o desenvolvimento da cobertura. A partição dos carboidratos dentro das folhas, dos ponteiros, dos colmos e dos componentes da raiz usam funções que consideram a temperatura e os estágios de desenvolvimento da cultura. Dois princípios foram adicionados durante o desenvolvimento do modelo. Inicialmente, funções matemáticas para descrever os processos biológicos foram derivadas e utilizadas sempre que possível sem fazer uso de simplificações. Posteriormente, quando foram necessárias descrições empíricas, equações foram elaboradas e ajustadas considerando os conhecimentos e os dados da literatura ou de experimentos não publicados. Um nível de modelagem empírica está presente porque os parâmetros envolvidos no modelo tem de ser baseados em observações.

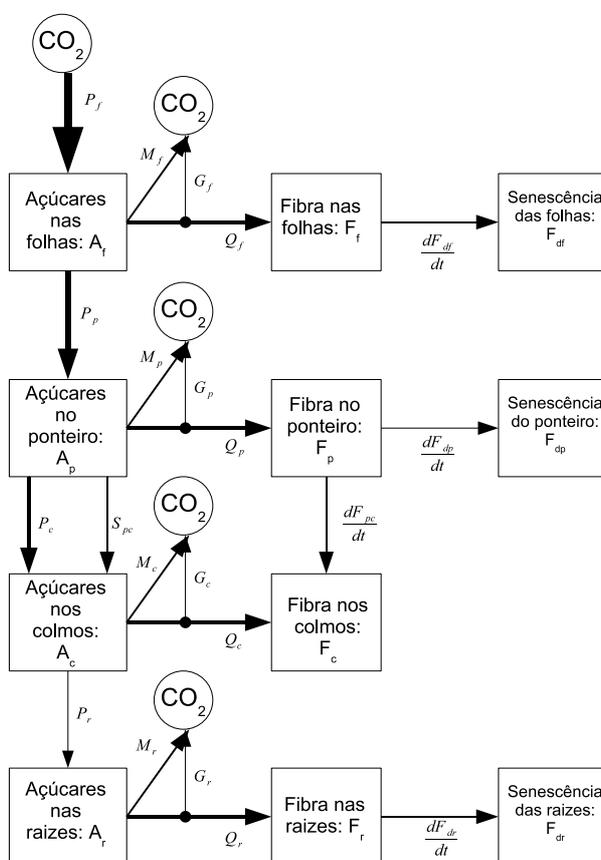


Fig. B.1: Representação esquemática do modelo QCANE.

B.2.1 Considerações gerais

O modelo considera que a planta é composta de quatro macro-partes: folhas, ponteiros, colmos e raíz.

As folhas são divididas em folhas verdes e folhas mortas. As funções do modelo associadas as folhas verdes recebem o subscrito f e às associadas as folhas mortas recebem o subscrito df .

Os ponteiros incluem os colmos a partir da primeira folha verde até a gema apical. Os ponteiros são divididos em ponteiros vivos e mortos, os ponteiros mortos representam os perfilhos que acabam morrendo na touceira da cana-de-açúcar; as funções do modelo referentes a estes ponteiros recebem o subscrito dp , já as funções associadas aos ponteiros vivos recebem o subscrito p .

Os componentes da cana incluem a cana acima do solo e abaixo do solo. O subscrito ' c ' será atribuído às funções dos colmos acima do solo e o ' ca ' será atribuído as funções dos colmos abaixo do solo.

As raízes são compostas por uma parte viva e outra morta. As funções associadas à parte das raízes vivas recebem o subscrito r e as associadas a parte morte recebem o subscrito dr .

O subscrito i é usado para os quatro componentes, p.e. $i = f, p, c, r$, a não ser que outra especificação seja indicada. Este indicador será utilizado em algumas formulações dos processos da planta.

O total da matéria seca em cada componente para cada instante de tempo t , consiste de três variáveis: A_i [g CH₂O m⁻²], F_i [g CH₂O m⁻²] e S_i [g substâncias m⁻²]. A_i são os açúcares, F_i é a fibra e S_i são as substâncias químicas restantes. Então S_i inclui minerais, amido, proteínas e outros metabólicos. O peso seco de cada componente PS_i , então pode ser escrito como

$$PS_i = F_i + A_i + S_i \quad (\text{B.1})$$

Uma representação esquemática é mostrada na Figura B.1, que mostra a organização do modelo com os trajetos do carbono absorvido pela planta ressaltados.

P_f é a quantidade de fotossintetizados produzidos pelas folhas e P_p , P_c e P_r são as parcelas de P_f repassadas aos ponteiros, aos colmos e às raízes respectivamente. As funções M_i representam a respiração de manutenção e constituem uma perda direta de carbono pela planta. As funções G_i representam o gasto energético para sintetizar novas fibras em cada componente e são denominadas respirações de crescimento. As funções Q_i determinam a acumulação de biomassa, ou fibra. As funções dF_{df}/dt , dF_{dp}/dt , e dF_{dr}/dt determinam as taxas de morte, ou perda, de folhas, ponteiros e raízes. S_{pc} e dF_{pc}/dt são as taxas de transferência de açúcar e de fibra, respectivamente, para o colmo que representa o aumento do número de colmos e conseqüentemente da altura da cana-de-açúcar.

Considerando que S_i é função de PS_i

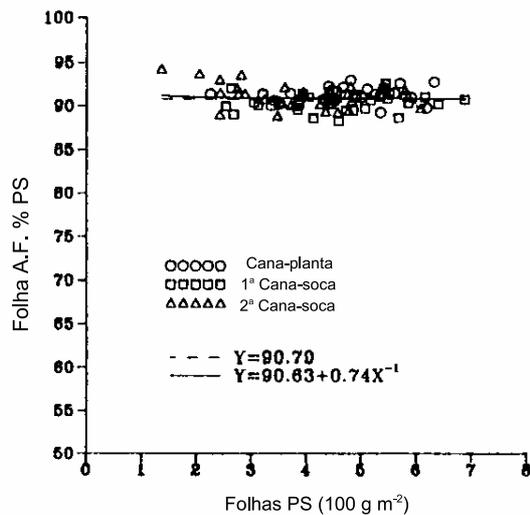


Fig. B.2: Proporção do Açúcar (A) e Fibras (F) nas folhas da cana-de-açúcar em relação ao Peso Seco (PS) total

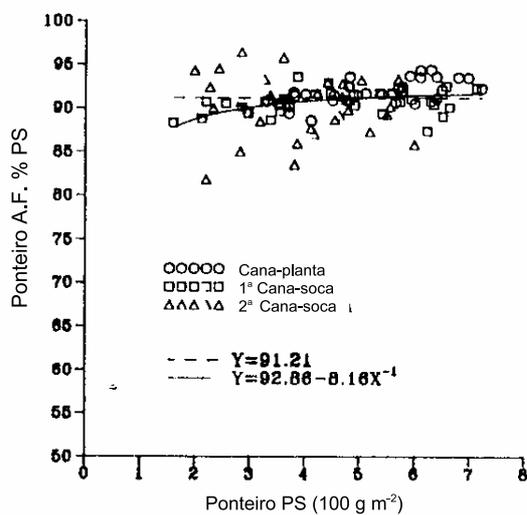


Fig. B.3: Proporção do Açúcar (A) e Fibras (F) nos ponteiros da cana-de-açúcar em relação ao Peso Seco (PS) total

