

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
FACULDADE DE AGRONOMIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ZOOTECNIA

**MODELO BIOECONÔMICO PARA SUPORTE À DECISÃO EM SISTEMAS
PECUÁRIOS**

SORAYA TANURE
Médica Veterinária/ULBRA
Mestre em Zootecnia/UFRGS

Tese apresentada como um dos requisitos à obtenção do Grau de Doutor em
Zootecnia
Área de concentração Plantas Forrageiras

Porto Alegre (RS), Brasil
Abril, 2012

DEDICATÓRIA

Aos meus adoráveis pais Sady Elias Tanure e Lia Lemos Tanure...
Muito antes de pensar em “modelagem”, meus pais foram meu primeiro “modelo”. E souberam, como poucos, transmitir-me os princípios de trabalho, integridade e honestidade, legados por meus avós, que hoje habitam meus pensamentos, guiam meus passos e iluminam meus caminhos.

Meu carinho, respeito, admiração e eterna gratidão nestes versos, que representam boa parte das palavras de incentivo que recebi ao longo da vida...

*“No te rindas, aún estás a tiempo
De alcanzar y comenzar de nuevo,
Aceptar tus sombras,
Enterrar tus miedos,
Liberar el lastre,
Retomar el vuelo.*

*No te rindas que la vida es eso,
Continuar el viaje,
Perseguir tus sueños,
Destruir el tiempo,
Correr los escombros
Y destapar el cielo.*

*No te rindas, por favor no cedas,
Aunque el frío queme,
Aunque el miedo muerda,
Aunque el sol se esconda,
Y se calle el viento,
Aún hay fuego en tu alma,
Aún hay vida en tus sueños.*

*Abrir las puertas,
Quitar los cerrojos,
Abandonar las murallas que te
protegieron,
Vivir la vida y aceptar el reto,
Recuperar la risa,
Ensayar un canto,
Bajar la guardia y extender las
manos,
Desplegar las alas,
E intentar de nuevo,
Celebrar la vida y retomar los
cielos.*

*No te rindas, por favor no cedas...
Porque cada día es un comienzo
nuevo,
Porque esta es la hora y el mejor
momento,
Porque no estás solo...”*

Mario Benedetti

Trechos do poema *No te rindas*

AGRADECIMENTOS

Ao concluir mais uma importante etapa de minha formação acadêmica, agradeço a todos aqueles que estiveram presentes nesta caminhada. Ao iniciar um novo ciclo, carregando em meu coração as palavras de carinho e os gestos afetuosos daqueles que neste momento cito.

Inicialmente agradeço a Deus e Nossa Senhora, por estarem sempre ao meu lado. Por confortarem a “cientista” nos momentos em que apenas a ciência não era suficiente. Por guiarem meus caminhos, dando-me forças para seguir sempre em frente, mesmo nos aparentemente infundáveis momentos de desespero e incerteza. Por serem fontes de luz e inspiração.

Ao meu orientador Carlos Nabinger, por incentivar minha entrada no fantástico mundo da modelagem de sistemas biológicos e, principalmente, por nunca ter deixado de acreditar que nosso esforço conjunto resultaria em um bom trabalho, que seguramente não será finalizado nesta tese e norteará minha pesquisa durante longos anos. Agradeço ainda por ter me ensinado, em inúmeras oportunidades, o verdadeiro sentido da pesquisa multi e interdisciplinar, aquela que agrega além de conhecimento, pessoas! Essa agregação e busca por novas fontes de conhecimento, mentes pensantes e amparo ao nosso objeto de estudo, nos permitiu a convivência com o professor João Luiz Becker, que se tornou co-orientador e peça fundamental para a construção desta tese.

Ao professor João Luiz Becker, agradeço por ter aceitado uma médica veterinária (com pouquíssima intimidade com números), como aluna e orientanda e, principalmente, pelo amparo em todas as vezes que busquei em sua sala alento para os “desesperos matemáticos”.

Aos inúmeros mestres presentes ao longo dos anos de estudo, entre eles destaco João Armando Dessimon Machado, José Fernando Piva Lobato e Paulo Dabdab Waquil, por terem me acompanhado durante o processo de qualificação. Suas análises e contribuições foram fundamentais para o preenchimento das lacunas do projeto que originou esta tese.

Aos professores e funcionários dos Departamentos de Plantas Forrageiras e Zootecnia da Universidade Federal do Rio Grande do Sul, em especial a Ione Borcelli pela competência, dedicação e atenção inesgotáveis.

Ao CNPq e a CAPES, pelo apoio financeiro e fomento à pesquisa brasileira.

Por fim, mas não menos importantes, meus amigos. Solidários e incentivadores. Em especial, ao meu melhor amigo, Sady Elias Tanure Junior. Meu querido irmão, meu mano, que acompanhou meu desenvolvimento como ser humano, me fazendo perceber a inexplicável e eterna ligação que existe entre os irmãos. Agradeço também aos amigos Cláudia Lanfredi, Daiane Mülling Neutzling, Gabriela Cardozo Ferreira, Igor Justin Carassai, Marcelo Fett Pinto, Raquel Rolim Cardoso, Taise Robinson Kunrath e Thais Devincenzi, pelas conversas, momentos de descontração e por cativarem o valor das verdadeiras amizades, aquelas que resistem ao tempo e a distância. Ainda no hall das amizades, agradeço aquela que esteve ao meu lado durante todo o processo de formação acadêmica, Márcia Tomasi. Sua “visão de mundo”, otimismo constante e afeto “materno”, me fizeram superar inúmeras batalhas emocionais e profissionais. Obrigado!

Aos homens e mulheres do campo, aos apaixonados pela agropecuária e aos que acreditam no setor primário como grande responsável pelo desenvolvimento de nosso país e fortalecimento de uma sociedade mais harmônica, justa e humana.

A todas estas pessoas, meus sinceros agradecimentos! Vocês me fazem superar obstáculos, vislumbrar o futuro e ter em nossa amizade meu porto seguro.

MODELO BIOECONÔMICO PARA SUPORTE À DECISÃO EM SISTEMAS PECUÁRIOS¹

Autora: Soraya Tanure
Orientador: Carlos Nabinger
Co-orientador: João Luiz Becker

RESUMO – Os administradores rurais tomam decisões dentro de ambientes incertos e dinâmicos. Essas características, associadas à racionalidade limitada, podem levar à formulação de modelos mentais que refletem a realidade de forma distorcida. Nesse contexto, os procedimentos de modelagem e simulação constituem importantes ferramentas para entender o funcionamento dos sistemas de produção e para auxiliar a tomada de decisão em diferentes cenários. Assim, nesta pesquisa, propõe-se um macromodelo de enfoque sistêmico do ambiente agropecuário como ferramenta de apoio à decisão, capaz de representar a complexidade de uma unidade de produção pecuária, de forma a suprir as deficiências de compreensão e gestão do sistema, bem como de auxiliar no processo de aprendizagem do produtor rural. Para melhor compreender o modelo geral e suas facetas, esta tese está estruturada com base em três pilares: (i) modelagem conceitual; (ii) modelagem matemática; e (iii) simulação. Na modelagem conceitual, vários submodelos, também chamados de modelos de entrada, foram incorporados e adaptados de estudos já existentes, destacando-se: meteorológico, pasto, animal, lavoura, solo e as interfaces pasto-animal e pasto-solo. Esses submodelos combinados originam e configuram a estrutura da unidade de produção. Entre as principais saídas do modelo proposto, destacam-se os resultados econômicos baseados na produtividade agropecuária. O refinamento do modelo conceitual baseou-se no método Delphi, que permitiu a coleta de dados e particularidades do objeto de estudo e orientou seu desenvolvimento. Posteriormente, para a integração dos submodelos, utilizou-se modelagem matemática baseada em equações diferenciais e integrais. Por fim, para o desenvolvimento da simulação computacional, as equações matemáticas foram incorporadas ao *software* iThink 9.1.4, que utiliza a metodologia dinâmica de sistemas para a construção de modelos representativos da realidade, permitindo a construção de distintos cenários de produção pecuária. A validação do modelo bioeconômico ocorreu de forma específica nas modelagens conceituais e matemáticas; no entanto, a validação da simulação final será objeto de trabalhos futuros, com o intuito de identificar as principais lacunas e limitações que devem ser repensadas e desenvolvidas, bem como as variáveis a serem otimizadas sob o ponto de vista teórico-prático.

¹Tese de Doutorado em Zootecnia – Plantas Forrageiras, Faculdade de Agronomia, Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, Brasil (172p.) Abril, 2012.

DECISION SUPPORT BIOECONOMIC MODEL FOR LIVESTOCK SYSTEMS¹

Author: Soraya Tanure

Adviser: Carlos Nabinger

Co-adviser: João Luiz Becker

ABSTRACT – Rural managers make decisions in uncertain and dynamic environments. These characteristics, associated with bounded rationality can lead to the formulation of mental models that reflect reality in a distorted way. In this context, the procedures for modeling and simulation are important tools to understand how the production systems operate and to make decisions in different scenarios. Thus, in this research, we propose a macro model with a systemic approach of the farm environment as a tool for decision making support, capable of representing the complexity of a livestock production unit, in order to overcome the difficulties in understanding and managing the system, as well as to assist the producers in their learning process. To better understand the general model and its facets, this thesis is structured based on three pillars: (i) conceptual modeling; (ii) mathematical modeling; and (iii) simulation. In conceptual modeling, several submodels, also called input models, were incorporated and adapted from existing studies, including: meteorological, pasture, animal, crop, soil, and the interfaces pasture-animal and pasture-soil. These submodels combined originate and shape the structure of the production unit. Among the main outputs of the proposed model, we highlight the economic results, based on agricultural productivity. The refinement of the conceptual model was based on the Delphi method, which allowed the collection of data and peculiarities of the object of study and guided its development. Subsequently, for the integration of these submodels, we used mathematical modeling based on differential and integral equations. Finally, for the development of computer simulation, mathematical equations were incorporated into iThink 9.1.4 software, which uses the system dynamics methodology to build representative models of reality, allowing the construction of different scenarios of livestock production. The validation of the bioeconomic model occurred specifically in the conceptual and mathematical modeling; however, the final validation of simulation will be the goal of future studies, aiming to identify the main gaps and weaknesses that should be rethought and developed, as well as the variables to be optimized both from the theoretical and practical perspectives.

¹Doctoral thesis in Forage Science, Faculdade de Agronomia, Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, Brazil (172p.) April, 2012.

SUMÁRIO

	Página
CAPÍTULO I	01
1. INTRODUÇÃO GERAL	02
2. REVISÃO BIBLIOGRÁFICA.....	03
2.1 Pensamento sistêmico e tomada de decisão	03
2.2 Dinâmica de sistemas	10
2.2.1 Sistemas de retroalimentação (enlaces, <i>feedbacks</i> ou <i>loops</i>)	16
2.2.2 Estoques e fluxos	19
2.2.3 Atrasos (<i>delays</i>)	22
2.2.3.1 Atrasos materiais	23
2.2.3.2 Atrasos informacionais	24
2.2.4 Não-linearidade	26
2.3 Modelagem e simulação nos processos de decisão: vantagens e desvantagens	27
2.4 Modelagem e simulação bioeconômica em sistemas agropecuários	32
3. QUESTÕES DE PESQUISA	39
4. HIPÓTESES	40
5. OBJETIVO GERAL	41
5.1 Objetivos específicos	41
CAPÍTULO II	42
Bioeconomic model of decision support system for farm management. Part I: Systemic conceptual modeling	43
Abstract	44
Highlights	45
1. Introduction.....	46
2. Overview and modeling of decision making process in farm management	48
3. Research method	51
3.1 Model overview	51
3.2. Conceptual validation.....	52
4. Results	54
4.1 Macro bioeconomic model of decision support system for agricultural and livestock enterprises	54
4.2 Meteorological submodel	56
4.3 Pasture submodel	57
4.4 Animal submodel	59
4.5 Connection consumption in pasture-animal submodel	60
4.6 Crop-livestock integration submodel	61

4.7 Crop submodel	62
4.8 Soil submodel	65
4.9 Economic and environmental outputs	67
5. Summary and conclusions.....	69
References	70
CAPÍTULO III	84
Bioeconomic model of decision support system for farm management. Part II: Mathematical model development	85
Abstract	86
Highlights	87
1. Introduction.....	88
2. Mathematical modeling in farm management	90
3. Research method	92
3.1 Model overview	93
4. Results	95
4.1 Decision support bioeconomic model for livestock systems	95
4.2 Herd structure and animal characteristics submodel	97
4.3 Animal nutrient requirement submodel	100
4.4 Meteorological-soil-pasture-animal integration submodel	102
4.5 Economic submodel	107
5. Validation	109
6. Summary and conclusions.....	110
References	111
CAPÍTULO IV	121
Utilização do modelo de integração meteorologia-solo-pasto-animal para suporte à decisão em sistemas pecuários	122
Resumo	123
1. Introdução	124
2. Modelagem e simulação dinâmica de sistemas biológicos	126
3. Método de pesquisa	128
3.1 Modelo de integração meteorologia-solo-pasto-animal	128
3.2 Apresentação dos cenários	129
4. Resultados	134
4.1 Comparação entre cenários	134
4.1.1 Pastagem natural	134
4.1.2 Pastagem natural melhorada	136
4.1.3 Pastagem cultivada	138
5. Implicações	140
6. Conclusões	140
Referências	141
CAPÍTULO V	159
6. CONCLUSÕES GERAIS	160

7. IMPLICAÇÕES PARA TRABALHOS FUTUROS	161
REFERÊNCIAS BIBLIOGRÁFICAS	166
VITA	172

RELAÇÃO DE TABELAS

	Página
CAPÍTULO I	01
Tabela 1. Diferenças entre as modelagens <i>soft</i> e <i>hard</i> (Maani & Cavana, 2000)	13
Tabela 2. Tabela 2. Principais notações utilizadas em <i>softwares</i> de dinâmica de sistemas para construção de diagramas e estruturação de modelos (Adaptado de Sterman, 2000)	16
Tabela 3. Características dos sistemas de apoio à decisão (SAD; Huryk, 2012)	27
Tabela 4. Realidade <i>versus</i> modelo (Sterman, 2000)	28
CAPÍTULO II - Bioeconomic model of decision support system for farm management. Part I: Systemic conceptual modeling	42
Tabela 1. Economic and environmental indicators	82
CAPÍTULO IV - Aplicação do modelo de integração meteorologia-solo-pasto-animal para suporte à decisão em sistemas pecuários .	121
Tabela 1. Variáveis utilizadas na construção dos cenários do modelo meteorologia-solo-pasto-animal	149
Tabela 2. Cenário 1 da pastagem natural (déficit hídrico)	150
Tabela 3. Cenário 2 da pastagem natural (precipitação pluvial normal) .	151
Tabela 4. Cenário 1 da pastagem natural melhorada (déficit hídrico)	153
Tabela 5. Cenário 2 da pastagem natural melhorada (precipitação pluvial normal)	154
Tabela 6. Cenário 1 da pastagem cultivada (déficit hídrico)	156
Tabela 7. Cenário 2 da pastagem cultivada (precipitação pluvial normal)	157

RELAÇÃO DE FIGURAS

	Página
CAPÍTULO I	01
Figura 1. Visão sistêmica do processo de produção em uma propriedade rural (Adaptado de Muniz & Faria, 2001; Romeiro, 2002; Sterman, 2000)	08
Figura 2. Processo de modelagem utilizando a dinâmica de sistemas (Adaptado de Sterman, 2000)	11
Figura 3. Relações de causa e efeito (retroalimentação positiva e negativa) em sistemas complexos (Adaptado de Sterman, 2000; 2006)	18
Figura 4. Diagrama de Forrester (Original da autora)	20
Figura 5. Estrutura de retroalimentação de expectativas adaptativas (Adaptado de Sterman, 2000)	25
Figura 6. Estrutura de atraso informacional de alta ordem (Adaptado de Sterman, 2000)	26
Figura 7. Estrutura organizacional da tese (Original da autora)	41
CAPÍTULO II - Bioeconomic model of decision support system for farm management. Part I: Systemic conceptual modeling	42
Figura 1. Bioeconomic macro model of decision support system for farm management	78
Figura 2. Meteorological submodel, adapted from Fonseca et al. (2007)	78
Figura 3. Pasture submodel, adapted from Nabinger and Carvalho (2009)	79
Figura 4. Animal submodel, adapted from Vetharaniem et al. (2009) ...	79
Figura 5. Connection consumption, adapted from Machado (2004)	80
Figura 6. Crop-livestock integration submodel, adapted from Cassol (2003)	80
Figura 7. Crop submodel, adapted from Inman-Bamber (1994)	81

Figura 8. Soil submodel, adapted from Matthews (2006)	81
CAPÍTULO III - Bioeconomic model of decision support system for farm management. Part I: Mathematical model development	84
Figura 1. Bioeconomic macro model of decision support system for farm management (iThink 9.1.4)	119
Figura 2. Beef cattle production cycle for pasture-based Brazilian southern systems	120
Figura 3. Pasture structure, adapted from Machado (2004)	120
CAPÍTULO IV - Aplicação do modelo de integração meteorologia-solo-pasto-animal para suporte à decisão em sistemas pecuários .	121
Figura 1. Estrutura do modelo de integração meteorologia-solo-pasto-animal (iThink 9.1.4)	148
Figura 2. Cenário 1 - Produção e consumo de forragem da pastagem natural (déficit hídrico)	152
Figura 3. Cenário 2 - Produção e consumo de forragem da pastagem natural (precipitação pluvial normal)	152
Figura 4. Comparação entre as saídas econômicas dos cenários 1 e 2 da pastagem natural	152
Figura 5. Cenário 1 - Produção e consumo de forragem da pastagem natural melhorada (déficit hídrico)	155
Figura 6. Cenário 2 - Produção e consumo de forragem da pastagem natural melhorada (precipitação pluvial normal)	155
Figura 7. Comparação entre as saídas econômicas dos cenários 1 e 2 da pastagem natural melhorada	155
Figura 8. Cenário 1 - Produção e consumo de forragem da pastagem cultivada (déficit hídrico)	158
Figura 9. Cenário 2 - Produção e consumo de forragem da pastagem cultivada (precipitação pluvial normal)	158
Figura 10. Comparação entre as saídas econômicas dos cenários 1 e 2 da pastagem cultivada	158

RELAÇÃO DE ABREVIATURAS E SÍMBOLOS

%	Porcentagem
<	Menor que
>	Maior que
BI	Balance Income
CB	Carbon Balance
CE	Carbon Emission
CF	Carbon Fixation
CFE	Cash Flow Efficiency
CNPq	Conselho Nacional de Desenvolvimento Científico e Tecnológico
DF ₀	Disponibilidade Inicial de Forragem
DM	Dry Matter
DS	Dinâmica de Sistemas
ϵ_{CA}	Eficiência de Conversão da Radiação Fotossinteticamente Ativa Incidente
ETP	Evapotranspiração Potencial
ETR	Evapotranspiração Real
G	Grama
GMD	Ganho Médio Diário
GP	Ganho de Peso Vivo por Área
ha	Hectare
kg	Quilograma
LUE	Land Use Efficiency

m ²	Metro Quadrado
MD	Monthly Deficits
MJ	Mega Joule
MS	Matéria Seca
NP	Net Profit
NRC	Nutritional Research Council
OCL	Opportunity Cost of Land
PARi	Radiação Fotossinteticamente Ativa Incidente
P _{max}	Maximum Price
Pr	Price
P _x	Average Price
R\$	Reais
RI	Risk Index
TI	Total Inputs
Ton	Tonelada
UFRGS	Universidade Federal do Rio Grande do Sul
ULBRA	Universidade Luterana do Brasil
WI	Waste

CAPÍTULO I

1. INTRODUÇÃO GERAL

*“Prevejo – e não sou o único – que a biomatemática será um dos mais emocionantes setores de vanguarda da ciência no século XXI. O próximo século testemunhará uma explosão de novos conceitos matemáticos, trazidos à luz pela necessidade de compreender o mundo vigente.”
(Ian Stewart – Life’s Other Secret, 1998)*

O ambiente mercadológico altamente competitivo e complexo da atualidade exige atenção especial por parte dos gestores das empresas, em todos os setores, pois uma análise equivocada da realidade pode conduzir a resultados desastrosos. No setor agropecuário, as pressões impostas pela globalização da economia têm demandado uma mudança gradual, baseada na eficiência, como forma de sobrevivência e permanência no negócio.

O desempenho de empresas rurais é determinado por um grande conjunto de variáveis, decorrentes tanto das políticas públicas e da conjuntura macroeconômica, como das especificidades locais e regionais. Muitas dessas variáveis fogem ao arbítrio da unidade de produção, mas outras como a gestão do sistema produtivo, possuem maior possibilidade de controle (King et al., 2010; Jakku & Thorburn, 2010).

Os administradores rurais tomam decisões dentro de ambientes incertos e dinâmicos, gerando a necessidade de criação ou adaptação de ferramentas capazes de auxiliar este complexo processo. A natureza sazonal

da produção agropecuária revela que as decisões tomadas hoje (relacionadas a investimentos, adoção de tecnologia e desenvolvimento de mercado) podem levar meses, anos ou até décadas para gerar resultados (Hardaker & Lien, 2010). Essas características associadas à racionalidade limitada levam os administradores e produtores rurais a formular modelos mentais que refletem a realidade de forma distorcida e contra intuitiva.

Além disso, as empresas rurais possuem características singulares que as diferenciam das demais, como, por exemplo, a dependência do tempo em seus processos biológicos e as influências climáticas, o que gera um alto custo de decisões erradas. Essas características tão peculiares reforçam a necessidade de uma gerência diferenciada que se aproxime, portanto, dos princípios de uma administração estratégica.

Dado o avanço das tecnologias de informação, coletar informações já não representa um problema, no entanto, utilizá-las de maneira eficiente ainda é um desafio. A empresa depende, portanto, de mecanismos para disseminar, filtrar e utilizar as informações apropriadas e, assim, criar um processo contínuo de aprendizagem (Zott et al., 2011). Neste contexto, a adoção de sistemas de informação de apoio à decisão capazes de gerar modelos norteadores do negócio, torna-se fundamental para um melhor desempenho e otimização dos processos na agropecuária.

Entretanto, existe uma notória carência de ferramentas quantitativas adaptáveis aos diversos fatores de produção envolvidos na atividade agropecuária e que possam ser utilizadas em um processo de decisão baseado em rentabilidade, viabilidade técnica e sustentabilidade ambiental. Os sistemas

de informação na agropecuária devem possuir componentes econômicos e biológicos inter-relacionados que atuem de maneira conjunta e contínua, recebendo insumos e produzindo resultados em um organizado processo de produção (Douthwaite & Gummert, 2010). Uma importante alternativa de análise dos sistemas agropecuários é integração entre modelos matemáticos e instrumentos computacionais que permitam a criação de cenários preditivos, capazes de nortear a tomada de decisão pelo produtor rural.

Entre os maiores desafios atuais na construção de modelos, a aplicação de modelos dinâmicos merece destaque. A quase totalidade dos modelos, utilizados em agropecuária (ou mesmo no contexto amplo do agronegócio) utiliza-se de critérios e variáveis “estáticas” para criação de planilhas e interligações entre variáveis. No contexto biológico, fica claro que esta abordagem além de limitada é errônea, pois a maioria os processos ocorrem por meio da não-linearidade. Os modelos estáticos assumem que o estado do sistema em um determinado ponto no tempo é suficiente para a predição de seu comportamento e que seus estados transitórios não influenciam os resultados, não necessitando, portanto, serem mencionados. Logo, além de não representarem o sistema de forma correta e não permitirem adaptações ao meio onde deverão ser aplicados, estes modelos traduzem respostas deturpadas aos agentes de decisão.

Uma metodologia capaz de congrega a modelagem matemática, a simulação de explorações agropecuárias e o conceito da não-linearidade é a dinâmica de sistemas. A dinâmica de sistemas possibilita a construção de modelos extremamente complexos, constituídos por um alto número de

variáveis e possibilita a experimentação de inúmeros cenários e seu acompanhamento ao longo do tempo (Sterman, 2000).

No entanto, os modelos não podem ser encarados como um objetivo final de pesquisa ou de qualquer necessidade produtiva, e nem tampouco como “ferramenta pronta”, visto que são previamente concebidos, compostos por diversos elementos e expressam extrema necessidade de melhoria, adaptação e ajuste contínuos. Outro ponto de destaque é o fato dos modelos não prescindirem de exatidão para serem utilizados, pois é a aproximação da realidade que os torna aplicáveis.

Assim, a presente tese propõe como ferramenta de apoio à decisão um modelo bioeconômico sistêmico do ambiente agropecuário apresentado sob três enfoques: (i) conceitual; (ii) matemático; e (iii) de simulação computacional, objetivando representar, dentro de certas limitações, a complexidade de uma unidade de produção pecuária, em especial a relação entre crescimento do pasto-consumo-desempenho animal, de forma a suprir as deficiências de compreensão e gestão do sistema produtivo, bem como auxiliar o processo de aprendizagem pelo produtor rural.

2. REVISÃO BIBLIOGRÁFICA

2.1 Pensamento sistêmico e tomada de decisão

O pensamento sistêmico é uma filosofia que procura analisar o comportamento de um sistema através de sua estrutura (Senge et al., 2007). Em sistemas de dinâmica complexa, esta análise se beneficia da utilização de modelos formais, uma vez que o comportamento dos sistemas não pode ser previsto de forma eficiente apenas com modelos mentais (Cundill et al., 2012; French et al., 2011).

Para que a tomada de decisão sobre as atividades a serem desenvolvidas na propriedade rural seja realizada corretamente, é importante que o produtor tenha uma visão sistêmica do processo produtivo (Hardaker & Lien, 2010). Segundo Jakku & Thorburn (2010), é necessário que o produtor conheça os “caminhos” que seu produto percorre, suas tendências e a evolução dos produtos derivados de seu processamento. Assim, a visão sistêmica das cadeias produtivas, inserida dentro da propriedade rural é decisiva para o sucesso do empreendimento.

Diante de um ambiente complexo, as organizações procuram estruturar-se e estabilizar-se para que suas decisões possam trazer benefícios e minimização das incertezas. Esta dinâmica estrutural também é observada nas organizações agropecuárias, em decorrência dos desafios gerados pela

economia globalizada (Boehlje, 1999).

A empresa rural possui características singulares que as diferenciam das demais, como, por exemplo, a dependência do tempo em seus processos biológicos, as influências climáticas e o alto custo de decisões deturpadas (Ferreira, 1997; Nuthall, 2012). Essas características tão peculiares reforçam a necessidade de uma gerência diferenciada que se aproxime, portanto, dos princípios de uma administração estratégica (Gouttenoire et al., 2011). O processo torna-se ainda mais complexo, quando observamos que as decisões neste setor são tomadas tanto pelo produtor, como por sua esposa, filhos e sucessores, possuindo assim um caráter participativo, principalmente no que tange ao conceito de empresa familiar (Machum, 2005).

A essência do planejamento, controle e contingência é a tomada de decisões. Esta, por sua vez, depende de informações oportunas, de conteúdo adequado e confiável. Isso pressupõe certo grau de consciência por parte dos executivos sobre os processos decisórios em que estão envolvidos e o desenvolvimento de um sistema de informação sintonizado com as necessidades de informação desses processos decisórios (Simon, 1955). A maioria das decisões tomadas pelos produtores e administradores rurais, ainda são baseadas em regras empíricas, com pouco fundamento econômico racional quantitativo (Sørensen et al., 2011). Este método simples de decisão não permite a realização de simulações com grau de precisão considerado satisfatório, proporcionando resultados inviáveis à produção (Zott et al., 2011).

O uso da análise sistêmica no estudo da gestão de propriedades rurais tem como finalidade elucidar que a coerência de um sistema de

produção agropecuária qualquer, se refere, antes de tudo, à visão do produtor sobre sua situação (Ferreira, 1997; Musshoff & Hirschauer, 2007). As bases do pensamento sistêmico consistem em compreender a complexidade do processo produtivo (Senge et al., 2007). Assim, o produtor deve visualizar sua propriedade como um processo composto por entradas, saídas e sistemas de retroalimentação (*feedbacks*), inserido em um ambiente que condiciona seu funcionamento (Figura 1).

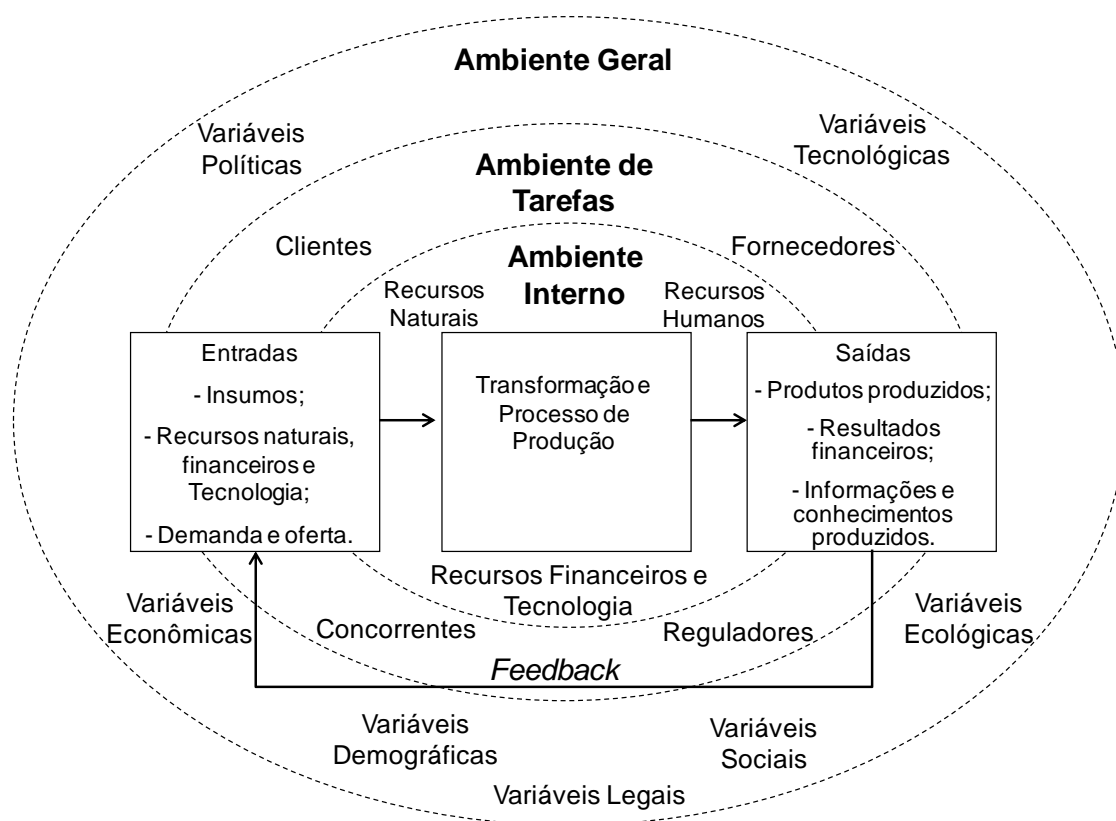


Figura 1. Visão sistêmica do processo de produção em uma propriedade rural (Adaptado de Muniz & Faria, 2001; Romeiro, 2002; Serman, 2000).

Na Figura 1, as entradas (*inputs*) são os elementos ou recursos físicos e abstratos que compõem os sistemas, incluindo as influências do meio no qual o sistema está inserido. No caso da propriedade rural, as entradas

compreendem os recursos naturais, humanos, financeiros, de infra-estrutura e informações sobre a demanda e oferta de produtos. Os processos de transformação interligam os componentes e transformam os elementos de entrada em resultados (Romeiro, 2002). Utilizando este conceito para a propriedade rural, os processos consistem na forma como o produtor “transforma” seus recursos em produto.

As saídas (*outputs*) são os resultados do sistema, ou seja, os objetivos almeçados ou efetivamente atingidos pelo sistema. E, finalmente, o *feedback* compara as saídas com as entradas, numa tentativa de controle ou reforço do processo produtivo (Muniz & Faria, 2001).

Diante de tamanha complexidade, o agente tomador de decisão, deve ser capaz de separar, claramente, os objetivos reais de produção dos objetivos de desenvolvimento político e social do sistema (Janssen & van Ittersum, 2007). A racionalidade está interligada às inúmeras alternativas comportamentais existentes, que variam de consciente a inconsciente, de forma específica e limitada ao ambiente ou situação onde a decisão é tomada (Simon, 1955), pois mesmo operando em um nível satisfatório de informações, as decisões agropecuárias contemplam elementos de difícil previsibilidade.

Segundo French et al. (2011), as decisões na agropecuária são norteadas pela produção com base em objetivos estratégicos ou critérios de racionalidade, com intuito de minimização dos riscos bioclimáticos e de mercado, garantia de segurança alimentar e emprego da mão de obra familiar já existente na propriedade, redução dos custos totais, em especial da produção, e investimento na melhoria nas condições de trabalho e produção.

No entanto, mesmo que o produtor possua conhecimento de sua realidade agrícola e pecuária, sua racionalidade baseada apenas na prática cotidiana conduz a decisões puramente empíricas (Machum, 2005; Sørensen et al., 2011). Assim, nem sempre a tomada de decisão é realizada de forma estruturada, lógica e coerente com a realidade macro e microeconômica (Nuthall, 2012).

Neste sentido, o surgimento de sistemas capazes de fornecer subsídios concretos, favoráveis à tomada de decisão é necessário para a otimização e difusão do uso de métodos flexíveis de organização e análise da informação (Zott et al., 2011), permitindo ao produtor a manipulação de elementos chave dentro do seu sistema.

2.2 Dinâmica de sistemas

A teoria que embasa a dinâmica de sistemas (DS) considera que todo sistema, não importa quão complexo seja, consiste em uma rede de retroalimentação positiva e negativa, cuja dinâmica de funcionamento, inicia-se com a interação entre *feedbacks* (Sterman, 2000; 2001). Além disso, a metodologia DS busca a melhoria da aprendizagem dos sistemas complexos, por meio do mapeamento de estruturas de sistemas organizacionais, analisando a inter-relação de suas forças, e entendendo como estes sistemas evoluem ao longo do tempo (Sterman, 2006).

A modelagem utilizando a DS permite facilmente representar por meio de estoques, fluxos e retroalimentações, um conjunto de elementos interconectados e suas relações, apresentando elementos, variáveis chave e

relações de forma mais realista que outras técnicas de modelagem (Nazemi, 2012).

Quando se combina dados produtivos e econômicos, com resultados, extrai-se uma infinidade de relações entre variáveis e repostas inesperadas de interações (Drack & Schwarz, 2010), possibilitando identificar *feedbacks* essenciais para modelagem da estrutura do sistema e facilitar a tomada de decisão. A Figura 2 apresenta a exemplificação do processo de modelagem dentro do conceito de DS.

