



Universidade Federal  
do Rio de Janeiro  

---

Escola Politécnica

## **Uso de sistemas fuzzy para implementar políticas de decisão em modelos de dinâmica de sistemas**

Daniel Cardoso de Salles

Projeto de Graduação apresentado ao  
Curso de Engenharia de Produção da  
Escola Politécnica, Universidade  
Federal do Rio de Janeiro.

Orientador:

Prof. Lino Guimarães Marujo, D. Sc.

Co- Orientador:

Prof. Armando Gonçalves Neto, D. Sc.

Rio de Janeiro

Setembro 2013

# **Uso de sistemas fuzzy para implementar políticas de decisão em modelos de dinâmica de sistemas**

Daniel Cardoso de Salles

PROJETO DE GRADUAÇÃO DO CURSO DE ENGENHARIA DE  
PRODUÇÃO DA ESCOLA POLITÉCNICA DA UNIVERSIDADE  
FEDERAL DO RIO DE JANEIRO.

Examinada por:

---

Prof. Lino Guimarães Marujo, D.Sc. (Orientador)

---

Prof. Armando Gonçalves Neto, D.Sc. (Co-Orientador)

---

Prof. Amarildo da Cruz Fernandes, D. Sc

---

Prof. Valdir Agostinho de Melo, D. Sc

RIO DE JANEIRO, RJ - BRASIL

SETEMBRO 2013

de Salles, Daniel Cardoso

Uso de sistemas fuzzy para implementar políticas de decisão em modelos de dinâmica de sistemas / Daniel Cardoso de Salles - Rio de Janeiro: UFRJ/Escola Politécnica, 2013.

IX, 85 p.: il.; 29,7 cm.

Projeto de Graduação – Universidade Federal do Rio de Janeiro, Escola Politécnica, Departamento de Engenharia Industrial, Curso de Engenharia de Produção, 2013

Referências Bibliográficas: pág 75-79

1 – Inferência Fuzzy. 2 – Dinâmica de Sistemas. 3 – Controladores de Negócio

I. Marujo, Lino Guimarães. Universidade Federal do Rio de Janeiro III. Uso de sistemas fuzzy para implementar políticas de decisão em modelos de dinâmica de sistemas

“ I don’t want to live in a world without melody”

“ My divinity is caught between the colors of a butterfly”

**Bad Religion**

## **Agradecimentos**

Primeiramente agradeço a minha família: meus pais, meu irmão, meus avós e meus tios. Faltam linhas e palavras para dizer como vocês são importantes para mim, estarei sempre buscando orgulhá-los da mesma forma que me orgulho de vocês.

A minha namorada, Stella, pelo apoio e paciência incondicionais, sempre me fazendo acreditar que há luz no fim do túnel.

Aos meus amigos, de infância, do colégio, da faculdade, da vida, perto ou longe, muito do que sou hoje como pessoa devo a vocês. Não citarei nomes para evitar esquecer alguém, àqueles que me refiro sabem quem são.

Aos professores do curso de engenharia de produção, especialmente meus orientadores Lino e Armando que além de conhecimento me deram algo tão valioso quanto, confiança. Também ao professor Amarildo, sem sua eloqüente apresentação de dinâmica de sistemas ficaria faltando uma das metades desse trabalho.

Por último, a professora e coordenadora Maria Alice, sem suas soluções para os meus intermináveis problemas agora não estaria me formando.

Resumo do Projeto de Graduação apresentado à Escola Politécnica/ UFRJ como parte dos requisitos necessários para a obtenção do grau de Engenheiro de Produção.

Uso de sistemas fuzzy para implementar políticas de decisão em modelos de dinâmica de sistemas

Daniel Cardoso de Salles

Setembro/2013

Orientador: Prof. Lino Guimarães Marujo, D.Sc.

Co-Orientador: Prof. Armando Gonçalves Neto, D.Sc.

Curso: Engenharia de Produção

Lógica fuzzy e dinâmica de sistemas são duas abordagens que lidam com complexidades construindo modelos mentais. A primeira tem o maior objetivo de modelar matematicamente variáveis linguísticas e sua inerente vagueza e imprecisão, permitindo usá-las para simular o raciocínio humano. Dinâmica de sistemas introduz um conjunto de ferramentas, notadamente a linguagem de fluxos e estoques, para criar modelos aproveitando todas as informações disponíveis e percepções e que permitem testar em simulações diferentes processos decisórios. O presente trabalho tem como objetivo mostrar que essas duas abordagens podem ser combinadas de maneira a potencializar o aprendizado organizacional.

Depois de breve revisão da teoria dessas duas abordagens, foi proposta uma metodologia para integrá-las aproveitando a capacidade da DS para modelar sistemas dinâmicos complexos e a habilidade da lógica fuzzy de modelar o raciocínio humano, especificamente sistemas fuzzy de decisão. Na sequência foi revisada a literatura em busca de propostas teóricas ou práticas de integração entre as duas abordagens e, finalmente, apresentou-se um estudo de caso simples para ilustrar a operacionalização da metodologia e analisar sua viabilidade.

Palavras-chave: Sistemas Fuzzy, Dinâmica de Sistemas, Balance Scorecard Dinâmico

Abstract of the Undergraduate Project presented to POLI/UFRJ as a partial fulfillment of the requirements for the degree of Industrial Engineer.

Use of fuzzy systems to implement decision policies in systems dynamics' models

Daniel Cardoso de Salles

September/2013

Advisor: Lino Guimarães Marujo (D. Sc.)

Co-Advisor: Armando Gonçalves Neto (D.Sc.)

Course: Industrial Engineering

Fuzzy logic and dynamic systems are two approaches that deal with complexities building mental models. The former has the highest goal to mathematically model linguistic variables and its inherent vagueness and imprecision, allowing to use them for human reasoning simulation. The latter introduces a set of tools, notably the flows and stocks language, to create models using all the available data and insights that enable testing different decision-making processes in simulations. This paper main objective is to show that these two approaches can be combined in order to maximize organizational learning.

After a brief review of the theory of these two approaches, a methodology was proposed to integrate them taking advantage of the DS's ability to model complex dynamic systems and the ability of fuzzy logic to model the human reasoning, specifically fuzzy decision systems. Following literature was reviewed searching for theoretical or practical proposals of integration between the two approaches. Finally it was presented a simplified case study to exemplify the implementation of the methodology and to evaluate its viability.

Keywords: Fuzzy Systems, System Dynamics, Dynamic Balance Scorecard

## SUMÁRIO

1	Introdução.....	1
1.1	Objetivos .....	2
1.1.1	Objetivo Geral .....	2
1.1.2	Objetivos Específicos .....	2
1.2	Metodologia .....	2
2	Apresentação das Teorias .....	4
2.1	Lógica Fuzzy .....	4
2.1.1	Fuzzy e Incerteza .....	4
2.1.2	Teoria de Conjuntos Fuzzy .....	5
2.1.3	Lógica Fuzzy.....	6
2.1.4	Implicação.....	9
2.1.5	Inferência Dedutiva e Approximate reasoning.....	11
2.1.6	Outras formas de implicação .....	12
2.1.7	Sistemas fuzzy .....	12
2.1.8	Técnicas Gráficas de Inferência.....	13
2.1.9	Técnicas de Defuzzificação .....	17
2.2	Dinâmica de Sistemas .....	18
2.2.1	Ferramentas de Modelagem dos Sistemas .....	19
2.2.1	Princípios para utilização de dinâmica de sistemas.....	22
3	A integração de dinâmica de sistemas e lógica fuzzy .....	24
3.1	O pensamento sistêmico e o aprendizado .....	24
3.2	Proposta de Metodologia.....	30
3.2.1	Justificativa da Metodologia.....	30
3.2.2	A metodologia proposta.....	33
3.3	Revisão da bibliografia que integra fuzzy a dinâmica de sistemas.....	37



4 Estudo de caso: Empresa xyz .....	43
4.1 Etapas “pré-controle” .....	43
4.2 Controlador 1 .....	55
4.3 Controlador 2 .....	62
4.4 Controlador 3 .....	66
4.5 Discussão dos Resultados da Integração.....	71
5 Conclusão.....	73
Referências bibliográficas .....	75
Apêndice 1: A toolbox de lógica fuzzy no matlab .....	80
Apêndice 2: As alternativas computacionais de integração entre fuzzy e dinâmica de sistemas .....	82

## ÍNDICE DE FIGURAS

Figura 1 Exemplo de Conjunto Fuzzy .....	6
Figura 2 Representação em diagrama de Venn da implicação .....	10
Figura 3 Método gráfico Mamdani máx-mim com inputs crisp.....	14
Figura 4 Método gráfico Mamdani máx-prod com inputs crisp.....	15
Figura 5 Método gráfico Sugeno com inputs crisp .....	16
Figura 6 Defuzzificação pelo princípio da máxima pertinência.....	17
Figura 7 Defuzzificação pelo método centróide.....	18
Figura 8 Loop causal de ajustamento de estoques.....	20
Figura 9 Modelo de fluxos e estoques da força de trabalho .....	21

Figura 10 Uma estrutura de feedback simples.....	22
Figura 11 Processo decisório linear orientado a eventos.....	25
Figura 12 Processo decisório com feedback .....	25
Figura 13 Aprendizado com dois loops.....	27
Figura 14 As barreiras ao aprendizado e sua relação com mundos virtuais .....	28
Figura 15 Esquema da integração entre sistema fuzzy e modelo de DS.....	33
Figura 16 Metodologia fuzzy-DS para resolução de problemas .....	34
Figura 17 Diagrama de Enlace Causal da empresa XYZ.....	45
Figura 18 Modelo de Fluxos e Estoques da empresa XYZ.....	46
Figura 19 Resultados do modelo sem controle.....	52
Figura 20 Perfis da Análise de sensibilidade e seus resultados .....	54
Figura 21 Pertinências do controlador 1.....	58
Figura 22 Resultados do Controlador 1.....	61
Figura 23 Estrutura do Controlador 2.....	63
Figura 25 Estrutura do Controlador 3.....	68
Figura 26 Resultados do Controlador 3.....	69
Figura 28 Telas do toolbox de sistemas fuzzy do Matlab® .....	80
Figura 29 Integração por DLL do Vensim ao Matlab .....	83
Figura 30 Modelo de integração computacional usado na prática do estudo de caso.....	85
Figura 31 Código do Matlab utilizado no estudo de caso .....	85

# 1 Introdução

Em momentos quase simultâneos na história, duas revolucionárias áreas de conhecimento foram desenvolvidas: a dinâmica de sistemas, criada por Jay Forrester do MIT na década de 50, e a lógica fuzzy, criada por Lotfi Zadeh na década de 60. Ambas surgiram da percepção que as ferramentas de suas épocas eram incapazes de tratar os problemas reais de forma adequada.

A dinâmica de sistemas percebia a deficiência de nosso processo decisório em considerar a complexidade dinâmica dos sistemas. Propunha para contorná-la a utilização de ferramentas de modelagem que permitissem discutir, refinar e simular modelos mentais expostos a diferentes políticas. Sua maior contribuição foi a criação de mundos virtuais, laboratórios de experimentos controlados que potencializavam o aprendizado.

A lógica fuzzy e a relacionada teoria de conjuntos fuzzy, foram criadas com o intuito de adequar o ferramental matemático da lógica a tipos de incerteza característicos da linguagem humana e seus modelos mentais. Desenvolvia assim um instrumental matemático capaz de modelar em sistemas lógicos a forma de raciocinar humana.

Como se pode notar, essas duas áreas de conhecimento tem em comum a tentativa de suportar e aprimorar o processo decisório, a primeira através do desenvolvimento e simulação de modelos mentais complexos e a segunda com uma linguagem matemática capaz de reproduzir processos decisórios de forma mais fiel ao raciocínio humano. Partindo dessa complementaridade que irá se construir esse trabalho, buscar-se-á destacar os pontos de benefício que uma abordagem fornece a outra e culminando na proposta de uma metodologia integrada.

## **1.1 Objetivos**

### **1.1.1 Objetivo Geral**

A complementaridade de dinâmica de sistemas (DS) e lógica fuzzy será o tema principal desse trabalho. Buscar-se-á apresentar cada uma das áreas de conhecimento a fim de destacar precisamente os pontos beneficiados com a integração em uma proposta de metodologia fuzzy-DS para resolução de problemas.

Na sequência, irá se recorrer às publicações científicas em busca de propostas ou implementações de objetivo semelhante e finalmente apresentar-se-á um estudo de caso para demonstrar a integração na prática e seu resultado.

### **1.1.2 Objetivos Específicos**

Pode-se separar a sequência proposta no item anterior nos seguintes objetivos:

- Revisar a teoria relevante de dinâmica de sistemas e lógica fuzzy;
- Delinear com clareza os pontos de complementaridade e apresentar frame unificado para resolução de problemas Fuzzy-DS;
- Busca bibliográfica por propostas teóricas ou práticas semelhantes;
- Apresentação de estudo de caso utilizando a metodologia proposta;

## **1.2 Metodologia**

Seguindo a caracterização de metodologia da pesquisa de LAKATOS E MARCONI (1992) o método de abordagem pode ser caracterizado como hipotético dedutivo, pois parte da percepção de uma lacuna de conhecimentos sobre a qual se formula uma hipótese que é testada.

Os procedimentos utilizados foram a pesquisa bibliográfica e o estudo de caso de caráter experimental para apresentar o modelo proposto.

Para construir o modelo experimental foram utilizados dois softwares específicos: Matlab® (R2011a) e o STELLA™ v9.

O objetivo desse trabalho é exploratório na medida em que investiga a integração dos dois métodos. Descritiva quando revisa a bibliografia em busca de iniciativas nesse sentido. Explicativa quando revisa as abordagens de lógica fuzzy e dinâmica de sistemas exibindo suas complementaridades.

## 2 Apresentação das teorias

Nessa parte do trabalho será apresentado o básico das teorias de lógica fuzzy e dinâmica de sistemas para sua utilização posteriormente. Como são áreas bem consolidadas, seus aspectos teóricos são apresentados de forma quase padrão em livros didáticos.

Por esse motivo optou-se por basear a revisão teórica em livros referência nas suas respectivas áreas. Para fuzzy utilizou-se o livro de ROSS (2004) e para dinâmica de sistemas o livro de STERMAN (2000). Para evitar carregar a leitura optou-se por não referenciá-los em tópicos que sejam de conhecimento comum, buscando referenciá-los em citações mais opinativas.

### 2.1 Lógica Fuzzy

#### 2.1.1 Fuzzy e Incerteza

Segundo ROSS (2004), a evolução da ciência partiu de modelos determinísticos, como a física newtoniana, para uma abordagem estatística, baseada na teoria das probabilidades, capaz de considerar incertezas buscando soluções mais robustas. Esse paradigma manteve-se pouco contestado até os estudos de Lotfi Zadeh em 1965 quando ele propôs uma lógica com valores contínuos na tentativa de contornar os problemas da lógica clássica aristotélica com diferentes tipos de incerteza.

A incerteza pode se manifestar nas seguintes formas: fuzzy (não sharp<sup>1</sup>, obscuro, impreciso, aproximado), vago (não específico, amorfo), ambíguo (com muitas alternativas, contraditório), ignorado (divergente, desconhecido), ou naturalmente variável (randômico, caótico, imprevisível). A teoria da probabilidade lida bem com incertezas decorrentes de uma imprecisão quantificável (relativa à ocorrência de determinado evento), porém não consegue tratar incertezas relacionadas a informações lingüísticas ou intuitivas (independentes da ocorrência).

Para ilustrar essas diferenças considere os exemplos: quando seleciono alguém aleatoriamente na rua e quero estudar se sua altura excede 1.50m, essa incerteza é probabilística, uma vez selecionado a pessoa não há mais dúvida. Diferentemente, se

---

<sup>1</sup> Agudo, bem delimitado

quero selecionar alguém para avaliar se essa pessoa “é alta”, mesmo depois de selecionar a pessoa a incerteza persiste, pois o conceito abarca incerteza fuzzy.

Lógica fuzzy de um ponto de vista simplório pode ser considerada um sistema lógico com uma extensão da lógica multi-valor. Entretanto, de uma perspectiva mais ampla e conceitual, lógica fuzzy reflete a teoria de conjuntos fuzzy que trata de classificações (em conjuntos) com fronteiras suaves determinadas por graus de pertinência e, portanto, abarca reflexões teóricas mais profundas (MATHWORKS, 2012).

### 2.1.2 Teoria de Conjuntos Fuzzy

Um subconjunto A de um conjunto U é considerado subconjunto *fuzzy* de U se for descrito como um conjunto de pares ordenados da seguinte maneira:

$$A = \{(\mu_A(x), x); x \in U \text{ ( } \mu_A(x) \in [0,1] \text{ )}$$


Onde,  $\mu_A(x)$  é uma função de pertinência que determina com que grau x está em A:

$$\mu_A(x)=1$$

$$0 < \mu_A(x) < 1$$

$$\mu_A(x)=0$$

Percebe-se que ao contrário da lógica clássica a pertinência de um elemento a um conjunto pode ser parcial, entre a pertinência totalmente verdadeira (=1) e a não pertinência (=0). Por exemplo, suponha a construção do conjunto “aproximadamente 6 metros” na Figura 1 a seguir.



**Figura 1 Exemplo de Conjunto Fuzzy**

**Fonte: ROSS, 2004**

Para a lógica clássica pode-se definir o conjunto como todos os números  $x$ ,  $5 \leq x \leq 6$ , cuja pertinência é total, para os demais é nula. Essa tipo de classificação gera algumas contradições, por exemplo, 5 é considerado “aproximadamente 6 metros”, porém 4.999999999m não é. O conjunto fuzzy por outro lado, apresenta uma transição suave nas fronteiras de pertinência de tal forma que o 4.999m tem uma pertinência suficientemente próxima a de 5m (por mais que sejam muito pequenas). Essa construção para a maioria de nossos conceitos lingüísticos parece de fato ser mais adequada.

### 2.1.3 Lógica Fuzzy

Lógica é uma das maneiras que o ser humano utiliza para raciocinar, é através dela que conseguimos organizar palavras para criar sentenças claras. O interesse em lógica é estudar a verdade em sentenças lógicas que no caso clássico é binária/booleana (verdadeiro ou falso) e no caso fuzzy, parcial.

Conforme ROSS (2004) destaca, a lógica (fuzzy ou não) não é por si capaz determinar quais sentenças usar em variados contextos, demandando uma racionalidade prévia para sua utilização. Por esse motivo, geralmente utiliza-se lógica em raciocínios dedutivos (do todo infere-se algo sobre a parte), considerados superficiais quando comparado ao raciocínio indutivo, que infere do particular conhecimento geral.

A linguagem natural é uma das formas mais poderosas de transmitir conhecimentos e informações que humanos possuem em relação a problemas e situações que envolvem raciocínio e decisão. Apesar de sua vagueza e ambigüidade a linguagem faz com que indivíduos sejam capazes de se entender. Por isso, para modelar



processo de raciocínio humano é necessário emular nossa linguagem natural (e suas variáveis lingüísticas).

A lógica fuzzy é um método para formalizar com ferramental matemático específico a capacidade humana de raciocínio impreciso ou raciocínio aproximado. Esse raciocínio representa a capacidade humana de julgar sob incerteza. Na lógica fuzzy as verdades são parciais ou aproximadas, interpoladas entre os extremos de verdadeiro e falso e, portanto, capazes de considerar verdades parciais (níveis de verdade).

Podemos apontar como algumas das vantagens de lógica fuzzy, segundo (MATHWORKS, 2012):

- é conceitualmente fácil de entender
- é flexível: pode ser facilmente modificada adaptada
- é tolerante a dados imprecisos:
- permite modelar funções não lineares de complexidade arbitrária: especialmente quando usado em sistemas adaptativos neuro-fuzzy de inferência.
- pode ser construída aproveitando a experiência e expertise de especialista
- pode ser mesclada a técnicas de controle convencionais.
- é baseado na linguagem natural, a forma mais efetiva para comunicar-se algo.

Para a lógica uma proposição  $P$  é uma afirmação lingüística ou declarativa contida em um universo de elementos, digamos  $X$ , que podem ser identificados como uma coleção de elementos em  $X$  que são verdadeiros ou falsos.

Uma proposição lógica fuzzy envolve um conceito com fronteiras não claramente definidas, geralmente enunciados lingüísticos que tendem a expressar idéias subjetivas e geralmente são interpretados ligeiramente diferente entre as pessoas.

À veracidade de um elemento na proposição P pode ser associado um grau de verdade,  $T(\tilde{P})$ . Formalmente, sendo U o universo de todas as proposições, T é uma função que mapeia elementos, u, nessas proposições a valores entre [1,0].

$$T : u \in U \rightarrow (0, 1)$$

Podemos definir conjuntos fuzzy  $\tilde{A}$  e  $\tilde{B}$  do universo X que representam idéias linguísticas ou pensamentos. Para trabalhar com proposições podemos definir uma proposição  $\tilde{P}$  que meça a “verdade” da afirmação que um elemento x (do universo X) está contido no conjunto  $\tilde{A}$ .

$$\tilde{P} : \text{verdade que } x \in \tilde{A}$$

$$T(\tilde{P}) = \mu_{\tilde{A}}(x) \text{ onde } 0 \leq \mu_{\tilde{A}} \leq 1$$

Sendo a verdade medida em termos da pertinência, i.e.,

$$T(\tilde{P}) = \mu_{\tilde{A}}(x) \text{ onde } 0 \leq \mu_{\tilde{A}} \leq 1$$

A partir de duas proposições simples,  $\tilde{P}$  (já definida) e  $\tilde{Q}$  (referente ao conjunto fuzzy  $\tilde{B}$ ), no universo de discurso pode-se combiná-las para formar novas proposições usando os seguintes conectivos lógicos:

**Disjunção=OU (OR)**

$$\tilde{P} \vee \tilde{Q} : x \in \tilde{A} \text{ OU } x \in \tilde{B}$$

$$\text{Logo, } T(\tilde{P} \vee \tilde{Q}) = \max(T(\tilde{P}), T(\tilde{Q}))$$

**Conjunção =E (AND)**

$$\tilde{P} \wedge \tilde{Q} : x \in \tilde{A} \text{ E } x \in \tilde{B}$$

$$\text{Logo, } T(\tilde{P} \wedge \tilde{Q}) = \min(T(\tilde{P}), T(\tilde{Q}))$$

**Negação =NÃO (NOT)**

$$T(\bar{\tilde{P}}) = 1 - T(\tilde{P})$$

**OU Exclusivo (XOR)**

$$T(\tilde{P} \text{ XOR } \tilde{Q}) = T((\tilde{P} \wedge \bar{\tilde{Q}}) \vee (\bar{\tilde{P}} \wedge \tilde{Q}))$$

**NÃO Exclusivo = “Nem” (NXOR)**

$$T(\tilde{P} \text{ NXOR } \tilde{Q}) = T(\overline{\tilde{P} \text{ XOR } \tilde{Q}})$$

**Implicação = SE, ENTÃO (IF, THEN)**

$$\tilde{P} \rightarrow \tilde{Q} : x \in \tilde{A} \text{ ENTÃO } x \in \tilde{B}$$

$$T(\tilde{P} \rightarrow \tilde{Q}) = T(\bar{\tilde{P}} \cup \tilde{Q}) = \max(T(\bar{\tilde{P}}), T(\tilde{Q}))$$


O conectivo de disjunção, o OU lógico, é o termo usado para referir-se ao OU inclusivo. Na nossa linguagem natural muitas vezes utilizamos o “ou” como o OU exclusivo que implica exclusão (não simultaneidade, “ou um ou outro”). O OU inclusivo, doravante tratado como OU, apenas, implica que a composição é verdadeira caso uma ou mais proposições simples sejam verdadeiras.

