

## Resumo

O processo de tomada de decisão em ambientes semi-estruturados é complexo por envolver dimensões de natureza algumas vezes conflitantes, um intervalo de tempo exíguo para que uma opção seja escolhida e, geralmente, um grande número de opções a serem analisadas antes da decisão ser tomada. Os Sistemas de Apoio à Decisão (SADs) são capazes de prover informações e modelos de simulação aos tomadores de decisão, melhorando a qualidade das decisões tomadas. O presente trabalho propõe uma abordagem para incorporar técnicas de Computação Inteligente (CI) em SADs. Para tanto, será proposto um modelo abstrato para o processo de tomada de decisão, endereçando dois grandes desafios para a área: (i) a busca combinatorial em espaços de decisão complexos e (ii) a busca de condicionantes para a consecução de um resultado desejado. Neste trabalho também foram abordados aspectos práticos da modelagem do problema, e o desenvolvimento de uma solução que combine duas ou mais técnicas de CI de acordo com sua aplicação específica, o chamado Sistema de Decisão Inteligente Híbrido (SDIH). Foram realizados dois estudos de caso para ilustrar a aplicação da abordagem: (1) a seleção de lotes para colheita da cana-de-açúcar e o (2) estudo de linhas de tratamento para pacientes cardíacos. Os resultados experimentais mostraram que a aplicação combinada de técnicas de Computação Inteligente à problemas de decisão complexos permite: (i) obter informações realísticas sobre cenários futuros, (ii) explorar o espaço de decisão de forma eficiente, e (iii) fornecer um meio de analisar esses cenários de forma interativa, utilizando a experiência do tomador de decisão durante o processo decisório.

## **Abstract**

Decision making in semi-structured environments is a complex task, because there are conflicting objectives to tackle, a short time to select an option and usually, there is a large deal of options to be analyzed, prior to decision making. Decision Support Systems (DSS) are capable of providing decision makers with information and simulation models, improving the quality of decisions.

This work proposes a new approach: to use Intelligent Computing (IC) techniques with DSS. To attain this objective, an abstract model to decision making is proposed, addressing two challenges in this area: (i) combinatorial search in complex decision spaces and (ii) search for conditioning factors for a desired result.

In this work, practical issues were addressed about how to model the problem, and the development of a solution combining two or more IC techniques, according to each specific application.

Two case studies were performed to test this approach: (1) the selection of sugarcane plots for harvesting, and (2) the study of lines of treatment for patients with cardiac disease.

Experimental results shown that the combined application of IC techniques to complex decision problems, allows for: (i) obtaining realistic information about future scenarios, (ii) exploring the decision space effectively, and (iii) providing an interactive way to analyze scenarios, using the decision maker's experience during the decision process.

# Sumário

<b>Índice de Figuras</b>	<b>v</b>
<b>Índice de Tabelas e Equações</b>	<b>vi</b>
<b>Tabela de Siglas</b>	<b>vii</b>
<b>1 Introdução</b>	<b>9</b>
1.1 Motivação	9
1.2 Objetivos	10
1.3 Estrutura dos Capítulos	10
<b>2 Sistemas de Apoio à Decisão</b>	<b>12</b>
2.1 Processo de Tomada de Decisão	12
2.2 Sistemas de Apoio à Decisão	13
2.2.1 Componentes de um SAD	14
<b>3 Tópicos de Computação Inteligente</b>	<b>15</b>
3.1 Redes Neurais Artificiais	15
3.2 Algoritmos Genéticos	17
3.3 Lógica Difusa	18
<b>4 Modelo Abstrato para Tomada de Decisão</b>	<b>21</b>
4.1 Formalização do Processo de Tomada de Decisão	21
4.1.1 O Tomador de Decisão	22
4.1.2 O Espaço de Decisão	22
4.1.3 Categorização da Decisão	23
4.2 Buscas Combinatoriais em Espaços de Decisão Complexos	24
4.3 Busca de Condicionantes para um Resultado Desejado	28
<b>5 Ciclo de Desenvolvimento do Sistema de Decisão Inteligente Híbrido</b>	<b>31</b>
5.1 Definição e Partes Constituintes do SDIH	31
5.2 O Ciclo de Desenvolvimento	33
5.3 Detalhamento da Etapa de Implementação	35
5.3.1 Implementação do Módulo Preditivo	35
5.3.2 Implementação do Módulo Analítico	37
5.3.3 Implementação do Módulo Interativo	38
<b>6 Estudos de Caso</b>	<b>41</b>
6.1 Seleção de Lotes na Colheita da Cana-de-açúcar	41
6.1.1 Contextualização e Objetivo	41
6.1.2 Modelando o problema com a Solução Proposta	42
6.1.3 Experimentos	45
6.2 Investigação do Impacto de Decisões no Tratamento de Pacientes Cardíacos	47

	iv	
6.2.1	Contextualização e Objetivo	47
6.2.2	Modelando o problema com a Solução Proposta	48
6.2.3	Experimentos	51
<b>7</b>	<b>Conclusão</b>	<b>53</b>
7.1	Resumo da Contribuição	53
7.2	Discussão	54
7.3	Trabalhos Futuros	54

# Índice de Figuras

<b>Figura 1</b> - Encadeamento das etapas do Processo Decisório	13
<b>Figura 2</b> - Esquema de um SAD padrão adaptado de Turban [Turban95]	14
<b>Figura 3</b> - Representação do neurônio artificial, e seus elementos constituintes	16
<b>Figura 4</b> - Típico ciclo evolutivo para um Algoritmo Genético	17
<b>Figura 5</b> - Esquema de um Controlador Baseado em Lógica Difusa	19
<b>Figura 6</b> - Mapeamento de Variável de Entrada em Graus de Pertinência	20
<b>Figura 7</b> - Defuzzificação calculando o Centro de Massa do polígono, a partir dos graus de pertinência de saída.	20
<b>Figura 8</b> - Esquema ilustrando a hierarquia do Espaço de Decisão $D_p$ com suas decisões, e decomposição em componentes $c_j$ e atributos $a_j$	22
<b>Figura 9</b> - Caracterização do Espaço de Busca Combinatorial Complexo	25
<b>Figura 10</b> - Função com dois pontos onde a primeira derivada se nula. Ponto 1 é o ponto de máximo e Ponto 2 é o ponto de mínimo.	26
<b>Figura 11</b> - Espaço de Decisão ordenado por Nível de Agrupamento e Iteração da Busca	26
<b>Figura 12</b> – Modelo Preditivo e computação no sentido Direto e Inverso	28
<b>Figura 13</b> - Mapeamento não funcional entre Domínio e Imagem que caracteriza a impossibilidade de computação do Problema Inverso	28
<b>Figura 14</b> - Diagrama de Blocos ilustrando Controlador e Modelo Preditivo	29
<b>Figura 15</b> - Arquitetura para um Sistema de Decisão Inteligente Híbrido	31
<b>Figura 16</b> - Relacionamento entre as sub-etapas de Implementação do SDIH	35
<b>Figura 17</b> - Ciclo de desenvolvimento para o Módulo Preditivo.	36
<b>Figura 18</b> - Ciclo de desenvolvimento para o Módulo Analítico	37
<b>Figura 19</b> - Ciclo de desenvolvimento para o Módulo Interativo	38
<b>Figura 20</b> - Esquema da solução proposta para a colheita da cana-de-açúcar	42
<b>Figura 21</b> - Número de Lotes em cada experimento, utilizando Programação Linear e Algoritmos Genéticos	46
<b>Figura 22</b> - PCC em cada experimento, utilizando Programação Linear e Algoritmos Genéticos	46
<b>Figura 23</b> - Fibra em cada experimento, utilizando Programação Linear e Algoritmos Genéticos	46
<b>Figura 24</b> - Toneladas de Cana em cada experimento, utilizando Programação Linear e Algoritmos Genéticos	46
<b>Figura 25</b> - Esquema da solução proposta para a investigação de impacto em pacientes cardíacos	48

# Índice de Tabelas e Equações

<b>Tabela 4-1:</b> Exemplo de Função de Avaliação para atributo qualitativo	24
<b>Tabela 5-1:</b> O Ciclo de Desenvolvimento	33
<b>Tabela 5-2:</b> Recursos gráficos para o Módulo Interativo e Indicações de Aplicação	39
<b>Tabela 6-1:</b> Dados utilizados como entrada para os 5 experimentos realizados	45
<b>Tabela 6-2:</b> Codificação dos Níveis de Risco Cardíaco na base <i>heart</i> em Proben1 [Whitley94]	49
<b>Tabela 6-3:</b> Atributos dos pacientes sujeitos à diagnose de risco cardíaco	51
<b>Tabela 6-4 :</b> Resultados das simulações de tratamento com os 5 pacientes	51
<b>Equação 4-1:</b> Mapeamento entre vetor de entrada $I$ e de atributos $A$ , no novo vetor de atributos $A'$ .	23
<b>Equação 4-2 :</b> Cálculo da Relevância de um Componente de Decisão $c_j$	24
<b>Equação 4-3:</b> Cálculo da Adequação da Decisão, utilizando cada componente $c_j$	24
<b>Equação 6-1 :</b> Função de Avaliação para PCC	43
<b>Equação 6-2:</b> Função de Avaliação para Fibra	43
<b>Equação 6-3:</b> Função da relevância de uma componente de decisão(lote)	43
<b>Equação 6-4:</b> Função de adequação da decisão (conjunto de lotes)	43
<b>Equação 6-5 :</b> Função de avaliação para colesterol ( $sc$ )	48
<b>Equação 6-6:</b> Função de avaliação para Máxima Frequência Cardíaca ( $mhr$ )	48
<b>Equação 6-7:</b> Cálculo da relevância para uma componente de decisão $C_j$ (estado futuro do paciente)	49
<b>Equação 6-8:</b> Função de Adequação para uma decisão $d_k$ (estado futuro do paciente)	49

# Tabela de Siglas

(Dispostos por ordem de aparição no texto)

Sistemas de Apoio à Decisão – SADs

Redes Neurais Artificiais - RNAs

*Multi-Layer Perceptron* – MLP

Algoritmos Genéticos - AGs

Controlador Baseado em Lógica Difusa – CBLD

Sistema de Decisão Inteligente Híbrido – SDIH

Project Management Body of Knowledge – PMBoK

Programação Linear – PL

# Agradecimentos

Primeiramente agradeço a Deus por tudo: as bênçãos recebidas, saúde, proteção, pela minha família e amigos. Sem a intervenção dEle, atuando através de pessoas especiais nos momentos oportunos, certamente não estaria escrevendo esses agradecimentos.

Logo em seguida, agradeço a toda minha família pelo apoio incondicional que sempre recebi. Destaco quando decidi abandonar um curso noutra instituição e iniciar meus estudos na Universidade de Pernambuco. Todo momento de grandes mudanças é difícil, mas são fortemente amenizados quando se possui na família uma base sólida.

Ao meu pai Manuel (em memória), agradeço especialmente pelos ensinamentos e preceitos para levar uma vida digna, pautada por retidão ética e moral. Levo esses conhecimentos a toda parte. À minha mãe Antônia, agradeço pelo amor dispensado em todos os momentos, sobretudo com atitudes (pequenas e grandes) que muitas vezes valem mais do que qualquer palavra.

Preciso agradecer também aos professores que compõe o Departamento de Sistemas Computacionais. Cada um deles contribuiu de maneira diferente para minha formação. Destaco o empenho em proporcionar a nós alunos, um curso superior de qualidade. Testemunhei durante o curso o esforço para conseguir recursos: no início uma realidade difícil mas que com muito trabalho vem sendo modificada. Em especial agradeço ao Prof. Fernando Buarque, pela orientação durante a Iniciação Científica e pelo *mentoring* que prosseguiu mesmo após o seu término.

Por último, mas não menos importante, agradeço aos colegas e amigos que fiz. Aprendi um pouco com cada um. Nossa convivência foi sempre muito agradável, nos ajudamos bastante e como consequência crescemos juntos. Espero que nos encontremos muitas vezes pelos caminhos da vida.

Enfim, escrever agradecimentos é difícil... A memória tende a falhar na hora H, e algo ou alguém sempre acaba sendo esquecido :)

Portanto, obrigado a todos por tudo!  
Vamos em frente...



# Capítulo 1

## Introdução

Esse capítulo motiva o trabalho desenvolvido nessa monografia expondo sua hipótese inicial e as fontes que fundamentaram sua realização. Também explicita os objetivos da monografia e apresenta de forma resumida a organização dos capítulos seguintes.

### 1.1 Motivação

O processo de tomada de decisão com características semi-estruturadas é freqüentemente complexo pois as condições que determinam o sucesso da operação mudam rapidamente. Nessas situações, a utilização de ferramentas de apoio é recomendada para auxiliar o Tomador de Decisão. Essas ferramentas podem maximizar o tempo disponível para analisar as opções e reduzir o considerável grau de incerteza associado às conseqüências de cada uma delas.

Em ambientes empresariais, cujas mudanças são rápidas e com o aumento crescente da competitividade, uma análise precisa e flexível de cenários de decisão torna-se muito importante [Lee06]. Freqüentemente há grandes impactos financeiros associados à tomada de decisão. Em outros contextos como a escolha de um tratamento por um médico, há pouco tempo para diagnosticar e escolher uma estratégia de ação. Nessa situação em particular, as conseqüências podem ser irreversíveis para o paciente.

Um Sistema de Apoio à Decisão (SAD) pode ser definido como uma ferramenta que fornece a seus usuários facilidades de análise, utilizando para isso modelos e informações muitas vezes oriundos de outros tipos de Sistemas da Informação [Edwards92]. A investigação empírica de Moreau [Moreau06] mostrou que SADs que utilizam recursos de Computação Inteligente (CI) tornam a tarefa intelectual do usuário mais agradável e acabam por melhorar a sua performance.

A dissertação de mestrado de Buarque [Buarque98] propõe um novo tipo de SAD, o nDSS (neural Decision Support System). Um nDSS é caracterizado por utilizar entre os seus modelos uma Rede Neural Artificial com a finalidade de gerar cenários de decisão futuros. A hipótese do presente trabalho, que acrescenta ao proposto nos nDSS, é que utilizar uma combinação de técnicas inteligentes pode permitir ao sistema lidar com problemas mais complexos de forma que os cenários gerados sejam mais úteis ao usuário.

Será proposta uma abordagem para utilizar CI híbrida para realizar buscas em espaços de decisão complexos e buscas por condicionantes para um resultado desejado. Como contribuição adicional, serão realizadas considerações sobre o ciclo de desenvolvimento de um SAD, incorporando suas especificidades, como modelar o problema de decisão, escolher a técnica de CI

e validar a solução. Por fim serão realizados dois estudos de caso para ilustrar a aplicação da abordagem em problemas que caracterizam as situações citadas acima.

## 1.2 Objetivos

O objetivo central desse trabalho é propor uma abordagem que propicie o uso eficaz de Computação Inteligente em Sistemas de Apoio à Decisão. Para tanto destacamos as metas:

- Apresentar um modelo abstrato para o Processo Decisório.
- Introduzir e ilustrar heurísticas para realizar Buscas Combinatoriais e Buscas por Condicionantes para um resultado desejado.
- Propor um ciclo de desenvolvimento para construir SADs baseados em CI.
- Desenvolver componentes de software parametrizáveis e modulares que facilitem a aplicação da abordagem proposta.
- Realizar dois estudos de caso, ilustrando o uso da abordagem em diferentes domínios de decisão.

## 1.3 Estrutura dos Capítulos

O presente trabalho foi estruturado de acordo com os tópicos seguintes:

- Fundamentação e Revisão Teórica:
  - No **Capítulo 2**, será introduzido o Processo de Tomada de Decisão e uma apresentação dos Sistemas de Apoio a Decisão. Suas principais características e componentes são descritos.
  - No **Capítulo 3**, as Técnicas Inteligentes utilizadas no trabalho são apresentadas para auxiliar a compreensão do leitor. São apresentadas as Redes Neurais Artificiais, Algoritmos Genéticos e Lógica Difusa, e dada uma breve explanação sobre seu funcionamento.
- Contribuição:
  - No **Capítulo 4**, é proposto um formalismo para a abordagem. Inicialmente será fornecido um modelo abstrato para o Processo Decisório e em seguida, duas áreas relevantes serão enfocadas: a Busca Combinatorial em Espaços de Decisão Complexos e a Busca por Condicionantes para um Resultado Desejado.
  - No **Capítulo 5**, será apresentado o ciclo de desenvolvimento para incorporar Computação Inteligente a Sistemas de Apoio à Decisão. Estão incluídas

considerações sobre a implementação dos Módulos Preditivo, Analítico e Interativo.

