

Sistemas Fuzzy Genéticos

Prof. Matheus Giovanni Pires

mgpires@ecomp.uefs.br

Laboratório de Sistemas Inteligentes e Cognitivos – LASIC

<http://sites.ecomp.uefs.br/lasic>



Sumário

- ~~Algoritmos Genéticos~~
- Lógica Fuzzy
- Sistemas Baseados em Regras Fuzzy
- Sistemas Fuzzy Genéticos
- O Futuro das Pesquisas em Sistemas Fuzzy Genéticos

Lógica Fuzzy: Introdução

- Metodologia capaz de capturar informações vagas, em geral descritas em uma linguagem natural, e convertê-las para um formato numérico.
- Exemplo:
 - O tempo está muito ensolarado.
 - Hoje está um pouco nublado.
 - Garçom, traga-me uma picanha mal passada.
- Quando o ser humano utiliza termos, tais como, um pouco, mais ou menos, não muito, etc., ele infere um grau de verdade, ou seja, entre as certezas de ser ou não ser, existem infinitos graus de incerteza.

Lógica Fuzzy: Introdução

- Os valores que definem o grau de verdade de uma proposição podem ser definidos pelo contexto social, linguístico ou uma base de referência experimental.
- Na Lógica Fuzzy, a representação destes termos e valores ocorre por meio do uso de Conjuntos Fuzzy.

Conjuntos Fuzzy




- A teoria dos Conjuntos Fuzzy e os conceitos envolvendo Lógica Fuzzy foram definidos por Lotfi A. Zadeh, em 1965.
- Podem ser usados para traduzir em termos matemáticos a informação imprecisa expressa por um conjunto de regras linguísticas.
- Um conjunto Fuzzy é definido como uma coleção de objetos com valores de pertinência entre zero (exclusão completa) e um (inclusão completa).

Conjuntos Fuzzy

- Este mapeamento é formalmente definido como:


$$\mu_A(x) : U \rightarrow [0, 1]; \quad x \in U$$

- $\mu_A(x)$ representa o grau de pertinência do elemento x , pertencente ao universo de discurso U , em relação ao conjunto Fuzzy A .
- Os gráficos das funções podem ter diferentes formas e propriedades.
 - As mais comuns são Triangular, Trapezoidal e Gaussiana.




Conjuntos Fuzzy

- Exemplo: conjunto Fuzzy "pessoa alta"