**2.1.4 Implicação**

A implicação é a base da inferência, e por isso será explicada com maior detalhe. Sua operação define que quando a primeira proposição (denominada antecedente ou hipótese) é atendida a segunda (denominada consequência ou conclusão) consequentemente também deve ser atendida (note que se a hipótese/condição não for atendida nada se pode dizer da consequência).

A implicação “P implica Q” é equivalente a tomar a união entre os elementos do complemento de A com os elementos de B (mapeando os elementos que não estão em A e os elementos que estão em B). Isso significa que “P → Q é verdadeiro” quando “NÃO A” OU “B” é verdadeiro. Esse resultado é ilustrado na

para o caso clássico no diagrama de Venn da Figura 2, onde a região em branco representa a diferença entre os conjuntos no qual a implicação é falsa.



**Figura 2** Representação em diagrama de Venn da implicação

**Fonte: ROSS, 2004**

Além disso, supondo que a proposição  $\tilde{P}$  descrita pelo conjunto  $\tilde{A}$  é definida no universo  $X$  e que a proposição  $\tilde{Q}$  definida pelo conjunto  $\tilde{B}$  é definida no universo  $Y$ . A implicação  $P \rightarrow Q$  pode ser representada na teoria de conjuntos pela relação  $R$ , definida como:

$$R = (\tilde{A} \times \tilde{B}) \cup (\tilde{A} \times Y) \equiv \text{IF } A, \text{ THEN } B$$

$$\text{SE } x \in \tilde{A} \text{ com } x \in X \text{ e } \tilde{A} \subset X$$

$$\text{ENTÃO } y \in \tilde{B} \text{ com } y \in Y \text{ e } \tilde{B} \subset Y$$

A pertinência da relação que representa essa implicação pode ser calculada como:

$$\mu_R(x, y) = \max[(\mu_A(x) \wedge \mu_B(y)), (1 - \mu_A(x))]$$

Outra proposição composta que contém regra lingüística comum é:

$$\text{IF } A, \text{ THEN } B, \text{ ELSE } C^2$$

$$\text{Análoga a: } (P \rightarrow Q) \wedge (\bar{P} \rightarrow S)$$

Essa composição pode ser separada em duas proposições:

---

<sup>2</sup> Usarei os termos em inglês apenas porque o Matlab®, usado para a implementação, assim o faz, mas a tradução é direta.

IF A, THEN B            E            IF  $\bar{A}$ , THEN C

Sendo calculada pela formula anterior e operando a interseção (operador min) entre os valores obtidos para cada proposição.

### 2.1.5 Inferência Dedutiva e Approximate reasoning

Como mencionado, o principal objetivo da lógica fuzzy é criar uma fundamentação teórica para abordar/utilizar proposições imprecisas com verdades parciais. O raciocínio baseado nesse tipo de proposição foi chamado de raciocínio aproximado por ZADEH (1975,1979) e sua maior aplicação é para inferências em sistemas baseados em regras (*rule-based*).

A forma mais básica de representar conhecimento humano usando expressões linguísticas é: SE premissas (antecedentes), ENTÃO conclusões (consequências).

Como comentado, esse tipo de construção é chamado de forma dedutiva, pois parte-se de um fato (premissa, hipótese) para inferir uma conclusão (consequência). Normalmente embute conhecimentos empíricos e heurísticos sendo incapaz de capturar formas mais profundas de conhecimento como a intuição, estrutura e comportamento.

Uma regra IF-THEN ( $A \rightarrow B$ ) é usada para determinar se um dado antecedente (causa ou ação) implica uma determinada consequência (efeito ou reação). Para tal transforma-se a regra IF A, THEN B em uma relação ( $\tilde{R}$ ) da forma já mencionada. A partir dela, com um novo antecedente, digamos  $A'$ , podemos usar a dedução do *modus ponens*<sup>3</sup> para inferir nova consequência  $B'$ , da seguinte forma:

$$\tilde{B}' = \tilde{A}' \circ R = \tilde{A}' \circ (\tilde{A} \times \tilde{B}) \cup (\bar{\tilde{A}} \times Y)$$
<sup>4</sup>

Basta, portanto, calcular o resultado da composição do novo antecedente com a relação para obter a nova consequência. Existem variadas propostas na literatura de operadores de composição, mas os mais comuns são o Max-min e o Max-prod.

---

<sup>3</sup>  $(A \wedge (A \rightarrow B)) \rightarrow B$

<sup>4</sup> O símbolo  $\circ$  representa a operação de composição em conjuntos

A dedução do *modus ponens* também pode ser usada para regras no formato IF A, THEN B, ELSE C. Para esse tipo de regra definindo um antecedente  $\tilde{A}$  deve-se considerar as duas regras separadas e depois uni-las pela interseção.

### 2.1.6 Outras formas de implicação

O calculo da função de pertinência da relação  $\tilde{R}$  ( $R = A \rightarrow B$ ) da forma como foi apresentado previamente pode ser muito trabalhoso quando se estiver operando em universos contínuos ou de grande dimensão. Por esse motivo, diversas formas mais simples (para facilitar cálculos computacionais ou não) foram propostas na literatura, ROSS (2004) cita algumas delas:

<ul style="list-style-type: none"> <li>• <math>\mu_{\tilde{R}}(x, y) = \max[\mu_{\tilde{B}}(y), 1 - \mu_{\tilde{A}}(x)]</math></li> <li>• <math>\mu_{\tilde{R}}(x, y) = \min[\mu_{\tilde{A}}(x), \mu_{\tilde{B}}(y)]</math></li> <li>• <math>\mu_{\tilde{R}}(x, y) = \min\{1, [1 - \mu_{\tilde{A}}(x) + \mu_{\tilde{B}}(y)]\}</math></li> <li>• <math>\mu_{\tilde{R}}(x, y) = \mu_{\tilde{A}}(x) \cdot \mu_{\tilde{B}}(y)</math></li> <li>• <math>\mu_{\tilde{R}}(x, y) = \begin{cases} 1, &amp; \text{se } \mu_{\tilde{A}}(x) \leq \mu_{\tilde{B}}(y) \\ \mu_{\tilde{B}}(y), &amp; \text{caso contrário} \end{cases}</math></li> </ul>
---

A primeira fórmula equivale à implicação clássica. A segunda é chamada de implicação Mamdani, em homenagem ao seu criador, e será usada no método de inferência gráfico a seguir. Essa formulação além de facilitar cálculos tem formato análogo ao produto cruzado de conjuntos fuzzy (ex.  $R = A \times B$ ).

### 2.1.7 Sistemas fuzzy

Sistemas fuzzy são conjuntos de regras IF-THEN relativas a variados antecedentes e versando sobre múltiplas conseqüências. Na maioria dos casos mais de uma regra se refere a uma mesma variável conseqüência havendo necessidade de definir uma técnica de agregação dessas diversas regras.

Um dos casos mais simples ocorre quando as regras formam um sistema conjunto (unido, coeso), nesse caso o output agregado é obtido pela interseção das saídas de cada uma das regras individuais:

$$y = y^1 \cap y^2 \cap \dots \cap y^r$$

Em outro caso, as regras podem formar um sistema disjunto (independente), nesse caso, no mínimo apenas uma das regras precisa ser satisfeita e o resultado final é encontrado pela união dos diversos outputs individuais:

$$y = y^1 \cup y^2 \cup \dots \cup y^r$$

### 2.1.8 Técnicas Gráficas de Inferência

Finalmente, o maior interesse dessa revisão são os métodos gráficos que realizam o processo de inferência e tornam a computação mais fácil. ROSS (2004) descreve três métodos de inferência dedutiva em sistemas fuzzy baseados em regras lingüísticas:

- (1) Sistemas Mamdani;
- (2) Modelos Sugeno;
- (3) Modelos Tsukamoto.

Desses optou-se por não apresentar o último, pois não há implementação no Matlab® para ele. Será mais aprofundado o primeiro, pois é o método usado na metodologia proposta.


O método Mamdani foi criado por MAMDANI E ASSILIAN (1975) e é o mais comum na prática e na literatura. Podem utilizar para inferência o max-min ou o max-product.

Sua estrutura básica consiste nas seguintes etapas:

- Fuzzificação: transforma os inputs (geralmente crisp) em variáveis fuzzy, calculando sua pertinência as diversas categorias.
- Inferência: combina os inputs fuzzificados através das diversas regras IF-THEN para definir a pertinência dos outputs em cada regra.

- Agregação: combina as pertinência geradas para o mesmo output por diferentes regras (geralmente pela união – operado Max).
- Defuzzificação: transforma o output fuzzy agregado em um único valor discreto (crisp) que será a saída do sistema.

A resolução gráfica do método Mamdani utilizando o max-min<sup>5</sup> através dessas 4 etapas é apresentada na Figura 3 abaixo:



**Figura 3 Método gráfico Mamdani máx-mim com inputs crisp**

**Fonte: ROSS, 2004**

O sistema Mamdani nesse gráfico recebe dois inputs discretos/escalares (crisp) e tem duas regras referentes a um único output. Primeiramente para cada regra usa-se a operação de disjunção (operador min), pois os pares de input estão relacionados pelo conectivo “E”. Depois usa-se o min (da fórmula de implicação) para truncar a função de pertinência da consequência para cada uma das regras. Na sequência, como as regras são disjuntas (OU) utiliza-se o operador max (segunda parte da fórmula de implicação) para agregar as funções de pertinência truncadas de cada regra em uma função de


---

<sup>5</sup>  $\mu_{\tilde{B}}^k(y) = \max_k [\min_1 [\mu_{\tilde{A}}^k(\text{input}(i)), \mu_{\tilde{A}}^k(\text{input}(j))]]$   $k = 1, 2, \dots, r$



pertinência final do output. Finalmente, para tornar esse output fuzzy um valor discreto utiliza-se alguma técnica de defuzificação obtendo o valor  $y^*$ .

Usando a inferência max-product<sup>6</sup>, o resultado gráfico, apresentado na Figura 4 abaixo, só se altera no segundo passo (quando calcula-se o produto entre o mínimo das regras e a pertinência do output):



**Figura 4 Método gráfico Mamdani máx-prod com inputs crisp**

**Fonte: ROSS, 2004**

O segundo método de inferência é chamado geralmente de método Sugeno ou método TSK - Takagi, Sugeno e Kand – (TAKAGI E SUGENO, 1985; SUGENO E KANG, 1988). Foi proposto como um esforço de desenvolver uma abordagem sistemática para gerar regras fuzzy a partir de dados input-output. Uma regra em modelos de Sugeno com dois inputs ( $x$  e  $y$ ) e um output ( $z$ ) tem geralmente a forma:

$$\text{IF } x \text{ is } \tilde{A} \text{ and } y \text{ is } \tilde{B}, \text{ THEN } z \text{ is } z = f(x, y)$$

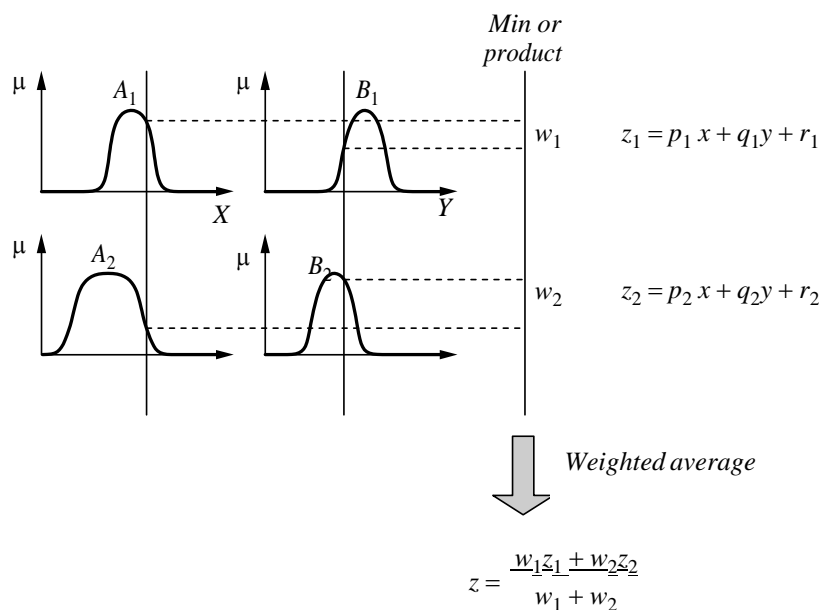
Onde  $z = f(x, y)$  é uma função escalar da consequência.

---

<sup>6</sup>  $\mu_{\tilde{B}}^k(y) = \max_k [\mu_{\tilde{A}_1}^k(\text{input}(i)) \cdot \mu_{\tilde{A}_2}^k(\text{input}(j))] \quad k = 1, 2, \dots, r$

Geralmente  $f(x, y)$  é uma função polinomial dos inputs  $x$  e  $y$  mas isso não é uma exigência, basta que ela explique o output satisfatoriamente na região fuzzy específica na regra de seus antecedentes.

Esse modelo de inferência faz com que cada regra dê origem a um output discreto (crisp) calculado pela função (e depois usando o operado min ou product). Dessa forma a defuzzificação do output (um conjunto de singletons) é simplesmente uma média ponderada o que representa grande economia de esforço computacional e por isso sua vantagem. O resultado gráfico é apresentado na Figura 5 abaixo:



**Figura 5 Método gráfico Sugeno com inputs crisp**

**Fonte: ROSS, 2004**

Em comparação com o modelo Mamdani o esforço computacional é muito menor (por não exigir métodos numéricos de defuzzificação), porém a construção de suas regras perde o paralelo com a linguagem natural humana e o raciocínio aproximado. Para muitas finalidades, que não buscam capturar determinado raciocínio lingüístico, esse método é valioso, por exemplo, em redes neurais fuzzy que definem sua estrutura interna e regras a partir do treinamento com dados de input e output e não a partir de definições do decisor.

Na sequência, para o estudo desse trabalho em que se deseja expressar conhecimentos humanos lingüísticos foi escolhido o modelo Mamdani por ser a opção mais apropriada, simples e intuitiva.

### 2.1.9 Técnicas de Defuzzificação

Para finalizar de maneira rápida a revisão de fuzzy iremos listar algumas das opções de métodos para defuzzificação que serão necessários para gerar outputs (comandos) discretos durante o controle.

#### 1. Princípio da máxima pertinência:

Esse é o mais simples dos métodos, simplesmente seleciona o ponto de máxima pertinência no número fuzzy.




Figura 6 Defuzzificação pelo princípio da máxima pertinência


Fonte: ROSS (2004)

#### 2. Método Centróide:

É o mais comum e fisicamente o mais coerente dos métodos de defuzzificação (SUGENO, 1985, Apud ROSS, 2004). Ele calcula o centro de massa ponderando o valor (crisp) pela sua pertinência, conforme a fórmula abaixo:

$$z^* = \frac{\int \mu_{\tilde{A}}(z) \cdot z \, dz}{\int \mu_{\tilde{A}}(z) \, dz}$$

Seu resultado gráfico para o mesmo número fuzzy do exemplo anterior é:



**Figura 7 Defuzzificação pelo método centróide**

**Fonte: ROSS, 2004**

O maior problema desse método é que exige cálculo numérico de integrais o que exige considerável esforço computacional.

### 3. Método da média ponderada:

Esse divide a função de pertinência do número fuzzy em regiões (preferencialmente simétricas) que permitam o cálculo mais fácil de seu centróide e então realiza uma média ponderada desses centróides por suas respectivas pertinências. Matematicamente:

$$z^* = \frac{\sum \mu_{\tilde{A}}(\bar{z}) \cdot \bar{z}}{\sum \mu_{\tilde{A}}(\bar{z})}$$

## 2.2 Dinâmica de Sistemas

A dinâmica de sistemas foi apresentada para o mundo no artigo seminal de Forrester, “Industrial dynamics: a major breakthrough for decision makers”, em 1958, para a Harvard Business Review. Na ocasião Forrester apontava como pilares de sua abordagem os avanços “recentes” em: tecnologia da computação, simulação computacional, compreensão do processo de tomada de decisões estratégicas e entendimento do papel de ciclos de feedback em sistemas complexos. (Apud G. P. RICHARDSON, 2011)

Dinâmica de sistemas pode ser definida como o ramo da teoria de controle que lida com sistemas sócio econômicos e o ramo da ciência de administração que lida com problemas de controlabilidade (COYLE,1997).

A grande premissa da dinâmica de sistemas é que a dinâmica observada em variados sistemas tem como causa a estrutura de loops causas, interdependências diversas entre as suas variáveis. Decorrente disso seu objetivo é modelar a estrutura causal do sistema de forma a internalizar todos os fatores que geram o comportamento problemático e avaliar políticas sobre essa estrutura (PANKAJ *et al.*, 1994).

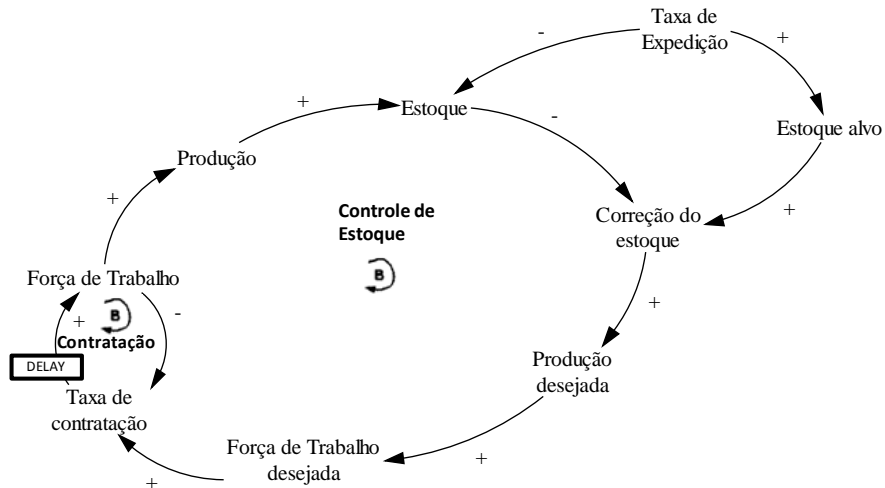
Detalharemos melhor na argumentação de nossa proposta as motivações da dinâmica de sistemas, por hora essa introdução é suficiente para apresentarmos as suas ferramentas.

### **2.2.1 Ferramentas de Modelagem dos Sistemas**

Em Dinâmica de Sistemas duas formas de modelagem são empregadas para caracterizar um sistema: a abordagem soft e hard. Apesar de haver divergências no meio acadêmico é largamente aceito que as técnicas podem ser combinadas com grande benefício. A abordagem qualitativa é especificamente valiosa para as fases iniciais de definição do problema e o modelo quantitativo permite aprofundar o aprendizado em direção à resolução do problema.

#### ***A Modelagem Soft da Dinâmica de Sistemas***

A modelagem soft é utilizada para análises qualitativas dos nossos modelos mentais. A técnica utilizada em DS para isso é o diagrama de loop causal (*causal loop diagram*) na qual são representadas as relações de causa e efeito, seus sinais/polaridades (direto ou inverso), as estruturas de feedback (loops) que eles formam e os delays de determinadas relações. Um exemplo, de MORECROFT (2007) para a relação entre força de trabalho e produção é apresentado na Figura 8 na sequência.




**Figura 8 Loop causal de ajustamento de estoques**

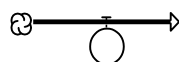
Fonte: MORECROFT, 2007

### *A Modelagem Hard da Dinâmica de Sistemas*

Apesar do valor da modelagem soft, a maior contribuição de Forrester foi a sua proposta de modelagem hard (modelos quantitativos de simulação) baseada em dois conceitos simples: Fluxo e Estoques. Com esses elementos e alguns outros, tornou-se muito mais fácil representar modelos, reduzindo o esforço de declarar suas equações e facilitando sua visualização. Adicionalmente, o desenvolvimento de diversos softwares, como o Stella, Ithink, Powersim, Vensim entre outros, tornou cada vez mais fácil construir e simular esses modelos.

A linguagem de fluxos e estoques apresenta os seguintes elementos principais:

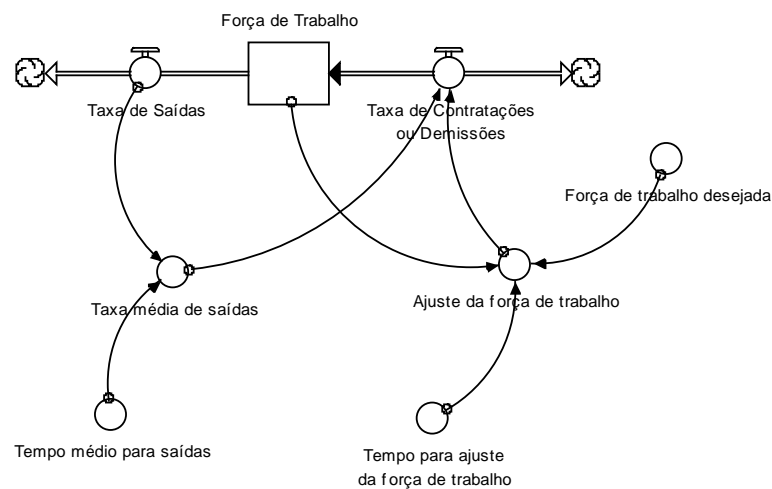
 Estoques: são resultado da acumulação ao longo do tempo de fluxos, representam variáveis de estado e se referem geralmente a recursos. Matematicamente são equivalentes a integrais (dos fluxos que recebe ao longo do tempo);

 Fluxos: são atividades que produzem crescimento ou redução dos estoques, matematicamente representam diferenciais (derivadas, taxas de variação);

○ Conversores: processam informações a respeito dos estoques e fluxos, ou representam fontes de informação externa ao sistema, são variáveis auxiliares;

→ Conectores: são links de informação que conectam Estoques, Fluxos e Conversores.

Para o mesmo exemplo de MORECROFT (2007) a Figura 9 apresenta a modelagem de fluxos e estoques para a parte de força de trabalho do esquema.



**Figura 9 Modelo de fluxos e estoques da força de trabalho**

**Fonte: MORECROFT (2007)**

Para FORRESTER (1961) (Apud FERNANDES, 2003) a decisão de "políticas" refere-se a forma de governar os fluxos. Segundo FERNANDES (2003) a estrutura básica de um sistema de feedback de controle é como representado na Figura 10 abaixo.

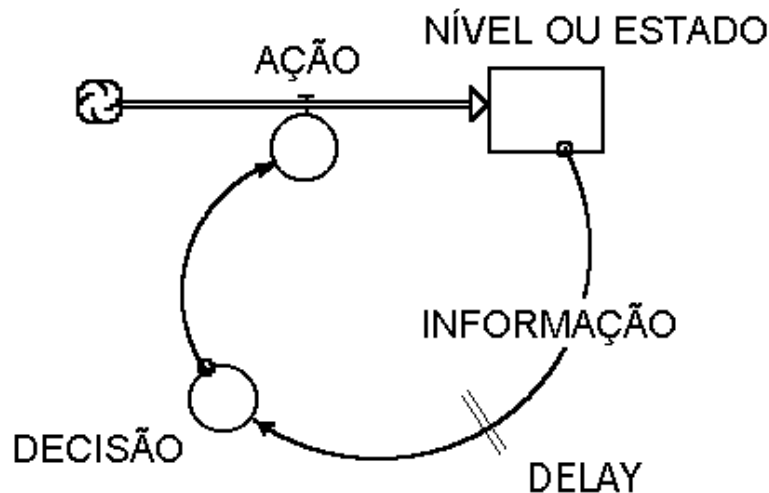


Figura 10 Uma estrutura de feedback simples

Fonte: FERNANDES (2003)

### 2.2.1 Princípios para utilização de dinâmica de sistemas

Para finalizar essa breve apresentação de dinâmica de sistemas é interessante reproduzir esta discussão de STERMAN (2000). O autor em sua obra resume alguns princípios para utilizar com sucesso a dinâmica de sistemas, dentre os quais:

- Desenvolver um modelo para resolver um problema específico e não “modelar o sistema”: o modelo tem que ter um propósito e excluir todos os fatores irrelevantes para esse problema.
- Integrar a modelagem desde o início do projeto: é uma ferramenta que ajuda a identificar o problema.
- Ser cético em relação à utilidade da modelagem e avaliar se ela é realmente necessária: pois para vários problemas a dinâmica de sistemas simplesmente não é útil.
- Usar outras ferramentas e métodos complementarmente a dinâmica de sistemas: no mínimo depende de uma coleta e tratamento de dados robusta.