- No **Capítulo 6**, a abordagem proposta é utilizada em dois estudos de caso. O primeiro trata da seleção de lotes na colheita da cana-de-açúcar e o segundo trata sobre a escolha de linhas de tratamento para pacientes cardíacos. Também são fornecidos alguns detalhes sobre a implementação dos componentes modulares e parametrizáveis utilizados nos módulos analíticos de cada estudo de caso.
- Conclusão
  - No **Capítulo 7**, são tecidas considerações sobre a contribuição do trabalho e uma discussão sobre a concretização das expectativas iniciais. Além disso, são propostas melhorias a serem realizadas em trabalhos futuros.

## Capítulo 2

# Sistemas de Apoio à Decisão

Esse capítulo aborda a área de Apoio a Decisão, apresentando o domínio no qual esse trabalho está inserido. Um método clássico para Tomada de Decisão é apresentado, e em seguida, os Sistemas de Apoio à Decisão (SADs) são definidos. Também são apresentados os principais componentes de um SAD, bem como suas funcionalidades e características especiais.

### 2.1 Processo de Tomada de Decisão

É importante iniciar esse capítulo com uma discussão sobre o Processo de Tomada de Decisão. Essa seção visa oferecer uma visão do Processo Decisório, livre das influências da área de Sistemas da Informação. Acredita-se que de posse de uma perspectiva isenta acerca do assunto, seja possível compreender melhor as motivações e objetivos dos SADs, que são assunto de importância central para essa monografia.

Em ambientes organizacionais, é possível afirmar que o fato de tomar decisões decorre de uma situação constante: existe uma diferença entre o estado atual e o estado desejado (objetivo). Dessa forma, o processo inicia com a identificação da necessidade de realizar ações para reduzir essa diferença. Serão criadas alternativas que precisam ser selecionadas e então ativadas. Caso a alternativa escolhida não seja bem sucedida para atingir o estado desejado, é preciso retornar ao planejamento e tentar outra alternativa.

O modelo proposto por Simon [Simon60] envolve quatro etapas diferentes para o processo de decisão: (i) Inteligência, (ii) Projeto, (iii) Escolha e (iv) Implementação. O encadeamento dessas etapas pode ser visto na Figura 1.

A etapa de Inteligência consiste em definir o problema, identificar os objetivos da decisão e também diagnosticar as causas do problema. É importante também determinar as ações necessárias para a solução. O Projeto envolve buscar alternativas para alcançar os objetivos da decisão. Nesse momento, ainda não é necessário avaliá-las, sendo ideal aglomerar um certo volume de alternativas para que o processo criativo se manifeste. Na etapa de Escolha, as alternativas serão avaliadas na expectativa de identificar e selecionar a melhor delas. Nesse ponto, há ao menos 3 questões pertinentes:

- Esta alternativa é exequível? - é preciso verificar se há recursos para implementar essa solução e verificar se ela está de acordo com os procedimentos da organização.
- Essa alternativa é uma solução satisfatória? – um critério importante a considerar é se a solução atende aos objetivos da decisão e qual a sua probabilidade de sucesso.
- Quais são as conseqüências possíveis para a organização? – deve-se verificar qual o impacto dessa solução sobre os demais setores da organização. As conseqüências negativas devem ser eliminadas.

Ainda é preciso realizar a escolha considerando o tempo e informações disponíveis. Por fim, a Implementação envolve ativar a decisão selecionada e monitorar seu desempenho, para reiniciar o processo em caso de necessidade.



**Figura 1.** Encadeamento das etapas do Processo Decisório

## 2.2 Sistemas de Apoio à Decisão

Sistemas de Apoio à Decisão (SADs) são ferramentas especiais que combinam recursos intelectuais de indivíduos com capacidades computacionais, a fim de melhorar a qualidade das decisões em problemas semi-estruturados [Turban95]. Esse tipo de problema é caracterizado pela mudança rápida de suas condições e por não serem de fácil identificação prévia.

A situação das lavouras no campo, notadamente em engenhos de cana-de-açúcar depende de uma série de fatores como a quantidade de chuvas e os investimentos feitos para melhorar a produtividade do solo. Determinar quais os lotes mais adequados para corte, considerando que a perda de alguns dias, colocará o aquele lote em situação diferenciada quanto ao teor de sacarose que pode ser extraído, é uma tarefa complexa. Além disso, é necessário respeitar a capacidade de moagem da usina, e ainda considerar a situação de todos os outros lotes que por ventura estejam maduros.


Os SADs se destinam a operar no nível gerencial das organizações, sendo preparados para auxiliar os gerentes durante o processo decisório. Para tanto, os SADs precisam ser rápidos o suficiente para executar várias vezes numa mesma sessão de simulações, possuindo maior poder analítico que outros tipos de sistema de informação. Por isso, os SADs são construídos contemplando uma variedade de modelos para análise de dados[Laudon00].

O uso de um SAD é realizado diretamente pelo seu usuário, um gerente de médio a alto nível na organização. Assim, sua interface deve ser simples e amigável o suficiente, provendo recursos para condensar as grandes quantidades de dados com os quais os tomadores de decisão precisam lidar.

## 2.2.1 Componentes de um SAD

Na Figura 2 foi representado um SAD padrão, segundo a descrição proposta por Turban [Turban95]. Nessa descrição, podem ser identificados os seguintes componentes:

- Subsistema de Dados: é uma coleção de dados correntes ou históricos de vários outros sistemas da empresa. Estes bancos geralmente são cópias (visões) dos bancos de dados de produção, assegurando que os SADs não interferem nas atividades críticas da empresa [Laudon00].
- Subsistema de Modelos: incorpora em seu repositório um conjunto de modelos destinados à fornecer a capacidade de análise ao SAD. Um modelo nesse caso, é uma abstração que ilustra componentes e relacionamentos de um fenômeno ou problema [Laudon00]. Esses modelos podem ser matemáticos ou estatísticos e abordam vários aspectos da organização como os níveis tático e estratégico, dependendo do propósito pelo qual o SAD foi concebido.
- Subsistema de Diálogos: Requer uma interface gráfica fácil de usar, flexível e capaz de suportar diálogos entre o usuário e o SAD. Vale ressaltar que estes usuários, na sua maioria, são gerentes ou executivos corporativos, que não possuem um conhecimento profundo de informática e precisam de respostas rápidas e com grande poder de síntese.



**Figura 2.** Esquema de um SAD padrão adaptado de Turban [Turban95]

## Capítulo 3

# Tópicos de Computação Inteligente

Esse Capítulo aborda as principais técnicas de Computação Inteligente utilizadas nesse trabalho. Seu entendimento é fundamental para a compreensão das aplicações realizadas nos Estudos de Caso. São apresentadas as Redes Neurais Artificiais, Algoritmos Genéticos e Lógica Difusa, com uma breve explanação sobre seu funcionamento.

### 3.1 Redes Neurais Artificiais

Redes Neurais Artificiais (RNAs) são uma técnica inspirada no funcionamento do cérebro, que utiliza um elemento básico de processamento, o neurônio artificial. Dentre suas características, possuem maior destaque [Jain96]:

- Conhecimento e computação distribuídos.
- Capacidade de aprendizado.
- Capacidade de generalização.
- Capacidade de adaptação;
- Tolerância a erros.

A organização dos neurônios artificiais conectados por ligações sinápticas (representadas por funções matemáticas), permite ao computador a criação de uma estrutura primitiva capaz de armazenar informações e gerar novos conhecimentos.


Haykin define uma rede neural vista como uma máquina adaptativa [Haykin94]:

*“Uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:*

- 1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.*
- 2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.”* [Haykin94, pág. 28].

Na Figura 3 pode ser visto um esquema da unidade básica de processamento de uma RNA. O neurônio artificial, é composto pelos seguintes elementos:

- Um conjunto de sinapses, que recebem as entradas  $X_n$  do sistema, e possuem pesos próprios  $W_n$ .
- Um somador, que processa as entradas ponderadas com os respectivos pesos realizando uma combinação linear
- E, uma função de ativação  $f(u)$ , que limita a amplitude de saída de um neurônio. Existem vários tipos de função de ativação, os mais conhecidos são: função de limiar, função linear por partes e função sigmóide (logística ou tangente hiperbólica)



**Figura 3.** Representação do neurônio artificial, e seus elementos constituintes

No restante dessa seção, serão enfocadas as redes *Multi-Layer Perceptron* (MLP) [Rumelhart86], pois foram o tipo utilizado nos estudos de caso dessa monografia. Ao realizar o processamento no sentido direto (*forward*) usando uma MLP, é possível mapear os valores apresentados nos neurônios de entrada em valores de saída, cujo significado pode ser interpretado como uma predição, classificação ou agrupamento.

A escolha dos melhores parâmetros para configurar uma RNA está fortemente ligada ao problema específico. Frequentemente, esse processo de seleção requer uma boa experiência do especialista, e uma quantidade significativa de simulações. Apesar de não existir uma fundamentação teórica para determinar os parâmetros, é possível contornar essa dificuldade. No trabalho de Madeiro [Madeiro06] a configuração de RNAs foi realizada por um Algoritmo Genético especialmente modificado para essa finalidade. Os resultados foram compatíveis com os encontrados por especialistas humanos.

A complexidade da tarefa de configuração de uma RNA está associada ao número de parâmetros que influenciam o seu desempenho. Dentre esses, possuem especial destaque: (i) o número de camadas escondidas, (ii) o número de neurônios nessas camadas, (iii) a taxa de treinamento utilizada e (iv) o tipo de função de ativação.

Para adquirir o conhecimento a partir de exemplos, é necessário utilizar algum mecanismo de treinamento. As MLPs utilizam o treinamento supervisionado, caracterizado por se ter disponível o conjunto de entradas e saídas dos dados. Durante o treinamento, as entradas são propagadas pela rede e as saídas calculadas são comparadas às saídas desejadas para calcular o erro. O algoritmo de treinamento para as redes MLP foi chamado de *Error Backpropagation* (retropropagação do erro) pois seu princípio era ir propagando o erro desde a camada de saída até a camada de entrada compensando os pesos sinápticos de cada neurônio de acordo com sua relevância no processamento realizado [Jain96].

Prechelt [Prechelt94] destaca em seu trabalho várias características desejáveis para o treinamento de RNAs. É sugerido dividir a massa de dados em 3 conjuntos: treinamento (50%), validação (25%) e teste (25%). O conjunto de treinamento será utilizado no momento do ajuste



dos pesos pelo algoritmo *Error Backpropagation*. O conjunto de validação é utilizado para medir a performance da rede durante o treinamento, evitando o fenômeno conhecido como *overfitting*. O *overfitting* ocorre quando a RNA incorpora características específicas dos dados apresentados, perdendo capacidade de generalização em situações não vistas. Por fim, o conjunto de teste se destina a mensurar a performance da rede em padrões não vistos durante o treinamento.

As RNAs tem sido utilizadas com sucesso em diversos ramos de aplicação e no presente trabalho, sua capacidade de generalização é altamente desejável. Isso porque, frequentemente, é preciso realizar uma decisão acerca de situações futuras, com características diferentes daquelas já vivenciadas pelo tomador de decisão. Assim, a RNA pode contribuir com a predição de atributos sobre o problema, reduzindo a incerteza associada ao processo decisório.

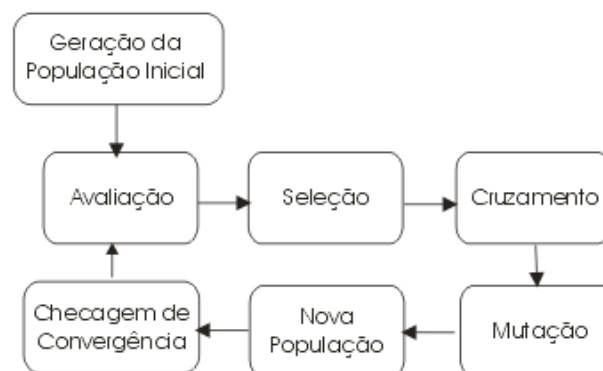
## 3.2 Algoritmos Genéticos

Algoritmos Genéticos (AGs) são uma técnica de otimização e busca baseada nos princípios da Genética e da Seleção Natural. Nessa técnica, cada aspecto específico de um problema é codificado em um gene. Os cromossomos que representam possíveis soluções para o problema, são compostos por um conjunto de genes. Assim, o AG permite que uma população composta por vários indivíduos evolua sob regras específicas visando alcançar um estado que maximize sua aptidão (chance de sobreviver no ambiente)[Haupt04].

Ao aplicar AGs para solucionar um problema, é necessário escolher uma representação apropriada para o cromossomo e genes. Frequentemente é utilizado um *array* de bits. As principais características dos AGs relevantes para esse trabalho são:

- Capazes de lidar com um grande número de variáveis.
- Podem otimizar variáveis com funções de custo complexas (difíceis de descrever analiticamente).
- São capazes de evitar máximos ou mínimos locais durante a busca.
- Podem inspecionar várias amostras da superfície de busca ao mesmo tempo.

Os AG possuem um certo número de parâmetros a definir. Seu desempenho está intimamente ligado a escolha desses parâmetros e possivelmente será necessário utilizar a experiência do especialista e algumas simulações para encontrar valores ótimos. Os parâmetros serão definidos ao longo dessa seção. Na Figura 4, pode ser visto um esquema de um ciclo evolutivo típico para um AG [Haupt04].



**Figura 4.** Típico ciclo evolutivo para um Algoritmo Genético

É preciso definir o número de elementos para a população e o número de genes necessários para representar todas as variáveis relevantes para a solução do problema. A população inicial de cromossomos (soluções) deve ser inicializada, ativando alguns genes. O número de genes ativados pode ser fixo ou definido randomicamente.

A população inicial deve então ser avaliada de acordo com a Função *Fitness*. A importância dessa função é a de mensurar objetivamente o ‘mérito’ de um cromossomo (solução) utilizando a informação contida em seus genes. O valor de aptidão para o cromossomo determina se suas chances de ‘sobreviver’ no ambiente são maiores ou menores [Haupt04].

De acordo com a aptidão de cada indivíduo, será realizada a seleção que pode ser feita de acordo com:

- Método da Roleta [Whitley94]: todos os cromossomos são dispostos numa ‘roleta’ onde a área de cada um é proporcional a sua aptidão. Esse método pode acarretar uma baixa variabilidade genética (exploração superficial do espaço de busca), pois cromossomos que possuem uma aptidão muito maior que a maioria da população são selecionados repetidas vezes na etapa do cruzamento.
- Método do Torneio: dois cromossomos são sorteados e disputam entre si pelo direito de passar suas características para a próxima geração (cruzamento). Vencerá o elemento com maior aptidão. Esse método tende a executar mais rapidamente e não incorre facilmente na baixa variabilidade genética.

Após selecionar os elementos mais aptos, eles devem ser agrupados em pares e cruzados. A operação de cruzamento pode ocorrer de diversas maneiras. A forma mais simples, consiste em dividir os cromossomos em seu ponto central e recombinar as partes correspondentes, formando dois novos indivíduos. Dessa forma, as características de dois cromossomos com boa aptidão na última população são combinados com potencial para gerar dois indivíduos ainda melhores.

Após o cruzamento, ocorre a mutação, cuja importância é evitar a desativação definitiva de um determinado gene [Whitley94]. Durante a evolução, a maior parte dos indivíduos mais aptos pode possuir um determinado gene desativado. No entanto, a ativação desse gene pode, numa geração futura, representar uma característica importante para uma solução ótima. A interpretação desse fato, é a utilização do operador de mutação para evitar a convergência prematura para um máximo ou mínimo local.

