

Busca Genética de Funções de Pertinência em Controladores Nebulosos

Weber Martins¹, Estanislau Gonçalves¹

¹Universidade Federal de Goiás
Escola de Engenharia Elétrica e de Computação
Grupo Pireneus
Praça Universitária, s/n
Setor Universitário
74.605-220
Goiânia - Goiás
E-mails: weber, estanislau@pireneus.eee.ufg.br

Abstract

In this paper we present a system that demonstrates the power of search and optimization of Genetic Algorithms in the generation of fuzzy membership functions. Results of experiments, concerning the control of the temperature and flow of water in showers, have proved the feasibility of finding, by genetic search, membership functions that allow controllers to work properly.

1. Introdução

A construção de controladores desafia cientistas e engenheiros. A busca por recursos computacionais que viabilizem o desenvolvimento de controladores eficazes é um vasto campo de estudo a ser explorado. Nesse contexto, a combinação de técnicas de **Inteligência Artificial (IA)** consolida-se como um paradigma que apresenta bons resultados [1].

O poder de inferência de **Sistemas Nebulosos**, integrados à capacidade de busca e otimização de **Algoritmos Genéticos**, fornece recursos para criação de **sistemas inteligentes híbridos** eficazes [2]. Esses sistemas integram técnicas de IA das abordagens **simbólica** [3] e **sub-simbólica (conexionista)** [4] em variadas combinações.

Nas seções 2 e 3, fundamentamos nosso trabalho apresentando conceitos de Lógica Nebulosa e de Algoritmos Genéticos. A seguir, demonstramos, na seção 4, a modelagem tradicional de controladores nebulosos. Nas seções 5, 6 e 7, discutiremos sobre o sistema proposto, os experimentos e os resultados. Na seção 8, apresentamos nossas conclusões sobre o estudo realizado.

2. Lógica Nebulosa

A lógica nebulosa é um superconjunto estendido da lógica proposicional. Criada em 1965 por **Zadeh** [5, 6] para lidar com o conceito de **graus de verdade**, aumentou o poder de representação de conhecimento em sistemas inteligentes.

A lógica tradicional trabalha com somente dois valores: “verdadeiro” ou “falso”. A lógica nebulosa assume valores desde “completamente verdadeiro” até “completamente falso”.

A necessidade de formas de representação para informações ambíguas e incertas motiva a utilização de valores, além do verdadeiro e do falso. Valores entre 0 e 1 indicam pertinência parcial do elemento.

Elementos do **universo de discurso** podem estar contidos em conjuntos na **lógica clássica**. A transição ocorre de forma abrupta e bem definida: os elementos pertencem ou não pertencem aos conjuntos. A transição ocorre gradualmente na **lógica nebulosa**. Os elementos possuem diferentes **graus de pertinência** aos **conjuntos nebulosos**. Ao contrário da teoria clássica de conjuntos, elementos em um mesmo universo de discurso podem pertencer a vários conjuntos nebulosos.

Funções de pertinência (μ) mapeiam elementos de universos de discurso a conjuntos nebulosos. O grau de pertinência indica o quanto elementos pertencem a conjuntos nebulosos. Elementos com grau de pertinência zero ($\mu = 0$) ou um ($\mu = 1$) não estão ou estão contidos no conjunto nebuloso, respectivamente.

A região do universo de discurso composta por elementos com pertinência completa ($\mu = 1$) ao conjunto nebuloso define o núcleo da função de pertinência. A região do universo de discurso caracterizada por elementos com pertinência maior do que 0 ($\mu > 0$) ao conjunto nebuloso define o apoio¹ da função de

¹ Do inglês support

pertinência. A região do universo de discurso contendo elementos com pertinência parcial ($\mu > 0$ e $\mu < 1$) ao conjunto nebuloso define os limites da função de pertinência.

Conjuntos nebulosos classificados como normais possuem elementos com pertinência completa. Conjuntos nebulosos compostos somente por elementos com pertinência parcial são classificados como subnormais.

Conjuntos nebulosos convexos são descritos por funções de pertinência cujos valores são estritamente crescentes, decrescentes ou crescentes e decrescentes, monotonicamente.

Operações comumente realizadas sobre conjuntos nebulosos são definidas conforme Tabela 1.

Tabela 1: Operações com conjuntos nebulosos.

Operador	Significado
União	$\mu_{A \cup B}(x) = \max(\mu_A(x), \mu_B(x))$
Intersecção	$\mu_{A \cap B}(x) = \min(\mu_A(x), \mu_B(x))$
Complemento	$\neg \mu_A(x) = 1 - \mu_A(x)$

Equipamentos que utilizam lógica nebulosa estão em evidência atualmente. Países como Japão e Estados Unidos utilizam essa tecnologia em equipamentos de veículos automotores, como sistemas anti-bloqueantes e controladores de tração; sistema de gerenciamento de tráfego; prospecção de dados e em diversas outras áreas [7].