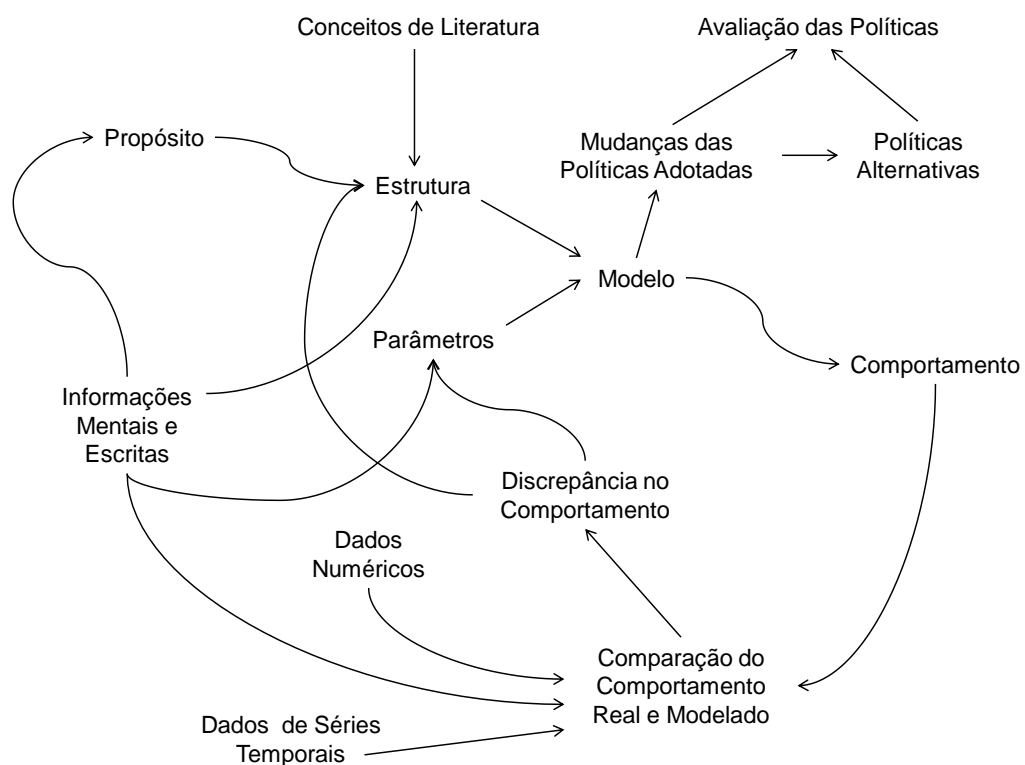


Figura 2. Processo de modelagem utilizando a dinâmica de sistemas (Adaptado de Sterman, 2000).

A Figura 2 demonstra que a partir de informações formais ou informais, é possível criar uma estrutura com parâmetros determinados, para a

construção da modelagem. Essas informações são importantes para se comparar o comportamento modelado ao mundo real, juntamente com dados numéricos variados e séries temporais (Buonomano et al., 2012), servindo de suporte às decisões de cunho estratégico.

Segundo Sterman (2000), do ponto de vista da utilização da DS no contexto dos negócios (*business dynamics*), três aplicações principais se fazem presentes: (i) investigação e solução de problemas; (ii) projeto de soluções; e (iii) laboratórios de aprendizagem. Em todas as situações citadas, o objetivo principal é a explicitação de modelos mentais e sua utilização como ferramentas de exploração dos contextos onde é necessário o entendimento da dinâmica de estruturas organizacionais (Nazemi, 2012).

De forma mais específica a DS, busca a compreensão da estrutura e do comportamento dos sistemas compostos por enlaces de *feedback*, utilizando dois tipos de notação: (i) diagramas de enlace causal (modelagem *soft*); e (ii) diagramas de estoque e fluxo (modelagem *hard*) (Sterman, 2000; 2001).

A idéia associada à modelagem *soft*, refere-se a abordagens conceituais que buscam maior realismo, pluralismo e uma intervenção mais holística que a modelagem *hard*. Os conceitos *soft* e *hard* também são comumente relacionados, respectivamente, às idéias de qualitativo e quantitativo (Maani & Cavana, 2000). As diferenças entre ambas as abordagens estão descritas na Tabela 1.

Na DS, ao modelar sistemas deve-se utilizar preliminarmente modelos *soft*, apropriados para o entendimento amplo, proporcionando uma

ligação útil entre a descrição verbal e sua representação em modelos computacionais. Os modelos *soft*, com seus diagramas de enlace causal, apresentam todas as ligações relevantes de causa e efeito dos fenômenos, indicando a direção destes acontecimentos através de setas e relações de retroalimentação com as respectivas polaridades (Wolfslehner & Vacik, 2011). Assim, uma retroalimentação (*feedback* ou *loop*) existe sempre que uma ação provoca conseqüências que vão influenciar a ação inicial. Estas conseqüências podem ocorrer de forma rápida e direta, causando efeitos facilmente atribuíveis à causa, ou ainda, podem ocorrer de forma indireta, no longo prazo (atrasos ou *delays*) e com resultados menos perceptíveis (Sterman, 2000). Quanto mais longo o prazo para ocorrer o *loop*, e menos diretas as conseqüências, maiores serão as dificuldades para que os agentes envolvidos, afetados ou interessados na situação sistêmica em foco identifiquem as estruturas de retroalimentação (Lyneis, 2011).

Tabela 1. Diferenças entre as modelagens *soft* e *hard* (Maani & Cavana, 2000)

Variáveis	<i>Soft</i>	<i>Hard</i>
Definição do modelo	Debates sobre a realidade	Representação da realidade
Definição do problema	Objetivos diversos	Objetivo específico
Agentes e organizações	Partes integrantes do modelo	Não considerados
Dados e informações	Qualitativos	Quantitativos
Objetivos	<i>Insights</i> e aprendizagem	Soluções e otimizações
Resultados	Aprendizado em grupo	Recomendações

Os diagramas de causa-efeito são empregados visando descrever possíveis cenários de negócios, com o objetivo de mostrar a relação de influências existentes entre as variáveis componentes do sistema, fundamentadas no conhecimento especialista dos agentes, o que atribui

confiança à interpretação global do processo administrativo, e conseqüente suporte à decisão coletiva. Apenas desta forma, o modelo de DS poderá ser considerado válido (Wolfslehner & Vacik, 2011).

Diagramas de enlace causal possuem duas importantes funções: (i) servir como esboço de hipóteses causais; e (ii) simplificar a estrutura do modelo. Em ambos os casos, os diagramas permitem ao pesquisador, comunicar os pressupostos iniciais do modelo (Sterman, 2006). Embora de grande utilidade nos processos iniciais de modelagem dos sistemas, os diagramas de enlace causal não são totalmente apropriados para a simulação computacional do comportamento das estruturas e processos sistêmicos ao longo do tempo, pois possuem limitações para simular situações futuras. Para construir um modelo mais adequado à simulação, nesta situação, utilizamos os diagramas de estoque e fluxo (*hard*). A abordagem quantitativa da modelagem *hard*, permite explorar a evolução de um sistema ao longo do tempo e dentro de um período de interesse (Lyneis, 2011).

Em um diagrama de estoque e fluxo, a estrutura do sistema é representada matematicamente, permitindo quantificar as relações causais entre os elementos do sistema. Na perspectiva da DS, qualquer sistema, natural ou artificial pode ser descrito em um diagrama de estoque e fluxo, através de uma linguagem composta por quatro elementos chave: (i) estoques (*stocks* ou níveis); (ii) fluxos (*flows*); (iii) auxiliares (conversores e constantes); e (iv) conectores (*links* de informação; Weil, 2007).

A possibilidade de criação de modelos computacionais mais complexos e com inúmeros cálculos simultâneos reforçam a utilização da

metodologia DS (Forrester, 1992). No caso da agropecuária, o entendimento sistêmico do processo produtivo, fazendo-se uso apenas de modelos estáticos seria impossível, pois algumas variáveis devem sofrer modificações no momento presente e suas mudanças apenas são percebidas algum tempo depois (*delay*) ou dependendo da interação, as variáveis provocam um *feedback* inesperado, potencializando ou prejudicando o objetivo inicial da alteração (Pang et al., 1999).


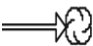
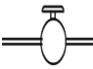


Diante de tamanha complexidade, deve-se atentar para os *softwares* que utilizam a metodologia DS, pois com inúmeras vantagens para o entendimento da organização dos sistemas, os *softwares* podem criar uma falsa impressão de simplificação dos processos, superestimando suas reais habilidades, sem verdadeiramente entender o real paradigma da ciência nesta área.

No mercado, existem inúmeros *softwares* disponíveis, entre os quais, destacam-se: Vensim®, Stella®, Powersim® e iThink®. Embora todos os *softwares* citados utilizem as principais ferramentas da DS, alguns apresentam particularidades de uso, quanto à construção de modelos e estruturas. Para elucidar as principais notações utilizadas por estes programas na construção de modelos a Tabela 2 apresenta algumas ferramentas e representações dos conceitos da DS na visão didática dos *softwares*.

A DS busca entender a evolução de um sistema ao longo do tempo, usando uma linguagem própria para modelagem e experimentação. Os elementos que determinam essa dinâmica, conforme já citados anteriormente, são processos de retroalimentação (enlaces, *feedbacks* ou *loops*), estruturas

de estoque e fluxo, atrasos de tempo (*time delay* ou *delay*) e não-linearidade (Forrester, 1992), cada um destes elementos será detalhado a seguir.

Tabela 2. Principais notações utilizadas em *softwares* de dinâmica de sistemas para construção de diagramas e estruturação de modelos (Adaptado de Sterman, 2000)

Notações	Objetivos	Exemplos
Estoques 	Acumular (armazenar) informações	Número de animais em cada categoria animal
Fluxos 	Conectar os estoques ou introduzir variáveis	Troca de animais entre categorias (evolução do rebanho)
Taxas de Fluxos 	Controlar os sistemas, diminuindo ou aumentando a velocidade dos fluxos	Condição para que os animais troquem de categoria
Conectores 	Carregar informações de um elemento para outro	Consumo animal/dia (quantidade)
Variáveis Auxiliares 	Armazenar, manipular ou converter dados de entrada	Taxa de manutenção

2.2.1 Sistemas de retroalimentação (enlaces, *feedbacks* ou *loops*)

Os sistemas complexos no mundo real são altamente interconectados, e apresentam um elevado grau de retroalimentação entre os elementos do sistema. Entretanto, alguns modelos não refletem essa realidade e podem, com o tempo, gerar resultados de efeitos colaterais ou atrasos não estabelecidos pelo modelo (Lyneis, 2011).

Os sistemas de retroalimentação são relações causais ou enlaces entre as variáveis ou componentes do sistema, representados por um conjunto

circular de efeitos interconectados (Radzicki, 2003), definindo assim, que a perturbação em um elemento causa como resposta uma variação nele próprio ou nos demais (Sterman, 2000).

Os sistemas podem ser classificados como abertos ou fechados. Um sistema aberto é caracterizado por um fluxo de saída que responde apenas a um fluxo de entrada, sem interferências. O sistema aberto não sofre alterações nem reage a estímulos de seu próprio desempenho, ou seja, as ações passadas não controlam ações ou reações futuras. Já os sistemas fechados sofrem ação de *feedback* e seu próprio desempenho interfere nos resultados futuros (Weil, 2007).

Tradicionalmente, os sistemas que utilizam a DS apresentam dois tipos de processos de *feedback* (Figura 3): (i) negativos (ou de balanço ou de equilíbrio); e (ii) positivos (ou de reforço). Nos *feedbacks* negativos, as mudanças em algum elemento conduzem a uma resposta oposta, em relação à mudança original, criando um ciclo de estabilidade. Enquanto nos *feedbacks* positivos, as alterações em um componente geram alterações em outro, reforçando o processo original e obrigando o sistema a modificar seu equilíbrio (Forrester, 1992; Sterman, 2006).

Conforme ilustrado na Figura 3, quando existem diferenças entre o estado atual e estado desejado, a retroalimentação negativa promove ações de influência nas políticas do sistema, objetivando a diminuição ou eliminação destas diferenças. A retroalimentação negativa poderá produzir ainda uma reação de estabilidade contra choques externos, proporcionando a eliminação das discrepâncias de forma branda, dentro de um determinado período de

tempo. Todavia, a menos que as políticas sejam adequadamente projetadas em relação às consequências no sistema, o processo de causa e efeito pode não ter sucesso, gerando uma discrepância que pode oscilar entre níveis muito altos e muito baixos (Wolfslehner & Vacik, 2011).




Figura 3. Relações de causa e efeito (retroalimentação positiva e negativa) em sistemas complexos (Adaptado de Sterman, 2000; 2006).

Por outro lado, a retroalimentação positiva opera como um mecanismo gerador de crescimento, onde o estado do sistema cresce continuamente, sendo chamado de círculo virtuoso (Nazemi, 2012).

Os *feedbacks* positivos apresentam comportamento previsível, pois suas variáveis atuam reforçando ou acelerando a mudança inicial, e apresentam comportamento exponencial (crescente ou decrescente). O comportamento exponencial ocorrerá indefinidamente, exceto em casos de colapso ou de introdução de restrições de interação com outros sistemas de retroalimentação ou variáveis exógenas (Kim & Senge, 1994; Senge et al., 2007).

Os *feedbacks* negativos apresentam maior variedade de possibilidades de comportamento, quando comparados aos positivos. A retroalimentação negativa se resume na tentativa de atingir um objetivo e caso

ocorram forças de desvio do sistema da meta pretendida, ele responderá buscando pela estabilização, de forma a conter a direção inicial de mudança das variáveis (Senge et al., 2007).

Analisar os *feedbacks* entre diferentes sistemas é uma forma de entender a estrutura e o comportamento de distintas e complexas organizações de dados. Entretanto, entender o comportamento de um sistema é uma tarefa árdua, pois a tendência é que o número de subsistemas e suas inter-relações aumente consideravelmente dentro da escala de tempo, criando assim uma complexidade dinâmica, que envolverá além dos *feedbacks*, estoques e fluxos, como descrito a seguir.

2.2.2 Estoques e fluxos

Para a DS, qualquer organização, por mais complexa que seja, pode ser descrita através de esquemas de estoques ou níveis e fluxos ou taxas, classicamente denominados Diagramas de Forrester (Figura 4; Forrester, 1992; Senge & Sterman, 1992). Estoque é uma simbologia para tudo que se acumula ou se esgota, enquanto o fluxo corresponde às mudanças que ocorrem nos estoques durante um determinado período de tempo (Nazemi, 2012). Essa dinâmica pode ser descrita utilizando-se a “analogia da banheira”, onde o fluxo de entrada de água é representado pela torneira, o estoque pela água acumulada ou presente na banheira e, por fim, o ralo corresponde ao fluxo de saída (Sterman, 2000).

Os estoques asseguram o quadro instantâneo da realidade, descrevendo, portanto, a condição e estruturação atual do sistema. Segundo

Radzicki (2003), os estoques possuem quatro características básicas de determinação do comportamento dinâmico dos sistemas: (i) memória; (ii) padrão de acumulação (linear constante, linear crescente e decrescente, negativo linear crescente e decrescente, crescimento exponencial e irregular oscilante); (iii) separação ou interrupção de taxas, permitindo que os fluxos sejam controlados por diferentes fontes de informação; e (iv) criação de atrasos. Dentre essas características, a criação de atrasos merece destaque.

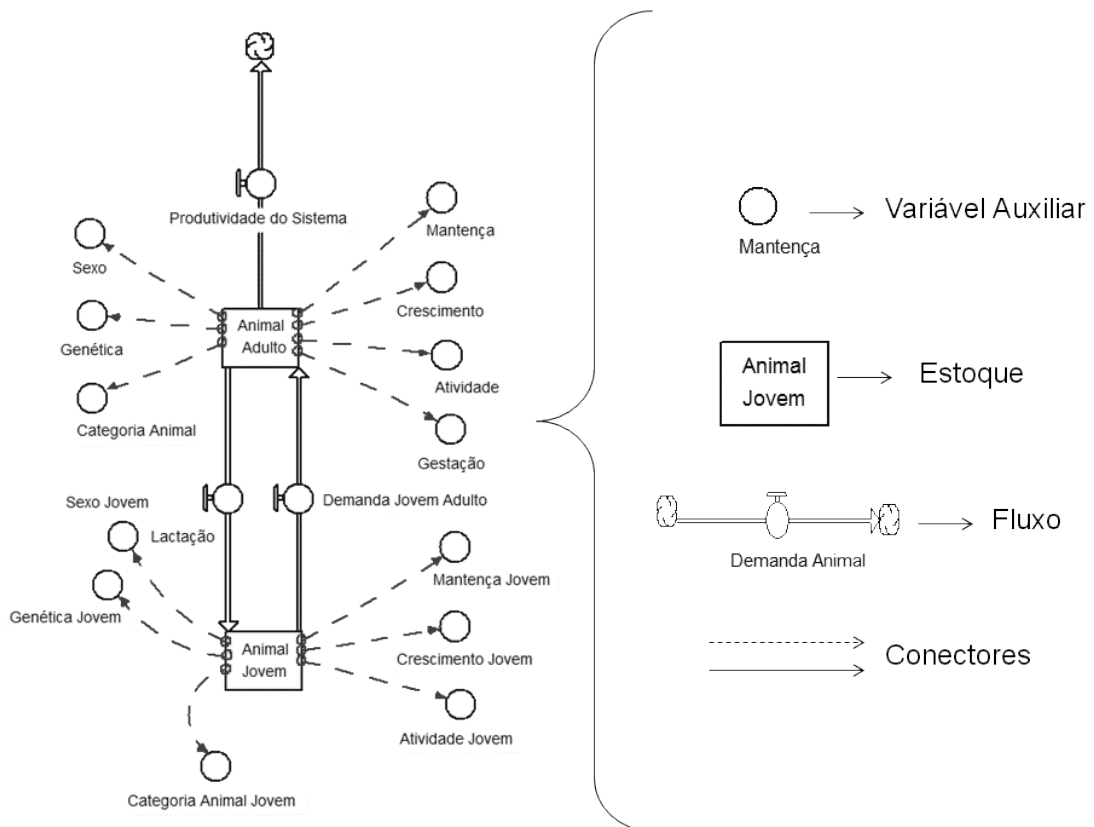


Figura 4. Diagrama de Forrester (Original da autora).

O atraso sempre estará presente em qualquer mudança de estoque. Ainda que um estoque esteja aparentemente inalterado, mudanças insignificantes, desprezíveis ou imperceptíveis à nossa percepção podem estar

ocorrendo (Sterman, 2006). Na DS a identificação de padrões de atrasos é primordial para o entendimento do comportamento dinâmico dos sistemas (Radzicki, 2003).

Além do atraso, o fluxo é fundamental para o entendimento do comportamento dos estoques e, por consequência, da dinâmica dos sistemas. Os fluxos representam a atividade do sistema e são dependentes da quantidade e dos valores dos estoques, sendo sua unidade de medida idêntica à unidade do estoque em que está conectado, considerando também a variável tempo (Wolfslehner & Vacik, 2011; Kim & Senge, 1994).

Os estoques acumulam ou integram os fluxos, correspondendo, portanto, a soma das taxas de entrada e saída e representadas matematicamente pela equação (Ragni et al., 2011):

$$\text{Estoque}(t) = \int_{t_0}^t [\text{Entrada}(t_i) - \text{Saída}(t_i)] ds + \text{Estoque}(t_0) \quad (1)$$

Onde as entradas (t_i) representam os valores entre o tempo inicial (t_0) e o tempo corrente (t). De forma equivalente, a taxa de mudança líquida do estoque pode ser calculada como sendo a diferença entre os fluxos de entrada e saída, definida pela equação diferencial (Ragni et al., 2011):

$$\frac{d(\text{Estoque})}{dt} = \Delta \text{Estoque} = \text{Entrada}(t) - \text{Saída}(t) \quad (2)$$

Por fim, a DS também utiliza variáveis auxiliares e conectores ou

links de informação, que processam os dados dos estoques e fluxos e representam fontes de informações exógenas (Sterman, 2000). Os conectores são utilizados para estabelecer as relações existentes entre as variáveis do modelo, transportando informações de um elemento ao outro, tais como quantidades, valores constantes, valores algébricos e gráficos. As variáveis auxiliares por sua vez, armazenam valores constantes, manipulam e convertem dados de entrada, através de cálculos secundários e equações, em valores de saída para utilização em outra variável (Richardson, 2011).

2.2.3 Atrasos (*delays*)

Os atrasos ou *delays* referem-se à defasagem de tempo necessário para que uma variável afete a outra. A incorporação do fator atraso torna-se necessária uma vez que, no mundo real, a transferência de informações entre fluxos dentro de um sistema de produção sofre variações no tempo, tanto de envio quanto de resposta (Ragni et al., 2011).

Os atrasos constituem uma das fontes mais importantes de dinamismo e instabilidade dos sistemas. Sempre existirá um período de tempo entre mensurar, relatar, inserir a informação no sistema, tomar a decisão e perceber os resultados e consequências desta ação. Assim, atraso é o tempo necessário para uma ação gerar efeito no sistema, ou seja, a resposta de uma entrada necessita de algum tempo para que seja visualizado seu resultado ou saída (Senge & Sterman, 1992).

Os atrasos podem ser classificados em materiais ou informacionais. Os atrasos materiais são estoques físicos e seus acúmulos são mensurados

em unidades (Richardson, 2011). Já os atrasos informacionais são baseados em crenças e percepções, e representam o atraso entre a chegada de uma nova informação e atualização das crenças pessoais (Sterman, 2006). Ambos os atrasos possuem distintas formas de modelagem e serão descritos a seguir.

2.2.3.1 Atrasos materiais

Os atrasos materiais são representados por estruturas de estoque e fluxo, representando o tempo necessário para que um objeto ou conjunto de elementos seja transferido de uma etapa à outra dentro do sistema (Buonomano et al., 2012; Weil, 2007). De forma exemplificada, na presente tese, para os animais transcenderem a condição de jovens e ingressarem na categoria de adultos, deverá ser transcorrido um período de tempo de crescimento determinado pela idade alvo para que se atinja a maturidade, gerado assim um atraso no fluxo constante de animais.

Os atrasos materiais podem ser classificados em três tipos básicos: (i) *pipeline*; (ii) de primeira ordem; e (iii) de alta ordem (ou de ordem maior) (Sterman, 2000). Atrasos do tipo *pipeline* possuem tempo de processamento constante e ordem de saída de estoque idêntica à ordem de chegada, e a taxa de saída é determinada exclusivamente pelo tempo de atraso (Li & Yang, 2012).

Os atrasos de primeira ordem por sua vez, são aqueles cuja ordem de saída do estoque é dependente da quantidade de material “em trânsito” e distinta da ordem de entrada (Senge & Sterman, 1992). Já nos atrasos de alta ordem, não existe apenas um estoque e sim, um conjunto de estoques “em

“cascata”, com distribuições de saída e atraso específicas. Os atrasos de alta ordem são representados por situações onde existem vários estágios de processamento, com atrasos de primeira, segunda, terceira e subsequentes ordens (Li & Yang, 2012).

2.2.3.2 Atrasos informacionais

Alguns atrasos estão vinculados à retroalimentação de informação na percepção de uma variável ou atualização de uma resposta. Consome-se tempo para reunir informações necessárias para a discussão de um assunto, e a mudança de opinião dos indivíduos não ocorre imediatamente após o recebimento de uma informação. Logo, considera-se que reflexões e deliberações necessitam de um período de tempo para serem executadas. Um atraso informacional consiste em ajustar gradativamente um conceito ou o valor real variável (Richardson, 2011).

Uma das formas de modelar o atraso informacional é denominada expectativa adaptável (*exponential smoothing*) ou atrasos informacionais de primeira ordem (Sterman, 2000). Neste tipo de atraso, quando ocorre uma mudança em alguma variável, nossa crença em relação ao valor dessa variável ajusta-se gradualmente até atingir o valor real (Sterman, 2006). A Figura 5 apresenta a estrutura de retroalimentação com expectativa adaptativa, onde o valor de “ x ” corresponde ao estoque.

A taxa de mudança é proporcional à diferença existente entre o valor real e o valor percebido de “ x ”, pelo tempo de ajuste (D), que é o responsável por determinar a rapidez com que as mudanças são aceitas pelo modelo. A

taxa de mudança no valor percebido é representada pela seguinte equação (Serman, 2000):

$$\text{Mudança Valor Percebido} = \frac{(\text{Valor Percebido} - \text{Valor Real})}{D} \quad (3)$$

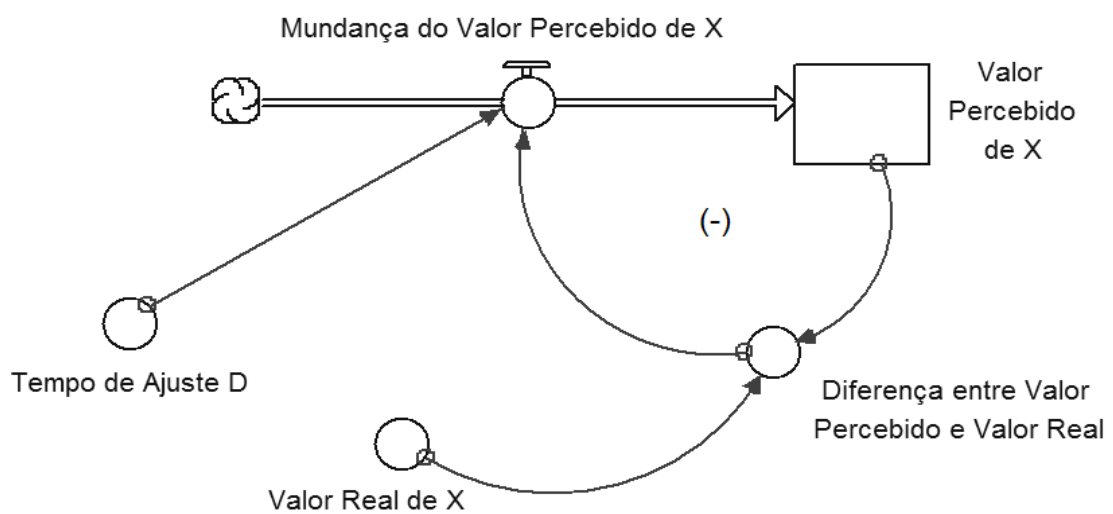


Figura 5. Estrutura de retroalimentação de expectativas adaptativas (Adaptado de Serman, 2000).

Um modelo mais complexo de atraso informacional é denominado atraso informacional de alta ordem (ou de ordem maior). Diferentemente do atraso de primeira ordem, onde as respostas às mudanças nos valores de entrada se dão de forma imediata, no atraso de alta ordem a resposta inicial é pouco significativa, posteriormente atinge um pico e decresce no estágio final (Li & Yang, 2012). Isso ocorre porque a informação é recebida por meio de vários estágios de mensuração e comunicação (Richardson, 2011). A estruturação do atraso informacional de alta ordem é demonstrada na Figura 6.

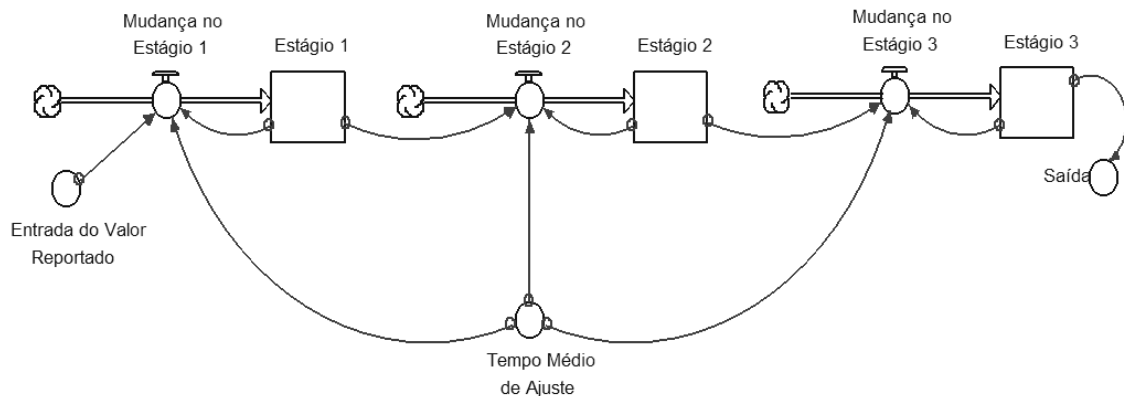


Figura 6. Estrutura de atraso informacional de alta ordem (Adaptado de Sterman, 2000).

Além dos atrasos, outro aspecto fundamental para determinação do comportamento, instabilidade e dinamismo dos sistemas é conceito de não-linearidade, como será apresentado a seguir.

2.2.4 Não-linearidade

Outro conceito de extrema relevância na DS é não-linearidade. Segundo Guastello (2007), um sistema linear é representado pela equação:

$$\dot{X} = Ax \quad (4)$$

Onde “ x ” representa o vetor dos estados e A corresponde à matriz Jacobiana dos estados. Na presença de um distúrbio externo $u(t)$, o sistema apresenta a seguinte forma:

$$\dot{X} = Ax + Bu \quad (5)$$

A principal característica de um sistema linear é o princípio de

superposição, isto é, o retorno da função linear aplicada a um conjunto de elementos é igual à soma do retorno da função aplicada a cada elemento isolado (Sterman, 2000):

$$f(ax + by) = a f(x) + b f(y) \quad (6)$$

Os sistemas lineares apresentam apenas um ponto de equilíbrio e os fluxos de entrada são sempre somas ponderadas das variáveis de estoque e variáveis exógenas, assim, qualquer outra forma de fluxo de entrada será não linear. Em sistemas não-lineares a variação dos estados, bem como das saídas, não apresentam dependência linear em relação aos estados (x) e entradas (u), gerando diferentes ganhos e dinâmicas para pontos de operação distintos. Logo, define-se como grau de não-linearidade, a não-linearidade observada entre as entradas e saídas de um dado processo (Lichtenstein, 2000).

2.3 Modelagem e simulação nos processos de decisão: vantagens e desvantagens

Para Huryk (2012) os sistemas de apoio à decisão (SAD) são sistemas computacionais que auxiliam os decisores a enfrentar problemas não-estruturados através da interação direta com modelos de dados e análises. Entretanto, os modelos ou simulações provenientes dos SAD's não decidem. Através de modelagens de situações do mundo real estes sistemas processam dados fornecidos e devolvem informações que apenas facilitam a tomada de decisão do usuário. Várias são as características que um SAD deve possuir. A

Tabela 3 apresenta as principais características dos SAD's.

Deve-se destacar que os SAD's não substituem o julgamento de especialistas humanos e visam contribuir para o aumento da qualidade das decisões tomadas em ambientes complexos (French et al., 2011)

Tabela 3. Características dos sistemas de apoio à decisão (SAD; Huryk, 2012)

Fatores	SAD
Foco central	Apoio e implantação da decisão
Horizonte de tempo	Presente e futuro
Ênfase do projeto	Flexibilização e utilização <i>ad hoc</i>
Palavras-chave	Interação, apoio, suporte e aprendizagem
Tipos de análise	Banco de dados e modelos
Avaliação do sistema	Satisfação e melhoria na tomada de decisão
Orientação das saídas	Planejamento, modelos de previsão e simulação
Formatos das saídas	Gráficos, planilhas e sumários
Tipo de projetos	Projeto adaptativo e interativo
Flexibilidade	Maleáveis e receptivos às mudanças no ambiente
Grupo alvo	Apoio à decisão em todos os níveis
Dados utilizados	Internos e externos de inúmeras fontes
Modelos utilizados	Matemáticos, estatísticos e financeiros

Os modelos, como um dos principais elementos constituintes dos SAD's, devem ser entendidos como uma representação explícita de parte da realidade, com a finalidade de compreendê-la, gerenciá-la e controlá-la (Jakku & Thorburn, 2010). Portanto, um modelo sempre será uma representação simplificada do mundo real, cujo intuito é descrever um problema específico, e são essas simplificações que os tornam passíveis de serem utilizados no apoio à decisão (Senge & Sterman, 1992). Os modelos de tomada de decisão devem descrever, representar ou imitar os fenômenos ou processos que ocorrem no mundo real, estabelecendo o relacionamento das variáveis com os objetivos, em nível satisfatório, respeitando as limitações de custo e tempo (Musshoff & Hirschauer, 2007).

Segundo Zott et al. (2011), pode-se apontar como aspectos positivos da modelagem: (i) fazer previsões de interesse particular visando nortear tomadas de decisão e operar um sistema de produção; (ii) identificar lacunas do conhecimento; (iii) nortear a pesquisa, através do rastreamento fornecido pela composição do modelo; e (iv) fornecer subsídios para estudos mais amplos e complexos. Assim, inúmeras vantagens podem ser obtidas com o uso de modelos bem elaborados, que resumam convenientemente uma gama de informações capazes de gerar progressos no conhecimento do sistema de produção, além de elucidar pontos obscuros.

No entanto, os modelos não podem ser encarados como um objetivo final de pesquisa ou de qualquer necessidade produtiva, e nem tampouco como “ferramenta pronta”, visto que são previamente concebidos, compostos por diversos elementos e expressam a extrema necessidade de melhoria e adaptação contínua (Ferreira, 1997; Magne et al., 2010). Outro ponto é o fato dos modelos não prescindirem de exatidão para serem utilizados, pois é a aproximação da realidade que os torna aplicáveis (Senge et al., 2007). Algumas diferenças importantes entre os modelos e a realidade são apresentadas na Tabela 4.

Tabela 4. Realidade *versus* modelo (Sterman, 2000)

Realidade	Modelo
Complexa	Simple
Subjetiva	Concreto
Mal definida	Totalmente definido

A modelagem matemática tem sido desde seus primórdios, ligada à teoria de sistemas e muitas vezes os termos são utilizados indistintamente. O

cerne da teoria de sistemas é o conceito de que a resposta do sistema a um estímulo não é igual ao resultado da resposta de cada um de seus componentes (Drack & Schwarz, 2010).

As interações dinâmicas entre os componentes do sistema são os determinantes primários de seu comportamento final (Kaine & Cowan, 2011). Desta forma, estudos isolados de componentes do sistema são inadequados para previsão das respostas do sistema como um todo.

A utilização de modelos para o processo de tomada de decisão proporciona aumento das chances de solução para os problemas levantados. Entretanto, não há garantia de sucesso da decisão, uma vez que existe a possibilidade do agente não identificar a totalidade de alternativas para resolução das incógnitas administrativas da propriedade, bem como ter certeza quanto aos resultados advindos da implantação de qualquer uma delas, devido ao alto grau de incerteza do processo (Gouttenoire et al., 2011; Simon, 1955).

Em modelos orientados ao gerenciamento, maior ênfase é dada às técnicas de análise de decisão em detrimento da representação minuciosa dos processos. Assim, considera-se que modelos matemáticos, como tecnologia de apoio à tomada de decisão, necessitam simular apenas processos relevantes às respostas do sistema às variáveis de controle consideradas como de maior importância (Annets & Ausdley, 2002).

A simplicidade é considerada uma virtude em modelagem matemática, porém a omissão de alguns processos do sistema pode mascarar aspectos primordiais do funcionamento dos sistemas (Janssen & van Ittersum, 2007). Segundo Plà (2007), os modelos matemáticos possuem duas fontes

principais de erros: (i) erros de estrutura, associados à escolha dos processos a serem considerados no modelo e como tais processos serão apresentados; e (ii) erros relacionados à parametrização, ou seja, ao valor dos parâmetros obtidos experimentalmente. O aumento da complexidade do modelo leva à redução do erro associado à estrutura do modelo, por ser mais realista na inclusão dos componentes e processos operacionais do sistema. Entretanto, o erro de parametrização aumenta em resposta à inclusão de novos parâmetros a serem estimados. Logo, um modelo deve ser, portanto, tão simples quanto possível e tão complexo quanto necessário para uma dada aplicação, de modo a atingir um balanço ótimo entre erros de estrutura e parâmetros (Huryk, 2012; Magne et al., 2010; Senge et al., 2007).