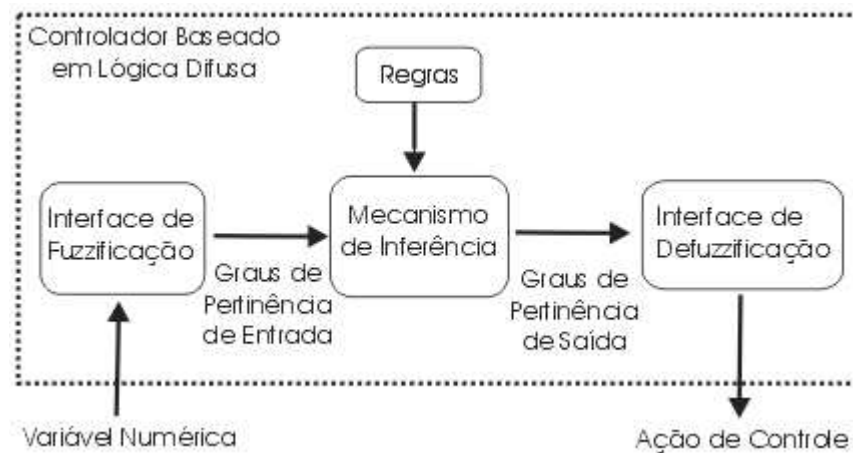
Um teste de convergência pode ser efetuado ao final de cada ciclo, verificando se a condição desejada na busca foi atingida, ou se ocorreu a convergência do algoritmo (quando não houver melhoria na aptidão após certo número de ciclos). Uma hipótese alternativa, é o uso de um valor máximo de ciclos para evitar um tempo de processamento muito alto em aplicações que requerem respostas rápidas. Mesmo que a solução ótima não tenha sido encontrada, o sistema pode então apresentar uma resposta intermediária. Essa característica de robustez e possibilidade de tratar problemas complexos, tornam os AGs bastante atrativos para o uso em SADs.

### 3.3 Lógica Difusa

A Lógica Difusa foi proposta por Lofti Zadeh em 1965 com a finalidade de estender a Lógica de Aristóteles, fornecendo subsídio para tratar intervalos de valores cujos limites não são bem definidos [Zadeh65]. A Lógica de Aristóteles lida com valores binários como: ‘bom-mal’,

‘sim-não’ e ‘quente-frio’. No entanto, os problemas reais freqüentemente incorporam elementos intermediários como: ‘sim-talvez-não’ ou ‘quente-morno-frio-gelado’.

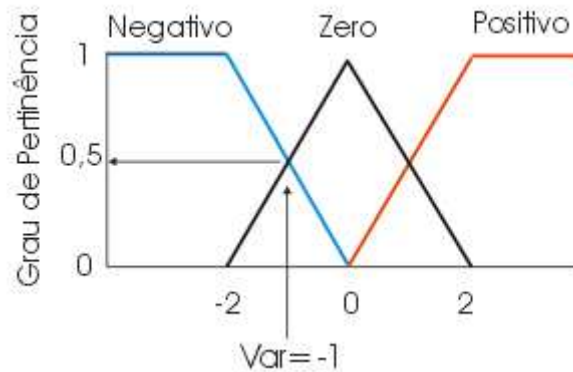
Os Controladores Baseados em Lógica Difusa (CBLD), são bem sucedidos para o controle de processos sofisticados. Com sua utilização, requisitos complexos podem ser implementados em controladores simples e de baixo custo [Sandri99]. Ao contrário dos controladores convencionais onde o algoritmo de controle é descrito analiticamente ou utilizando equações algébricas, o CBLD utiliza regras no formato ‘*Se (premissa) Então (conclusão)*’. Essas regras almejam representar a experiência humana, intuição e heurística para solucionar um problema com uma rotina[Zadeh65]. Um esquema que representa um CBLD pode ser visto na Figura 5.



**Figura 5.** Esquema de um Controlador Baseado em Lógica Difusa

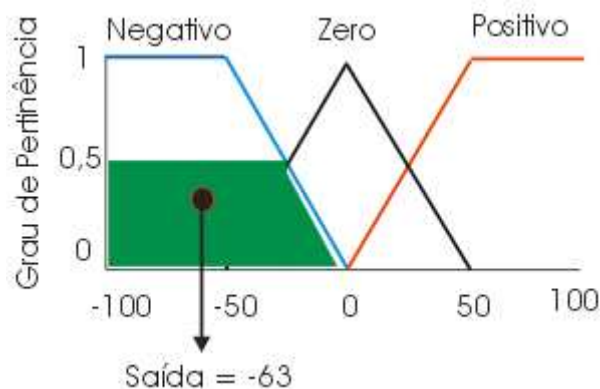
Um CBLD utiliza ao menos 3 elementos: (i) a Interface de Fuzzificação, (ii) o Mecanismo de Inferência e (iii) a Interface de Defuzzificação. O fluxo da informação ocorre segundo os passos abaixo:

- Uma variável numérica é informada ao CBLD.
- A variável numérica é transformada em graus de pertinência de entrada através da Interface de Fuzzificação. Na Figura 6 é possível observar o mapeamento de uma variável numérica em 3 conjuntos de pertinência: Negativo, Zero e Positivo. Nesse caso, a variável com valor  $-1$  pertence 50% ao conjunto Negativo e 50% ao conjunto Zero. Os valores para funções de pertinência freqüentemente são normalizados no intervalo  $[0..1]$ . Foram utilizadas funções triangulares mas também poderiam ser utilizadas funções Gaussianas[Wang96].
- Os graus de pertinência de entrada são processados pelo Mecanismo de Inferência, que utiliza as regras que descrevem a rotina para solução do problema. Devem ser calculados valores de conclusão para cada regra, de acordo com o grau de compatibilidade entre os dados e suas premissas[Sandri99].



**Figura 6.** Mapeamento de Variável de Entrada em Graus de Pertinência

- O resultado do processamento do valor de conclusão de cada regra é computado para gerar graus de pertinência de saída.
- Os graus de pertinência de saída são passados à Interface de Defuzzificação para que sejam transformados em um valor numérico de saída, que servirá como ação de controle para o ambiente externo.
- Na Figura 7, pode ser visto um exemplo de Defuzzificação. Os graus de pertinência de saída formaram o polígono destacado. Assim, o processo de Defuzzificação consistiu em calcular o Centro de Massa do polígono para determinar o valor de saída.



**Figura 7.** Defuzzificação calculando o Centro de Massa do polígono, a partir dos graus de pertinência de saída.

Devido a sua característica de lidar bem com variáveis cujos limites não são bem definidos, e sua capacidade de controlar processos complexos, a Lógica Difusa e CBLD são tópicos de interesse para auxiliar a superar os desafios encontrados na área de Apoio à Decisão.

## Capítulo 4

# Modelo Abstrato para Tomada de Decisão

O objetivo deste capítulo é fornecer uma visão abstrata do Processo Decisório cujo formalismo é útil na modelagem de problemas para posterior implementação num Sistema de Apoio à Decisão. Além de propor o formalismo, são enfocados dois tópicos de grande relevância na área, tratando-se das Buscas Combinatoriais em Espaços de Decisão Complexos e a Busca por Condicionantes para um Resultado Desejado. As considerações foram feitas de forma abstrata, informando as características desejáveis ao se tratar sistemas que envolvam os tópicos.

### 4.1 Formalização do Processo de Tomada de Decisão

A principal vantagem e motivação para se criar um modelo abstrato, antes de implementar um SAD, é a possibilidade de tratar o problema de uma forma mais simples e ajustar os detalhes junto ao Tomador de Decisão antecipadamente. Cerca de 60% dos projetos de *Business Intelligence*[Rud01, pp. 32] , dentre os quais se enquadram os SADs, são abandonados ou falham devido a um planejamento inadequado ou mesmo falha em entregar os requisitos principais acordados previamente [Moss03, pp. 5].

Também é possível criar um protótipo e estudar as conseqüências de realizar modificações no modelo. Em alguns casos, incluir variáveis de decisão adicionais no modelo do problema pode melhorar o controle do Tomador de Decisão acerca do processo decisório. Por fim, a modelagem abstrata permite adaptar uma solução a outros problemas cuja abstração seja semelhante, reduzindo o custo de produção dos próximos projetos. Por exemplo, dois gerentes agrícolas podem não realizar a colheita utilizando a mesma metodologia. No entanto, se as diferenças não forem demasiado profundas, ao modelar um SAD para a decisão de colheita para o primeiro, é possível adaptar o modelo criado e reutilizá-lo para o segundo.

Durante o levantamento bibliográfico, não se encontrou um formalismo abstrato para criar modelos de decisão utilizando o nível de detalhes requerido para esse trabalho. Portanto, para embasar a modelagem de SADs, o formalismo abstrato proposto no trabalho de Oliveira [Oliveira06] foi estendido e enriquecido com exemplos. Esse formalismo continha apenas uma

descrição resumida dos principais elementos: (i) o Tomador de Decisão, (ii) o Espaço de Decisão e (iii) a Categorização das Decisões. Esses elementos são detalhados nas subseções seguintes.

### 4.1.1 O Tomador de Decisão


Dado um problema  $p_k$  da classe de problemas  $P$ , considere-se um tomador de decisão  $t_k$  pertencente à classe dos Tomadores de Decisão  $T$ . Cada indivíduo da classe  $T$  é necessariamente autorizado e capaz de solucionar problemas da classe  $P$ . Espera-se que de acordo com a situação,  $t_k$  arbitre as características que determinam a validade de uma opção, bem como suas prioridades no momento. Esses elementos serão fundamentais para o processo sugerido de Categorização da Decisão e serão explicitados em seção posterior.

Por exemplo, suponha um corretor de imóveis que precisa fazer uma nova aquisição para seu escritório. Considera-se que corretores de imóveis ( $t_k$ ) são capazes e autorizados a solucionar problemas de seleção e compra de imóveis ( $p_k$ ). Também sabem de acordo com a necessidade da corretora em dado momento, que não lhes interessa um terreno com menos de  $100m^2$  (validade) e que a vizinhança do terreno é mais importante do que o preço (prioridade).

### 4.1.2 O Espaço de Decisão

A pré-condição para o formalismo desenvolvido ao longo dessa seção é a existência de um Espaço de Decisão  $D_p$  que contém todas as possíveis soluções para um problema  $p_k$ . Assim, considera-se  $D_p = \{d_1, d_2, d_3 \dots d_n\}$ , onde cada  $d_k$  é uma combinação de diferentes elementos  $c_j$ . Cada  $c_j$  pertencente ao conjunto  $C$  que é composto por Componentes de Decisão; em termos gerais  $C_k = \{c_1, c_2, c_3 \dots c_n\}$ .

O nível mais baixo dessa abstração são os atributos, que caracterizam um Componente de Decisão. Assim,  $c_k = (a_1, a_2, a_3 \dots a_n)$ , onde cada  $a_j$  pode assumir valores quantitativos ou qualitativos. Pode-se verificar um esquema ilustrativo na Figura 8. É muito importante destacar que em se tratando de uma decisão futura, alguns (muitos) dos atributos devem ser obtidos através de uma função especial  $\Phi$ , que obrigatoriamente consiga realizar induções, ou seja, possua habilidades preditivas.



**Figura 8.** Esquema ilustrando a hierarquia do Espaço de Decisão  $D_p$  com suas decisões, e decomposição em componentes  $c_j$  e atributos  $a_j$

A função  $\Phi$  realiza o mapeamento entre um vetor de entradas externas, fatores de decisão,  $I = \{i_1, i_2, \dots, i_m\}$  que foram identificadas como relevantes para o processo de decisão em lide e um vetor com alguns dos atributos pertencentes a  $c_j$ , no caso o vetor  $A = \{a_1, a_2, \dots, a_m\}$  – os indicadores de decisão. O resultado será uma tupla com atributos modificados  $A' = (a'_1, a'_2, \dots, a'_r)$

que pertencem ao componente  $c_j$  valorados no horizonte futuro da decisão. Pode-se perceber mais claramente o mapeamento realizado pela função  $\Phi$  na Equação 4-1. Considerando o exemplo do corretor de imóveis, esse mapeamento ocorreria quando se desejasse estimar o preço futuro para um terreno.

$$\Phi(I, A) = (a'_1, a'_2, \dots, a'_n)$$

**Equação 4-1:** Mapeamento entre vetor de entrada I e de atributos A, no novo vetor de atributos A'.

Ainda utilizando o exemplo introduzido na seção anterior, o problema do corretor de imóveis poderia ser modelado como se segue. Um imóvel é um componente de decisão  $c_k$  e é composto pelos atributos: código identificador, preço, área e vizinhança, que é qualitativa e categorizada como boa, média ou ruim. O conjunto de componentes de decisão  $C$ , contém todos os terrenos à venda numa determinada região e que são interessantes para a corretora. O Espaço de Decisão  $D_p$  contém todas as possíveis combinações de terrenos, que podem ser adquiridos. Uma decisão poderia ser comprar terrenos 1 e 2, outra seria comprar terrenos 1, 3 e 4, e assim teríamos o conjunto preenchido por todas as combinações possíveis.

### 4.1.3 Categorização da Decisão

Considerando o Espaço de Decisão que contém as decisões possíveis para solucionar determinado problema, bem como suas componentes e atributos, é necessário estabelecer um mecanismo para definir quais dessas decisões são válidas. Também é preciso determinar uma ordem de precedência entre elas a fim de selecionar a melhor, ou mesmo analisar detalhadamente um conjunto de boas decisões que pareçam satisfatórias naquela ocasião. Propomos que da interação entre Tomador de Decisão e Problema podem ser obtidos os elementos necessários para esta finalidade:

- Os Critérios de Seleção  $S = \{s_1, s_2, \dots, s_n\}$ , são condições definidas sobre os atributos de decisão ou sobre operações realizadas sobre eles. São divididos em duas categorias:
  - Critérios Rígidos: uma decisão que não obedeça a esses critérios será considerada inválida e não será solução para o problema.
  - Critérios Flexíveis: mesmo que uma decisão não atenda a esses critérios, ainda será válida, mas considerada como uma solução inferior a outras que os atendam.
- O Vetor de Pesos,  $W = \{w_1, w_2, \dots, w_n\}$ , onde cada  $w_i$  é um valor numérico no intervalo [0..10] descrevendo o nível de prioridade de cada atributo utilizado no modelo para aquela decisão. Esses valores serão determinantes na ordenação das decisões do espaço  $D_p$ .
- As Funções de Avaliação  $f_i$  são métricas definidas com o propósito de auferir de maneira objetiva o quão bom é um atributo  $a_i$  quando considerado isoladamente. Essas

funções devem produzir valores normalizados na faixa [0..1]. Esse cuidado tem a finalidade de evitar distorções originadas por diferenças de magnitude entre os atributos considerados. Em se tratando de uma função para avaliar um atributo qualitativo, a formatação deve ocorrer de forma que a enumeração dos atributos seja distribuída uniformemente entre o intervalo [0..1]. Por exemplo, um atributo qualitativo cujos valores possíveis são: bom, médio e ruim, poderia ser avaliado conforme a Tabela 4-1.

**Tabela 4-1:** Exemplo de Função de Avaliação para atributo qualitativo

$a_i$	$f(a_i)$
Bom	1,0
Médio	0,5
Ruim	0,1

- A Relevância de um Componente de Decisão, é dada pela média ponderada entre Funções de Avaliação  $f_i$  e os respectivos pesos contidos no vetor  $\mathbf{W}$ . O cálculo da Relevância é feito de acordo com a Equação 4-2.

$$R(c_j) = \frac{\sum_{i=0}^n w_i * f_i(a_i)}{\sum_{i=0}^n w_i}$$

**Equação 4-2 :** Cálculo da Relevância de um Componente de Decisão  $c_j$

- A avaliação da adequação de uma decisão como um todo, compreende o somatório das relevâncias individuais de cada componente  $c_j$ . Seu cálculo é realizado de acordo com a Equação 4-3.

$$F(d_k) = \sum_{j=0}^n R(c_j)$$

**Equação 4-3:** Cálculo da Adequação da Decisão, utilizando cada componente  $c_j$

De posse dos elementos citados anteriormente, é possível selecionar e priorizar decisões de acordo com sua adequação aos critérios do Tomador de Decisão. Assim, considera-se o processo de tomada de decisão como a busca pelo conjunto de componentes que irá maximizar a função de adequação  $\mathbf{F}(d_k)$ .