- Fazer da modelagem um processo iterativo entre cliente(s) e consultor(es): é um processo de descoberta e aprendizado, deve-se evitar usar o modelo como argumentos para convencimento.

- Evitar modelos caixa preta: o processo de modelagem também é largamente responsável pelo aprendizado; caso seja ocultado, dificilmente o usuário irá concordar e se interessar.

- Enxergar a validação como um processo contínuo de teste e desenvolvimento de confiança modelo: não basta ajustar-se a dados históricos para convencer especialistas, deve ser contestado de forma muito mais reflexiva e desafiado com dados diversos.

- Produzir um modelo preliminar o mais cedo possível, adicionando detalhes gradualmente: modelos são hipóteses que precisam ser testadas não adianta buscar grande detalhismo sem testá-lo.

- Fronteiras amplas são mais importantes que exagerado grau de detalhe

- Não limitar a implementação a um único projeto: para ser útil o modelo desenvolvido tem que ser constantemente contestado e atualizado.

Essa discussão pode parecer inócua nesse momento, mas mais a frente alguns desses itens serão retomados como uma necessidade para a metodologia fuzzy-DS proposta.

## **3 A Integração de dinâmica de sistemas e lógica fuzzy**

Após a breve revisão das duas teorias, esse capítulo buscará apresentar a possibilidade de integração e seu objetivo. Para tal será preciso começar aprofundando a discussão de dinâmica de sistemas mais um pouco, pois sua própria motivação servirá para propor a integração.

Antes de começar vale repetir que a revisão teórica de dinâmica de sistemas, especificamente o próximo tópico<sup>7</sup>, foi fortemente baseada em STERMAN (2000) o qual citaremos apenas nas passagens de cunho mais crítico apesar de sua constante inspiração.

### **3.1 O pensamento sistêmico e o aprendizado**

Segundo STERMAN (2000) um processo decisório efetivo e o aprendizado em um mundo de crescente complexidade dinâmica exige que pensemos sistemicamente, expandindo as fronteiras de nossos modelos mentais e desenvolvendo ferramentas para compreender como a estrutura de sistemas complexos cria seus comportamentos.

Uma abordagem sistêmica admite que somente quando um sistema é observado em sua totalidade que se pode compreender seu funcionamento. Essa abordagem é diferente do processo analítico clássico que estuda as partes (análise) para compreender o todo (síntese).


A dinâmica de sistemas é uma das abordagens metodológicas derivadas do pensamento sistêmico com principal objetivo de facilitar o aprendizado em sistemas complexos de feedback, multi-loop, multi-estados e com caráter não-linear em que vivemos (FORRESTER, 1961).

Segundo STERMAN (2000) nosso processo decisório é baseado fortemente na visão aristotélica tradicional evento-orientada, na qual geralmente observamos um evento (único e pontual) e derivamos cadeias de causa e efeito até atingir (espera-se) a causa raiz. Esse processo é claramente linear (sem feedback), isto é a cada causa e efeito

---

<sup>7</sup> Reproduzo nesse tópico grande parte da discussão do capítulo 1 de STEARMAN (2000).

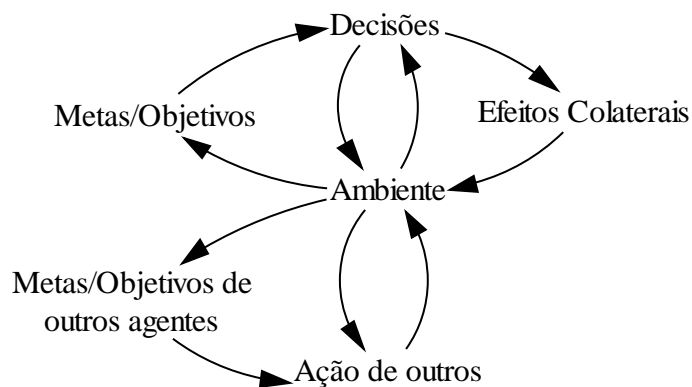
associamos novos elementos, em teoria primitivos, que não se relacionam causalmente a elementos desdobrados previamente. O resultado dessa forma de tomar decisão é um processo decisório como na Figura 11.



**Figura 11 Processo decisório linear orientado a eventos**

**Fonte: STERMAN (2000)**

Verifica-se, entretanto, que raramente as decisões tomadas dessa maneira atingem os resultados esperados (“surtem efeitos colaterais”). Isso evidencia que a estrutura do sistema sobre o qual se designam políticas é mais complexa do que o pensamento linear é capaz de mapear, nela nossas próprias decisões geram impactos em diferentes níveis e intervalos e influem nas decisões futuras (causa e efeito se confundem com o passar do tempo). A Figura 12 ilustra essa estrutura.



**Figura 12 Processo decisório com feedback**

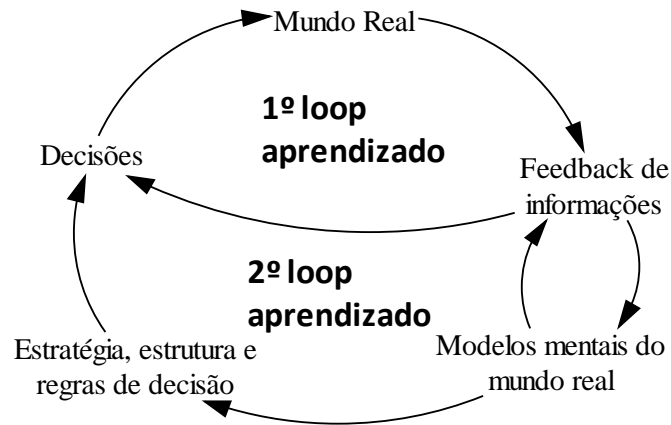
**Fonte: STERMAN (2000)**

Geralmente a complexidade é consequência das seguintes características do sistema:

- Dinamismo: alteração ao longo do tempo em horizontes variáveis e muitas vezes interativos.
- Acoplamento justo dos elementos: agentes de um sistema interagem fortemente com outros agentes do mundo natural.
- Governança de feedbacks: devido ao acoplamento as ações impactam elas mesmas de volta. Cada decisão muda a situação que influi em nossa próxima decisão ad eternum.
- Não-linearidades: por envolver fenômenos físicos, sociais e psicológicos entre múltiplos agentes, na grande maioria das vezes não pode se esperar proporcionalidade/linearidade nos comportamentos.
- Dependência histórica: as escolhas do passado condicionam o que é possível de fazer atualmente, muitas ações são irreversíveis.
- Auto-organização: a dinâmica de sistemas provém espontaneamente de sua estrutura interna. Pequenas perturbações são moldadas e amplificadas por estruturas de feedback criando padrões no espaço e tempo e gerando dependência do percurso.
- Adaptatividade: as capacidades e modelos decisórios dos agentes mudam com o tempo e conseqüentemente o comportamento do sistema.
- Contra-intuitivo: geralmente verifica-se o distanciamento entre causa e efeito no espaço e tempo e nossa busca por causas próximas em geral só consegue vislumbrar sintomas.
- Resistência a políticas: a complexidade do sistema sobrepõe nossa capacidade de compreendê-lo e as soluções aparentemente óbvias se mostram inócuas.
- Delays (atrasos): entre a tomada de decisão e seus efeitos no estado do sistema, que levam a oscilações.

Devido a essa natureza sistêmica do ambiente e do problema que se deseja estudar, mostra-se necessário um processo de tomada de decisão mais resiliente,

compatível com a natureza sistêmica e complexa do sistema e baseado fortemente em um processo de aprendizado retro-alimentado (com feedback<sup>8</sup>), como exibido na Figura 13 abaixo:



**Figura 13** Aprendizado com dois loops

Fonte: STERMAN (2000)

Um elemento que essa estrutura torna explícito são os modelos (geralmente mentais), usados para compreender a realidade/problema e tomar decisões. Em dinâmica de sistemas, os modelos mentais devem incluir as crenças sobre a rede de causas e efeitos, as fronteiras do sistema (quais variáveis estão incluídas e quais não) e o horizonte temporal considerado relevante.

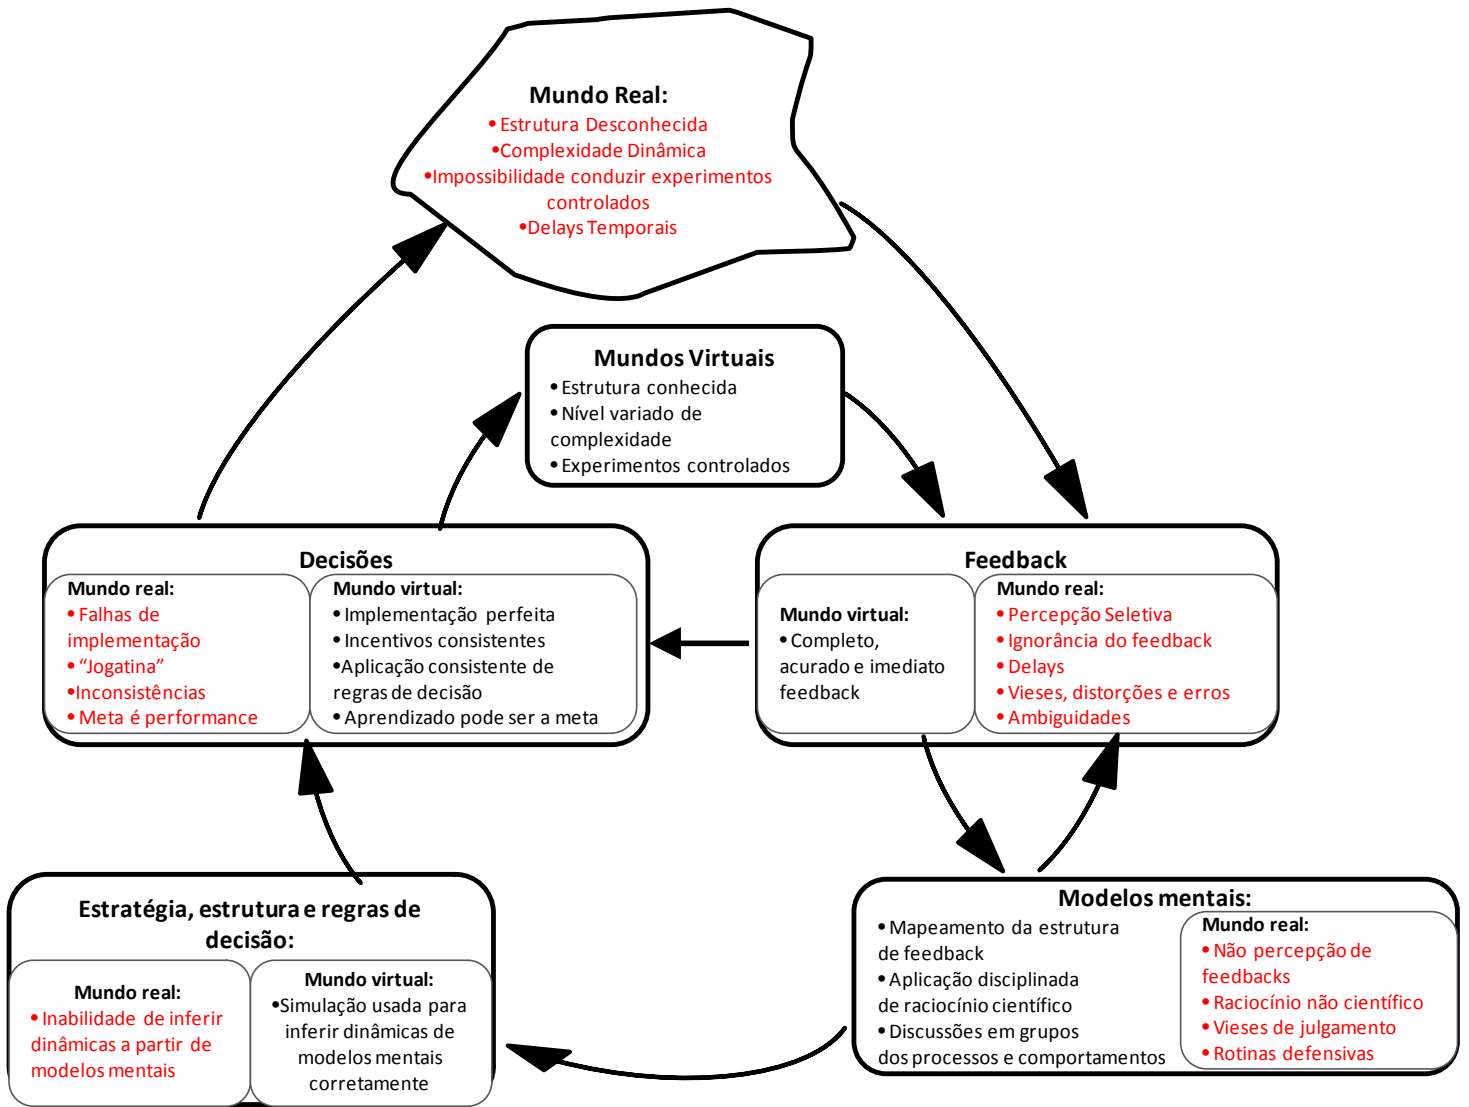
O ciclo mais comum de aprendizado (chamado primeiro loop de aprendizado) é aquele decorrente da coleta de informações (imprecisas e imperfeitas) e conseqüente tomada de decisão. Nele não alteramos nossos modelos mentais e seus pressupostos, que por melhores que sejam nunca serão perfeita representação do mundo real, podendo/devendo ser progressivamente refinados.

Por isso, para que o aprendizado seja efetivo é necessário o chamado segundo loop de aprendizado, no qual nossos modelos mentais são refinados, adaptados e/ou alterados conforme aumentamos nossa compreensão do sistema.

---

<sup>8</sup> Um exemplo desse tipo de aprendizado é o previsto pelo ciclo PDCA de Shewart-Deming, coração da gestão da qualidade total (TQM).

Justamente para promover e potencializar o aprendizado de duplo loop que a dinâmica de sistemas foi primordialmente desenvolvida. A Figura 14, originalmente apresentada por STERMAN (2000), relaciona as diversas barreiras que o modelo de duplo loop apresenta e a proposta da dinâmica de sistemas para solucioná-los.



**Figura 14** As barreiras ao aprendizado e sua relação com mundos virtuais

Fonte: Adaptado de STERMAN (2000)

Percebe-se que, além da complexidade dinâmica do mundo real, existem outros dificultadores como: nosso acesso às informações é imperfeito e incompleto; o fato que humanos em sistemas sociais tomam decisões baseados em emoções, reflexos e outras motivações afastadas da racionalidade que permitiria uma modelagem “catedrática”.

Devido a esses fatores, para diversos problemas reais, a prática científica habitual - de coletar informações buscando revelar a estrutura e parâmetros que definem o comportamento de determinado sistema e possam ser conformadas em teoria<sup>9</sup> - simplesmente não é viável.

Outrossim, nossos próprios modelos são deficientes, segundo STERMAN (2000) seus maiores problemas são: (i) nossos mapas cognitivos da estrutura causal do sistema são muito mais simplificados que o sistema real; (ii) somos incapazes de inferir a dinâmica de sistemas (mesmo os mais simples), pois a solução intuitiva de sistemas de equações diferenciais de alta ordem e não lineares excede as capacidades humanas.

Outro problema citado por STERMAN (2000) é que a formalização de modelos geralmente força o modelador a eliminar variáveis soft<sup>10</sup> e omitir aspectos importantes do problema para preservar a tratabilidade permitindo que teoremas sejam provados.

A dinâmica de sistemas busca contornar essas dificuldades com os chamados mundos virtuais: modelos formais, simulações, ou “micromundos” (PAPERT 1980 Apud STERMAN, 2000) nos quais decisores podem refinar suas habilidades de tomada de decisão conduzindo experimentos, estudos de campo em ambientes controlados.

Dessa forma incentiva-se a explicitação e permanente discussão dos modelos mentais. Criam-se modelos que não são limitados pela tratabilidade analítica, baseando-se em pressupostos realísticos sobre comportamentos humanos e utilizando todos os tipos de dados (não apenas numéricos) disponíveis para especificar e estimar relacionamentos (FORRESTER 1961, 1987).

Algumas das vantagens de mundos virtuais destacadas por STERMAN (2000) são:

- São laboratórios de aprendizado com baixo custo;
- Permitem dilatar ou comprimir o espaço e tempo;

---

<sup>9</sup> Conjunto de hipóteses permanentemente confrontadas a realidade e explicativas para uma gama relativamente ampla de fatos científicos, o que lhe garante generalidade, até que se prove o contrário.

<sup>10</sup> Diz-se variáveis das quais não se dispõe dados numéricos.

- Permitem repetir ações em quantidade ilimitada e nas condições que se desejar;
- Permite (deve) pausar a ação para refletir;
- Decisões que são perigosas, inviáveis ou anti-éticas podem ser tomadas sem restrições;
- Ao habilitarem a execução de diversos experimentos controlados reduzem drasticamente a demora dos loops de aprendizado.

## **3.2 Proposta de Metodologia**

### **3.2.1 Justificativa da Metodologia**

Retomando a Figura 14, ela foi adaptada, pois deseja-se destacar que para superar algumas das barreiras ao aprendizado o uso de mundos virtuais por si só não é suficiente.

De fato, STERMAN (2000) destaca que o uso de mundos virtuais tem algumas armadilhas, dentre as quais:

- não ser capaz de superar falhas em nossos modelos mentais;
- não desenvolver habilidade de raciocínio científico;
- não superar deficiências nos processos de aprendizado do grupo;

Segundo o autor, dois problemas comuns relacionados são a síndrome de videogame (decisor passa a operar a simulação como um jogo, sem refletir sobre a implicação real daquilo que acontece na simulação) e a carência de método científico.

Verifica-se que para o aprendizado efetivo com DS é necessário que as hipóteses sejam declaradas, testadas eficientemente e que seus resultados sejam comunicados ao grupo de forma padronizada. Caso contrário, os esforços serão difusos e o aprendizado pode ser perdido com práticas como a síndrome de videogame.

Outra barreira para o aprendizado com mundos virtuais que STERMAN (2000) menciona apesar de não destacá-lo nesse sentido é a natureza fuzzy dos modelos mentais de cada indivíduo. Como já mencionado, o modelo mental das pessoas é fuzzy,



incompleto, imprecisamente definido e variável no tempo. Por essa razão cada indivíduo interpreta determinado conteúdo de maneira distinta e adapta seu modelo particularmente.

Analisando esses limitantes à aplicação de mundos virtuais, será argumentado que boa parte deles podem ser minimizados ou eliminados com o uso integrado e disciplinado de lógica fuzzy.

Uma primeira causa para esses problemas é o fato que na maioria dos modelos de dinâmica de sistemas, o processo decisório ou é parametrizado em uma lógica clássica ou é fornecido diretamente (manualmente) pelo operador do experimento.

A primeira opção, de regras clássicas, como já apontado na revisão de fuzzy, não condiz com nosso real processo decisório e, portanto, tem pequeno valor prático. Inclusive, MORECROFT (1988) Apud PANKAJ *et al* (1994) nessa época já antecipava que a maior e mais desafiadora colaboração possível a dinâmica de sistemas seria focada no uso a nível simbólico/conceitual dos conhecimentos do decisor de política.

A segunda opção é em grande parte a origem do problema de falta de método científico e síndrome de videogame porque o utilizador (mesmo que não mude) ao não declarar explicitamente seu processo decisório (ou seja, sua hipótese de política) perde facilmente o foco do aprendizado.

Outra causa para esses problemas decorre da incapacidade de comunicar (ao grupo) em linguagem comum as hipóteses de cada experimento e seus resultados. Novamente, um sistema fuzzy com regras lingüísticas declaradas claramente é a solução perfeita para externar a todos as hipóteses e o processo decisório em teste.

A grande vantagem da lógica fuzzy em relação a outras abordagens de suporte a tomada de decisão é que sua linguagem é muito simples e flexível, uma necessidade para que o ferramental não pareça uma caixa preta para o decisor e sua equipe.

Acredito, através desses argumentos, mostrar que nesse contexto a lógica fuzzy pode potencializar o aprendizado com mundos virtuais. Entretanto, deve se destacar que ainda assim outros esforços serão necessários para o sucesso mútuo, pois algumas dificuldades inerentes à dinâmica de sistemas precisam ser equacionadas de qualquer

forma. Dentre elas, as três principais que merecem menção são: a construção participativa do modelo, a calibração do modelo e a seleção de políticas.

Já destacamos na listagem de STERMAN (2000) de aspectos para uma implementação de DS com sucesso que o envolvimento de toda a equipe é essencial para potencializar o aprendizado e gerar modelos realistas. A separação dos sistemas de políticas e controlado mantém a necessidade desse exercício participativo, simplesmente o divide em dois esforços, um para decidir a estrutura de loops do sistema complexo e outra para decidir o conteúdo das políticas no sistema de políticas.

A calibração do modelo é uma etapa necessária a qualquer modelo (seja ele de dinâmica de sistemas ou não) e a depender do nível de conhecimento da situação real e da disponibilidade de dados pode ser extremamente trabalhoso. Além disso, como a dinâmica de sistemas é uma abordagem de resolução de problemas, a validação é ainda mais necessária, pois representa um processo iterativo de ganho gradual de confiança na verossimilhança do modelo e suas premissas (VAN HORN, 1971 Apud M. SALEH *et al.*, 2010).

Novamente, a proposta de separação não tem efeito significativo sobre essa etapa (talvez possa simplificá-la ao separar controles do comportamento “natural” do sistema, mas depende caso a caso).

Finalmente, a seleção de políticas, sejam elas definidas tradicionalmente, no próprio modelo ou manualmente, sejam elas definidas em um sistema fuzzy à parte, geralmente exige avaliação de múltiplas possibilidades, envolvendo diversos parâmetros e em vários níveis.