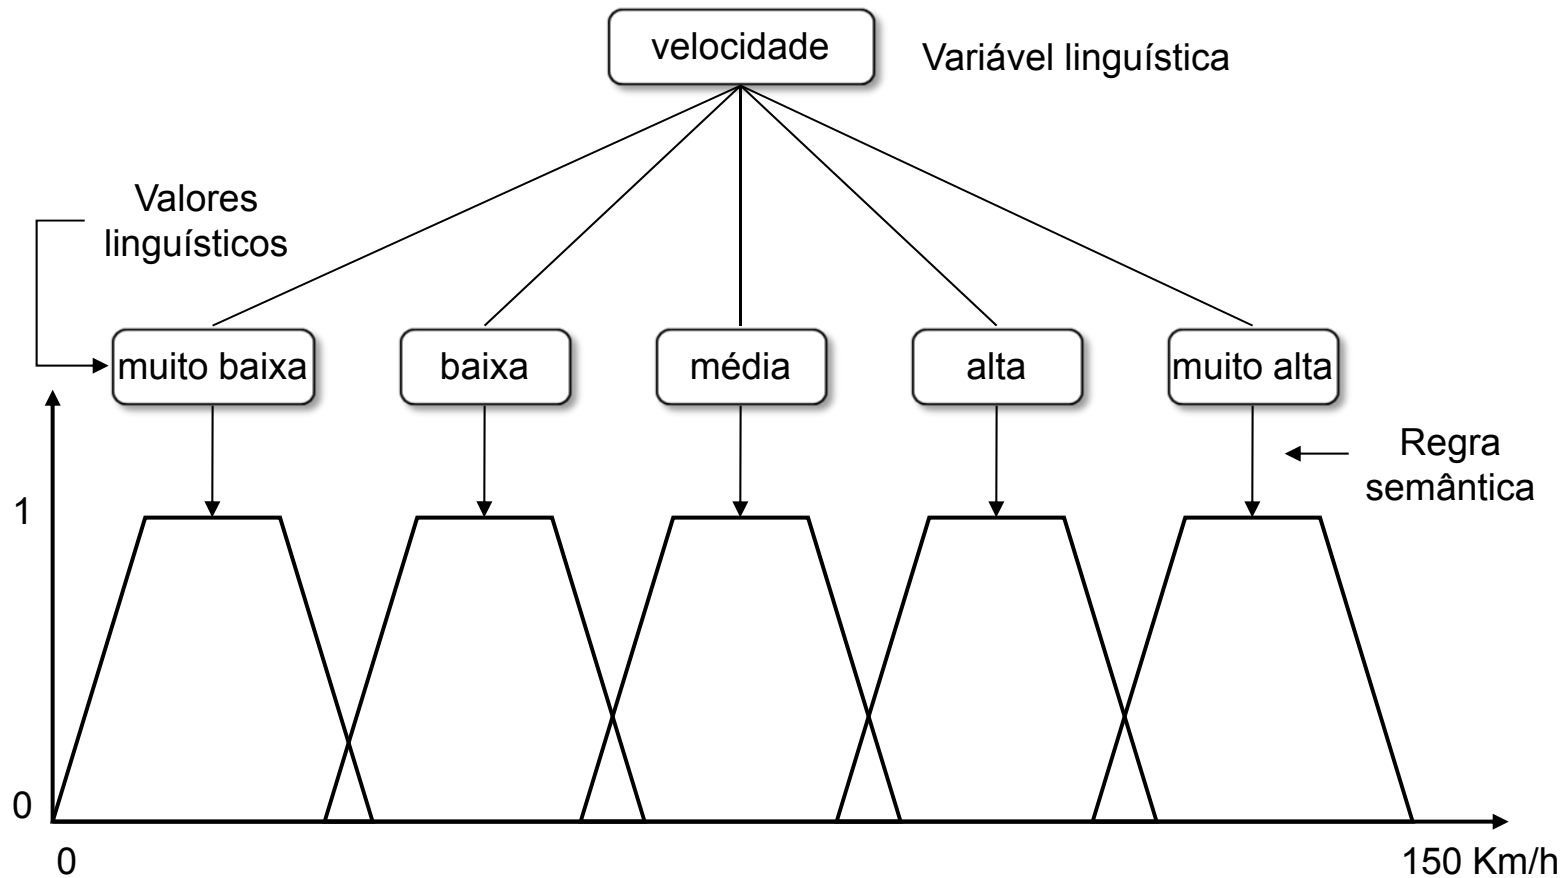
Lógica Clássica

- Na lógica clássica os objetos são classificados em categorias bem definidas
 - Um objeto pertence ou não a uma determinada categoria
 - Exemplo: conjunto “pessoa alta”




$$\mu_A(x) = \begin{cases} 1 & \text{se } x \geq 1,9 \\ 0 & \text{se } x < 1,9 \end{cases}$$

Variável Linguística



Granularidade

- O número de valores linguísticos define a *granularidade*
 - Um número pequeno de termos linguísticos define uma partição esparsa ou grossa, ao passo que um número maior resulta numa partição fina



Sistemas Fuzzy

- Têm sido aplicados com sucesso em diversas áreas, tais como, problemas de controle, classificação de padrões, mineração de dados, diagnóstico médico, entre outras.
- Faz-se o uso da Lógica Fuzzy para o tratamento de informações imprecisas descritas em linguagem natural.
- Sistemas que imitam a habilidade humana de tomar decisões racionais em ambientes de incerteza e imprecisão.