## 4.2 Buscas Combinatoriais em Espaços de Decisão Complexos

Conforme visto na seção 4.1, o espaço de decisão é o conjunto contendo todas as soluções possíveis para um determinado problema. Considerando a Teoria dos Conjuntos, o Conjunto das Decisões possíveis de um conjunto com  $n$  elementos é  $2^n$ . Considerando a relação exponencial



entre o número de componentes e o total de combinações possíveis, esse total poderá atingir um valor de combinações a ponto de tornar inviável o tratamento (avaliação) de cada uma delas em termos de impactos futuros (via os indicadores de decisão).

No presente trabalho, considera-se um espaço de decisão complexo quando as decisões que o compõem forem formadas por mais de um componente  $c_j$  e houver incerteza acerca do número de componentes para a solução ótima. Dessa forma, haverá uma grande quantidade de resultados possíveis e que precisam ser analisados. A Figura 9 ilustra uma visão do Espaço de Decisão  $D_p$  e algumas combinações entre as componentes  $c_1, c_2, c_3$ . Não se sabe num primeiro momento qual das decisões  $d_k$  é a melhor e quais são os seus componentes  $c_k$ .




**Figura 9.** Caracterização do Espaço de Busca Combinatorial Complexo

Neste ponto é importante realizar uma breve discussão sobre os métodos de busca clássicos. A busca por força bruta consiste em testar todas as possibilidades a fim de encontrar o elemento procurado, no caso aquele que maximiza a função de adequação  $F(d_k)$ . No entanto, é pertinente destacar que para um  $n$  grande, o conjunto de boas soluções torna-se esparso em meio a essas possíveis alternativas, o que tornaria essa busca custosa demais em termos de tempo e outros recursos despendidos para a realizar.

Uma alternativa seria aplicar restrições prévias acerca dos atributos de cada componente de decisão  $c_j$ , mas isso limitaria a flexibilidade das soluções propostas. É válido lembrar que uma opção que isoladamente possui baixa relevância, pode ser combinada com opções ligeiramente melhores para compor a decisão mais adequada aos critérios do tomador de decisão.

Algumas soluções empregam técnicas analíticas que requerem uma descrição em forma de função da superfície estudada. A função também precisa ser derivável para que se encontrem os pontos de derivada nula, localizando possíveis pontos de máximo ou mínimo, conforme ilustrado na Figura 10. Em problemas reais, é difícil descrever o espaço de decisão de forma tão precisa, o que inviabiliza essa abordagem na maioria dos casos.




**Figura 10.** Função com dois pontos onde a primeira derivada se nula. Ponto 1 é o ponto de máximo e Ponto 2 é o ponto de mínimo.

A abordagem proposta nessa seção é particularmente útil, nos casos seguintes:

1. Quando não se souber previamente quantos elementos contém a decisão ótima.
2. Quando o conjunto de componentes de decisão for grande. No trabalho de [Whitley94], considera-se esse limite como  $n > 30$ .
3. Quando a função que representa o espaço de decisão não for de fácil descrição ou derivável.

A abordagem proposta para Buscas Combinatoriais em Espaços de Busca Complexos traz características desejáveis para uma pesquisa eficaz do Espaço de Decisão. Sua descrição é abstrata por não ser possível incorporar as particularidades de cada problema. Seguem as características propostas:

- Inicialmente é ideal dividir a busca em níveis de agrupamento de acordo com a natureza do problema. Essa medida visa estudar isoladamente diferentes regiões do espaço de decisão, procurando concentrar os esforços da busca na área mais provável de encontrar o conjunto ótimo de decisões. Pode ser visto um exemplo de agrupamento para um exemplo com apenas 3 Componentes de Decisão na Figura 11. As mesmas podem ser combinadas em até 7 decisões diferentes.



**Figura 11.** Espaço de Decisão ordenado por Nível de Agrupamento e Iteração da Busca

- Após algumas iterações nos diferentes níveis, é possível decidir se vale a pena continuar ou não a exploração nesse nível de agrupamento. Vale destacar que não é necessário enumerar previamente todas as combinações. Os níveis que trouxeram um grande número de decisões inválidas, de acordo com os Critérios de Seleção  $S$ , devem ser abandonados.
- Em cada nível de agrupamento, deve-se buscar simultaneamente em várias pontos distintos do espaço na mesma iteração. Isso permitirá obter amostras de decisões  $\mathbf{d}_k$  distintas e utilizar essa informação para guiar a busca.
- É necessário manter algum nível de memória no sistema. Dessa forma os melhores resultados podem ser armazenados de forma que suas características sejam usadas para influenciar a busca. Por exemplo, após as primeiras iterações é possível ter noção acerca do valor máximo de adequação  $F(\mathbf{d}_k)$  encontrado, podendo descartar cenários muito distantes desse valor.
- A partir dos pontos utilizados em cada iteração, devem ser realizadas combinações de forma construtiva. Ou seja, ao modificar elementos no conjunto, devem ser mantidos os elementos com maior relevância  $R(\mathbf{c}_j)$ , dado que os mesmos tendem a otimizar o resultado.
- Para evitar a convergência prematura para uma certa região, é ideal incorporar um pequeno nível de aleatoriedade na busca. Deve-se realizar um pequeno percentual das combinações de forma randômica, para que eventualmente uma solução  $\mathbf{d}_k$  que estivesse numa região inexplorada, possa ser considerada.
- O critério de parada pode ser estipulado pelo número de iterações em cada nível, ou quando não houver mais mudanças significativas entre a adequação dos cenários de decisão encontrados.
- Após concluir a exploração entre os níveis, é possível agrupar os melhores cenários  $\mathbf{d}_k$  encontrados e categorizá-los para uma posterior exibição ao tomador de decisão.

No Estudo de Caso 1 (capítulo 6) que trata com a seleção de lotes na colheita de cana-de-açúcar, as Redes Neurais Artificiais foram utilizadas para gerar as informações preditivas necessárias acerca dos lotes a serem colhidos. Já para determinar a combinação desses lotes, de forma a encontrar o conjunto que tivesse a maior relevância em relação aos critérios do tomador de decisão, foi utilizada uma versão modificada de Algoritmos Genéticos baseada nas características desejáveis para buscas, apresentadas nessa seção. A solução está descrita em mais detalhes no Capítulo 6.

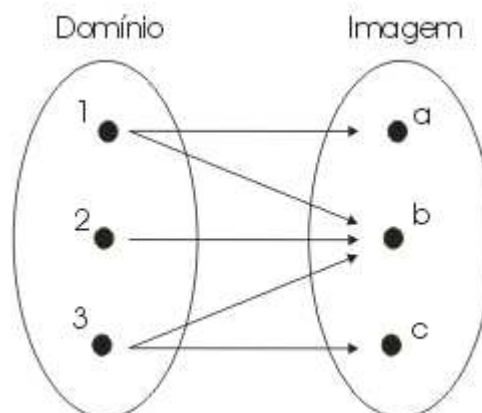
### 4.3 Busca de Condicionantes para um Resultado Desejado

O conhecimento sobre as regras que governam um fenômeno é de grande valor para um tomador de decisão. Esse conhecimento permite realizar avaliações prévias acerca do resultado de certas combinações de parâmetros para solucionar um problema. No entanto em muitos casos, seria desejável realizar a computação inversa, ou seja, sabendo o resultado desejado, descobrir seus fatores condicionantes. Isso permitiria ao tomador de decisão influenciar o ambiente para conseguir melhores resultados. Vemos na Figura 12 um exemplo de Computação Inversa.



**Figura 12.** Modelo Preditivo e computação no sentido Direto e Inverso

No entanto, manipular um modelo tentando descobrir as entradas a partir do resultado, pode ocasionar o chamado Problema Inverso [Tarantola05] . Se o modelo em questão não for uma função bijetiva, não será possível calcular a sua função inversa. Assim surge a questão: Como determinar os elementos do Domínio que são mapeados numa certa Imagem? Um exemplo dessa ambigüidade é ilustrado na Figura 13, quando o elemento b da Imagem é mapeado pelos três elementos do domínio. Nesse caso, considera-se que o Domínio contém as combinações de entradas possíveis para o modelo, e a Imagem, contém os valores correspondentes a cada combinação de entradas.



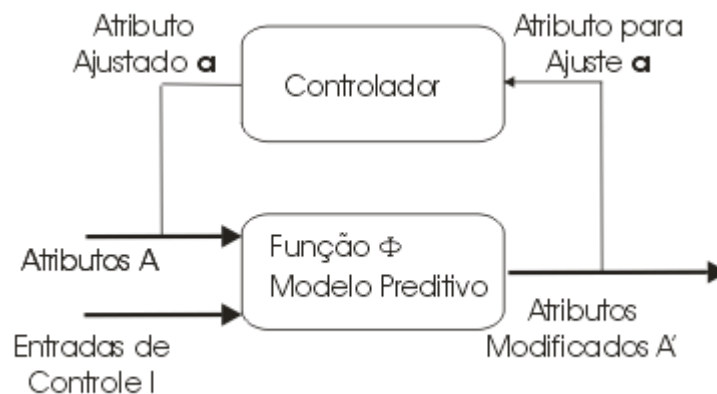
**Figura 13.** Mapeamento não funcional entre Domínio e Imagem que caracteriza a impossibilidade de computação do Problema Inverso

Uma solução de força bruta poderia ser utilizada, mas problemas reais freqüentemente possuem muitos pares Domínio-Imagem a serem analisados, tornando essa opção proibitiva. Uma

busca por amostragem seria uma solução satisfatória nos casos em que apenas se deseja conhecer a distribuição das variáveis de decisão e os resultados associados a elas. Frequentemente é necessário um nível adicional de profundidade, requerendo os valores condicionantes de resultados tão próximos quanto possível aos informados como objetivo da busca.

Essa seção apresenta uma heurística para realizar buscas eficazes acerca de fatores condicionantes para decisões. A estratégia de busca proposta evita as dificuldades derivadas do Problema Inverso. Essa heurística pressupõe a existência de um modelo acerca do fenômeno estudado, que mapeia entradas em saídas. Seu ponto chave é determinar a partir da Imagem, o ponto ou pontos do Domínio correspondentes.

Para tanto, sugere-se implementar um controlador que realiza ajustes nos parâmetros dinamicamente visando atingir um objetivo definido previamente. Um diagrama de blocos simplificado dessa abordagem utilizando Modelo e Controlador, pode ser visto na Figura 14. Nela, os Atributos A e Entradas de Controle I são mapeados em Atributos Modificados A'. Desses, um atributo  $a$  será processado pelo Controlador e ajustado para realimentar o Modelo Preditivo.



**Figura 14.** Diagrama de Blocos ilustrando Controlador e Modelo Preditivo

Seguem as características propostas para a busca por condicionantes de um resultado desejado:

- Nem todas as variáveis de um modelo precisam ser investigadas e as que precisam, podem ser restritas a uma faixa de interesse. Inicialmente devem ser definidas quais variáveis serão investigadas e os limites de exploração para as mesmas.
- Devem ser fixados  $n-1$  valores de variáveis para que se realize a exploração na  $n$ ésima variável. Os valores serão passados pelo modelo para auferir o resultado atual.
- A diferença entre o resultado atual da simulação e o resultado desejado deve ser calculado. É preciso utilizar alguma distância mensurável para guiar a busca. Por exemplo, poder-se-ia utilizar a Distância Euclidiana [Larose05] em alguns casos.
- Baseado no conhecimento acerca da influência de cada variável no modelo, deve ser implementado o cálculo do ajuste. Sugere-se considerar nesse cálculo a distância entre o resultado desejado e o resultado atual. Também, deve-se utilizar a variação da distância a cada iteração, como fator adicional para o ajuste.

- Após realizar um determinado número de iterações, para coletar uma quantidade suficiente de amostras, pode-se iniciar a busca com a variável seguinte.
- O algoritmo pode encerrar a exploração após investigar todas as variáveis determinadas ou prosseguir realizando combinações entre as melhores amostras visando encontrar uma solução ainda melhor.
- Quando o processamento for finalizado, o conjunto de cenários pode ser categorizado de acordo com a abordagem proposta na seção 4.1 e então submetido ao tomador de decisão para análise.

No Estudo de Caso 2 (capítulo 6), que trata da investigação do impacto de decisões no diagnóstico de pacientes cardíacos, foi utilizada uma RNA como modelo que mapeia características do paciente em 5 níveis de risco cardíaco. Um controlador baseado em Lógica Difusa foi implementado para utilizar as idéias expostas nessa seção. Nesse caso, o controlador tem a finalidade de explorar o espaço de decisão e gerar cenários correspondentes a diferentes linhas de tratamento. Detalhes da solução também estão apresentados no Capítulo 6.

## Capítulo 5

# Ciclo de Desenvolvimento do Sistema de Decisão Inteligente Híbrido

Nesse capítulo será abordada a construção do Sistema de Decisão Inteligente Híbrido (SDIH) que é definido de acordo com as partes – técnicas inteligentes - que o compõe. Em seguida, é apresentado o ciclo de desenvolvimento, quando são levantados tópicos e discussões importantes ao longo de suas etapas. Por fim a etapa de Implementação dos seus módulos é detalhada, constituindo-se efetivamente num guia útil para o desenvolvimento de Sistemas híbridos de Apoio à Decisão que empregam tecnologias inteligentes.

### 5.1 Definição e Partes Constituintes do SDIH

No presente trabalho, considera-se um Sistema de Decisão Inteligente Híbrido (SDIH), o sistema composto por: Repositório de Informações, Módulo Preditivo, Módulo Analítico, Módulo Interativo e o próprio Tomador de Decisão (este, externo ao sistema). Destaca-se que a principal contribuição desse modelo é a utilização de técnicas de computação inteligente ao menos nos módulos Analítico e Preditivo. Na Figura 15 pode ser vista a arquitetura do SDIH em uma configuração típica de SDIH, em que as setas indicam o fluxo de informações entre os módulos. É importante destacar que essa arquitetura é flexível, podendo ser adaptada de acordo com o problema.



**Figura 15.** Arquitetura para um Sistema de Decisão Inteligente Híbrido

O Repositório de Informações se destina a armazenar configurações e estatísticas acerca dos demais módulos, que serão fundamentais na sua operação e manutenção. Dentre essas configurações e estatísticas, poderiam estar armazenadas a configuração de Redes Neurais,

parâmetros de controle para Algoritmos Genéticos, bem como suas respectivas taxas de erro, com a finalidade de monitorar seu desempenho e determinar o momento para um possível novo treinamento.

Sistemas Transacionais [Rosini03] são aqueles operados no nível operacional de uma organização, quando não há uma grande complexidade para a solução de problemas. Não há uma preocupação inicial em correlacionar e extrair conhecimento a partir da sua operação. O insumo básico para o funcionamento do SDIH são os dados oriundos de Sistemas Transacionais contidos na organização. Pode ser necessário processar esses dados e manter um Banco de Dados próprio com informações processadas para fácil acesso, constituindo-se em um *DataMart*[Becker02]. Além disso, os parâmetros de decisão e seus resultados na solução dos problemas pode ser armazenado gerando um registro da experiência da organização. Esse registro irá influenciar a operação do SDIH e sugerir para o Tomador de Decisão linhas de atuação que se mostraram efetivas no passado.

O Módulo Preditivo conterá um conjunto de técnicas de Computação Inteligente adequadas para solucionar cada problema, devidamente treinadas e configuradas para auxiliar na geração de cenários futuros. A saída desse módulo freqüentemente é uma lista com Componentes de Decisão, contendo alguns atributos obtidos através da predição. Por exemplo, considerando um conjunto de automóveis para venda numa loja, seria possível após processá-los com o Módulo Preditivo, determinar seu preço daqui a 2 meses. No presente trabalho, utilizaram-se Redes Neurais Artificiais como núcleo do Módulo Preditivo, mas podem ser utilizadas outras técnicas de computação inteligente de acordo com a necessidade.