Entre os maiores desafios atuais na construção de modelos e simulações, além da correção das limitações já citadas, a aplicação de modelos dinâmicos merece destaque. A quase totalidade dos programas, utilizados em agropecuária (ou mesmo no contexto amplo do agronegócio) utiliza-se de critérios e variáveis “estáticas” para criação de planilhas ou linguagem de programação (Sørensen et al., 2011; Tanure & Nabinger, 2010). No contexto biológico, fica claro que esta abordagem além de limitada é errônea, pois a maioria dos processos ocorrem por meio da não-linearidade. Esses modelos assumem que o estado do sistema em um determinado ponto no tempo é suficiente para a predição de seu comportamento e que seus estados transitórios não influenciam os resultados, não necessitando, portanto, serem calculados. Assim, além de não representarem o sistema de forma correta e não permitirem adaptações ao meio onde deverão ser aplicados,

estes modelos traduzem respostas deturpadas aos agentes de decisão (Gouttenoire et al., 2011).

Outro desafio é a modelagem do comportamento humano na tomada de decisão. O conhecimento sobre as características “cognitivas” do tomador de decisão podem alterar a construção e a dinâmica de inúmeros programas propostos ao contexto do “agro”, tanto em âmbito técnico ou de políticas públicas (Nuthall, 2012). Na construção de um modelo de comportamento do tomador de decisão no agronegócio, podemos atentar para os seguintes aspectos: (i) a unidade de produção é assimilada como um sistema; (ii) são as decisões dos agentes do sistema que o fazem evoluir de um estado a outro; (iii) a ligação família-exploração tem influência determinante sobre o funcionamento da unidade de produção (questões relacionadas à sucessão do negócio são altamente relevantes no setor primário); e (iv) o conhecimento das possibilidades de evolução e reações futuras da unidade de produção necessitam de uma análise histórica (Austin et al., 1998; French et al., 2011). Assim, a utilização de trabalhos que abordem a modelagem do comportamento humano frente à tomada de decisão é imprescindível para a condução e o entendimento dos sistemas de produção do setor primário.

2.4 Modelagem e simulação bioeconômica em sistemas agropecuários

A modelagem de processos bioeconômicos é caracterizada por ter um alto nível de complexidade, isso pelo fato de todos os processos possuírem um comportamento dinâmico, onde as interações entre os parâmetros e as

variáveis que descrevem um processo, mudam de acordo com o tempo (Musshoff & Hirschauer, 2007). A principal dificuldade em se modelar e integrar um modelo biológico e econômico está na definição do foco para a modelagem e principalmente no nível de detalhamento que o modelo deve tratar (Mosnier et al., 2009).

A expressão bioeconômico é utilizada para expressar a relação entre os componentes biofísicos e econômicos de um sistema, sendo classificados de acordo com o uso ou não de um *framework* de otimização. Segundo Ritten et al. (2010), os modelos bioeconômicos classificam-se em:

(i) Modelos com *framework* de otimização: Utilizam técnicas de modelagem matemática, como a programação linear, não linear, dinâmica e estocástica para a minimização de uma função objetivo sob diferentes restrições. Frequentemente, estes modelos utilizam técnicas de programação linear, sendo esta abordagem altamente criticada na comunidade científica, haja vista o comportamento não linear das variáveis envolvidas nos modelos bioeconômicos;

(ii) Modelos sem *framework* de otimização: São componentes baseados em regras heurísticas para a solução de problemas específicos, qualidade dos componentes quanto à abstração de variáveis bioeconômicas e a interação entre eles, capazes de influenciar diretamente a qualidade final do modelo.

A integração de conceitos e conhecimento em programas computacionais, utilizando técnicas de simulação, pode melhorar a utilização das informações dirigidas ao manejo dos sistemas comerciais de produção

animal (Pang et al., 1999). Segundo Mosnier et al. (2009), a demanda crescente por mecanismos formais capazes de sintetizar as informações científicas, associada ao alto custo da experimentação física, tem estimulado muitos pesquisadores da área pecuária a adotar a simulação como instrumento de trabalho.

Plà (2007) descreve os quatro principais níveis de modelos utilizados nos sistemas agropecuários: bioquímicos/físicos, vegetal/animal, empresa agropecuária e empresa nacional/internacional, sendo quanto maior a área de atuação, maior o nível de resolução do sistema. A simulação em pecuária de corte tem sido utilizada em diferentes níveis de resolução (Rotz et al., 2005). Estes processos consideram o animal como sistema, uma categoria animal e o rebanho ou a propriedade/empresa rural, incluindo neste último nível os aspectos biológicos e econômicos do sistema pecuário. Assim, a modificação de um componente do sistema produtivo, permite avaliar a resposta dos indicadores de maior interesse nas empresas, dentre eles, a eficiência e a produtividade (Boehlje, 1999; Musshoff & Hirschauer, 2007).

Matthews et al. (2006) desenvolveram um modelo com o objetivo de avaliar opções de planejamento de propriedades pecuárias, onde pode ser incluído o conjunto da empresa ou as principais variáveis de interesse. A projeção histórica possibilita observar onde se apresentam os pontos de estrangulamento do sistema, representando uma melhor forma de planejamento do que a análise estática. Modelos deste tipo, conhecidos como DSS (*Decision Support System*), são basicamente empíricos, caracterizando-se por integrar componentes biológicos e econômicos, orientando o produtor na

tomada de decisões.

Outros exemplos de programas de suporte são: (i) “*Hot-Cross*” (Newman et al., 1997), desenvolvido para auxiliar o produtor na decisão sobre o melhor sistema de cruzamento genético para uma ampla variedade de ambientes produtivos na Austrália; (ii) “*Bo-Vision*” (Rollo et al., 1996), desenhado para orientar as decisões táticas e estratégicas nos sistemas de engorda sobre a lucratividade de diferentes políticas para comercialização de bovinos, a partir de informações do rebanho e das pastagens; e (iii) GAAT (*Granzingland Alternative Analysis Tool*; Kreuter et al., 1996), desenvolvido para estimar a eficiência econômica de uma ampla variedade de sistemas de produção pastoris.

A eficiência e produtividade de um sistema biológico são funções da relação *input* (entrada)/*output* (saída) dentro do sistema. Estas relações são oriundas dos processos biológicos que resultam da transformação dos *inputs* em *outputs*. As relações entre *inputs* e *outputs* variam entre os trabalhos, dependendo da fase do ciclo completo de produção pecuária avaliada. Os estudos revelam melhores valores de eficiência em sistemas exclusivamente terminadores (Williams et al., 1995), enquanto os valores intermediários são representados pelo ciclo completo (Davis et al., 1994). Os piores valores de eficiência são registrados, indiscutivelmente, pela fase de cria (Tess & Kolstad, 2000)

Na Venezuela, Nicholson et al. (1994) desenvolveram um modelo de programação linear para uma propriedade de ciclo completo, com o objetivo de avaliar através da maximização da margem líquida, três estratégias de manejo

nutricional para rebanhos de duplo propósito. Em Cuba, também utilizando simulações, as possibilidades econômicas de utilização do sistema de pastoreio “*Voisin*” consorciado a “bancos de proteína” com bovinos de corte, foram avaliadas por Cino & Valdes (1995).

Modelos capazes de descrever a produção animal em pastagens são altamente complexos, pois além de necessitarem de submodelos envolvendo as relações entre os processos vegetais e o meio, também são dependentes de modelos para descrever a fisiologia do animal em pastejo e a interação entre animal e pastagem (Cangiano et al., 1999; Machado et al., 2010). Para Nabinger & Carvalho (2009), pelo menos dois aspectos importantes emergem da interação das plantas com os animais. O primeiro é que os animais têm exigências quanto ao estado da forragem (disponibilidade, estrutura e qualidade), e demandam forragem em diferentes intensidades ao longo do ano. Assim, uma adequação entre produção e consumo de forragem se faz necessária, e, portanto, a estacionalidade da produção de forragem deve ser informada pelo usuário do programa ou estimada pelo modelo. O segundo aspecto, é que a pastagem, ao contrário das outras culturas, é sucessivamente submetida à desfolha pelos animais. Assim, o crescimento da planta é afetado pela remoção da área foliar, remoção ou não de pontos de crescimento, e mobilização e reconstituição de suas reservas orgânicas. Estes processos dependem fundamentalmente da severidade do pastejo e, conseqüentemente, do manejo realizado com os animais na pastagem (Wilman et al., 1996).

Diante das limitações de construção de programas capazes de descrever com alguma precisão a interação entre tipologia e qualidade de

consumo e ganho de peso, o modelo CONPAST 3.0 (Cangiano et al., 1999), desenvolvido na Argentina, em condições muito similares as do Rio Grande do Sul, propõe-se a prever o comportamento ingestivo de bovinos em pastoreio. O CONPAST 3.0 agrega quatro níveis de resolução, onde o primeiro consiste no bocado do animal, cujas dimensões são estimadas empiricamente. O segundo nível trata do comportamento ingestivo no horizonte de pastejo (independente da variável tempo), sendo o terceiro nível contemplado pelo comportamento ingestivo no período de 24 horas. Por fim, o último nível, avalia o comportamento ingestivo correspondente a sete dias (uma semana). A distinção deste modelo é a utilização de dimensões do bocado (área e profundidade), o que o torna muito confiável nas condições de pastagens naturais do Rio Grande do Sul, Uruguai e Argentina, no entanto, a dificuldade de mensurar o impacto da variável “estrutura do pasto”, ainda gera conflito entre as respostas do modelo e a realidade apresentada.

Mais recentemente, o uso de técnicas de otimização numérica para sistemas não lineares e descontínuos tem possibilitado estabelecer valores ótimos para as variáveis controláveis dentro do sistema que resultem em um ótimo global observando-se determinado critério (Nousiainen et al., 2011). Considera-se, conseqüentemente, de forma simultânea, variações na oferta ambiental, preços de insumos e produtos, bem como restrições de capital e outras variáveis de decisão como, por exemplo, épocas de compra e venda de animais, uso de suplementos e fertilizantes (Magne et al., 2010; Mosnier et al., 2009).

Além disso, um aspecto importante a serem considerados na adoção

de grandes modelos sistêmicos é a integração do conhecimento, que se dá na maioria dos casos através de sistemas computadorizados “amigáveis”. Quando se trata da operação integrada de *softwares*, trabalhos têm apontado que a alternativa prática para se sanar a falta de um sistema que realmente integre as ferramentas em um sistema complexo é trabalhar com um conjunto de diversos *softwares* independentes, cada qual responsável por parte da tentativa de solução do problema (Machado et al., 2010; Plà, 2007; Zott et al., 2011). Nestes casos, é visível a importância de um modelo de simulação trabalhando lado a lado com um sistema decisório baseado em regras (Ferreira, 1997). A partir da obtenção de dados sobre a condição de animais, pastagens e outros insumos (incluindo dados econômicos e financeiros) pode-se utilizar o modelo de simulação para projetar cenários, respondendo à questões colocadas pelo decisor, e obter resultados quali-quantitativos (Machado et al., 2010).

Conforme Moghaddam & DePuy (2011), a necessidade por sistemas produtivos eficientes e mais atrativos economicamente, gera maior objetividade na seleção dos problemas e nas suas inter-relações com as informações disponíveis. Portanto, na busca por uma pecuária mais competitiva e dinâmica tecnologicamente, a abordagem sistêmica e os modelos de simulação tornam-se instrumentos essenciais para avaliação de impactos ao processo produtivo.

3. QUESTÕES DE PESQUISA

- É possível simular o funcionamento de uma unidade de produção agropecuária real utilizando parâmetros meteorológicos, fisiológicos (animais e vegetais) e de solo, e projetar um “ambiente ideal de produção”, capaz de equilibrar questões econômicas e de sustentabilidade ambiental?

- Quais bancos de dados (biológicos, econômicos, comportamento humano ou dados intrínsecos do setor primário) ou características dos sistemas de produção no agronegócio necessitam maior desenvolvimento, pesquisa e exploração para facilitar a construção de modelos bioeconômicos (sistemas de informação) capazes de auxiliar o suporte à tomada de decisão pelo administrador ou produtor rural?

4. HIPÓTESES

- É possível simular o funcionamento dinâmico de unidades de produção agropecuária considerando além dos fatores biológicos e sazonais intrínsecos à produção primária, questões econômicas e mercadológicas de comercialização da produção;

- O modelo matemático gerado para construir cenários e distintos sistemas de produção agropecuários endereça novas ações e demandas para os administradores e produtores rurais, e para a pesquisa científica, em especial para as questões relacionadas à utilização de *softwares* para modelagem dinâmica.

5. OBJETIVO GERAL

- Elaborar um modelo bioeconômico de suporte à decisão em sistemas de produção de bovinos de corte, além de analisar o comportamento e o impacto econômico dos principais recursos biotecnológicos existentes nas unidades de produção agropecuária, identificando quais alternativas poderiam ser implantadas, a fim de gerar acréscimos de eficiência, e rentabilidade ao produtor, adaptação às exigências mercadológicas de comercialização de produtos e preservação ambiental.

5.1 Objetivos específicos

- Modelar distintos cenários de produção pecuária bovina de corte;
- Simular mudanças nos principais coeficientes técnicos;
- Verificar o impacto econômico, após a modificação dos coeficientes técnicos;
- Analisar a introdução de novas tecnologias, de forma a construir diferentes sistemas de produção (adaptáveis para realidades específicas) e projetar inúmeros cenários;
- Analisar a viabilidade da metodologia dinâmica de sistemas na modelagem de sistemas de exploração pecuária bovina.

Visando atingir os objetivos propostos, a presente pesquisa foi

estruturada conforme ilustrado pela Figura 7.

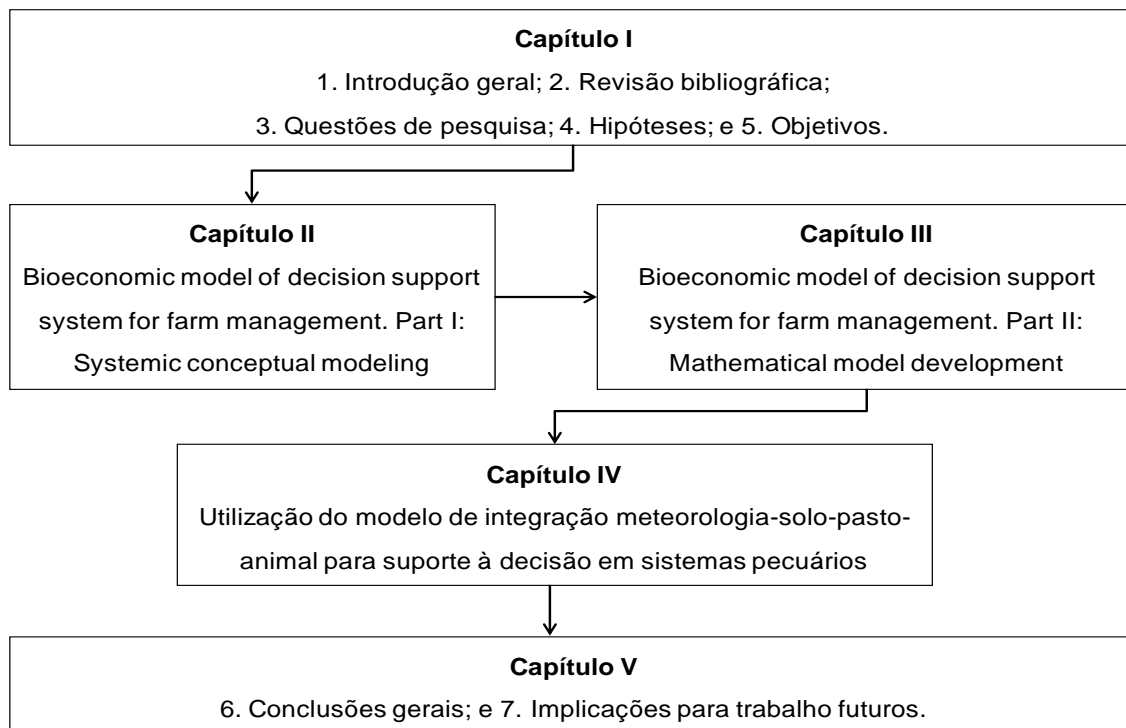


Figura 7. Estrutura organizacional da tese (Original da autora).

O primeiro capítulo da tese reúne as considerações iniciais sobre a modelagem de sistemas agropecuários, bem como a estruturação das questões de pesquisa, hipóteses e objetivos do estudo. Posteriormente, os capítulos dois, três e quatro, apresentam o desenvolvimento da pesquisa, estruturada na forma de três artigos chave, que abordam respectivamente, a modelagem conceitual, o desenvolvimento matemático e a simulação de sistemas pecuários de produção de bovinos de corte. Por fim, o capítulo cinco apresenta as conclusões gerais e promove uma breve discussão sobre as implicações do tema para trabalhos futuros.

CAPÍTULO II²

**Bioeconomic model of decision support system for farm management. Part I:
Systemic conceptual modeling**

Soraya Tanure^{a*}, Carlos Nabinger^a, João Luiz Becker^b

^a *Post-Graduate Program in Zootechny, Agronomy College, Universidade Federal do Rio Grande do Sul, Av. Bento Gonçalves, 7712, 91540-000, Porto Alegre, RS, Brazil*

^b *Post-Graduate Program in Administration, Administration School, Universidade Federal do Rio Grande do Sul, Av. Bento Gonçalves, 7712, 91540-000, Porto Alegre, RS, Brazil*

* Corresponding author. Tel.: +55 (51) 3308 7406; fax: +55 (51) 3308 6048.

E-mail address: sorayat@terra.com.br (S. Tanure).

ABSTRACT

Information systems used in farming systems are characterized by high complexity. They should be composed of inter-related economical and biological components capable of working in a dynamic and continuous manner, receiving data and producing results within an organized production process. Taking this complexity into account, in this study we propose a novel conceptual macromodel with a system approach of the agricultural and livestock production environment to be adopted as information system in order to support the decision making process. This model is capable of representing the innumerable aspects of a production unit aiming to help farm producers understand and manage their production system. To better understand the general model and its nuances, several submodels (input models) were built based on adaptation of pre-existing research, among which we mention: meteorological, pasture, animal, crop-livestock integration, crop, soil, pasture-animal, and pasture-soil submodels. The combination of these submodels originates and configures the production unit structure. Among the main outputs of the proposed model are the economic results, based on agricultural and livestock productivity, the environmental impact assessment, and the analysis of operational risk. A qualitative approach was used with an exploratory descriptive design to carry out this research, based on literature review, interviews, and meetings with experts to refine and validate the proposed model. The refinement of the conceptual model was based on the Delphi method, which allowed the collection of data and peculiarities of the object under study, guided its development to achieve the goals of this research, and allowed the register of several issues for further studies. The validation of the model, also using a qualitative approach, was performed employing conceptual, face, and subsystem validation procedures, also applying the Delphi method. This way, we

aimed to identify the weak and strong points of our conceptual model, its main shortcomings and limitations, and the variables that should be optimized, in theoretical and practical perspectives, so that this model can be improved.

Keywords: Bioeconomic model; Conceptual framework; Decision making; Farm production modeling; Farming system management.

Highlights

> We model a decision support system for farming system production. > The model inputs are based on meteorological, pasture, animal, crop, and soil conditions. > The combination of all inputs makes the farm structure and originates the outputs. > The model outputs are based on economic, environmental, and risk analyses.

1. Introduction

The current highly competitive and complex market requires decision makers' special attention, since an incorrect or incomplete assessment of the reality may lead to disastrous results (Zott et al., 2011). In agriculture and livestock sectors, the pressures imposed by the globalization of the economy have been demanding gradual changes based on efficiency (Jakku and Thorburn, 2010) so that the enterprises can stay profitable and remain competitive.

The performance of rural enterprises is, therefore, determined by a large number of variables, resulting from public policies, macroeconomic scenario, as well as local and regional specificities. Several variables cannot be controlled in the production unit, whereas others, such as production system management, are likely to be controlled at this level (Boehlje, 1999; Jakku and Thorburn, 2010; King et al., 2010).

Rural managers have to make their decisions in an uncertain and dynamic environment, leading to the need of creating or adapting tools that are able to help them in this complex process (Boehlje, 1999). The seasonal nature of agricultural and livestock production reveals that the decision taken now (regarding investments, technology adoption, and market development) may take months, years, or even decades to produce results (Fisher et al., 2000). These characteristics, associated to limited rationality, lead rural managers and producers to come up with mental models that reflect reality in a distorted way as well as counterintuitive phenomena that are not noticed in a problem solving perspective (Simon, 1955; Hardaker and Lien, 2010).

The organizational decision making process requires accurate and readily available information. Given the advances in information technology, collecting information is no longer a problem, although using it efficiently is still challenging. The organization, therefore, depends on mechanisms to spread, filter, and use appropriate information and, consequently, create an ongoing learning process (Brouthers et al., 2008; Zott et al., 2011).

Transparency and quickness of information flow contribute to improve efficiency of all production chain components, and may result not only in better management but in high quality and safe products as well. Combining the use of technology as information and follow-up tool is currently an essential aspect of competitiveness both in internal and external markets (Janssen and van Ittersum, 2007).

In this context, adopting decision support systems that are capable of generating models to guide the business is fundamental to achieve a better performance and to optimize the agricultural and livestock production process. Information systems directed to agricultural and livestock production should possess inter-related economic and biological components that work together and continually, receiving inputs and generating results in an organized production process (Austin et al., 1998; Annetts and Audsley, 2002; Douthwaite and Gummert, 2010).

In this study, we propose a novel systemic conceptual model to be used as a decision making tool in agricultural and livestock production systems, capable of representing, with certain limitations, the complexity of a production unit, aiming to supply the resources to overcome the difficulty in understanding and managing the production system, as well as to give support to the rural producer learning process.

2. Overview and modeling of decision making process in farm management

A system for supporting strategic decision making helps managers to deal with non-structured problems through the direct interaction of data modeling and analyses (Štůsek and Ulrych, 2008). However, the models developed from these systems do not provide decisions. Modeling real world situations, these systems process the data supplied and give back information that merely facilitate the user's decision making. Also, although systems for supporting strategic decision making do not replace the judgment of human specialists, they truly contribute to enhance the quality of the decisions taken in complex environments (French et al., 2011).

We can mention as positive aspects of modeling: (i) make predictions of particular interest with the purpose of guiding decision making and operating processes in a production system; (ii) identify knowledge gaps; (iii) help to implement climatic and geographic zoning and to structure productive systems; (iv) guide the research using the screening provided by the model composition; (v) furnish resources for broader and more complex studies (Senge and Sterman, 1992). Therefore, the use of well designed models, which conveniently summarize different types of information that are able to create knowledge about the production system, as well as elucidate obscure points, brings several advantages.

On the other hand, models cannot be taken as a final goal of research, of any production need, or as a ready tool, since they are previously designed, composed of several elements, and express extreme need for enhancement and continuous adaptation. Another important point is the fact that models do not require accuracy to be applied, because the approximation to reality is what makes them applicable

(Annetts and Audsley, 2002).

Since the beginning of its use, modeling has been connected with the general systems theory, and these terms are often used interchangeably. The core of the general systems theory is the concept that the response of the system to a stimulus does not equal the result of the response of each of its components (Kaine and Cowan, 2011). The dynamic interactions between the components of the system are the primary determinants of its final behavior (Drack and Schwarz, 2010). Thus, studies dealing with system components isolatedly are inappropriate to predict responses of this system as a whole (Oberle and Keeney, 1991). The basis of systemic thinking consists of understanding the complexity of the production process. Consequently, the producer should consider his property a process composed of inputs, outputs, and feedback systems, inserted in an environment that conditions its operation.

The inputs are the physical and abstract elements or resources that compose the systems, including the influences of the environment in which the system is inserted. In the rural property, for instance, the inputs encompass natural, human, financial, and infrastructure resources, as well as information about the product demand and supply. The transformation processes interconnect components and transform the inputs into results (Fisher et al., 2000). The outputs are the results of the system, i.e., the goals established or effectively achieved by the system. Finally, the feedback compares outputs and inputs in an attempt to control or reinforce the production process (Boehlje, 1999; King et al., 2010).

Models can present two main sources of errors: (i) errors in structure, associated to the choice of the processes to be taken into consideration in the model

and how they are going to be presented; and (ii) errors related to parameterization, i.e., to the values of the parameters obtained experimentally or empirically (Štůsek and Ulrych, 2008). As the complexity of the model enhances, the errors associated to the model structure are reduced, since this is more realistic when including the system components and operational processes. Nevertheless, parameterization errors increase in response to the inclusion of new parameters (Senge and Sterman, 1992). Hence a model should be as simple as possible and as complex as necessary for a determined use, aiming to achieve good balance between errors in structure and in parameters (Jakku and Thorburn, 2010).

Among the greatest current challenges in building models, we can mention the correction of the aforementioned limitations and the usage of dynamic models. Almost all models applied in agricultural and livestock production (or even in the broad context of agribusiness) employ “static” criteria and variables for creating spreadsheets and interconnections between key elements. In the biological context, it is clear that this approach is both limited and erroneous, because the majority of processes involved are non-linear. In these models it is assumed that the state of the system at a determined point in time is enough to predict its behavior and also that its transient states do not have influence upon the results, and therefore do not need to be mentioned. As a consequence, in addition to the facts of not representing the system correctly and not permitting adaptations to the environment where they should be used, these models transmit distorted responses to decision making agents (Tanure and Nabinger, 2010).

3. Research method

3.1. Model overview

A qualitative approach was used with an exploratory descriptive design to carry out this research, based on literature review, interviews, and meetings with experts to refine and validate the proposed model. The qualitative approach was chosen because it fits the complexity of the variables used in the conceptual model and permits a more robust assessment of their interaction (Denzin and Lincoln, 2005).

Exploratory descriptive studies aim to develop and/or modify concepts in order to formulate research problems or hypotheses. Furthermore, exploratory techniques are concentrated in the analysis of the changing process and viable alternative paths that lead to the future. The refinement of this novel conceptual model was based on the Delphi method (Okoli and Pawlowski, 2004), which allowed the collection of data and peculiarities of the object under study, guided its development to achieve the goals of this research, and allowed the register of several issues for further studies.

Among the essential characteristics of the Delphi method we can mention information and opinion exchange between participants, guarantee of anonymity to research participants, and the possibility of reviewing individual points of view about the future (Keeney et al., 2001). The Delphi method is an approach used to gain consensus among the opinions of a panel of experts about future events (Williams and Webb, 1994), taking into account that a collective opinion is better than the opinion of a single individual, provided that the study is properly organized.

In our research, following the characteristics of the Delphi method, we

prepared a questionnaire that was sent to experts. The responses to the questions were analyzed and, posteriorly, discussed with all the participant experts in meetings, aiming to explore the diverging points, in an attempt to reach consensus thus achieving consistency and feasibility for the models proposed. After cross-checking the information collected, it was possible to refine the conceptual model presented in the subsequent step, and especially identify its main variables, in order to organize all the phases of this research.

In the first phase of the research, we carried out a literature review to support the identification of relevant variables to the second phase of this study and to guide the construction of the conceptual model in the third phase. This model was posteriorly sent to the participants, resulting in its refinement and validation, in the fourth and fifth phases, respectively. Finally, the sixth phase consisted in the presentation of the final macro model, submodels, and perspectives for future studies.

Another distinctive point refers to participant selection. The experts interviewed to refine and validate the conceptual submodels were chosen based on the following characteristics: (i) they are university professors with more than 15 years of experience in practical work (and consultancy) in different agricultural and livestock production systems; (ii) they participate in multidisciplinary areas and research groups related to agribusiness, such as rural economy, decision making, and zootechny; (iii) they are in direct contact or have already worked with research involving modeling, mapping, and scenario structuring in rural properties.

3.2. Conceptual validation

In this study, we chose to apply the qualitative validation of the conceptual model, using conceptual, face, and subsystem validation procedures. The conceptual validation aims to guarantee that the assumptions and theories that give support to the proposed conceptual model are pertinent and mainly viable (Borenstein, 1998; Borenstein and Becker, 2001).

Face validation consists in gathering experts in one or more fields of knowledge and verify whether the proposed research object is structured enough to generate a viable and acceptable solution, as the result of a detailed process, searching for understanding the potential users' point of view about the system (Borenstein and Becker, 2001).

For the subsystem validation it is possible to adopt the same protocol used for face validation. This validation consists in dividing the main system into several subsystems and validating each one isolatedly (Borenstein, 1998), searching for better precision between the segments that compose the general conceptual model. In this research, given that we tried and segmented the principal conceptual model into several secondary submodels, in order to better understand its complexity and operation, the subsystem validation technique is of paramount importance to ensure the coherence and validation of the principal model.

The validation procedures were performed employing the Delphi method, aiming to identify the weak and strong points of our conceptual model. This way, it was possible to determine its main shortcomings and limitations, as well as the variables that should be optimized, originating the bioeconomic macro model and its submodels.

4. Results

4.1 Macro bioeconomic model of decision support system for agricultural and livestock enterprises

Bioeconomic modeling is characterized by a high level of complexity, as the processes involved are dynamic and the interactions of the parameters and the variables that describe the process are modified over time (Finger et al., 2010). Taking this complexity into account, in the present research we propose a novel conceptual bioeconomic macro model (Fig. 1) that congregates the characteristics of the biological production environment, as well as the economic (costs of production and market) and institutional aspects (laws). The macro environment (production environment) where this model was developed is an open system in which all the environmental, economic, and institutional aspects directly or indirectly influence the model inputs and outputs, representing a highly complex system that is difficult to be structured.

In order to better understand the general model and its nuances, we adapted several submodels, also named input models, of pre-existing studies: (i) meteorological; (ii) pasture; (iii) animal; (iv) crop-livestock integration; (v) crop; (vi) soil; (vii) pasture-animal; (viii) and pasture-soil. The combination of these submodels originates and configures the production unit structure.

It is worth emphasizing the importance of the connection “consumption” for the animal submodel. The inclusion of the consumption measurement for animals that are exclusively grass-fed or receive food complements (dietary supplements or in

confinement) is intended to overcome one of the great knowledge gaps in current understanding of animal performance: consumption based on diet selection and stratification (Nousiainen et al., 2011). Due to its importance and direct influence on the economic aspects that guide the rural producer decision making process, the topic consumption is going to be detailed in a subsequent item.

Among the main outputs of the proposed model are the economic results, based on agricultural and livestock productivity, and the environmental impact analysis. Because of the constant discussion about the influence of human activities on environmental changes in the last decades, especially the impacts of agricultural crops and, more recently, methane emissions from livestock (Beauchemin et al., 2010; Thornton and Herrero, 2010), it is essential to include the environmental aspects in the analysis for decision making.

Risk analysis, especially the market risk, should be included in the general analysis of the economic environment. The market risks are among the most important aspects to be taken into account in agricultural and livestock management. Price fluctuations in agricultural and livestock products may render the entire production process unfeasible. Thus, revenue decreases due to decreased commodity selling pricing may lead to unsatisfactory results, even when the enterprise productivity is high (Malan et al., 2010).

Finally, understanding the system productivity from the economic and environmental point of view, the rural producers will be able to develop strategic and contingency plans perfectly adapted to their reality and, consequently, make their decision with a large amount of resources, which allow a broad knowledge of the production system as a whole. One of the options for the systemic view of the

production unit is its segmentation into subsystems, represented by the submodels of this study, presented below.

4.2 Meteorological submodel

The interaction between climate and soil is fundamental to determine the meteorological models capacity to adapt to a particular ecosystem, as well as the phenological phases, production, and final yield of innumerable plant species. This is even more relevant when we take into account the plant species, pasture or cereals, cropped for economic reasons (Finger et al., 2010).

Reliable climatic data are fundamental for modeling adapted to plant population growth, since modeling associated to simulations requires long-term series of mean values for rainfall, temperature, solar radiation, wind, among others (Dueri et al., 2007). In order to make a meteorological model more easily usable for operational purposes, most biophysical systems modeled demand some reality simplification (Maas, 1993). Aiming to develop a practical model, with few input variables and, simultaneously, applicable to reality, Fonseca et al. (2007) proposed a meteorological model to estimate pasture availability (Fig. 2).

The submodel presented in Fig. 2 resulted from the development of a potential pasture production model that estimates the maximum (or potential) accumulation of pasture, in a determined period of time, based on the amount of incident solar radiation, in the form of photosynthetically active radiation and taking into account the initial (or existent) forage availability (Fonseca et al., 2006; Fonseca et al., 2007).

The existence of known relationships between meteorological variables and

the components that define plant productivity enable the construction of empirical models to estimate this productivity and diagnose the conditions for plant growth. The models that have the solar energy intercepted by the crop as an input, which permit the calculation of biomass accumulated during a determined period of time, are commonly used in studies involving grass in temperate climate to estimate yield potential under non-limiting growth conditions (Nabinger and Carvalho, 2009). These models are based on linear relationships between the amount of photosynthetically active radiation intercepted by the crop and total dry matter produced by the canopy (Fonseca et al., 2007). Therefore, the main purpose of this submodel is to estimate the final forage availability, based on its initial availability, upon which the agrometeorological factors that define plant growth are acting, according to the pasture submodel.

4.3 Pasture submodel

To understand pasture growth, we applied a model proposed by Nabinger and Carvalho (2009), which aggregates information about the type of pasture, since it would be impossible to measure all the existing pastures, taking into account that the floristic composition of each type of pasture, in distinct environments and at different times of the year, varies considerably. Thus, the authors proposed three types of pasture: (i) natural; (ii) winter; (iii) improved natural pasture. Due to the varied floristic composition of pasture, and the unique growth, reproduction, and aging characteristics of each species in this composition, pasture growth is different for each type of pasture. Nevertheless, the conceptual model is similar for all plant

crops, because the variables that are relevant for their growth are identical, although they assume different values in each type of pasture (Fig. 3).

Altogether, the effects of the environmental variables climate and soil determine both the floristic composition of pasture and the carbon balance in the system (Nabinger and Carvalho, 2009). In a human-controlled grazing ecosystem, we should also associate the effects of herbivory, which can be controlled by deciding the animal species, category, and density to be used. These parameters determine different levels of pressure (selectivity and preference) on the pasture and, in an interaction with the grazing method, regulate the frequency of its different floristic elements. However, the antropic effects on the floristic composition can also appear as a consequence of other more direct types of intervention, such as fertilizer application, species overseeding, use of fire, slashing, and herbicides, among others (Hillebrand and Matthiessen, 2009).

Pasture submodel shows forage general availability and structure as the result of different functional groups integration, which, in turn, allow an ingestion behavior determined by bite depth, bite rate, time allocated for forage searching and apprehension, and daily grazing time (Cangiano et al., 1999). These characteristics, naturally associated to dietary quality, determine the individual animal performance that, multiplied by the total number of animals, results in the production per area (Nabinger and Carvalho, 2009). Therefore, the final result of this submodel directly influences the animal submodel, in which the characteristics of nutritional requirements are measured.

4.4 Animal submodel

Models of animal growth, gestation, and lactation present great variation in terms of purpose, time, modeled processes, and complexity (Bryant et al., 2008). Considering models of animal growth isolatedly, for instance, several objectives can be proposed: (i) predict animal weight gain and the composition of this gain in a certain phase of animal life as well as nutritional conditions (NRC, 1996); (ii) formulate more economically viable diets (Lanna et al., 1999); (iii) study the implications of compensatory gain and agents that modify nutrient partitioning (Oltjen et al., 1986; Sainz and Wolff, 1990). Nonetheless, models that aggregate environmental characteristics of seasonality, consumption, and economic characteristics, such as production costs, aiming to obtain a systemic interpretation about production unit control are very scarce (Tanure and Nabinger, 2010).