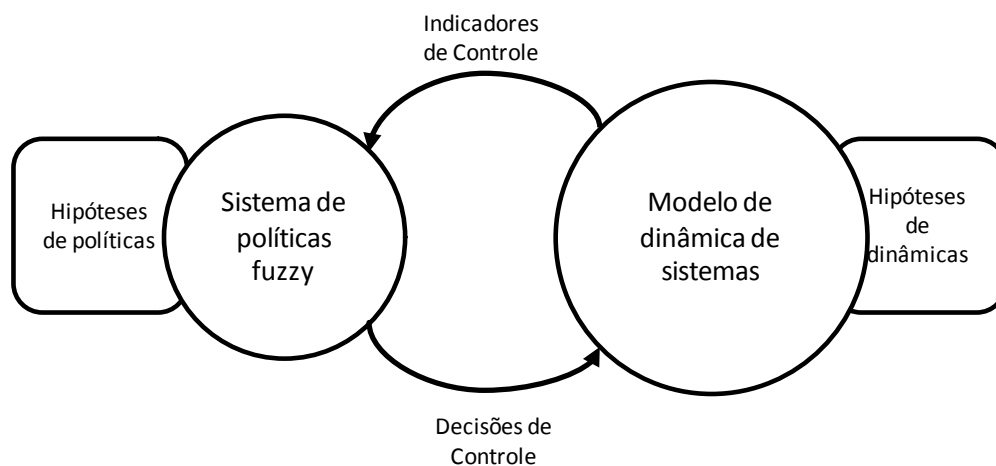
Segundo SALEH *et al.* (2010) a abordagem exploratória de cenários (*What-if*) exaustiva e a experimentação por especialistas são as formas mais comuns de gerar e avaliar políticas em modelos de dinâmica de sistemas. Outros (KLEIJNEN, 1985 Apud M. SALEH *et al.* 2010 ) utilizam softwares de otimização automatizados para analisar os parâmetros em busca de uma melhor solução de determinada função objetivo. SALEH *et al.* (2010) argumentam que as três técnicas são limitadas, as duas primeiras porque são extremamente complexas em modelos grandes, e a terceira por poder gerar soluções não intuitivas e tornar-se uma caixa preta.

Ainda no mesmo artigo os autores apresentam uma técnica capaz de conectar comportamentos do sistema a sua estrutura e a seus parâmetros, sugerindo uma abordagem sistemática para avaliar políticas. A complexidade matemática e a dificuldade de implementação fazem dessa proposta algo muito além do escopo desse trabalho, porém é valioso saber que a pesquisa especializada busca maneiras para facilitar essa etapa.

### 3.2.2. A metodologia proposta

Anteriormente argumentou-se sobre as limitações da abordagem de mundos virtuais que podem ser minimizadas com a integração a sistemas fuzzy. Nesse tópico será detalhada essa proposta.

Na metodologia proposta, o papel dos sistemas fuzzy é modelar o processo decisório que se deseja testar, mantendo-se a construção do modelo da forma natural em dinâmica de sistemas. Simplesmente separa-se o sistema que se deseja governar (modelado em DS) do sistema de decisão humano (políticas), que agora pode ser modelado em uma linguagem natural e declarado formalmente, facilitando a aplicação do método científico e disciplinando o teste de políticas. A Figura 15 ilustra essa interação.



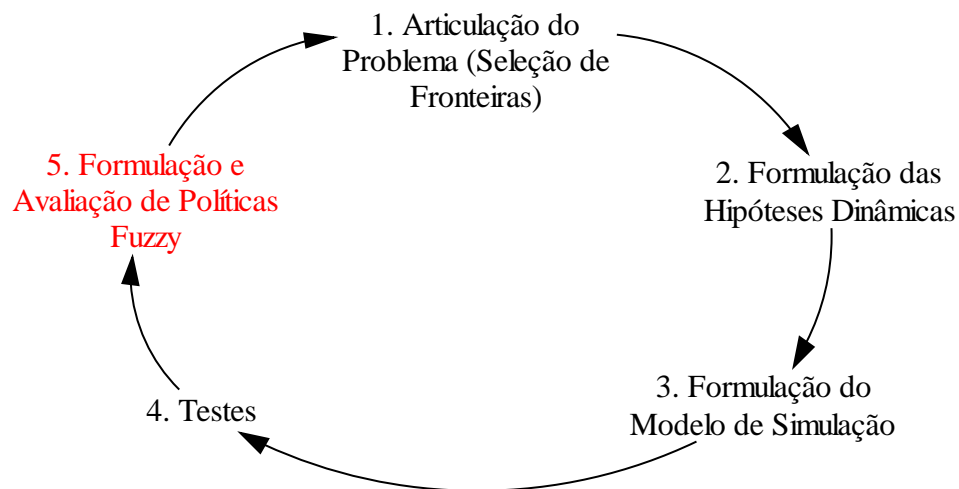
**Figura 15** Esquema da integração entre sistema fuzzy e modelo de DS

**Fonte:** Elaboração Própria

Essa metodologia proposta pode ser incluída em um framework mais geral chamado “Metodologia de Controle Adaptativo” (*Adaptive Control Methodology*, ACM) desenvolvida por BRANS *et al* (1998, 2002) e KUNSCH *et al* (2001). Que

consiste em técnicas de suporte a tomada de decisão usando dinâmica de sistemas com ferramentas de decisão multicritério. (Apud P. KUNSCH, J. SPRINGAEL, 2008)

Essa separação não gera alteração na sequência de atividades podendo preservar-se o esqueleto da metodologia de resolução de problemas proposta por STERMAN (2000) adaptada na Figura 16.



**Figura 16 Metodologia fuzzy-DS para resolução de problemas**

**Fonte: Elaboração Própria**

Acredita-se que essa seja a grande contribuição desse trabalho e por isso buscar-se-á descrever essa metodologia em um formato de cartilha, apresentando o passo a passo que tentar-se-á exemplificar no estudo de caso.

Deve-se destacar que esse é um “ciclo”, e não um “roteiro”, de resolução de problemas devendo ser repetido múltiplas vezes para que a solução obtida seja aplicável e o aprendizado de duplo loop seja efetivo.

## **1. Articulação do Problema (Delimitação das fronteiras):**

*1.1 Definir qual é o tema/problema;*

*1.2 Definir variáveis chaves;*

*1.3 Definir horizonte de tempo;*

1.4 *Definir o problema dinâmico:* normalmente alguma evolução temporal ou comportamento de referência que se deseja estudar;

## **2. Formulação das Hipóteses Dinâmicas:**

2.1 *Gerar as hipóteses iniciais:* que expliquem o comportamento observado;

2.2 *Buscar foco endógeno (explicar o problema na estrutura de feedback do sistema modelado):* Deve-se cuidar para nunca perder esse foco, de fato, RICHARDSON (2011) destaca que essa é uma condição sine qua non da abordagem sistêmica.

2.3 *Mapeamento da estrutura do sistema:* desenvolvimento de mapas da estrutura causal baseados nas hipóteses iniciais, variáveis chaves, comportamento de referência, dados disponíveis e usando ferramentas como diagramas de fronteira do modelo, diagramas de subsistemas, diagramas de loops causais, entre outras.

## **3. Formulação de Modelos de Simulação:**

3.1 *Especificar a estrutura e relacionamento (“não controlado”) entre as variáveis*<sup>11</sup>;

3.2 *Estimar os parâmetros, comportamentos, relacionamentos e condições iniciais;*

3.3 *Testar consistência com propósito e fronteiras;*

## **4. Teste:**

4.1 *Comparação com comportamento de referência:* etapa mais conhecida como calibração do modelo. Já mencionamos sua frequente dificuldade, condicionada ao problema que se estuda e informações disponíveis.

---

<sup>11</sup> Antes nessa etapa definiam-se as regras de decisão (pelo modelo original de STEARMAN, 2000), agora totalmente transferidas para o controlador fuzzy.

Sugere-se para aquele que deseja se aprofundar no tema o relevante artigo de R. OLIVA (2003);

4.2 *Avaliar robustez frente a condições extremas;*

4.3 *Testar sensibilidade:* avaliar as incertezas nos parâmetros, condições iniciais, fronteiras do problema e níveis de agregação;

**5. Formulação e Avaliação de Políticas Fuzzy:** essa é a etapa que os sistemas fuzzy devem ser utilizados. Como mencionado o sistema fuzzy deve receber do modelo de DS apenas os indicadores que usará para tomar decisões e devolver ao modelo as ordens de comando. Essa comunicação é realizada a cada intervalo de controle delimitado que pode ser igual ao intervalo de simulação ou não. As etapas para formulação de políticas fuzzy são:

5.1 *Definir variáveis de controle:* idealmente variáveis que possam ser controladas na realidade;

5.2 *Definir indicadores para monitoramento e sua periodicidade:* idealmente utilizar parâmetros que na realidade possam ser medidos e uma frequência realista;

5.3 *Definir controlador fuzzy ou sistema de políticas fuzzy:* usando os indicadores como input e variáveis de controle como output definir em lógica fuzzy as políticas;

As etapas 5.1 e 5.2 são comuns a qualquer processo decisório de controle e consistem em primeiro definir o que será controlado e depois as informações nas quais será baseada a decisão. A construção de um sistema fuzzy já foi antecipada na revisão teórica sobre lógica fuzzy, mas como é um diferencial da proposta deve-se detalhar melhor seus aspectos construtivos.

Conforme argumentado o sistema fuzzy mais adequado para implementar regras em linguagem natural é o sistema Mamdani. Para construir um sistema Mamdani deve-se definir os seguintes itens:

5.3.1 *Funções de pertinência dos inputs:* definição dos diferentes níveis lingüísticos das variáveis de entrada para a fuzzificação do input e

operacionalização das regras. O Matlab® oferece uma grande variedade de funções de pertinência que devem ser escolhidas e parametrizadas conforme o desejo do modelador.

5.3.2 *Funções de pertinência dos outputs*: definição dos diferentes níveis (funções de pertinência) do output para utilização nas regras.

5.3.3 *Regras lógicas*: construção das sentenças lógicas IF-THEN que mapeiam níveis (fuzzy) dos inputs - modificados e combinados por operadores lógicos (OR, AND, NOT etc.) - a níveis dos outputs.

Adicionalmente o Matlab® permite configurar os diversos operadores e formas de cálculos utilizadas pelo controlador dentre as quais: métodos de conjunção (OU), disjunção (E) e implicação, a forma de agregação das regras e técnica de defuzzificação. Como padrão utiliza-se os operadores mencionados na revisão sobre o modelo Mamdani e o método do centróide para defuzzificação do output.

No Apêndice 1 damos maiores detalhes a interface do Matlab® e no Apêndice 2 apresentamos algumas das opções para a implementação computacional da metodologia com softwares disponíveis no mercado (dentre as quais, a escolhida).

### **3.3 Revisão da bibliografia que integra fuzzy a dinâmica de sistemas**

A literatura de lógica fuzzy utiliza a abordagem principalmente para o processamento de linguagem natural e de conhecimentos imprecisos em sistemas especialistas. Outras aplicações comuns são em controles de processo e reconhecimento de padrões (KARAVEZYRIS *et al.* 2002), função geralmente útil a sistemas de BI que utilizam mecanismo de inteligência artificial (AI) como as redes neuro-fuzzy (um exemplo dessa aplicação é KOHOUT *et al.* ,1991 em sistemas de suporte médicos).

No outro extremo, a literatura de dinâmica de sistemas permeia diversas áreas de estudo, principalmente socioeconômicas e administrativas. Como uma técnica de modelagem sistêmica, em teoria qualquer sistema pode ser estudado com suas técnicas.

O primeiro artigo encontrado integrando as duas abordagens é de PANKAJ *et al.* (1994) que propunha um método de análise qualitativa de loops causais usando fuzzy

para incorporar as incertezas lingüísticas nas percepções e crenças do modelador. Segundo o autor buscava-se um uso a nível de conhecimento com através de uma interface capaz de sistematizar a análise que de outra forma seria feita subjetivamente. A idéia adotada pelo autor é transformar uma relação causal do diagrama de enlace em uma relação fuzzy, como no seguinte exemplo do artigo:

Gastos com Propaganda  $\xrightarrow{+}$  Vendas

Pode ser transformado em: SE Gasto com Propaganda É Alto ENTÃO Vendas É Alta

Nota-se que a motivação dessa proposta é semelhante à apresenta previamente, partindo da percepção que determinadas relações em nosso modelos mentais são melhor expressadas em linguagem natural. Contudo, seu objetivo é bastante distinto, buscando quantificar relações causais, aplicando lógica fuzzy não apenas para políticas quanto para relações “naturais” ao sistema. Acredito que a quantificação buscada de certa forma é realizada em modelo de fluxos e estoque se mostrando menos valiosa. Além disso defende-se que só faz sentido modelar relações com lógica fuzzy quando as variáveis e suas relações tiverem esse tipo de incerteza (o que não se aplica a uma regra determinística como “aumentar a produção aumenta o custo variável”) mais característico em relações fruto de políticas.

Em outro artigo, KUNSCH E SPRINGAEL (2008) usam DS para simular o comportamento dos consumidores e mecanismos de controle de impostos por emissão de carbono (relacionados ao consumo energético). Os autores usam raciocínio fuzzy aportando o modelo de DS para agregar dados externos provindos de diferentes fontes com credibilidades diversas e utilizados para controlar/dirigir o modelo. Na aplicação o uso de lógica fuzzy é simplesmente para tratar das incertezas de diversas fontes de uma mesma informação para obtenção/cálculo de um parâmetro ao modelo, operando de maneira exógena. Em aplicação semelhante, CAMPUZANO *et al.* (2010) usam fuzzy para modelar incertezas da demanda em um modelo de cadeia de suprimentos em DS. Como no caso anterior a variável fuzzy é exógena ao modelo.

Nesses dois artigos citados percebe-se que fuzzy foi integrado ao modelo de DS para tratar a natureza incerta de determinadas variáveis do modelo que continua



embutindo as políticas classicamente (inclusive as que envolvam as variáveis com incerteza fuzzy, discretizadas para serem passadas ao modelo).

KARAVEZYRIS *et al.* (2002) integra fuzzy a seu modelo de DS para tratamento de resíduos sólidos devido a uma demanda semelhante a casos anteriores: a incerteza na estimação de parâmetros despertando o interesse em usar variáveis lingüísticas para aproveitar conhecimentos tácitos de especialistas. Entretanto, diferentemente dos demais, ao final do artigo os autores mencionam vagamente algo semelhante a proposta desse projeto: usar lógica fuzzy para deduzir regras a partir de resultados experimentais<sup>12</sup>. Sem maiores detalhamentos esse parece ser o único artigo que apontava a possibilidade de dissociar políticas de decisão aproveitando a habilidade da lógica fuzzy de emular linguagem natural.

Em outra linha de pesquisa, POLAT E BOZDAĞ (2002) utilizam um modelo de DS simples para comparar sistemas de decisão clássica e fuzzy em diferentes situações. Outros artigos com esse tipo de experimento podem ser encontrados na literatura de controle e automação, porém um diferencial desse artigo é a utilização de um modelo de dinâmica de sistemas para os testes (no caso para controle de temperatura).

Seus resultados mostraram a proximidade do desempenho entre sistemas fuzzy e sistemas contínuos crisp, indicaram que os sistemas fuzzy eram relativamente robustos (apresentando comportamento semelhante mesmo com quantidades de regras diferentes e em cenários variáveis) e identificaram que, especificamente em uma situação extrema de um dos parâmetros, os controladores contínuos crisp foram mais eficientes na busca da meta. A conclusão dos autores (reproduzida em diversos outros artigos aplicados a modelos de controle) é que a superioridade entre sistemas crisp ou fuzzy depende da situação específica.

Essa conclusão dos autores serve para destacar o fato que para finalidades de controle de sistemas não há qualquer indicação a priori que fuzzy seja a melhor alternativa (principalmente se a precisão for uma necessidade). Reforçando o argumento que fuzzy deve ser escolhido por sua adequação teórica/conceitual ao tipo de controle, isto é para os casos em que as políticas sejam declaradas em linguagem natural e

---

<sup>12</sup> Dão a entender que fuzzy serviria para extrair regras (políticas) e não para fornecê-las

envolvendo variáveis fuzzy. Se esse não for o caso, deve-se analisar entre as diversas técnicas de controle qual tem o melhor desempenho para o sistema específico.

Outra variante da integração pode ser encontrada nos recentes artigos de KHANZADI *et al.* (2012), cuja situação problema era definição do período de concessão ótimo em projetos BOT<sup>13</sup>, e NASIRZADEH *et al.* (2013), cujo objetivo era tomar a decisão ótima na alocação de riscos entre dono e contratado de obras.

Nesses artigos os autores constroem modelos mais robustos (que os trabalhos anteriores), pois usam no modelo além das variáveis crisp, cujas relações são obtidas por dados históricos, variáveis fuzzy (de conhecimentos de especialistas), cujas relações são obtidas por sistemas fuzzy (simulando modelos mentais de especialistas).

A adição de números fuzzy ao modelo torna as operações algébricas mais complexas, necessitando do princípio da extensão para serem realizadas. Para isso, nos artigos em questão, foi adotada a seguinte sequência: fornecer um  $\alpha$ -cuts<sup>14</sup>, calcular inputs crisp (para o  $\alpha$  específico) ao modelo, rodar a simulação e gerar um valor único do output. Repetindo esses passos para diversos  $\alpha$ -cuts obtendo um output fuzzy (executando-se uma “simulação dentro de uma simulação”).

Da bibliografia pesquisada estes dois são os trabalhos que integram mais proveitosamente as duas abordagens, explorando suas especialidades para a resolução de um problema específico. Acredito que para a resolução de problemas específicos (que justifiquem o rigor e complexidade do modelo) esse seja um caminho promissor integrando as duas técnicas.

Entretanto, a maior complexidade desse tipo de aplicação afasta o modelo do uso regular dos decisores e suas equipes para aprendizado, tornando-se ferramental para especialistas em pesquisa operacional. Para a finalidade de aprendizado organizacional, propósito da metodologia nesse trabalho, não parece ser justificável a complicação das aplicações nesses artigos.– lembrando da recomendação de STERMAN (2000) que o modelo não pode ser uma caixa preta.

---

<sup>13</sup> Do inglês “*build–operate–transfer*”, “construir-operar-transferir”.

<sup>14</sup> Um  $\alpha$ -cut de um conjunto fuzzy é um conjunto contendo elementos com pertinência superior ou igual a  $\alpha$ .

Com essa necessidade em mente que se indica na metodologia proposta o uso de sistemas fuzzy apenas para modelar as políticas a serem testadas e não elementos (variáveis) do sistema controlado.

Em outra linha de integração, artigos recentes na literatura como XU E LI (2011) e WU E XU (2013) usam dinâmica de sistemas e fuzzy para otimizações. Nesses dois artigos, por exemplo, utiliza-se programação multi-objetivo fuzzy resolvida por algoritmos genéticos. Como em outros artigos mencionados o uso de fuzzy é para modelar incertezas de determinadas variáveis e não suas relações. Essas propostas são ainda mais complexas, com objetivos específicos e conseqüentemente inaplicáveis para aprendizado organizacional.

Conclui-se com os últimos a relação de artigos mais relevantes obtida da pesquisa bibliográfica não exaustiva conduzida. Como pode-se notar, a grande maioria dos autores propunha a integração de fuzzy a modelos de dinâmica de sistemas para modelar variáveis fuzzy, ou soft quando havia indisponibilidade ou baixa credibilidade de dados.

Apenas um artigo na literatura cogitava (vagamente) a utilização de fuzzy especificamente para modelar sistemas de decisão (e testá-los). A falta de propostas com essa finalidade é em grande parte decorrente do fato que a maioria das aplicações era voltada para problemas práticos de áreas específicas e não para promoção de aprendizado gerencial sobre determinado problema/sistema.

Em problemas práticos podem ser observadas duas aplicações principais de fuzzy:

Primeiro, para modelar variáveis (e suas relações) com características de incerteza fuzzy que é a aplicação mais comum na literatura. Acredito que seja uma adição proveitosa a modelos de dinâmica de sistemas para lidar com situações reais, mas como argumentado pode aumentar consideravelmente a complexidade da formulação matemática (ao menos enquanto os softwares de DS não oferecerem ferramentas mais apropriadas para lidar com variáveis fuzzy e suas operações).

Segundo, para controlar sistemas dinâmicos, uma abordagem mais estudada pela teoria de controle e em modelos de engenharia (com outras linguagens de modelagem).

Para esse tipo de aplicação são variadas as opções de técnicas de controle e como argumentado só deve se escolher sistemas fuzzy quando eles forem conceitualmente adequados.

Por outro lado, o uso de fuzzy com o objetivo desse trabalho, associado a mundos virtuais para aprendizado gerencial, é sempre conceitualmente adequado pois sua simplicidade e emulação do raciocínio impreciso humano impreciso são altamente desejadas. Nesse tipo de situação não se aplicam as ressalvas mencionadas para aplicações práticas e como pode-se notar a literatura especializada deixa brechas para a metodologia proposta. O próximo passo é aplicá-la a um estudo de caso que permita avaliação de sua viabilidade.

## 4 Estudo de Caso: Empresa XYZ

Segundo GHEMAWAT E CASSIMAN (2007) Apud M. S. GARY *et al* (2008) “incorporar dinâmicas ao nosso pensamento sobre estratégia é um grande, talvez o maior, desafio que o campo de estratégia enfrenta para avançar”.

Outro influente autor da área, PORTER (1991) Apud M. S. GARY *et al* (2008), também ressalta que existem diversos frames que conseguem explicar diferenças entre as empresas em dado momento no tempo, porém nossa compreensão dos processos dinâmicos que levam a uma posição de mercado superior ainda é muito limitada.

Busca-se com essas citações de autores muito respeitados na área demonstrar a permanente relevância de estudar a dinâmica de sistemas estratégicos. Por esse motivo e pela grande prevalência de estudos nessa área utilizando dinâmica de sistemas, optou-se por construir um modelo (e um problema) de estratégia para exemplificar a metodologia.

Deve ser destacado, antes de começar, que o objetivo desse estudo de caso é tão somente implementar a metodologia e por isso buscou-se manter a simplicidade do modelo evitando também sua trivialidade. A relevância e dificuldade de criar e trabalhar sobre um modelo ficcional serão discutidas ao final do capítulo.

Sem mais delongas será percorrido a seguir cada um dos passos da metodologia construída sobre os problemas da empresa ficcional XYZ. Para facilitar serão separadas as etapas antes da definição das políticas fuzzy, que chamarei de “pré-controle”, da etapa de definição de políticas/controles fuzzy em que apresentar-se-ão algumas opções.

### 4.1 Etapas “pré-controle”

#### 1. Articulação do Problema (Delimitação das fronteiras):

1.1 *Definir qual é o tema/problema:* A empresa XYZ está num momento em que não consegue atender sua demanda e busca aumentar seu lucro devendo decidir a precificação e nível de staff (produtividade) que atraíam clientes.

1.2 *Definir variáveis chaves:* As principais variáveis são produtividade, inovação, melhorias de processos, tamanho da equipe/staff e preço.

1.3 *Definir horizonte de tempo:* utiliza-se um período de 2 anos e meio (30 meses)

1.4 *Definir o problema dinâmico:* Decisões de precificação e quantidade de empregados de forma a obter maior lucro no final dos dois anos e meio.