O Módulo Analítico opera sobre a lista obtida na predição e irá elaborar de modo adequado cenários de decisão. Leva em consideração os critérios de validade e vetor de pesos, para prover funcionalidades como a exploração do espaço de decisão para geração de cenários ou atingir metas. O resultado de seu processamento é um conjunto de cenários possíveis, já categorizados de acordo com os critérios informados. O Módulo Analítico por exemplo, poderia ser utilizado para determinar a partir da lista preditiva, quais carros deveriam ser exibidos na vitrine da loja, a fim de aumentar sua exposição, gerar fluxo de pessoas na loja e aumentar o volume de vendas. Foram utilizados Algoritmos Genéticos e Lógica Difusa como núcleos dos Módulos Analíticos em cada Estudo de Caso, por serem consideradas técnicas apropriadas para cada caso. Considerando a arquitetura flexível do SDIH, é possível utilizar outras técnicas quando se fizer necessário.

O Módulo Interativo consiste na interface com o usuário e mecanismos para gerenciar os diálogos de decisão além de manipular os resultados dos cenários. Além dos diálogos (de decisão) que podem ser adaptados de acordo com o tomador de decisão, destacam-se entre suas facilidades os gráficos, tabelas para ordenação e explicitação, e até mesmo mapas. Frequentemente o Módulo Interativo proverá um meio guiado para entrada dos critérios, priorização dos cenários e por fim a seleção do cenário a ser utilizado.

Nessa visão sistêmica, considera-se que o Tomador de Decisão é de vital importância para o desempenho do SDIH. Ele irá operar e direcionar as simulações de forma que ao longo do tempo, os resultados de suas ações gerem conhecimentos e influenciem o processamento do sistema. Para tanto, o Tomador de Decisão deve possuir o conhecimento sobre o domínio do problema de decisão, e também deve considerar que a ferramenta traz um auxílio de qualidade, estando devidamente adaptada ao seu estilo cognitivo. Entretanto, ele deve entender também que a ferramenta é uma baliza para as suas decisões. Com essas características integradas, ocorre uma melhoria na qualidade do trabalho intelectual, conforme sugerido pela investigação empírica de Moreau [Moreau06].



## 5.2 O Ciclo de Desenvolvimento

O ciclo sugerido nessa seção aborda desde a etapa de Justificação do projeto do SDIH até sua Manutenção. Os tópicos escolhidos foram reunidos de diferentes fontes de conhecimento com o intuito de indicar um caminho que, ao ser trilhado, propicie a obtenção de bons resultados ao final do projeto.

São abordados os fatores que foram considerados mais críticos, sem a intenção de esgotar o assunto. A Tabela 5-1 contém as etapas sugeridas, que são sucessivas e não repetitivas no escopo do mesmo projeto. No entanto, as atividades da etapa de Implementação são cíclicas e contam com esquemas mais detalhados na seção seguinte.

**Tabela 5-1: O Ciclo de Desenvolvimento para o SDIH**

<b>Etapa</b>	<b>Detalhamento</b>
Justificação	Identificação de Oportunidade
	Aquisição da Apoio dos Interessados
	Quebra de Objeções
Planejamento	Definição dos Objetivos do SDIH
	Criação do Plano de Projeto
	Modelagem Abstrata
Implementação	Módulo Preditivo
	Módulo Analítico
	Módulo Interativo
Implantação	Rotinas de Carga do <i>Data-Mart</i>
	Restrições de Acesso e Privilégios no SDIH
	Procedimento de cópia de segurança e restauração
	Treinamento e Suporte
Manutenção	Monitoramento do Repositório de Informações
	Criação de novas versões do SDIH

A etapa de Justificação visa abordar a organização e investigar se há realmente uma oportunidade a ser explorada pelo novo Sistema de Decisão. São fundamentais nessa etapa obter o apoio da alta direção, a determinação de um responsável pelo projeto na organização e por fim a colaboração do Tomador de Decisão.

Dado o alto custo que um projeto de SAD pode alcançar, é preciso justificar muito bem o desenvolvimento de tal iniciativa. Projetos de *Business Intelligence* (BI) em geral, dentre os quais se enquadram os SADs, são motivados por oportunidade mais do que por necessidade [Moss03, pp. 8]. Ou seja, as atividades poderiam ser realizadas sem o sistema, mas teriam seus resultados otimizados com a presença de uma ferramenta de apoio.

Para conseguir uma boa justificativa é ideal alinhar os objetivos do projeto com alvos estratégicos da organização. Como os benefícios oriundos de um SAD não são todos tangíveis, é preciso associar um valor monetário aos mesmos para então fazer uma análise de custo benefício e retorno do investimento. Sem contar com as premissas básicas de apoio da direção e colaboração do agente decisor, o projeto terá seu desempenho resultado fortemente comprometido.

Recomenda-se que seja elaborado um projeto formal na etapa de Planejamento, em que serão explicitados os objetivos, escopo e definição de requisitos básicos do sistema. Considerando que um SIDH depende de informações de qualidade para geração do Módulo

Preditivo, é recomendável que se proceda uma investigação da infra-estrutura sistêmica da organização e uma análise prévia da integridade dos dados e de sua disponibilidade para a equipe de projeto. Apesar de a etapa de Planejamento não ser repetitiva, o plano de projeto gerado nele servirá de base para as etapas de Planejamento e Concepção dos módulos Preditivo, Analítico e Interativo.

O plano de projeto pode ser realizado de acordo com princípios amplamente utilizados no mercado, como os recomendados pelo PMBoK [Lewis05] mas deve trazer adicionalmente a modelagem abstrata conforme indicado no Capítulo 4 e quando apropriado, um planejamento em alto nível dos Módulos Preditivo e Analítico.

Na etapa de implementação será desenvolvido o Repositório de Informações paralelamente aos Módulos Preditivo, Analítico e Interativo. Isso porque o Repositório tem a finalidade de disponibilizar os dados necessários e armazenar as configurações para que os demais módulos operem. Dentro da etapa de implementação, as sub-etapas destinadas à implementação dos três módulos se dá em ciclos para implementar a estratégia: Planeja – Executa – Corrige.

Cada um dos módulos será planejado, sua implementação executada, e em seguida validada pelo Tomador de Decisão. Só é possível passar a sub-etapa seguinte com a anterior aprovada. Por possuírem uma importância fundamental e alinhada com a contribuição desse trabalho, a implementação dos módulos será detalhada na próxima seção.

Na etapa de Implantação, há uma série de fatores a serem considerados para uma utilização eficiente e segura do SDIH. Considerando que se fará uso de um *DataMart* no Repositório de Informações, é preciso garantir que as rotinas de processamento e carga do mesmo que se repetem periodicamente, estejam corretas e registradas no mecanismo utilizado como agendador de tarefas.

Também é essencial garantir que o acesso ao sistema seja restrito ao Tomador de Decisão e à equipe responsável pela manutenção do sistema. Como os SADs operam com informações de interesse tático e estratégico para a organização sua segurança precisa ser assegurada.

Outro tópico a ser considerado são as estratégias de cópia de segurança (*backup*) e restauração do Repositório de Informações e dos aplicativos associados aos Módulos constituintes do SDIH. Apesar de grande parte do Repositório ser composto por informações que poderiam ser recuperadas, o tempo para treinar e configurar os núcleos de IA seria um prejuízo considerável.

Após a instalação do SDIH em seu ambiente de funcionamento é preciso treinar o Tomador de Decisão e preparar a equipe técnica da organização para prover o suporte. Além da documentação básica para uso do sistema, é desejável que se preparem procedimentos operacionais acerca de aspectos que não são visíveis pelo usuário de alto nível, mas que os técnicos de informática precisem lidar.

Por fim, a etapa de Manutenção é ligeiramente diferente daquela observada em sistemas que não utilizam IA. O principal motivo é que as técnicas de IA que constituem os Módulos Preditivo e Analítico são adaptativas, mas possuem uma capacidade de generalização que pode decair após a determinação da configuração inicial.

Assim, é preciso monitorar o Repositório de Informações para verificar até quando a performance das técnicas inteligentes se mantém satisfatória. Quando as taxas de erro estiverem acima do aceitável por um período continuado, é recomendável que se faça um novo treinamento com dados mais recentes, ou mesmo que se ajustem as configurações de técnicas no Módulo Analítico.


Essa atividade pode também ser realizada em períodos pré-determinados para acompanhar as modificações periódicas acerca dos fenômenos estudados. Por exemplo, uma RNA que modela

a maturação de lotes de cana, deveria ser treinada novamente a cada plantio, para garantir que as informações coletadas na última safra sejam incorporadas ao seu modelo de conhecimento.

Também, existe a possibilidade de criar novas versões do Sistema de Apoio, seja para incorporar novas funcionalidades, corrigir erros, ou ainda incorporar novas tecnologias. Portanto, é importante cientificar ao responsável pelo projeto que a manutenção de um SIDH é um processo dinâmico que acompanha todo o seu ciclo de vida.

## 5.3 Detalhamento da Etapa de Implementação

A etapa de Implementação é dividida em sub-etapas as quais são regidas por um ciclo que envolve planejamento, execução do plano e avaliação. A Figura 16 ilustra o relacionamento entre as sub-etapas, levando em consideração que uma modificação em um dos módulos, pode acarretar alterações nos módulos anteriores. O Ciclo se inicia na etapa de Implementação do Módulo Preditivo (a base do SDIH) e as setas indicam a ordem, de execução das etapas em que o resultado de cada etapa é um módulo completo.



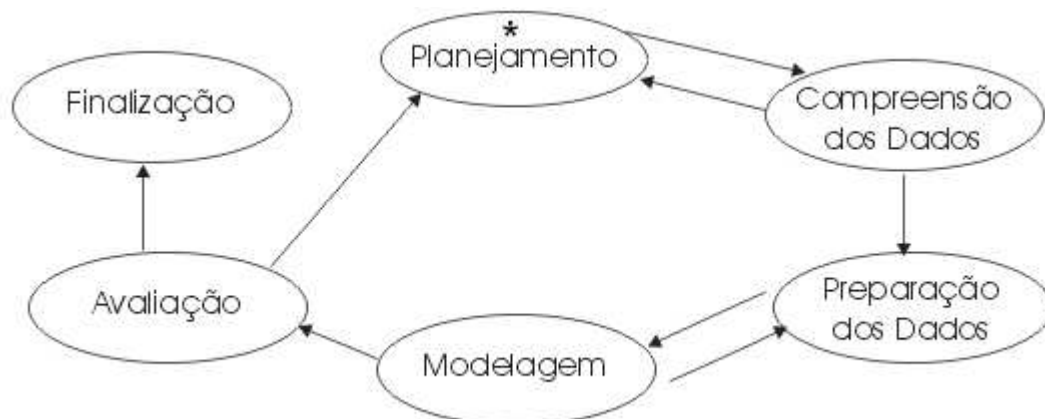
**Figura 16.** Relacionamento entre as sub-etapas de Implementação do SDIH

Por exemplo, modificações no Módulo Preditivo, como uma mudança de técnica pode requerer alterações na informação gerada para o Módulo Analítico que pode requerer informações adicionais advindas do usuário, a partir do Módulo Interativo. Ao voltar para uma etapa anterior, todas as suas sub-etapas devem ser executadas, avaliadas e aprovadas.

### 5.3.1 Implementação do Módulo Preditivo

No processo de tomada de decisão, a redução da incerteza associada a cada possível opção está ligada à geração confiável de cenários, utilizando modelos de simulação. O Módulo Preditivo que é a base do SDIH, emprega esse princípio incorporando técnicas de Computação Inteligente em seu núcleo.

O resultado do processamento do Módulo Preditivo tipicamente será um ou mais componentes de decisão em que alguns atributos terão sido modificados pelo elemento preditivo, conforme indicado no Capítulo 4, Equação 4-1. A Figura 17 ilustra o ciclo de desenvolvimento proposto para o Módulo Preditivo, iniciando na sub-etapa de Planejamento. As setas indicam a ordem de execução e as elipses indicam as sub-etapas realizadas.



**Figura 17.** Ciclo de desenvolvimento para o Módulo Preditivo.

A sub-etapa da Planejamento compreende o estudo do Modelo Abstrato para identificar pontos que poderiam ser aprimorados com o uso de uma ferramenta de IA focada em gerar previsões acerca de componentes de decisão. Deve ser criado um plano para essa sub-etapa, destacando o objetivo do Módulo Preditivo, os riscos associados ao seu desenvolvimento (ex. a falta de dados em quantidade suficiente e qualidade aceitável) e recursos necessários (ex. a presença de pessoal técnico para a sub-etapa de Compreensão dos Dados).

Os dados contidos nas bases de Sistemas Transacionais da organização precisam ser acessados e seu conteúdo compreendido, para uma posterior extração e utilização no treinamento dos modelos. Nessa sub-etapa, o pessoal técnico da organização e a documentação das bases de dados são fundamentais.

A sub-etapa de Preparação dos Dados envolve analisar e transformar a massa de dados obtida num formato apropriado para realizar a modelagem. Larose destaca problemas que são freqüentemente encontrados em bases de dados [Larose05]:

- Atributos obsoletos ou redundantes.
- Valores faltantes.
- Valores com magnitude demasiado maior ou menor do que o esperado em certa situação.
- Dados num formato que precisa ser alterado para treinamento dos modelos.

Também é necessário na sub-etapa de Preparação: (i) integrar informações de diferentes fontes para composição do arquivo de treinamento, (ii) selecionar os atributos (ex. colunas numa tabela) a serem utilizados na modelagem, (iii) remover padrões espúrios, ou seja, retirar elementos que não contribuam para o aprendizado do modelo e (iv) Criar algum mecanismo para lidar com padrões (ex. linhas numa tabela) que contenham valores faltantes. Se esses padrões representarem um pequeno percentual da massa de dados, eles podem ser removidos para simplificar o processo.

A sub-etapa de modelagem envolve utilizar a informação coletada no Planejamento e os dados pré-processados e investigar a possibilidade de uso de diferentes tipos de técnicas visando alcançar os objetivos definidos. No Módulo Preditivo, sugere-se utilizar técnicas com aprendizagem supervisionada, cujo treinamento pressupõe que serão informados o vetor de entradas e as saídas desejadas associadas a cada vetor de entrada. Assim é possível calcular o erro e ajustar o modelo de acordo. No SDIH foi utilizada a rede *Multi Layer Perceptron* (MLP) como núcleo do Módulo Preditivo.

Após selecionar a técnica, os experimentos visando encontrar a configuração mais apropriada para modelar o problema devem ser executados. No trabalho de Buarque [Buarque98] é utilizada uma técnica estatística chamada Planejamento Fatorial, com a finalidade de auxiliar o projetista a encontrar experimentalmente a configuração mais conveniente para o modelo.

O trabalho de Madeiro [Madeiro06] apresenta uma metodologia para utilizar Algoritmos Genéticos para selecionar a configuração que minimiza o erro de Teste de uma Rede Neural. Ou seja, técnicas de IA podem ser utilizadas também para automatizar as simulações na sub-etapa de Modelagem. Os resultados de cada experimento devem ser coletados e uma pré-seleção realizada antes de passar à sub-etapa de Validação.