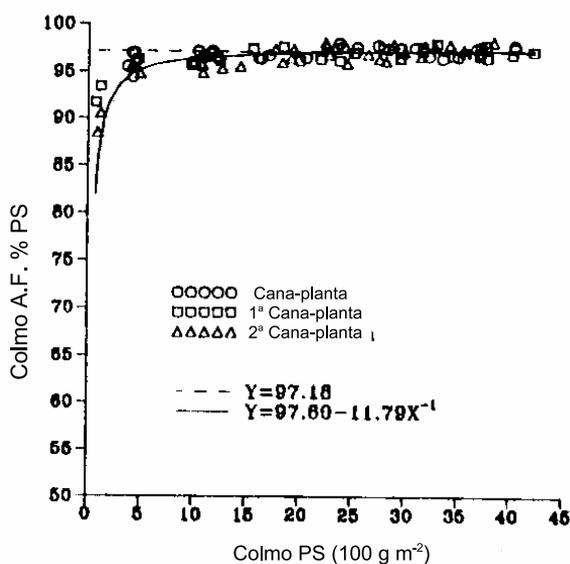


Fig. B.4: Proporção do Açúcar (A) e Fibras (F) nos colmos da cana-de-açúcar em relação ao Peso Seco (PS) total

$$S_i = \frac{g_i - 1}{g_i} P S_i \quad (\text{B.2})$$

onde, g_i é um coeficiente ≥ 1 . Por exemplo, se $g_i = 1$, p.e. $S_i = 0$, e o peso seco é constituído apenas de açúcar e fibra. Um modelo considerando o caso anterior foi desenvolvido em (THORNLEY; FRANCE, 1976), devido à contribuição de S_i ser muito pequena. Foram avaliadas as contribuições de S_i em folhas, ponteiro e colmo em duas variedades diferentes de cana-de-açúcar com níveis contrastantes de fibra, obtendo as Figuras B.2, B.3 e B.4, em (LIU; KINGSTON, 1993), e se determinou que g_i foi constante para estes três componentes exceto quando o peso seco do colmo foi menor de 500 [g m⁻²](ou, 5 [ton/hect⁻¹]). O valor g_c varia com a acumulação da matéria seca da cana e é obtido como a seguir:

$$\begin{aligned}
 A_c &= P S_c - (S_c + F_c) \\
 \frac{S_c + F_c}{P S_c} &= a_{gc} - b_{gc} P S_c^{-1} \\
 A_c &= \left(1 - \frac{1}{g_c} \right) P S_c
 \end{aligned}$$

$$g_c = \frac{PS_c}{a_{gc}PS_c - b_{gc}} \quad (\text{B.3})$$

onde, a_{gc} e b_{gc} são constantes. Se $PS_c < 40 \text{ g m}^{-2}$, $g_c = 1,468$. Daqui em diante, a , b , c e d serão geralmente usadas como constantes e os valores de todas as constantes e parâmetros estão listados na Tabela B.1. Substituindo a equação B.2 na equação B.1 resulta,

$$PS_i = g_i A_i + g_i F_i \quad (\text{B.4})$$

Então o peso seco do i -ésimo componente é expresso como a soma do peso seco da fibra e do açúcar com o multiplicador g_i ponderando igualmente A_i e F_i .

As concentrações de açúcares (C_{ai})[g g^{-1}] e de fibra (C_{fi})[g g^{-1}], respectivamente são definidas como:

$$C_{ai} = \frac{A_i}{PS_i}; \quad C_{fi} = \frac{F_i}{PS_i} \quad (\text{B.5})$$

Combinando as equações B.4 e B.5 resulta:

$$g_i = \frac{1}{C_{ai} + C_{fi}}, \quad i = f, p, r \quad (\text{B.6})$$

As concentrações de fibra (C_{fi}) e de açúcares (C_{ai}) nas folhas, ponteiros e raízes variam muito pouco ao longo do ano ou dos estágios de desenvolvimento, pois estes não são órgãos de armazenamento de açúcar. Então, foram usados valores constantes de C_{ai} e C_{fi} para folhas, ponteiros e raízes. Então g_i , definido na Equação B.6 é constante nos três componentes (folha, ponteiro e raiz). Dessa forma, as variáveis A , F e S para folhas, ponteiros e raízes para um instante de tempo, t , podem ser derivadas do PS_i . Isso é, a acumulação de açúcar, de fibra e de outras substâncias ocorre na mesma proporção da acumulação de matéria seca total nos componentes da cana-de-açúcar que não armazenam açúcar.

Considera-se que as senescências das folhas e das raízes são contínuas, após o início destes processos, e a senescência dos perfilhos secundário e terciário que falham ao longo do desenvolvimento da cana-de-açúcar é modelada como a senescência do ponteiro. O processo da senescência não foi modelado para os colmos.

Parâmetro	Valor	Parâmetro	Valor
α_{max}	$1,608 \times 10^{-4}$	B_{dp}	1500 [$^{\circ}Cd$]
β_d	12,7 [$^{\circ}C$]	B_{dr}	2000 [$g m^{-2}$]
β_e	11,6 [$^{\circ}C$]	B_{gc}	11,79
β_s	12,4 [$^{\circ}C$]	b_{AIFma}	0,0863
γ_c	0,059 [$^{\circ}C^{-1}$]	b_{NI}	0,167 [$m^{-2}m^2$]
γ_f	0,046 [$^{\circ}C^{-1}$]	b_{pm}	$7,656 \times 10^{-5}$
γ_p	0,054 [$^{\circ}C^{-1}$]	c_{pm}	0,5774 [$m^2 g^{-1}$]
γ_r	0,059 [$^{\circ}C^{-1}$]	d_{lgN}	60
λ_{ϕ}	0,23	d_{lgpc}	0/349
λ_c	$8,52 \times 10^{-5}$ [$g CO_2 g^{-1} min^{-1}$]	d_{lga}	39
λ_f	$3,991 \times 10^{-6}$ [$g CO_2 g^{-1} min^{-1}$]	d_{pm}	2,13
λ_p	$2,03 \times 10^{-6}$ [$g CO_2 g^{-1} min^{-1}$]	g_f	1,09
λ_r	$2,01 \times 10^{-6}$ [$g CO_2 g^{-1} min^{-1}$]	g_p	1,1
ω	0,33	g_r	1,10
μ	0,34	k	0,58
θ_d	800 [$^{\circ}Cd$]	C_{af}	0,05 [$g g^{-1}$]
θ_e	119 [$^{\circ}Cd$]	C_{ap}	0,25 [$g g^{-1}$]
θ_s	1132 [$^{\circ}Cd$]	C_{ar}	0,11 [$g g^{-1}$]
τ	0,41	C_{ff}	0,85 [$g g^{-1}$]
a_{α}	8,28 [$^{\circ}C$]	C_{fp}	0,66 [$g g^{-1}$]
a_{ψ}	0,5 [$^{\circ}Cd$]	C_{fr}	0,80 [$g g^{-1}$]
a_{dp}	0,03 [$^{\circ}Cd$]	T_o	29 [$^{\circ}C$]
a_{dr}	2,0 [$g m^{-2} d^{-1}$]	T_s	40 [$^{\circ}C$]
a_{gc}	0,976	T_{ro}	40 [$^{\circ}C$]
a_{AIFma}	85,5 [$g m^{-2}$]	V_{vN}	1,20
a_{Nf}	1,85 [$g m^{-2}$]	V_{vpc}	446 [$g m^{-2}$]
a_{pm}	$1,4243 \times 10^{-3}$ [$CO_2 d^{-1}$]	V_{va}	1,163
a_{ar}	$1,4 \times 10^{-3}$ [$m^2 g^{-1}$]	V_{iN}	0,75
b_{α}	2,82 [$^{\circ}C$]	V_{ipc}	227 [$g m^{-2}$]
b_{ψ}	499	V_{ia}	0,027