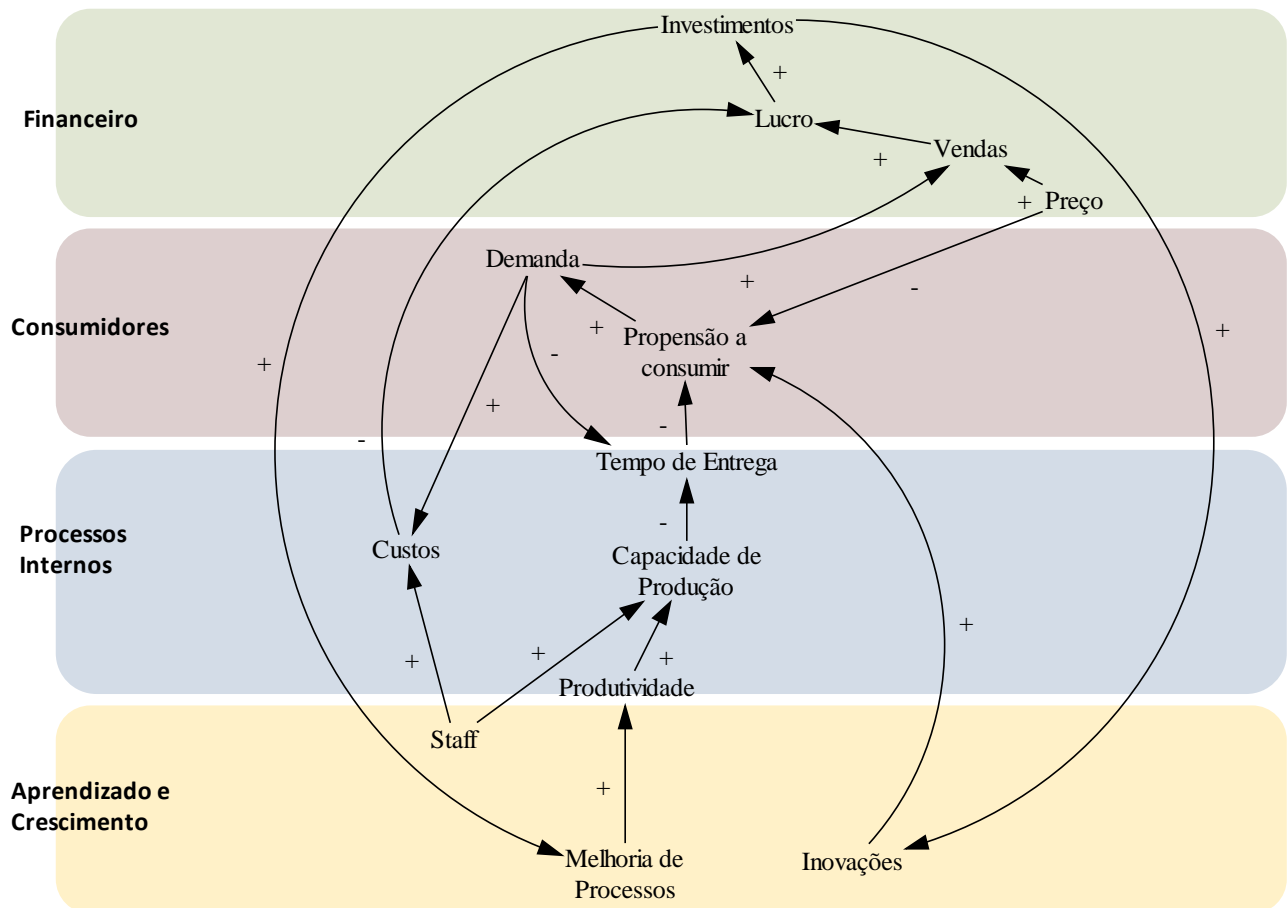
## **2. Formulação das Hipóteses Dinâmicas:**

2.1 *Gerar as hipóteses iniciais:*

- O consumidor é atraído negativamente pelo tempo de entrega e preço, positivamente por inovações do produto.
- Investimentos em melhorias de processo e em inovações tem rendimentos decrescentes de escala.
- A empresa tem custos fixos de salários e custo variável de matéria prima, apenas.

2.2 *Buscar foco endógeno:* Para o caso em questão seria garantir que todos os elementos para explicar o comportamento da demanda e o problema na produção fossem considerados no modelo. Pode-se explicar os problemas iniciais assumindo serem decorrentes dos investimentos passados em inovação que tornaram o produto extremamente atraente (considerado seu baixo preço) e fizeram a demanda exceder a capacidade de produção.

2.3 *Mapeamento da estrutura do sistema:* a figura abaixo apresenta o mapa de loop causal alinhado à estrutura do balance scorecard:



**Figura 17 Diagrama de Enlace Causal da empresa XYZ**

**Fonte: Elaboração Própria**

### **3 Formulação de Modelos de Simulação:**

- 3.1 *Especificar a estrutura e relacionamento (“não controlado”) entre as variáveis;*
- 3.2 *Estimar os parâmetros, comportamentos, relacionamentos e condições iniciais;*
- 3.3 *Testar consistência com propósito e fronteiras.*

Como o caso é ficcional não haviam dados para suportar sua formulação que não garantindo que seja a mais adequada. De qualquer forma buscou-se modelar um comportamento factível e condizente com o problema declarado no início da metodologia. Dito isso, apresenta-se na Figura 18 a seguir, o modelo de fluxos e estoques construído para simular o problema.

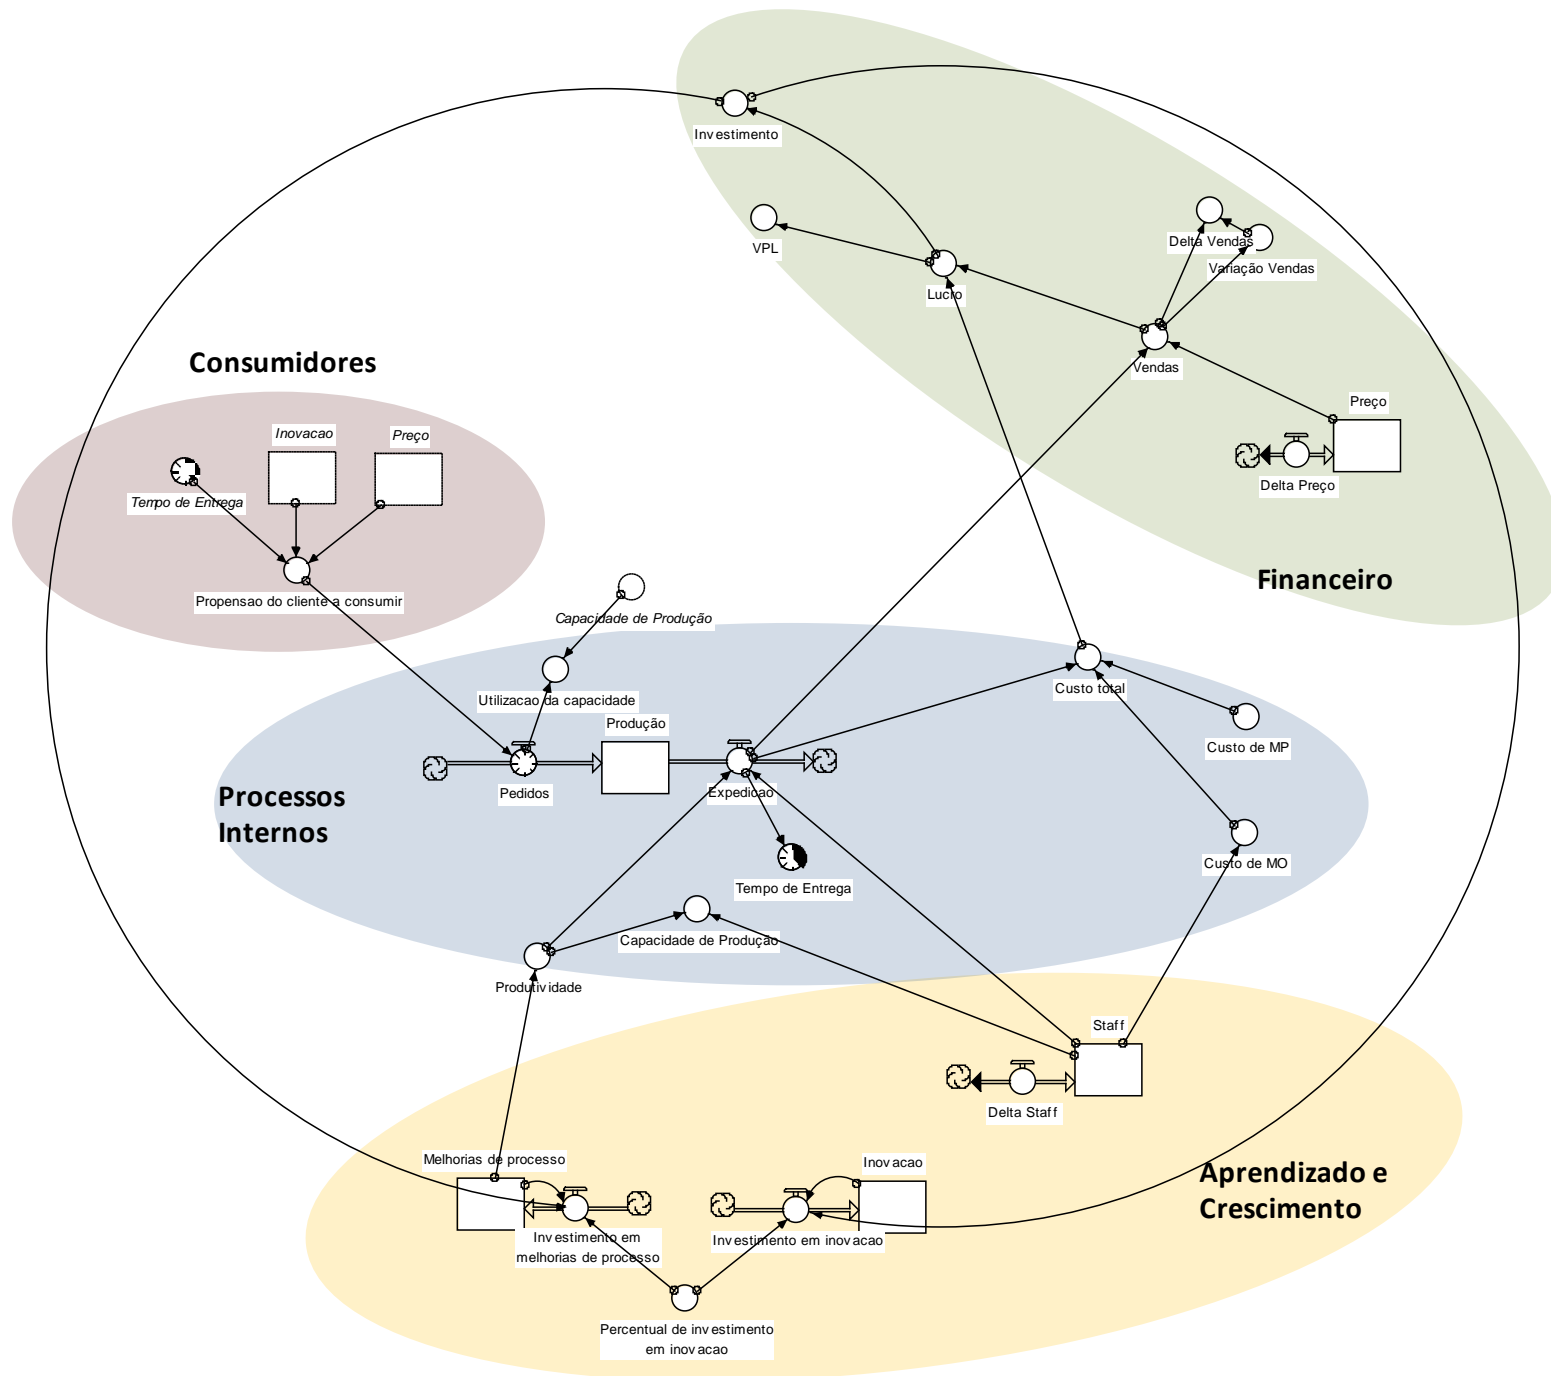


Figura 18 Modelo de Fluxos e Estoques da empresa XYZ

Fonte: Elaboração Própria



As fórmulas para cada uma das variáveis apresentadas no modelo de fluxos e estoques são as seguintes:

- $Inovacao(t) = Inovacao(t - dt) + (Investimento\_em\_inovacao) * dt$ <sup>15</sup>
- $INIT\ Inovacao = 5000$ <sup>16</sup>

Inovação é um estoque que começa com 5000 unidades monetárias investidas e é acrescido ao longo do tempo pelos investimentos em inovação.

- $Investimento\_em\_inovacao = (Investimento / Inovacao) * Percentual\_de\_investimento\_em\_inovacao$

Taxa de incremento na inovação do produto. Construí a fórmula dessa maneira para garantir que os rendimentos dos investimentos são decrescentes em escala, significando que progressivamente é necessário investir mais para conseguir gerar maior inovação do produto.

- $Melhorias\_de\_processo(t) = Melhorias\_de\_processo(t - dt) + (Investimento\_em\_melhorias\_de\_processo) * dt$
- $INIT\ Melhorias\_de\_processo = 10000$

Melhorias de Processo é um estoque que começa com 10000 unidades monetárias investidas e é acrescido ao longo do tempo pelos investimentos em melhoria de processo.

- $Investimento\_em\_melhorias\_de\_processo = (Investimento / Melhorias\_de\_processo) * (1 - Percentual\_de\_investimento\_em\_inovacao)$

Fórmula análoga a dos investimentos em inovação usando a parcela complementar do investimento total.

- $Preco(t) = Preco(t - dt) + (Delta\_Preço) * dt$

---

<sup>15</sup> “dt” é um intervalo de simulação. A fórmula apresentada significa que o valor do em “t” do estoque é igual ao seu valor em “t-dt” acrescido do fluxo recebido em “dt”.

<sup>16</sup> Essa é a sintaxe para declarar o valor inicial do estoque.

- $INIT\ Preço = 50$

- $Delta\_Preço = 0$

Preço é um estoque que será uma das variáveis controladas (via “delta preço”). Por ora o preço não é alterado mantendo-se no patamar de 50 unidades monetárias.

- $Produção(t) = Produção(t - dt) + (Pedidos - Expedicao) * dt$
- $INIT\ Produção = 0$

A produção recebe fluxo de pedidos e libera produtos a uma taxa “expedição”. Sua acumulação se dá em forma de estoques.

- $Pedidos = 10000 * Propensao\_do\_cliente\_a\_consumir/100$

Parte-se do princípio que mantidas as condições iniciais de entrega, preço e inovação a demanda seja de 10.000 podendo crescer ou diminuir conforme a propensão do cliente a consumir se altere. A divisão por 100 é apenas para corrigir o fato que a propensão está em percentual.

- $Expedicao = Produtividade * Staff$

A expedição, ou taxa de produção, é no máximo a capacidade calculada multiplicação da produtividade (por trabalhador) pela quantidade de trabalhadores (quando no máximo de capacidade) - ou da quantidade de produtos em processamento (quando abaixo da capacidade máxima).

- $Staff(t) = Staff(t - dt) + (Delta\_Staff) * dt$

- $INIT\ Staff = 20$

- $Delta\_Staff = 0$

Staff é um estoque que será a outra variável controlada (via “delta staff”). Por ora o staff não é alterado nem com demissões nem com contratações, mantendo-se no patamar de 20 empregados.

- $Custo\_de\_MO = Staff * 2500$

Custo fixo obtido pela multiplicação do Staff pelo salário de cada empregado.

- $Custo\_de\_MP = 5$

Único custo variável do modelo, seu valor unitário é de 5.

- $Custo\_total = (Expedicao * Custo\_de\_MP) + Custo\_de\_MO$

Obtido pelo somatório dos custos variáveis e fixos.

- $Investimento = 0.5 * Lucro$

Essa é uma regra rígida que usaremos nesse modelo, poderia não ser o caso. Considera-se que a empresa tem a meta fixa de reinvestir sempre 50% de seus lucros.

- $Lucro = Vendas - Custo\_total$

Fórmula evidente, não precisa de maiores explicações.

- $Percentual\_de\_investimento\_em\_inovacao = 5000/15000$

Significa dizer que as inovações sempre receberão 1/3 dos investimentos (calculei assim só para mostrar que os estoques iniciais de inovações e melhorias já seguem essa mesma proporção).

- $Produtividade = (450 * Melhorias\_de\_processo) / 10000$

Essa fórmula é meramente uma regra de três simples. No valor inicial de “melhorias de processo” a produtividade seria de 450 produtos/ trabalhador \* mês. E calcula-se a nova produtividade pela razão entre melhorias de processo no início e atual.

- $Propensao\_do\_cliente\_a\_consumir = IF\ TIME > 2\ THEN\ 100 * (50/Preço) * (17/Tempo\_de\_Entrega) * (Inovacao/5000)\ ELSE\ 100$

O If é novamente para evitar problemas de cálculo enquanto o tempo de entrega for nulo no ramp-up da linha de produção. A fórmula é uma regra de três composta usando a seguinte proporcionalidade:

	<b>Propensão a consumir</b>	<b>Preço</b>	<b>Tempo de Entrega</b>	<b>Inovação</b>
<b>Situação Inicial</b>	1	50	17	5000
<b>Situação X</b>	X	Preço	Tempo de Entrega	Inovação
		<b>X =</b>	<b>50</b>	<b>* 17</b>
			<b>Preço</b>	<b>* Inovação</b>
			<b>Tempo de Entrega</b>	<b>5000</b>

A multiplicação por 100 é para aumentar a dimensão do número (em percentual) e facilitar a plotagem.

- $Tempo\_de\_Entrega = CTMEAN(Expedicao) * 30$

CTMEAN é uma função nativa do STELLA<sup>17</sup> usada para calcular a média do tempo de atravessamento. Multiplica-se por 30 para obter o resultado em dias. Utiliza-se a média, pois caso contrário o valor seria muito oscilante.

- $Utilizacao\_da\_capacidade = (Pedidos/Capacidade\ de\ Produ\c\c{a}\o) * 100$

Não representa a medida mais tradicional de utilização da capacidade, pois só considera os novos pedidos na razão com a capacidade. É meramente uma opção de construção do modelo pois será um dos indicadores utilizados para a tomada de decisões. Novamente a multiplicação por 100 serve para não operar com decimais.

- $Variac\c{a}\o\_Vendas = DERIVN(Vendas,1)$

Mede a variação (derivada de 1º grau) das vendas.

- $\Delta\_Vendas = IF\ Vendas = 0\ THEN\ 0\ ELSE\ (Variac\c{a}\o\_Vendas/Vendas) * 100$

A condicional só serve para não dar erro de cálculo no início da simulação quando nenhuma venda foi realizada ainda.

É outro dos indicadores que será utilizado para tomar decisões de controle e mede a variação percentual das vendas, é multiplicado por 100 apenas para não operar-se com decimais.

- $Vendas = Expedicao * Pre\c{c}o$

Fórmula tradicional sem necessidade de explicações.

- $VPL = NPV(Lucro,0.005)$

Função nativa do programa que calcula o valor presente líquido usando o tempo de simulação e os inputs que são fornecidos a cada intervalo de simulação. O segundo valor é a taxa de juros por intervalo de simulação, no caso 15 dias. Como pode se notar foi usada uma taxa nominal mensal de 1%<sup>18</sup> como referência para cálculo.

---

<sup>17</sup> Para maiores detalhes dessas e de outras *built-ins* do STELLA consultar o arquivo de Help do programa. Versões compiladas em arquivos únicos podem ser obtidas na internet.

<sup>18</sup> Pode-se criticar esse valor como alto, de fato é. Porém volto a destacar que o caso é fictício e peço para desprender-se dos valores absolutos para atentar ao método.

#### **4 Teste:**

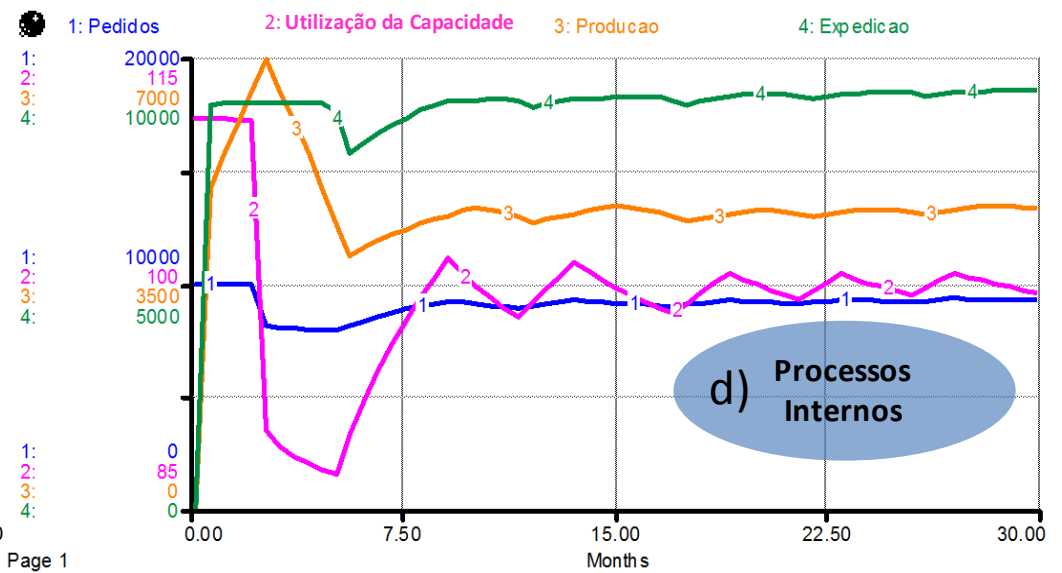
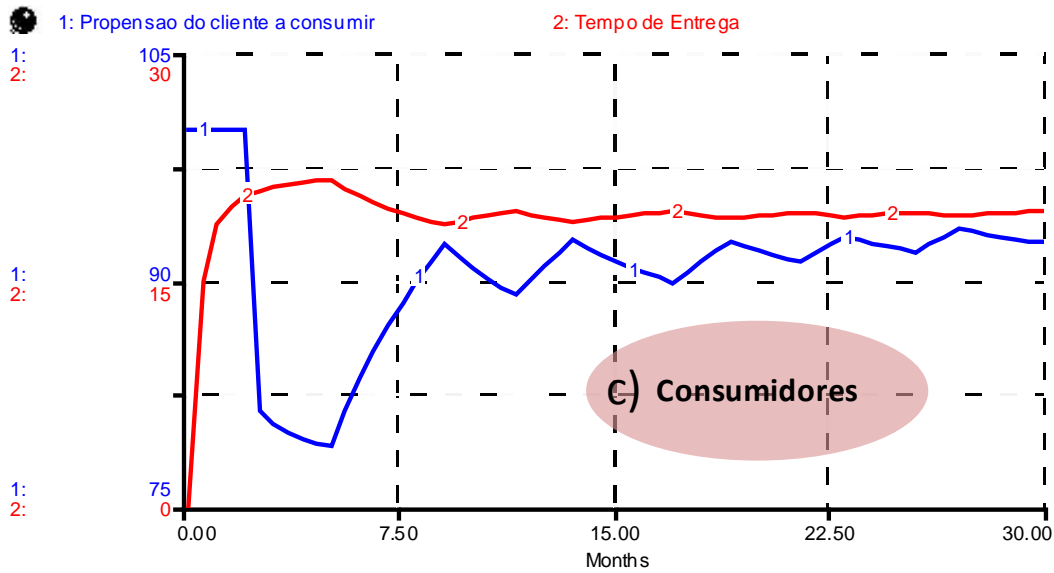
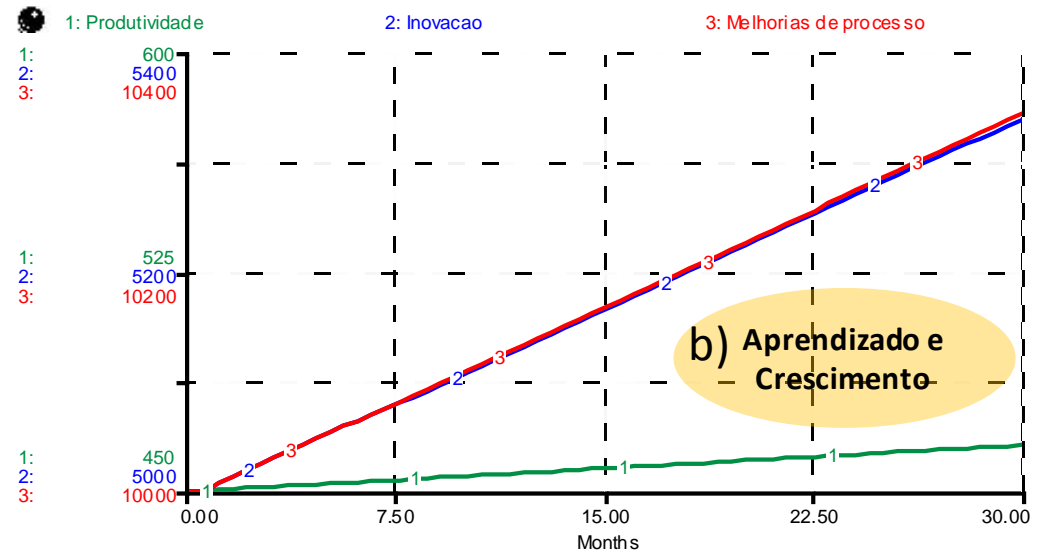
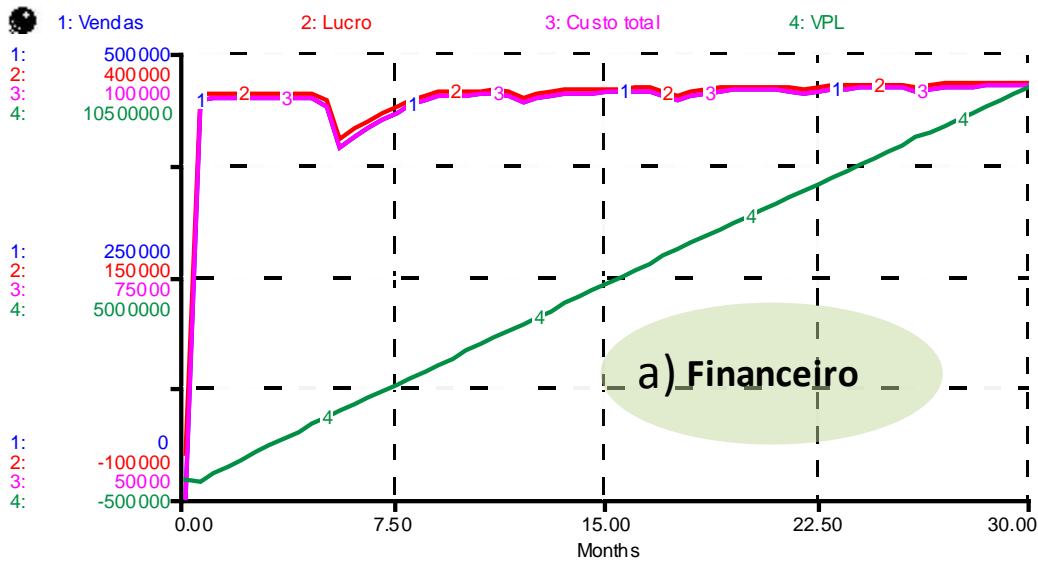
4.1 *Comparação com comportamento de referência;*

4.2 *Avaliar robustez frente a condições extremas;*

Essa etapa, mais conhecida como calibração, teria o papel de ajustar o modelo a determinado comportamento de referência. Como mencionado, na ausência de um relativo na realidade buscou-se tornar o modelo crível e adequado ao problema declarado.