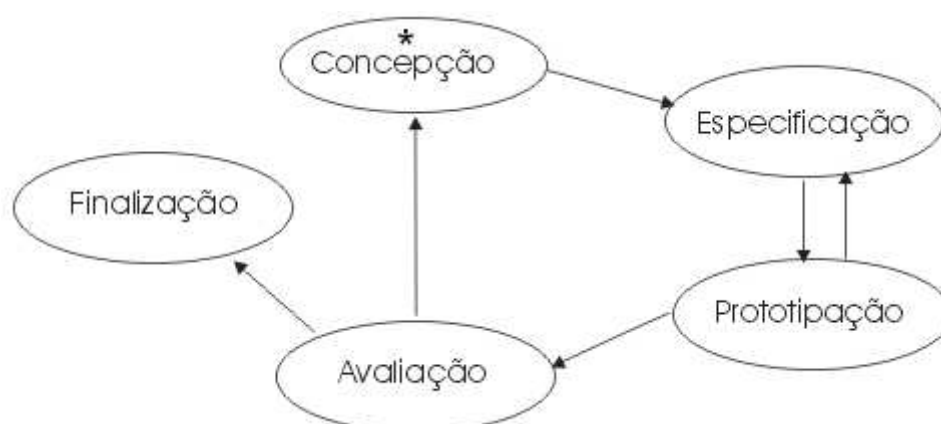
Os melhores modelos serão levados ao conhecimento do Tomador de Decisão na sub-etapa de Avaliação. Nessa sub-etapa, serão levantados os pontos fortes e fracos de cada modelo e sua utilização potencial discutida. Espera-se que o Tomador de Decisão, utilizando seu conhecimento do negócio, auxilie o especialista a selecionar o modelo mais adequado para a sua atividade.

Após a escolha de um dos modelos, a Implementação do Módulo Preditivo estará concluída e se passará ao desenvolvimento do Módulo Analítico. Caso nenhum modelo seja satisfatório, ou se for detectado que algum aspecto de negócio foi negligenciado, deverá ser iniciada uma nova sub-etapa de Planejamento [Crisp-DM07].

### 5.3.2 Implementação do Módulo Analítico

Em geral, o uso do Módulo Preditivo isoladamente auxilia o Tomador de Decisão a realizar projeções futuras acerca de informações que não estariam disponíveis antecipadamente (ex. indicadores de produtividade nos lotes agrícolas). No entanto, de acordo com o número de componentes de decisão envolvidos e as diferentes possibilidades de combinação entre eles, será necessário utilizar mecanismos adicionais para prover funcionalidades de análise.

A finalidade do Módulo Analítico é utilizar a informação gerada no Módulo Preditivo e combina-la de acordo com a necessidade específica do Tomador de Decisão. Na Figura 18 pode ser visto o ciclo de desenvolvimento sugerido para a criação do Módulo Analítico.



**Figura 18.** Ciclo de desenvolvimento para o Módulo Analítico

Na concepção do Módulo Analítico é fundamental entrevistar o Tomador de Decisão e em conjunto com o modelo abstrato obtido na sub-etapa de Planejamento contida na Seção 5.2, deve-se identificar precisamente quais as metas do Módulo Analítico. Por exemplo, em um momento o

objetivo pode ser uma busca combinatorial cujo resultado do processamento será o melhor cenário. Em outro momento, o tomador de decisão pode estar mais interessado em um estudo dos cenários alternativos de decisão. A definição clara de metas e objetivo para este Módulo é de importância crítica para o projeto e a falha na sua definição acarretará uma perda de recursos financeiros e de oportunidades [Rud01, pp. 4].


O passo seguinte é a sub- etapa de Especificação, em que os desejos do usuário devem ser traduzidos num documento, elicitando claramente o objetivo, propondo possíveis soluções e definindo os critérios que definirão o sucesso do protótipo .

Na sub- etapa seguinte, devem ser selecionadas as técnicas inteligentes mais apropriadas para manipular as componentes de decisão e gerar os cenários. A sub- etapa de Prototipação irá se basear no documento produzido na Especificação e testar várias configurações com as técnicas selecionadas. No presente trabalho as técnicas utilizadas como núcleo do Módulo Analítico foram Algoritmos Genéticos para realizar buscas combinatoriais e Lógica Difusa para buscar fatores condicionantes. As simulações devem ser executadas e feito um registro dos seus resultados.

Na sub- etapa de Avaliação, os protótipos criados devem ser apresentados ao Tomador de Decisão que dever auxiliar na escolha do protótipo que será utilizado como núcleo, baseando-se em seu conhecimento do negócio. Após a discussão das vantagens de cada protótipo, o Tomador de Decisão poderá propor melhorias reiniciando a sub- etapa de Concepção ou aprovar o que lhe foi apresentado, finalizando essa sub- etapa e iniciando a sub- etapa de Implementação do Módulo Interativo.

### 5.3.3 Implementação do Módulo Interativo

O Módulo Interativo representa o elo de ligação entre o usuário e os recursos do SDIH. Um tomador de decisão lida com problemas naturalmente complexos e espera que o SAD, traga funcionalidades que facilitem e melhorem o desempenho de suas atividades. Portanto não podem ser utilizadas interfaces de uso complexo e aprendizagem difícil pois se o usuário entender que a ferramenta lhe causa um stress adicional, ele poderá abrir mão de seu benefício aparentemente duvidoso (para ele). Dado o aspecto crítico que o Módulo Interativo possui para o sucesso do projeto do SDIH, seu desenvolvimento merece atenção especial. A Figura 19 ilustra o ciclo de desenvolvimento proposto para a criação do Módulo Interativo.



**Figura 19.** Ciclo de desenvolvimento para o Módulo Interativo

Na sub-etapa de Concepção, serão utilizados como premissa o modelo abstrato de decisão para definir os parâmetros de entrada e o formato dos cenários gerados pelo Módulo Analítico para definir como essas informações serão dispostas. Baseado nessas duas premissas, é preciso definir o formato de diálogo com o usuário dentre as quais destacamos duas das opções propostas por Buarque em [Buarque98]:

- Perguntas e Respostas: A entrada dos dados será feita baseada em questões do sistema feitas acerca do problema. Sua utilização requer um projeto cuidadoso e é indicada nos casos em que há muitas variáveis de decisão, das quais apenas algumas são utilizadas de acordo com a situação.
- Formulários Encadeados: Essa opção é mais simples mas bastante efetiva nos casos em que todas as variáveis de decisão são utilizadas. Também proporciona uma interatividade maior, na medida que a navegação entre as sub-etapas é mais fácil do que no modelo de Perguntas e Respostas.

Após definir o formato das entradas, é necessário planejar a forma de exibição dos dados ao final das simulações. A Tabela 5-2 contém algumas possibilidades de recursos gráficos e indicações para suas aplicações:

**Tabela 5-2:** Recursos gráficos para o Módulo Interativo e Indicações de Aplicação

Recurso	Indicações de Aplicação
Tabelas	Quantidade de informações pequenas, e que requeiram inspeção minuciosa. Além disso, devem ser usadas quando for necessário inspecionar níveis adicionais (ex. uma Decisão $d_k$ e suas Componentes $c_j$ )
Gráficos (ex. Barras, Colunas e Retas)	Indicados para sumarização de grandes volumes de informações, quando a tendência da massa de dados for mais importante do que a individualidade (ex. evolução de um atributo para uma Componente $c_j$ ).
Mapas	Seu uso está associado com a representação espacial dos cenários gerados. Indicado em casos que se deseje representar uma área real ressaltando seus atributos (ex. cores diferentes no mapa da usina de acordo com a qualidade dos lotes)
Indicadores Gráficos (ex. Odômetros, Semáforos e Avatares)	Também usados para sumarização de informações, agregando uma conotação subjetiva à interpretação dos dados. Útil sobretudo no monitoramento para permitir uma interpretação rápida das informações (ex. um semáforo vermelho indicando que há poucos itens em estoque).

Devem ser discutidas as preferências de usabilidade do Tomador de Decisão como a maneira como ele gostaria de utilizar a ajuda e como prefere interagir com o sistema (ex. mouse ou teclado). Por fim, podem ser verificados aspectos estéticos como a cor das telas e a padronização das mensagens de erro e alerta gerados pelo sistema (ex. utilizar sons ou apenas imagens). Essas características podem melhorar bastante a satisfação do Tomador de Decisão no uso do sistema.

Após a sessão conduzida com o Tomador de Decisão, as informações coletadas devem ser traduzidas em requisitos e modeladas na sub-etapa de Especificação. De posse a especificação se

passa ao design do Módulo Interativo que deve buscar a melhor tradução dos requisitos para aquele usuário. Um recurso de interfaces multi-camada proposto por Shneiderman [Schneiderman03] pode ser utilizado para aprimorar a usabilidade do Módulo Interativo. Trata-se de utilizar diferentes níveis de sofisticação nas opções disponíveis de acordo com o nível de proficiência do usuário.

Por exemplo, um médico residente poderia ter poucas opções e parâmetros de simulação num SDIH, permitindo um menor nível de variabilidade na geração de cenários, para priorizar a segurança do paciente. Um médico experiente, que possui maior vivência e casos diagnosticados, poderia utilizar mais opções ao realizar simulações, esperando encontrar maior variabilidade, assumindo que eventuais cenários perigosos serão identificados e não utilizados pelo médico.

Segue então a sub-etapa de Avaliação em que o Tomador de Decisão será apresentado ao sistema em seu formato completo. Ele terá finalmente a visão de como poderá operar o sistema quando estiver implantado. Baseado nessa abordagem prática, o Tomador de Decisão poderá propor melhorias e ajustes de forma consciente, incorporando ao projeto sua visão das funcionalidades que poderão melhorar seu trabalho.

No trabalho de Buarque [Buarque98] é proposta uma metodologia para avaliar a interface com o usuário que pode ser utilizada com sucesso no Módulo Interativo. Nesse método, devem ser atribuídas notas de 0 a 10 aos critérios: (i) Clareza, organização, coerência e coordenação de sub-etapas, (ii) Facilidade de Interação, (iii) Relevância e precisão da informação para o negócio.

Se o Módulo não for aprovado, sua Concepção deverá ser alterada e as demais sub-etapas ajustadas para uma nova avaliação. As notas atribuídas a cada critério na Avaliação podem ser utilizadas para balizar as modificações feitas numa nova Concepção. Se for aprovado, a etapa de Implementação como um todo terá sido completada e o ciclo de desenvolvimento continuará na etapa de Implantação, conforme visto na Seção 5.2.



# Capítulo 6

## Estudos de Caso

O objetivo deste capítulo é aplicar a metodologia e princípios de desenvolvimento propostos e apresentados nos capítulos anteriores e aqui exemplificados em dois estudos de caso. O primeiro, caracteriza-se como uma busca em espaço de decisão complexo, tratando da seleção (*i.e.* colheita) de lotes cultivados com cana-de-açúcar. O segundo estudo de caso trata da busca por condicionantes para avaliação de impacto de decisões no tratamento de pacientes cardíacos. Nos dois estudo de caso, o problema é contextualizado e os objetivos são definidos. Em seguida, a solução de cada um deles é apresentada, ambas baseadas nas propostas dessa monografia. Por fim, os resultados dos experimentos são exibidos, suportando as hipóteses iniciais.

### 6.1 Seleção de Lotes na Colheita da Cana-de-açúcar

#### 6.1.1 Contextualização e Objetivo

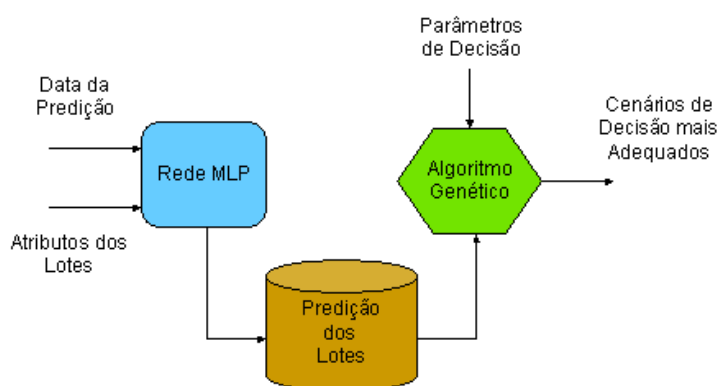
Esse estudo de caso simula a tomada de decisão gerencial numa usina de cana-de-açúcar. Nesse ambiente, a tomada de decisão é complexa por possuir um grande número de alternativas a serem consideradas além das fortes implicações financeiras. Ou seja, escolhas de baixa qualidade irão comprometer grandemente o lucro da empresa ao final da safra. Portanto uma ferramenta de apoio à decisão ajudaria a minimizar a incerteza associada às escolhas do gerente agrícola que nesse caso é o Tomador de Decisão.

O processo de colheita de cana-de-açúcar baseia-se em três indicadores de produtividade: (i) o PCC indica o quanto de açúcar/álcool poderá ser extraído daquele lote, (ii) a Fibra indica o quanto será obtido em termos de massa seca, ou seja, bagaço e (iii) o TCH é a relação toneladas de cana por hectare. Devem ser considerados limites mínimos para os indicadores de produtividade procurando maximizar a lucratividade da colheita. Também deve ser indicada uma mínima tonelage de cana de acordo com a capacidade de processamento da usina, que deve gerar massa seca suficiente para suprir suas necessidades energéticas. Adicionalmente, o gerente agrícola precisa informar o nível de importância de cada um desses parâmetros.

Dando seguimento aos trabalhos de Buarque e Pacheco [Buarque98] [Pacheco06], considerou-se que o processo de tomada de decisão partia de uma predição dos três indicadores de produtividade gerada por uma RNA. Em seguida, uma heurística com Programação Linear era

utilizada para remover os lotes abaixo dos critérios exigidos e acumular os melhores lotes de acordo com as preferências do gerente agrícola, até atingir a tonelagem mínima. O volume de dados usado neste estudo representa valores reais fornecidos por uma usina sucro-alcooleira do interior de São Paulo.

O objetivo desse estudo de caso foi verificar a viabilidade de utilizar uma segunda técnica de CI para conferir flexibilidade à geração de cenários, visando otimizar a logística da colheita. No caso, a otimização logística proposta se materializa com a redução do número de lotes utilizados, atendendo tanto quanto possível às restrições impostas pelo tomador de decisão. Assim os esforços serão concentrados em gerar as previsões com o Módulo Preditivo e aplicar uma heurística de busca utilizando o Módulo Analítico, conforme ilustrado na Figura 20.



**Figura 20.** Esquema da solução proposta para a colheita da cana-de-açúcar

### 6.1.2 Modelando o problema com a Solução Proposta

O melhoramento da administração da colheita (*i.e.* seqüenciamento de lotes a cortar) e logística de sua execução, proporcionaria economia no manejo da mão-de-obra, e também permitiria selecionar lotes que atendessem de maneira global aos requisitos do gerente agrícola. Seria possível então equilibrar os requisitos do campo (ex. picos dos indicadores de produtividade) e da indústria (ex. quantidade de massa seca para atender às necessidades energéticas). A oportunidade do SDIH nesse estudo de caso consiste nessa otimização logística, e nos benefícios derivados da mesma.