The animal submodel we propose in the present study was adapted from the work of Vetharaniam et al. (2009), associating information about meteorological and consumption conditions to the physiological characteristics of growth, gestation, and lactation (Fig. 4) with the purpose of measuring beef cattle productivity in grazing systems (pasture-animal submodel) or using food complements (connection consumption).

Furthermore, similarly to the pasture submodel, in which the floristic composition and environment variation is huge, in the specific case of the animals, the variation regarding genetics, sex, age, and animal category is also highly relevant. Based on the premise that it would be impossible to map all these differences, the animals were divided into genetic groups (European or British, Zebu,

and crosses) and categories or life cycle stages. Some models are extensively employed to characterize animal categories (NRC, 1996), but this does not represent a limitation to the proposed submodel. It is worth to mention that regardless of genetics or category, the conceptual model remains the same, since the reference variables do not change, just their values.

Among the main aspects of the animal submodel are the incorporation of the meteorological submodel, the economic characteristics associated to the cost of production, the balance of carbon flow resulting from the pasture-animal submodel, and the balance between the nutritional demand and the consumption (connection consumption, described in the next subitem). Therefore, regardless of animal age (young or adult), the nutritional balance permeates all the model and generates results that influence animal growth, reproduction, and fattening period, with an increase in working capital, and also generating an economic impact in a systemic approach of the production process.

4.5 Connection consumption in pasture-animal submodel

Due to the relevance of animal consumption characteristics, this process was connected to the pasture-animal submodel, resulting in the proposal of an individualized subsystem, herein named connection consumption (Fig. 5) , based on the assumptions of Machado (2004).

The purpose of the connection consumption, originally called BeefSim model (Machado, 2004), is to assess the potential of using supplementation or pastures, and to achieve this goal the following processes are incorporated to the model:

pasture growth rate, food intake rate (cereals versus pasture), food intake rate associated to pasture structure (height, leaf/stem ratio, spatial distribution of different pasture components, among others), chemical composition of the food offered, soil fertilization, as well as their interaction with the cost of production of innumerable technologies evaluated. The main advantage of this subsystem is the incorporation of the food intake rate associated to pasture structure. The incorporation of the variable pasture structure permits to better understand the animals' capacity of selecting their diet and, consequently, their performance (Wilman et al., 1996; Nousiainen et al., 2011).

The variables forage mass and forage yield (and subdivisions), originating from the pasture submodel, have a leading role in consumption and help characterize diet composition, which is influenced by the availability of dietary supplements, taking economical aspects into consideration, such as the cost of the diet. Physiological aspects, such as ruminal capacity and consumption potential, are related to the animal submodel, which generates responses based on characteristics already described, such as age, sex, and genetic group.

In addition to animal production, in several production units the farmers also cultivate cereals for their own consumption, or as dietary supplements for their animals, or for commercialization. Agricultural production accounts for several economical and managerial aspects of rural properties and the necessity to map this sector originated the crop-livestock integration submodel, described below.

4.6 Crop-livestock integration submodel

Finding the correct balance between production and pasture quality, providing animals with sufficient amounts and proper balance of nutrients to perform their productive functions, making the cycle of production sustainable over time, and keeping a harmonious relationship between soil, plants, and animals are the main challenges of production systems that integrate crop and livestock (Thomson and Bahhady, 1995). Therefore, in order to better understand the innumerable relationships and highlight the main variables involved in systems integrating livestock and crop production, we designed a conceptual crop-livestock integration model aiming to quantify the productivity of the system as a whole (Fig. 6). This submodel was originally proposed by Cassol (2003) and includes biological and economic characteristics in systems that integrate pasture and grain production, such as rice, maize, and soybean, representing almost all the crops cultivated in the state of Rio Grande do Sul, Brazil (IBGE, 2009).

In a general context, this submodel is based on agricultural crop rotation or planting only one crop in the growing season followed by off-season annual pasture. It presents grazing intensity as a fundamental variable that determines the productivity of the crop-livestock integration system. This submodel can be analyzed based on the variable amount of available forage, corresponding to the last activity in the area. This is important, since different pasture heights affect the forage mass due to changes in leaf area index caused by greater or lower light-intercepting capacity (Cassol, 2003). Consequently, this submodel establishes a connection with the pasture submodel, which, in turn, generates results of pasture growth, considering, among other variables, the incident solar radiation on pasture (Nabinger and Carvalho, 2009). Santos et al. (2004) consider that grazing frequency, intensity, and period are important factors to better use plant growth characteristics. According to

the authors, grazing intensity refers to the proportion of forage removed as well as the characteristics and quantity of the remaining material after defoliation, and therefore it is associated to the stocking rate or grazing pressure used.

It is possible to observe that both the pasture growth and the grain crop yield highly influence the soil characteristics. Simultaneously, grain crop and animal production can have impact on the soil and, consequently, on carbon flow. Briefly, the crop-livestock integration submodel is strongly connected to the crop and soil submodels, presented below, which originate from morphological, physical, chemical, and mineralogical characteristics of the soil that are also prevalent in grain crops and pasture growth.

4.7 Crop submodel

Brazilian agriculture is characterized by spring-summer crops, corresponding to over 70% of total grain production. Soybean and maize are the most expressive crops. In the Southern Region of the country, these two crops together represent 70% of the cultivated area and 60% of total grain production (IBGE, 2009). As a result of the social and economic importance of these crops, not only the direct managers of the production systems, but all the agents involved in the agriculture sector demand information about crop yields as early as possible, preferably before the growing season.

Among the principal difficulties to make an accurate estimate of grain production we can mention meteorological conditions associated to low adoption rate of irrigation systems (Vico and Porporato, 2011). The use of conceptual models

capable of representing several scenarios (extreme weather conditions – rain or drought – and soil) and allowing their analyses is considered effective to help forecast crop yields (Moore et al., 2011) and, consequently the final decision making. Taking these difficulties into account, mainly trying to evidence the relationships between net photosynthesis and crop yields, the crop submodel herein presented (Fig. 7) was adapted from the model named Canegro, originally proposed by Inman-Bamber (1994) for sugarcane. Although the conception of the Canegro model was directed to a specific culture, the inter-relations between the predominant variables of agricultural systems, and especially its conceptual structure focused on crop yield, can be easily adapted to other crops, thus justifying the choice of this model to give support to the construction of the crop submodel for rice, maize, and soybean in the present study.

The crop submodel is based on process modeling, evidencing the importance of knowledge on crop development during its productive cycle to allow final estimate of grain production considering water balance and nutrient cycling in the soil. Moreover, this submodel is strongly associated to meteorological information and, similarly to the crop-livestock integration submodel, it considers dry matter accumulation during the crop cycle as a prevalent part of soil quality and, finally, of crop yield. The results of this conceptual structuration point to the importance of a systemic understanding of production units, because animal, plant, and soil relationships are equally relevant for decision making. One among the several pillars of this study, the crop submodel emphatically shows the importance of the soil submodel, presented below, as one of the conceptual bases that require further comprehensive research in order to generate a better understanding of its potentialities and, principally, its impacts on all the other factors of the agricultural

and livestock production systems.

4.8 Soil submodel

Soil quality can be included as one of the main factors that define the sustainability of an agricultural and livestock production system. As an open system, soil reaches quality through the interaction of microorganisms and plants. Consequently, management is one of the most important factors that define soil quality as well as sustainability of a production system (Manderson and Palmer, 2006). The existence of robust information systems capable of encompassing physical, chemical, and managerial characteristics is of paramount importance to achieve a better quality decision making.

Information systems on soils are relatively recent and describe soils in their natural environment (Matthews, 2006). They can be descriptive and present quantitative data, such as spatial dimensions (units in maps), or punctual data, which describe and quantify specific properties of a soil profile in a determined place and time on the surface of the Earth (Lark and Bolam, 1997). Due to the need of information for the development of studies involving location, quality, and quantification of soil properties, as well as its processes and interactions with other natural resources, Matthews (2006) designed a macro model to organize a soil information system capable of providing decision criteria on the management of this resource in different production systems. This macro model was adapted to the present study generating the soil submodel (Fig. 8).

Based on traditional analysis reports furnished by the laboratories that evaluate soil physical and chemical characteristics, the soil submodel herein

proposed classifies soil types according to their fertility level (high, medium, or low), as well as morphological, physical, chemical, and mineralogical aspects. Therefore, this submodel provides the system manager with information on soil quality, with direct implications on pasture growth and crop yield, thus helping him make correct decisions. Assessing soil quality (fertility levels) requires choosing some soil properties to be monitored as quality indicators. In order to be an efficient quality indicator, a soil property needs to be sensitive to management variations.

Possible soil quality indicators can be classified into three groups: (i) ephemeral, whose alterations take place quickly according to management, such as pH, nutrient availability, density, porosity, and moisture; (ii) intermediary, which strongly influence the processes occurring in the soil, such as organic matter, aggregation, and microbial biomass; (iii) permanent, which are inherent to the soil, such as depth, texture, and mineralogy (Islam and Weil, 2000). In a very simplified way, aiming to help the decision making process, and taking into consideration the limitations of simplifying reality, the soil analysis report used in this submodel includes the features considered fundamental to generate the classification into fertility levels proposed, especially the variable organic matter, which provides resources to calculate carbon balance.

Another feature of the soil submodel, which is intended to help understand agricultural and livestock production in a systemic perspective, is the direct influence of the meteorological submodel on soil quality characteristics. Therefore, starting the submodels presentation with the meteorological submodel and finishing it with the soil submodel, it is possible to observe the evident influence and dependence between them. Consequently, it is clear that all the submodels are interconnected and that this connection is vital to help production managers make the correct

decision, in a broad and organized way that privileges the whole system (Sørensen et al., 2011). The decision making agent will only be able to turn his rationality less limited visualizing all the subsystems present in the production unit, in order to plan and manage the system, aiming to reach his goals and prioritize bioeconomic production indicators in tune with global demand.

4.9 Economic and environmental outputs

Economic analysis is fundamental to help producers make decisions, because it permits assessing the economic impact of new technologies on the production system, as well as optimizing available resources (Hardaker and Lien, 2010). Formal financial demonstrations constitute an accounting information system capable of providing the decision making agent with the variables needed for the analyses based on aspects of the internal and external environment. Additionally, they also permit to include extra-accounting information, such as environment variables associated to carbon credit values, which influence on economic and systemic process of organizational control (Bosch et al., 2008). This led to the model proposed in this study, which presents financial and environmental indicators (Table 1), measurable in a determined time span, as its main outputs.

The first financial indicator evaluates the frequency of product sales (meat and grains) when prices are high. Obtaining high prices for commercialization indicates cash flow alignment; on the other hand, commercializing off-season products maximizes the income (King et al., 2010).

The second financial indicator evaluates the efficiency to minimize monthly

deficits, which can interfere in the negotiations that take place in strategic periods (Štůsek and Ulrych, 2008), due to enhanced efficiency of cash flow management.

The third financial indicator evaluates whether the historical profit trend points to growth or decline. The retroactive evaluation of some years is capable of revealing this behavior, so that profitability can be more broadly monitored considering the analyses of several years (King et al., 2010).

The fourth financial indicator monitors the waste of production inputs, since correct storage and application of fertilizers to the soil, chemicals to pastures, and veterinary products to animals can contribute to decrease loss and operating costs.

The fifth financial indicator evaluates income distribution among commercialized products, taking into consideration that risks can be minimized by product diversification (Malan et al., 2010), which can help cope with an eventual crisis by occupying different market niches.

Finally, the sixth financial indicator is determined by the capacity of the enterprise to generate return higher than the opportunity cost of land use.

Regarding environmental analysis, the indicator carbon balance can clearly represent the effects of environmental degradation caused by crop and pasture disorganized management, mainly in case of soil degradation and consequent desertification of ecosystems (Hillier et al., 2011). Thus, we chose this indicator as a general output that represents the environmental impact on the production systems focused in the present study, because the positive balance, i.e., when carbon fixation is higher than carbon emission, represents a lower impact or a greater possibility to achieve system sustainability (Thornton and Herrero, 2010).

5. Summary and conclusions

The increasing globalization experienced by modern society, including rural areas, has been generating great opportunities to store and spread data, information, and knowledge intended to help decision makers. Systems designed to support decisions should use these resources in an intelligent way in their different spheres of action. However, it is worth mentioning that many producers believe that their managers' knowledge, acquired in the working environment due to accumulated experience over time, is sufficient to overcome problems. Obviously, we cannot deny that direct experience is one of the most efficient learning processes. Nevertheless, it is necessary to bear in mind that this process is limited and, moreover, it can develop or reinforce wrong premises and points of view about production system dynamics.

Modeling and mapping agricultural and livestock production scenarios effectively help producers make right decisions, since they are priceless instruments of persuasion to implement the use of new technologies and discard those that are already outdated. However, designing models in biological systems is not simple. Due to the diversity and complexity of the agricultural and livestock systems, simulation poses a challenge to the researchers and stimulates them to develop comprehensive models that are able to give support to the analyses of complex decisions involving such systems.

Because of the intrinsic formulation of comprehensive managerial problems, using optimization techniques makes it possible to observe that some of these problems, simplified by the adoption of fixed values for some control variables or by the treatment of these variables as input data for the problem, cause discrepancy in

results and limited applicability to the reality in rural areas.

The available models, related to agricultural and livestock production systems, do not appropriately represent several and important features of these systems. This stimulates researchers to generate knowledge and quantify the processes concerning systems with grazing animals or using dietary supplements. In our study, we tried and include all the areas and subsystems of the production unit in order to help systemic decision making processes. Nevertheless, we recognize the limitations of this work, taking into account the huge complexity of agricultural and livestock production as well as the need to reduce the number of variables, so that we can design a consistent and applicable model.

In summary, it is necessary to gather human resources from distinct fields of knowledge to form multi and interdisciplinary teams intended to respond clearly to the needs of producers, so that system research efforts result in more sophisticated, versatile, and reliable models.

References

- Annetts, J.E., Audsley, E., 2002. Multiple objective linear programming for environmental farm planning. *J. Oper. Res. Soc.* 53, 933–943.
- Austin, E.J., Willock, J., Deary, I.J., Gibson, G.J., Dent, J.B., Edwards-Jones, G., Morgan, O., Grieve, R., Sutherland, A., 1998. Empirical models of farmer behavior using psychological, social and economic variables. Part I: linear modelling. *Agric. Syst.* 58, 203–224.
- Beauchemin, K.A., Janzen, H.H., Little, S.M., McAllister, T.A., McGinn, S.M., 2010. Life cycle assessment of greenhouse gas emissions from beef production in

- western Canada: A case study. *Agric. Syst.* 103, 371–379.
- Boehlje, M., 1999. Structural changes in the agricultural industries: how do we measure, analyze and understand them? *Am. J. Agric. Econ.* 81, 1028–1041.
- Borenstein, D., 1998. Towards a practical method to validate decision support systems. *Decis. Sup. Syst.* 23, 227–239.
- Borenstein, D., Becker, J.L., 2001. Validating decision support systems. In: Kent, A., Williams, J.G. (Orgs.), *Encyclopedia of microcomputers*. Marcel Dekker, New York, pp. 323–341.
- Bosch, D.J., Stephenson, K., Groover, G., Hutchins, B., 2008. Farm returns to carbon credit creation with intensive rotational grazing. *J. Soil Water Conserv.* 63, 91–98.
- Brouthers, K.D., Brouthers, L.E., Werner, S., 2008. Resource-based advantages in an international context. *J. Manag.* 34, 189–217.
- Bryant, J., Lopez-Villalobos, N., Holmes, C., Pryce, J., Rossi, J., MacDonald, K., 2008. Development and evaluation of a pastoral simulation model that predicts dairy cattle performance based on animal genotype and environmental sensitivity information. *Agric. Syst.* 97, 13–25.
- Cangiano, C.A., Fernández, H.H., Galli, J.R., 1999. *ConPast 3.0: programa de computación para la estimación del consumo de bovinos en pastoreo*. La Barrosa, Buenos Aires.
- Cassol, L.C., 2003. *Relações solo-planta-animal num sistema de integração lavoura-pecuária em semeadura direta com calcário na superfície*. Doctoral thesis, Universidade Federal do Rio Grande do Sul, Porto Alegre, Brazil.
- Denzin, N.K., Lincoln, Y.S., 2005. *Introduction: The discipline and practice of*

- qualitative research. In: Denzin, N.K., Lincoln, Y.S. (Eds.), *The SAGE Handbook of Qualitative Research*. 3rd ed. Sage Publications, Thousand Oaks, pp. 1–33.
- Douthwaite, B., Gummert, M., 2010. Learning selection revisited: How can agricultural researches make a difference? *Agric. Syst.* 103, 245–255.
- Drack, M., Schwarz, G. 2010. Recent developments in general system theory. *Syst. Res. Behav. Sci.* 27, 601–610.
- Dueri, S., Calanca, P.L., Fuhrer, J., 2007. Climate change affects farm nitrogen loss – A Swiss case study with a dynamic farm model. *Agric. Syst.* 93, 191–214.
- Finger, R., Lazzarotto, P., Calanca, P., 2010. Bio-economic assessment of climate change impacts on managed grassland production. *Agric. Syst.* 103, 666–674.
- Fisher, D.K., Norvell, J., Sonka, S., Nelson, M.J., 2000. Understanding technology adoption through system dynamics modeling: implications for agribusiness management. *Int. Food Agribus. Manag. Rev.* 3, 281–296.
- Fonseca, E.L., Ponzoni, F.J., Formaggio, A.R., 2007. Modelo agrometeorológico-espectral para estimativa da disponibilidade de forragem no bioma “campos sulinos”. *Rev. Bras. Agrometeorol.* 15, 241–249.
- Fonseca, E.L., Silveira, V.C.P., Salomoni, E., 2006. Eficiência de conversão da radiação fotossinteticamente ativa incidente em biomassa aérea da vegetação campestre natural no bioma Campos Sulinos do Brasil. *Ciênc. Rural* 36, 656–659.
- French, S., Bedford, T., Pollard, S.J.T., Soane, E., 2011. Human reliability analysis: A critique and review for managers. *Saf. Sci.* 49, 753–763.
- Hardaker, J.B., Lien, G., 2010. Probabilities for decision analysis in agriculture and

- rural resource economics: The need for a paradigm change. *Agric. Syst.* 103, 345–350.
- Hillebrand, H., Matthiessen, B., 2009. Biodiversity in a complex world: consolidation and progress in functional biodiversity research. *Ecol. Letters* 12, 1405–1419.
- Hillier, J., Walter, C., Malin, D., Garcia-Suarez, T., Mila-i-Canals, L., Smith, P., 2011. A farm-focused calculator for emissions from crop and livestock production. *Environ. Model. Software* 26, 1070–1078.
- IBGE. Instituto Brasileiro de Geografia e Estatística, 2009. *Lavoura permanente 2009*. Rio de Janeiro.
<<http://www.ibge.gov.br/estadosat/temas.php?sigla=rs&tema=lavourapermanente2009>>.
- Inman-Bamber, N.G., 1994. Temperature and seasonal effects on canopy development and light interception of sugarcane. *Field Crops Res.* 36, 41–51.
- Islam, K.R., Weil, R.R., 2000. Soil quality indicator properties in mid-Atlantic soils as influenced by conservation management. *J. Soil Water Conserv.* 55, 69–78.
- Jakku, E., Thorburn, P.J., 2010. A conceptual framework for guiding the participatory development of agricultural decision support systems. *Agric. Syst.* 103, 675–682.
- Janssen, S., van Ittersum, M.K., 2007. Assessing farm innovations and responses to policies: A review of bio-economic farm models. *Agric. Syst.* 94, 622–636.
- Kaine, G., Cowan, L., 2011. Using general systems theory to understand how farmers manage variability. *Syst. Res. Behav. Sci.* 28, 231–244.
- Keeney, S., Hasson, F., McKenna, H.P., 2001. A critical review of the Delphi technique as a research methodology for nursing. *Int. J. Nurs. Stud.* 38, 195–

200.

- King, R.P., Boehlje, M., Cook, M.L., Sonka, S.T., 2010. Agribusiness economics and management. *Am. J. Agric. Econ.* 92, 554–570.
- Lanna, D.P.D., Tedeschi, L.O., Beltrame Filho, J.A., 1999. Modelos lineares e não-lineares de uso de nutrientes para formulação de dietas de ruminantes. *Sci. Agric.* 56, 479–488.
- Lark, R.M., Bolam, H.C., 1997. Uncertainty in prediction and interpretation of spatially variable data on soils. *Geoderma* 77, 263–282.
- Maas, S.J., 1993. Parameterized model of gramineous crop growth. 1. Leaf area and dry mass simulation. *Agron. J.* 85, 348–353.
- Machado, C. F., 2004. Field and modelling studies of the effect of herbage allowance and maize grain feeding on animal performance in beef cattle finishing systems. Doctoral thesis, Massey University, Palmerston North, New Zealand.
- Malan, D.J.C., Louw, A., Blignaut, C., 2010. Simulation analysis of risk management for a diversified commercial farm. *Agrekon* 49, 373–395.
- Manderson, A., Palmer, A., 2006. Soil information for agricultural decision making: a New Zealand perspective. *Soil Use Manag.* 22, 393–400.
- Matthews, R., 2006. The People and Landscape Model (PALM): Towards full integration of human decision-making and biophysical simulation models. *Ecol. Model.* 194, 329–343.
- Moore, A.D., Robertson, M.J., Routley, R., 2011. Evaluation of the water use efficiency of alternative farm practices at a range of spatial and temporal scales: A conceptual framework and a modelling approach. *Agric. Syst.* 104, 162–174.

- Nabinger, C., Carvalho, P.C.F., 2009. Ecofisiología de sistemas pastoriles: aplicaciones para su sustentabilidad. *Agrociencia* 13, 18–27.
- Nousiainen, J., Tuori, M., Turtola, E., Huhtanen, P., 2011. Dairy farm nutrient management model. 1. Model description and validation. *Agric. Syst.* 104, 371–382.
- NRC. National Research Council, 1996. Nutrient requirement of beef cattle. 7th ed. National Academy Press, Washington, DC.
- Oberle, S.L., Keeney, D.R., 1991. A case for agricultural systems research. *J. Environ.* 20, 4–7.
- Okoli, C., Pawlowski, S.D., 2004. The Delphi method as a research tool: an example, design considerations and applications. *Info. Manag.* 42, 15–29.
- Oltjen, J.W., Bywater, A.C., Baldwin, R.L., Garrett, W.N., 1986. Development of a dynamic model of beef cattle growth and composition. *J. Anim. Sci.* 62, 86–97.
- Sainz, R.D., Wolff, J.E., 1990. Development of a dynamic, mechanistic model of lamb metabolism and growth. *Anim. Prod.* 51, 535–549.
- Santos, P.M., Balsalobre, M.A.A., Corsi, M., 2004. Características morfogénicas e taxa de acúmulo de forragem do capim-Mombaça submetido a três intervalos de pastejo. *Rev. Bras. Zootec.* 33, 843–851.
- Senge, P.M., Sterman, J.D., 1992. Systems thinking and organizational learning: Acting locally and thinking globally in the organization of the future. *Eur. J. Operat. Res.* 59, 137–150.
- Simon, H.A., 1955. A behavioral model of rational choice. *Q. J. Econ.* 69, 99–118.
- Sørensen, C.G., Pesonen, L., Bochtis, D.D., Vougioukas, S.G., Suomi, P., 2011.

- Functional requirements for a future farm management information system. *Comput. Electron. Agric.* 76, 266–276.
- Štůsek, J., Ulrych, L., 2008. Strategic thinking in the management of agribusiness companies. *Agric. Econ.* 54, 117–124.
- Tanure, S., Nabinger, C., 2010. Ferramentas de gerenciamento bioeconômico e suporte à decisão em empresas de pecuária de corte. In: *Anais do IV Congresso Internacional de La Carne Bovina*, Asunción, Paraguay, 23–25 March, 2010.
- Thomson, E.F., Bahhady, F.A., 1995. A model-farm approach to research on crop-livestock integration - I. Conceptual framework and methods. *Agric. Syst.* 49, 1–16.
- Thornton, P.K., Herrero, M., 2010. Potential for reduced methane and carbon dioxide emissions from livestock and pasture management in the tropics. *Proc. Natl. Acad. Sci. USA.* 107, 19627–19632.
- Vetharaniam, I., Stevens, D.R., Asher, G.W., Woodward, S.J.R., Archer, J.A., Rollo, M.D., 2009. Model of growth, pregnancy and lactation in red deer. *J. Agric. Sci.* 147, 253–272.
- Vico, G., Porporato, A., 2011. From rainfed agriculture to stress-avoidance irrigation: I. A generalized irrigation scheme with stochastic soil moisture. *Adv. Water Resour.* 34, 263–271.
- Williams, P.L., Webb, C., 1994. The Delphi technique: A methodological discussion. *J. Adv. Nurs.* 19, 180–186.
- Wilman, D., Mtengeti, E.J., Moseley, G., 1996. Physical structure of twelve forage species in relation to rate of intake by sheep. *J. Agric. Sci.* 126, 277–285.

Zott, C., Amit, R., Massa, L., 2011. The business model: Recent developments and future research. *J. Manag.* 37, 1019–1042.

Appendix

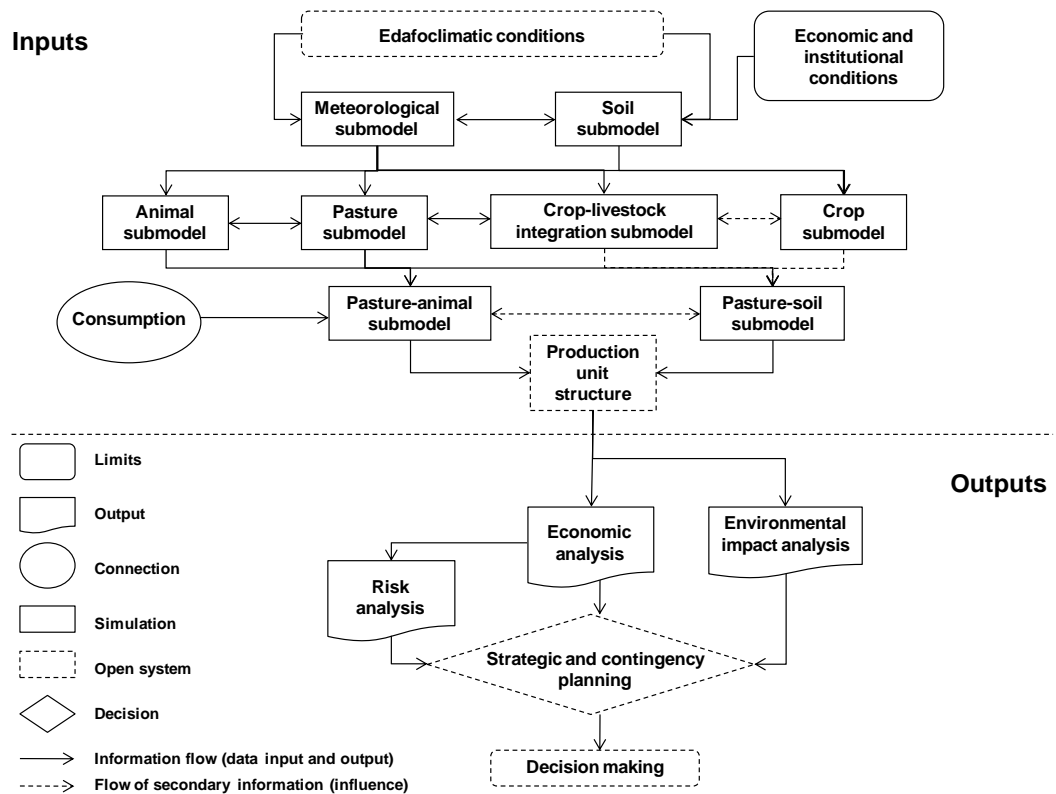


Figure 1. Bioeconomic macro model of decision support system for farm management

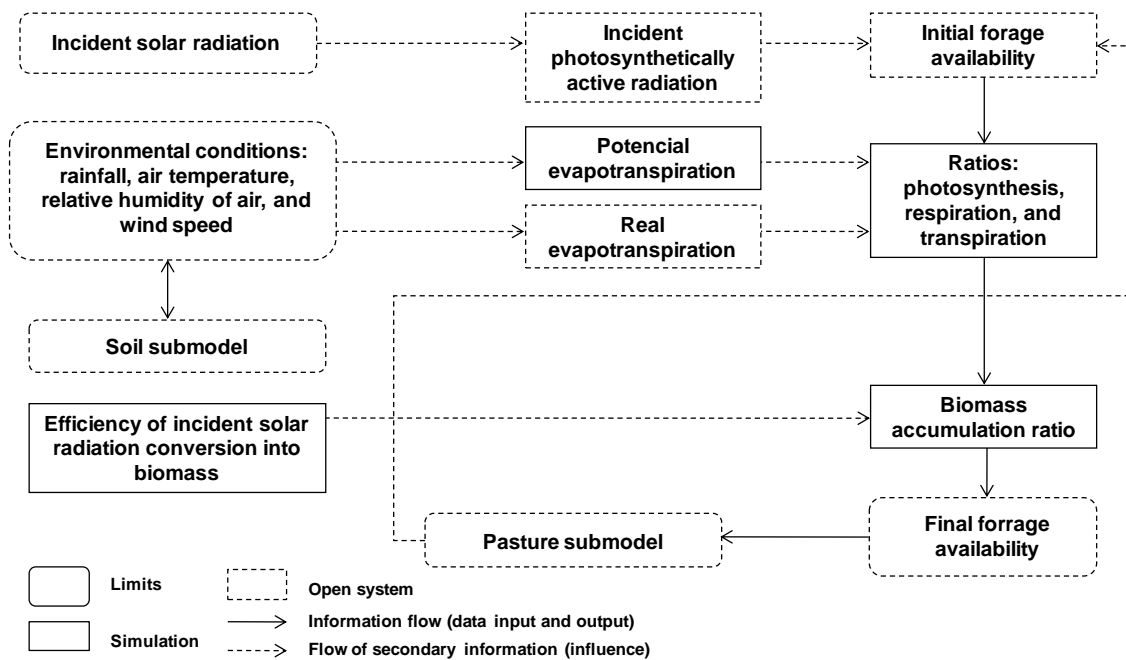


Figure 2. Meteorological submodel, adapted from Fonseca et al. (2007).

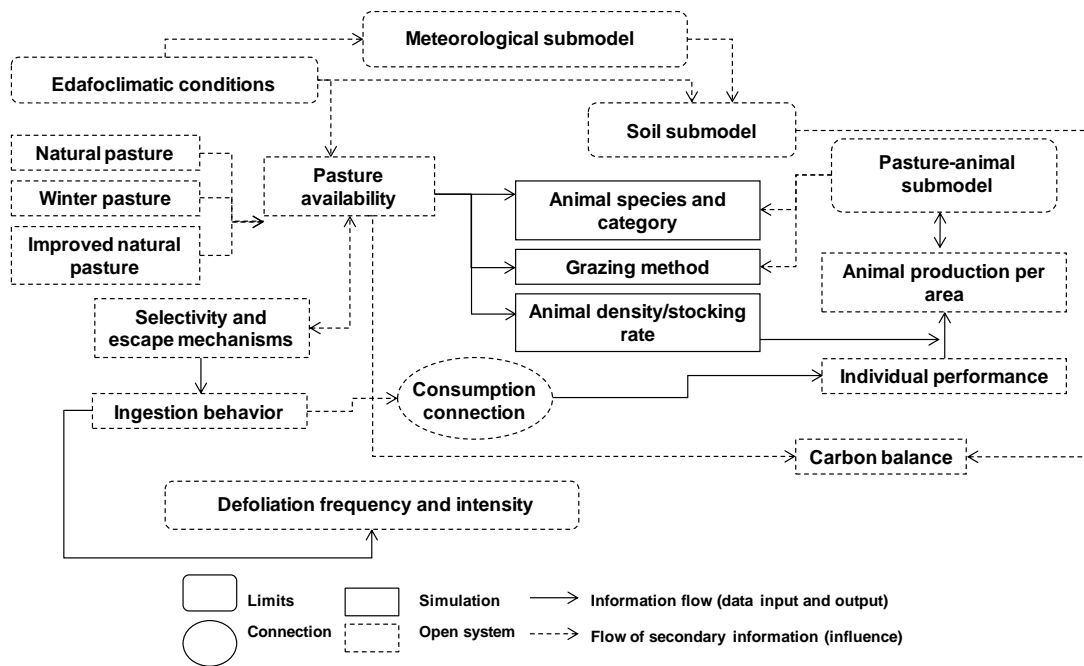


Figure 3. Pasture submodel, adapted from Nabinger and Carvalho (2009).

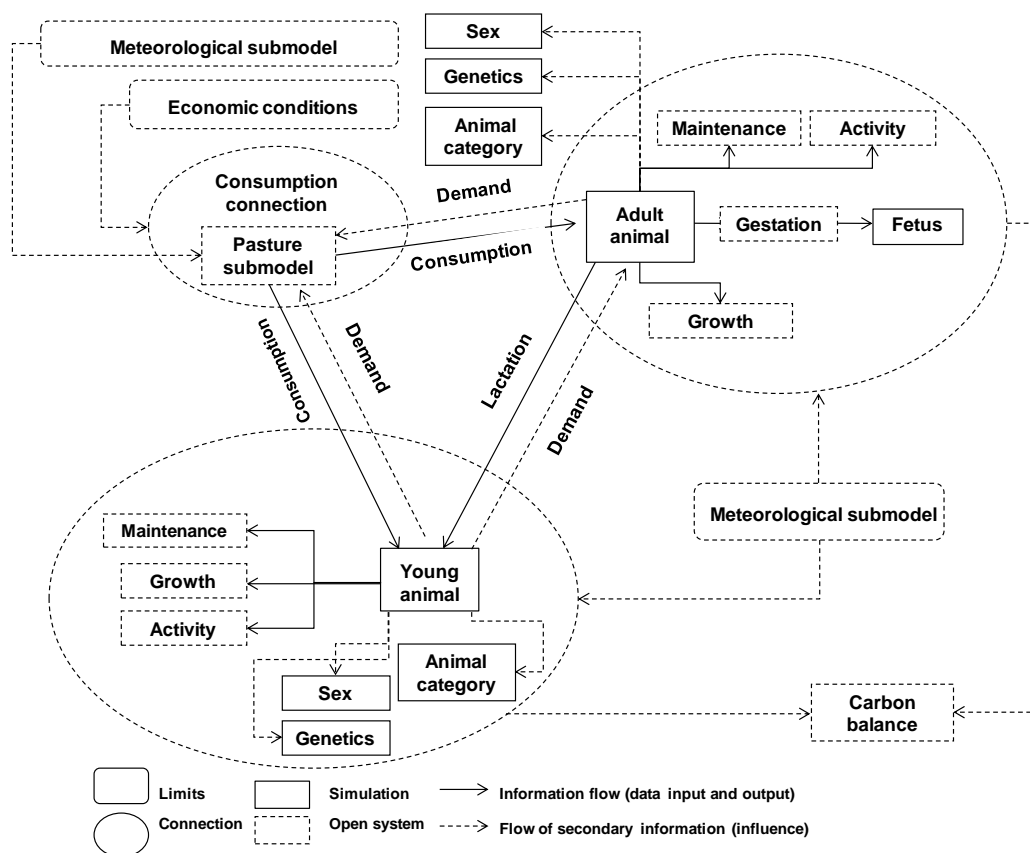


Figure 4. Animal submodel, adapted from Vetharanim et al. (2009).