Tab. B.1: Constantes usadas no modelo

B.2.2 Acumulação de matéria seca, fibra e açúcar

As equações descrevendo a movimentação diária do açúcar para cada componente são desenvolvidas a partir da Figura B.1, baseada no balanço de entrada e saída de massa de fotossintetizados [$g CH_2O m^{-2} dia^{-1}$]. As equações para o incremento diário de açúcar na folhas, ponteiros, colmos e raízes são :

$$\frac{dA_f}{dt} = P_f - P_p - M_f - Q_f - G_f \quad (B.7a)$$

$$\frac{dA_p}{dt} = P_p - P_c - M_p - Q_p - G_p - A_{pc} \quad (B.7b)$$

$$\frac{dA_c}{dt} = P_c - P_r + A_{pc} - M_c - Q_c - G_c \quad (B.7c)$$

$$\frac{dA_r}{dt} = P_r - M_r - Q_r - G_r \quad (B.7d)$$

onde todos os termos são expressos em unidades [$g CH_2O m^{-2} dia^{-1}$], P_f é a quantidade de [CH_2O] produzido pela fotossíntese e P_p, P_c, P_r são as quantidades transportadas para o ponteiro, colmo e raiz, respectivamente.

Q_i é a taxa de crescimento da nova fibra,

G_i é a respiração de crescimento,

M_i é a respiração de manutenção, e

A_{pc} é a taxa de transformação do açúcar a partir de A_p para A_c através do processo de maturação.

Devido as concentrações de açúcar nas folhas, ponteiros, e raízes serem constantes, o incremento diário de açúcar nesses três componentes pode ser derivado das equações B.5 como é mostrado a seguir:

$$C_{ai} = \frac{A_i}{PS_i} \rightarrow A_i = C_{ai}PS_i \rightarrow \frac{dA_i}{dt} = C_{ai} \frac{dPS_i}{dt}, \quad i = f, p, r \quad (B.7e)$$

A equação B.7e implica que o açúcar só pode ser acumulado, acima de uma dada concentração, no componente de armazenagem (colmo). O incremento diário de açúcar é proporcional ao incremento diário de fibra. A equação B.7e é a condição limite para as equações B.7a, B.7b e B.7d. A quantidade diária de açúcares acumulados na cana é o balanço entre o crescimento da planta e a acumulação de açúcar. Isto será discutido posteriormente.

Similarmente, a partir da figura B.1 o estado da variável fibra para cada componente pode ser

descrito por

$$\frac{dF_f}{dt} = Q_f - \frac{dF_{df}}{dt} \quad (\text{B.8a})$$

$$\frac{dF_p}{dt} = Q_p - \frac{dF_{dp}}{dt} - \frac{dF_{pc}}{dt} \quad (\text{B.8b})$$

$$\frac{dF_c}{dt} = Q_c + \frac{dF_{pc}}{dt} \quad (\text{B.8c})$$

$$\frac{dF_r}{dt} = Q_r - \frac{dF_{dr}}{dt} \quad (\text{B.8d})$$

em unidades $[g \text{ CH}_2\text{O m}^{-2} \text{ dia}^{-1}]$, onde $F_{di}(i = l, p, r)$ é a senescência da fibra $[g \text{ CH}_2\text{O m}^{-2} \text{ dia}^{-1}]$, F_{pc} é a transformação da fibra a partir de F_p para F_c , através do processo de crescimento $[g \text{ CH}_2\text{O m}^{-2}]$

Os incrementos diários de matéria seca nas folhas, ponteiros e raízes, são derivados como:

$$\frac{dPS_f}{dt} = \frac{Q_f}{C_{ff}} - \frac{dPS_{df}}{dt} \quad (\text{B.9a})$$

$$\frac{dPS_p}{dt} = \frac{Q_p}{C_{fp}} - \frac{dPS_{pc}}{dt} - \frac{dPS_{dp}}{dt} \quad (\text{B.9b})$$

$$\frac{dPS_r}{dt} = \frac{Q_r}{C_{fr}} - \frac{dPS_{dr}}{dt} \quad (\text{B.9c})$$

em unidades de $[g \text{ m}^{-2} \text{ dia}^{-1}]$. $PS_{di}(i = l, p, r)$ é a senescência da matéria seca $[g \text{ m}^{-2}]$. Diferenciando a Equação B.4 e combinando com a Equação B.3 obtêm-se o incremento diário de matéria seca no colmo como

$$\begin{aligned} PS_c &= g_c A_c + g_c F_c \\ g_c &= \frac{PS_c}{a_{gc} PS_c - b_{gc}} \\ &\Downarrow \\ PS_c &= \frac{PS_c}{a_{gc} PS_c - b_{gc}} A_c + \frac{PS_c}{a_{gc} PS_c - b_{gc}} F_c \\ a_{gc} PS_c - b_{gc} &= A_c + F_c \\ PS_c &= \frac{1}{a_{gc}} (b_{gc} + A_c + F_c) \\ \frac{dPS_c}{dt} &= \frac{1}{a_{gc}} \left(\frac{dA_c}{dt} + \frac{dF_c}{dt} \right) \end{aligned} \quad (\text{B.9d})$$

B.2.3 Fotossíntese

A assimilação diária bruta de CO_2 por toda a cobertura (P_d) é expressa como:

$$P_d = \frac{P_m D}{k} \left[kF + \ln \left(\frac{1 + \delta}{1 + \delta e^{kF}} \right) + \delta \ln \left(\frac{1 + \delta}{\delta} \right) + \delta e^{kF} \ln \left(\frac{\delta e^{kF}}{1 + \delta e^{kF}} \right) \right] \quad (\text{B.10})$$

em unidades de $[\text{g CH}_2\text{O m}^{-2} \text{ dia}^{-1}]$, onde

$$\delta = \frac{(1 - \tau) P_m D}{2\alpha k I_d} IAF (mm^{-2}) \quad (\text{B.11})$$

é o índice de acumulação de área foliar a partir do topo da cobertura até a camada mais baixa de folha verde.

P_m é o valor assintótico da taxa de fotossíntese da folha para a densidade de fluxo de luz saturada $[\text{g CH}_2\text{O m}^{-2} \text{ s}^{-1}]$.

α é a eficiência fotossintética $[\text{g CH}_2\text{O J}^{-1}]$.

k é o coeficiente de extinção.

τ é coeficiente de transmissão da folha.

I_d é a radiação fotossinteticamente ativa diária $[\text{J m}^{-2}]$.

D é o comprimento do dia, calculado como função do dia do ano e da latitude.

