

# Sistemas Neurais Híbridos: Redes Neurais Artificiais e Algoritmos Genéticos

Leonardo Nascimento Ferreira



# Conteúdo

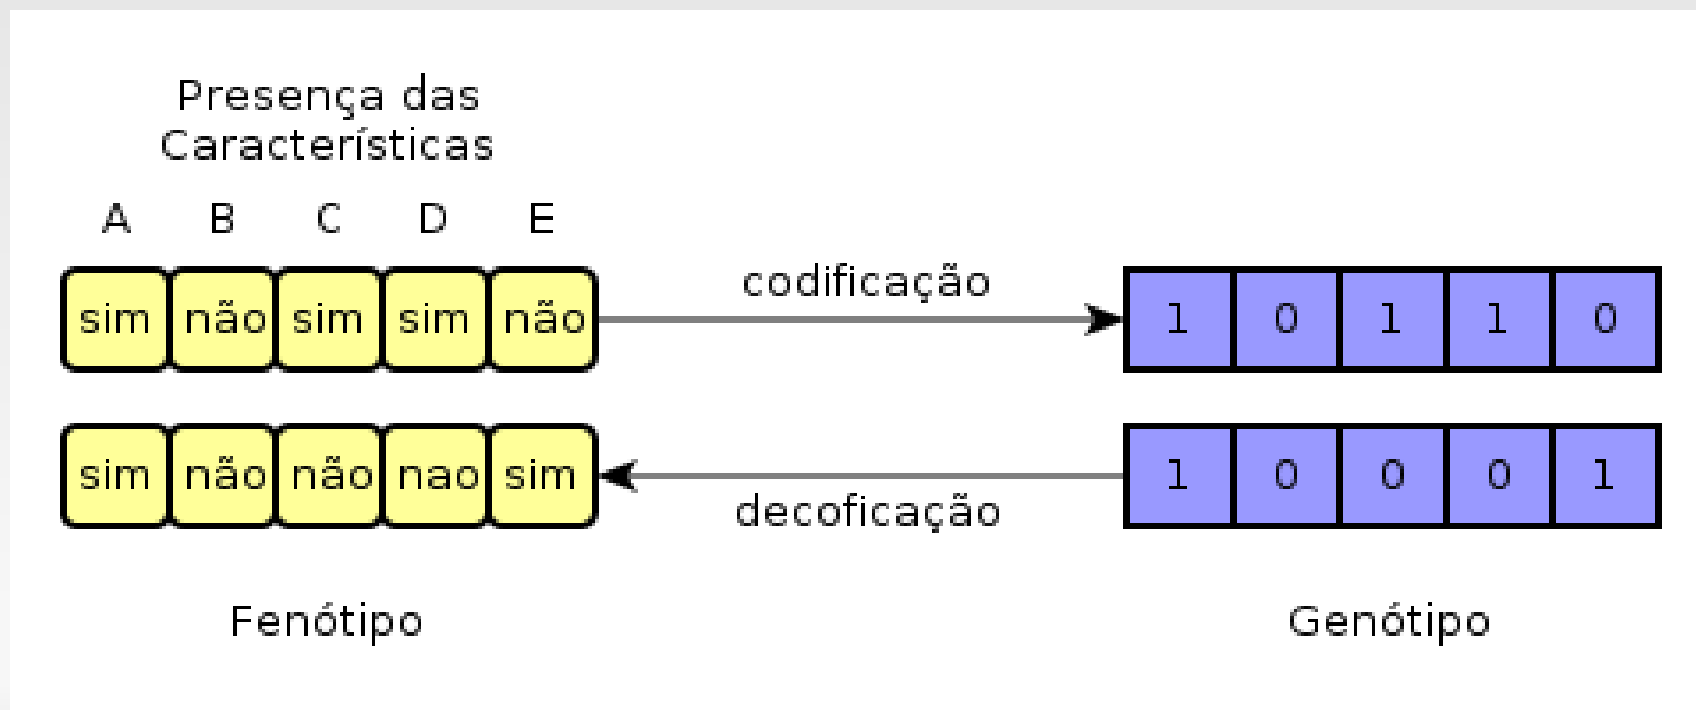
- Algoritmo Genético
  - Representação
  - Seleção
  - Reprodução
- Redes Neurais Evolucionárias
  - Vantagens e desvantagens
  - Principais abordagens
- Simulações
- Considerações Finais

# Algoritmos Genéticos

- Algoritmos de otimização e busca baseados no mecanismo de seleção natural e genética
- Baseados na Teoria da Evolução proposta por Darwin
- Seleção Natural
- Cada possível solução: Indivíduo
- Conjunto de Indivíduos: População