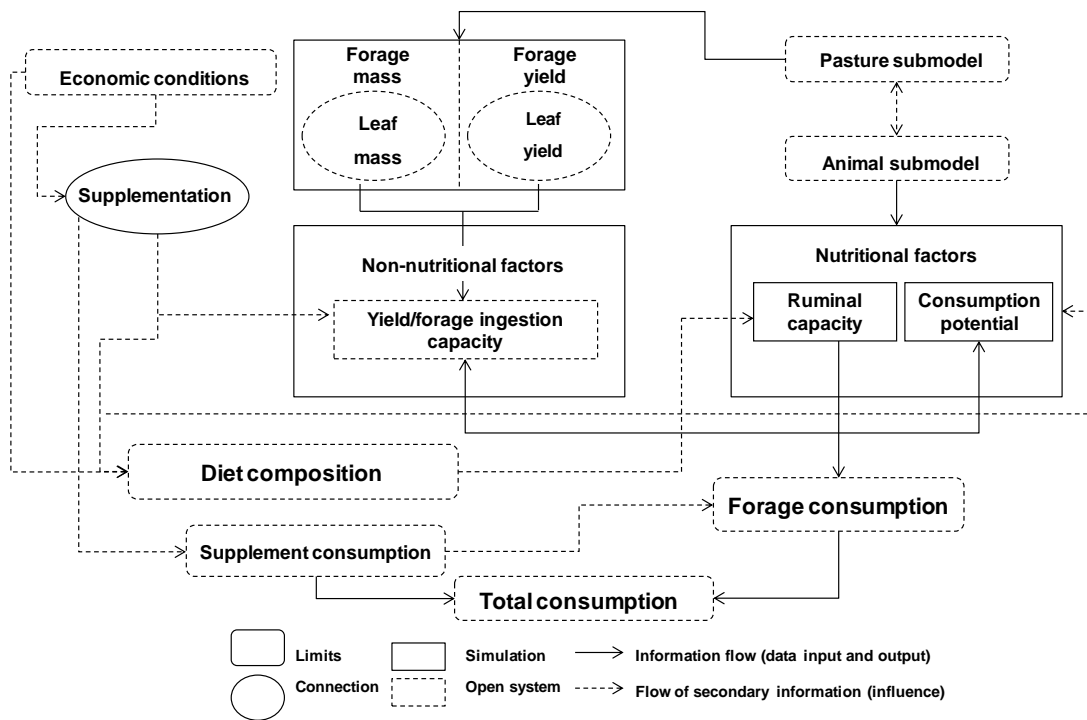


Figure 5. Connection consumption, adapted from Machado (2004).

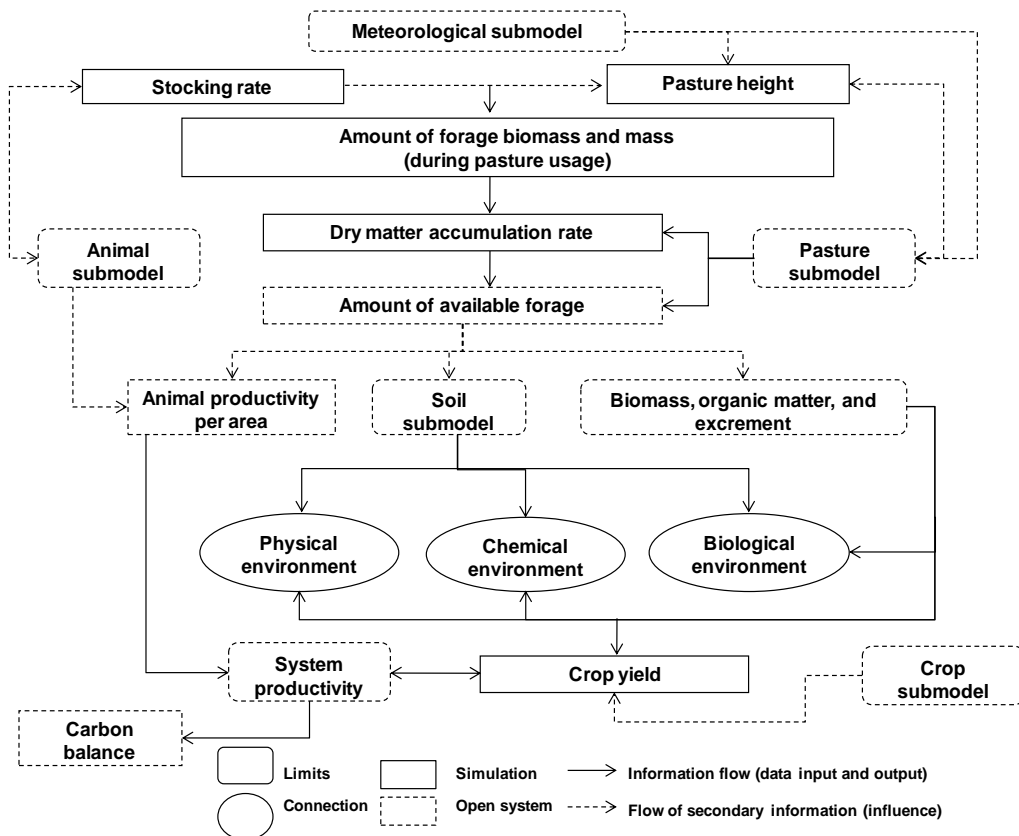


Figure 6. Crop-livestock integration submodel, adapted from Cassol (2003).

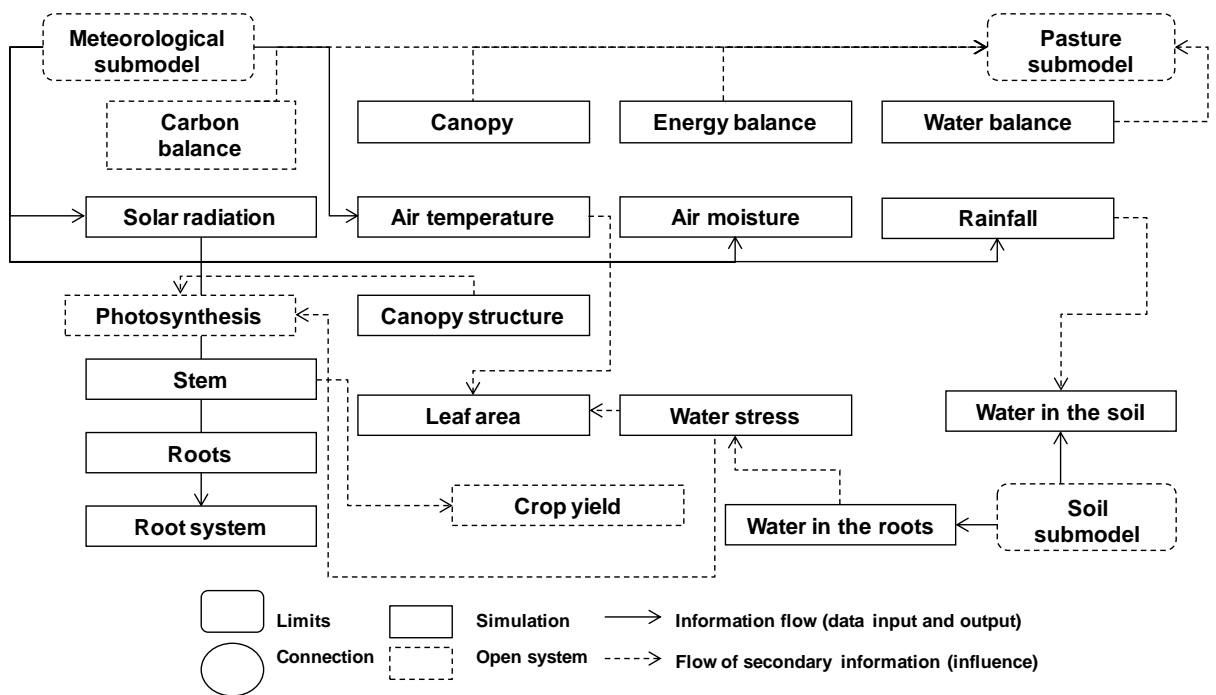


Figure 7. Crop submodel, adapted from Inman-Bamber (1994).

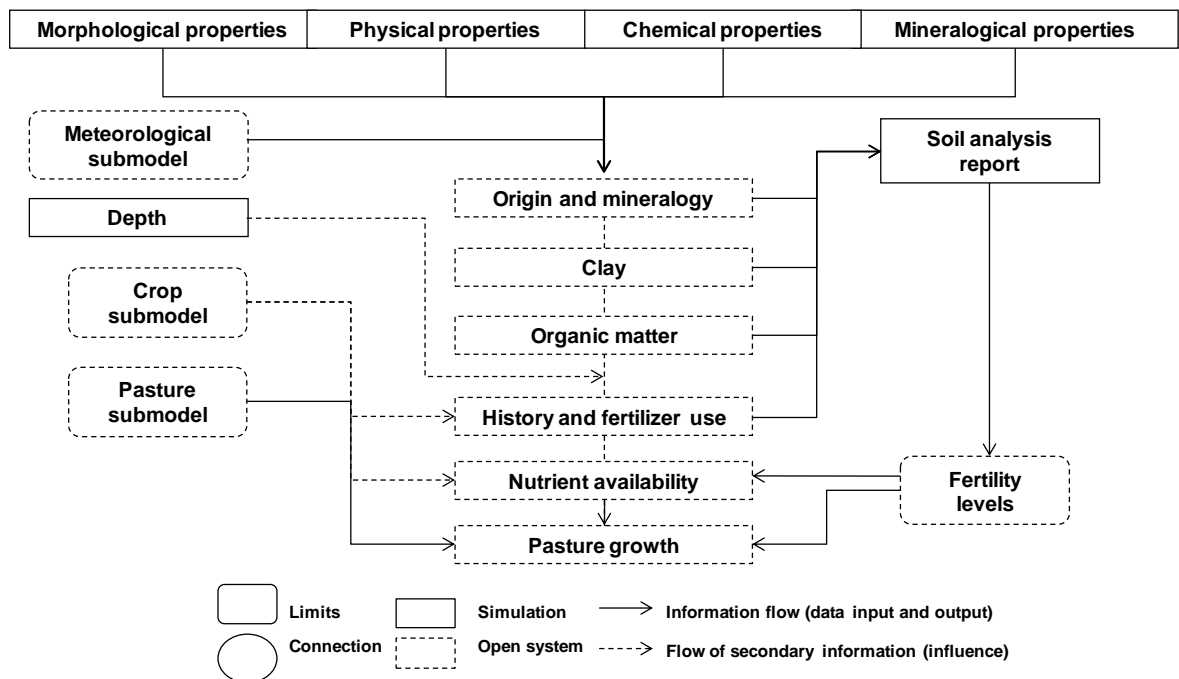


Figure 8. Soil submodel, adapted from Matthews (2006).

Table 1. Economic and environmental indicators.

Indicator	Objective	Focus	Description	Unit of measurement	Formula	Periodicity of evaluation
Balanced income (BI)	Balance income and cost according to production seasonality	Evaluate frequency of product sales when prices are high	Quantifies the average price (P_x) in relation maximum price (P_{max}) on the market	%	$BI = (P_x/P_{max}) * 100$	Annual
Cash flow efficiency (CFE)	Strategically negotiate products	Evaluate efficiency to minimize monthly deficits	Represents the participation of monthly deficits (MD) in total inputs (TI) of cash flow	%	$CFE = (\sum MD/TI) * 100$	Annual
Marginal profit (MP)	Reduce the projects payback period and enhance profitability	Evaluate system historical profit trend	Evaluates profit trend [$Pr = \{[(Gross\ income/Operating\ costs) - 1] \times 100\}$ over time	%	$MP = \Delta Pr/\Delta Time$	Annual
Waste (WI)	Reduce operating costs by reducing loss	Monitor waste of production inputs	Weight storage and use of fertilizers (S – soil), chemicals (P – plant), and veterinary products (A – animal), through this scale: 1 (unsatisfactory), 2 (partly satisfactory), 3 (regular), 4 (satisfactory), and 5 (totally satisfactory)	–	$WI = (S + P + A)/(scale\ 1\ to\ 5)$	Bimonthly

Risk index (RI)	Evaluate variable income and market risks	Evaluate income distribution among the commercialized products	Describes and analyzes production diversification and quantifies profit	–	Subjective evaluation of risk from 0 to 1, through graphic analyses of market trend of commercialized products	Annual
Land use efficiency (LUE)	Evaluate opportunity cost	Evaluate the capacity of the enterprise to generate return higher than the opportunity cost of land use	Measures the range between net profit (NP = Total income – Total cost) and opportunity cost of land (OCL)	%	$UT = [(NP - OCL)/OCL] * 100$	Annual
Carbon balance (CB)	Evaluate carbon flow in the system	Evaluate the system capacity to mitigate the action of greenhouse gases	Monitors the balance between carbon fixation (CF) and carbon emission (CE) by the system, evidencing the effects on biodiversity and environmental sustainability	ton	$CB = CF - CE$	Annual

CAPÍTULO III³

³Artigo submetido ao periódico *Agricultural Systems*.

**Bioeconomic model of decision support system for farm management. Part II:
Mathematical model development**

Soraya Tanure^{a*}, Carlos Nabinger^a, João Luiz Becker^b

^a *Post-Graduate Program in Zootechny, Agronomy College, Universidade Federal do Rio Grande do Sul, Av. Bento Gonçalves, 7712, 91540-000, Porto Alegre, RS, Brazil*

^b *Post-Graduate Program in Administration, Administration School, Universidade Federal do Rio Grande do Sul, Rua Washington Luiz, 855, 90010-460, Porto Alegre, RS, Brazil*

* Corresponding author. Tel.: +55 (51) 3308 7406; fax: +55 (51) 3308 6048.

E-mail address: sorayat@terra.com.br (S. Tanure).

ABSTRACT

The declining profitability of agriculture and livestock production, increasing climatic variations, and growing concern over the environmental impact of farming pose complex challenges for farm management. These challenges have prompted a search for ways to incorporate knowledge into tools in order to help farmers take more accurate managerial decisions. In this context, we developed a generalized mathematical bioeconomic macro model for livestock production systems. The development of the model is the result of a multidisciplinary effort to integrate major databases of biological knowledge – climate, soil, plants, animals – and their economic aspects, in search for the representation of a livestock production similar to Brazilian systems of pasture-based beef cattle production. This work is divided into four submodels: (i) herd structure and animal characteristics; (ii) animal nutrient requirements; (iii) meteorological-soil-pasture-animal integration; and (iv) economic. We adopted the system dynamics modeling methodology, composed of differential and integral equations in structured iThink 9.1.4 software. The equations herein proposed were adapted from pre-existing studies and the contributions of this study are the inclusion of the equations into a macro model in a near future and their use to build different scenarios based on real data coupled with a judicious validation process.

Keywords: Bioeconomic model; Decision making; Farm production modeling; Livestock production systems; Mathematical framework; System dynamics modeling.

Highlights

> We model a decision support system for livestock production. > The model is based on mathematical equations to describe livestock systems. > The integration of equations represents farm structure and generates the outputs. > The model output is based on economic analyses.

1. Introduction

Farm management stands for more than just looking after various grain crops, pastures, and herds (Fisher et al., 2000). In the range of operational, tactical, and strategic decisions, often used to classify levels of planning, producers have to cover the whole management field of production, market, and finance (Hardaker and Lien, 2010; King et al., 2010). In this context, it is of fundamental importance to adopt decision support systems capable of generating models to guide the business.

A decision support system is a computer system that provides information on a given domain of application by means of analytical decision models and access to databases, in order to support a decision maker to effectively deal with complex tasks (Senge and Sterman, 1992). Modeling and systems analysis attempt to integrate, interpret, and gather scientific information from several sources in such a way that this can be directly applied to a decision making process (Štůsek and Ulrych, 2008).

Mathematical programming is a methodology typically used to model agricultural systems. It consists of modeling strategies and biological processes of agricultural systems and simulating the interactions between them (Cros et al., 2004). Farming systems modeling is a useful aspect of this research, allowing the probable value of new management systems and technologies to be gauged before being implemented or developed (Jakku and Thorburn, 2010). Additionally, modeling can identify gaps in knowledge and thus improve rank prioritizes in research (Nabinger, 1996; Senge and Sterman, 1992).

Among the examples of mathematical programming models available in the

literature, changes in animal properties (Rotz et al., 2005; Tess and Kolstad, 2000) and pasture properties (Cros et al., 2004) have been investigated with respect to their impacts on farm production. Although most of these models have been developed to provide decisions and describe agricultural systems with high academic and scientific merit, they are not producer friendly (Musshoff and Hirschauer, 2007), because producers' way of thinking does not operate on the same knowledge basis as that of researchers (Nuthall, 2012).

Research is needed to develop the necessary methodology to evaluate and compare alternative management strategies under a set of available resources. It is often difficult and expensive to collect all the data required to develop a system for evaluating bioeconomic efficiency (Pang et al., 1999) aiming to provide high quality information to producers.

The difficulty for producers lies more in finding and selecting the relevant information needed to deal with their routine problems and to adapt it to better manage their farms. Producers have to systematically rethink their information requirements and weigh up costs, values, and alternative sources of information (Magne et al., 2010). This situation raises questions about the way farm management researchers have been modeling information (Slavik, 2004) and applying mathematical programming methodologies to studies that are too difficult to understand and, consequently, to be put into practice by producers during their decision making process.

Thus, to support producers in their decision making process, we developed a generalized mathematical model of livestock production systems. It should be noted that the model was developed based on data from the literature and, due to the

unavailability of suitable data, the model has not been validated yet. In a near future, we intend to validate all the mathematical equations that helped build the general model by applying them to real systems of livestock production, particularly in Brazilian systems of pasture-based beef cattle production.

We briefly review mathematical modeling for farm management and then analyze the general model, the submodels, and their respective inputs and mathematical equations. After that, we describe the economic analysis and discuss the practical benefits and the implications of using decision support systems.

2. Mathematical modeling in farm management

Given the difficulties for the adoption of quantitative techniques and systems analysis for the primary sector, most researchers adopt a deductive approach, based on diagnostic descriptions, usually qualitative, using historical trends, extrapolation of experimental results, and case studies, generating few results applicable to producers' reality (Gouttenoire et al., 2011).

The use of census data, edaphoclimatic and quantitative surveys, coupled with mathematical models of integrated analysis, provides greater accuracy and reliability to studies that aim to develop strategies and action plans for the primary sector through prognostic and predictive research (Annetts and Audsley, 2002; Happe et al., 2011).

Optimal decisions can be supported by the use of mathematical modeling (Sterman, 2001). In a nutshell, a mathematical model is a simplified representation of

a system aiming to detect the quantitative relationships between variables and predict the effects of their changes, aiming to achieve accuracy and tractability (Plà, 2007).

Methodologically, mathematical modeling applied to farm management can be divided into optimization and simulation models. Optimization models allow determining optimal outcomes given the objective function of expected utility or profit that is maximized subject to production alternatives, prices, and resources availability (Nabinger, 1996). Simulation models are developed mainly to improve the understanding of the systems by studying their behavior under different conditions, and also to calculate their expected utility according to a given number of parameters and decision rules (Moghaddam and DePuy, 2011). Simulation models are used to determine “optimal” strategies aiming to find the optimal set of decision rules given the precision of current knowledge about the parameters (Plà, 2007).

Recently, great advances have been achieved in the capacity to store information from heterogeneous sources, as well as in the evolution of mathematical models capable of integrating both biological and economic analyses and promoting more comprehensive results (Fisher et al., 2000).

Bioeconomic models detail biotechnical specifications and simulate producers' decisions assuming that they make their decisions in order to optimize their objective function (Janssen and van Ittersum, 2007). Some dynamic bioeconomic livestock models have been built to assess impacts of weather (Finger et al., 2010) or price risks (Hardaker and Lien, 2010; Malan et al., 2010) on farms. However, few authors (Austin et al., 1998; Pang et al., 1999) have already simulated shock impacts when taking simultaneously into account the possibility of adjusting animal weight, herd

size, crop product, and land use, given that livestock production systems are particularly complex.

Livestock modeling concerns systems defined by different boundaries, from an animal to a production unit or even a whole farm (Ferreira, 1997). These systems can be analyzed from different disciplinary viewpoints, resulting in different ways of assessing and supporting changes (Gouttenoire et al., 2011). Modeling real world situations, these systems process data supplied and give back information that merely facilitates users' decision making (French et al., 2011).

Modeling and systems analysis attempt to integrate, interpret, and apply scientific information from several fields in such a way that these data can be directly applied to decision making processes. As science advances, the need for integration and interpretation continues (Tess and Kolstad, 2000).

3. Research method

The research of any production system necessarily involves understanding both the production process and how it works. Nevertheless, only knowledge of the major variables responsible for the characteristics of the system is not sufficient, since it is also necessary to understand how these variables behave over time and generate structural relationships in the system (Sterman, 2000; 2001).

For animal production systems, this fact assumes greater significance due to the complexity of biological environments and production cycles, which usually occur on different time scales for each animal or plant species evaluated. Thus, a model for

livestock production systems should be part of the strategic planning and developed according to its main variables, with the aid of secondary variables in the simulation of events, aiming to represent a situation consistent with the reality of that production unit (Hardaker and Lien, 2010).

System dynamics is a methodology that can help the construction of models applicable to reality, since it uses concepts of dynamic simulation and aims to assist researchers to understand and discuss complex systems in order to gather knowledge and detect strengths and weaknesses of the business to solve problems (Senge and Sterman, 1992). In this context, this paper adopts the methodology and modeling technique named system dynamics (Sterman, 2000), and presents a mathematical model composed of differential and integral equations in structured iThink 9.1.4 software (iSee Systems, Inc., USA), which is able to represent the operation of a livestock production unit, as detailed below.

3.1. Model overview

The development of the bioeconomic macro model herein presented is the result of a multidisciplinary effort to integrate the major databases of biological knowledge, i.e., climate, soil, plants, and animals, as well as their economic aspects to represent a livestock production system similar to Brazilian pasture-based beef cattle production systems. To facilitate the understanding of animal production systems, and especially the development of the macro model, this work is divided into four submodels: (i) herd structure and animal characteristics; (ii) animal nutrient

requirements; (iii) meteorological-soil-pasture-animal integration; and (iv) economic. The first three submodels are the inputs of the macro model, while the economic submodel presents the main outputs and assists producers in making their decisions. However, for the general model to work seamlessly, each submodel should have specific inputs and outputs, as detailed in subsequent sections.

These submodels were developed based on mathematical equations adapted from a number of pre-existing studies, which enabled the construction of an extensive survey allowing the interaction with several different data sources and diverse experimental realities. It should be noted that many changes and restrictions have been incorporated into the proposed model in order to maintain the logic, the similarity with the Brazilian beef cattle production systems, and, especially, the applicability to real systems.

The integration of the equations and the general functioning of the system, based on inputs and outputs of the submodels, were optimized using the iThink 9.1.4 software, which presents a friendly interface and uses the system dynamics methodology for interaction between stock and flow variables (Sterman, 2000). Stocks are accumulations, i.e., they represent quantities measured or evaluated over time and characterize the state of the system, whereas flows can connect stocks or introduce exogenous elements into the systems (Senge and Sterman, 1992; Sterman, 2001).

The models presented in this paper are predominantly quantitative, and their variables can be quantified and analyzed in future studies. Moreover, this research can be classified as explanatory and aimed to identify the causal relationships between the proposed macro model and subsystems.

4. Results

4.1 Decision support bioeconomic model for livestock systems

Throughout this research, the operation of a rural enterprise is confirmed to be the result of a complex structure consisting of several interdependent variables. However, even if the producer chooses a limited view of the business and takes into consideration only his own productive unit, the main variables used to make the decisions will continue forming a complex environment, in which resources (inputs), technologies, and empirical and intrinsic information to the business are the most important factors (French et al., 2011). Thus, regardless of the view adopted by producers, either systemic or limited, it is necessary and urgent to use tools that are able to help organize the information flow, pinpoint key decision variables, and, especially, guide rural business management (Ferreira, 1997; Jakku and Thorburn, 2010).

The bioeconomic macro model proposed in this research (Fig. 1) presents the main constituent elements (and the details of the variables) of a livestock production unit and identifies the inputs, outputs, and key points of each element in order to map the environment for the decision making process.

The union of the main bases of biological knowledge, in terms of meteorological element, soil element, pasture element, and animal element, originates the submodel “integration”, presented in another section. The objective of this submodel is to gather a high number of relevant variables, which provide

producers with a logical and coherent information flow for their production environments, thereby facilitating their decision making. To this end, each element has key points, called stocks. Illustratively, the stocks are presented as simple squares that represent information storage, or as hatched squares (stocks conveyors) with the function of transporting information between the elements of the system (Sterman, 2000).

For instance, the meteorological element has two key points, symbolized by the incident solar radiation and the potential evapotranspiration stocks. These stocks illustrate, respectively, the storage and the information flow and represent the main entries of the pasture element. Nonetheless, in order to have information exchange and, consequently, interaction between the elements of the system, flow and converter symbols were also used. The flows are represented by wide arrows connecting stocks, while the converters, also called auxiliary variables, are represented by circles (Sterman, 2000; 2001). Thus, forage availability (initial and final), key points of the pasture element are connected by the exchange of information on the flow of total aerial biomass and have interrelationships with soil and animal elements.

The stock named soil fertility level, which belongs to the soil element, corresponds to one of the main entries to forage final availability, and gathers the information exchange between two mainstreams: (i) soil nutrient availability without the use of any amendments (availability of endogenous or natural fertility) and (ii) soil nutrient availability after the use of any methods of fertilization (exogenous availability). On the other hand, the animal element influences on stocks of forage availability due to the balance between the flows of pasture growth (represented by

aerial biomass accumulation), forage consumption, and animal nutrient demand, for young and adult animal stocks.

Due to the complexity of animal physiology and the difficulty building models that are similar to the reality of several animal categories in terms of growth and reproduction, in this study, a high number of flows and converters were incorporated into young and adult animals stocks, because they are able to assist the flow of information between the animal element and the other elements of the macro model. Moreover, considering the complexity of the animal element, this study proposes specific submodels to analyze the characteristics of the herd and the adjustment between consumption and nutrient demand, both presented in subsequent sections.

Finally, the macro model presents the main outputs, represented by the economic analysis and balance between productivity of system elements and market rates, as well as by the producer decision making. This set of information allows producers and managers to decide what, how, and when to produce, within a strategic planning that aims primarily to analyze future scenarios and thus avoid possible losses.

4.2 Herd structure and animal characteristics submodel

Herd structure, characterized by different animal categories, is one of the key points for achieving a good operational level with the decision support system in livestock production. The correct organization of this structure is crucial and decisive for the synergy between herd evolution and generation of reliable results. In the

present work, the division of the herd in different categories was based on characteristics related to age (from newborn to mature, 9 years old for females, and slaughter for males), sex (females, males, and castrated males), genetic group (European or British, Zebu, and crosses) and goal production (replacement or slaughter) for each animal category.

In addition, we adopted the calving period between September and December, with the weaning of the respective calves concentrated between February and April of the following year and, finally, the mating season between November and January (Fig. 2).

Therefore, objectively, the herd was divided into the following categories: (i) male calves from birth to weaning; (ii) female calves from birth to weaning; (iii) females weaned until one year of age (rearing); (iv) heifers from 1 to 2 years of age (primiparous); (v) males weaned until 1 year of age (rearing); (vi) steers from 1 to 2 years of age; (vii) cows from 3 to 9 years of age (multiparous); (viii) steers from 3 years of age on (slaughter); and (ix) bulls.

The animals may change from one category to another in two moments of each year: (i) in April, when the calves are weaned; and (ii) at the end of the calving period, in December, due to the natural aging process (the number of 1-year-old heifers at the end of a year is the initial number of 2-year-old heifers the following year), the reproductive objectives (the number of calves depends on the number of mated cows), and the fattening objectives.

To determine the number of animals in each category, we adapted the equation originally proposed by Mosnier et al. (2009), in which the number of animals

is determined according to the function f . For each month (p) of the year (t) and the animal category (a), this function presents the balance between the number of animals in the production unit (NB), sales decisions ($ASold$), purchase decisions ($ABought$), and mortality ($mort$):

$$NB_{a,t,p-1} = \int_{p-1} (\cdot) = NB_{a,t,p-1} \times (1 - mort_{a,t,p-1}) - ASold_{a,t,p-1} + ABought_{a,t,p-1} \quad (1)$$

After organizing the herd structure and determining the number of animals in each category, inventory and its key equation (Equation 1) are used to evaluate four basic pillars of the operation of animal production system (Pang et al., 1999): (i) simulate the change in category of animals according to the age groups in the herd; (ii) predict the number of animals for replacement and slaughter based on the planned expansion or reduction of the herd; (iii) simulate the number of slaughtered animals and weaned calves available in each category and in the whole herd; and (iv) estimate the nutrient requirements for the herd.

It should also be clear that the herd submodel is designed to evaluate a complete cycle of livestock production, with three distinct stages: suckling, rearing, and finishing. However, the submodel can be retrofitted and modeled for different production systems, including only one or two stages of production, according to the producer objective and the reality of the environment where the system is developed.

Therefore, with the knowledge of herd structure and characteristics of animals that compose it, the variables can be integrated, simulating different production systems able to predict outcomes to support the producers' decision making process. Nonetheless, considering only the characteristics of the herd, the results generated by the models will be highly limited. After all, the reality of livestock production

systems is strongly influenced by the environment where the activity is developed and their interrelationships with pasture, soil, and animal management. Considering the importance of these interrelationships, the dynamic of the system is the main point of this research, having originated animal nutrient requirement and meteorological-soil-pasture-animal integration submodels, both presented below, as multidisciplinary data analysis tools and decision support systems for farm management.

4.3 Animal nutrient requirement submodel

Considerable research has been conducted to evaluate effects of nutrient requirements, specially protein and energy, on feed intake and rate of gain (Lanna et al., 1999; Nousiainen et al., 2011; Vetharanim et al., 2009). Nevertheless, factors that regulate ruminant feed intake are complex and not fully understood (Cros et al., 2004; Fox et al., 1995; Rotz et al., 2005). Accurate estimates of feed intake are vital to equations for predicting the nutrient requirements of beef cattle (NRC, 1996). The routine evaluation of diets, including costs, animal performance, and environmental conditions to a particular farm, is fundamental to the process of making appropriate decisions on managing the herd (Pang et al., 1999). Aiming to facilitate making decisions about the nutritional management of the herd, as well as to represent the relationship between the consumption capacity and the nutritional demand of each animal category, the proposed nutritional requirement submodel uses the concept of “metabolic demand” (Vetharanim et al., 2009) and adjusts the equations originally

presented by NRC (1996) to calculate the impact of the diet on animal performance.

Metabolic demand is defined as the maximum daily utilization of metabolizable energy (ME) by a ruminant, if the energy intake is unconstrained by rumen capacity, satisfaction, or diet availability. Thus, the metabolic demand was moderated by a function reflecting rumen-fill and satiation effects on appetite to produce an energy-intake demand that the ruminant would attempt to meet by foraging (Vetharaniam et al., 2009).

The efficiency of utilization of ME for maintenance is calculated as the ratio of net energy for maintenance (NE_m) to ME_m (Equation 2; NRC, 1996). The NE_m requirements for beef cattle production are estimated as follows (NRC, 1996):

$$NE_m = 0.077 \text{Mcal/EBW}^{0.75} \quad (2)$$

Where EBW is the average empty body weight in kilograms. Effects of activity and environment are implicitly incorporated into NE_m in this system. Similarly, influences of increased diet during the feeding period, altered activity, or environment effects differing from those at maintenance can also be addressed (Fox et al., 1995; NRC, 1996).

Although the nutritional requirements are critical to animal performance evaluation and prediction of dietary demands of the herd, consumption is also strongly influenced by matters outside the energy balance of the diets (Machado, 2004; Wilman et al., 1996). Thus, considering the impact of external factors such as sex, animal category, type of vegetation and soil, and especially the interaction climate-pasture-animal, this study presents an integrated meteorological-soil-pasture-animal submodel capable of bringing very sensitive variables to the system, aiming to

understand the coexistence and interaction of relevant elements in the livestock production unit.

4.4 Meteorological-soil-pasture-animal integration submodel

Agrometeorological models represent, in a simplified way, the relationship between physiological responses of plants and environmental conditions (Bryant et al., 2008; Fonseca et al., 2006; Maas, 1993), as well as animal management observed during different phenological stages of vegetation (Ferreira, 1997; Nabinger and Carvalho, 2009). Matching herbage mass and nutritional requirements of grazing animals is one of the key challenges producers have to face (Fox et al., 1995; Machado, 2004; Wilman et al., 1996).

Based on simplifications and theoretical adaptations of the model originally proposed by Fonseca et al. (2007), as well as the incorporation of some physiological characteristics of grazing animals (Vetharaniem et al., 2009), the meteorological-soil-pasture-animal integration submodel predicts pasture growth rate, cattle grazing rate, pasture yield and quality, stocking rate, and total area required for a herd, based on three different types of pasture: natural, winter, and improved natural pasture. It must be noted that the submodel and its equations are similar for all crops, because the variables that are relevant for their growth are identical, although they assume different values in each type of pasture. This submodel was developed to represent the vegetation reality of farms and livestock production units in southern Brazil, aiming to establish parameters for animal stocking rate in order to maintain the

natural diversity of species and economic exploration of vegetation.

The first step of the integration submodel is the equation to determine the maximum forage accumulation (or potential) in a given period of time (t) based on the knowledge of the photosynthetically active radiation (PAR_i) and considering the availability of existing or initial forage (AF₀):

$$AF/t = f(AF_0, PAR_i) \quad (3)$$

The final availability of forage is a function of AF₀ at time t = 0 and the growth of pasture during the time between 0 and n days, derived from the integration of the daily dry matter accumulation (A_{DM}) as follows:

$$AF_n = AF_0 + \int_{t=0}^n A_{DM} t \quad (4)$$

The daily rate of dry matter accumulation is a function of the PAR_i on the canopy, in the time interval between 0 and n days, and the conversion efficiency of the incident radiation in aerial biomass (ε_{CA}):

$$\int_0^n A_{DM} t = \epsilon_{CA} \sum_{t=0}^n PAR_i \quad (5)$$

Thus, replacing the integration of the biomass aerial accumulation during a determined time (Equation 5), we obtained the estimation of the final potential forage availability at a given time, considering:

$$AF_n = AF_0 + \epsilon_{CA} \sum_{t=0}^n PAR_i \quad (6)$$

To develop a real model of forage production which estimates the real amount of forage that the grassland can produce in a given period of time (t), it is necessary

to know the limitation of the biomass accumulation that may occur due to a hydric deficit (Maas, 1993). We used the ratio between real evapotranspiration (RET) and potential evapotranspiration (PET) for the composition of a hydric index to represent the water availability in the soil-plant-atmosphere system (Fonseca et al., 2007), since the real productivity of the grassland is directly related to the hydric status of the plant (Finger et al., 2010; Moore et al., 2011). The ratio RET/PET has a finite range between 0 and 1 and tends to zero because real evaporation is lower than potential evaporation (Fonseca et al., 2007).

Thus, when the hydric index is introduced in the equation to calculate potential production, it is possible to simulate the decrease in forage production caused by hydric deficit, resulting in the estimate of real aerial biomass of the canopy:

$$AF_n = \left(DF_0 + \varepsilon_{ca} \sum_{t=0}^n PAR_i \right) \times RET/PET \quad (7)$$

However, pasture growth and total yield (forage biomass) are affected not only by meteorological characteristics, but also by soil characteristics (Islam and Weil, 2000) and cattle grazing rate (Gonçalves et al., 2009).