Baseado na informação obtida com o gerente agrícola, o SDIH foi planejado como a interação entre o Módulo Preditivo e Analítico. O primeiro para gerar estimativas acerca dos indicadores de produtividade nos lotes, e o último para os combinar de forma flexível a fim de alcançar a otimização logística. O processo decisório foi modelado como se segue:

- $t_k$ , tomador de decisão é o gerente agrícola.
- $c_k$ , componente de decisão é um lote.
- Após investigar a massa de dados disponível para modelagem, decidiu-se caracterizar os atributos de  $c_k$  como  $a_k = (\text{Identificador}, \text{PCC}, \text{Fibra}, \text{TCH})$
- Os critérios de seleção, considerados flexíveis são:  $S = \{\text{PCC Mínimo}, \text{Fibra Mínima}, \text{Tonelagem Desejada}\}$
- Os pesos são dados pelo vetor  $W = \{w_{\text{pcc}}, w_{\text{fibra}}\}$
- As funções de avaliação para PCC e Fibra são dadas pela Equação 6-1 e Equação 6-2 respectivamente. Ambas utilizam o TCH como forma de incorporar a produtividade

do lote na categorização. O denominador das funções realiza sua normalização no intervalo [0..1].

$$f_{pcc}(PCC) = \frac{TCH * PCC}{MAX(TCH * PCC)}$$

**Equação 6-1 :** Função de Avaliação para PCC

$$f_{Fibra}(Fibra) = \frac{TCH * Fibra}{MAX(TCH * Fibra)}$$

**Equação 6-2:** Função de Avaliação para Fibra

- A relevância de uma componente de decisão  $c_j$  é dada pela Equação 6-3, que utiliza os pesos de PCC e Fibra e suas respectivas funções de avaliação.

$$R(c_j) = \frac{f_{Fibra}(Fibra) * w_{Fibra} + f_{PCC}(PCC) * w_{PCC}}{w_{Fibra} + w_{PCC}}$$

**Equação 6-3:** Função da relevância de uma componente de decisão(lote)

- Por fim, a categorização de uma decisão é dada pela Equação 6-4 . A busca combinatorial ocorrerá no sentido de localizar o conjunto de lotes, representado pela decisão  $d_k$  que maximize a função  $F(d_k)$ .

$$F(d_k) = \sum_{j=0}^n R(c_j)$$

**Equação 6-4:** Função de adequação da decisão (conjunto de lotes)

Para o desenvolvimento do módulo Preditivo, foi utilizada a metodologia descrita no trabalho de Pacheco [Pacheco06]. A base de dados da usina sucro-alcooleira do interior de São Paulo foi pré-processada e em seguida modelada utilizando o simulador neural N2M2 (*Neural Network Multi-Modal Simulator*). Da massa de dados originais, foram considerados como atributos de entrada para o modelo: Safra, Estágio de Maturação, Idade do Corte (em dias), Época do Plantio (dia/mês/ano), Época do Corte (dia/mês/ano) e Tipo do Solo. As saídas consideradas foram os 3 indicadores de produtividade: PCC, TCH e Fibra, todos em valores médios.

Após a seleção dos atributos, os dados originais foram pré-processados segundo duas regras básicas, descritas no trabalho de Buarque [Buarque98]:

- A codificação binária foi utilizada para incluir uma conotação quantitativa em algumas variáveis. Por exemplo, Estágio de Maturação e Idade do Corte.
- A codificação unária é utilizada nas variáveis que devem ser consideradas como informação qualitativa. Nesse contexto, a data de plantio e corte de um lote, não devem apresentar uma ordem de grandeza entre si.

Após realizar simulações com diferentes configurações de rede, foi decidido utilizar a mesma configuração utilizada no trabalho de Pacheco [Pacheco06]. Essa decisão foi tomada por considerar que a configuração apresentada por ele, oferece um nível de precisão aceitável. Nessa configuração, são utilizados 16 neurônios na camada escondida, com função de ativação Logística. A RNA foi treinada com uma taxa de aprendizado de 0,1 e com 15000 ciclos. Após a validação considerando essa RNA como a melhor, se obteve o Módulo Preditivo finalizado, capaz de gerar projeções sobre os indicadores de produtividade para os 418 lotes considerados, para uma data informada.

O Módulo Analítico interage com os resultados do Preditivo com a finalidade de atender aos critérios do gerente, procurando minimizar o número de lotes. Para implementar a heurística proposta no Capítulo 4 para buscas combinatoriais, foram escolhidos os Algoritmos Genéticos. Essa escolha se deve a: (i) sua capacidade de buscar em múltiplos níveis de forma adaptativa (ex. combinações com diferentes números de lotes), (ii) a capacidade inerente de guardar informação sobre as melhores soluções e (iii) seu método de avaliação das soluções poderia ser facilmente adaptado para incorporar os critérios do tomador de decisão. Assim, destacam-se as características usadas na implementação do componente modular e parametrizável para Algoritmos Genéticos:

- Foi implementado na linguagem Java, utilizando o ambiente de desenvolvimento Eclipse.
- Os valores de controle para o algoritmo como o tamanho da população e taxa de mutação, são armazenados na classe *Configuration* que possui visibilidade global de seus atributos, que são estáticos.
- A classe principal *Genotipe* utiliza um laço para simular os ciclos evolutivos no método *evolve*.
- Cada etapa do AG, conforme visto na Figura 4, é representada por uma classe contendo um único método, que recebe e retorna um *array* de cromossomos. Por exemplo, há classes específicas para inicializar, cruzar e avaliar cromossomos.
- Na classe *Genotipe*, são instanciadas as classes responsáveis por cada etapa.
- É possível então estender as classes básicas como *Initializer* e *Evaluator* para então utilizar métodos de inicialização e avaliação diferenciados e mais adequados a cada problema de decisão.
- Esse baixo acoplamento e alta especialização entre as classes confere o caráter modular e parametrizável desejável para o componente.

É importante destacar o componente utilizado para a modelagem de decisão, contido no pacote *decisionModel*. Nele está contida a classe *DecisionComponent*, que representa um componente de decisão com seus diversos atributos, e a classe *combinatorialDecisionModel*, que representa e traz métodos para tratar com uma decisão combinatorial (conjunto de componentes de decisão). Destaca-se o método *evaluate* que recebe como entrada um cromossomo, que é portanto abstrato (um *array* binário) e lhe confere o significado específico para o problema, atribuindo seu valor de aptidão. Seguem algumas características específicas utilizadas para parametrizar o componente no primeiro estudo de caso:

- Um cromossomo possui 418 genes, um para cada lote. O estado ativado indica que aquele lote faz parte da decisão.
- Foram utilizadas populações com 50 indivíduos e o algoritmo encerra a busca após 50 gerações.

- No cruzamento, utilizou-se uma taxa de elitismo de 30% e foram realizados cruzamentos de ponto central.
- Todo cromossomo teve estabelecida como chance de sofrer mutação 5% e caso a sofresse, teria um gene sorteado e ativado.
- Na avaliação do cromossomo, foram utilizadas as métricas do modelo abstrato para calcular a adequação da solução.
- Foi utilizado um mecanismo de penalidades cumulativas na aptidão. Cada Critério Flexível não atendido reduziria de 20 a 50% na aptidão daquele cromossomo.

### 6.1.3 Experimentos

Para validar a ferramenta desenvolvida, foram elaborados 5 experimentos cujos valores podem ser vistos na Tabela 6-1 . A heurística baseada em AG foi testada e comparada a uma heurística que utiliza Programação Linear (PL). Nessa heurística, os lotes são ordenados em relação à importância de PCC ou Fibra (pesos). Os lotes que não atendem aos critérios de seleção são eliminados. Em seguida, os lotes válidos são agrupados até que se atinja a tonelagem mínima desejada.


**Tabela 6-1:** Dados utilizados como entrada para os 5 experimentos realizados

Experimento	Peso PCC	Peso Fibra	PCC Mínimo	Fibra Mínima	Ton. Desejada	Data da Predição
1	10	5	16	15	650	15/04
2	5	5	15	15	500	15/05
3	5	10	15	15	600	15/06
4	7	3	14	13	450	15/07
5	3	7	14	15	500	15/08


Na Figura 21, pode-se observar que o número de lotes necessários para atender aos critérios do tomador de decisão foi menor ao utilizar Algoritmos Genéticos(AG). Destacam-se o experimento 1 com uma redução de 3 lotes, e o experimento 5 com uma redução de 4 lotes.

A Figura 22 e 23, representam os resultados de PCC e Fibra em cada experimento. É possível observar que os resultados obtidos pelos AG foram compatíveis com a heurística de PL. Nota-se que a heurística de PL nesses casos privilegiou melhores resultados, em detrimento da otimização logística.

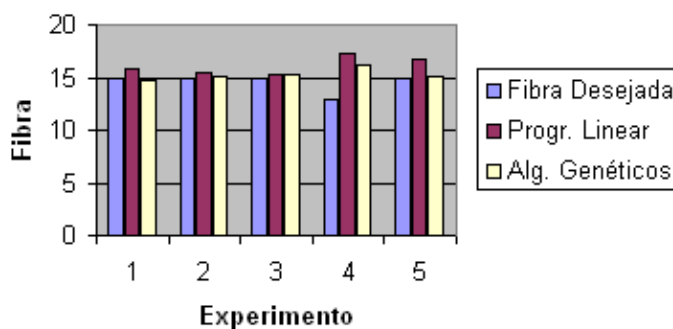
Na Figura 24 foi exibida a relação entre toneladas de cana desejadas, e os resultados obtidos por PL e AG. Nota-se que os AG obtiveram um ajuste melhor ao valor desejado pelo gerente agrícola. Essa característica é importante pois as usinas possuem uma capacidade de processamento limitada. Quando houver um excedente entre o total de cana colhida e a quantidade processada, haverá uma queda da qualidade nesse excedente, que sofrerá uma degradação enquanto aguarda no pátio para posterior moagem.




**Figura 21.** Número de Lotes em cada experimento, utilizando Programação Linear e Algoritmos Genéticos



**Figura 22.** PCC em cada experimento, utilizando Programação Linear e Algoritmos Genéticos



**Figura 23.** Fibra em cada experimento, utilizando Programação Linear e Algoritmos Genéticos



**Figura 24.** Toneladas de Cana em cada experimento, utilizando Programação Linear e Algoritmos Genéticos

De acordo com o exposto, a ferramenta utilizando AG e RNAs nos Módulos Analítico e Preditivo trouxe uma contribuição tangível ao tomador de decisão. Essa instância do HIDS possibilitou uma redução no número de lotes e atendeu aos requisitos do gerente agrícola de maneira consistente.

## 6.2 Investigação do Impacto de Decisões no Tratamento de Pacientes Cardíacos

### 6.2.1 Contextualização e Objetivo


Nesse estudo de caso foi simulada a tomada de decisão realizada por um médico, quando opta por um tratamento para um determinado paciente cardíaco. Essa situação torna-se complexa, pois a tomada de decisão deve ser o mais precisa possível, dado que as conseqüências para o paciente podem ser irreversíveis. Frequentemente, o único recurso à disposição do médico é sua própria experiência em situações similares. Uma ferramenta de auxílio seria duplamente importante: (i) para investigar possíveis linhas de tratamento e (ii) simular de antemão as conseqüências da decisão em relação ao nível de risco cardíaco para o paciente.

O processo de tomada de decisão nesse caso, estaria relacionado a obter uma classificação de risco para o paciente, e em seguida realizar projeções usando variações nos níveis de colesterol (sc) e na máxima frequência cardíaca (mhr). Baseado nas projeções, o médico poderia determinar a linha de tratamento mais eficaz para aquele paciente: uma dieta e medicação para reduzir o nível de colesterol ou um regime de exercícios, que visa ampliar a frequência máxima para melhorar a saúde cardíaca.

Utilizando seu conhecimento sobre o histórico do paciente e também sua experiência em situações similares, o médico pode informar limites para a busca nessas variáveis e também informar a importância de cada uma para alcançar um estado de risco satisfatório (situação controlada). Por exemplo, um paciente jovem com indicação de risco elevado, poderia se beneficiar de melhores hábitos alimentares e exercícios regulares. Já um paciente idoso com problemas nas articulações, teria maior dificuldade para realizar exercícios. Assim, o médico é capaz de utilizar seu conhecimento para guiar a ferramenta de apoio. Para as simulações, foi utilizada a base de dados *heart* do repositório Proben1 [Prechelt94].

A ferramenta de apoio nesse caso deve realizar uma exploração dos condicionantes para mensurar o impacto da alteração de cada variável no nível de risco. Os cenários produzidos ilustrariam a progressão de melhoria do paciente em relação a cada variável, com o objetivo de ao final, selecionar a opção que traz a maior melhora com o menor esforço (ou no menor tempo).

O objetivo desse estudo de caso é modelar o diagnóstico de pacientes cardíacos utilizando o Módulo Preditivo e em seguida, investigar possibilidades de utilização do Módulo Analítico para prover a capacidade de exploração adaptativa conforme explicitado no Capítulo 4. Essa exploração dinâmica, resultado do arranjo ilustrado na Figura 25, será então comparada a uma exploração utilizando busca exaustiva.



**Figura 25.** Esquema da solução proposta para a investigação de impacto em pacientes cardíacos

### 6.2.2 Modelando o problema com a Solução Proposta

O diagnóstico de pacientes cardíacos poderia ter sua qualidade melhorada se fosse possível estimar antecipadamente seu nível de risco e realizar projeções acerca de linhas de tratamento. A configuração do SDIH implementado nesse estudo de caso se destina a reduzir a incerteza na seleção da linha de tratamento mais eficaz de acordo com as condições do paciente e a experiência do médico. O processo de decisão foi modelado considerando os elementos seguintes:

- $t_k$ , tomador de decisão é o médico
- $c_k$ , componente de decisão é um paciente.
- Os atributos de  $c_k$  são  $a_k = (\text{Idade, Sexo, Dor Cardíaca, Pressão em Repouso, Colesterol, Açúcar em Jejum, Resultados Eletrocardiográficos em Repouso, Máxima Freqüência Cardíaca, Angina Induzida por Exercício})$ . Os atributos manipulados nas simulações são Colesterol (*Serum Cholesterol* –  $sc$ ) e Máxima Freqüência Cardíaca (*Maximum Heart Rate* –  $mhr$ ).
- Os Critérios de Seleção, considerados rígidos são:  $S = \{\text{Máximo } mhr \text{ e Mínimo } sc\}$
- Os pesos são dados pelo vetor  $W = \{w_{sc}, w_{mhr}\}$
- As funções de avaliação para  $sc$  e  $mhr$  são dadas pela Equação 6-5 e Equação 6-6 respectivamente. Ambas avaliam a distância entre o estado inicial e final de cada variável no paciente.

$$f_{sc}(sc_i) = sc_{final} - sc_{inicial}$$

**Equação 6-5 :** Função de avaliação para colesterol ( $sc$ )

$$f_{mhr}(mhr_i) = mhr_{final} - mhr_{inicial}$$

**Equação 6-6:** Função de avaliação para Máxima Freqüência Cardíaca ( $mhr$ )

- A relevância de cada componente  $C_j$  é dada pela Equação 6-7 e utiliza os pesos de  $sc$  e  $mhr$  bem como os resultados de suas funções de avaliação.



$$R(C_j) = \frac{f_{sc}(sc_i) * w_{sc} + f_{mhr}(mhr_i) * w_{mhr}}{w_{sc} + w_{mhr}}$$

**Equação 6-7:** Cálculo da relevância para uma componente de decisão  $C_j$  (estado futuro do paciente)

- A categorização de uma decisão é feita utilizando a Equação 6-8 . Nesse caso, foi usada uma adaptação da Equação 4-3. Essa equação assume o formato abaixo pois cada decisão possui apenas um componente e o valor de sua adequação é inversamente proporcional à relevância da componente. A busca por condicionantes ocorrerá no sentido de encontrar a decisão  $d_k$  (estado futuro do paciente) que maximize a função  $F(d_k)$ .

$$F(d_k) = \frac{1}{R(C_j)}$$

**Equação 6-8:** Função de Adequação para uma decisão  $d_k$  (estado futuro do paciente)

A massa de dados original *heart* disponível no repositório Proben1[Prechelt94] foi utilizada como base para gerar o modelo contido no Módulo Preditivo. Novamente foi utilizado o simulador neural N2M2 para realizar a modelagem. Foram considerados os atributos Idade, Sexo, Dor Cardíaca, Pressão em Repouso, Colesterol, Açúcar em Jejum, Resultados Eletrocardiográficos em Repouso, Máxima Frequência Cardíaca, Angina Induzida por Exercício como entradas da RNA. A única saída considerada foi o nível de risco cardíaco, que foi decomposto em níveis de acordo com a Tabela 6-2 .

**Tabela 6-2:** Codificação dos Níveis de Risco Cardíaco na base *heart* em Proben1 [Whitley94]

Nível de Risco	Valor Correspondente
0	0,1
1	0,6
2	0,7
3	0,8
4	0,9

O pré-processamento foi realizado de acordo com os critérios contidos no repositório de dados. As regras foram: (i) atributos mensuráveis foram normalizados no intervalo [0..1], (ii) atributos qualitativos foram transformados de acordo com codificação unária, (iii) um dígito binário foi utilizado para indicar se cada atributo estava presente ou não naquele padrão (linha). Após realizar algumas simulações, a RNA com melhor desempenho foi a que empregava a seguinte configuração:

- 8 neurônios na camada escondida com Função de Ativação Logística
- Para o treinamento, foi utilizada uma taxa de aprendizagem de 0,01 e 15000 ciclos.