Sistemas Baseados em Regras Fuzzy

- Sistemas Baseados em Regras Fuzzy (SBRF) constituem uma extensão dos sistemas clássicos baseados em regras.
- Tanto os antecedentes quanto os consequentes das regras são compostos por Conjuntos Fuzzy.

SE tem_molho E molho = doce
ENTÃO melhor_docura = médio com fator_certeza = 0.4

SE tem_molho E molho = doce
ENTÃO melhor_docura = doce com fator_certeza = 0.9

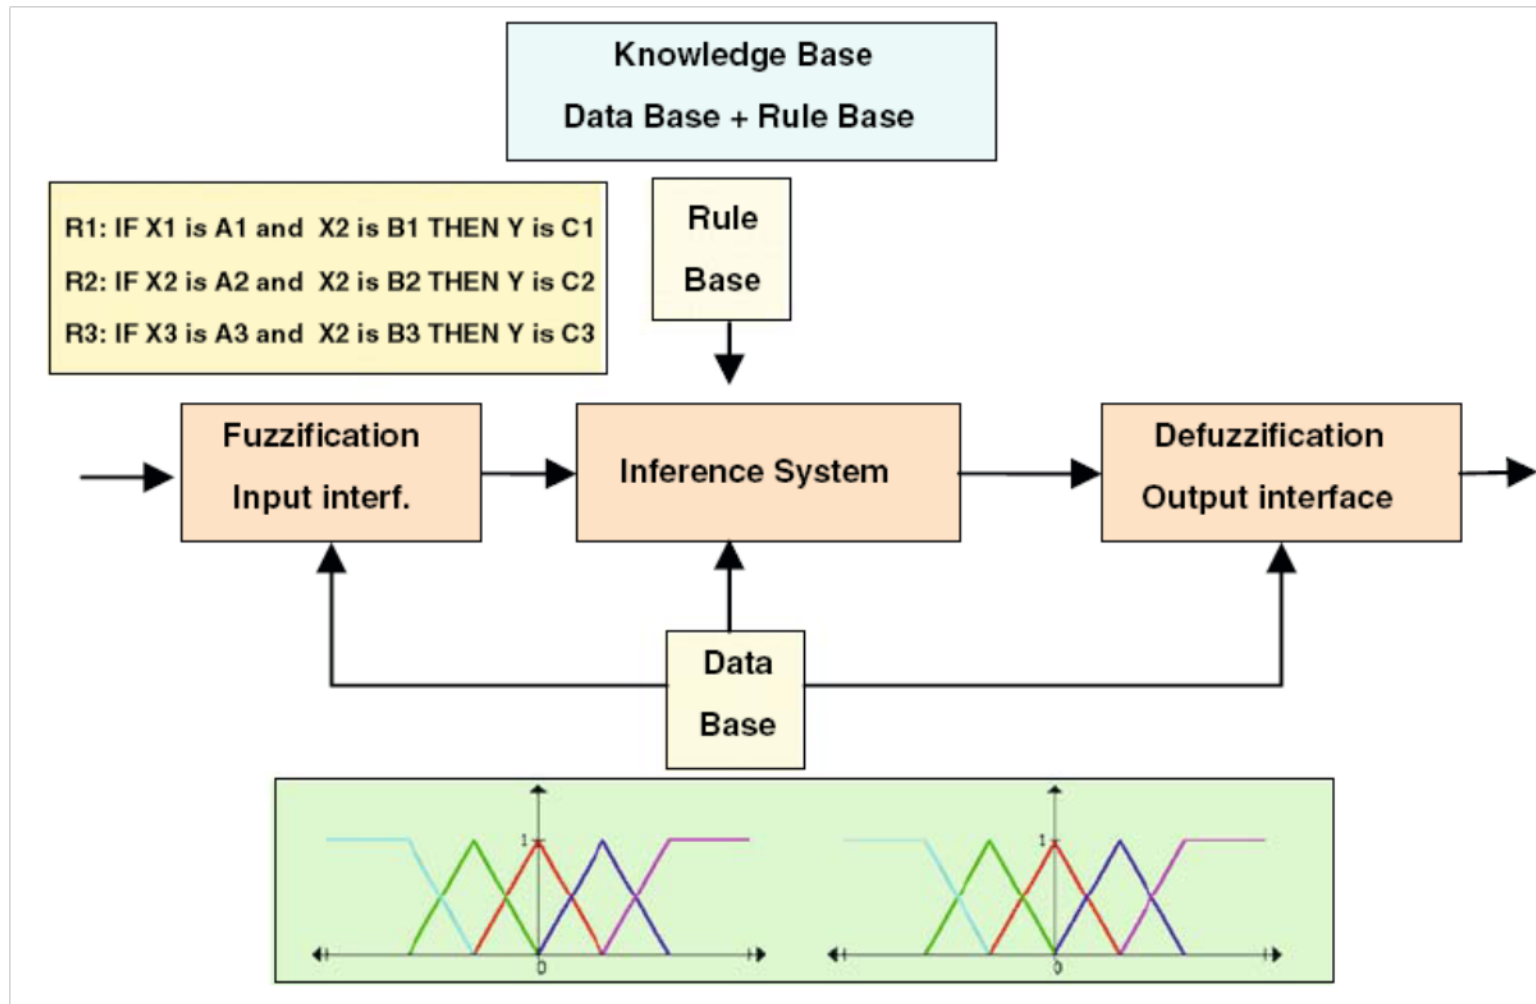
SE tem_molho E molho = cremoso
ENTÃO melhor_corpo = pesado com fator_certeza = 0.6