From a practical perspective, soil fertility levels in terms of macro and microelements do not affect pasture protein and digestibility (Bryant et al., 2011). On the other hand, in case they are deficient, this can directly affect pasture yield. In perennial pastures and hay fields, inadequate soil fertility levels probably have the major economic impact not only on forage yield but also on pasture persistence and longevity (Nabinger and Carvalho, 2009).

Due to the importance of soil fertility levels, the element soil is also discussed

in this paper. The inclusion of the soil element in the model proposed by Fonseca et al. (2007) occurs in a subliminal way, since the values of the input meteorological variables shift according to different types of soil, consequently generating different impacts on the values of the output variable forage availability.

However, in addition to the impact that soil type causes on grass growth, it is also necessary to include it in the general assessment to map the pastoral environment. Therefore, in this research, cation exchange capacity (CEC) at pH 7.0 is considered an indicator of fertility to map the type of soil due to the readily availability of this traditional data in analysis reports. CEC is calculated by adding the cations that have a basic reaction (Ca^{2+} , Mg^{2+} , K^+ , and Na^+) and the acidic cations (H^+ + Al^{3+}), in $\text{cmol}_c/\text{dm}^3$ of dry soil (Chapman, 1965):

$$\text{CTC}_{\text{pH}7.0} = \text{Ca}^{2+} + \text{Mg}^{2+} + \text{K}^+ + \text{Na}^+ + (\text{H}^+ + \text{Al}^{3+}) \quad (8)$$

Based on the results of Equation 8, in this research, low, medium, and high levels of fertility were taken into consideration and combined with their ranges of $\text{CEC}_{\text{pH}7.0}$ ($\leq 5.0 \text{ cmol}_c/\text{dm}^3$, 5.1 to 15.0 $\text{cmol}_c/\text{dm}^3$, and $> 15.0 \text{ cmol}_c/\text{dm}^3$, respectively), in order to assess the soil type and detect possible needs for nutrient correction.

Furthermore, it is necessary to consider the rate of pasture defoliation (grazing intensity) as an important factor that causes impact and determines variation in pasture growth. The rate of pasture defoliation increases as forage biomass increases and reaches a plateau when animal consumption potential is maximum. As forage biomass is reduced, forage intake per animal also declines because of low forage availability. So, adapting the approach of Machado (2004), in Fig. 3, forage

biomass is divided into leaf (L), stem (S), and dead material (D), and these sward components are assumed to be selected by the animals according to the sequence $L > S > D$ (Nielsen et al., 2003).

According to Johnson and Parsons (1985), the proportions of the three sward components under continuous grazing are described as:

$$\text{Sel}_L = Lk_1 / (Lk_1 + Sk_2 + Dk_3) \quad (9)$$

$$\text{Sel}_{St} = Sk_2 / (Lk_1 + Sk_2 + Dk_3) \quad (10)$$

$$\text{Sel}_D = Dk_3 / (Lk_1 + Sk_2 + Dk_3) \quad (11)$$

Where Sel_L , Sel_{St} , and Sel_D are the proportions of leaf, stem, and dead components of the diet, and L, St, and D represent kilograms of dry matter per hectare (kg DM ha^{-1}) of leaf, stem, and dead forage biomass above ground level, respectively, while k_1 , k_2 , and k_3 , represent the level of preference for each component. These equations imply that grazing animals consume different proportions of leaf, stem, and dead material (L%, St%, and D%, respectively), based on the level of selectivity and the preference parameters for each sward component (Machado, 2004).

Therefore, the cattle grazing rate (GR) is estimated as follows (Pang et al., 1999):

$$\text{GR} = \text{DMI}_m \times \left[\frac{Y}{Y + Y_{50}} \right] \quad (12)$$

Where DMI_m is the maximum dry matter intake of cattle in 1 hectare based on nutrient requirements (kg ha^{-1}), Y is the forage biomass or yield (kg ha^{-1}), and Y_{50} is the forage biomass at half of the maximum grazing rate (kg ha^{-1}). Finally, the cattle grazing rate associated with initial forage availability (AF_0 , input to the model

proposed by Fonseca et al. (2007), permits estimate the final forage availability, a variable that is a major output of the meteorological-soil-pasture-animal integration submodel and that leads to decision making.

When this submodel was finished, it was possible to note that one of its final variables (cattle grazing rate) is also an input variable for the supply of one of the first equations proposed in this research (initial forage availability). Therefore, it is clear the need for communication between all the proposed elements in an attempt to identify the key points of the systems in a way that is consistent with the reality. Furthermore, the knowledge of these key points allows the identification of the variables that have higher economic impact and, consequently, the financial analysis of the livestock production unit, presented in the next section.

4.5 Economic submodel

The new world economic order transformed the agricultural and livestock market in such a way that it is currently as complex as the other sectors of the economy, requiring a comprehensive view of the producer to administrate his business, particularly regarding the economic and financial control of the enterprise (Malan et al., 2010; Zott et al., 2011). The methodologies used by various companies in the primary sector are still based on empiricism and application of calculations established in other sectors of the economy, without taking into account the specificities of agribusiness (Tanure and Nabinger, 2010). Analyzing agribusiness as an industry without any particularity, and comparing it to other sectors of the

economy will certainly result in failure to determine the profitability of operations and, ultimately, the inefficiency of the business (Kulak et al., 2003).

Based on this and considering the difficulty of developing economic and financial control consistent with the reality of agriculture and livestock production, in this work the cash flow was adopted as the main tool for financial analysis, seeking the benefits of adaptability to the data available for most agricultural and livestock enterprises, especially the ones that are easily understood by farmers.

The economic submodel is derived from the analysis of cash flow, mathematically defined by the net cash flow for year t (NCF_t) (Pacheco and Morabito, 2011):

$$NCF_t = (R_t - OD_t - CO_t - A_t) \times (1 - \tau) + A_t \quad (13)$$

Where R_t is the gross revenue for year t , OD_t is the operating expenses in year t (variable costs of production, administration, and commerce), CO_t is the opportunity cost of capital assets (in this study, the rental value of land is taken into consideration), A_t is the depreciation in year t (considering livestock and farm implements or machinery), and τ is the tax rate of the enterprise income.

Even though cash flow is easy to understand, it requires a previous organization of the production system in order to access the main inputs and outputs of the production unit. Structuring activities that involve the gross revenue and the payment of expenses and documenting storage and proper training of the human resources involved in the process are crucial for the successful deployment and use of future cash flow (Austin et al., 1998; Pacheco and Morabito, 2011).

Therefore, it is clear that all equations considered in this study, whether

economic or biological representations, are the result of a set of reliable data, and especially the interrelationships between the data and the rural environment where the business is located. Otherwise, even if the submodels presented are applicable to reality, the absence of accurate data will result in arguably misleading results and decisions. The existence of reliable data will increase the accuracy of the model and allow consistent validation tests, so that in the near future this work will be applied to real agricultural and livestock production systems.

5. Validation

Validation is a process by which users (and readers) judge how well a model performs with regard to its intended uses. For some mathematical models, simulated results can be directly compared with experimental results using the same treatments, and statistics can be computed to conduct hypothesis tests regarding differences between simulated and experimental outputs (Tess and Kolstad, 2000). Harrison (1990) showed that statistical tests are often not appropriate for model validation and affirmed that subjective tests are more useful to build confidence in model performance. Gaining confidence in the model is generally a slow process, which occurs through model construction, validation, and application (Borenstein and Becker, 2001).

In the present model, all the equations were independently validated in many pre-existent studies. However, in the future, all the equations will be integrated and the model will be validated in a dynamic way, on farms and livestock production units,

to produce true results for all the elements involved in this production system.

6. Summary and conclusions

Bioeconomic modeling of processes is characterized by a high level of complexity, since all processes have a dynamic behavior and the interactions between the parameters and variables that describe a process change with time. The main difficulty of modeling and integrating biological and economic systems lies in defining the focus for modeling and mainly the level of detail that the model should address.

All models have weaknesses and most of them can produce unrealistic results when used improperly or when used to study problems beyond the model boundary. It is the researchers' responsibility to use tools that are appropriate for dealing with the problems studied. It is unlikely that a large model can be developed to study all beef problems. Models are tools and should be designed for specific purposes.

In management-oriented models, more emphasis is given to the techniques of decision analysis rather than the detailed representation of processes. Considering mathematical models a type of technology used to provide support to the decision making processes, they should simulate only the relevant responses to control the most important variables.

Although several studies on system dynamics methodology have been carried out in the last few years, they have not promoted the development of software tools that meet the needs of livestock production units and are able to build up farmers'

knowledge and computer skills. Hence, a more widespread use of model-based decision support methods at farm level demands a close cooperation between researchers, managers, and producers.

In this sense, we have developed a mathematical model of integration of differential and integral equations that is able to represent the operation of a livestock production unit, highlighting its main key elements. The equations presented here were adapted from pre-existing studies, so the challenge of this work is to integrate the equations in a macro model in the near future and use them to build different scenarios based on real data, coupled with a judicious validation process.

This research is part of a larger project, which began with the construction of theoretical models for decision making in livestock production units as well as the equations presented in this research. In a near future, we aim to integrate both works mentioned above in the simulation of real production scenarios.

The modeling process requires the integration and synthesis of scientific discoveries from several research areas. Since researchers tend to focus on specific areas, modeling efforts are extremely valuable in the application of basic research. Efforts to model biological systems highlight areas where information is lacking or incomplete. Consequently, this may be one of the most valuable contributions of systems research.

References

Annetts, J.E., Audsley, E., 2002. Multiple objective linear programming for environmental farm planning. *J. Oper. Res. Soc.* 53, 933–943.

- Austin, E.J., Willock, J., Deary, I.J., Gibson, G.J., Dent, J.B., Edwards-Jones, G., Morgan, O., Grieve, R., Sutherland, A., 1998. Empirical models of farmer behaviour using psychological, social and economic variables. Part I: linear modelling. *Agric. Syst.* 58, 203–224.
- Borenstein, D., Becker, J.L., 2001. Validating decision support systems, in: Kent, A., Williams, J.G. (Eds.), *Encyclopedia of microcomputers*. Marcel Dekker, New York, pp. 323–341.
- Bryant, J., Lopez-Villalobos, N., Holmes, C., Pryce, J., Rossi, J., MacDonald, K., 2008. Development and evaluation of a pastoral simulation model that predicts dairy cattle performance based on animal genotype and environmental sensitivity information. *Agric. Syst.* 97, 13–25.
- Bryant, J.R., Snow, V.O., Chicota, R., Jolly, B.H., 2011. The effect of situational variability in climate and soil, choice of animal type and N fertilisation level on nitrogen leaching from pastoral farming systems around Lake Taupo, New Zealand. *Agric. Syst.* 104, 271–280.
- Chapman, H.D., 1965. Cation-exchange capacity, in: Black, C.A. (Ed.), *Methods of soil analysis. Part 2: Chemical and microbiological properties*. American Society of Agronomy, Madison, pp. 891–901.
- Cros, M.J., Duru, M., Garcia, F., Martin-Clouaire, R., 2004. Simulating management strategies: the rotational grazing example. *Agric. Syst.* 80, 23–42.
- Ferreira, G., 1997. An evolutionary approach to farming decision making on extensive rangelands. PhD Thesis. Institute of Ecology and Resource Management, University of Edinburgh, Scotland.

- Finger, R., Lazzarotto, P., Calanca, P., 2010. Bio-economic assessment of climate change impacts on managed grassland production. *Agric. Syst.* 103, 666–674.
- Fisher, D.K., Norvell, J., Sonka, S., Nelson, M.J., 2000. Understanding technology adoption through system dynamics modeling: implications for agribusiness management. *Int. Food Agribus. Manag. Rev.* 3, 281–296.
- Fonseca, E.L., Ponzoni, F.J., Formaggio, A.R., 2007. Modelo agrometeorológico-espectral para estimativa da disponibilidade de forragem no bioma “campos sulinos”. *Rev. Bras. Agrometeorol.* 15, 241–249.
- Fonseca, E.L., Silveira, V.C.P., Salomoni, E., 2006. Eficiência de conversão da radiação fotossinteticamente ativa incidente em biomassa aérea da vegetação campestre natural no bioma Campos Sulinos do Brasil. *Ciênc. Rural* 36, 656–659.
- Fox, D.G., Barry, M.C., Pitt, R.E, Roseler, D.K., Stone, W.C., 1995. Application of the Cornell Net Carbohydrate and Protein model for cattle consuming forages. *J. Anim. Sci.* 73, 267–277.
- French, S., Bedford, T., Pollard, S.J.T., Soane, E., 2011. Human reliability analysis: A critique and review for managers. *Saf. Sci.* 49, 753–763.
- Gonçalves, E.N., Carvalho, P.C.F., Silva, C.E.G., Santos, D.T., Díaz, J.A.Q., Baggio, C., Nabinger, C., 2009. Relações planta-animal em ambiente pastoril heterogêneo: padrões de desfolhação e seleção de dietas. *Rev. Bras. Zootec.* 38, 611–617.
- Gouttenoire, L., Cournut, S., Ingrand, S., 2011. Modelling as a tool to redesign livestock farming systems: a literature review. *Animal* 5, 1957–1971.

- Happe, K., Hutchings, N.J., Dalgaard, T., Kellerman, K., 2011. Modelling the interactions between regional farming structure, nitrogen losses and environmental regulation. *Agric. Syst.* 104, 281–291.
- Hardaker, J.B., Lien, G., 2010. Probabilities for decision analysis in agriculture and rural resource economics: The need for a paradigm change. *Agric. Syst.* 103, 345–350.
- Harrison, S.R., 1990. Regression of a model on real-system output: an invalid test of model validity. *Agric. Syst.* 34, 183–190.
- Islam, K.R., Weil, R.R., 2000. Soil quality indicator properties in mid-Atlantic soils as influenced by conservation management. *J. Soil Water Conserv.* 55, 69–78.
- Jakku, E., Thorburn, P.J., 2010. A conceptual framework for guiding the participatory development of agricultural decision support systems. *Agric. Syst.* 103, 675–682.
- Janssen, S., van Ittersum, M.K., 2007. Assessing farm innovations and responses to policies: A review of bio-economic farm models. *Agric. Syst.* 94, 622–636.
- Johnson, I.R., Parsons, A.J., 1985. A theoretical analysis of grass growth under grazing. *J. Theor. Biol.* 112, 345–368.
- King, R.P., Boehlje, M., Cook, M.L., Sonka, S.T., 2010. Agribusiness economics and management. *Am. J. Agric. Econ.* 92, 554–570.
- Kulak, K., Wilton, J., Fox, G., Dekkers, J., 2003. Comparisons of economic values with and without risk for livestock trait improvement. *Livest. Prod. Sci.* 79, 183–191.
- Lanna, D.P.D., Tedeschi, L.O., Beltrame Filho, J.A., 1999. Modelos lineares e não-

- lineares de uso de nutrientes para formulação de dietas de ruminantes. *Sci. Agric.* 56, 479–488.
- Maas, S.J., 1993. Parameterized model of gramineous crop growth. I. Leaf area and dry mass simulation. *Agron. J.* 85, 348–353.
- Machado, C. F., 2004. Field and modelling studies of the effect of herbage allowance and maize grain feeding on animal performance in beef cattle finishing systems. PhD thesis. Massey University, Palmerston North, New Zealand.
- Magne, M.A., Cerf, M., Ingrand, S., 2010. A conceptual model of farmers' informational activity: a tool for improved support of livestock farming management. *Animal* 4, 842–852.
- Malan, D.J.C., Louw, A., Blignaut, C., 2010. Simulation analysis of risk management for a diversified commercial farm. *Agrekon: Agric. Econ. Res. Policy Pract. S. Afr.* 49, 373–395.
- Moghaddam, K.S., DePuy, G.W., 2011. Farm management optimization using chance constrained programming method. *Comput. Electr. Agric.* 77, 229–237.
- Moore, A.D., Robertson, M.J., Routley, R., 2011. Evaluation of the water use efficiency of alternative farm practices at a range of spatial and temporal scales: A conceptual framework and a modelling approach. *Agric. Syst.* 104, 162–174.
- Mosnier, C., Agabriel, J., Lherm, M., Reynaud, A., 2009. A dynamic bio-economic model to simulate optimal adjustments of suckler cow farm management to production and market shocks in France. *Agric. Syst.* 102, 77–88.
- Musshoff, O., Hirschauer, N., 2007. What benefits are to be derived from improved farm program planning approaches? – The role of time series models and

stochastic optimization. *Agric. Syst.* 95, 11–27.

Nabinger, C., 1996. Aspectos ecofisiológicos do manejo de pastagens e utilização de modelos como ferramenta de diagnóstico e indicação das necessidades de pesquisa. In *Anais da XVI Reunião do Grupo Técnico Regional do Cone Sul (Zona Campos) em Melhoramento e Utilização dos Recursos Forrageiros das Áreas Tropical e Subtropical*, Porto Alegre, Brazil, 16–19 April, 1996.

Nabinger, C., Carvalho, P.C.F., 2009. Ecofisiología de sistemas pastoriles: aplicaciones para su sustentabilidad. *Agrociencia* 13, 18–27.

Nielsen, B., Thamsborg, S.M., Andersen, H.R., Kristensen, T., 2003. Effect of winter feeding level and season on herbage intake in dairy breed steers on perennial ryegrass/white clover pasture. *Anim. Sci.* 76, 341–352.

Nousiainen, J., Tuori, M., Turtola, E., Huhtanen, P., 2011. Dairy farm nutrient management model. 1. Model description and validation. *Agric. Syst.* 104, 371–382.

NRC. National Research Council, 1996. *Nutrient requirement of beef cattle*, 7th ed. National Academy Press, Washington, DC.

Nuthall, P.L., 2012. The intuitive world of farmers – The case of grazing management systems and experts. *Agric. Syst.* 107, 65–73.

Pacheco, J.V.A., Morabito, R., 2011. Application of network flow models for the cash management of an agribusiness company. *Comput. Ind. Eng.* 61, 848–857.

Pang, H., Makarechian, M., Basarab, J.A., Berg, R.T., 1999. Structure of a dynamic simulation model for beef cattle production systems. *Can. J. Anim. Sci.* 79, 409–417.

- Plà, L.M., 2007. Review of mathematical models for sow herd management. *Livest. Sci.* 106, 107–119.
- Rotz, C.A., Buckmaster, D.R., Comerford, J.W., 2005. A beef herd model for simulating feed intake, animal performance, and manure excretion in farm systems. *J. Anim. Sci.* 83, 231–242.
- Senge, P.M., Sterman, J.D., 1992. Systems thinking and organizational learning: Acting locally and thinking globally in the organization of the future. *Eur. J. Operat. Res.* 59, 137–150.
- Slavik, M., 2004. Changes in information systems in Czech agriculture. *J. Agr. Educ. Ext.* 10, 193–202.
- Sterman, J.D., 2000. *Systems dynamics: thinking systems and modeling for a complex world*. Irwin/McGraw-Hill, Boston.
- Sterman, J.D., 2001. System dynamics modeling: Tools for learning in a complex word. *Calif. Manag. Rev.* 43, 8–25.
- Štůsek, J., Ulrych, L., 2008. Strategic thinking in the management of agribusiness companies. *Agric. Econ.* 54, 117–124.
- Tanure, S., Nabinger, C., 2010. Ferramentas de gerenciamento bioeconômico e suporte à decisão em empresas de pecuária de corte. In *Anais do IV Congresso Internacional de La Carne Bovina*, Asunción, Paraguay, 23–25 March, 2010.
- Tess, M.W., Kolstad, B.W., 2000. Simulation of cow-calf production systems in a range environment: I. Model development. *J. Anim. Sci.* 78, 1159–1169.
- Vetharanim, I., Stevens, D.R., Asher, G.W., Woodward, S.J.R., Archer, J.A., Rollo,

M.D., 2009. Model of growth, pregnancy and lactation in the red deer. *J. Agric. Sci.* 147, 253–272.

Wilman, D., Mtengeti, E.J., Moseley, G., 1996. Physical structure of twelve forage species in relation to rate of intake by sheep. *J. Agric. Sci.* 126, 277–285.

Zott, C., Amit, R., Massa, L., 2011. The business model: recent developments and future research. *J. Manag.* 37, 1019–1042.

Appendix




Figure 1. Bioeconomic macro model of decision support system for farm management (iThink 9.1.4).




Figure 2. Beef cattle production cycle for pasture-based Brazilian southern systems.

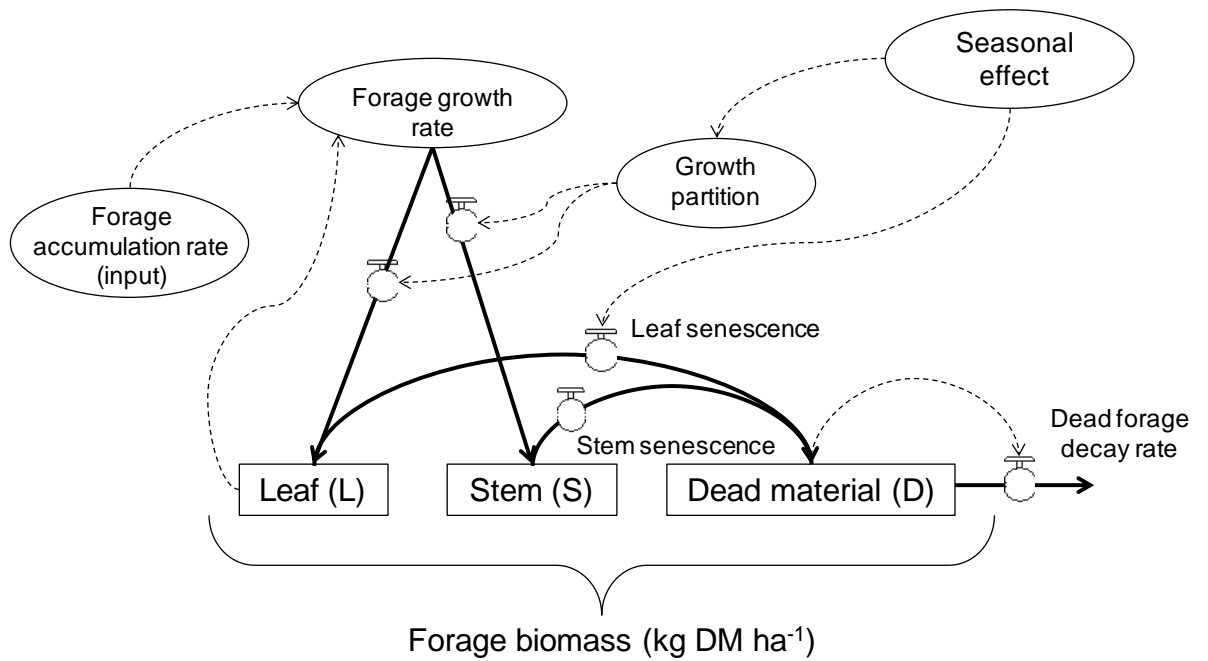


Figure 3. Pasture structure, adapted from Machado (2004).

CAPÍTULO IV⁴

⁴Artigo elaborado de acordo com as normas do periódico *Agricultural Systems*.

Aplicação do modelo de integração meteorologia-solo-pasto-animal para suporte à decisão em sistemas pecuários

Soraya Tanure^{a*}, Carlos Nabinger^a, João Luiz Becker^b

^a *Programa de Pós-Graduação em Zootecnia, Faculdade de Agronomia, Universidade Federal do Rio Grande do Sul, Av. Bento Gonçalves, 7712, 91540-000, Porto Alegre, RS, Brasil*

^b *Programa de Pós-Graduação em Administração, Escola de Administração, Universidade Federal do Rio Grande do Sul, Rua Washington Luiz, 855, 90010-460, Porto Alegre, RS, Brasil*

* Tel.: +55 (51) 3308 7406; fax: +55 (51) 3308 6048

sorayat@terra.com.br (S. Tanure)

RESUMO

A modelagem é uma importante ferramenta de análise para os sistemas de produção agropecuários. Definidos como um conjunto de equações matemáticas baseadas na descrição de processos, os modelos permitem analisar detalhadamente os diversos componentes do sistema de produção, possibilitando uma visão integrada de sua participação no sistema. Objetivando o desenvolvimento da simulação computacional do submodelo de integração meteorologia-solo-pasto-animal, integrante do macro modelo bioeconômico de suporte à decisão proposto nos capítulos II e III da presente tese, adotou-se a metodologia dinâmica de sistemas. Para tanto, propõe-se a estruturação de um simulador computacional, amparado por equações matemáticas previamente definidas, capaz de representar o funcionamento de uma parcela da unidade de produção pecuária, baseada na produção a pasto e condizente com a realidade dos principais sistemas de produção de carne bovina da região sul do Brasil. Foram construídos dois cenários básicos: (i) Cenário 1: Déficit hídrico durante os meses de primavera e verão (setembro a março); e (ii) Cenário 2: Precipitação pluvial média normal (Rio Grande do Sul) durante todo o ano. Ambos os cenários foram aplicados no comportamento vegetal das pastagens naturais, naturais melhoradas e cultivadas (*Lolium multiflorum* Lam.). A lotação animal foi a variável chave em todos os cenários. Considerada o ponto principal de decisão pelo produtor rural, foi a responsável pelo equilíbrio entre o consumo animal e a produção de forragem.

Palavras-chave: Dinâmica de sistemas; Modelo bioeconômico; Tomada de decisão; Simulação; Sistema pecuário.

1. Introdução

A década de 90 foi marcada por profundas modificações no cenário econômico mundial, onde se destacou a consolidação do processo de globalização e a rápida transformação das estruturas produtivas visando à adaptação ao novo ambiente macroeconômico (Fisher et al., 2000; Zott et al., 2011).

Sob essa nova ordem mundial, o setor primário, em especial a agropecuária, sofreu modificações na forma de produção e na administração das unidades produtivas. As propriedades rurais, inicialmente denominadas “fazendas”, ganharam o status de empresas e empreendimentos, elevaram o grau de profissionalismo nas decisões e, conseqüentemente, aumentaram sua rentabilidade, visando à sobrevivência do negócio (Boehlje, 1999).

O sucesso da atividade agropecuária está diretamente relacionado à capacidade dos administradores e produtores de planejar e gerir seus negócios (Hardaker e Lien, 2010). No entanto, esta não é uma tarefa fácil. A agropecuária, diferentemente de outras atividades econômicas, é permeada por características específicas, que incluem a dependência dos recursos naturais, o complexo ciclo fisiológico das espécies animais e vegetais, e o longo tempo para retorno dos investimentos (Boehlje, 1999; King et al., 2010). Estas especificidades geram um ambiente organizacional altamente complexo e imprimem uma necessidade extrema do emprego de técnicas quantitativas e ferramentas gerenciais, capazes de auxiliar o processo decisório e contribuir com a longevidade do negócio (Gouttenoire et al., 2011).

Dentre as metodologias capazes de congrega a modelagem matemática e a simulação de explorações agropecuárias, destaca-se a dinâmica de sistemas (DS). A metodologia DS possibilita a construção de modelos extremamente complexos, constituídos por um alto número de variáveis e possibilita a experimentação de inúmeros cenários e seu acompanhamento ao longo do tempo (Senge et al., 2007; Sterman, 2000; 2006).

Considerando essas vantagens e visando incorporar em suas análises fatores biológicos e econômicos, além das defasagens de tempo, comuns aos sistemas agropecuários, a pesquisa adotou a metodologia DS, objetivando a estruturação matemática e o desenvolvimento da simulação computacional de uma pequena parcela do macro modelo bioeconômico de suporte à decisão apresentado nos capítulos II e III da presente tese, responsável pela integração entre meteorologia, solo, pasto e desempenho animal, em unidades de produção pecuária.

Para tanto, propõe-se a estruturação de um simulador computacional, amparado por equações matemáticas previamente definidas, capaz de representar o crescimento de uma pastagem e sua interação com o consumo e desempenho animal, de forma similar aos cenários de produção de carne bovina da região sul do Brasil.

A estrutura da pesquisa consiste em uma breve revisão sobre a simulação dinâmica e sua inserção nos sistemas biológicos, seguida de uma descrição detalhada dos cenários construídos baseados na metodologia DS. Posteriormente, são apresentados e discutidos os principais resultados e, por fim, são apontadas as implicações para trabalhos futuros e conclusões.

2. Modelagem e simulação dinâmica de sistemas biológicos

Modelos são representações explícitas de parte da realidade, e visam compreender e gerenciar as inúmeras informações e variáveis que compõem os sistemas, bem como apontar soluções para os possíveis problemas encontrados (Senge et al., 2007; Sterman, 2001). Inúmeras vantagens podem ser obtidas com o uso de modelos bem elaborados, como a integração entre conhecimentos teóricos e práticos (empíricos) sobre temas específicos, ou ainda o esclarecimento de pontos obscuros e a produção de “novos” conhecimentos em situações onde a experimentação real é dispendiosa ou de difícil realização (Gouttenoire et al., 2011).

No entanto, nem sempre os modelos terão como objetivo descrever problemas específicos, pois a finalidade da modelagem é dependente da capacidade de incorporação de variáveis e da representação de cenários complexos. Algumas das principais dificuldades do processo de modelagem estão no tratamento estatístico a ser utilizado, o que leva muitos pesquisadores a desenvolver modelos demasiadamente simplificados (Sterman, 2000).

As limitações computacionais existentes até as décadas de 80 e 90, impactavam na construção de modelos biológicos conflitantes com as respostas estatísticas, levando ao uso indiscriminado de modelos lineares (Kim e Senge, 1994). Felizmente, os avanços computacionais na área estatística entre os anos de 2000 e 2010, alavancaram a utilização de modelos não-lineares para a modelagem de processos biológicos e o correto emprego das análises temporais (Huryk, 2012), onde se destaca o uso da metodologia DS (Sterman, 2001; 2006).

Um modelo de DS pode ser representado como a estrutura resultante da interação de políticas. Estas, por sua vez, representam as regras que determinam a decisão a ser tomada. Duas características merecem destaque na DS: (i) uma vez que se conhece a política adotada, dado um conjunto de variáveis de entrada, pode-se estabelecer a decisão a ser tomada; e (ii) as políticas não se alteram ao longo do tempo, e sim as decisões geradas a partir delas (Senge e Sterman, 1992). Desse raciocínio deriva-se uma das principais vantagens da DS, que está na compreensão de como as políticas são adotadas, ou seja, como a própria estrutura do sistema afeta ou determina o comportamento dinâmico observado nas organizações (Forrester, 1992).

Frente a estas habilidades, a metodologia DS vem sendo utilizada em diversas áreas do conhecimento (Janssen e van Ittersum, 2007; Sterman, 2006; Weil, 2007). Na área de estratégia empresarial, por exemplo, o enfoque da DS busca compreender o comportamento de clientes, fornecedores e concorrentes, para moldar o desempenho da empresa ao longo do tempo e as possíveis decisões a serem tomadas no curto e no longo prazo (Radzicki, 2003). Na agropecuária, a DS tem ganhado espaço no mapeamento de processos relacionados à produção de leite (Nousiainen et al., 2011), carne (Pang et al., 1999; Tess e Kolstald, 2000), e ainda no comportamento do produtor frente à situações de risco econômico (French et al., 2011; Malan et al., 2010; Mosnier et al., 2009).

Assim, fica clara a notória capacidade desta metodologia no auxílio à compreensão de processos e detecção de inconsistências e conflitos frente às pressuposições, estratégias e normas adotadas, contribuindo para a redução de incertezas e de desacordos, por meio da busca do consenso sobre as decisões mais

promissoras (Richardson, 2011).

3. Método de pesquisa

3.1 Modelo de integração meteorologia-solo-pasto-animal

Frente à notória carência de ferramentas quantitativas adaptáveis aos diversos fatores de produção envolvidos na atividade agropecuária e que possam ser utilizadas em um processo de decisão baseado em rentabilidade, viabilidade técnica e sustentabilidade ambiental (Huryk, 2012), uma importante alternativa é o integração entre modelos matemáticos e instrumentos computacionais que permitam a criação de cenários preditivos (Plà, 2007).

Neste sentido, a criação de cenários capazes de representar o balanço entre a disponibilidade forrageira, o consumo e o desempenho animal são primordiais para que num futuro próximo as modelagens e simulações possam agregar novas variáveis e representar situações ainda mais complexas (Cangiano et al., 1999). Um dos principais entraves para a tomada de decisão baseada no balanço acima mencionado refere-se ao entendimento da lotação animal a ser praticada em sistemas que vislumbrem a dinâmica de crescimento do pasto (Johnson e Parsons, 1985). O crescimento vegetal é dependente da quantidade de radiação solar incidente sobre o dossel da planta, no entanto, a eficiência com que essa energia é utilizada no processo de fotossíntese e que resultará no real acúmulo de biomassa vegetal, possui relação direta com inúmeros outros fatores (Fonseca et al., 2006;

2007).

A disponibilidade hídrica e de nutrientes do solo são fatores chave neste processo (Inman-Barber, 1994). Portanto, modelar a resposta do pasto à radiação solar incidente e as restrições impostas pelo déficit hídrico e nutricional representa a única forma de “predizer” seu crescimento e, por consequência, a disponibilidade de forragem, no caso de sistemas pastoris.

O macro modelo bioeconômico para suporte à decisão em sistemas pecuários proposto nos capítulos II e III da presente tese considera as variáveis radiação e precipitação pluvial na geração de um submodelo capaz de reproduzir a disponibilidade de forragem em um horizonte de tempo (dia, mês ou ano) a ser definido pelo usuário da simulação. Este submodelo é o objeto central do presente artigo e, embora, apresente como principal saída o desempenho animal (permitindo o ingresso de variáveis econômicas), objetivando a simplificação do processo de comparação de cenários, optou-se por suprimir, neste primeiro momento, alguns processos referentes à fisiologia animal e a incorporação de variáveis econômicas tais como: custos de produção e impostos, que possibilitariam o funcionamento do fluxo de caixa, citado no capítulo III.

O modelo de integração meteorologia-solo-pasto-animal é apresentado na Figura 1, e seus parâmetros, variáveis e coeficientes são detalhados a seguir, na apresentação dos cenários.

3.2 Apresentação dos cenários

As pastagens representam o principal recurso forrageiro disponível para a produção pecuária bovina e ovina da região sul do Brasil (Maraschin et al., 1997; Nabinger, 1996). Considerando a extrema importância econômica deste aporte alimentar, o conhecimento das respostas fisiológicas das espécies forrageiras aos fatores do meio físico e à ação do animal tornou-se ao longo dos anos imprescindível, e permite aos produtores avaliar a eficiência de utilização das áreas de pastagem (Nabinger e Carvalho, 2009).

O conhecimento das potencialidades da produção forrageira determinadas pelo clima e as principais limitações edáficas são essenciais para qualquer estratégia de produção animal (Fonseca et al., 2006; Johnson e Parsons, 1985), tanto em regiões temperadas como tropicais. A identificação destas limitações à expressão da produção potencial representa um dos grandes desafios para futuras pesquisas, e vislumbra o quanto é possível manejar e intervir nos principais fatores de impacto da produtividade animal, de forma a otimizar a sustentabilidade e a lucratividade do sistema (Carassai et al., 2012). Assim, buscando encurtar o período despendido pelas experimentações reais à campo, os cenários apresentados pela presente pesquisa buscam modelar os principais impactos causados por variáveis meteorológicas na produção vegetal, com consequente reflexo no desempenho animal.