Ao fim dessa etapa, foi possível utilizar o Módulo Preditivo para gerar projeções sobre os pacientes, manipulando *sc* e *mhr* para obter o nível de risco correspondente.

O Módulo Preditivo será controlado de forma adaptativa pelo Controlador Baseado em Lógica Difusa (CBLD), contido no Módulo Analítico. O uso de Lógica Difusa foi escolhido por: (i) sua capacidade de tratar de forma eficaz variáveis cujos limites não são bem definidos e (ii) pela forma com que trata problemas de controle, criando um controlador adaptativo a partir de elementos simples de fácil implementação. O Controlador gera ajustes para as variáveis *sc* e *mhr* de acordo com o nível de risco do paciente em cada simulação.

Assim, destacam-se as características usadas na implementação do componente modular e parametrizável para um CBLD:

- O CBLD foi implementado na linguagem Java utilizando o ambiente de desenvolvimento Eclipse.
- A classe principal chamada *FuzzyEngine* armazena o erro da última iteração de controle, importante nos cálculos e três instâncias de classes: (i) *InputMembership*, que realiza a fuzzificação, (ii) *RuleMatrix* que realiza os cálculos das regras e (iii) *OutputMembership* que utiliza as saídas das regras para calcular o valor do ajuste (defuzzificação).
- A classe *InputMembership* recebe o erro e a variação do erro e retorna dois *arrays* contendo os graus de pertinência para o erro e a variação do erro.
- A classe *RuleMatrix* recebe os *arrays* e calcula forças de disparo, combinando os graus de pertinência de entrada, realizando a operação *ou* da Lógica Difusa.
- Por fim a classe *OutputMembership* combina as forças de disparo oriundas do processamento das regras e calcula o valor de saída, utilizado para ajustar as variáveis do modelo.
- Utilizando essa arquitetura, as três classes supracitadas podem ser estendidas (parametrizadas) para incorporar características específicas de cada problema. Por exemplo, é possível fuzzificar utilizando funções de pertinência com formatos diferentes, usar outras regras ou ainda utilizar outro método para defuzzificar.

Os cenários resultantes, que são possíveis estados do paciente após o tratamento, são avaliados de acordo com o Modelo de Decisão que se destina a implementar as métricas apresentadas na modelagem abstrata. Dentre os detalhes utilizados nos experimentos, destacam-se:

- A exploração foi conduzida para cada variável de forma adaptativa, do valor inicial do paciente indo até o Máximo *mhr* e Mínimo *sc*.
- O ajuste é calculado levando em consideração o erro e a variação do erro entre o nível de risco atual e o nível de risco inferior. Assim, de acordo com a adaptação é possível explorar o espaço de decisão mais livremente, na medida em que um estado final de risco não é determinado explicitamente pelo médico.
- O valor do ajuste é calculado no intervalo  $[-100..100]$ , mas é parametrizado (dividido por 1000) antes de ser usado para recalculer o valor da variável explorada. Essa parametrização resultou nos melhores resultados durante as simulações preliminares do Módulo Analítico.
- A exploração continua até que os limites informados para *mhr* e *sc* sejam atingidos.
- Ao final da simulação, os cenários obtidos são agrupados e aqueles que não atenderem aos critérios de seleção **S** serão eliminados.

- Os demais cenários são classificados de acordo com a função de adequação  $F(d_k)$ , ordenados e informados ao médico para auxiliar em seu processo de seleção do tratamento mais adequado.

### 6.2.3 Experimentos

Para validar a implementação do SDIH nesse estudo de caso, foi implementado um programa de testes, que realiza uma busca exaustiva manipulando o Módulo Preditivo. Seu mecanismo consiste em aumentar ou reduzir cada variável a ser explorada, partindo do ponto onde o paciente se encontra e ajustando até alcançar os limites de *sc* e *mhr*. Após algumas simulações iniciais, se decidiu utilizar o valor de ajuste constante igual a 0,001 para prover uma investigação suficientemente detalhada.

É possível ver na Tabela 6-3 os atributos de 5 pacientes escolhidos na base de dados para verificar a hipótese de que é possível realizar uma busca eficaz, utilizando a heurística de busca por condicionantes apresentada no Capítulo 4. O Módulo Analítico foi testado em conjunto com o programa de testes e os resultados são apresentados na Tabela 6-4.

**Tabela 6-3:** Atributos dos pacientes sujeitos à diagnose de risco cardíaco

Paciente	sc	mhr	Peso sc	Peso mhr	Risco Cardíaco
1	0,4166	0,4666	3	7	0,6371
2	0,7000	0,2000	5	3	0,8095
3	0,2916	0,1466	5	5	0,7122
4	0,2500	0,3200	4	6	0,8000
5	0,5000	0,4000	7	3	0,7000

**Tabela 6-4 :** Resultados das simulações de tratamento com os 5 pacientes

Paciente	Tipo de Busca	Número de Cenários		Menor Risco Cardíaco	
		sc	mhr	sc	mhr
1	CBLD	10	8	0,5995	0,5514
	Busca Exaustiva	216	333	0,5978	0,5459
2	CBLD	18	21	0,7777	0,7559
	Busca Exaustiva	499	599	0,7776	0,7635
3	CBLD	5	26	0,7046	0,5224
	Busca Exaustiva	91	653	0,7041	0,5171
4	CBLD	3	14	0,4789	0,4639
	Busca Exaustiva	49	479	0,4785	0,4633
5	CBLD	13	10	0,6281	0,6494
	Busca Exaustiva	299	399	0,6278	0,6491

Ao analisar os resultados da Tabela 6-4, observa-se que o SDIH foi capaz de explorar o espaço de busca, encontrando situações que realmente reduziriam o risco dos 5 pacientes. O principal resultado favorável para a heurística utilizando o CBLD, é que foi possível realizar uma exploração compatível com uma busca exaustiva, mas utilizando uma quantidade significativamente menor de cenários.

Portanto, o SDIH utilizando uma RNA no Módulo Preditivo e um CBLD no Analítico, constituiu-se numa ferramenta de apoio útil ao médico na investigação do impacto de decisões sobre o tratamento de pacientes cardíacos. A heurística desenvolvida, realizando uma exploração dinâmica, mostrou potencial para tratar problemas de maior dimensionalidade, dado o reduzido número de cenários necessários para encontrar resultados satisfatórios dentre o espaço de decisão.

# Capítulo 7

## Conclusão

Esse capítulo sumariza a contribuição do trabalho, destacando a modelagem abstrata para o Processo Decisório, os métodos de busca e os dois estudos de caso. Também é feita uma discussão crítica acerca do trabalho como um todo e por fim são feitas considerações e sugestões para trabalhos futuros.

### 7.1 Resumo da Contribuição

Esse trabalho foi realizado levando em consideração os estudos anteriores de Buarque e Pacheco [Buarque98][Pacheco06], que utilizaram uma Rede Neural Artificial como base para um SAD. A hipótese investigada foi a viabilidade de se utilizar uma segunda técnica de IA para melhorar o desempenho do sistema no Suporte à Decisão, especialmente em problemas complexos.

Como não se identificou uma abordagem para modelar problemas de decisão com o detalhamento necessário para o problema proposto, foi desenvolvido um modelo abstrato, estendendo as características descritas no trabalho anterior de Oliveira [Oliveira06] Também foi proposta uma metodologia para realizar buscas combinatoriais e busca por fatores condicionantes, ambos julgados necessários para área de Suporte à Decisão.

Adicionalmente foi proposto um ciclo de desenvolvimento para o chamado SDIH, Sistema de Decisão Inteligente Híbrido. Além disso, foram tratados aspectos como: justificação, detalhes de implementação dos módulos componentes e fornecidas considerações sobre a manutenção do sistema. Isto pois, SADs que utilizam CI diferem dos sistemas desenvolvidos com computação convencional.

Os dois estudos de caso mostraram utilizações práticas da abordagem, e seus resultados suportaram a hipótese inicial – que sistemas inteligentes híbridos, especialmente construídos para apoiar a decisão, reduziriam a incerteza acerca do processo decisório. Na seleção de lotes para colheita da cana-de-açúcar, foi possível otimizar a logística do processo, agrupando os lotes de forma flexível. No estudo de linhas de tratamento para pacientes cardíacos, a ferramenta se mostrou útil para gerar cenários indicativos de opções de tratamento viáveis para reduzir o nível de risco do paciente.

## 7.2 Discussão

A abordagem foi proposta de forma abstrata, não considerando diretamente as técnicas que as implementariam. Essa preocupação se deve ao fato de que a área de IA é profusa em novas técnicas, e extremamente dinâmica, de forma que a vinculação direta da abordagem a qualquer uma delas poderia limita-la. Assim, optou-se por não realizar vinculações diretas, da abordagem com alguma técnica de CI específica; o resultado foi uma maior liberdade de seleção e adequação da abordagem aos diversos problemas de decisão.

Os estudos de caso visaram aplicar a abordagem proposta trazendo uma aplicação prática do que foi exposto até o Capítulo 5. Apesar de baseadas em investigações prévias e realizadas de forma a simular aplicações reais, os estudos seriam bastante enriquecidos se tivessem contado com o apoio de especialistas externos. Por isso, foram enfocados apenas os Módulos Analítico e Preditivo para comprovar a hipótese do trabalho, mas sem prejuízo das propostas acerca do Repositório de Informações e Módulo Interativo.

Os resultados obtidos experimentalmente indicaram que os sistemas produzidos são consistentes e que reduziriam a incerteza acerca das decisões se utilizados em situações reais.

## 7.3 Trabalhos Futuros

Os componentes de software desenvolvidos foram aplicações diretas para essa monografia. Uma possível linha de trabalho seria estender esses componentes e torná-los uma API mais completa para incorporar a modelagem da decisão, e a criação dos Módulos Preditivo, Analítico e Interativo.

Por fim, destaca-se que utilizar CI no Módulo Interativo e Repositório de Informações traria uma completude maior à proposta do SDIH. Isso porque seria possível incorporar uma qualidade muito mais alta nas interações do usuário com o sistema, personalizando melhor a interface e oferecendo opções de acordo com a situação atual. A gestão do conhecimento gerado através dos resultados das decisões tomadas, poderia então ser utilizada ativamente nos demais módulos para guiar as ações futuras.

O ciclo de desenvolvimento poderia ser melhorado ao aprofundar suas explicações em termos de artefatos e papéis mais bem definidos. Para validar sua utilização seria interessante realizar experimentos acerca da utilização do método para desenvolver diferentes instâncias do SDIH.

## Referências

- [Becker02] BECKER, Shirley. *Data Warehousing and Web Engineering*. 1. ed. IRM Press, 2002. 300 p.
- [Buarque98] LIMA NETO, Fernando B. de. *Suporte à decisão gerencial baseado em redes neurais artificiais - nDSS*. Dissertação de Mestrado – Departamento de Informática, Universidade Federal de Pernambuco, Recife. 1998.
- [Crisp-DM07] *CRoss Industry Standart Process for Data Mining*. Disponível em <http://www.crisp-dm.org/download.htm> . Acesso em Maio de 2007.
- [Edwards92] EDWARDS, J.S. *Experts systems in management and administration. Are they really different from decision support systems?*. European Journal of Operational Research, n. 61, p.114–121, 1992.
- [Haupt04] HAUPT, Randy L. e HAUPT, Sue E. *Practical Genetic Algorithms*. 2. ed. Wiley-Interscience, 2004.
- [Haykin94] HAYKIN, S. *Neural Networks – A Comprehensive Foundation*. Prentice-Hall International Editions, NJ, USA, 1994.
- [Jain96] JAIN, A. K.; MAO, J. e MOHIUDDIN, K. M. *Artificial Neural Networks: A Tutorial*. IEEE Computer, Março 1996, 31-44.
- [Larose05] LAROSE, Daniel T. *Discovering knowledge in data: an introduction to data mining*. 1. ed. John Wiley & Sons, 2005. 217 p.
- [Laudon00] LAUDON, Kenneth C. e LAUDON, Jane P. *Management information systems: organization and technology in the networked enterprise*. 6.ed. Prentice-Hall, New Jersey, 2000.
- [Lee06] LEE, K.W. e HUH, S.Y. *A model-solver integration framework for autonomous and intelligent model solution*. Decision Support Systems, n. 42, pp. 926–944, 2006
- [Lewis05] LEWIS, James P. e DUDLEY, Robert E. *The McGraw-Hill Guide to the PMP Exam*. 1. ed. McGraw-Hill Professional, 2005. 435 p.
- [Madeiro06] MADEIRO, Salomão S.; OLIVEIRA, Flávio R. S. e ALEXANDRE, Frederico B. A. *Intelligent Modelling of Sugarcane Maturation*. Proceedings of World Congress on Computers in Agriculture, 2006, Orlando, Florida.
- [Moreau06] MOREAU, Eliane. *The impact of intelligent decision support systems on intellectual task success: An empirical investigation*. Decision Support Systems, n. 42, p. 593-607, 2006.
- [Moss03] MOSS, Larissa T. e ATRE, Shaku. *Business Intelligence Roadmap: The Complete Project Lifecycle for Decision-Support Applications*. 1.ed. Addison Wesley, 2003. 576 p.
- [Oliveira06] OLIVEIRA, Flávio R. S.; PACHECO, Diogo F.; LEONEL, Amanda e LIMA NETO, Fernando B. *Intelligent Decision Support in Sugarcane Harvest*. Proceedings of World Congress on Computers in Agriculture, 2006, Orlando, Florida.
- [Pacheco06] PACHECO, Diogo F. *Suporte à Decisão em Sistemas Inteligentes de Colheitas Agrícolas*. Monografia de Graduação – Departamento de Sistemas Computacionais, Universidade de Pernambuco, Recife. 2006.

- [Prechelt94] PRECHELT, Lutz. *PROBEN1- A Set of Benchmarks and Benchmarking Rules for Neural Network Training Algorithms*. Technical Report 21/94, Fakultät für Informatik, Universität Karlsruhe, Germany, 1994.
- [Rosini03] ROSINI, Alessandro M. e PALMISSANO, Angelo. *Administração de Sistemas da Informação e a gestão do conhecimento*. 1.ed. Pioneira Thomson Learning, 2003. 233p.
- [Rud01] RUD, Olivia P. *Data Mining CookBook. Modeling Data for Marketing, Risk and Customer Relationship Management*. 1.ed. Wiley Computer Publishing, 2001. 367p.
- [Rumelhart86] RUMELHART, D. E.; HINTON, G. E. e WILLIAMS, R. J. *Learning internal representations by error propagation*. In: D.E. RUMELHART and J.L. MC-CLELLAND (Eds.): *Parallel Distributed Processing Vol 1*. MIT Press, Cambridge, 318-362. 1986.
- [Sandri99] SANDRI, Sandra e CORREA, Cláudio. *Lógica Nebulosa*. Escola de Redes Neurais, n. 5, pp. 73-90, 1999.
- [Schneiderman03] SCHNEIDERMAN, Ben. *Promoting Universal Usability with Multi-Layer Interface Design*. Proceedings of ACM Conference on Universal usability, 2003, British Columbia, Canada.
- [Simon60] SIMON, H. A. *The new science of management decisions*, Harper & ROW, New York, 1960.
- [Tarantola05] TARANTOLA, Albert. *Inverse Problem Theory and Methods for Model Parameter Estimation*. 1. ed. Society for Industrial and Applied Mathematics, 2005. 333 p.
- [Turban95] TURBAN, E. *Decision Support Systems and Expert Systems*, 4. ed., Prentice-Hall International Editions, NJ, USA, 1995.
- [Wang96] WANG, Li-Xin. *A course in fuzzy systems and control*. Prentice-Hall, Inc. Upper Saddle River, NJ, USA, 1996
- [Whitley94] WHITLEY, Darrel. *A Genetic Algorithm Tutorial*. Statistics and Computing, n. 4, p. 65-85, 1994.
- [Zadeh65] ZADEH, L.A. *Fuzzy sets*. Fuzzy Sets, Information and Control, n. 8, pp. 338-353, 1965.