O modelo da fotossíntese (equação B.10) é simples; esta é uma solução analítica para uma integração de relações bem conhecidas e fáceis de medir, por exemplo, a relação da fotossíntese de uma única folha, a lei de Beer para atenuação da luz e a aproximação triangular da variação da luz diurna. Deve-se notar que tanto a aproximação triangular quanto a senoidal podem ser usadas para estimar os padrões da distribuição da radiação. As avaliações prévias dos padrões de radiação mostraram que a abordagem triangular provou ser uma descrição mais realista da variação diária e menos complexa do que a aproximação senoidal. Os valores de τ e k (tabela B.1) foram determinados a partir de dados de campo que mediram as diferenças na quantidade de radiação acima e abaixo da cobertura como uma função do Índice de Área Foliar IAF . O valor de 0,41 medido para a cana-de-açúcar foi muito maior do que o valor 0,1 usado para a cultura da grama. Isto ocorre porque a cana-de-açúcar é plantada com espaço entre as linhas usualmente 1,4 [m] (ver Seção 2.2.5) e uma grande porção da luz atinge o solo, o que não ocorre em campos gramados. Adicionalmente, a altura e o espaço vertical das folhas na cobertura da cana-de-açúcar também contribui para o alto coeficiente de transmissão das folhas.

A produção (P_f) diária de carboidratos (CH_2O) a partir da fotossíntese realizada pela cobertura para o presente IAF é calculada por:

$$P_f = \sigma P_d \quad (\text{B.12})$$

em unidades de $[\text{g CH}_2\text{O m}^{-2} \text{ d}^{-1}]$, onde σ é a taxa das massas moleculares relativas de CH_2O para CO_2 ($30/44=0,682$).

A taxa de fotossíntese na cana-de-açúcar decresce com o Nitrogênio específico na folha (N) com uma faixa entre 0,8 e 1,7 $[\text{g m}^{-2}]$. A relação entre P_m e N foi derivada como:

$$P_m = (a_{pm}N - b_{pm})(1 - e^{(c_{pm}N - d_{pm})}) \quad (\text{B.13})$$

O N pode ser estimado a partir do IAF ou da idade da cultura, mas também varia com a estação de crescimento da cultura. Os dados de Allison et al (1997) forneceram a relação:

$$N_f = \frac{a_{Nf}}{1 + b_{Nf}IAF} \quad (\text{B.14})$$

O nitrogênio específico das folhas da cobertura, N_F , $[\text{g m}^{-2}]$ pode ser derivado como:

$$N_F = \frac{1}{IAF} \int_0^{IAF} N_f df = \frac{a_{Nf} \ln(1 + b_{Nf}IAF)}{b_{Nf}IAF} \quad (\text{B.15})$$

Os níveis de nitrogênio na folha variam a partir de baixos no inverno para altos no verão e podem ser descritos por:

$$N = N_F \zeta(\Lambda, v_{vN}, v_{iN}, d, d_{lgN}) \quad (\text{B.16})$$

onde $\zeta(\Lambda, v_{vN}, v_{iN}, d, d_{lgN})$ é definida como uma função de ciclo sazonal, a qual é representada por:

$$\zeta(\Lambda, v_{vN}, v_{iN}, d, d_{lgN}) = \frac{V_v + V_i}{2} + \frac{V_v - V_i}{2} \sin \left[2\pi \left(\frac{d - d_{lgN}}{Y} - \frac{|\Lambda|}{\Lambda} \frac{1}{4} \right) \right] \quad (\text{B.17})$$

,onde Y é o comprimento do ano, p.e. 365 ou 366 dias para o ano bissexto.

Λ é a latitude com valor negativo no hemisfério sul e um valor positivo para o norte.

V_v e V_i são os dois valores extremos.

d é o dia do ano e

d_{lgN} é o dia do ano quando V_s é atingido.

V_i é encontrado quando $d = d_{lg} + 183$.

A Equação B.17 apresenta a mudança sazonal a partir do menor valor para o maior valor durante

o ano, continuando o ciclo no ano seguinte. Esta é uma equação geral usada no QCANE. Os dados usados para ajustar a Equação B.16 foram obtidos a partir de experimentos projetados para estudar o crescimento da cultura para altas aplicações de adubos nitrogenados. A variação da concentração de nitrogênio na folha com a estação do ano se deve ao efeito da temperatura sobre o crescimento da cultura e a absorção de nitrogênio do solo. Então, altas concentrações de nitrogênio nas folhas durante o verão resultam das temperaturas favoráveis para o crescimento da cultura e absorção do nitrogênio, enquanto baixas concentrações de nitrogênio nas folhas durante o inverno se devem as temperaturas desfavoráveis para o crescimento da cultura e baixos níveis de absorção de N.

A eficiência fotossintética na cana-de-açúcar é afetada pela temperatura mostrando que esta varia a partir de 4×10^{-6} até 12×10^{-6} [g CO₂ J⁻¹] quando a temperatura da noite muda de 10 para 20 [°C]. A equação para modelar o efeito da temperatura sobre α é

$$\alpha(T_{media}) = \frac{\alpha_{max}(T_{media} - a_{\alpha})}{b_{\alpha} + T_{media}} \quad (B.18)$$

onde, α_{max} é a eficiência fotossintética máxima.

T_{media} é a temperatura média diária. Se a temperatura média diária é menor que 12 [°C], a T_{media} é ajustada para 12.

B.2.4 Respiração de crescimento e de manutenção

A respiração de crescimento é custo energético para converter os fotossintetizados em materiais estruturais, ou seja, em fibra. Considera-se, usualmente, que a síntese de uma nova de tecido custa uma unidade de CH₂O, ou seja, além dos fotossintetizados utilizados (3 no total) na composição da nova fibra, gastam-se adicionalmente mais uma unidade de CH₂O para construí-la. O gasto energético para a síntese de outros materiais é muito pequeno e não será considerado. Então, a respiração de crescimento é considerada a partir da quantidade sintetizada de fibra e pode ser escrita como

$$G_i = \omega Q_i \quad (B.19a)$$

onde, ω é uma constante com um valor de 0,33.

A respiração de manutenção supre a energia necessária para a continuidade dos processos celulares. Assim como muitos processos metabólicos, a respiração de manutenção da cana-de-açúcar é altamente dependente da temperatura e aumenta com o aumento da temperatura até uma temperatura ótima (T_{ro}). Se o aumento da temperatura for acima da temperatura ótima, a taxa da respiração de

manutenção irá decrescer. A respiração de manutenção dos internódios da cana-de-açúcar cai para temperaturas maiores que 40 [°C]. A resposta da respiração de manutenção da cana-de-açúcar para a temperatura é exponencial e foi evidenciada pelos dados experimentais de (GLOVER, 1973). A taxa da respiração de manutenção diária (R_i) é dada por:

$$R_i = \frac{1440\sigma\lambda_i}{\gamma_i(T_{max} - T_{min})} (e^{\gamma_i T_{max}} - e^{\gamma_i T_{min}}) \quad T_{min} < T_{max} \leq T_{ro} \quad (\text{B.19b})$$

$$R_i = \frac{1440\sigma\lambda_i}{\gamma_i(T_{max} - T_{min})} [1 + e^{\gamma_i T_{ro}} [1 + \gamma_i(T_{max} - T_{ro})] - e^{\gamma_i T_{min}} - e^{(\gamma_i T_{max} - \gamma_i T_{ro})}] \quad T_{min} < T_{ro} \leq T_{max} \quad (\text{B.19c})$$

$$R_i = \frac{1440\sigma\lambda_i}{\gamma_i(T_{max} - T_{min})} [e^{\gamma_i T_{ro}} + e^{\gamma_i(T_{max} - T_{ro})} - e^{\gamma_i(T_{min} - T_{ro})}] \quad T_{ro} < T_{min} \leq T_{max} \quad (\text{B.19d})$$

em unidade [g CH₂O g⁻¹ dia⁻¹], onde $\sigma = 0,682$ se a fonte de respiração é CH₂O; e $\sigma = 0,648$ se a fonte de respiração é a sucrose (C₁₂H₂₂O₁₁).