2.1. Sistemas especialistas baseados em regras nebulosas

Sistemas especialistas baseados em regras utilizam a lógica para representação do conhecimento. Eles são construídos baseados em linguagem natural.

Sistemas especialistas baseados em regras nebulosas (ver Figura 1) utilizam lógica nebulosa em vez de lógica clássica. Sistemas especialistas convencionais têm o processamento baseado em símbolos. Sistemas especialistas nebulosos têm o processamento baseado em números.

Uma vez que a quantidade de informações contidas na comunicação humana é muito grande, a linguagem natural é, por natureza, vaga, imprecisa e ambígua. Por esse motivo, sistemas especialistas trabalham com modelos de representação da linguagem natural.

Nesses modelos, representa-se a linguagem natural utilizando-se **termos fundamentais**, chamados termos atômicos, e **qualificadores**.

Os termos fundamentais representam conjuntos nebulosos. Exemplos de termos fundamentais são

quente, frio, rápido, lento etc.




Figura 1: Sistema baseado em regras nebuloso.

Qualificadores são adjetivos ou advérbios que modificam termos fundamentais. Exemplos de qualificadores são: muito, pouco, levemente, bastante, aproximadamente, entre outros. Qualificadores modificam o formato de funções de pertinência de termos fundamentais da mesma forma que advérbios e adjetivos fazem na linguagem natural.

O centro da técnica de modelagem nebulosa é a idéia de **variáveis linguísticas**. Em linhas gerais, a partir de termos fundamentais e qualificadores obtemos variáveis linguísticas. Variáveis linguísticas permitem à modelagem nebulosa expressar a semântica usada pelos especialistas.

Conjuntos de proposições nebulosas formam a base do **raciocínio nebuloso**. Proposições são declarações de relacionamento entre variáveis linguísticas e regiões nebulosas.

Proposições condicionais são aquelas qualificadas por declarações “se”. Proposições condicionais nebulosas são análogas às regras dos sistemas especialistas baseados em regras convencionais. Elas têm a forma geral (ver Figura 2), onde w e x são valores escalares e Z e Y são variáveis linguísticas. Proposições que seguem o termo “se” formam o **antecedente** ou **predicado**. Proposições que seguem o termo “então” formam o **consequente**.

Nas proposições condicionais, a declaração x é Y é condicional ao valor de pertinência do predicado.

Proposições incondicionais são aquelas não qualificadas por declarações “se”. Proposições incondicionais são definidas conforme mostrado na figura 3, onde x é um escalar e Y é uma variável linguística.

Declarações incondicionais são sempre aplicadas ao modelo.




Figura 2: exemplo de proposição condicional.




Figura 3: exemplo de proposição incondicional

Proposições compõem **regras**. Regras formam a **base de conhecimento** de sistemas especialistas.

Na **composição**, regras são avaliadas por mecanismos de implicação e os grau de pertinência das premissas que compõem o predicado são determinados.

A **decomposição** converte os valores “nebulosos”, obtidos na fase de composição, em valores escalares.

3. Algoritmos Genéticos

Algoritmos Genéticos (AGs) são técnicas de **busca e otimização**. São baseados no princípio da **Seleção Natural da Teoria da Evolução** de Charles Darwin [8]. Segundo Darwin, os seres mais aptos às condições ambientais sobrevivem e reproduzem com maior frequência.

Nos AGs, os problemas são representados por ambientes, onde indivíduos mais adaptados são naturalmente os mais fortes e solucionam melhor o problema. Os cromossomos caracterizam os indivíduos. Cada cromossomo armazena um conjunto de genes.

Gerações de novos indivíduos são criadas a partir da seleção dos mais aptos e da troca de informações genéticas entre eles. O processo evolutivo repete-se por “n” gerações ou até a população convergir em indivíduos da mesma categoria (idênticos).

AGs encontram soluções em tempo aceitável. Porém, nem sempre essas soluções são as melhores. Baseados nessa premissa, AGs são classificados como completos e sub-ótimos [9].

Na fase de **seleção**, os indivíduos participantes do processo de reprodução são determinados. A aptidão determina a probabilidade de reprodução dos

indivíduos.

A troca de informações genéticas ocorre na fase de **cruzamento**. Dessa forma, os mais aptos reproduzem com maior frequência. Características genéticas dos pais são herdadas pelos filhos. Esse procedimento viabiliza novas soluções a cada geração.