# Algoritmos Genéticos


- Representação:
  - Binária



# Algoritmos Genéticos

- Seleção:
  - Melhorar a população
  - Manter os mais aptos
  - Função de avaliação
  - Método da Roleta

$$nota_j^{normalizada} = \frac{nota_j^{original}}{\sum_{i=1}^N nota_i^{original}}$$




# Algoritmos Genéticos

- Reprodução:
  - Aplicação de Operadores Genéticos:
    - *Crossover*
    - Mutação
    - Entre outros
  - Aumentar espaço de busca
  - Melhorar as boas características ao longo das gerações

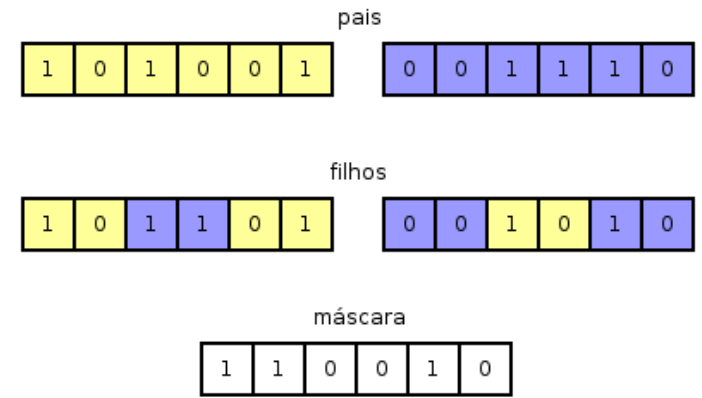
# Algoritmos Genéticos

- *Crossover:*
  - Aumentar variabilidade sem perder as boas características
  - Recombinação dos indivíduos


Um-Ponto:



Dois-Pontos:



Uniforme:



# Algoritmos Genéticos

- Mutaç o:
  - Altera o aleat ria de bits
  - Aumentar espa o de busca
  - N o estagnar em solu es locais
  - Ocorre com baixa frequ ncia





# Algoritmos Genéticos

- Algoritmo:
- Início
  - Representação
  - Iniciar população de forma randômica
  - Repetir
    - Avalia grau de aptidão
    - Seleciona os Mais aptos
    - Aplica operadores genéticos (*crossover* e *mutação*) na população
  - Até encontrar boa resposta ou atingir critério de parada
- Fim