λ_i e γ_i são constantes. A respiração de manutenção diária é, então, calculada por

$$M_i = P S_i R_i \quad (\text{B.19e})$$

em unidades [g CH₂O m⁻² dia⁻¹].

B.2.5 Estágios fenológicos

Existem três estágios de desenvolvimento fenológicos da cana-de-açúcar:

1. emergência, a partir do plantio até o surgimento das primeiras folhas;
2. perfilhamento, a partir da emergência até o aparecimento da cana;
3. maturidade, a partir do aparecimento do colmo.

A emergência é definida como o período que vai do começo da brotação até quando aparecer um pé por metro da linha de plantio. Os estágios fenológicos são determinados para dois cultivares o Q138 e o Q141, a partir de experimentos conduzidos em Bundaberg como descrito por (LIU; KINGSTON;

BULL, 1998). O tempo térmico, θ_e , θ_s e θ_d [$^{\circ}Cd$] e a temperatura base β_e , β_s e β_d [$^{\circ}C$] para emergência, perfilhamento e maturidade respectivamente, dos dois cultivares estão listados na Tabela B.1. Assim, os estágios de desenvolvimento considerados no QCANE são diferentes dos apresentados na Figura 2.13. A Figura B.5 apresenta os estágios considerados pelo QCANE, modificando a figura originalmente apresentada.

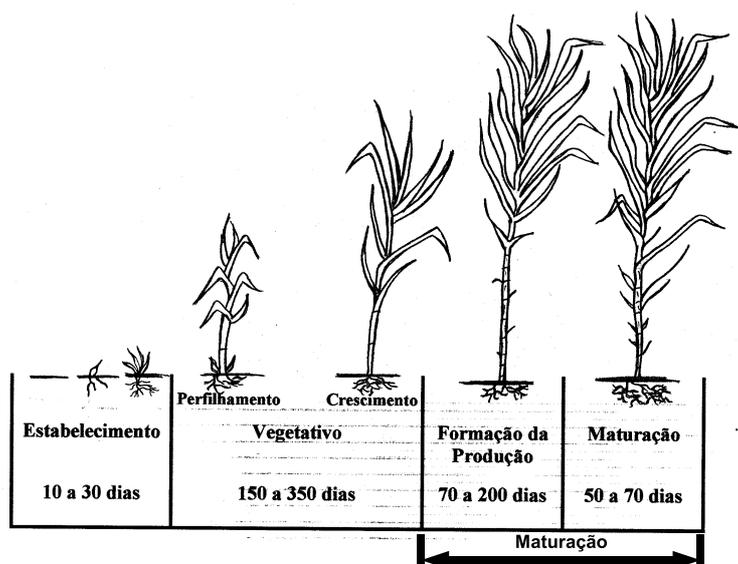


Fig. B.5: Estágios considerados no QCANE. Fonte: PLANALSUCAR, adaptado por (CESAR; SILVA, 1993b)

B.2.6 Particionamento dos fotossintetizados

Das equações (B.7a, B.7b, B.7c, B.7d) $P_f - P_p$, $P_p - P_c$, $P_c - P_r$ e P_r são as quantidades líquidas dos fotossintetizados (CH_2O) particionados nas folhas, nos ponteiros, nos colmos e nas raízes, respectivamente. Definindo a fração líquida dos fotossintetizados diários particionados na folha, ponteiro, colmo e raiz como f_f, f_p, f_c e f_r , respectivamente, as quantidades líquidas de fotossintetizados em cada componente, podem ser escritas como:

$$\begin{aligned}
 P_f - P_p &= f_f P_f; & P_p - P_c &= f_p P_f; \\
 P_c - P_r &= f_c P_f; & P_r &= f_r P_r.
 \end{aligned}
 \tag{B.20a}$$

A partir da equação B.20a, pode-se derivar:

$$f_f + f_p + f_c + f_r = 1 \quad (\text{B.20b})$$

A relação entre as frações podem ser denotadas por

$$\begin{aligned} \frac{f_p}{f_f} &= \rho_p \\ \frac{f_c}{f_f} &= \rho_c \\ \frac{f_r}{f_f} &= \rho_r \end{aligned} \quad (\text{B.20c})$$

Dessa forma, com a relação dada pela Equação B.20c, as relações seguinte podem ser derivadas a partir da Equação B.20b:

$$f_f = \frac{1}{1 + \rho_p + \rho_c + \rho_r} \quad (\text{B.20d})$$

$$f_p = \frac{\rho_p}{1 + \rho_p + \rho_c + \rho_r} \quad (\text{B.20e})$$

$$f_c = \frac{\rho_c}{1 + \rho_p + \rho_c + \rho_r} \quad (\text{B.20f})$$

$$f_r = \frac{\rho_r}{1 + \rho_p + \rho_c + \rho_r} \quad (\text{B.20g})$$

Uma função de partição pode ser descrita por fatores como suprimento de nitrogênio, quantidade de água disponível ou taxa de crescimento. De qualquer forma, para a cana-de-açúcar sob condições sem restrições de crescimento, a temperatura é o fator principal afetando o particionamento dos fotossintetizados entre armazenamento de açúcar e alongamento dos colmos.

Usando dados de acumulação de massa a partir de colheitas seqüenciais podem ser calculadas as frações de partição de cada componente. Adicionando-se as perdas da respiração de crescimento e de manutenção na massa acumulada líquida (Equação B.20c), os coeficientes entre as frações de partição ρ_p , ρ_c e ρ_r puderam ser calculados como taxas do ganho bruto de massa do ponteiro, colmo e raiz, respectivamente. As equações empíricas para ρ_p , ρ_c e ρ_r consideram a temperatura média como variável independente. As equações empíricas ajustadas são descritas pelas equações (B.21a), (B.21b) e (B.21c) para o estágio de perfilhamento e as equações (B.21d), (B.21e) e (B.21f) para o estágio de maturidade, respectivamente:

$$\rho_p = \frac{0,711T}{1 + 0,00278T} - 0,634T \quad R^2 = 0,31 \quad (\text{B.21a})$$

$$\rho_c = \frac{46,594}{13,954 + T} \quad R^2 = 0,56 \quad (\text{B.21b})$$

$$\rho_r = \frac{1,302}{1 + T^{3,093}} - \frac{56,055}{T^2} \quad (\text{B.21c})$$

$$\rho_p = \frac{2,625}{1 + 0,00916T^{1,575}} - \frac{9,611}{T} \quad R^2 = 0,63 \quad (\text{B.21d})$$

$$\rho_c = \frac{1,209(T - 2,777)^{1,761}}{(T - 2,777)^{1,761} - 25,394} \quad R^2 = 0,59 \quad (\text{B.21e})$$

$$\rho_r = \frac{1,622}{1 + 1,540(T - 9,63)^{0,489}} \quad (\text{B.21f})$$

onde T é temperatura média diária, a qual varia na faixa de 13,4 e 25,6 [°C] nas observações. As equações foram desenvolvidas pela combinação de resultados de ambas as variedades e se considera que as relações se mantenham para temperaturas médias entre 10 e 25 [°C]. Se a temperatura média diária for menor que 10 [°C], o T é fixado em 10; e se a temperatura diária média for maior que 25[°C], o T é fixado em 25.