SE cor_recomendada = tinto E docura_recomendada = seco OU docura_recomendada = médio
ENTÃO vinho = cabernet_sauvignon com fator_certeza = 1

SE prato_principal = ave E tem_peru ENTÃO melhor_cor = branco com fator_certeza = 0.5

Algumas regras para a escolha do melhor vinho para acompanhar uma refeição

SBRF: Estrutura



Fonte: [Herrera 2008]

Sistemas Baseados em Regras Fuzzy


- O sucesso dos SBRF deve-se à:
 - Habilidade para representar o conhecimento vago e incerto
 - Facilidade de expressar o comportamento do sistema em uma linguagem facilmente interpretável pelos seres humanos
- A aquisição de conhecimento é feita a partir de:
 - Um especialista humano
 - Ou através de métodos automáticos
- Modelagem Fuzzy + Algoritmos Genéticos = **Sistemas Fuzzy Genéticos (SFG)**.

Sistemas Fuzzy Genéticos

- Objetivo
 - Aplicar um processo de aprendizado genético para aprender e/ou ajustar componentes de um Sistema Baseado em Regras Fuzzy
 - Aprendizado genético de regras
 - Seleção genética de regras
 - Otimização das funções de pertinência
 - Aprendizado simultâneo da Base de Conhecimento (BR + BD)
 - Aprendizado genético dos parâmetros do sistema de inferência