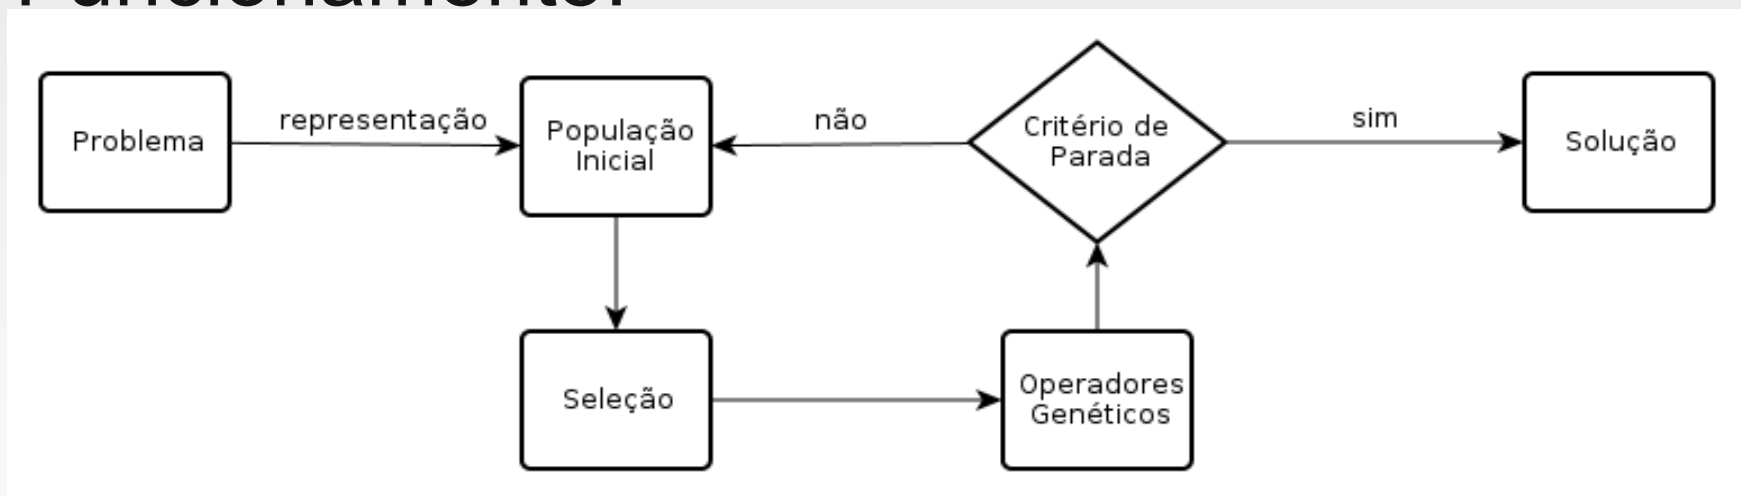
# Algoritmos Genéticos

- Parâmetros e Critérios de Parada:
  - Tamanho da População:
    - Quanto maior melhor, porem mais esforço computacional
  - Taxa de *Crossover*:
    - Probabilidade de um indivíduo se recombinar com outro. Deve ser balanceado pois se:
      - Baixa: Diminui espaço de busca
      - Alta: Indivíduos aptos podem ser descartados
  - Taxa de Mutação:
    - Probabilidade de um gene sofrer mutação. Deve ser baixo para a busca não ficar aleatória

# Algoritmos Genéticos

- Parâmetros e Critérios de Parada:
  - Número de Gerações:
    - Critério de parada

- Funcionamento:



# Redes Neurais Evolucionárias

- Motivação de Sistemas Neurais Híbridos:
  - Aproveitar os benefícios das técnicas envolvidas
  - Construção de sistemas mais robustos e eficientes
- Nem sempre apresentam resultados melhores

# Redes Neurais Evolucionárias

- Redes Neurais Artificiais:
  - Podem contribuir com:
    - Aprendizado a partir de dados
    - Técnica de aproximação universal
    - Paralelismo
    - Robusto
  - Dificuldades:
    - Longo tempo de treinamento
    - Inexistência de mecanismo explicativo

# Redes Neurais Evolucionárias

- Algoritmos Genéticos:
  - Podem contribuir com:
    - Não é necessário conhecimento aprofundado do problema
    - Tolerância a ruídos e dados incompletos
    - Paralelismo
    - Facilmente hibridizados
  - Dificuldades:
    - Custo computacional na avaliação do indivíduo
    - Convergência as vezes prematura

Antonio de Padua Braga, Andre Ponce de Leon F. de Carvalho, e Teresa Bernarda Ludermir.  
*Redes Neurais Artificiais* - Teoria e Aplicações. LTC editora, 2 edition, 2007. 2

# Redes Neurais Evolucionárias

- Na tentativa de aproveitar os benefícios de RNAs e AGs, surgem as Redes Neurais Evolucionárias (RNEs):
- “São capazes de evoluir para se adequar a uma tarefa sem interferência externa eliminando assim o processo manual de tentativa e erro para encontrar uma rede neural ótima para tarefas que não se tem conhecimento prévio”

# Redes Neurais Evolucionárias

- Seleção de características com AG
  - Selecionar mais importantes e expressivas
  - Descartar menos importantes
  - Difícil de ser realizado manualmente pois não se conhece os dados a priori
  - Reduz tempo de aprendizado
  - Aumenta generalização



# Redes Neurais Evolucionárias

- Definição da Topologia das redes com AG
  - Escolha da topologia é um problema em RNAs
  - Não pode ter poucos nós porque:
    - Poderá demorar a convergir
  - Não pode ter muitos nós porque:
    - Overfitting

# Redes Neurais Evolucionárias

- Definição da Topologia das redes com AG
  - Representação Direta:
    - Mais simples:
    - Matriz de adjacência ( $n \times n$ )
    - Mais adequado para AG porque pode ser transformada em vetor
    - Codificação dos indivíduos  $O(n^2)$
    - Pouco escalável para problemas grandes
    - Descobriu topologias que aprendem mais rápido

# Redes Neurais Evolucionárias

- Definição da Topologia das redes com AG
  - Representação Indireta:
    - Descrições abstratas e mais complexas
    - Gramáticas livre de contexto
    - Podem ser projetadas para evitar arquiteturas indesejadas
    - Restringem espaço de busca de forma inteligente
    - Diminuem tempo de processamento

Hiroaki Kitano. *Designing Neural Networks Using Genetic Algorithms with Graph Generation System*. *Complex Systems Journal*, 4:461–476, 1990.

# Redes Neurais Evolucionárias

- Treinamento de RNAs com AGs
  - Simplesmente com AGs [Montana and Davis, 1989]
    - Bons resultados para redes pequenas
    - Alto custo computacional
  - Backpropagation e refinar com Ags [Kadaba and Nygard, 1990]
    - Mesmos problemas
  - Escolha dos pesos iniciais com AGs e refinamento com backpropagation
    - Abordagem mais utilizada

Kim W. C. Ku and M. W. Mak. *Exploring the effects of lamarckian and baldwinian learning in evolving recurrent neural networks*, 1997.

# Redes Neurais Evolucionárias

- Simulações:
  - Comparação entre treinamento de RNAs com backpropagation e com AG.

