Referências Bibliográficas

- [Back97] Back, T.; Fogel, D. B.; Michalewicz, Z., editors. Handbook of Evolutionary Computation. Institute of Physics Publishing, 1997. 1.1
- [Bishop95] BISHOP, C. M. Neural Networks for Pattern Recognition. Oxford University Press, 1995. 3.4
- [Blanco01] BLANCO, A.; DELGADO, M.; PEGALAJAR, M. C. A real-coded genetic algorithm for training recurrent neural networks. Neural Networks, 14:93–105, 2001. 1.4
- [Figueiredo03] FIGUEIREDO, K.. Novos modelos neuro-fuzzy hierárquicos com aprendizado por reforço para agentes inteligentes. PhD thesis, Pontifícia Universidade Católica do Rio de Janeiro, 2003. 4.2.2, 4.2.2
- [Franklin96] FRANKLIN, S.; GRAESSER, A.. Is it an agent, or just a program?: A taxonomy for autonomous agents. In: INTELLIGENT AGENTS III. AGENT THEORIES, ARCHITECTURES AND LANGUAGES (ATAL'96), volumen 1193, Berlin, Germany, 1996. Springer-Verlag. 5.2
- [Gillespie73] GILLESPIE, D. T.. A Quantum Mechanics Primer An Elementary Introduction to the Formal Theory of Non-Relativistic Quantum Mechanics. Open University Set Book, 1973. 2.1.2, 2.1.3, 2.1.3
- [Gomez97] GOMEZ, F.; MIIKKULAINEN, R.. Incremental evolution of complex general behavior. In: ADAPTIVE BEHAVIOR, volumen 5, p. 317–342, 1997. 2.7
- [Gomez03] GOMEZ, F. Robust Non–Linear Control through Neuroevolution. PhD thesis, The University of Texas at Austin, 2003. 2.7, 3.4, 3.4, 4.2.2, 4.2.2, 4.2.2
- [Green01] GREEN, N. J. B.. Quantum Mechanics 1: Foundations. Oxford Science Publications, 2001. 2.1.1, 2.1.2, 2.1.2, 2.1.2, 2.1.3, 2.2
- [Han00] HAN, K.; KIM, J.. Genetic quantum algorithm and its application to combinatorial optimization problem. In: PROCEEDINGS OF THE 2000

CONGRESS ON EVOLUTIONARY COMPUTATION, volumen 2, p. 1354– 1360, 2000. 2.5, 2.5, 2.5

- [Han02] HAN, K.; KIM, J.. Quantum-inspired evolutionary algorithm for a class of combinatorial optimization. In: IEEE TRANS. EVOL. COMPUT. 6, p. 580–593, 2002. 1.1, 2.5
- [Han04] HAN, K.-H.; KIM, J.-H.. Quantum–inspired evolutionary algorithms with a new termination criterion, h_e gate and two–phase scheme. IEEE Transactions on Evolutionary Computation, 8, 2004. 1.1, 4.1.2, 5
- [Haykin99] HAYKIN, S.. Neural Networks A Comprehensive Foundation. Prentice Hall, 2 edition, 1999. 1.1, 3.4, 3.4, 4
- [ICA05] Projeto de previsão de vazões, 2005. 4.2.1
- [Ilonen03] ILONEN, J.; KAMARAINEN, J.-K.; LAMPINEN, J.. Differential evolution training algorithm for feed-forward neural networks. Neural Processing Letters, 17:93–105, 2003. 1.1
- [Jang04] JANG, J.-S.; HAN, K.-H.; KIM, J.-H.. Face detection using quantuminspired evolutionary algorithm. In: PROCEEDINGS OF CONGRESS ON EVOLUTIONARY COMPUTATION, volumen 2, p. 2100–2106, 2004. 2.5
- [Jsbsim] http://jsbsim.sourceforge.net/. 5.1
- [Knuth73] KNUTH, D. E.. Sorting and Searching. Addison Wesley, 1973. 2.4
- [Koza92] KOZA, J. R.. Genetic Programming: on the programming of computers by means of natural selection. MIT Press, 1992. 1.1, 4.2.2
- [Michalewicz94] MICHALEWICZ, Z.. Genetic algorithms + data structures = evolution programs (2nd, extended ed.). Springer-Verlag New York, Inc., New York, NY, USA, 1994. 1.1, 3.1.4, 4.1, 4.1.2
- [Moore91] MOORE, A. W.. Variable resolution dynamic programming:efficiently learning action maps in multivariate real-valued statespaces. In: PROCEEDINGS OF THE EIGHTH INTERNATIONAL CONFE-RENCE ON MACHINE LEARNING, p. 333–337, 1991. 4.2.2
- [Moore95] MOORE, M.; NARAYANAN, A.. Quantum-inspired computing, 1995. 2.4, 2.4, 2.4, 2.4
- [Moriarty97] MORIARTY, D. E.. Symbiotic Evolution of Neural Networks in Sequential Decision Tasks. PhD thesis, The University of Texas at Austin, 1997. 2.7