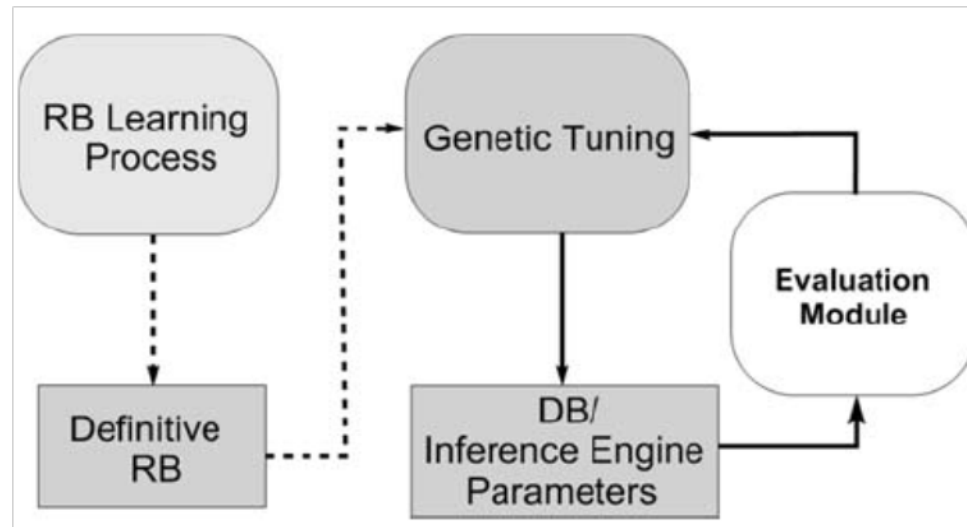
Sistemas Fuzzy Genéticos

- Balanceamento entre precisão e interpretabilidade



Sistemas Fuzzy Genéticos: Ajuste Genético da BD


- Ajuste Genético (*Genetic Tuning*): melhorar o desempenho do SBRF através da otimização de uma Base de Dados preliminar, considerando uma Base de Regras predefinida.



Fonte: [Herrera 2008]


Sistemas Fuzzy Genéticos: Ajuste Genético da BD

- Ajuste genético da BD
 - Focaliza a sintonia dos conjuntos fuzzy
 - A BR e a BD são previamente definidas, manualmente ou por um processo automático qualquer
 - A BR permanece fixa
 - A BD é ajustada pelo AG
 - O número de termos linguísticos em cada partição permanece fixo desde o início do processo.



Sistemas Fuzzy Genéticos: Ajuste Genético da BD

- Codificação genética



$$C = (P_{01}^1, P_{01}^2, P_{01}^3, \dots, P_{0m_0}^1, P_{0m_0}^2, P_{0m_0}^3, \dots, P_{N1}^1, P_{N1}^2, P_{N1}^3, \dots, P_{Nm_N}^1, P_{Nm_N}^2, P_{Nm_N}^3)$$


Sistemas Fuzzy Genéticos: Ajuste Genético da BD

- Interpretabilidade

$$P_{ij}^1 \in [A_L, A_R] = \left[A - \frac{B-A}{2}, A + \frac{B-A}{2} \right]$$

$$P_{ij}^2 \in [B_L, B_R] = \left[B - \frac{B-A}{2}, B + \frac{C-B}{2} \right]$$

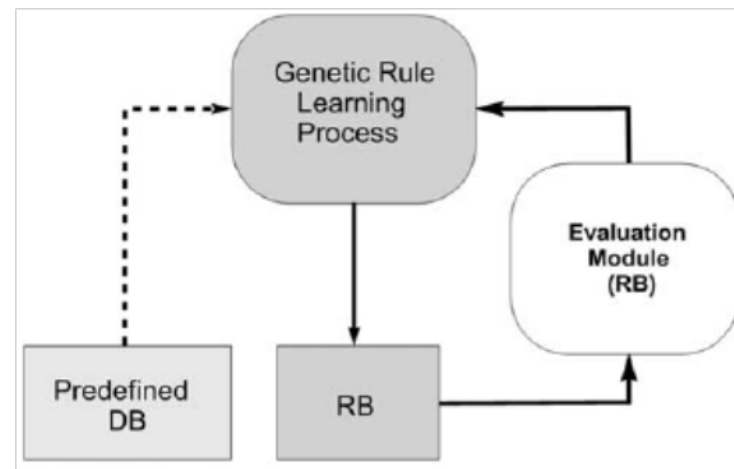

$$P_{ij}^3 \in [C_L, C_R] = \left[C - \frac{C-B}{2}, C + \frac{C-B}{2} \right]$$



- Proposto por Cordón et all (2001).