Por esse motivo as atividades dessa etapa perdem um pouco do sentido simplesmente será apresentado e explicado o comportamento do modelo “sem controle”.

A Figura 19 a seguir mostra o comportamento de suas variáveis agrupadas de acordo com seu posicionamento no *balance scorecard*.



Page 1

Figura 19 Resultados do modelo sem controle

Fonte: Elaboração Própria

Na Figura 19c pode-se perceber que a propensão do consumidor começa muito alta mas rapidamente cai conforme o tempo de entrega cresce. A produção em momento nenhum é capaz de atender aos 17 dias de entrega do produto e por isso não aproveita o potencial de seu mercado – ficando com a propensão marginal permanentemente abaixo de 100. Por esse comportamento percebe-se também que a inovação mesmo que crescente (como mostrado na figura 19b) não é capaz de compensar a demora do serviço de entrega. Nota-se também que as crescentes melhorias de processo (também na Figura 19b), e conseqüente aumento da produtividade, não são capazes de reduzir o tempo de entrega com a demanda que se deparam.


Na Figura 19d, com a dimensão de processos internos, nota-se que a utilização da capacidade oscila sempre em torno do seu limite (100%), motivo pelo qual não consegue abaixar seus elevados estoques em processo e conseqüentemente melhorar seu prazo de atendimento (precisaria processar seu estoque em processamento além dos novos pedidos que entram).

Na Figura 19a, com a dimensão financeira, nota-se que depois de pequena oscilação os indicadores (lucro, vendas e custo total) caminharam juntos, pelo motivo óbvio que todos dependem do volume de expedição.

Como mencionado na declaração inicial do problema, sem alterar-se os parâmetros, a produção encontra-se saturada e incapaz de reduzir seus estoques em processo e o tempo de entrega. Não conseguindo atender sua demanda potencial e resultando na estagnação dos lucros.

#### 4.3 Testar sensibilidade:

Para exemplificar nesse item será feita a análise de sensibilidade do percentual de divisão do investimento que por hipótese é mantido fixo no modelo original. Testaram-se 4 perfis para a evolução dessa variável no tempo e que foram comparados pelo VPL ao final do período – resultado apresentado na Figura 20.



**Figura 20 Perfis da Análise de sensibilidade e seus resultados**

**Fonte: Elaboração Própria**

Fica evidente que na configuração do modelo a capacidade está limitada. Por esse motivo aumentos em produtividade são mais efetivos por permitirem melhorar o tempo de entrega e por conseqüências os novos pedidos.

A inovação por outro lado impulsiona ainda mais a demanda o que deteriora ainda mais o tempo de entrega do produto voltando a reduzir a demanda. Explica-se assim porque os modelos que priorizaram investimentos em melhorias de processo obtiveram melhores resultados (quando comparados pelo VPL).

## **5 Formulação e Avaliação de Políticas Fuzzy:**

Idealmente nesse item apresentar-se-ia a maneira como foi pensado cada um dos sistemas fuzzy de políticas, porém essa é uma tarefa difícil de rastrear. Em sistemas que reproduzem alguma realidade as políticas podem surgir naturalmente de práticas habituais ou modificações destas, no presente caso, entretanto, o sistema é não é real e seu comportamento em reação a diferentes parâmetros é difícil de prever.

Já foi mencionado previamente que existem na literatura propostas de métodos sistemáticos para avaliação de políticas, nesse trabalho, na falta desses métodos serão utilizados os tradicionais testes para uma grande variedade de controladores.

Apesar da necessidade de testar deve-se ressaltar que quanto maior a compreensão do modelo e da influência de cada parâmetro no seu comportamento mais habilitado o modelador está para definir políticas. Por esse motivo a etapa anterior de testes é extremamente determinante à qualidade das políticas que serão propostas nessa etapa. É



bem verdade que no teste das políticas muito se aprende sobre o modelo, mas um conhecimento prévio é essencial no mínimo para formular a primeira política.

Não acho ter valor apresentar grande quantidade de sistemas fuzzy construídos e seus resultados. Por esse motivo serão registrados “apenas” três modelos de controladores com conteúdo bastante diferente. Para não prolongar excessivamente este relato apresentarei a construção em detalhes apenas daquele que obteve melhor resultado quando comparado pelo VPL, os demais apresentarei de forma mais resumida.

## **4.2 Controlador 1**

A numeração abaixo volta a seguir a sequência de passos da metodologia proposta e não deve ser confundida com o item acima, que marca o início de um subcapítulo.

### *5.1 Definir variáveis de controle*

Nesse controlador e nos demais serão controladas mudanças de preço e do tamanho do staff.

### *5.2 Definir indicadores para monitoramento e sua periodicidade*

Utilizou-se para o controle o indicador “Utilização da Capacidade” e “Delta Vendas”. A intenção era manter as vendas (dependente da quantidade demandada e do preço) crescentes e a utilização média (para garantir tempo de entrega satisfatório). A periodicidade de sua coleta foi de um mês (dois intervalos de simulação).

### *5.3 Definir controlador fuzzy ou sistema de políticas fuzzy*

Como comentado é difícil em retrospectiva explicar o porquê das decisões. Com a motivação de controle acima tinha a sensação que a utilização era um bom indicador para acessar a qualidade de entrega e ao mesmo tempo a ociosidade (ou tamanho excessivo de staff). E a variação de vendas um bom indicativo para motivar alterações de preço e/ou staff seletivamente – imaginando que em certo momento haveria um equilíbrio ideal entre nível de preços e tamanho de equipe que não permitisse mais crescimento de vendas significante.

Ressalta-se que um dos valores dessa metodologia é que experimentar por experimentar ou seguir impressões é algo não apenas possível como recomendado. O

objetivo não é de otimização das políticas, é somente de aprender mais sobre o sistema e possibilidades de políticas para governá-lo<sup>19</sup>.

#### 5.3.1 *Funções de pertinência dos inputs*

O passo inicial para essa etapa é ter bem definido qual o domínio de cada um dos indicadores (os possíveis valores que eles podem tomar). Isso pode ser obtido normalizando de alguma forma o cálculo do indicador (como foi feito se observar as fórmulas já apresentadas) ou estudando o modelo para experimentalmente determinar as bandas de variações dos valores.

Em situações reais, se o modelo já foi adequado a comportamentos de referência, essa definição pode ser menos problemáticas, bastando usar o conhecimento que já foi adquirido na prática.

#### 5.3.2 *Funções de pertinência dos outputs*

Como no passo anterior, a primeira das necessidades é definir quais os possíveis valores que esses outputs tomarão. Ao contrário dos inputs que são resultados do modelo esses são parâmetros exógenos ao modelo e na grande maioria das vezes podem tomar valores conforme o desejo do definidor da política.

Mesmo nessas situações, entretanto, o realismo desses valores deve ser levado em conta. Não se pode liberar determinados valores que não tenham sentido ou viabilidade na vida real, pois perde-se todo o valor prático do aprendizado.

Para o controlador 1 definiu-se o *range* de variação dos preços de 10 unidades monetárias para cima ou para baixo. A variação de staff, por motivos unicamente subjetivos<sup>20</sup>, foi definida para demissões não superiores a cinco (5) pessoas e contratações não acima de dez (10) pessoas ( em um intervalo de 15 dias).

A Figura 21 na sequência apresenta as diversas funções de pertinência de cada um dos inputs e outputs associados a seus termos lingüísticos. Como pode-se notar forma escolhidas funções de pertinência simples, triangulares e trapezoidais, pois não

---

<sup>19</sup> Acredito inclusive que muito provavelmente outras tentativas possam encontrar uma “melhor solução”.


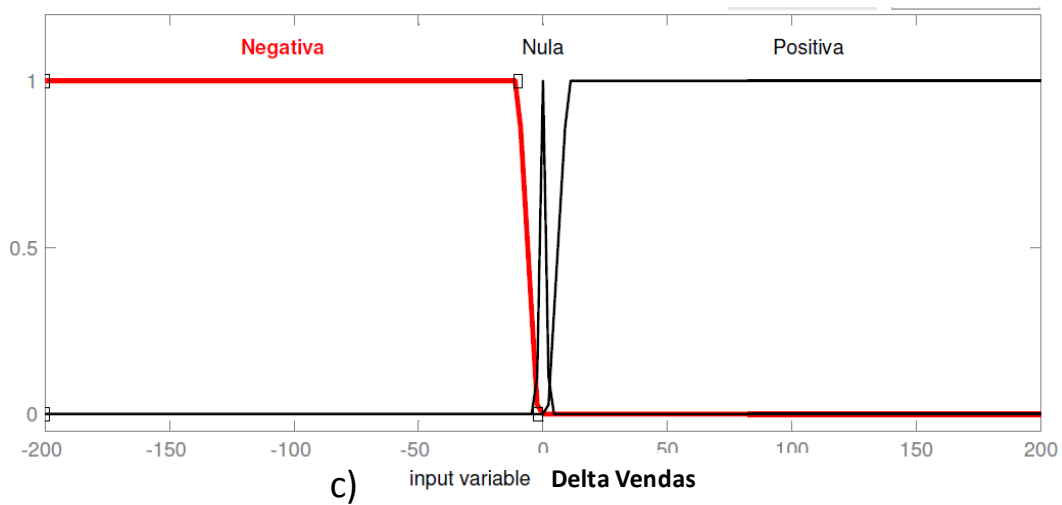
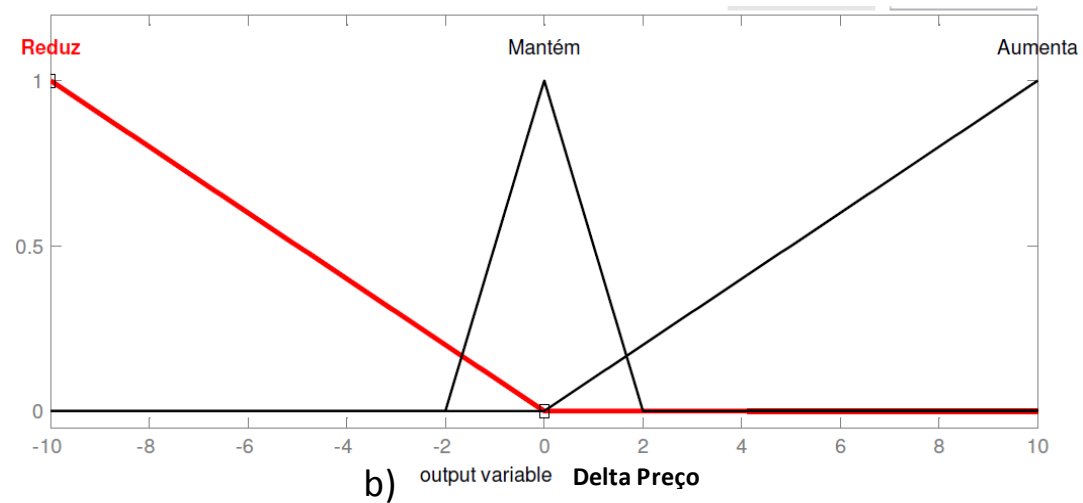
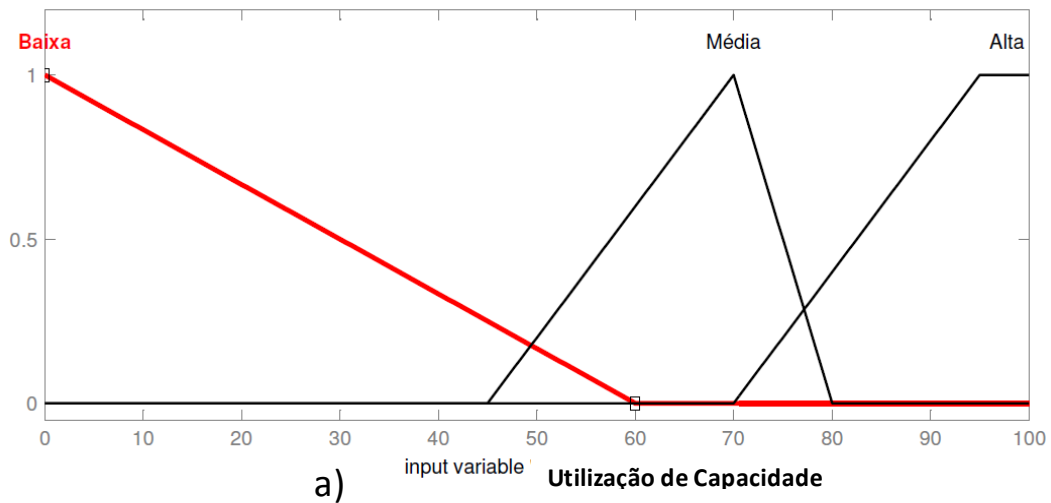
<sup>20</sup> Não queria ter um controle muito longe da realidade que demitisse e/ou contratasse em massa.

tinha motivos para usar outras<sup>21</sup> e por serem as mais usadas na literatura. O modelador tem total liberdade de escolher entre os formatos de funções de pertinência e não coloca-se os formatos escolhidos como uma imposição.

Igualmente a quantidade de funções de pertinência para cada elemento depende da necessidade do modelador, quanto maior seu número maior a flexibilidade do controle (ao serem declaradas em regras).

---

<sup>21</sup> O critério para escolher entre as diversas funções é unicamente a percepção do modelador, se no seu subjetivismo achar outro formato mais adequado deve utilizá-lo.



**Figura 21** Pertinências do controlador 1

Fonte: Elaboração Própria

Como pode-se notar na Figura 21a a Utilização de Capacidade foi considerada média próxima de 70% (mais inclinada para valores maiores) e será esse o alvo de utilização desejado.

Na Figura 21c destaca-se que o Delta Vendas foi definido de maneira muito sensível a variações com o nula entre  $\pm 3\%$  e o positivo e negativo acionados a partir de 2,5%.

Na Figura 21b destaca-se o range mencionado e a manutenção de preços entre  $\pm 2 u.m.$  Na Figura 21d com a variação de Staff destaca-se que em busca de maior opção de comandos para serem evocadas nas regras utilizou-se uma função de pertinência a mais.

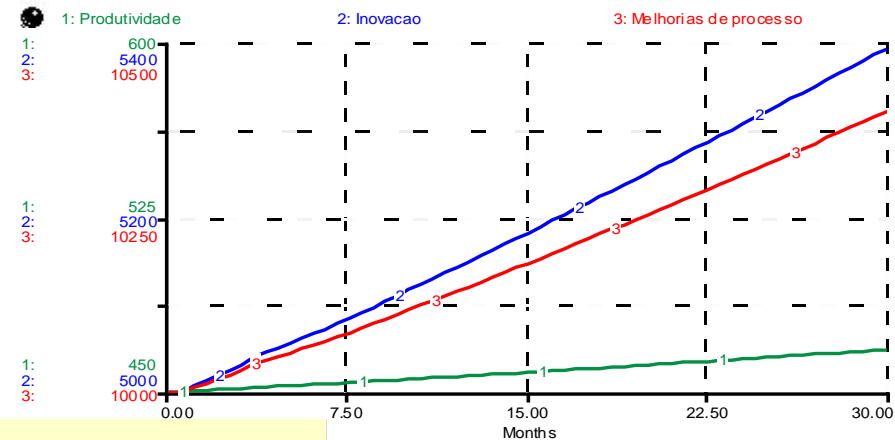
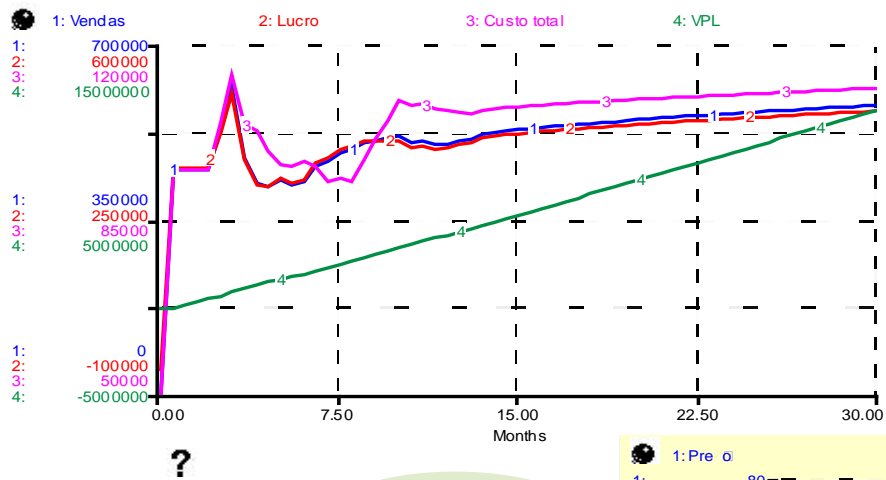
### 5.3.3 Regras lógicas

IF	Utilização de Capacidade IS	AND	Delta Vendas IS	THEN	Delta Preço IS	Delta Staff IS
1	Baixa		Positiva		Mantém	Reduz
2	Baixa		Nula		Reduz	Reduz
3	Baixa		Negativa		Reduz	Reduz
4	Média		Positiva		Mantém	Reduz
5	Média		Nula		Mantém	Mantém
6	Média		Negativa		Reduz	Mantém
7	Alta		Positiva		Aumenta	Aumenta
8	Alta		Nula		Aumenta	Aumenta
9	Alta		Negativa		Mantém	Aumenta Muito

As regras são auto-explicativas e pode-se perceber que tem duas reações bem definidas: a primeira é que quando a utilização estiver alta contrata-se e quando a utilização estiver baixa demite-se; a segunda é que os preços são usados para controlar a demanda e tentar com sua variação atingir patamares melhores de lucro.

***Resultados:***

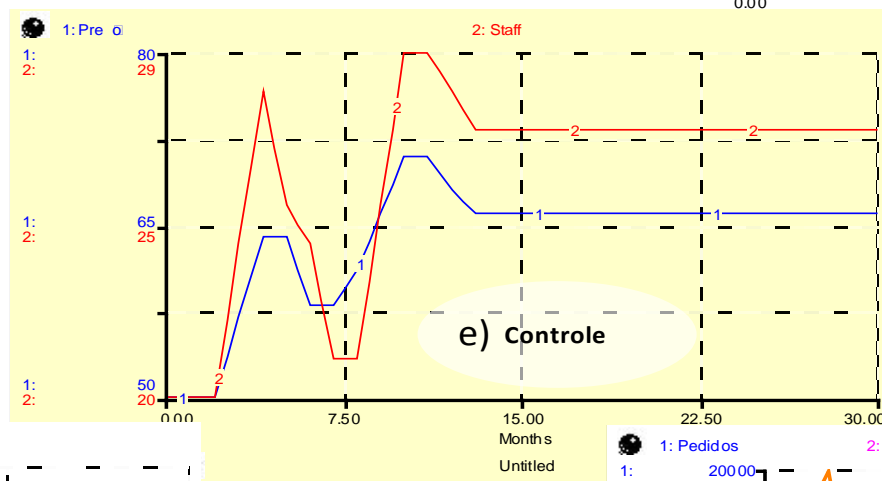
Os mesmos gráficos apresentados para o modelo sem controle são apresentados na Figura 22 a seguir com a adição de um gráfico que apresenta as decisões de controle tomadas pelo sistema fuzzy.



?

a) Financeiro

c) Consumidores



b) Aprendizado e Crescimento

d) Processos Internos

e) Controle


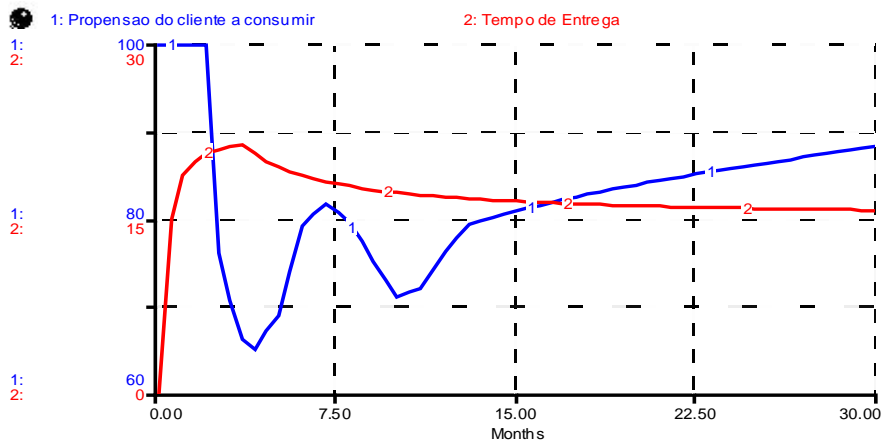


Figura 22 Resultados do Controlador 1

Fonte: Elaboração Própria

Como pode-se notar na Figura 22c a propensão a consumir tem uma queda inicial puxada pelo aumento de preços e depois retoma uma trajetória ascendente puxada por um tempo de entrega próximo do seu mínimo (15 dias, ou um intervalo de simulação) e pelo crescimento da inovação de produto.