Mutações genéticas garantem a diversidade genética da população. Nas mutações, genes de novos indivíduos são modificados. Esse procedimento insere indivíduos com características diferenciadas (dos pais) na população.

Mecanismos avaliam o desempenho dos indivíduos atribuindo-lhes notas. Essas **funções de avaliação** indicam o quanto soluções candidatas aproximam-se de uma solução ótima.

A natureza do problema e os recursos computacionais disponíveis fornecem subsídios para definição dos **Parâmetros Genéticos**. O tamanho da população, a taxa de cruzamento e a taxa de mutação são os principais parâmetros genéticos.

A eficiência de AGs relaciona-se diretamente com o **tamanho da população**. Esse parâmetro define a quantidade de soluções candidatas pertencentes ao espaço de busca. Populações grandes podem cobrir maior parte do domínio do problema, mas possuem complexidades de tempo e de espaços maiores.

A **taxa de cruzamento** define a quantidade de indivíduos adicionados à população em cada geração.

A **taxa de mutação** define a probabilidade de indivíduos sofrerem mutação genética.

4. Controlador Nebuloso Tradicional

O controlador nebuloso tradicional (modelagem tradicional), quando ativado, estabiliza a temperatura e fluxo de água baseado em medições aferidas nas saídas de chuveiros (ver Figura 4). Ele funciona independentemente do conhecimento da arquitetura interna de chuveiros.

Nos chuveiros, a temperatura da água quente (**H**) e a temperatura da água fria (**C**) são as entradas. A temperatura da água (**T**) e o fluxo de água (**F**) são as saídas.




Figura 4: O chuveiro e o controlador.

Modelos matemáticos representam a dinâmica de funcionamento de chuveiros[10]. A Figura 5 demonstra o modelo matemático utilizado no experimento. O fluxo interno de água quente (F_h), o fluxo interno de água fria

(F_c), a temperatura interna da água quente (T_h) e a temperatura interna da água fria (T_c) representam estados do chuveiro. Os valores são escolhidos, aleatoriamente, conforme as seguintes restrições: $10 < T_c < 38$; $34 < T_h < 72$; $T_c < T_h$; $10 < F_c < 60$ e $10 < F_h < 60$.

$$F = F_h H + F_c C$$

$$T = \frac{T_h F_h H + T_c F_c C}{F_h H + F_c C} \quad (1)$$

Figura 5: Modelo matemático da dinâmica do chuveiro.

Os **universos de discurso** da temperatura e do fluxo de água variam entre 0 a 72 graus Celsius e 0 a 120 litros/minuto, respectivamente. Conjuntos nebulosos do tipo trapezoidal (ver Figura 6) dividem o universo de discurso. Funções de pertinência que melhor representam esses conjuntos nebulosos são encontradas empiricamente.




Figura 6: Conjuntos nebulosos trapezoidais.

Regras compõem o sistema de produção do controlador. Elas podem ser disparadas a cada iteração. Na Figura 7, ilustramos uma das regras.

```

se Temperatura(T) é Baixo e Fluxo(F) é MuitoAlto
então
    AjusteTorneiraFria(NegativoPequeno)
    AjusteTorneiraQuente(NegativoGrande)
fim-se

```

Figura 7: Exemplo de regra nebulosa do controlador .

Para que as regras disparadas no processo de possam contribuir com algum valor no resultado final utilizamos o método aditivo [6]. Esse método compila e converte as saídas em valores discretos. Esses valores são ajustes recomendados para as torneiras de água quente e de água fria (ver Tabela 2).

O estado corrente inicial do chuveiro e a qualidade das funções de pertinência influenciam o

comportamento do controlador.

Tabela 2: Valores dos tipos de ajustes.

Tipo de Ajuste	Valor
PositivoMuitoGrande	127
PositivoGrande	47
PositivoMédio	15
PositivoPequeno	7
Z	0
NegativoPequeno	-7
NegativoMédio	-15
NegativoGrande	-47
NegativoMuitoGrande	-127

5. Sistema Proposto

Propomos uma nova modelagem para o controlador nebuloso tradicional. Diferentemente do controlador tradicional, automatizamos a criação das funções de pertinência. Para realizarmos essa tarefa, utilizamos AGs.

Em nosso AG, indivíduos são compostos de 40 cromossomos. Os cromossomos representam os vértices (A,B,C e D na figura 6) dos conjuntos nebulosos referentes à temperatura e ao fluxo de água.

A quantidade de estados de chuveiro varia conforme o tipo de experimento. Na avaliação da nota dos indivíduos, os conjuntos nebulosos, neles instanciados, são carregados no mecanismo de inferência. O controlador estabiliza a temperatura e o fluxo de água. A média aritmética da quantidade de ajustes (iterações) determina a nota do indivíduo. O desempenho é melhor quando menos ajustes são realizados.