Sistemas Fuzzy Genéticos: Aprendizado Genético da BR

- A construção das regras considera uma BD predefinida e fixa.
 - Usualmente esta definição é feita escolhendo-se um número de valores linguísticos para as variáveis e distribuindo-os uniformemente




Fonte: [Herrera 2008]

Sistemas Fuzzy Genéticos: Aprendizado Genético da BR

- No aprendizado genético de regras há quatro abordagens:
 - **Pittsburgh**
 - Cada cromossomo representa uma BR.
 - A BR final é o melhor cromossomo obtido.
 - **Michigan**
 - Cada regra é codificada como um cromossomo.
 - A BR final é a união de todos os cromossomos da melhor população.
 - **Iterativa ou *Iterative Rule Learning* (IRL)**
 - Cada regra é codificada como um cromossomo.
 - A diferença da abordagem Michigan, é que uma nova regra é adaptada e adicionada na BR final de forma iterativa, ou seja, em cada execução do AG.
 - **Cooperativa–Competitiva**
 - A população inteira ou um subconjunto dela codifica a BR e os cromossomos competem e cooperam simultaneamente.

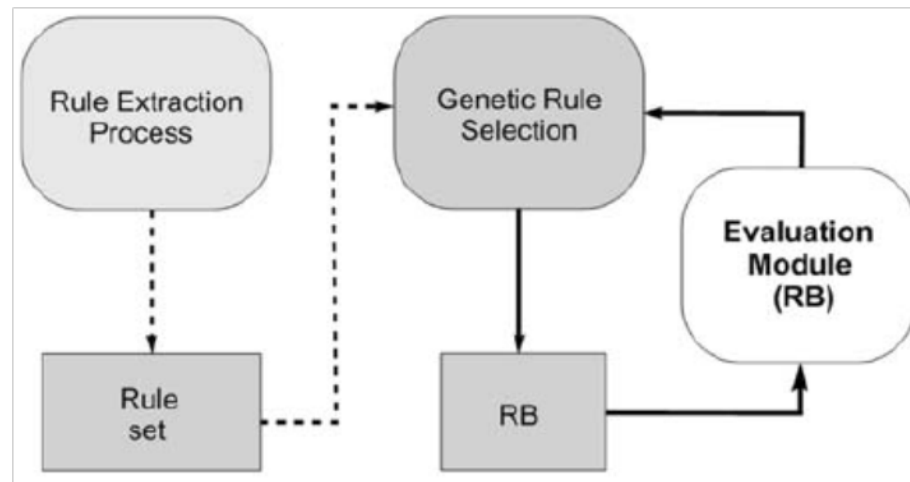
Sistemas Fuzzy Genéticos: Aprendizado Genético da BR

- Codificação genética
 - 2 variáveis de entrada e 1 de saída
 - 3 conjuntos fuzzy por variável
 - Pittsburgh



Sistemas Fuzzy Genéticos: Seleção Genética de regras

- Uma BR com um número excessivo de regras dificulta o entendimento do comportamento do SBRF.
 - Diferentes tipos de regras podem ser encontradas: regras irrelevantes, redundantes e erradas (conflitantes).



Fonte: [Herrera 2008]

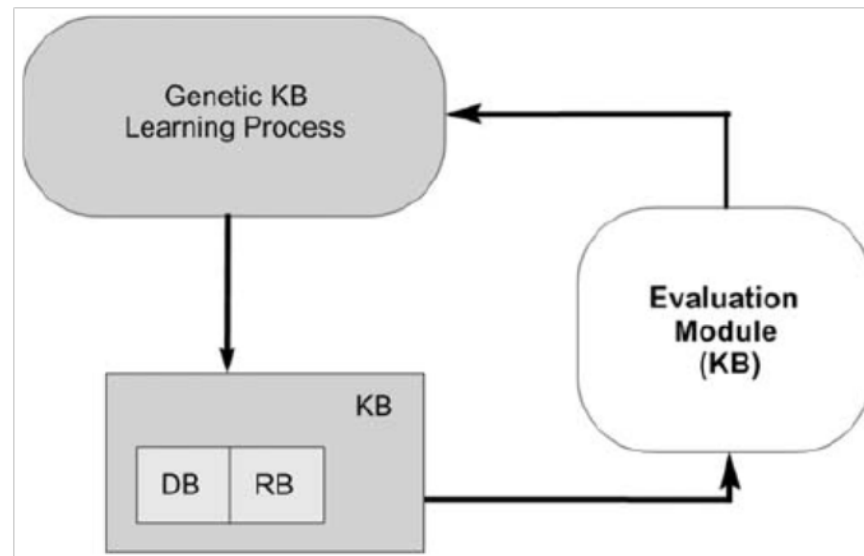
Sistemas Fuzzy Genéticos: Seleção Genética de regras