Na Figura 22d nota-se que a utilização é mantida a em torno de 70% como era desejado e como consequência disso os estoques em processo mantêm-se em um nível mais baixo.

A dimensão de aprendizado e crescimento na Figura 22b apresenta a mesma trajetória ascendente por serem estoques que só crescem porém em maior ritmo (apesar da escala não possibilitar essa comparação).

Na Figura 22a com a dimensão financeira, nota-se que o custo total agora tem um comportamento dessincronizado do lucro e vendas porque muda-se a sua parcela fixa com as contratações e demissões. Além disso, nota-se que o lucro tem um comportamento crescente acompanhando o aumento da propensão a consumir e fixado o nível de preços acima do inicial. Para fins de comparação, o VPL desse modelo foi de  $1.132e+007$  unidades monetárias (apesar da escala não permitir essa leitura), resultado bem superior ao do modelo sem controle (apresentado na análise de sensibilidade).

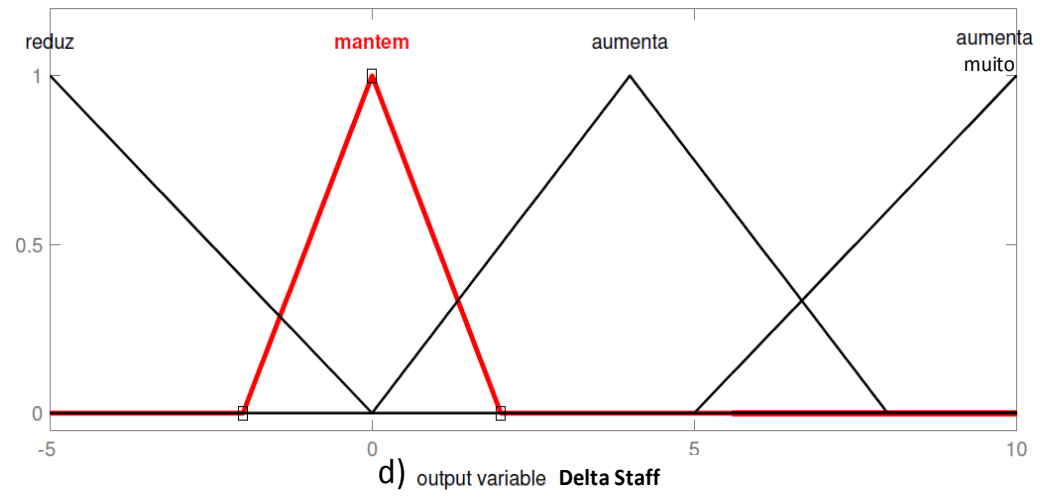
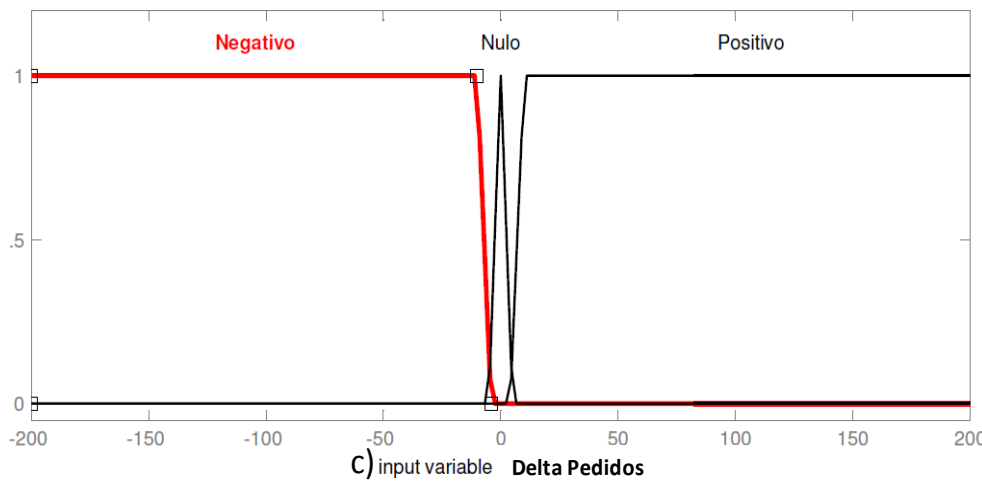
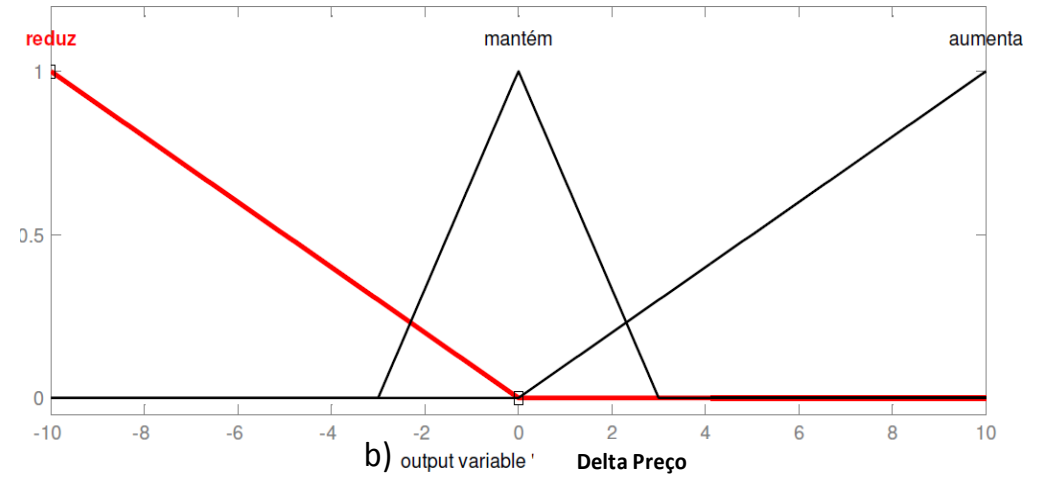

Finalmente a Figura 22e registra os comandos de controle. É interessante notar que após a metade da simulação o controle se estabilizou mantendo o preço no valor de 66 e o staff em 27 pessoas.

### **4.3 Controlador 2**

Outro conjunto de política que poderia ser pensado é usando o “tempo de entrega” e a variação nos pedidos (“delta pedidos”) como indicadores para controle. Usando o tempo de entrega para aferir a qualidade do serviço e o delta pedidos para ver como mudanças no preço e inovação (e tempo de entrega que estará explicitamente monitorado) estão afetando a demanda pelo produto.

As pertinências decididas para inputs e outputs e seu envolvimento em regras são apresentadas na Figura 23 a seguir.





**Figura 23** Pertinências do Controlador 2

Fonte: Elaboração Própria

IF	Tempo de Espera IS	AND	Delta Pedidos IS	THEN	Delta Preço IS	Delta Staff IS
1	Baixo		Positiva		Reduz	Mantém
2	Baixo		Nula		Aumenta	Reduz
3	Baixo		Negativa		Aumenta	Reduz
4	Médio		Positiva		Aumenta	Aumenta
5	Médio		Nula		Mantém	Aumenta
6	Médio		Negativa		Reduz	Aumenta
7	Alto		Positiva		Aumenta	Aumenta Muito
8	Alto		Nula		Aumenta	Aumenta Muito
9	Alto		Negativa		Mantém	Aumenta Muita

Pode-se notar na Figura 23a que as pertinências do tempo de espera seguiram a formulação da propensão do consumidor e foram consideradas médias em torno de 17 dias. Valores inferiores a partir de 16,5 dias são considerados baixos e são buscados nas regras (aumentando staff quando está alta e média a utilização) para atrair os consumidores.

O delta pedidos na Figura 23c tem função de pertinência idêntica ao delta vendas do controlador anterior pois é igualmente normalizada. As pertinências dos outputs (delta preço e staff) são mantidas inalteradas).

Como pode-se perceber nas regras a busca é por reduzir o tempo de entrega até o nível baixo quando varia-se preço e staff em busca de uma combinação que melhore as vendas.

Os resultados desse controlador são apresentados na Figura 24 na sequência no qual se omitiu a dimensão de aprendizado e crescimento que visualmente teria comportamento idêntico aos dos casos anteriores por motivos já mencionados.







Figura 24 Resultados do Controlador 2

Fonte: Elaboração Própria

Pode-se perceber que a mudança nos indicadores e nos pressupostos de controle (embutidos nas regras) fizeram o controle ser bem distinto. Como mostra a Figura 24b inicialmente o staff foi acrescido de forma exagerada, o que, por um lado, elevou os custos excessivamente e por outro deixou o tempo de entrega em ótimo patamar. A mesma figura mostra que os preços desde o início cresceram dado o tempo de entrega inicialmente alto e a tentativa de controlar a demanda chegando a um patamar muito superior ao do caso anterior. A Figura 24c mostra que o resultado desse crescimento de preços é crítico sobre a propensão marginal a consumir que cai bruscamente (também porque a inovação não foi capaz de conter essa redução da demanda).

A Figura 24d mostra que essa perda da demanda deixa muita ociosidade na produção (conseqüência também das excessivas contratações) e os estoques em processo atingem baixíssimos patamares.

Na perspectiva financeira da Figura 24a nota-se que o crescimento dos custos acaba afetando os lucros mesmo com o crescimento da margem (elevação dos preços) e só passa a melhorar quando o controlador passa a demitir intensamente, reduzindo os custos fixos. O resultado óbvio é que seu VPL registrou pior desempenho com o valor de  $8.581e+006$ .

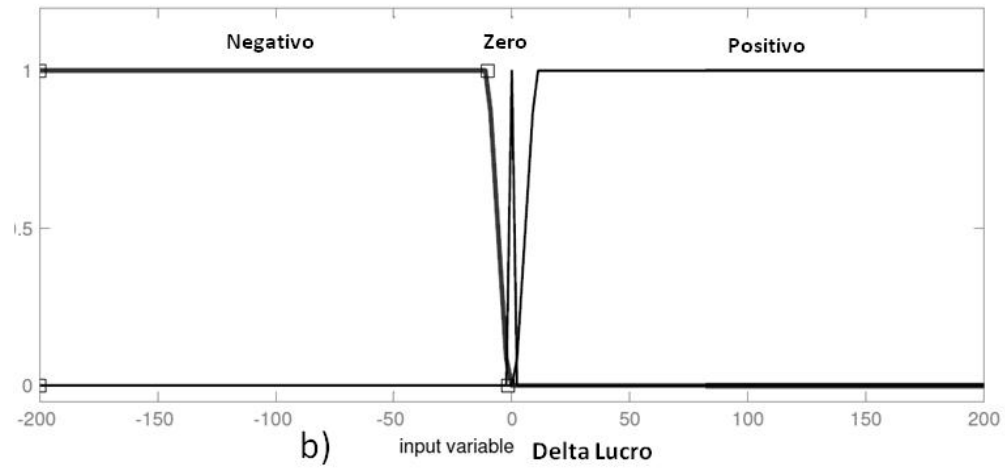

Esse resultado faz parecer que a opção de aumentar preços e melhorar a qualidade da entrega é um extremo que não parece ser ideal. De fato, se compararmos meramente os indicadores deste controlador com os do anterior percebe-se que os dois desse segundo controlador são mais míopes, no sentido que fornecem menos informações, ambos mais voltados para aspectos da demanda simplesmente (sem dar informações financeiras).

#### **4.4 Controlador 3**

Como último exemplo desejava-se mostrar um sistema fuzzy que adicionasse um grau de complexidade maior a sua estrutura. Propõe-se para esse exemplo o uso de três indicadores: variação do lucro (“delta lucro”), propensão do consumidor, tempo de entrega. O uso de 3 indicadores permite a criação de regras mais robustas, que podem ser “chaveadas” para situações mais específicas.

Ressalta-se que não necessariamente todos os parâmetros devem ser envolvidos em todas as regras (aliás, dificilmente esta combinatória fará sentido). Entretanto, de experiência própria, o desafio de criar um sistema de regras cresce com o aumento das variáveis, especialmente se realizado de forma totalmente experimental.

A Figura 25 abaixo mostra a pertinência para os novos elementos desse modelo e as regras construídas .



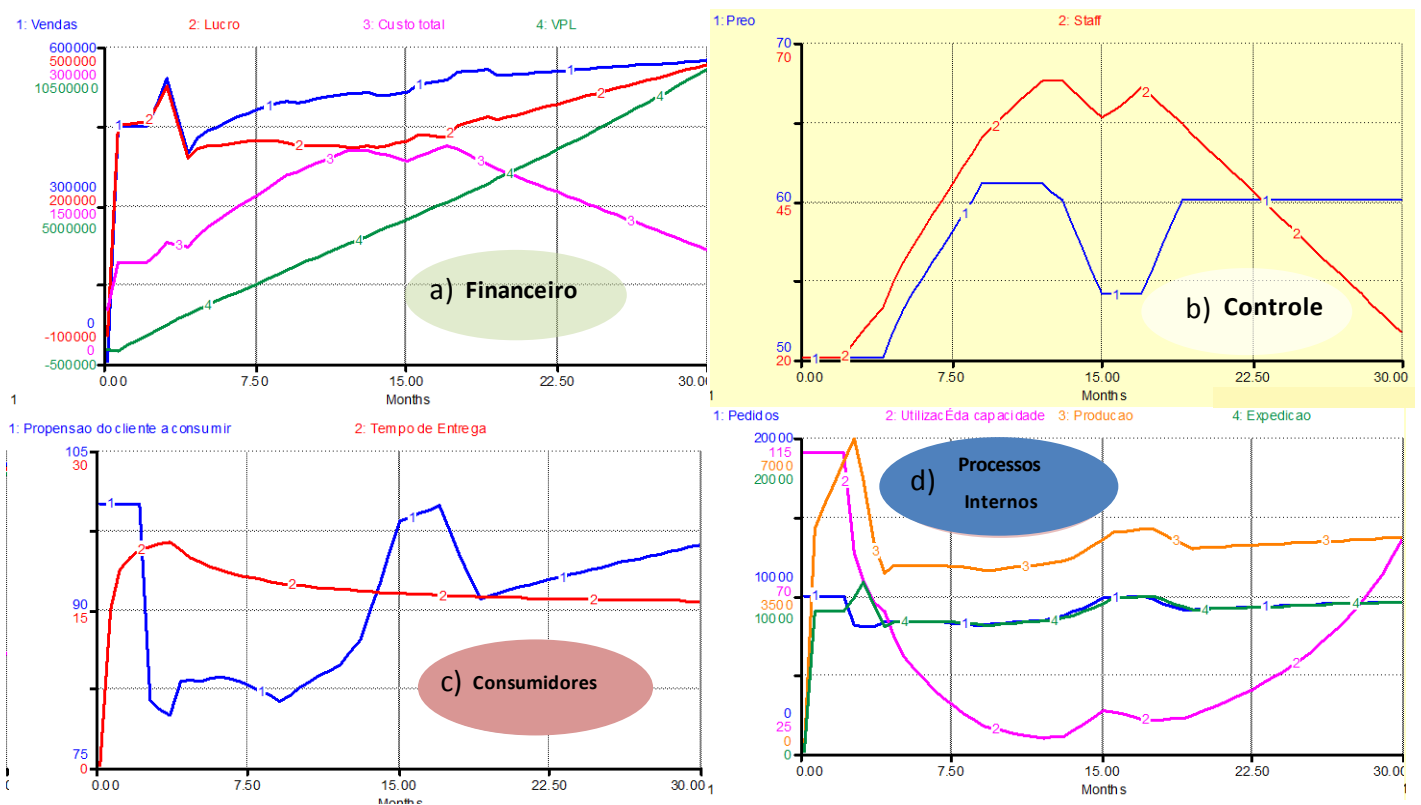
IF	Delta Lucro IS	AND	Propensão do Consumidor IS	AND	Tempo de Espera IS	THE N	Delta Preço IS	Delta Staff IS
1			Baixa		Alto		Aumenta	Aumenta Muito
2			Baixa		NOT Alto		Reduz	Reduz
3	Negativo		Baixa		Médio		Reduz	Mantém
4			Média		Alto		Mantém	Aumenta
5	Positivo		Média		Baixo		Mantém	Reduz
6	Zero		Média		Baixo		Aumenta	Reduz
7	Negativo		Média		Baixo		Reduz	Reduz
8			Alta		Baixo		Aumenta	Reduz
9			Alta		Alto		Aumenta	Aumenta muito
10			Alta		Médio		Mantém	Aumenta
11	Negativo		Alta		Baixo		Aumenta	Reduz
12	Zero		Alta		Baixo		Aumenta	Reduz
13	Positivo		Alta		Baixo		Mantém	Reduz

**Figura 25 Estrutura do Controlador 3**  
**Fonte: Elaboração Própria**

Como pode-se notar na Figura 25a a propensão a consumir foi considerada média entre 80 e 120 (em torno do inicial 100). Como o objetivo é o lucro as regras não encaminharam diretamente para a propensão alta, tentando buscar o nível de demanda equilibrado com preço que atinja melhor resultado. A Figura 25b mostra as pertinências de Delta Lucro idêntica aos outros delta já citados.

As regras mostram o mencionado chaveamento e operam de maneira quase igual ao do controlador 2, só modificando-se quando alguma das condições do terceiro indicador são acionadas.

O resultado desse controlador é apresentado na Figura 26 na sequência.



**Figura 26 Resultados do Controlador 3**

Fonte: Elaboração Própria

Na Figura 26c pode-se perceber um comportamento logo no início da simulação muito parecido com do controlador 2, explicado por um início do controle (na Figura 26b) também muito parecido. O grande diferencial do chaveamento é que a partir desse

ponto foi evitado a escalada de preços dessa forma recuperando a propensão a consumir que se manteve no patamar mais alto dos modelos anteriores e em franca ascensão.

Como pode se verificar na Figura 26a o grande problema desse controle foi o exagero de contratações no início que explodiu os custos e corroeu o lucro. Pela Figura 26b nota-se que depois da metade passou-se a demitir-se quase voltando ao patamar inicial com a diferença de ter uma propensão muito melhor (pois o preço equilibrou a demanda junto com a atratividade das inovações).

Esse problema do controle pode ser verificado também pela Figura 26d que mostra que a utilização chega a níveis baixíssimos, com muita ociosidade. O controle tem um final consideravelmente melhor que seus antecessores, mas devido a seu começo pior apresenta VPL baixo ( $9.76e+006$ )<sup>22</sup>.

---

<sup>22</sup> Se a comparação fosse pela condição ao final do período e sua tendência esse controlador teria o melhor resultado. O que não acontece com o VPL que prioriza fluxos de caixa iniciais.



## 4.5 Discussão dos Resultados da Integração

O objetivo desse tópico é analisar o desempenho da metodologia e não dos controladores, já apresentado nos tópicos anteriores. Como mencionado o estudo de caso foi usado como um plano de fundo para aplicar a metodologia e a maior discussão desse trabalho deve ser sobre a viabilidade da metodologia proposta.

Primeiramente, devemos destacar quais foram as dificuldades encontradas ao longo da aplicação. A apresentação anterior não é capaz de ilustrar as muitas idas e vindas, para estabelecimento do modelo de DS e das políticas, características do “ciclo” de resolução de problema.

Nesse percurso as maiores dificuldades verificadas foram principalmente a calibração do modelo e propostas de políticas. Ambas frequentes na utilização de dinâmica de sistemas independentemente da metodologia proposta nesse trabalho. No estudo de caso específico, esses desafios foram aumentados pela não-realidade do problema que obrigou a criação de um modelo hipotético cujo comportamento era desconhecido a priori.

Em relação aos objetivos para os quais foi proposta a metodologia pode-se notar que a separação dos sistemas controlado (DS) e controlador (fuzzy):

- Não acrescentou maiores complicações ao método de DS (mantendo-o acessível ao decisor e sua equipe), pois a sequência pode ser mantida e os softwares utilizados apresentavam interface e ferramental intuitivo e adequado para sua operação<sup>23</sup>;
- Favoreceu a utilização do método científico, na medida em que conferiu maior disciplina na declaração das hipóteses, uma obrigação para formatar os controladores fuzzy.
- Aumentou a rastreabilidade e comunicabilidade das hipóteses políticas e seus resultados, pois o controlador fuzzy passava a ser separadamente declarado e armazenado, usando pertinências e regras que reproduziam o raciocínio aproximado humano. Prova disso é o relatório apresentado nesse trabalho que mostra a facilidade de registro das políticas

---

<sup>23</sup> Na realidade para utilização prática de forma mais ampla, acredito ser necessário algumas das soluções de implementação computacional automatizadas citadas no apêndice 2.

Apesar do atingimento dos objetivos propostos pode ser percebido que alguns fatores são capazes de potencializar a aplicação da metodologia, dentre os quais:

- Participação intensa da equipe para proposta e discussão de políticas, especialmente se existirem especialistas na situação problema que já tenham suas próprias heurísticas ou hipóteses de políticas. A participação é uma necessidade para a formulação dos modelos de DS e a adição de fuzzy só reforça essa exigência;
- Conhecimento prévio do sistema (e problema) modelado: se forem casos reais provavelmente já existe algum conhecimento prévio que acelera o aprendizado via experimentação.
- Eventual combinação com técnicas para calibração de modelo e avaliação sistemática de políticas pode reduzir os esforços manuais e acelerar o aprendizado e como se operam apenas nas etapas de dinâmica de sistemas da metodologia, não tem interferência da parte fuzzy proposta.

## 5 Conclusão

Verificou-se que apesar da simplicidade do estudo de caso a viabilidade da metodologia proposta pôde ser atestada e os objetivos da integração atingidos. Por tudo que foi argumentado mostrou-se que lógica fuzzy é um ferramental mais apropriado para expressar políticas de maneira mais fiel à forma como pensamos, em linguagem natural, e perfeitamente complementar a modelagem de dinâmica de sistemas. A proposta de separação do sistema de controle fuzzy não trouxe consideráveis alterações ao método tradicional de STERMAN (2000) para resolução de problemas com dinâmica de sistemas permitindo adaptá-lo facilmente na metodologia de resolução de problemas Fuzzy-DS.

A metodologia ao obrigar o modelador a declarar explicitamente suas hipóteses e modelos mentais de políticas afasta problemas regulares da implantação de mundos virtuais como: síndrome do vídeo-game; carência de método científico; dificuldades de discussão e comunicação a nível de equipe das políticas e seus resultados.

Em termos práticos, a separação não torna mais complexa a implementação, pois a interface do Matlab® é extremamente amigável ao usuário tal como a interface do software de dinâmica de sistemas, no caso o STELLA v9. Esse era um fator extremamente necessário para manter a modelagem do problema acessível ao usuário e não intimidá-lo a aprender.

Entretanto, a metodologia não é capaz de superar sozinha todos os obstáculos para resolver problemas usando dinâmica de sistemas, podendo ser complementada (sem interferências) por outros métodos específicos de calibração e seleção de políticas<sup>25</sup>.

Como foi argumentado ao longo do trabalho para aplicações de controle, fuzzy não é solução para todo tipo de política e problema em modelos de dinâmica de sistemas, devendo ser avaliada sua eficácia. Destacou-se que, a princípio, lógica fuzzy deve ser usada apenas nos casos em que seja aplicável e adequada conceitualmente, isto é, para políticas que sejam declaradas em linguagem natural e com variáveis naturalmente fuzzy.