B.2.7 Crescimento, acumulação de açúcar na cana e senescência

B.2.7.1 Folha

O desenvolvimento inicial da cana-de-açúcar a partir da germinação até a emergência utiliza reservas de carboidratos e nutrientes armazenados em pedaços de cana plantados ou do rizoma (soqueira) até que a área foliar seja suficiente para sustentar o crescimento. Depois da emergência, o QCANE começa a simular a produção de carboidratos com um valor inicial de $IAF = 0,008$ para a cultura de cana-planta e de $IAF = 0,08$ para cana-soca. O valor inicial maior de IAF da cultura de cana-soca se deve às reservas energéticas sob o solo e ao maior perfilhamento na emergência.

A taxa de crescimento da folha, Q_l , é obtida pela substituição da Equação (B.9a) na (B.7e) e substituindo (B.19a) na (B.7a), e então combinando as equações resultantes, e finalmente combinando a Equação (B.6) resulta na equação para Q_l expressa por:

$$Q_f = \frac{g_f \left[f_f P_f + M_f + C_{sf} \frac{dPS_{df}}{dt} \right]}{1 + g_f C_{ff} \omega} \quad (\text{B.22})$$

A senescência das folhas ocorre quando $\theta \geq 800$ [$^{\circ}\text{C dia}$] e é descrita como sendo proporcional ao incremento da matéria seca da cana porque a morte das folhas primárias resulta a partir da maturação da cana junto ao internódio. Então, a taxa de senescência das folhas pode ser escrita como:

$$\frac{dPS_{df}}{dt} = \Phi \frac{dPS_c}{dt} \quad (\text{B.23a})$$

onde Φ é um coeficiente. O número de folhas verdes em um talo varia de umas poucas no inverno para mais de 20 no verão. Observações de diferenças na senescência das folhas nas linhas das pontas e linhas internas de um campo implicam que o fator mais limitante do número de folhas verdes em condições ideais de crescimento na cana-de-açúcar é a falta de radiação nas camadas mais baixas da cobertura. No outono, como a cultura recebe uma quantidade menor de radiação solar do que no verão, a fotossíntese nas camadas mais baixas da cobertura não pode sustentar a demanda da respiração. Subseqüentemente as folhas nas camadas mais baixas da cobertura morrem e a cultura retém um número menor de folhas verdes no inverno. Então, Φ é expresso como uma função dos fatores de sombreamento nas camadas mais baixas da cobertura (I_s):

$$\Phi = \lambda_{\Phi} I_s \quad (\text{B.23b})$$

onde I_s é definida por:

$$I_s = \frac{R_{low}}{P_{low}} \quad (\text{B.23c})$$

onde R_{low} é a respiração de manutenção na camada de folhas a partir 0,9IAF até IAF. Para evitar o efeito de alguns fenômenos extremos, I_s é ajustado para 0,1, quando $R_{low}/P_{low} < 0,1$, e I_s é ajustado para 2,0, quando $2 < R_{low}/P_{low}$. R_{low} é calculado por:

$$R_{low} = 0,1IAFIAF_{ma}M_f \quad (\text{B.23d})$$

onde 0,1IAF é a área da folha na camada mais baixa da cobertura a partir de 0,9IAF para IAF e IAF_{ma} [g m^{-2}] é a massa de folha por área. Devido ao engrossamento com a idade da cultura, os dados experimentais mostram que IAF_{ma} obedece a seguinte relação:

$$IAF_{ma} = \frac{PS_f}{IAF} = a_{Fma} + b_{Fma}t \quad (\text{B.23e})$$

IAF_{ma} foi determinada pela medições das taxas de peso de matéria seca das lâminas das folhas para estas áreas, usando um sistema de medição de área foliar junto com colheitas seqüenciais.

λ_Φ foi determinado usando os cálculos das médias I_s , a taxa da senescência e a cana acumulada sobre o intervalo da colheita (Equações (B.23a) e (B.23b)). P_{low} é a produção de fotossintetizado na camada inferior da cobertura calculada por uma equação similar a Equação (B.10), mas a integração com relação à l é tomada a partir de $0,9IAF$ até IAF . Essa equação é obtida de forma similar a apresentada em (LIU, 1996):

$$P_{low} = \frac{P_m D}{k} \left[0,1kIAF + \ln \left(\frac{1 + \delta e^{-kIAF}}{1 + \delta e^{-0,9kIAF}} \right) + \delta e^{-kIAF} \ln \left(\frac{1 + \delta e^{-kIAF}}{\delta e^{-kIAF}} \right) \right] + \frac{P_m D}{k} \left[\delta e^{-0,9kIAF} \ln \left(\frac{\delta e^{-0,9kIAF}}{1 + \delta e^{-0,9kIAF}} \right) \right] \quad (B.23f)$$

onde todos os parâmetros são consistentes com as definições na Equação (B.10).

O desenvolvimento da área foliar para o dia é derivado da Equação (B.23e) e combinado com a Equação (B.9a) resulta:

$$\frac{dIAF}{dt} = \frac{1}{IAF_{ma}} \left(\frac{Q_f}{C_{ff}} - \frac{dPS_{df}}{dt} - b_{Lma} IAF \right) \quad (B.24)$$

B.2.7.2 Ponteiro

A taxa de crescimento do ponteiro, Q_p é obtida pela substituição da Equação (B.9b) na (B.7e) e substituindo a equação (B.19a) em (B.7b), então combinando as equações resultantes com a Equação (B.6); resulta:

$$Q_p = \frac{g_p C_{fp} \left[f_p P_f - M_p + C_{sp} \left(\frac{dPS_{pc}}{dt} + \frac{dPS_{dp}}{dt} \right) \right]}{1 + g_p C_{fp} \omega} \quad (B.25)$$

A senescência dos ponteiros é definida como a morte dos perfilhos, que é resultado do sombreamento devido ao desenvolvimento da cobertura. Então, a senescência diária dos ponteiros é calculada por:

$$\frac{dPS_{dp}}{dt} = \frac{dPS_{df}}{dt} \frac{a_{dp}}{b_{dp} + \theta} \quad (B.26a)$$

θ é o número de [°C dia] acima da temperatura da aparição da cana. A conversão dos ponteiros da cana começa depois do estágio de aparição do colmo. A quantidade de ponteiros varia com a estação e atinge um valor máximo no meio do verão quando a taxa de crescimento da cultura é máxima; é

mínima no inverno quando a taxa de crescimento é mínima. Então, depois da aparição do colmo, a quantidade de matéria seca no ponteiro varia ciclicamente. A quantidade de ponteiro varia entre V_{vpc} e V_{ipc} e a quantidade de matéria seca transformada em cana a partir do ponteiro pode ser descrita por:

$$\frac{dPS_{pc}}{dt} = PS_p - \zeta(\Lambda, V_{vpc}, V_{ipc}, d, d_{lg\ pc}) \quad (\text{B.26b})$$

quando,

$$PS_p < \zeta(\Lambda, V_{vpc}, V_{ipc}, d, d_{lg\ pc}), \quad \frac{dPS_{pc}}{dt} = 0 \quad (\text{B.27})$$