6. Experimentos

6.1. Experimento 1: estados isolados

Efetuamos estudos de viabilidade do sistema proposto nesse primeiro experimento. A busca genética utiliza um único estado de chuveiro como restrição na função de avaliação.

Investigamos a eficácia da capacidade de generalização do sistema proposto nos experimentos seguintes.

6.2. Experimento 2: conjunto único de estados em todas gerações

Este experimento demonstra que, dado um conjunto de estados de chuva, o AG consegue buscar funções de pertinência ideais para o chuva.

O AG funciona da seguinte forma: estados do chuva são criados no início do processamento. A função de avaliação utiliza esse conjunto de chuva para todas gerações durante a busca genética.

Ao final, validamos a eficácia das funções de pertinência encontradas. Para tanto, apresentamos novos estados de chuva ao controlador e mensuramos os resultados.

6.3. Experimento 3: conjuntos novos de estados a cada geração

Neste último experimento, a função de avaliação utiliza novos estados de chuva a cada geração. Validamos a eficácia das soluções encontradas como relatado no item anterior.

7. Resultados

Comparações entre os resultados obtidos no modelo tradicional e os obtidos neste estudo são mostradas na Figura 8.




Figura 8: Desempenho médio dos modelos.

No modelo tradicional, o desempenho médio e o desvio padrão são de 6,2 e 2,9 iterações, respectivamente. Neste trabalho, o desempenho médio e o desvio padrão são de 5,7 e 2,9 iterações para o experimento 2 e de 8,6 e 3,2 iterações para o

experimento 3.

Conforme observamos, os resultados dos testes comprovam que o desempenho médio obtido nos experimentos assemelha-se ao desempenho médio do modelo tradicional. No melhor caso, experimento 2, o desempenho médio é superior.

Utilizamos recursos da Estatística Inferencial para nos certificarmos dos resultados dos experimentos. Aplicamos o “**Teste t**” [11] em amostras extraídas do experimento original e do experimento 2. Com nível de significância de 5%, concluímos que o desempenho dos dois experimentos é estatisticamente equivalente. Na verdade, a probabilidade de encontrarmos resultados tão ou mais diferentes que os encontrados é de 50%. A diferença seria significativa se tal probabilidade fosse menor que 5%. Portanto, podemos afirmar que a diferença de desempenho entre o sistema proposto e o modelo tradicional pode ser atribuída ao acaso.

8. Conclusão

Neste artigo, demonstramos a viabilidade de integração de técnicas de inteligência artificial por intermédio da construção de um modelo híbrido específico.

No experimento de referência, modelagem tradicional, o controlador funciona independentemente do modelo de chuva. No entanto, relega-se a configuração dos conjuntos nebulosos. No sentido de automatizar a configuração, adicionamos um módulo para realizar essa tarefa.

Os resultados dos experimentos são satisfatórios. Provamos que o desempenho dos controladores é similar.

Referências

- [1] ALBUS, James S. Albus e MEYSTEEL, Alexander M. *Intelligent System: Architecture, Design, Control*. Wiley-Interscience, 2001.
- [2] ROSS, Timothy J. *Fuzzy Logic with Engineering Applications*. Singapore: McGraw-hill Book Co, 1997.
- [3] RUSSEL, Stuart e NORVIG, Peter. *Artificial Intelligence: A Modern Approach*. 2ª. edição, New Jersey: Prentice Hall, Inc, 1995.
- [4] FU, Limin. *Neural Networks in Computer Intelligence*. McGraw-hill, Inc, 1994.
- [5] COX, Earl. *The Fuzzy Systems Handbook: A Practitioners Guide to Building, Using, and Maintaining Fuzzy Systems*. Cambridge: Academic Press, Inc, 1994.
- [6] KRUSE, R, GEGHARDT, J e KLAWONN, F. *Foundations of Fuzzy Systems*, West Sussex: John Wiley & Sons Ltd, 1994.

- [7] FUZZYTECH online. Disponível em <http://www.fuzzytech.com>. Acessado em 02/12/2002.
- [8] DARWIN, Charles. *Origin of Species*, The Gramercy Books, 1996
- [9] GOLDBERG, David E., *Genetic Algorithms in Search, Optimization and Machine Learning*, Massachusetts: Addison-Wesley Publishing Company, 1989
- [10] OGATA, Katsuhiko. *Modern Control Engineering*, 4ª edição. Prentice Hall, 2001.
- [11] COHEN, Paul R. *Empirical Methods for Artificial Intelligence*, MIT Press, 1995.