---

<sup>25</sup> Como os citados ao longo do trabalho.

Devendo evitar aplicá-la cegamente aos diversos casos práticos em que isso não é a realidade, como em controles otimizantes, em sistemas de controle de engenharia, onde a precisão é uma exigência, ou ainda para regras que não sejam no formato SE-ENTÃO (gráficas, por exemplo).

De qualquer forma para o aprendizado organizacional, a finalidade desse trabalho, o uso de sistemas fuzzy para declarar políticas mostra-se sempre adequado para explicitar nosso raciocínio em linguagem natural e permite afastar algumas das dificuldades freqüentes no uso de mundos virtuais.

Finalmente, acredito essa proposta abra diversas oportunidades para testar a metodologia em outros modelos mais complexos e realistas, envolvendo maiores equipes nas discussões. Provavelmente em modelos mais complexos serão inviáveis as práticas de teste exaustivo e de análise de cenários, havendo a necessidade de integração com métodos sistemáticos de avaliação de políticas, como os citados ao longo do trabalho, capazes de auxiliar a concepção de políticas. Como mencionado, outra oportunidade de adição é com métodos de calibração de modelos, reduzindo igualmente o esforço de experimentação. Ressalta-se que o risco dessas integrações e aplicação a modelos mais complexos é de perder-se a simplicidade necessária ao envolvimento do usuário. A análise desse risco nesses contextos mostra-se um interessante campo para novos estudos.

## REFERÊNCIAS BIBLIOGRÁFICAS

BOURGUET, R.E. SOTO, R. **Qualitative knowledge acquisition using fuzzy logic and system dynamics.** Proceedings of 20<sup>th</sup> International Conference of the System Dynamics Society, paper 106. 2002.

BRANS, J.P., MACHARIS, C., KUNSCH, P.L., CHEVALIER, A., SCHWANINGER, M. **Combining multicriteria decision aid and system dynamics for the control of socio-economic processes. An iterative real-time procedure.** European Journal of Operational Research 109 (2), 428–441. 1998

BRANS, J.P., KUNSCH, P.L., MARESCHAL, B., **Management of the Future. A system dynamics and MCDA approach.** Special Volume Dedicated to Professor Bernard Roy. Kluwer Academic Publishers, pp. 483–502. 2002.

CAMPUZANO, F. MULA, J. PEIDRO, D. **Fuzzy estimations and system dynamics for improving supply chains.** Fuzzy Sets and System, vol. 161, pp. 1530-1542. 2010.

COYLE, R.G. **Management System Dynamics.** Wiley, 1977.

DIMITROVSKI, A. FORD, A. TOMSOVIC, K. **An interdisciplinary approach to long-term modeling for power system expansion.** International Journal of Critical Infrastructures, vol. 3 (1/2), pp. 235-264. 2007.

FERNANDES, A. C. **Scorecard dinâmico – em direção à integração da dinâmica de sistemas com o balance scorecard.** Tese de Doutorado. COPPE/UFRJ, 2003.

FORRESTER, J.W. **Industrial dynamics: a major breakthrough for decision makers.** Harvard Business Review, vol. 36(4), pp. 37-66. 1958.

FORRESTER, J.W., **Industrial Dynamics,** MIT Press, 1961.

FORRESTER, J.W., **Principles of Systems,** Wright Allen Press, 1968.

GARY, M. S. KUNC, M. MORECROFT, J. D. W. ROCKART, S. F. **System dynamics and strategy.** System Dynamics Review, vol. 24, pp. 407-429. 2008.

GHAZANFARI, M. JAFARI, M. ALIZADEH, S. **An approach to solve fuzzy system dynamics problems.** Proceedings of 20<sup>th</sup> International Conference of the System Dynamics Society , paper 240. 2003.

GHEMAWAT, P. CASSIMAN, B. **Introduction to the special issue on strategic dynamics.** Management Science, vol. 53(4), pp. 529 .2007.

JOHNSON, P. VEAZIE, P. DUTTA, P. **Physician decisions as a source of variation in chronic disease outcomes.** Proceedings of 20<sup>th</sup> International Conference of the System Dynamics Society, paper 106. 2000.

KARAVEZYRIS, V. TIMPE, K. MARZI, R. **Application of system dynamics and fuzzy logic to forecasting of municipal solid waste.** Mathematics and Computers and Simulation, vol. 60, pp. 149-158. 2002.

KHANZADI, M. NASIRZADEH, F. ALIPOUR, M. **Integrating system dynamics and fuzzy logic modeling to determine concession period in BOT projects.** Automation in Construction, vol. 22, pp. 368-376. 2012.

KLEIJNEN, J.P.C. **Sensitivity analysis and optimization of system dynamics models: Regression analysis and statistical design of experiments.** System Dynamics Review, vol. 11 (4), pp. 275–288. 1995.

KOHOUT, L.J. ANDERSON, J. BANDLER, W. BEHROOZ, A. GAO, S. TRAYNER, C. **Activity structure based architectures for knowledge-based systems, Part1: Dynamics of localized fuzzy inference and its interaction with planning.** Fuzzy Sets and Systems, vol. 44, pp. 405-420. 1991.

KUNSCH, P. SPRINGAEL, J. **Simulation with system dynamics and fuzzy reasoning of a tax policy to reduce CO2 emissions in the residential sector.** European Journal of Operational Research, vol. 185 (3), pp. 1285-1299. 2008.

KUNSCH, P.L., SPRINGAEL, J., BRANS, J.P. **An adaptive control methodology based on system dynamics and MCDA case study: The CO2 energy tax in the residential sector.** Aide Multi Critère à la Décision/Multiple Criteria Decision Aiding, Report of the Commission of the European Communities, Joint Research Centre JRC-ISPRA, EUR - report 19808 EN, pp. 145–162. 2001

LAKATOS, E. M. MARCONI, M. A. **Metodologia do Trabalho Científico**, 4<sup>a</sup> Edição, Atlas, 1992.

LIU, S. TRIANTIS, K. P. SARANGI, S. **Representing Qualitative Variables and their interactions with fuzzy logic in system dynamics modeling**. Research Paper. System Research and Behavioral Science, vol. 28, pp. 245-263. 2011.

MAMDANI, E. ASSILIAN, S. **An experiment in linguistic synthesis with a fuzzy logic controller**. International Journal of Man-Machines Studies, vol. 7, pp. 1-13. 1975.

MAMDANI, E. H. **Advances in linguistic synthesis of fuzzy controllers**. International Journal of Man-Machines Studies, vol. 8, pp. 669-678. 1976.

MATHWORKS. **Fuzzy Logic Toolbox: User's Guide**. 2012.

MORECROFT, J.D.W. **Strategic Modelling and Business Dynamics: A Feedback System Approach**. John Wiley E Sons, 2007.

MORECROFT, J.D.W. **System Dynamics and microworlds for policymakers** European Journal of Operational Research, vol. 35, pp. 301-320. 1988.

NASIRZADEH, F. KHANZADI, M. RAZAIE. **Dynamic modeling of quantitative risk allocation in construction projects**. International Journal of Project Management, <http://dx.doi.org/10.1016/j.ijproman.2013.06.002>. 2013.

OLIVA, R. **Model calibration as a testing strategy for system dynamics models**. European Journal of Operational Research, vol. 151, pp. 552-568. 2003.

PANKAJ. SETH, K. SUSHIL. **A fuzzy set theoretic approach to qualitative analysis of causal loops system dynamics**. European Journal of Operational Research, vol. 78 (3), pp. 380-393. 1994.

PAPERT, S. **Mindstorms**. Basic Books, 1980.

POLAT, S. BOZDAĞ , C.E. **Comparison of fuzzy and crisp system via system dynamics simulation**. European Journal of Operation Research, vol. 138, pp. 178-190. 2002.

PORTER, M. E. **Towards a dynamic theory of strategy.** Strategic Management Journal, vol. 12, pp. 95–117. 1991.

RICHARSON, G. P. **Reflections on the foundations of system dynamics.** System Dynamics Review, vol. 27(3), pp. 219-243. 2011.

ROSS, T. J. **Fuzzy logic with engineering applications.** Second Edition. John Wiley E Sons, 2004.

SALEH, M. OLIVA, R. KAMPMANN, C. E. DAVIDSEN, P. I. **A comprehensive analytical approach for policy analysis of system dynamics models.** European Journal of Operational Research, vol. 203, pp. 673-683. 2010.

SOUSA-POZA, A. CORREA, Y. C. BEDOYA, L. **First approach to model satisfaction at work under equity theory using fuzzy set theory and system dynamics.** Proceedings of 20<sup>th</sup> International Conference of the System Dynamics Society, paper 272. 2003.

STERMAN, J. D. **Business Dynamics: System Thinking and Modeling for a Complex World.** Irwin MacGraw-Hill, 2000.

SUGENO, M. KANG, G. **Structure identification of fuzzy model.** Fuzzy Sets Systems, vol. 28, pp. 15-33. 1988.

TAKAGI, T. SUGENO, M. **Fuzzy identification of systems and its applications to modeling and control.** IEEE Transactions on Systems, Man and Cybernetics, vol. 15, pp. 116-132. 1985.

WU, Z. XU, J. **Predicting and optimization of energy consumption using system dynamics-fuzzy multiple objective programming in world heritage areas.** Energy, vol. 49, pp. 19-31. 2013.

XU, J. LI, X. **Using system dynamics for simulation and optimization of one coal industry system under fuzzy environment.** Expert Systems with Applications, vol. 38, pp. 11552-11559. 2011.

ZADEH, L. **A fuzzy-set-theoretic interpretation of linguistic hedges.** Journal of Cybernetics, vol. 2, pp. 4-34. 1972.



ZADEH, L. **A theory of approximate reasoning.** in J. Hayes, D. Michie, and L. Mikulich (eds.) Machine Intelligence, pp. 149-194. 1979.

ZADEH, L. **The concept of a linguistic variable and its application to approximate reasoning – I.** Information Science, vol. 8, pp. 199-249. 1975.

ZADEH, L. **The concept of a linguistic variable and its application to approximate reasoning – II.** Information Science, vol. 8, pp. 301-357. 1975.

## APÊNDICE 1: A toolbox de Lógica Fuzzy no Matlab

Figura 26 abaixo apresenta as interfaces da toolbox de sistemas Mamdani do Matlab®. As três janelas superiores são utilizadas para parametrização do sistema, as inferiores são apenas para observação dos resultados da parametrização do sistema fuzzy.

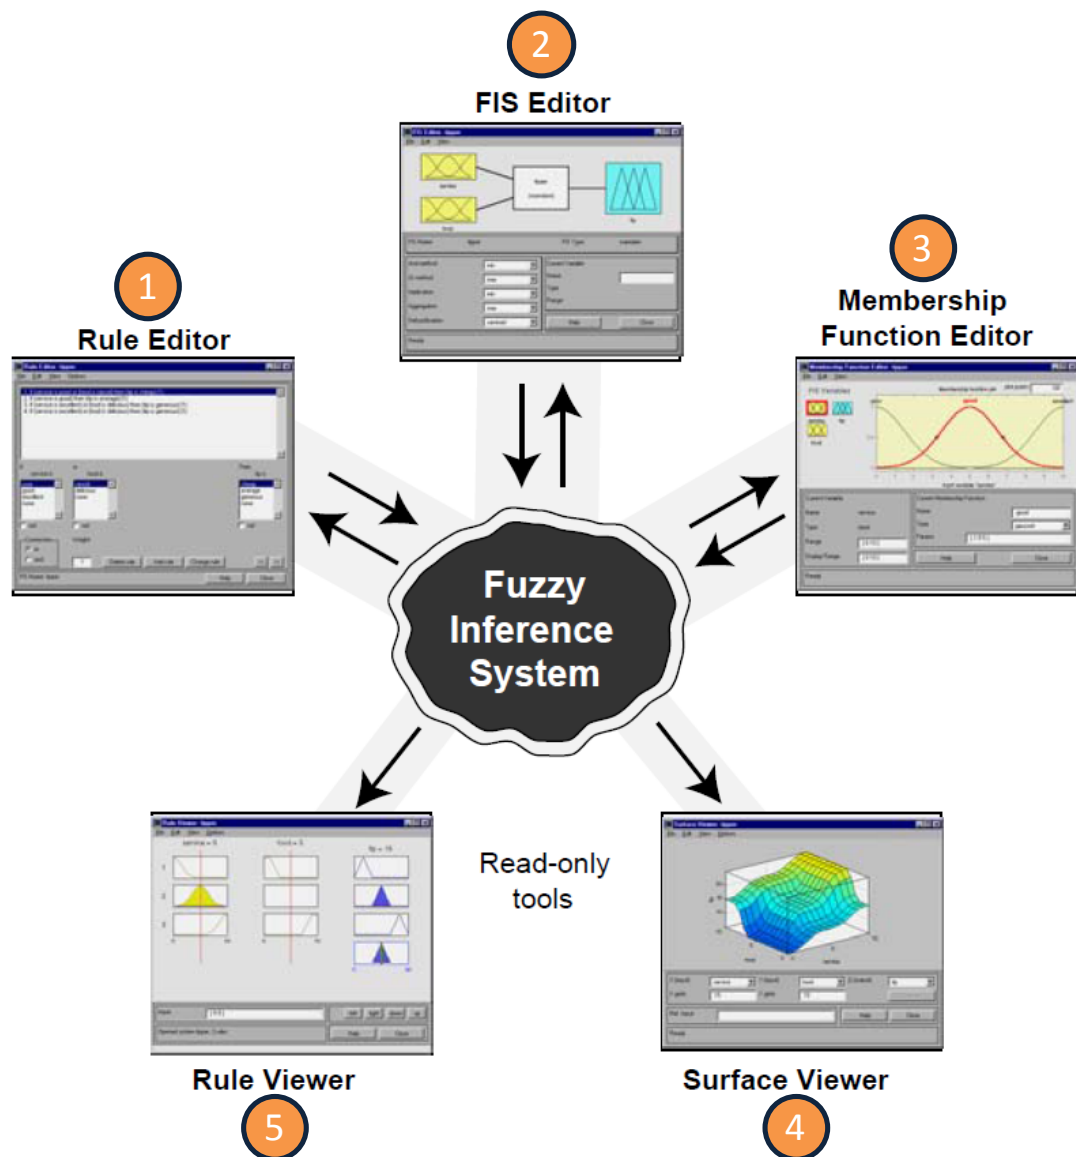


Figura 27 Telas do toolbox de sistemas fuzzy do Matlab®

Fonte: Mathworks

A janela 1 é utilizada para definir as regras, permite selecionar e relacionar as pertinências dos inputs e outputs (ou sua negações), fazer conexões com conectivos lógicos (E/OU) e definir pesos para cada regra.

A janela 2 exibe a estrutura do sistema fuzzy (suas entradas e saídas) e permite configurar todos os métodos de cálculo lógico, implicação, agregação e defuzzificação.

A janela 3 é usada para definir as diversas pertinências para os inputs e outputs. Apresenta enorme variedade funções de pertinência, sendo as mais comuns, triangulares, trapezoidais e gaussiana, que devem ser parametrizadas pelo usuário preenchendo todo o domínio possível das variáveis.

A janela 4 permite visualização espacial das regras de decisão. Obviamente está limitada a 3 dimensões exigindo que o usuário selecione três das variáveis se o modelador tiver maior dimensão.

Finalmente, a janela 5 permite visualização gráfica das regras e do processo de inferência (representação é idêntica a da revisão teórica sobre fuzzy). Particularmente recomendo operar cálculos nessa janela para aqueles menos habituados com a linha de comandos.

Poderia detalhar melhor cada janela e suas possibilidades de configuração, mas o software é muito intuitivo e não acredito haver necessidade de me prolongar nessas explicações.

## **APÊNDICE 2: As alternativas computacionais de integração entre fuzzy e dinâmica de sistemas**

Buscando na literatura e principalmente em fóruns especializados na internet foi possível identificar diferentes alternativas utilizadas para integrar softwares de modelagem de DS e sistemas fuzzy.

Encontrei quatro opções para integrar essas duas práticas:

1. Integração de variáveis fuzzy e inferência a modelos de DS no ambiente do Vensim
2. Com o Vensim usar sua comunicação DLL para integrar-se a outros softwares.
3. Com o Stella/Ithink adquirir o isee.NET Framework e programar em .NET.
4. Usar a comunicação persistente e dinâmica do Stella com planilhas.

### ***Integração de variáveis fuzzy e inferência a modelos de DS no ambiente do Vensim***

SHIYONG *et al* (2011) apresentam um método para incorporar variáveis lingüísticas (soft) a um modelo de DS no VENSIM Simulation Environment. Uma forma parecida de fazê-lo no mesmo ambiente é através de *look up tables*<sup>26</sup>, como foi realizado por KUNSCH E SPRINGAEL (2008), apesar desse estudo não acionar as variáveis lingüísticas endógenamente (isto quer dizer elas não se relacionavam ao modelo).

Segundo os autores, trabalhos anteriores como os de BOURGUET E SOTO (2002), JOHNSON *et al* (2000), GHAZANFARI *et al* (2003) e SOUSA-POZA *et al* (2003) sugeriam aplicação de conceitos fuzzy em modelos de DS mas sem especificar como implementar esses conceitos. A contribuição do trabalho era, portanto, um método para implementar essa integração no VENSIM, usando subscripts para criar as variáveis fuzzy (equivalente a array no Stella/Ithink).

O artigo é uma boa referência para aquele que desejar fazê-las, contudo o ferramental do VENSIM é limitado para a implementação de sistemas fuzzy, o que obrigou os autores a usarem para defuzzificação o método “maior dos máximos”. A

---

<sup>26</sup> <http://www.sdl.ise.vt.edu/Tutorial/table-functions-tutorial.pdf>

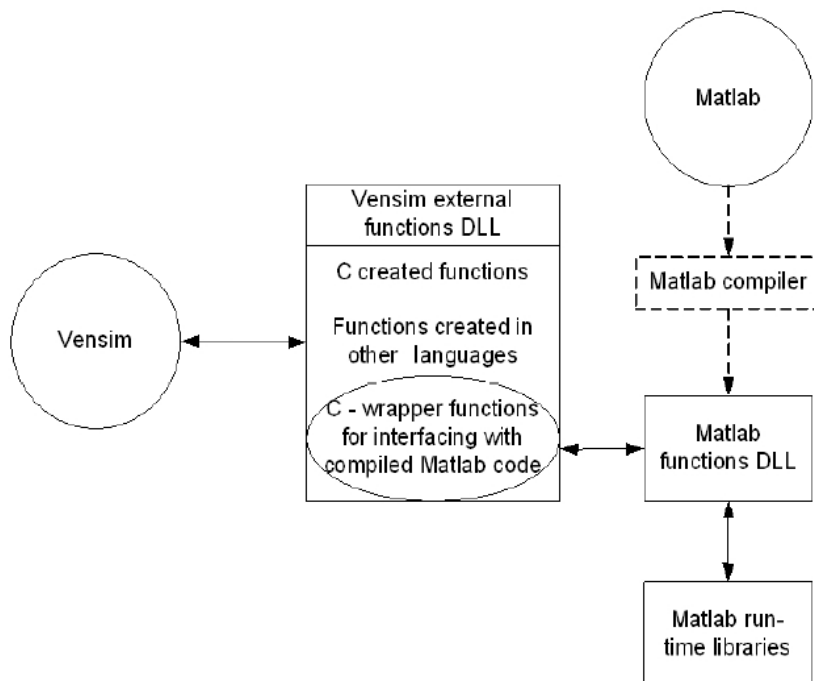
incapacidade de operar integrações sem ser no tempo impossibilita métodos mais recomendados para defuzzificação com o do centróide.

Além disso, o modelo resultante acabou ficando excessivamente complexo e poluído, pois a não adequação da ferramenta a esses constructos exigiu diversos “jeitinhos”.

### *Usar a comunicação DLL do Vensim*

Essa é a alternativa mais utilizada na literatura para integrar softwares de engenharia a modelos de DS. De fato, dos programas de DS o Vensim é o mais completo e que apresenta mais robusto ferramental, como opções de otimização.

DIMIREOVSKI *et al* (2007) utiliza modelos de engenharia (no qual as relações matemáticas são explicitamente designadas) associados a modelos de DS (no qual relações não rigorosas podem ser definidas de maneira gráfica e intuitiva) implementando uma integração entre o Matlab e o Vensim. Apesar de não ser para o mesmo uso a integração entre os softwares é idêntica. A Figura 27 abaixo mostra como essa integração se opera:



**Figura 28 Integração por DLL do Vensim ao Matlab**

**Fonte: DIMITROVSKI (2007)**

DLL são pacotes de função (realizados por outros aplicativos) que podem ser chamados durante determinadas aplicação. Tanto o Matlab quanto o Vensim tem capacidade de gerar e chamar DLLs o que torna a integração muito fácil e totalmente automática.

Infelizmente o Vensim é um software pago e sua versão para estudantes é extremamente simplificada, não dispondo essa funcionalidade. Impossibilitando seu uso nesse trabalho.

### ***Usar o isee.NET Framework com Stella/Ithink***

Essa implementação é análoga à opção anterior com o Vensim. São poucos os relatos práticos dessa aplicação (a maioria no site da própria empresa), que acredito decorrer de sua menor praticidade.

Como no caso anterior esse software não tem versão gratuita e sua utilização mostra-se inviável nesse contexto.

### ***Comunicação persistente e dinâmica do Stella com planilhas Excel***

Essa alternativa é a mais simplificada e computacionalmente exigente das anteriores. O STELLA v9 permite criar links de importação e exportação permanentes com planilhas Excel, que se marcados como persistentes e dinâmicos a cada início de simulação são atualizadas (ou atualizam).

Essa era a única alternativa a meu alcance pela falta de acesso as duas opções anteriores (e já descartando a alternativa anterior que simplificava excessivamente a inferência fuzzy e tornava o modelo extremamente congestionado). Esperava que apesar do maior esforço de processamento que fosse ser satisfatória. Entretanto a propaganda do fornecedor acabou me ludibriando e a funcionalidade de comunicação dinâmica e persistente não era tão potente como parecia ser.

Acontece que mesmo que dinâmica a importação de dados só é realizada ao início da simulação, o que se adéqua a minha necessidade de a cada intervalo de simulação definir outputs de controle.

Sem outra alternativa possível e não querendo usar a simplificação do primeiro caso fui obrigado a decidir por uma via de semi-automação que tornou meu esforço muito superior ao que projetava no início. A exportação de dados dinâmica funcionava a cada intervalo de simulação e gravava na planilha os resultados a cada passo de simulação. O Matlab programado para tal pegava automaticamente esses dados e calculava o output utilizando o controlador fuzzy. Entretanto, esse output precisava ser fornecido manualmente ao STELLA a cada passo de simulação. A Figura 28 mostra como se realizou a troca de dados.



**Figura 29 Modelo de integração computacional usado na prática do estudo de caso**

**Fonte: Elaboração Própria**

O código usado no Matlab® para adquirir os dados da planilha Excel, executar o controlador fuzzy e retornar os outputs de comando é apresentado na Figura 29 abaixo.

```

1 -   clc
2 -   counter = 0;
3 -   controler = readfis('Controlador Fuzzy 7.fis')
4 -   while counter < 30
5 -       counter = counter + 1
6 -       sheet = xlsread('Exportador.xls','Plan1');
7 -       StaffUt = sheet(counter,2)
8 -       DeltaRev = sheet(counter,3)
9 -       display(evalfis([StaffUt DeltaRev], controler))
10 -      parada = counter+5;
11 -   end
12 -

```

**Figura 30 Código do Matlab utilizado no estudo de caso**

**Fonte: Elaboração Própria**