B.2.7.3 Colmo

A quantidade de carboidratos usada para sintetizar os materiais estruturais no colmo pode ser escrita como:

$$Q_c + G_c = \psi(f_c P_f - M_c) \quad (\text{B.28})$$

onde ψ é a taxa de crescimento da fibra no colmo, definida por uma função logística dependente da temperatura:

$$\psi = \frac{a_\psi}{1 + b_\psi e^{-\mu T_{media}}} \quad (\text{B.29})$$

Durante o estágio de perfilhamento, ocorre o desenvolvimento do colmo do sub-solo (PS_{cb}). O desenvolvimento dos colmos sobre o solo (PS_c) começa após a aparição do colmo. Então, quando o tempo térmico é menor do que θ_s , as acumulações de fibra e de açúcar ocorrem somente nos colmos do sub-solo e não ocorre a transformação de matéria seca dos ponteiros para os colmos. Os incrementos diários de fibra e de açúcar são derivados da combinação das Equações (B.7c), (B.8c), (B.19a) e (B.28), para $\theta < \theta_s$, e são dados por:

$$\frac{dF_c}{dt} = 0; \quad \frac{dF_{cb}}{dt} = \frac{\psi(f_c P_f - M_c)}{1 + \omega} \quad (\text{B.30a})$$

$$\frac{dA_c}{dt} = 0; \quad \frac{dA_{cb}}{dt} = (1 - \psi)(f_c P_f - M_c) \quad (\text{B.30b})$$

respectivamente. Quando o tempo térmico é maior que ou igual a θ_s , as acumulações de fibra e açúcar

passam a ocorrer na cana acima do solo e são dadas por:

$$\frac{dF_c}{dt} = \frac{\psi(f_c P_f - M_c - M_{cb})}{1 + \omega} + C_{fp} \frac{dPS_{pc}}{dt} \quad \frac{dF_{cb}}{dt} = 0 \quad (\text{B.30c})$$

$$\frac{dA_c}{dt} = (1 - \psi)(f_c P_f - M_c - M_{cb}) + C_{sp} \frac{dPS_{pc}}{dt} \quad \frac{dA_{cb}}{dt} = 0 \quad (\text{B.30d})$$

A respiração de manutenção dos colmos do sub-solo é sustentada pela produção de fotossintetizados a partir das folhas que surgem na fase de estabelecimento da cultura.

B.2.7.4 Raiz

A taxa de crescimento da raiz Q_r , é obtida pela substituição da Equação (B.9c) na (B.7e) e substituindo a Equação (B.19a) na (B.7d), e então combinando as equações resultantes, que combinadas a Equação (B.6) resultam em:

$$Q_r = \frac{g_r C_{fr} (f_r P_f - M_r + C_{sr} \frac{dPS_{dr}}{dt})}{1 + g_r C_{fr} \omega} \quad (\text{B.31})$$

A taxa da senescência das raízes aumenta com o tempo e pode variar com as mudanças da temperatura. De qualquer forma, a temperatura do solo varia com menor intensidade que a temperatura do ar e a taxa diária da senescência da raiz é estimada a partir da massa do sub-solo, considerando a relação hiperbólica:

$$\frac{dPS_{dr}}{dt} = \frac{a_{dr} PS_r}{b_{dr} + PS_r + PS_{cb}} \quad (\text{B.32})$$

Foi considerado que a senescência na cana planta começa quando a senescência das folhas começa.

B.2.7.5 Relação entre a sacarose e os açúcares redutores

Os açúcares são acumulados nos colmos como sacarose (A_{sc}) e em açúcares redutores (A_{rc}) (p.e. glicose e frutose). Os açúcares redutores são os açúcares simples obtidos diretamente do processo de fotossíntese. A quantidade de açúcares redutores é pequena nos colmos maduros, mas é grande nos colmos verdes ou quando a cana-de-açúcar está com altas taxas de crescimento. No inverno, as quantidades de açúcares redutores atingem seus menores níveis e, no verão, ocorrem os maiores

níveis.

Isto sugere que as quantidades de açúcares redutores diminuem com a matéria seca acumulada de colmo e variam com as estações devido às taxas de crescimento. Então, as quantidades de açúcares redutores são calculadas a partir das quantidades totais de açúcar como:

$$A_{rc} = A_c \frac{\zeta(\Lambda, v_{av}, v_{ai}, d, d_{lg a})}{1 + a_{ar} P S_c} \quad (\text{B.33})$$

$$A_{ac} = 0,95 S_c \left(1 - \frac{\zeta(\Lambda, v_{av}, v_{ai}, d, d_{lg a})}{1 + a_{ar} P S_c} \right) \quad (\text{B.34})$$

onde, 0,95 é a constante de conversão a partir de CH_2O em $\text{C}_{12}\text{H}_{22}\text{O}_{11}$. Os parâmetros da função sazonal são ajustados para as quantidades observadas dos açúcares redutores ao longo do ano.

Apêndice C

Procedimento de análise laboratorial de amostras

C.1 Introdução

Neste apêndice apresentamos as etapas de processamento analítico das amostras de cana-de-açúcar em laboratório. Este procedimento é baseado na mesma literatura que apresentou o procedimento de coleta de amostras em campo, descrito na Seção 2.3, (ALAGOAS, 1975). Cada estado brasileiro tem um órgão que regulamenta os padrões de análise utilizado, que são atualizado ano a ano. Desta forma apresentamos este procedimento para fornecer uma visão geral do processo analítico das amostras de cana-de-açúcar em laboratório.

C.2 Conservação das amostras

C.2.1 Anticépticos

Toda amostra deverá ser protegida de infecção de fungos, leveduras ou bactérias para evitar fermentação ou inversão. Para isso usam-se soluções anticépticas de bicloreto de mercurio (HgCl_2) em quantidade de 0.5 [ml] por litro de caldo.

O formol poderá ser utilizado na dosagem de 0,5 [ml] por litro, mas não deve ser usado quando se quer determinar os açúcares redutores.

C.2.2 Refrigeração

A conservação perfeita será com uma temperatura de $-10[^\circ\text{C}]$. Atualmente os laboratório utilizam geladeiras, ou câmaras frigoríficas quando se trabalha com uma grande quantidade de amostras. Uma temperatura de 1 a $4 [^\circ\text{C}]$ é eficaz quando a amostra tiver de ser conservada de 2 a 4 dias, mas para a conservação por um periodo superior a uma semana a temperatura deve ser inferior a $-10[^\circ\text{C}]$.

C.3 Processo de análise da cana-de-açúcar - Método de Payne

Serão descritos os procedimentos envolvidos na análise das amostras de cana-de-açúcar e em cada uma de suas etapas o procedimento realizado em laboratório.

C.3.1 Recepção da amostra de cana-de-açúcar

As canas vêm do campo em feixes etiquetados, e devem ser realizadas os seguintes etapas:

- Triturar as amostras, assim que chegam, de forma a ficarem uniformes e bem misturadas;
- Retirar vários punhados entre todas as partes da amostra triturada e espalhá-los e misturá-los sobre uma lona plástica preta.
- Armazenar o material em dois sacos com capacidade aproximada de 2 a 3 [kg], mantendo a etiqueta e amarrando o saco com barbante.
- Transportar o material para o laboratório da usina.
- Realizar imediatamente as análises para evitar evaporação e inversão.