Para tanto, foram construídos dois cenários básicos: (i) Cenário 1: Déficit hídrico durante os meses de primavera e verão (setembro a março); e (ii) Cenário 2: Precipitação pluvial dentro da curva de normalidade para o Estado do Rio Grande do Sul, durante todo o ano. Ambos os cenários foram aplicados em situações que visaram representar o comportamento vegetal das pastagens naturais, naturais

melhoradas e cultivadas (azevém anual; *Lolium multiflorum* Lam.).

A condição hídrica em todas as situações simuladas é representada pela relação evapotranspiração real (ETR)/evapotranspiração potencial (ETP) e baseou-se em séries históricas propostas por Berlato e Fontana (2003). No entanto, vale ressaltar que a relação ETR/ETP é considerada, na presente pesquisa, uma variável de entrada e poderá ser modificada de acordo com os parâmetros específicos adotados pelo usuário do modelo. Outra possibilidade de incorporação da precipitação pluvial no modelo, é a utilização do balanço hídrico como variável de entrada, no entanto, a ausência de dados deste parâmetro e, em especial, sobre a capacidade de armazenamento de água em distintos tipos de solo representou um entrave para seu uso (Dourado-Neto et al., 2000).

Outra variável de destaque é a radiação fotossinteticamente ativa incidente (PAR_i). A PAR_i permaneceu inalterada em todas as situações apresentadas e seus valores mensais foram obtidos através do modelo proposto por Forserth e Norman (1993). A radiação também poderá ser alterada a qualquer momento pelo usuário do modelo, no entanto, nesta pesquisa optou-se por torná-la comum a todos os cenários, para que seus valores não influenciassem na sensibilidade de outras variáveis analisadas.

As demais variáveis consideradas na pesquisa e suas respectivas fórmulas matemáticas para implementação do modelo e posterior simulação, são apresentadas na Tabela 1.

As eficiências de conversão da PAR_i em matéria seca (MS; ϵ_{CA}) variaram de acordo com o estágio fisiológico (representado pelos diferentes meses do ano) da

pastagem simulada: (i) pastagem natural: 0,05 a 0,30 g/MS/MJ⁻¹ (Barro, 2011; Fonseca et al., 2006; 2007; Nabinger, 1998); (ii) pastagem natural melhorada: 0,20 a 0,8 g/MS/MJ⁻¹, conforme adaptações de Barro (2011) e Carassai (2010) e considerando a maior incidência de espécies hibernais (nesta pesquisa, apenas *Lolium multiflorum* Lam.) entre os meses de junho e agosto ; e (i) pastagem cultivada: 1,00 a 1,55 g/MS/MJ⁻¹, com base em Carassai et al. (2012) e considerando o uso de doses de nitrogênio inferiores aquelas que propiciaram os valores de eficiência máxima determinada por esses autores.

A lotação animal por hectare também é uma importante variável, representa o processo decisório do produtor, e é responsável pelo ajuste entre a demanda animal e a disponibilidade de forragem, determinada pelas condições ambientais (PAR_i, ETR/ETP e outras). Na presente pesquisa, buscou-se manipular a lotação animal de forma que a disponibilidade inicial de forragem (DF₀) se mantivesse estabilizada e adotou-se para os animais, o peso médio individual inicial de 250 kg. A partir do peso inicial, os demais pesos individuais são atribuídos pelo modelo. A escolha do peso vivo inicial baseou-se na categoria pretendida pelo estudo: machos com aproximadamente um ano de idade ao início do período simulado (novilhos).

Em relação ao consumo de forragem pelo animal, o modelo considera o valor máximo de 3% do peso vivo (PV), proposto pelo NRC (1996), para a categoria de bovinos jovens, acrescido da porcentagem de perdas resultantes do pisoteio, fezes e urina (Costa et al., 2011; Montagner et al., 2011). Assim, nas pastagens naturais e naturais melhoradas considerou-se como valor fixo, 4% do PV para consumo e perdas, enquanto na pastagem cultivada, esse valor foi modificado para 5%, devido a maior fragilidade da estrutura do pasto e, conseqüente, aumento das perdas

(Roman et al., 2010).

O NRC (1996) também foi utilizado para parametrizar o ganho médio diário (GMD) dos animais nas diferentes pastagens. Devido a ausência de dados de qualitativos e de composição bromatológica das pastagens naturais e naturais melhoradas, os valores utilizados são empíricos, baseados em observações à campo, e diferentes fontes de literatura (Maraschin et al., 1997; Maraschin, 2001; Nabinger, 1996; 1998; Nabinger e Carvalho, 2009). Para a pastagem cultivada, considerou-se o parâmetro “nutrientes digestíveis totais” (%NDT; NRC, 1996), na composição dos ganhos de peso entre 0,700 e 1,000 kg/animal/dia, baseados na categoria em estudo (novilhos) e na disponibilidade forrageira (*Lolium multiflorum* Lam.).

Por fim, o ingresso econômico foi quantificado através da média do preço pago pelo quilo do boi gordo no ano de 2011 (Anualpec, 2011). Assim, o indexador, em reais, foi de R\$ 3,20, multiplicado pelo ganho de peso vivo por hectare (GP).

Após a determinação das variáveis chave para a composição dos cenários, o modelo foi desenhado e estruturado matematicamente pelo *software* iThink 9.1.4 (iSee Systems, Inc., USA; Figura 1), que identificou os principais estoques, fluxos e variáveis auxiliares, fundamentais para a simulação.

Os estoques, identificados por quadrados vazios (Sterman, 2000), representam as acumulações de disponibilidade de forragem (potencial, real e final). Enquanto os fluxos, identificados por setas largas, subsidiam os estoques com informações provenientes das variáveis auxiliares, representadas por pequenos círculos (Forrester, 1992). De forma exemplificada o fluxo “eficiência de conversão da

radiação em matéria seca” é subsidiado pelas variáveis auxiliares PAR_i e ETR/ETP. Da mesma forma, o fluxo “consumo e perdas” fornece informações fundamentais para o estoque “disponibilidade final de forragem”, que por sua vez representa a massa residual de forragem após o pastejo que servirá de entrada (*input*, disponibilidade inicial de forragem) para o próximo ciclo produtivo. Assim, optou-se por representar a “disponibilidade inicial de forragem” como o fluxo precursor da modelagem de crescimento do pasto e atendimento à demanda animal.

Ainda em relação aos fluxos, o GMD recebe informações da maior parte das variáveis auxiliares do sistema e fornece os dados de abastecimento para a variável GP, responsável por subsidiar o módulo final de ingresso econômico do modelo.

A partir da estruturação matemática do modelo no *software*, deu-se início as simulações e construções dos cenários, conforme descrito a seguir.

4. Resultados

4.1 Comparação entre cenários

4.1.1 Pastagem natural

O estresse hídrico afeta o crescimento, desenvolvimento e a eficiência de uso da água pelas culturas (Berlato e Fontana, 2003). De forma mais específica, estes efeitos decorrem de respostas morfológicas como o desenvolvimento do índice de

área foliar (IAF), crescimento de perfilhos e raízes, e processos fisiológicos como a fotossíntese e a respiração (Maas, 1993). O grau de resposta ao déficit hídrico varia de acordo com a severidade, duração e estágio fenológico da planta (Gastal e Lemaire, 2002). Assim, ao observarmos o cenário 1 da pastagem natural (Tabela 2), com menor incidência de chuvas no período de crescimento e rebrota das espécies de verão (setembro a fevereiro), é notório o impacto do déficit hídrico nas produções potencial e real de forragem.

Conceitualmente, define-se a produtividade potencial como aquela passível de ser obtida quando todos os fatores modificáveis do meio são levados a um nível ótimo (Johnson e Parsons, 1985; Maas, 1993). Desta forma, o potencial de produção de uma cultura é diretamente dependente dos fatores não modificáveis (altitude, latitude, temperatura, relevo e outros) do meio. Quando um fator modificável (água, nutrientes, sanidade e outros) é mantido em níveis limitantes, obtém-se uma produtividade real inferior a potencial, como pode ser observado nos cenários 1 e 2 (Tabelas 2 e 3).

Assim, ainda que em condições consideradas dentro da normalidade para o regime de chuvas do Estado do Rio Grande do Sul (Cenário 2; Tabela 3), a disponibilidade hídrica se mostrou limitante para que a pastagem pudesse expressar seu potencial de crescimento. Além disso, todos os cenários apresentados na presente pesquisa, não consideram o impacto direto da fertilização do solo, pois os valores da \mathcal{E}_{CA} apresentados referem-se a condições de baixa a média fertilidade, o que seguramente também representa um limitante ao crescimento do pasto. Em cenários com o uso de adubação nitrogenada, por exemplo, os valores da \mathcal{E}_{CA} seriam superiores e seguramente a produção real e potencial de forragem estaria

mais próxima do equilíbrio (Carassai, 2010; Carassai et al., 2012). A adequada nutrição nitrogenada atua na morfogênese da planta em crescimento vegetativo, aumentando a taxa de expansão das folhas, mantendo praticamente inalterado o ritmo de aparecimento de folhas, reduzindo a taxa de senescência e otimizando o surgimento de perfilhos/hastes (Gastal e Lemaire, 2002).

Conforme já salientado na descrição do modelo, os cenários construídos em todos os tipos de pastagem visaram um manejo ideal, com pronunciado equilíbrio entre o consumo (e as perdas) e o crescimento do pasto (Figuras 2 e 3).

No entanto, esta realidade é distinta daquela observada na maioria das unidades de produção pecuária, onde os ganhos de peso por área e a renda (Figura 4) apresentam-se negativos, em especial durante os períodos de frio ou estiagem prolongados (Nabinger, 1996). Assim, ainda que sob condições meteorológicas adversas, obteve-se ingressos econômicos positivos em ambos os cenários, devido ao ajuste da lotação animal e o minucioso acompanhamento das massas residuais de forragem ao final de cada mês avaliado.

4.1.2 Pastagem natural melhorada

Vários autores têm demonstrado que a introdução de espécies hibernais em pastagens naturais melhora a condição corporal e os ganhos de peso dos animais nos períodos de inverno e primavera (Pötter e Lobato, 2004; Sorgatto et al., 2001). No entanto, quando mal manejadas ou submetidas às condições meteorológicas adversas, as pastagens melhoradas podem apresentar, em termos de ganho de

peso, desempenhos insatisfatórios e algumas vezes inferiores às pastagens puramente naturais (Nabinger, 1998).

Assim, observa-se que o cenário 1 da pastagem natural melhorada (Tabela 4) apresenta ganhos de peso inferiores aqueles obtidos em condições de precipitação pluvial moderada (Tabela 5).

Novamente, o ponto de destaque na comparação entre os dois cenários apresentados foi o ajuste de lotação animal, onde buscou-se equiparar o consumo e a produção de pasto, em especial nos meses de inverno (Figuras 5 e 6). Em condições adversas, a pastagem natural melhorada apresentou uma capacidade de suporte máxima de 1 animal/hectare, nos meses de primavera e verão, ou seja, em situações de déficit hídrico pronunciado, o azevém apresentou baixa participação no desempenho animal. No cenário 2, a lotação máxima suportada pela pastagem foi de 2,5 animais/hectare, o que representa um GP médio de 70 kg/ha entre os meses de junho e outubro. Economicamente, 70 kg de peso vivo, representam neste cenário, um ingresso econômico de R\$ 224,00. Sorgatto et al. (2001) também observaram capacidades de suporte e ganhos de peso/hectare (PV/ha) significativamente superiores em pastagens naturais sobressemeadas com espécies hibernais, em relação as pastagens naturais sem melhoramento.

Ainda sobre a comparação econômica, ao final do ciclo de produção, o cenário 2 apresentou um acréscimo de 43 kg de PV/ha e R\$ 140,00/ha, quando comparado ao cenário 1 (Figura 7). No mesmo sentido, Pötter et al. (1998), também por meio de simulação, compararam três alternativas alimentares para bovinos de corte e obtiveram taxas de desfrute e ganhos de PV/ha superiores em sistemas de pastagem melhorada em relação a pastagem natural e ganhos similares aos

sistemas de alimentação com suplementação a base de grãos, porém com menor custo de produção.

Portanto, além de permitir adequado desenvolvimento e elevada produção por área (Pötter e Lobato, 2004), o melhoramento das pastagens naturais por meio de espécies cultivadas de clima temperado, possibilita obter um menor custo e uma maior receita bruta em relação à utilização de grãos quando se analisa sistemas pecuários de produção de carne, resultando em uma melhor relação custo/benefício (Pötter et al., 1998).

4.1.3 Pastagem cultivada

A pastagem cultivada de inverno tem importância fundamental na região sul do Brasil, pois sua estação de crescimento ocorre em períodos críticos para a maioria das espécies forrageiras naturais, que apresentam ciclo estival, e agrega qualidade na dieta do rebanho.

O azevém anual é reconhecidamente a principal espécie forrageira de inverno cultivada na região sul, e sua presença é verificada de diversas formas nos sistemas de produção animal a pasto, como: em sistemas intensivos com pastagens singulares ou consorciadas, na sobressemeadura em pastagem natural, na integração com florestas e outros cultivos agrícolas (sistemas agrosilvipastoris), na sucessão e rotação com lavouras, na conservação de forragem e na produção de sementes (Carassai, 2010). Assim, justifica-se a escolha desta espécie forrageira para representar a pastagem cultivada dos cenários 1 e 2. Além disso, o vasto banco

de dados históricos desta espécie para algumas variáveis possibilita sua utilização em estudos de modelagem e simulação.

Em todas as situações simuladas (pastagens natural, melhorada e cultivada), os maiores ganhos de PV/ha ocorrem indiscutivelmente com o azevém, independente do cenário do observado (Tabelas 6 e 7). No entanto, embora seja notável a renda bruta obtida nos cenários 1 e 2, o custo para implantação da pastagem não foi incorporado nesta análise e seguramente causaria uma redução moderada nos valores apresentados. Por outro lado, como já mencionado anteriormente, as condições meteorológicas utilizadas na presente pesquisa vislumbram um ambiente mais severo do que a realidade historicamente apresentada pelo Rio Grande do Sul. Assim, com a utilização de valores para a PAR_i e também para a relação ETR/ETP, mais otimistas, a ϵ_{CA} para as pastagens cultivadas facilmente atingiria níveis próximos a $2 \text{ MJ/m}^2/\text{dia}$, proporcionando maiores produções de forragens (Carassai et al., 2012), diluindo assim o custo para implantação desta pastagem.

Destaca-se ainda a alta lotação animal praticada durante todo o período simulado, fruto do ajuste entre consumo e crescimento do pasto (Figuras 8 e 9).

Em ambos os cenários observa-se cargas animais (na média) superiores a 1200 kg/ha , com manutenção da massa residual de forragem e ganhos por animal fixados na média de $0,860 \text{ kg/dia}$ (NRC, 1996), gerando rendas superiores a R\$ $400,00$ e $540,00/\text{ha}$ nos cenários 1 e 2 (Figura 10), respectivamente.

Por fim, ao analisarmos todos os cenários construídos na presente pesquisa fica claro que a produção de forragem e sua transformação em produto animal, pode

deixar de ser uma observação puramente empírica, se entendermos e utilizarmos corretamente as potencialidades permitidas pelo meio e algumas ferramentas quantitativas para suporte à decisão.

5. Implicações

Modelos que objetivam descrever a produção animal em pastagens são altamente complexos, e necessitam do aporte de submodelos envolvendo as relações entre as plantas e o meio (geralmente utilizados nas culturas agrícolas) e também daqueles capazes de identificar os processos fisiológicos dos animais em pastejo e a interação dos animais com o pasto e o meio. Considerando tamanha complexidade, o desenvolvimento de modelos confiáveis e simulações compatíveis com a realidade é um processo lento e altamente dependente do envolvimento de equipes multidisciplinares e, principalmente, de bancos de dados amplos, de todas as áreas envolvidas.

6. Conclusões

À luz do conhecimento atual, a metodologia dinâmica de sistemas demonstrou flexibilidade e aptidão em representar (dentro de certas limitações) um sistema de produção pecuário, condizente com a realidade das unidades de produção do Estado do Rio Grande do Sul. No entanto, a ausência de dados e séries históricas para algumas características, tais como: PAR_i e ETR/ETP limitaram a sofisticação da modelagem e, por consequência, da simulação apresentada. Além disso, a ausência

de padrões metodológicos para a coleta de dados representou um entrave na busca por informações referentes à fisiologia animal e vegetal, implicando diretamente na superficialidade de algumas interações apresentadas.

Referências

ANUALPEC. Anuário da Pecuária Brasileiro, 2011. FNP, São Paulo, Brasil.

Barro, R.S., 2011. Respostas morfofisiológicas e produtivas de genótipos forrageiros nativos em diferentes condições de luminosidade. Doctoral thesis, Universidade Federal do Rio Grande do Sul, Porto Alegre, Brasil.

Berlato, M. A., Fontana, D.C., 2003 El Niño e La Niña: impactos no clima, na vegetação e na agricultura do Rio Grande do Sul; aplicações de previsões climáticas na agricultura. Porto Alegre, UFRGS.

Boehlje, M., 1999. Structural changes in the agricultural industries: how do we measure, analyze and understand them? *Am. J. Agric. Econ.* 81, 1028–1041.

Cangiano, C.A., Fernández, H.H., Galli, J.R., 1999. ConPast 3.0: programa de computación para la estimación del consumo de bovinos en pastoreo. La Barrosa, Buenos Aires.

Carassai, I.J., 2010. Modelagem do crescimento do azevém anual (*Lolium multiflorum* Lam.) submetido a diferentes níveis de nitrogênio, em função da radiação solar absorvida. Doctoral thesis, Universidade Federal do Rio Grande do Sul, Porto Alegre, Brasil.

Carassai, I.J., Trindade, J.K., Nabinger, C., Lemaire, G., Carvalho, P.C.F., Silva,

- C.E.G., Vieira, P.C., Dutra, V.S., Tischler, M.R., 2012. Ecophysiological model of growth of annual ryegrass as function of nitrogen fertilization. In Proceedings of 24th General Meeting of the European Grassland Federation, Lublin, Poland, 2012.
- Costa, V.G., Rocha, M.G., Pötter, L., Roso, D., Rosa, A.T.N., Reis, J., 2011. Comportamento de pastejo e ingestão de forragem por novilhas de corte em pastagens de milho e papuã. *Rev. Bras. Zoot.* 40, 251-259.
- Dourado-Neto, D., Nielsen, D.R., Hopmans, J.W., Reichardt, K., Bacchi, O.O.S., 2000. Software to model soil water retention curves (SWRC, version 2.00). *Sci. Agric.* 57, 191-192, 2000.
- Fisher, D.K., Norvell, J., Sonka, S., Nelson, M.J., 2000. Understanding technology adoption through system dynamics modeling: implications for agribusiness management. *Int. Food Agribus. Manag. Rev.* 3, 281–296.
- Fonseca, E.L., Ponzoni, F.J., Formaggio, A.R., 2007. Modelo agrometeorológico-espectral para estimativa da disponibilidade de forragem no bioma “campos sulinos”. *Rev. Bras. Agrometeorol.* 15, 241–249.
- Fonseca, E.L., Silveira, V.C.P., Salomoni, E., 2006. Eficiência de conversão da radiação fotossinteticamente ativa incidente em biomassa aérea da vegetação campestre natural no bioma Campos Sulinos do Brasil. *Ciênc. Rural* 36, 656–659.
- Forrester, J.W., 1992. Policies, decisions and information-sources for modeling. *Eur. J. Operat. Res.* 59, 42-63.
- Forseth, I. N., Norman, J.M., 1993. Modeling of solar irradiance, leaf energy budget,

- and canopy photosynthesis. In: *Photosynthesis and Production in a Changing Environment - A Field and Laboratory Manual*. Hall, D.O, Scurlock, J.M.O, Bolhar, H., Leegood, R.C., Long, S.P. (eds.). p. 207-219. Chapman and Hall, London, 1993.
- French, S., Bedford, T., Pollard, S.J.T., Soane, E., 2011. Human reliability analysis: A critique and review for managers. *Saf. Sci.* 49, 753–763.
- Gastal, F., Lemaire, G., 2002. N uptake and distribution in crops: an agronomical and ecophysiological perspective. *J. Exp. Bot.* 53, 789-799.
- Gouttenoire, L., Cournut, S., Ingrand, S., 2011 Modelling as tool to redesign livestock farming systems: A literature review. *Animal* 5, 1957-1971.
- Hardaker, J.B., Lien, G., 2010. Probabilities for decision analysis in agriculture and rural resource economics: The need for a paradigm change. *Agric. Syst.* 103, 345–350.
- Huryk, L.A., 2012. Information systems and decision support systems. *Am. J. Nursing* 112, 62-65.
- Inman-Bamber, N.G., 1994. Temperature and seasonal effects on canopy development and light interception of sugarcane. *Field Crops Research* 36, 41-51.
- Janssen, S., van Ittersum, M.K., 2007. Assessing farm innovations and responses to policies: A review of bio-economic farm models. *Agric. Syst.* 94, 622–636.
- Johnson, I.R., Parsons, A.J., 1985. A theoretical analysis of grass growth under grazing. *J. Theor. Biol.* 112, 345–368.

- Kim, D.H., Senge, P.M., 1994. Putting systems thinking into practice. *Syst. Dynam. Rev.* 10, 277-290.
- King, R.P., Boehlje, M., Cook, M.L., Sonka, S.T., 2010. Agribusiness economics and management. *Am. J. Agric. Econ.* 92, 554–570.
- Maas, S.J., 1993. Parameterized model of gramineous crop growth. 1. Leaf area and dry mass simulation. *Agron. J.* 85, 348–353.
- Malan, D.J.C., Louw, A., Blignaut, C., 2010. Simulation analysis of risk management for a diversified commercial farm. *Agrekon* 49, 373–395.
- Maraschin, G.E., 2001. Production potential of South American grasslands. In *Proceedings of 19th International Grassland Congress, Piracicaba, Brasil, 2001.*
- Maraschin, G.E., Moojen, E.L., Escosteguy, C.M.D., Corrêa, F.L., Apezteguia, E.S., Boldrini, I.J., Riboldi, J., 1997. Native pasture, forage on offer and animal response. In: *XVIII International Grassland Congress, Saskatoon, Canada, 1997.*
- Montagner, D.B., Rocha, M.G., Genro, T.C.M., Brem, C., Santos, D.T., Roman, J., Roso, D., 2011. Ingestão de matéria seca por novilhas de corte em pastagem de milho. *Ciênc. Rural* 41,686-691.
- Mosnier, C., Agabriel, J., Lhern, M., 2009. A dynamic bio-economic model to simulate optimal adjustments of suckler cow farm management to production and market shocks in France. *Agricultural Systems* 102, 77-88.
- Nabinger, C., 1996. Aspectos ecofisiológicos do manejo de pastagens e utilização de modelos como ferramenta de diagnóstico e indicação das necessidades de pesquisa. In *Anais da XVI Reunião do Grupo Técnico Regional do Cone Sul (Zona Campos) em Melhoramento e Utilização dos Recursos Forrageiros das*

Áreas Tropical e Subtropical, Porto Alegre, Brasil, 16–19 Abril, 1996.

Nabinger, C., 1998. Princípios de manejo e produtividade de pastagens. In Anais do III Ciclo de Palestras em Produção e Manejo de Bovinos de Corte, Canoas, Brasil, 1998.

Nabinger, C., Carvalho, P.C.F., 2009. Ecofisiología de sistemas pastoriles: aplicaciones para su sustentabilidad. *Agrociencia* 13, 18–27.

Nousiainen, J., Tuori, M., Turtola, E., Huhtanen, P., 2011. Dairy farm nutrient management model. 1. Model description and validation. *Agric. Syst.* 104, 371–382.

NRC. National Research Council, 1996. Nutrient requirement of beef cattle. 7th ed. National Academy Press, Washington, DC.

Pang, H., Makarechian, M., Basarab, J.A., 1999. Structure of a dynamic simulation model for beef cattle production systems. *Canadian Journal of Animal Science* 79, 409-417.

Plà, L.M., 2007. Review of mathematical models for sow herd management. *Livestock Science* 106, 107-119.

Pötter, B.A.A., Lobato, J.F.P., 2004. Efeitos da carga animal, pastagem melhorada e da idade de desmame no comportamento reprodutivo de vacas primíparas. *Revista Brasileira de Zootecnia*, 33, 192-202.

Pötter, L., Lobato, J.F.P., Mielitz Neto, C.G.A., 1998. Produtividade de um modelo de produção para novilhas de corte primíparas aos dois, três e quatro anos de idade. *Rev. Bras. Zoot.* 27, 613-619.

- Radzicki, M.J., 2003. Mr. Hamilton, Mr. Forrester, and a foundation for evolutionary economics. *Journal of Economic Issues* 37, 133-173.
- Richardson, G.P., 2011. Reflections on the foundations of system dynamics. *System Dynamics Review* 27, 219-243.
- Roman, J., Rocha, M.G., Pires, C.C., Macari, S., Pötter, L., Elejalde, D.A.G., Oliveira Neto, R.A., Kloss, M.G., 2010. Características produtivas e perdas de forragem em pastagem de azevém com diferentes massas de forragem. *Agrociência* 16, 109-115.
- Senge, P.M., Sterman, J.D., 1992. Systems thinking and organizational learning: Acting locally and thinking globally in the organization of the future. *Eur. J. Operat. Res.* 59, 137–150.
- Senge, P.M., Lichtenstein, B.M.B., Kaufer, K., 2007. Collaborating for systemic change. *MIT Sloan Management Review* 48, 44-53.
- Sorgatto, D.C., Rizo, L.M., Moojen, E.L., Quadros, F.L.F., Corrêa, F.L., 2001. Produção animal em pastagem natural sobre-semeada com espécies hibernais com e sem o uso do herbicida glifosato. In *Anais da XXXVIII Reunião Anual da Sociedade Brasileira de Zootecnia*, Piracicaba, Brasil, 2001.
- Sterman, J.D., 2006. Learning from evidence in a complex world. *American Journal of Public Health* 96, 505-514.
- Sterman, J.D., 2001. System dynamics modeling: Tools for learning in a complex world. *California Management Review* 43, 8-25.
- Sterman, J.D., 2000. *Systems dynamics - Thinking systems and modeling for a complex world*. McGraw-Hill, New York.

- Tess, M.W. Kolstad, B.W., 2000. Simulation of cow-calf production systems in a range environment: I. Model development. *Journal of Animal Science* 78,1159-1169.
- Weil, H.B., 2007. Application of system dynamics to corporate strategy: An evolution of issues and frameworks. *System Dynamics Review* 23, 137-156.
- Zott, C., Amit, R., Massa, L., 2011. The business model: Recent developments and future research. *J. Manag.* 37, 1019–104.

Apêndices

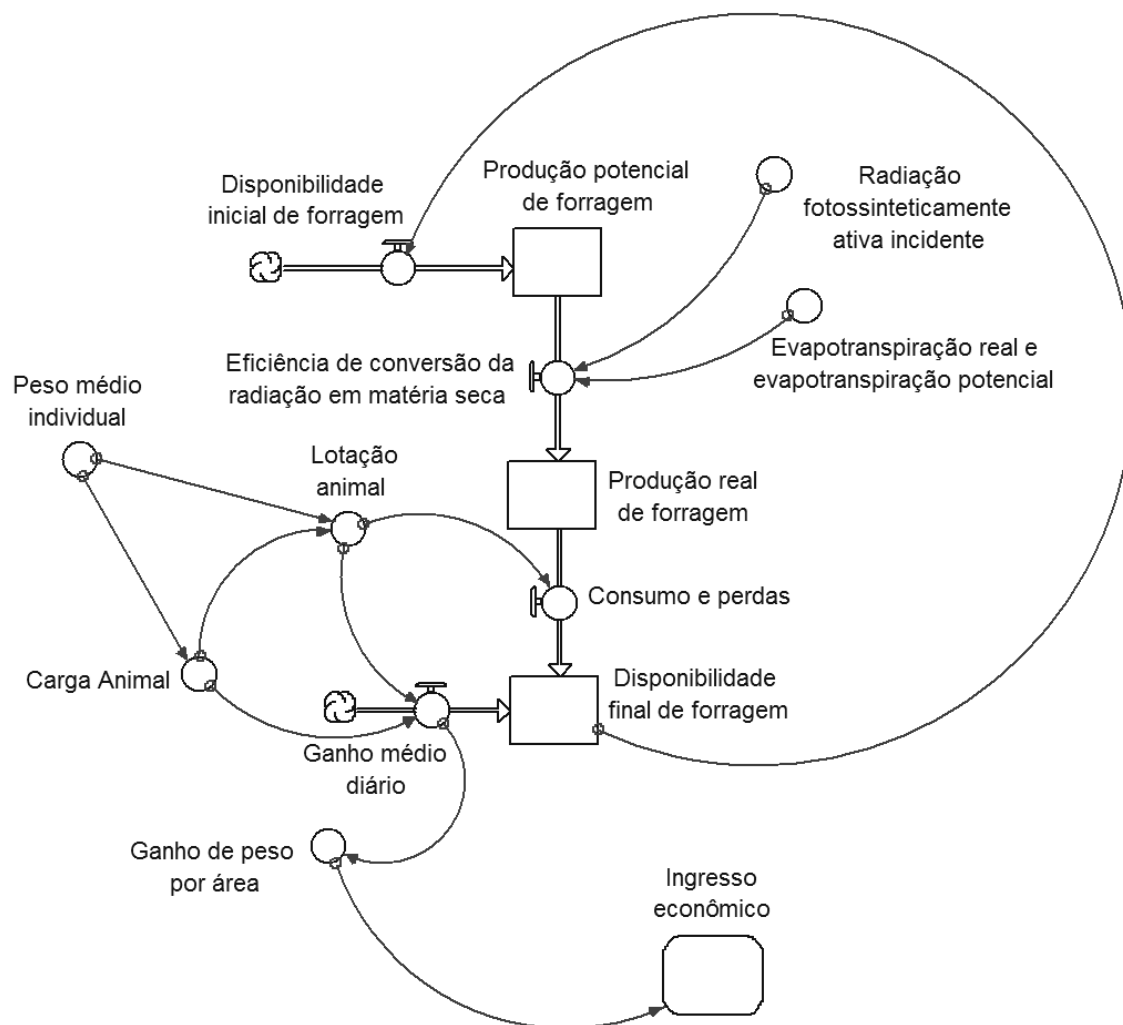


Figura 1. Estrutura do modelo de integração meteorologia-solo-pasto-animal (iThink 9.1.4).

Tabela 1

Variáveis utilizadas na construção dos cenários do modelo meteorologia-solo-pasto-animal.

Variável	Representação matemática	Unidade
Disponibilidade inicial de forragem (DF_0)	$DF_0/t = f(DF_0, PAR_i)$	kg/MS/ha
Radiação fotossinteticamente ativa incidente (PAR_i)	Valor pré-determinado por Forseth e Norman (1993)	MJ/m ² /dia
Eficiência de conversão da PAR_i em matéria seca (ϵ_{CA} ; PAR_i/MS)	Valor pré-determinado por revisão de literatura	g/MS/MJ ⁻¹
Produção potencial de forragem	Eficiência $PAR_i/MS * PAR_i$	kg/MS/ha
Evapotranspiração real/Evapotranspiração potencial (ETR/ETP)	Valor pré-determinado por Berlato e Fonseca (2003)	Índice numérico
Produção real de forragem	Produção potencial * ETR/ETP	kg/MS/ha
Disponibilidade final de forragem	$DF_n = \left(DI_0 + \epsilon_{ca} \sum_{t=0}^n PAR_i \right) * ETR/ETP$	kg/MS/ha
Lotação animal	Número de animais	Número de animais/ha
Peso médio individual	Peso médio individual inicial (ou do mês anterior) * (GMD * Número de dias do período avaliado)	kg/ha
Carga animal	Peso médio individual * Lotação animal	kg/ha
Consumo e perdas	Carga animal * %Peso vivo * Número de dias do período avaliado	kg/MS/ha
Ganho médio diário (GMD)	Valor pré-determinado pelo NRC (1996) e revisão de literatura	kg/animal/dia
Ganho de peso vivo por área (GP)	GMD * (Lotação animal * Número de dias do período avaliado)	kg/ha
Ingresso econômico	GP * Indexador (valor pago pelo quilo do boi gordo)	R\$/ha

Tabela 2

Cenário 1 da pastagem natural (déficit hídrico).

Variáveis	Jun	Jul	Ago	Set	Out	Nov	Dez	Jan	Fev	Mar	Abr	Mai	Média
Disponibilidade inicial de forragem (kg/MS/ha)	1300	1180	1074	1027	1067	1137	1227	1243	1286	1207	1292	1235	1190
PAR _i (MJ/m ² /dia)	5	5	5	6	7	8	9	9	8	8	7	6	6,30
Eficiência PAR _i /MS (g/MS/MJ ⁻¹)	0,10	0,05	0,10	0,29	0,28	0,28	0,28	0,28	0,29	0,29	0,30	0,30	0,24
Produção potencial de forragem (kg/MS/ha)	150	77	155	522	607	672	781	781	649	719	630	558	497
ETR/ETP	0,60	0,60	0,70	0,50	0,50	0,50	0,40	0,50	0,50	0,70	0,60	0,60	0,56
Produção real de forragem (kg/MS/ha)	90	46	108	261	303	336	312	390	324	503	378	334	282
Disponibilidade final de forragem (kg/MS/ha)	1390	1226	1182	1288	1371	1473	1540	1634	1611	1711	1670	1569	1472
Lotação animal (número de animais/ha)	0,70	0,50	0,50	0,70	0,70	0,70	0,80	0,90	1,0	1,0	1,0	0,70	0,77
Peso médio individual (kg)	250	254	259	263	278	293	308	322	336	349	363	375	304
Carga animal (kg/ha)	175	127	129	184	194	205	246	290	336	348	362	262	239
Consumo e perdas (kg/MS/ha)	210	153	155	221	233	246	296	348	404	419	435	315	286
GMD (kg/animal/dia)	0,140	0,140	0,140	0,500	0,500	0,500	0,450	0,450	0,450	0,450	0,400	0,300	0,368
Ganho peso vivo por área (kg/ha)	2,94	2,17	2,17	10,50	10,85	10,50	11,16	12,55	12,60	13,95	12,00	6,51	Σ = 107,90
Ingresso econômico (R\$/ha)	9,41	6,94	6,94	33,60	34,72	33,60	35,71	40,18	40,32	44,64	38,40	20,83	Σ = 345,30

Tabela 3

Cenário 2 da pastagem natural (precipitação pluvial normal).