- [Narayanan96] NARAYANAN, A.; MOORE, M.. Quantum inspired genetic algorithms. In: INTERNATIONAL CONFERENCE ON EVOLUTIONARY COMPUTATION, p. 61–66, 1996. 1.1
- [Planck01] PLANCK, M.. On the law of distribution of energy in the normal spectrum. Annalen der Physik, 4:553, 1901. 2.1.1
- [Reynolds94] REYNOLDS, R. G.. An introduction to cultural algorithms. In: PROCEEDINGS OF THE 3RD ANNUAL CONFERENCE ON EVOLUTIO-NARY PROGRAMMING, p. 131–139, 1994. 1.1, 2.6
- [Reynolds04] REYNOLDS, R. G.; PENG, B.. Cultural algorithms: Modeling of how cultures learn to solve problems. In: PROCEEDINGS OF THE 18TH IEEE INTERNATIONAL CONFERENCE ON TOOLS WITH ARTIFICIAL INTELLIGENCE (ICTAI 2004), 2004. 1.1, 2.6.1, 2.6.1
- [Rieffel00] RIEFFEL, E.; POLAK, W. An introduction to quantum computing for non-physicists. ACM Computing Surveys, 32(5):300–335, 2000. 2.3
- [Robocode] http://robocode.sourceforge.net/. 5.2
- [Rychtyckyj03] RYCHTYCKYJ, N.; OSTROWSKI, D.; SCHLEIS, G. ; REY-NOLDS, R. G.. Using cultural algorithms in industry. In: PROCEEDINGS OF IEEE SWARM INTELLIGENCE SYMPOSIUM, Indianapolis, Indiana, 2003. IEEE Press. 2.6.1
- [Saad98] Saad, D., editor. **On-line Learning in Neural Networks**. Cambridge University Press, 1998. 5.1
- [Skinner95] SKINNER, A.; BROUGHTON, J. Q. Neural networks in computational material science: Training algorithms. Modelling and Simulation in Material and Engineering, 3:371–390, 1995. 2.7
- [Spector04] SPECTOR, L.: Automatic Quantum Computer Programming A Genetic Programming Approach. Springer, 2004. 2.3
- [Stanley02] STANLEY, K. O.; MIIKKULAINEN, R.. Evolving neural networks through augmenting topologies. In: EVOLUTIONARY COMPUTATION, 2002. 2.7
- [Storn95] STORN, R.; PRICE, K.. Differential evolution a simple and efficient adaptive scheme for global optimization over continuous spaces. Technical Report TR-95-012, 1995. 1.1, 3.1.3