C.3.2 Análise de Fibra

A partir das amostras trituradas que foram ensacadas e levadas para o laboratório da usina serão realizadas as análises da composição de fibra do material. O processo de análise é descrito a seguir:

- Espalhar a amostra contida no saco sobre a mesa e misturá-la em seguida;
- Retirar com o auxílio de uma espátula 800 [g] da amostra colocando-a numa recipiente plástico, de 3 a 4 litros. Descartar as sobras;

- Adicionar à amostra 2 [l] de água destilada;
- Transferir a amostra diluída para o recipiente do digestor sem deixar resíduos. A função do digestor é reduzir a amostra ao menor tamanho de partícula possível.
- Ativar o digestor por 10 minutos. Enquanto a amostra está no digestor, efetuar as seguintes operações:
 - Calibrar uma balança de precisão para desconsiderar o peso de um pano de algodão, utilizado para filtrar a amostra após o digestor.
 - Registrar os dados da fibra a ser analisada.
- Transferir a amostra para o lavador de fibra tomando o cuidado de manter a integridade da amostra.
- Tirar uma amostra do caldo de 400 [ml]
- Deixar a fibra numa torneira até não restar qualquer matéria solúvel.
- Retirar a amostra de fibra juntamente com o pano e passá-la em uma prensa manual.
- Colocar a amostra na estufa à 110 [°C] até obter um peso constante.

C.3.3 Determinação do Brix

O caldo extraído da amostra após o digestor é utilizado para o procedimento de análise do brix, pol, pureza e açúcares redutores. O procedimento para a determinação do brix é:

- Determinar o brix do caldo do digestor em um refratômetro.
- Corrigir a leitura utilizando a tabela de correção para a temperatura de 20 [°C].
- Subtrair o peso da fibra da quantidade inicial da amostra.
- Determinar o brix refratométrico do caldo do digestor.
- Calcular o Caldo Absoluto (Peso do caldo do digestor - Peso da Fibra - a Água adicionada)
- Ajustar o grau de brix para o caldo absoluto.

C.3.4 Determinação do Pol

Considerando o mesmo caldo utilizado na etapa anterior será realizada a determinação do Pol. As etapas para a determinação desse parâmetros são descritos a seguir:

- Tomar 300 [ml] de caldo do digestor, e adicionar de 1 à 2 [g] de subacetato de chumbo seco, misturar e filtrar;
- Recuperar o caldo filtrado num tubo polarimétrico de 200 [mm];
- Realizar leitura no polarímetro;
- Corrigir a leitura através da tabela de valores prefixados de Payne.

C.3.5 Determinação da Pureza Aparente do Caldo -PAP

A determinação da pureza consiste de uma relação percentual entre o Pol e o brix da amostra de cana-de-açúcar.

C.3.6 Determinação dos Açúcares Redutores - AR

O caldo de cana poderá ser simplesmente coado ou até clarificado com acetato de chumbo (utilizado na determinação do Pol). Para se determinar os açúcares redutores pelo método de Eynon e Lane, devemos proceder da seguinte maneira:

- Filtrar a amostra de caldo em algodão para eliminar as partículas em suspensão;
- Diluir a amostra, em volume ou em peso, visando consumir na titulação um volume em torno de 35 [ml], de maneira a reduzir os erros de análise;
- Na Tabela C.1 estão indicadas diluições que podem ser realizadas;
- Adicionar a solução de EDTA¹ antes de completar o volume a 100 [ml];
- Transferir, com auxílio de pipetas volumétricas, 5 [ml] da solução de Fehling B e 5 [ml] da solução de Fehling A;

¹Agente seqüestrante de cálcio e magnésio

Volume do caldo [ml]	Volume de EDTA [ml]	Fator de diluição (f)
10	2	10
20	4	5
25	5	4
50	10	2

Tab. C.1: Quadro com os índices de diluição para a solução de EDTA

- Colocar algumas perólas de vidro;
- Transferir para uma bureta 15 [ml] da solução e aquecer a mistura até a ebulição;
- Deve-se adicionar mais solução na bureta até que a cor da mistura torne-se vermelho tijolo;
- Marcar o volume (V) gasto, como valor aproximado da titulação;
- Repetir as mesmas operações, adicionando além do licor de Fehling, o volume da solução consumido na titulação anterior, menos 1 [ml] (V-1);
- Aquecer a mistura até a ebulição e então cronometrar, exatamente 2 [min], mantendo o líquido em ebulição constante;
- Adicionar de 3 a 4 gotas de solução de azul de metileno;
- Completar a titulação, gota a gota, até a completa eliminação da cor azul;
- Observar para que o tempo máximo entre o início da ebulição e a titulação seja menor do que 3 [min];
- Anotar o volume gasto na bureta e corrigi-lo com o fator do licor de Fehling, anotando como V.

A porcentagem dos açúcares redutores pode ser obtida através de dois procedimentos de cálculo apresentados em (CONSECANA, 2006). A seguir vamos mostrar os dois procedimentos:

1. O teor de AR em por cento pode ser calculado pela equação:

$$AR_{\%} = 3,641 - 0,0343 \times PAp \quad (C.1)$$

, onde PAp é a pureza aparente do caldo expressa em porcentagem.

2. Outra forma pode ser utilizando os dados pelo método de Eynon e Lane descrito anteriormente através dos seguintes cálculos:

$$AR = \frac{f \times s}{V \times me}, \quad (C.2)$$

onde:

f = fator de diluição;

V = volume gasto corrigido [ml];

me = massa específica do caldo [g/ml], dada por

$$me = 0,00431 \times B + 0,99367, \quad (C.3)$$

B = brix do caldo, válido para índices entre 9 a 23;

s = fator que considera a influência da sacarose na análise é dado por

$$s = 5,2096 - 0,2625 \sqrt[3]{0,00052 \times LPb \times V}, \quad (C.4)$$

onde:

LPb = leitura do polarímetro do caldo sem a adição de acetato de chumbo, e sem correção de leitura;

V = volume corrigido gasto [ml].

A adoção do segundo procedimento para a determinação do AR é indicada em sistemas experimentais, como por exemplo, a avaliação de uma nova variedade de cana-de-açúcar. Neste casos os resultados podem apresentar singularidades devido ao desconhecimento do comportamento do sistema. Assim os dados devem ser apurados profundamente.

C.4 Observações

Os procedimentos técnicos de análise das amostras de cana-de-açúcar em vigência nas usinas e destilarias são determinados pela Câmara Técnica e Econômica - CANATEC pertencente ao CON-SECANA Conselho dos produtores de Cana, Açúcar e Alcool do Estado de São Paulo. Esta câmara determinou os padrões tecnológicos das amostras realizadas na cana-de-açúcar. Contudo seus procedimentos estão apenas voltados para a análise de material com finalidades industriais, definindo assim os padrões para amostragens técnicas de fornecedores com finalidade de remuneração de fornecedores e não aborda amostragens de campos experimentais como descrito anteriormente. Dessa

forma determinou-se prudente adotar o “Manual de Técnicas de Laboratório e Fabricação de Açúcar de Cana” elaborado pela Estação Experimental de Cana-de-açúcar de Alagoas, (ALAGOAS, 1975), como o padrão de amostragem conforme descrito anteriormente.