Variáveis	Jun	Jul	Ago	Set	Out	Nov	Dez	Jan	Fev	Mar	Abr	Mai	Média
Disponibilidade inicial de forragem (kg/MS/ha)	1300	1210	1089	1057	1223	1248	1296	1325	1252	1157	1158	1227	1212
PAR _i (MJ/m ² /dia)	5	5	5	6	7	8	9	9	8	8	7	6	6,30
Eficiência PAR _i /MS (g/MS/MJ ⁻¹)	0,10	0,05	0,10	0,29	0,28	0,28	0,28	0,28	0,29	0,29	0,30	0,30	0,24
Produção potencial de forragem (kg/MS/ha)	150	78	155	522	608	672	781	781	650	719	630	558	525
ETR/ETP	0,80	0,80	0,80	0,80	0,70	0,70	0,70	0,60	0,60	0,70	0,80	0,80	0,73
Produção real de forragem (kg/MS/ha)	120	62	124	417	425	470	546	468	389	503	504	446	373
Disponibilidade final de forragem (kg/MS/ha)	1420	1272	1213	1475	1648	1718	1843	1793	1641	1661	1662	1673	1585
Lotação animal (número de animais/ha)	0,70	0,60	0,50	0,80	1,20	1,20	1,40	1,40	1,20	1,20	1,00	0,70	0,99
Peso médio individual (kg)	250	254	259	263	278	293	308	322	336	349	363	375	304
Carga animal (kg/ha)	175	153	129	210	333	352	432	451	404	419	363	262	307
Consumo e perdas (kg/MS/ha)	210	183	155	252	400	422	518	542	484	502	435	315	368
GMD (kg/animal/dia)	0,140	0,140	0,140	0,500	0,500	0,500	0,450	0,450	0,450	0,450	0,400	0,300	0,368
Ganho peso vivo por área (kg/ha)	2,90	2,60	2,20	12,00	18,60	18,00	19,50	19,50	15,10	16,70	12,00	6,50	Σ = 146,00
Ingresso econômico (R\$/ha)	9,41	8,33	6,94	38,40	59,52	57,60	62,50	62,50	48,38	53,57	38,40	20,83	Σ = 466,38




Figura 2. Cenário 1 - Produção e consumo de forragem da pastagem natural (déficit hídrico).




Figura 3. Cenário 2 - Produção e consumo de forragem da pastagem natural (precipitação pluvial normal).

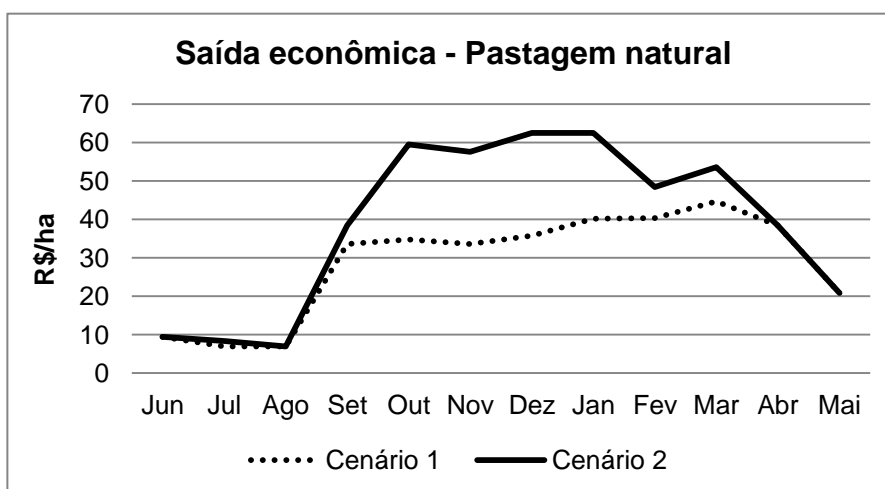


Figura 4. Comparação entre as saídas econômicas dos cenários 1 e 2 da pastagem natural.

Tabela 4

Cenário 1 da pastagem natural melhorada (déficit hídrico).

Variáveis	Jun	Jul	Ago	Set	Out	Nov	Dez	Jan	Fev	Mar	Abr	Mai	Média
Disponibilidade inicial de forragem (kg/MS/ha)	1300	1420	1510	1668	1814	1738	1679	1747	1731	1680	1775	1742	1651
PAR _i (MJ/m ² /dia)	5	5	5	6	7	8	9	9	8	8	7	6	6,30
Eficiência PAR _i /MS (g/MS/MJ ⁻¹)	0,80	0,80	0,80	0,80	0,30	0,30	0,30	0,25	0,25	0,25	0,25	0,20	0,44
Produção potencial de forragem (kg/MS/ha)	1200	1240	1240	1440	651	720	837	697	560	620	525	372	842
ETR/ETP	0,60	0,60	0,70	0,50	0,50	0,50	0,40	0,50	0,50	0,70	0,60	0,60	0,56
Produção real de forragem (kg/MS/ha)	720	744	868	720	325,5	360	418,5	348,75	280	434	315	223,2	480
Disponibilidade final de forragem (kg/MS/ha)	2020	2164	2378	2388	2139	2098	2097	2096	2011	2114	2090	1965	2131
Lotação animal (número de animais/ha)	2,00	2,00	2,00	1,50	1,00	1,00	0,80	0,80	0,70	0,70	0,70	0,50	1,14
Peso médio individual (kg)	250	273	296	319	334	350	365	380	394	404	415	425	350
Carga animal (kg/ha)	500	545	591	478	334	349	291	304	275	282	290	212	371
Consumo e perdas (kg/MS/ha)	600	654	709	574	400	419	349	364	330	339	348	255	446
GMD (kg/animal/dia)	0,750	0,750	0,750	0,500	0,500	0,500	0,500	0,450	0,350	0,350	0,350	0,300	0,504
Ganho peso vivo por área (kg/ha)	45,00	46,500	46,50	22,50	15,50	15,00	12,40	11,16	6,86	7,59	7,35	4,65	Σ = 241,01
Ingresso econômico (R\$/ha)	144,00	148,80	148,80	72,00	49,60	48,00	39,68	35,71	21,95	24,30	23,52	14,88	Σ = 771,25

Tabela 5

Cenário 2 da pastagem natural melhorada (precipitação pluvial normal).

Variáveis	Jun	Jul	Ago	Set	Out	Nov	Dez	Jan	Fev	Mar	Abr	Mai	Média
Disponibilidade inicial de forragem (kg/MS/ha)	1300	1510	1684	1966	2353	2327	2370	2519	2572	2530	2576	2598	2193
PAR _i (MJ/m ² /dia)	5	5	5	6	7	8	9	9	8	8	7	6	6,30
Eficiência PAR _i /MS (g/MS/MJ ⁻¹)	0,80	0,80	0,80	0,80	0,30	0,30	0,30	0,25	0,25	0,25	0,25	0,20	0,44
Produção potencial de forragem (kg/MS/ha)	1200	1240	1240	1440	651	720	837	697,5	560	620	525	372	842
ETR/ETP	0,80	0,80	0,80	0,80	0,70	0,70	0,70	0,60	0,60	0,70	0,80	0,80	0,73
Produção real de forragem (kg/MS/ha)	960	992	992	1152	455,7	504	585,9	418,5	336	434	420	297,6	629
Disponibilidade final de forragem (kg/MS/ha)	2260	2502	2676	3118	2808	2831	2956	2937	2908	2964	2996	2896	2822
Lotação animal (número de animais/ha)	2,50	2,50	2,00	2,00	1,20	1,10	1,00	0,80	0,80	0,80	0,80	0,80	1,36
Peso médio individual (kg)	250	272	295	319	334	349	364	380	393	403	414	425	350
Carga animal (kg/ha)	625	681	591	638	400	384	364	304	315	323	331	340	442
Consumo e perdas (kg/MS/ha)	750	817	709	765	480	461	437	364	378	387	398	408	530
GMD (kg/animal/dia)	0,750	0,750	0,750	0,500	0,500	0,500	0,500	0,450	0,350	0,350	0,350	0,300	0,504
Ganho peso vivo por área (kg/ha)	56,25	58,12	46,50	30,00	18,60	16,50	15,50	11,16	7,84	8,68	8,40	7,44	Σ = 284,99
Ingresso econômico (R\$/ha)	180,00	186,00	148,80	96,00	59,52	52,80	49,60	35,71	25,09	27,78	26,88	23,81	Σ = 911,98




Figura 5. Cenário 1 - Produção e consumo de forragem da pastagem natural melhorada (déficit hídrico).

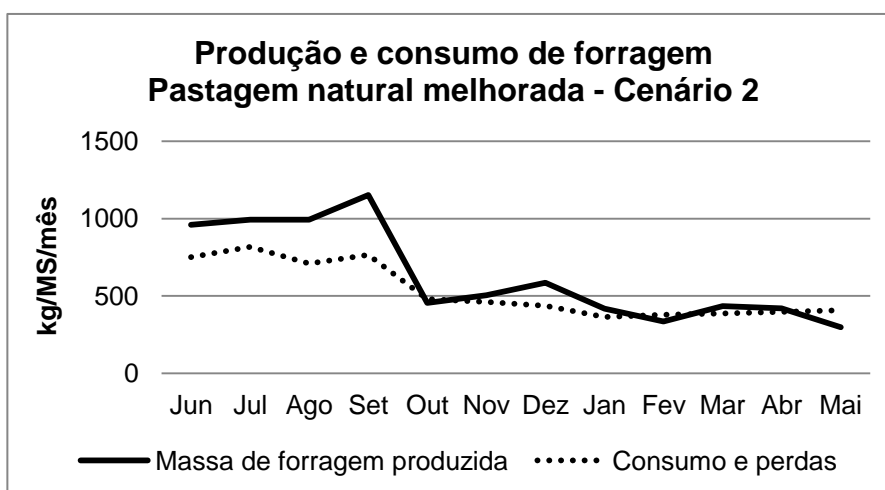


Figura 6. Cenário 2 - Produção e consumo de forragem da pastagem natural melhorada (precipitação pluvial normal).




Figura 7. Comparação entre as saídas econômicas dos cenários 1 e 2 da pastagem natural melhorada.

Tabela 6

Cenário 1 da pastagem cultivada (déficit hídrico).

Variáveis	Jun	Jul	Ago	Set	Out	Média
Disponibilidade inicial de forragem (kg/MS/ha)	1500	1912	1856	1870	1615	1751
PAR _i (MJ/m ² /dia)	5	5	5	6	7	5,8
Eficiência PAR _i /MS (g/MS/MJ ⁻¹)	1,50	1,55	1,50	1,50	1,00	1,40
Produção potencial de forragem (kg/MS/ha)	2250	2325	2325	2700	2170	2354
ETR/ETP	0,60	0,60	0,70	0,50	0,50	0,58
Produção real de forragem (kg/MS/ha)	1350	1395	1627	1350	1085	1362
Disponibilidade final de forragem (kg/MS/ha)	2850	3307	3484	3220	2700	3113
Lotação animal (número de animais/ha)	2,50	3,50	3,50	3,20	3,00	3,14
Peso médio individual (kg)	250	276	307	334	360	306
Carga animal (kg/ha)	625	967	1075	1069	1082	964
Consumo e perdas (kg/MS/ha)	937	1450	1613	1604	1623	1446
GMD (kg/animal/dia)	0,850	1,000	0,900	0,850	0,700	0,860
Ganho peso vivo por área (kg/ha)	63,75	108,50	97,65	81,60	65,10	Σ = 416,60
Ingresso econômico (R\$/ha)	204,00	347,20	312,48	261,12	208,32	Σ = 1333,12

Tabela 7

Cenário 2 da pastagem cultivada (precipitação pluvial normal).

Variáveis	Jun	Jul	Ago	Set	Out	Média
Disponibilidade inicial de forragem (kg/MS/ha)	1500	1987	1836	1622	1776	1744
PAR _i (MJ/m ² /dia)	5	5	5	6	7	5,8
Eficiência PAR _i /MS (g/MS/MJ ⁻¹)	1,50	1,55	1,50	1,50	1,00	1,40
Produção potencial de forragem (kg/MS/ha)	2250	2402	2325	2700	2170	2369
ETR/ETP	0,80	0,80	0,80	0,80	0,70	0,78
Produção real de forragem (kg/MS/ha)	1800	1922	1860	2160	1519	1852
Disponibilidade final de forragem (kg/MS/ha)	3300	3909	3696	3782	3295	3596
Lotação animal (número de animais/ha)	3,50	5,00	4,50	4,00	3,50	4,10
Peso médio individual (kg)	250	276	307	334	360	305
Carga animal (kg/ha)	875	1381	1383	1337	1262	1247
Consumo e perdas (kg/MS/ha)	1312	2072	2074	2006	1893	1871
GMD (kg/animal/dia)	0,850	1,000	0,900	0,850	0,700	0,860
Ganho peso vivo por área (kg/ha)	89,25	155,00	125,55	102,00	75,95	Σ = 547,75
Ingresso econômico (R\$/ha)	285,60	496,00	401,76	326,40	243,04	Σ = 1752,8




Figura 8. Cenário 1 - Produção e consumo de forragem da pastagem cultivada (déficit hídrico).




Figura 9. Cenário 2 - Produção e consumo de forragem da pastagem cultivada (precipitação pluvial normal).




Figura 10. Comparação entre as saídas econômicas dos cenários 1 e 2 da pastagem cultivada.

CAPÍTULO V

6. CONCLUSÕES GERAIS

O modelo conceitual apresentado, expressa adequadamente o funcionamento de uma unidade de produção pecuária e é capaz de representar de forma coerente as mais relevantes saídas do sistema: rentabilidade, análise de risco e sustentabilidade ambiental.

O modelo matemático por sua vez, sintetiza as variáveis de maior relevância identificadas pelo modelo conceitual e estrutura a unidade de produção a partir de equações integrais e diferenciais, fornecendo subsídios para projetar o tamanho e perfil do rebanho de acordo com os recursos alimentares disponíveis, considerando o fluxo de caixa como balizador do equilíbrio entre custos e receitas da unidade.

Por fim, a simulação de uma pequena parcela do macro modelo bioeconômico apresentado de forma conceitual e matemática, demonstra a viabilidade dos sistemas pecuários de produção de carne bovina à pasto. Em todos os cenários apresentados, a atividade pecuária apresentou-se lucrativa.

A metodologia dinâmica de sistemas foi capaz de representar de forma flexível e organizada o funcionamento do sistema de produção estudado, permitindo planejar, comparar e dimensionar inúmeras variáveis, gerando resultados de produtividade técnica e econômica para os diferentes cenários construídos.

7. IMPLICAÇÕES PARA FUTUROS TRABALHOS

“It is not knowledge, but the act of learning, not possession but the act of getting there, which grants the greatest enjoyment.” (Karl Friedrich Gauss – 1977-1855)

A crescente informatização da sociedade moderna, incluindo o meio rural, tem gerado grandes oportunidades de armazenamento e veiculação de dados, informações e conhecimento a serem utilizados no auxílio à tomada de decisão. Sistemas de decisão devem, portanto, fazer uso inteligente de tais dados e informações nos seus diversos contextos de atuação. Contudo, um aspecto importante a ser destacado é o fato de muitos acreditarem que o apenas o conhecimento dos gestores de empresas, adquirido no ambiente de trabalho pela experiência ao longo dos anos, é suficiente para enfrentar os problemas.

Não se pode deixar de admitir a experiência direta como um dos mais persuasivos e eficientes processos de aprendizagem. No entanto, é preciso entender que o processo de aprendizado no ambiente de trabalho por meio da experiência direta é limitado e pode desenvolver ou reforçar premissas e visões equivocadas a respeito do funcionamento do sistema de produção.

Neste contexto, a utilização de modelos de simulação vem a auxiliar efetivamente a tomada de decisão pelo produtor rural, constituindo-se num

valioso instrumento de aprendizado para a implantação de novas tecnologias e descarte daquelas já ultrapassadas. Porém, a construção de modelos em sistemas biológicos ou “vivos” não é simples. Devido à complexidade apresentada pelos sistemas pecuários, a simulação representa um desafio ao modelador, no sentido de desenvolver modelos abrangentes capazes de suportar análises de decisões complexas envolvendo tais sistemas.

O fato dos modelos disponíveis, relacionados aos sistemas pecuários, não representarem adequadamente diversas e importantes características dos sistemas de produção estimula cada vez mais pesquisadores a gerar conhecimento e quantificar os processos relativos aos sistemas de produção, em especial aqueles que envolvem animais em pastagens.

Na presente tese, a metodologia dinâmica de sistemas demonstrou ser uma ferramenta capaz de modelar sistemas abrangentes e complexos. A dinâmica de sistemas possui como diferencial o processo de participação direta do modelador na construção do modelo, aumentando sua confiabilidade, uma vez que as sugestões dos gestores (decisores) auxiliam no direcionamento de novas simulações e modificações na estrutura do modelo. A metodologia, como ferramenta de decisão, apresentou ainda a capacidade de identificação de pontos de estrangulamento das atividades produtivas e avaliações perspectivas.

Além disso, a metodologia permite a visualização das relações de influência no sistema, não perceptíveis em análises de modelos puramente mentais. Portanto, os diagramas de causa e efeito, apresentados pela dinâmica

de sistemas, são adequados para o estudo do comportamento dos sistemas pecuários, e úteis no processo de planejamento estratégico.

Em pesquisas futuras, a metodologia poderá ser utilizada para avaliar pontos específicos e seu grau de impacto como, por exemplo, aspectos relacionados à fisiologia animal e vegetal, visando uma análise detalhada dos componentes que interferem de forma específica em cada segmento do sistema de produção.

Ao longo da pesquisa, as maiores dificuldades encontradas dizem respeito à escassez de trabalhos científicos que apresentem de forma explícita os procedimentos, resultados e recursos didáticos para a orientação da construção de modelos dinâmicos. Outra dificuldade encontra-se na flexibilidade da dinâmica de sistemas, o que demanda do modelador um profundo conhecimento a respeito da problemática abordada e da linguagem de programação adotada pelos *softwares* que utilizam esta metodologia. Por outro lado, esta característica direciona o modelador para um processo de aprendizagem contínuo, à medida que novas versões do modelo são propostas e testadas.

Assim, para que esforços de pesquisa com visão sistêmica resultem em modelos matemáticos mais sofisticados, versáteis e confiáveis, faz-se necessário o estreitamento entre recursos humanos das mais distintas áreas do conhecimento, a fim de formar equipes multi e interdisciplinares que respondam de maneira clara e acessível aos anseios do meio agropecuário. No entanto, apenas a formação de equipes multidisciplinares e integração de mentes pensantes das mais diversas áreas do conhecimento não basta! É

necessário que a pesquisa evolua vislumbrando preencher as lacunas presentes nos segmentos mais básicos da ciência, como a produção de dados confiáveis e verdadeiramente relevantes para a sociedade como um todo.

A modelagem, em especial a modelagem conceitual, é uma ferramenta de extrema utilidade para este fim, e ao construirmos boa parte dos modelos que nortearam esta tese, percebemos que por mais que evoluíssemos e sofisticássemos “nosso sistema de produção”, estaríamos fardados ao insucesso pela ausência de dados e informações em alguns pontos chave da ciência. Entre os principais entraves encontrados para a evolução do modelo estão a ausência de bancos de dados com informações específicas para as pastagens naturais do Rio Grande do Sul, como por exemplo, a radiação fotossinteticamente ativa incidente e seu impacto no crescimento do pasto. Além disso, ressalta-se a necessidade de padrões metodológicos comuns a inúmeros segmentos da pesquisa. Inacreditavelmente, metodologias “padrão” ainda são pouco utilizadas para a construção de bancos de dados confiáveis.

A frustração em determinados momentos, nos permitiu refletir sobre a (in)compatibilidade da evolução da ciência e a geração de dados para trabalhos futuros. A conclusão desta reflexão, nos fez acreditar, por vezes, que a ciência aplicada caminha em sentido contrário ao conhecimento básico que deveria norteá-la, como o entendimento dos processos biológicos. Assim, em alguns momentos os estudos e pesquisas envolvendo a modelagem de sistemas, deverão “retroceder” e retornar ao campo (ou ao chão de fábrica) para buscar dados que alimentem de forma robusta os modelos e simulações. Neste caso, o termo “retroceder” não possui caráter pejorativo, pelo contrário,

implica em almejar o avanço da ciência com uma base sólida de informações sobre as mais diversas áreas.

É notório, que apenas o enaltecimento de uma das principais vantagens da modelagem de sistemas, a identificação de lacunas do conhecimento, não possui significado algum, se não houverem grupos dispostos a entender os reais motivos que geraram tais lacunas, avaliar a melhor forma de preenchê-las e produzir conhecimento de qualidade! Ainda neste sentido, citar a “quebra de paradigmas” como um dos grandes desafios da ciência atual, sem compreender que a pesquisa deve objetivar sempre a produção de dados concretos e não a pirotecnia, constitui um discurso vazio.

No setor agropecuário, este fato é ainda mais grave, pois não avançaremos em metodologias sofisticadas como a dinâmica de sistemas, se antes não conhecermos de forma detalhada, nosso ambiente de produção desde o chão de fábrica (campo) até o consumidor final (atacado e varejo). Somente com conhecimento da base do sistema, seremos capazes de incrementar e diferenciar nossa produção, agregando valor ao produtor e desbravando novos mercados, além de avançar nas imensas fronteiras agropecuárias (e científicas) ainda mal exploradas no Brasil (e no mundo). Acreditar que os produtores rurais são capazes de produzir um produto com características totalmente diferentes daquelas produzidas pelos outros setores da economia e que ainda há muito a produzir, em quantidade e qualidade, pode ser o primeiro passo na busca de qualificação e amplitude de visão dos homens do campo, bem como no seu enaltecimento frente à sociedade urbana.

REFERÊNCIAS BIBLIOGRÁFICAS

- ANNETTS, J. E.; AUDSLEY, E. Multiple objective linear programming for environmental farm planning. **Journal of the Operational Research Society**, Hants, v. 53, n. 9, p. 933-943, 2002.
- AUSTIN, E. J. et al. Empirical models of farmer behavior using psychological, social and economic variables. Part II: nonlinear and expert modelling. **Agricultural Systems**, Oxon, v. 58, n. 2, p. 225-241, 1998.
- BOEHLJE, M. Structural changes in the agricultural industries: how do we measure, analyze and understand them? **American Journal Agricultural Economics**, Ames, v. 81, n. 5, p. 1028-1041, 1999.
- BUONOMANO, A.; CALISE, F.; PALOMBO, A. Buildings dynamic simulation: water loop heat pump systems analysis for European climates. **Applied Energy**, Oxon, v. 91, n. 1, p. 222-234, 2012.
- CANGIANO, C. A.; FERNÁNDEZ, H. H.; GALLI, J. R. **ConPast 3.0**: programa de computación para la estimación del consumo de bovinos en pastoreo. Balcarce: Instituto Nacional de Tecnología Agropecuaria, 1999. 228 p.
- CINO, D. M.; VALDES, G. Simulation of the economical feasibility of the utilization of the Voisin grazing system in beef fattening. **Cuban Journal of Agriculture Science**, Havana, v. 29, n. 2, p. 145-151, 1995.
- CUNDILL, G. et al. Soft systems thinking and social learning for adaptive management. **Conservation Biology**, Malden, v. 26, n. 1, p. 13-20, 2012.
- DAVIS, K. C. et al. Life cycle evaluation of 5 biological types of beef-cattle in a cow-calf range system. 2. Biological and economic-performance. **Journal of Animal Science**, Savoy, v. 72, n. 10, p. 2591-2598, 1994.
- DRACK, M.; SCHWARZ, G. Recent developments in general system theory. **Systems Research Behavioral Science**, West Sussex, v. 27, n. 6, p. 601-610, 2010.
- FERREIRA, G. **An evolutionary approach to farming decision making on extensive rangelands**. 1997. 370 f. Tese (Doutorado) - Programa de Pós-Graduação em Ecologia e Manejo de Recursos Naturais, Institute of Ecology and Resource Management, University of Edinburgh, Edinburgh, 1997.
- FORRESTER, J. W. Policies, decisions and information-sources for modeling. **European Journal of Operational Research**, Netherlands, v. 59, n. 1, p. 42-63, 1992.

FRENCH, S. et al. Human reliability analysis: a critique and review for managers. **Safety Science**, Netherlands, v. 49, n. 6, p. 753-763, 2011.

GOUTTENOIRE, L.; COURNOT, S.; INGRAND, S. Modelling as tool to redesign livestock farming systems: a literature review. **Animal**, Edinburgh, v. 5, n. 12, p. 1957-1971, 2011.

GUASTELLO, S.J. Non-linear dynamics and leadership emergence. **Leadership Quarterly**, New York, v. 18, n. 4, p. 357-369, 2007.

HARDAKER, J. B.; LIEN, G. Probabilities for decision analysis in agriculture and rural resource economics: the need for a paradigm change. **Agricultural Systems**, Oxon, v. 103, n. 6, p. 345-350, 2010.

HURYK, L.A. Information systems and decision support systems. **American Journal of Nursing**, Philadelphia, v. 112, n. 1, p. 62-65, 2012.

JAKKU, E.; THORBURN, P. J. A conceptual framework for guiding the participatory development of agricultural decision support systems. **Agricultural Systems**, Oxon, v. 103, n. 9, p. 675-682, 2010.

JANSSEN, S.; VAN ITTERSUM, M. K. Assessing farm innovations and responses to policies: a review of bio-economic farm models. **Agricultural Systems**, Oxon, v. 94, n. 3, p. 622-636, 2007.

KAINE, G.; COWAN, L. Using general systems theory to understand how farmers manage variability. **System Research and Behavioral Science**, Malden, v. 28, n. 3, p. 231-244, 2011.

KIM, D. H.; SENGE, P. M. Putting systems thinking into practice. **System Dynamics Review**, West Sussex, v. 10, n. 2-3, p. 277-290, 1994.

KREUTER, U. P. et al. Decision support software for estimating the economic efficiency of grazingland production. **Journal of Range Management**, Denver, v. 49, n. 5, p. 464-469, 1996.

LI, X.J.; YANG, G.H. Dynamic output feedback control synthesis for stochastic time-delay systems. **International Journal of Systems Science**, Oxon, v. 43, n. 3, p. 586-595, 2012.

LICHTENSTEIN, B. M. B. Emergence as a process of self-organizing - new assumptions and insights from the study of non-linear dynamic systems. **Journal of Organizational Change Management**, West Yorkshire, v. 13, n. 6, p. 526-544, 2000.

LYNEIS, J.M. Strategic modelling and business dynamics: a feedback systems approach. **Journal of the Operational Research Society**, Hants, v. 62, n. 5, p. 934-935, 2011.

MAANI, K. E.; CAVANA, R. Y. **Systems thinking and modelling - understanding change and complexity**. Auckland: Prentice Hall, 2000. 261 p.

MACHADO, C. F. et al. A web-based model for simulating whole-farm beef cattle systems. **Computers and Electronics in Agriculture**, Oxon, v. 74, n. 1, p. 129-136, 2010.

MACHUM, S. The persistence of family farming in the wake of agribusiness: a New Brunswick, Canada case study. **Journal of Comparative Family Studies**, Calgary, v. 36, n. 3, p. 377-390, 2005.

MAGNE, M. A.; CERF, M.; INGRAND, S. A conceptual model of farmers' informational activity: a tool for improved support of livestock farming management. **Animal**, Edinburgh, v. 4, n. 6, p. 842-852, 2010.

MATTHEWS, K. B. et al. Assessing the options for upland livestock systems under CAP reform: developing and applying a livestock systems model within whole-farm systems analysis. **Agricultural Systems**, Oxon, v. 90, n. 1-3, p. 32-61, 2006.

MOGHADDAM, K. S.; DePUY, G. W. Farm management optimization using chance constrained programming method. **Computers and Electronics in Agriculture**, Oxon, v. 77, n. 2, p. 229-237, 2011.

MOSNIER, C.; AGABRIEL, J.; LHERN, M. A dynamic bio-economic model to simulate optimal adjustments of suckler cow farm management to production and market shocks in France. **Agricultural Systems**, Oxon, v. 102, n. 1-3, p. 77-88, 2009.

MUNIZ, A. J. O.; FARIA, H. A. **Teoria geral da administração - noções básicas**. 4. ed. São Paulo: Atlas, 2001. 168 p.

MUSSHOFF, O.; HIRSCHAUER, N. What benefits are to be derived from improved farm program planning approaches? The role of time series models and stochastic optimization. **Agricultural Systems**, Oxon, v. 95, n. 1-3, p. 11-27, 2007.

NABINGER, C.; CARVALHO, P. C. F. Ecofisiología de sistemas pastoriles: aplicaciones para su sustentabilidad. **Agrociencia**, Montevideo, v. 13, n. 3, p. 18-27, 2009.

NAZEMI, A. R. A dynamic model for solving convex nonlinear optimization problems. **Communications in Nonlinear Science and Numerical Simulation**, Netherlands, v. 17, n. 4, p. 1696-1705, 2012.

NEWMAN, S. et al. Hotcross: a decision support aid for crossbreeding of beef cattle in tropical and subtropical environments. In: CONFERENCE BREEDING -

RESPONDING TO CLIENT NEEDS, 20., 1997, Dubbo. **Proceedings...** Dubbo: Association for the Advancement of Animal Breeding and Genetics, 1997. p. 400-404.

NICHOLSON, C. F. et al. Economic comparison of nutritional management strategies for Venezuelan dual-purpose cattle systems. **Journal of Animal Science**, Savoy, v. 72, n. 7, p. 1680-1696, 1994.

NOUSIAINEN, J. et al. Dairy farm nutrient management model. 1. Model description and validation. **Agricultural Systems**, Oxon, v. 104, n. 5, p. 371-382, 2011.

NUTHALL, P. L. The intuitive world of farmers - the case of grazing management systems and experts. **Agricultural Systems**, Oxon, v. 107, n. 1, p. 65-73, 2012.

PANG, H. et al. Structure of a dynamic simulation model for beef cattle production systems. **Canadian Journal of Animal Science**, Ottawa, v. 79, n. 4, p. 409-417, 1999.

PLÀ, L. M. Review of mathematical models for sow herd management. **Livestock Science**, Netherlands, v. 106, n. 2-3, p. 107-119, 2007.

RADZICKI, M. J. Mr. Hamilton, Mr. Forrester, and a foundation for evolutionary economics. **Journal of Economic Issues**, Knoxville, v. 37, n. 1, p. 133-173, 2003.

RAGNI, M.; STEFFENHAGEN, F.; KLEIN, A. Generalized dynamic stock and flow systems: an al approach. **Cognitive Systems Research**, Freiburg, v. 12, n. 3-4, p. 309-320, 2011.

RICHARDSON, G. P. Reflections on the foundations of system dynamics. **System Dynamics Review**, Albany, v. 27, n. 3, p. 219-243, 2011.

RITTEN, J. P.; BASTIAN, C. T.; FRASIER, W. M. Economically optimal stocking rates: a bioeconomic grazing model. **Rangeland Ecology & Management**, Lakewood, v. 63, n. 4, p. 407-414, 2010.

ROLLO, M. D. et al. Evaluation of a beef growth model for use in beef finishing decisions. **Proceedings of the New Zealand Grassland Association**, Wellington, v. 57, p. 95-99, 1996.

ROMEIRO, V. M. B. **Gestão da pequena unidade de produção familiar de citros: uma análise dos fatores influentes no sucesso do empreendimento do ponto de vista do produtor de bebedouro.** 2002. 242 f. Dissertação (Mestrado) - Programa de Pós-Graduação em Engenharia da Produção, Faculdade de Engenharia, Universidade Federal de São Carlos, São Paulo, 2002.

ROTZ, C. A.; BUCKMASTER, D. R.; COMERFORD, J. K. A beef herd model for simulating feed intake, animal performance, and manure excretion in farm systems. **Journal of Animal Science**, Savoy, v. 83, n. 1, p. 231-242, 2005.

SENGE, P. M. et al. Collaborating for systemic change. **MIT Sloan Management Review**, Massachusetts, v. 48, n. 2, p. 44-53, 2007.

SENGE, P. M.; STERMAN, J. D. Systems thinking and organizational learning - acting locally and thinking globally in the organization of the future. **European Journal of Operational Research**, Netherlands, v. 59, n. 1, p. 137-150, 1992.

SIMON, H. A. A behavioral model of rational choice. **Quarterly Journal of Economics**, Cambridge, v. 69, n. 1, p. 99-118, 1955.

SØRENSEN, C. G. et al. Functional requirements for a future farm management information system. **Computers and Electronics in Agriculture**, New York, v. 76, n. 2, p. 266-276, 2011.

STERMAN, J. D. Learning from evidence in a complex world. **American Journal of Public Health**, Birmingham, v. 96, n. 3, p. 505-514, 2006.

STERMAN, J.D. System dynamics modeling: tools for learning in a complex world. **California Management Review**, Berkeley, v. 43, n. 4, p. 8-25, 2001.

STERMAN, J.D. **Systems dynamics - thinking systems and modeling for a complex world**. New York: McGraw-Hill, 2000. 982 p.

TANURE, S.; NABINGER, C. Ferramentas de gerenciamento bioeconômico e suporte à decisão em empresas de pecuária de corte. In: CONGRESO INTERNACIONAL DE LA CARNE BOVINA, 4., 2010, Asunción. **Anais...** Asunción: Universidad Nacional de Asunción, 2010. 29 p. 1 CD-ROM.

TESS, M. W.; KOLSTAD, B. W. Simulation of cow-calf production systems in a range environment: I. Model development. **Journal of Animal Science**, Savoy, v. 78, n. 5, p. 1159-1169, 2000.

WEIL, H.B. Application of system dynamics to corporate strategy: an evolution of issues and frameworks. **System Dynamics Review**, West Sussex, v. 23, n. 2-3, p. 137-156, 2007.

WILLIAMS, C. B.; BENNET, G. L.; KEELE, J. W. Simulated influence of postweaning production system on performance of different biological types of cattle. 3. Biological efficiency. **Journal of Animal Science**, Savoy, v. 73, n. 3, p. 686-698, 1995.

WILMAN, D.; MTENGETI, E. J.; MOSELEY, G. Physical structure of twelve forage species in relation to rate of intake by sheep. **Journal of Agricultural Science**, New York, v. 126, n. 3, p. 277-285, 1996.

WOLFSLEHNER, B.; VACIK, H. Mapping indicator models: from intuitive problem structuring to quantified decision-making in sustainable forest management. **Ecological Indicators**, Netherlands, v. 11, n. 2, p. 274-283, 2011.

ZOTT, C.; AMIT, R.; MASSA, L. The business model: recent developments and future research. **Journal of Management**, Thousand Oaks, v. 37, n. 4, p. 1019-1042, 2011.

VITA

Soraya Tanure, filha de Sady Elias Tanure e Lia Lemos Tanure nasceu em 28 de novembro de 1982, no município de Porto Alegre, Estado do Rio Grande do Sul.

Cursou o ensino fundamental e médio no Colégio Maria Auxiliadora – Escola de 1º e 2º Graus, no município de Canoas, onde atualmente reside. Em 2000 ingressou no curso de medicina veterinária da Universidade Luterana do Brasil (ULBRA). Durante a graduação teve experiência na área de pesquisa como bolsista de iniciação científica da Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul nos anos de 2004 e 2005, e como bolsista voluntária da Pró-Reitoria de Pesquisa - ULBRA entre 2002 e 2004, sob a orientação do Professor Carlos Santos Gottschall. Atuou em projetos de pesquisa relacionados à produção e manejo de bovinos de corte, bem como realizou estágios na área de melhoramento genético, forragicultura e integração lavoura e pecuária. Concluiu a graduação em agosto de 2005, com o trabalho intitulado “Sistemas de Produção para Recria de Novilhas de Corte”, sob a orientação do Professor Jamir Luís Silva da Silva.

Em março de 2006 ingressou no Programa de Pós-Graduação em Zootecnia da Universidade Federal do Rio Grande do Sul (UFRGS), curso de mestrado, área de concentração produção animal, como bolsista CNPq, sob a orientação do Professor José Fernando Piva Lobato. Concluiu o curso de mestrado em março de 2008 com a dissertação intitulada “Estratégias de Manejo Nutricional para Novilhas e Vacas Primíparas de Corte”. No mesmo ano iniciou o curso de doutorado no também no Programa de Pós-Graduação em Zootecnia da UFRGS, como bolsista CAPES, na área de concentração plantas forrageiras, sob a orientação do professor Carlos Nabinger. Concluiu o doutorado em abril de 2012, com a tese intitulada “Modelo Bioeconômico para Suporte à Decisão em Sistemas Pecuários”.