- [Tasgetiren05] TASGETIREN, M. F.; GENCYLMAZ, G.; LIANG, Y.-C. ; EKER, I.. A differential evolution algorithm for continuous function optimization. In: CONGRESS ON EVOLUTIONARY COMPUTATION, 2005. 4.1.1
- [Tasgetiren05A] TASGETIREN, M. F.; GENCYLMAZ, G.; LIANG, Y.-C. ; EKER,
 I.. Global optimization of continuous functions using particle swarm optimization. In: CONGRESS ON EVOLUTIONARY COMPUTATION, 2005. 4.1.1
- [Yao99] YAO, X.; LIU, Y.; LIN, G. M.. Evolutionary programming made faster. IEEE Trans. Evolutionary Computation, 3:82–102, 1999. 1.1, 4.1.2
- [Yao99a] YAO, X.. Evolving artificial neural networks. In: PROCEEDINGS OF THE IEEE, volumen 87, p. 1423–1447, 1999. 1.1

Anexo 1

Funções para Medida de Desempenho

Função Sphere Deslocada

$$f_1(\mathbf{x}) = \sum_{i=1}^D z_i^2 + bias_1$$

$$\mathbf{z} = \mathbf{x} - \mathbf{0}, \mathbf{x} = [x_1, x_2, \cdots, x_D]$$



Figura 5.3: Mapa 3D da função f_1 .

- Unimodal
- Deslocamento da origem
- Separável
- Escalonável
- − $\mathbf{x} \in [-100, 100]^{D}$, Ótimo global: $\mathbf{x}^* = \mathbf{0}, F_1(\mathbf{x}^*) = bias_1 = -450$

Função Schwefel Deslocada

$$f_2(\mathbf{x}) = \sum_{i=1}^{D} \left(\sum_{j=1}^{i} z_j \right)^2 + bias_2$$

$$\mathbf{z} = \mathbf{x} - \mathbf{0}, \mathbf{x} = [x_1, x_2, \cdots, x_D]$$



Figura 5.4: Mapa 3D da função f_2 .

- Unimodal
- Deslocamento da origem
- Não-separável
- Escalonável
- − $\mathbf{x} \in [-100, 100]^{D}$, Ótimo global: $\mathbf{x}^{*} = \mathbf{0}, F_{2}(\mathbf{x}^{*}) = bias_{2} = -450$

Função Elíptica Rotacionada e Deslocada

$$f_3(\mathbf{x}) = \sum_{i=1}^{D} \left(10^6\right)^{\frac{i-1}{D-1}} z_i^2 + bias_3$$

$$\mathbf{z} = (\mathbf{x} - \mathbf{o}) \cdot \mathbf{M}, \mathbf{x} = [x_1, x_2, \cdots, x_D]$$



Figura 5.5: Mapa 3D da função f_3 .

- Unimodal
- Deslocamento da origem
- Rotacionada
- Não-separável
- Escalonável
- **M** é uma matriz ortogonal qualquer pré-definida
- − $\mathbf{x} \in [-100, 100]^{D}$, Ótimo global: $\mathbf{x}^{*} = \mathbf{0}, F_{3}(\mathbf{x}^{*}) = bias_{3} = -450$

Função Schwefel 1.2 Deslocada com Ruído

$$f_4(\mathbf{x}) = \left(\sum_{i=1}^{D} \left(\sum_{j=1}^{i} z_j\right)^2\right) * (1 + 0.4 |N(0,1)|) + bias_4$$

$$\mathbf{z} = \mathbf{x} - \mathbf{0}, \mathbf{x} = [x_1, x_2, \cdots, x_D]$$



Figura 5.6: Mapa 3D da função f_4 .

- Unimodal
- Deslocamento da origem
- Não-separável
- Escalonável
- Ruído aleatório
- $\mathbf{x} \in [-100, 100]^D$, Ótimo global: $\mathbf{x}^* = \mathbf{0}, F_4(\mathbf{x}^*) = bias_4 = -450$

Função Schwefel 2.6

$$f_5(\mathbf{x}) = max\{|\mathbf{A}_i\mathbf{x} - \mathbf{B}_i|\} + bias_5$$

A é uma matriz DxD, onde a_{ij} são números inteiros aleatórios no intervalo [-500, 500], det(**A**) $\neq 0$, **A**_i é a *i*-ésima linha de **A**.