Domínio	Casos Class.		Características			Rede Neural Artificial			
			Cont.	Disc.	Faltando	Entrada	Escond.	Saída	Épocas
Breast Cancer	699	2	9	-	N	9	1	5	20
Credit-Australian	653	2	6	9	S	46	1	10	35
Credit-German	1000	2	7	13	N	62	1	10	30
Pima Diabetes	768	2	9	-	S	8	1	5	30
Heart-Cleveland	303	2	6	7	N	26	1	5	40
Housing	506	3	12	1	N	13	3	2	70
Ionosphere	351	2	34	-	N	34	1	10	40
Iris	150	3	4	-	N	4	3	5	80
Kr-vs-kp	3196	2	-	36	N	74	1	15	20
Sonar	208	2	60	-	N	60	1	10	60
Wine	178	3	13	-	N	13	3	5	15
POL2	2000	2	2	-	N	2	1	15	30
RCB2	2000	8	2	-	N	2	8	10	25
Random21	2500	2	21	-	N	21	1	1	100
Redundant21	2500	2	21	-	N	21	1	1	100

Erick Cantú-Paz and Chandrika Kamath. *An empirical comparison of combinations of evolutionary algorithms and neural networks for classification problems*. IEEE Transactions on Systems, Man, and Cybernetics, Part B, 35(5):915–927, 2005.

# Redes Neurais Evolucionárias

- Simulações:
  - Rede Feedforward com uma camada escondida totalmente conectada
  - Função da ativação:  $f(\text{net}) = \tanh(\text{net})$
  - Algoritmo backpropagation com momentum
  - Taxa de aprendizado = 0,15
  - Momentum = 0,9
  - Validação cruzada com 5 iterações de 2-folds

D. Opitz and R. Maclin, *Popular ensemble methods: an empirical study*, Journal of Artificial Intelligence Research, vol. 11, pp.169–198, 1999.

# Redes Neurais Evolucionárias

- Simulações:
  - AG com codificação binária
  - População inicial de  $3\sqrt[2]{l}$ , onde  $l$  é tamanho do cromossomo
  - Crossover uniforme
  - Seleção por torneio
  - Toda a população é trocada (taxa máxima de crossover)
  - Taxa de mutação =  $1/l$
  - Validação realizada treinando uma RNA com 70% dos dados e 30% para validação.
  - Melhor rede é o resultado do experimento

# Redes Neurais Evolucionárias

- Resultado
  - RNAE apresentou Acurácia média um pouco maior

Domínio	RNA	RNAE
Breast Cancer	96.39	98.88
Credit-Australian	82.53	83.28
Credit-German	70.12	70.94
Diabetes-Pima	73.30	73.83
Heart-Cleveland	78.17	<b>87.72</b>
Housing	64.62	67.94
Ionosphere	84.77	<b>74.10</b>
Iris	94.53	<b>88.67</b>
Kr-vs-kp	74.30	<b>90.14</b>
Sonar	69.61	73.65
Wine	95.16	92.47
POL2	90.72	90.81
RCB2-8	92.61	96.41
Random21	91.70	93.29
Redundant21	91.75	<b>98.52</b>
Média da Acurácia	83.35	85.38



# Redes Neurais Evolucionárias

- Considerações Finais
  - Apresentados conceitos de AG
  - Apresentadas as principais abordagens da utilização de AGs com RNAs
  - Simulação comparativa entre o treinamento de RNAs com backpropagation e com AG
  - Para essas simulações, o treinamento com AG foi um pouco mais eficiente
  - Pode ser uma das soluções para os problemas com RNAs

# Referências Bibliográficas

Tobias Blickle and Lothar Thiele. A Comparison of Selection Schemes Used in Genetic Algorithms. Technical Report 11, Gloriastrasse 35, 8092 Zurich, Switzerland, 1995.

Charles Darwin. On the Origin of Species by Means of Natural Selection. Murray, London, 1859. or the Preservation of Favored Races in the Struggle for Life.

David E. Goldberg. Genetic Algorithms in Search, Optimization and Machine Learning. Addison-Wesley Longman Publishing Co., Inc., Boston, MA, USA, 1st edition, 1989. ISBN 0201157675.

David E. Goldberg and Kalyanmoy Deb. A comparative analysis of selection schemes used in genetic algorithms. In Gregory J. E. Rawlins, editor, Foundations of Genetic Algorithms, pages 69–93. San Francisco, CA: Morgan Kaufmann, 1991.

David J. Montana and Lawrence Davis. Training feedforward neural networks using genetic algorithms. In Proceedings of the 11th international joint conference on Artificial intelligence - Volume 1, pages 762–767, San Francisco, CA, USA, 1989. Morgan Kaufmann Publishers Inc.