- Codificação genética
 - 2 variáveis de entrada e 1 de saída
 - 3 conjuntos fuzzy por variável
 - Pittsburgh
 - Cada gene indica se a regra está presente ou não na base de regras

1	0	1	0	0	1	...	0	0	1
---	---	---	---	---	---	-----	---	---	---

Sistemas Fuzzy Genéticos: Aprendizado Genético da BC

- O objetivo desta abordagem é aprender os dois componentes da BC simultaneamente, ou seja, a BD + BR
 - É possível gerar uma melhor definição do SBRF, mas a necessidade de lidar com um grande espaço de busca torna o processo difícil e lento.



Fonte: [Herrera 2008]

Sistemas Fuzzy Genéticos: Função de *fitness*


- Os primeiros trabalhos de SFG são no início da década de 90 e o problema do balanceamento entre precisão e interpretabilidade era tratado como um problema mono-objetivo. Exemplo:
 - $\text{Fitness}(C_i) = \text{NPC} * P_1 + \text{NR} * P_2$
 - NPC = número de padrões classificados corretamente
 - NR = número de regras
- Para contornar este problema, já no final da década de 90 e início da década de 2000, surgiram as primeiras propostas baseadas em otimização multiobjetivo.

Sistemas Fuzzy Genéticos: Função de *fitness*

- A ideia básica da otimização multiobjetivo é trabalhar com um conjunto de modelos de SBRF com diferentes balanceamentos entre precisão e interpretabilidade, ao invés de apenas um modelo de sistema.
 - O especialista ou o processo automático de decisão pode selecionar, de acordo com os requisitos do problema, o modelo mais adequado.
 - Uma das formas muito utilizadas atualmente para o projeto automático de SBRF é por meio de Algoritmos Evolutivos Multiobjetivo (AEMO) (Deb 2001; Coello et al. 2007).
- Esta abordagem híbrida é conhecida como *Sistemas Fuzzy Evolutivos Multiobjetivo*.


Otimização Multiobjetivo

- Exemplo: quero comprar um carro e o objetivo é minimizar o custo e maximizar o conforto.



Otimização Multiobjetivo

- Conjunto de soluções não-dominadas
 - O conjunto de soluções não-dominadas define o conjunto *Pareto-ótimo*



Pesquisas atuais

- Uso de AEMO na construção e/ou ajuste dos componentes de um SBRF
 - Sempre buscando o melhor equilíbrio entre precisão e interpretabilidade
- Busca por novas métricas de interpretabilidade
- Modelos de aprendizado genético baseados em dados de baixa qualidade (dados ruidosos e incertos)
- Técnicas baseadas em AG para regras de associação fuzzy e descoberta de novidades em mineração de dados
 - Extração de regras, identificação de associações, agrupamento, classificação e detecção de novidades e anomalias.

Referências

- Coello, C. A. C., Lamont, G. B. e Veldhuizen, D. A. V. **Evolutionary Algorithms for Solving Multi-Objective Problems**, 2nd ed., Springer, New York, 2007.
- Cordón, O.; Herrera, F. e Villar, P. *Generating the Knowledge Base of a Fuzzy Rule-Based System by the Genetic Learning of the Data Base*. **IEEE Transactions on Fuzzy Systems**, vol.9, no.4, 2001.
- Deb, K. **Multi-Objective Optimization Using Evolutionary Algorithms**, John Wiley & Sons, New York, 2001.
- Herrera, F. Genetic Fuzzy Systems: *Taxonomy, Current Research Trends and Prospects*. **Evolutionary Intelligence**, vol.1, n.1, pp.27-46, 2008.

Perguntas ?