 $\mathbf{B}_i = \mathbf{A}_i * \mathbf{0}$, $\mathbf{0}$ é um vetor Dx1, onde o_i é um número aletório no intervalo [-100, 100].



Figura 5.7: Mapa 3D da função f_5 .

- Unimodal
- Não-separável
- Escalonável
- Ótimo global na borda do domínio
- − $\mathbf{x} \in [-100, 100]^{D}$, Ótimo global: $\mathbf{x}^{*} = \mathbf{0}, F_{5}(\mathbf{x}^{*}) = bias_{5} = -310$

Função Rosenbrock Deslocada

$$f_6(\mathbf{x}) = \sum_{i=1}^{D} \left(100 \left(z_i^2 - z_{i+1} \right)^2 + (z_i - 1)^2 \right) + bias_6$$

$$\mathbf{z} = \mathbf{x} - \mathbf{0} + 1, \mathbf{x} = [x_1, x_2, \cdots, x_D]$$



Figura 5.8: Mapa 3D da função f_6 .

- Multi-modal
- Deslocamento da origem
- Não-separável
- Escalonável
- Esta função tem um vale muito estreito entre o mínimo local e o mínimo global

$$-\mathbf{x} \in [-100, 100]^D$$
, Ótimo global: $\mathbf{x}^* = \mathbf{0}, F_6(\mathbf{x}^*) = bias_6 = 390$

Função Ackley Rotacionada e Deslocada

$$f_8(\mathbf{x}) = -20 \exp\left(-0.2 \sqrt{\frac{1}{D} \sum_{i=1}^{D} z_i^2}\right) - \exp\left(\frac{1}{D} \sum_{i=1}^{D} \cos\left(2\pi z_i\right)\right) + 20 + e + bias_8$$

 $\mathbf{z} = (\mathbf{x} - \mathbf{o}) \cdot \mathbf{M}, \mathbf{x} = [x_1, x_2, \cdots, x_D]$

M é uma matriz de transformação linear com um número de condição igual a 100.



Figura 5.9: Mapa 3D da função f_8 .

- Multi-modal
- Deslocamento da origem
- Rotacionada
- Não-separável
- Escalonável
- Ótimo global na borda do domínio
- − $\mathbf{x} \in [-32, 32]^D$, Ótimo global: $\mathbf{x}^* = \mathbf{0}, F_8(\mathbf{x}^*) = bias_8 = -140$

Função Rastrigin Deslocada

$$f_9(\mathbf{x}) = \sum_{i=1}^{D} \left(z_i^2 - 10 \cos \left(2\pi z_i \right) + 10 \right) + bias_9$$

$$\mathbf{z} = \mathbf{x} - \mathbf{0}, \mathbf{x} = [x_1, x_2, \cdots, x_D]$$



Figura 5.10: Mapa 3D da função f₉.

- Multi-modal
- Deslocamento da origem
- Separável
- Escalonável
- Grande número de ótimos locais
- − $\mathbf{x} \in [-5, 5]^D$, Ótimo global: $\mathbf{x}^* = \mathbf{0}, F_9(\mathbf{x}^*) = bias_9 = -330$

Função Rastrigin Deslocada e Rotacionada

$$f_{10}(\mathbf{x}) = \sum_{i=1}^{D} \left(z_i^2 - 10 \cos\left(2\pi z_i\right) + 10 \right) + bias_{10}, \left[-5, 5\right]^D$$

$$\mathbf{z} = (\mathbf{x} - \mathbf{o}) \cdot \mathbf{M}, \mathbf{x} = [x_1, x_2, \cdots, x_D]$$

M é uma matriz de transformação linear com um número de condição igual a

2.



Figura 5.11: Mapa 3D da função f_{10} .

- Multi-modal
- Deslocamento da origem
- Rotacionada
- Não-Separável
- Escalonável
- Grande número de ótimos locais
- − $\mathbf{x} \in [-5, 5]^{D}$, Ótimo global: $\mathbf{x}^{*} = \mathbf{0}, F_{10}(\mathbf{x}^{*}) = bias_{10} = -330$

Função Weierstrass Deslocada e Rotacionada

$$f_{11}(\mathbf{x}) = \sum_{i=1}^{D} \left(\sum_{k=0}^{20} \left[0.5^k \cos\left(2\pi 3^k \left(z_i + 0.5\right)\right) \right] \right) - D \sum_{k=0}^{20} \left[0.5^k \cos\left(2\pi 3^k \cdot 0.5\right) \right] + bias_{11}$$

 $\mathbf{z} = (\mathbf{x} - \mathbf{o}) \cdot \mathbf{M}, \mathbf{x} = [x_1, x_2, \cdots, x_D]$

M é uma matriz de transformação linear com um número de condição igual a 5.



Figura 5.12: Mapa 3D da função f_{11} .

- Multi-modal
- Deslocamento da origem
- Rotacionada
- Não-Separável
- Escalonável
- Função contínua mas diferenciável apenas em alguns pontos
- $\mathbf{x} \in [-0.5, 0.5]^D$, Ótimo global: $\mathbf{x}^* = \mathbf{0}, F_{11}(\mathbf{x}^*) = bias_{11} = 90$

Função Schwefel 2.13

$$f_{12}(\mathbf{x}) = \sum_{i=1}^{D} (\mathbf{A_i} - \mathbf{B_i}(\mathbf{x}))^2 + bias_{12}$$
$$\mathbf{A}_i = \sum_{j=1}^{D} \left(a_{ij} \sin \alpha_j + b_{ij} \cos \alpha_j \right)$$
$$\mathbf{B}_i(x) = \sum_{j=1}^{D} \left(a_{ij} \sin x_j + b_{ij} \cos x_j \right), i = 1, \cdots, D$$



Figura 5.13: Mapa 3D da função f_{12} .

- Multi-modal
- Deslocamento da origem
- Não-Separável
- Escalonável
- − $\mathbf{x} \in [-\pi, \pi]^D$, Ótimo global: $\mathbf{x}^* = \alpha, F_{12}(\mathbf{x}^*) = bias_{12} = -460$

Função Griewank e Rosenbrock Expandida e Deslocada

Considerando-se as funções:

F8 - Função Griewank : $F8(x) = \sum_{i=1}^{D} \frac{x_i^2}{4000} - \prod_{i=1}^{D} \cos\left(\frac{x_i}{\sqrt{t}}\right) + 1$ F2 - Função Rosenbrock : $F2(x) = \sum_{i=1}^{D-1} \left(100\left(x_i^2 - x_{i+1}\right)^2 + (x_i - 1)^2\right)$ $f_{13}(\mathbf{x}) = F8(F2(z_1, z_2)) + F8(F2(z_2, z_3)) + \dots + F8(F2(z_{D-1}, z_D)) + F8(F2(z_D, z_1)) + bias_{13}$

$$\mathbf{z} = \mathbf{x} - \mathbf{o} + 1, \mathbf{x} = [x_1, x_2, \cdots, x_D]$$



Figura 5.14: Mapa 3D da função f_{13} .

- Multi-modal
- Deslocamento da origem
- Não-separável
- Escalonável
- − $\mathbf{x} \in [-5, 5]^D$, Ótimo global: $\mathbf{x}^* = \mathbf{0}, F_{13}(\mathbf{x}^*) = bias_{13} = -130$

Função F6 Expandida, Rotacionada e Deslocada

Considerando-se a função:

$$F(x, y) = 0.5 + \frac{\left(\sin^2\left(\sqrt{x^2 + y^2}\right) - 0.5\right)}{\left(1 + 0.001\left(x^2 + y^2\right)\right)^2}$$

$$f_{14}(\mathbf{x}) = F(z_1, z_2) + F(z_2, z_3) + \dots + F(z_{D-1}, z_d) + F(z_D, z_1) + bias_{14}$$

$$\mathbf{z} = (\mathbf{x} - \mathbf{o}) \cdot \mathbf{M}, \mathbf{x} = [x_1, x_2, \cdots, x_D]$$

 \mathbf{M} é uma matriz de transformação linear com um número de condição igual a

Função f_{14}

Figura 5.15: Mapa 3D da função f_{14} .

- Multi-modal
- Deslocamento da origem
- Não-separável
- Escalonável
- − $\mathbf{x} \in [-100, 100]^{D}$, Ótimo global: $\mathbf{x}^{*} = \mathbf{0}, F_{14}(\mathbf{x}^{*}) = bias_{14} = -300$

5.

103

Anexo 2

Funções para Medida de Desempenho

Função Sphere





Figura 5.16: Mapa 3D da função $f_{S phere}$.

- Unimodal
- − $\mathbf{x} \in [-100, 100]^{D}$, Ótimo global: $\mathbf{x}^{*} = \mathbf{0}, f_{S phere}(\mathbf{x}^{*}) = 0$

Função Ackley

$$f_{Ackley}(\mathbf{x}) = -20 \exp\left(-0.2 \sqrt{\frac{1}{D} \sum_{i=1}^{D} x_i^2}\right) - \exp\left(\frac{1}{D} \sum_{i=1}^{D} \cos(2\pi x_i)\right) + 20 + e^{-\frac{1}{D} \sum_{i=1}^{D} x_i^2}$$



Figura 5.17: Mapa 3D da função *f*_{Ackley}.

- Multi-modal
- − $\mathbf{x} \in [-32, 32]^D$, Ótimo global: $\mathbf{x}^* = \mathbf{0}, f_{Ackley}(\mathbf{x}^*) = 0$

Função Griewank

$$f_{Griewank}(\mathbf{x}) = \frac{1}{4000} \sum_{i=1}^{D} x_i^2 - \prod_{i=1}^{D} \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$$



Figura 5.18: Mapa 3D da função $f_{Griewank}$.

- Multi-modal

− $\mathbf{x} \in [-600, 600]^D$, Ótimo global: $\mathbf{x}^* = \mathbf{0}, f_{Griewank}(\mathbf{x}^*) = 0$

Função Rastrigin

$$f_{Rastrigin}(\mathbf{x}) = \sum_{i=1}^{D} \left[x_i^2 - 10\cos(2\pi x_i) + 10 \right]$$



Figura 5.19: Mapa 3D da função $f_{Rastrigin}$.

- Multi-modal

- $\mathbf{x} \in [-5.12, 5.12]^D$, Ótimo global: $\mathbf{x}^* = \mathbf{0}, f_{Rastrigin}(\mathbf{x}^*) = 0$

Função Schwefel 2.26

$$f_{Schwefel}(\mathbf{x}) = -\sum_{i=1}^{D} \left(x_i \sin\left(\sqrt{|x_i|}\right) \right) + 12569.5$$



Figura 5.20: Mapa 3D da função *f_{Schwefel}*.

- Multi-modal
- − $\mathbf{x} \in [-500, 500]^D$, Ótimo global: $\mathbf{x}^* = 420.9687$, $f_{Schwefel}(\mathbf{x}^*) = 0$

Função Rosenbrock

$$f_{Rosenbrock}(\mathbf{x}) = \sum_{i=1}^{D-1} \left[100 \left(x_{i+1} - x_i^2 \right)^2 + (x_i - 1)^2 \right]$$



Figura 5.21: Mapa 3D da função $f_{Rosenbrock}$.

- Multi-modal

- $\mathbf{x} \in [-30, 30]^{D}$, Ótimo global: $\mathbf{x}^{*} = \mathbf{1}, f_{Rosenbrock}(\mathbf{x}^{*}) = 0$