

Análise Comparativa de Técnicas de Inteligência Computacional na Classificação de Jogadores de Xadrez

Pedro H. A. Ribeiro¹, Ronnyel C. C. Silva¹, José M. P. M Júnior¹

¹Grupo de Análise de Sistemas Inteligentes – Universidade Federal do Piauí (UFPI)
Campus Universitário Ministro Petrônio Portella, s/n Bairro Ininga
CEP: 64049-550 – Teresina – PI – Brasil

pedro.eeufpi@gmail.com, ronnyelcarlos@gmail.com,
josemenezesjr@ufpi.edu.br

Abstract. *In this work, the Multi-Layer Perceptron (MLP), Radial Base Network (RBF), and Learning Vector Quantization (LVQ) neural patterns are repeated to solve the problem of classification of chess players in levels (basic, intermediate and advanced). The following parameters were used as input to neural networks as indicators of chess match performance: peer media, inaccuracies, errors and grave errors. For each technique used, four network topologies were used, which varied the number of hidden layer neurons. Performance measures were mean acuity, minimum acuity, minimum acuity, mean acuity, standard deviation of actions, and mean square error (MSE). The results were more than an MLP obtained as the best performance solutions in solving the chess player classification problem.*

Resumo. *Neste trabalho são aplicadas redes neurais Perceptron de Múltiplas Camadas (MLP), Rede de Base Radial (RBF) e Rede Learning Vector Quantization (LVQ) para resolver o problema de classificação de jogadores de xadrez em níveis (básico, intermediário e avançado). Foram usados como parâmetros de entrada das redes neurais as seguintes métricas de desempenho da partida de xadrez: perdas médias em centésimo de peões, imprecisões, erros e erros graves. Para cada técnica usada, utilizou-se quatro topologias de rede, onde fez-se variar a quantidade de neurônios da camada oculta. As métricas de desempenho usadas foram a acuidade média, acuidade máxima, acuidade mínima, acuidade mediana, desvio padrão das acuidades e o Erro Médio Quadrático (MSE). Os resultados encontrados mostraram que a MLP obteve as melhores métricas de desempenho na solução do problema de classificação de jogadores de xadrez.*

1. Introdução

O xadrez pode ser utilizado no ensino como ferramenta para desenvolver no estudante a capacidade de atenção, memória, raciocínio lógico, inteligência e imaginação. Além disso, esse jogo trabalha o poder de concentração, paciência, imaginação e autocontrole do jogador, uma vez que há a necessidade de visualizar as jogadas futuras do seu adversário. Dessa forma, o jogo de xadrez é um excelente meio para ampliar o desenvolvimento das capacidades intelectuais (D'Agostini, 2002).

Silva (2010) mostra que há correlação positiva entre os desempenhos no jogo de xadrez e a Escala de Desenvolvimento do Pensamento Lógico (EDPL). Realizou a análise das partidas jogadas contra o computador, por jogadores iniciantes, experientes e mestres com os objetivos de caracterizar e comparar o desempenho enxadrístico dos grupos, e calcular seu índice de expertise no xadrez. Pela comparação entre nível enxadrístico e

desempenho na EDPL, pode-se identificar em quais provas da EDPL os participantes apresentaram melhor desempenho.

Segundo Dauvergne (2011) a concentração e a atenção são desenvolvidas e estimuladas pelo xadrez e representam um conjunto crucial para a progressão da partida, uma vez que um deslize na concentração pode acarretar um erro simples ou, até mesmo, o término da partida.

Portanto, é evidente a importância do jogo de xadrez como ferramenta pedagógica no auxílio do desenvolvimento de habilidades importantes dos estudantes. Nesse sentido, faz-se necessário que os estudantes tenham o seu desempenho avaliado mediante análise das partidas jogadas, ao longo do processo de estudo e prática do jogo de xadrez.

A classificação de jogadores de xadrez em todo o mundo é feita, normalmente, mediante a utilização de *rating fide*. Esta métrica mede a força de jogadores de xadrez através de fórmulas matemáticas, levando em conta todas as suas partidas oficiais jogadas ao longo da sua carreira. Na prática, o nível de um jogador de xadrez está compreendido dentro de uma faixa de *rating fide*, ou seja, hora o jogador tem um desempenho melhor, hora o jogador tem um desempenho pior. Portanto, o nível de uma partida jogada não necessariamente corresponde ao nível teórico que o jogador possui.

Esse trabalho, então, propõe a classificação dos jogadores de xadrez tomando por base, não o uso do *rating fide*, mas o nível de precisão das partidas jogadas, analisando-as no formato *Portable Game Notation (PGN)*, formato cujas partidas de xadrez são registradas e anotadas para análise.

Atualmente, existem vários sistemas de notação de partidas, os mais conhecidos são: o descritivo e o algébrico. Outros sistemas atuais para notação incluem o PGN, que usa o sistema algébrico para armazenar partidas em computador; e o FEN (ou *Forsyth*), usado para anotar posições de meio-jogo ou finais (D'Agostini, 2002).

O sistema de notação algébrica é um método usado hoje em todas as organizações de competição de xadrez e na maioria dos livros e periódicos para registrar e descrever lances de partidas de Xadrez. Assim, as partidas de xadrez registradas no formato PGN utilizam a notação algébrica abreviada, onde existe uma codificação para cada movimento das peças, que depende da peça em questão, a coordenada do tabuleiro, ou no caso de um movimento especiais, símbolos específicos (D'Agostini, 2002).

Jeremic et al (2010) usaram o método estatístico de classificação em um campeonato de xadrez de equipe, no qual examinaram os resultados do torneio de 2008 e 2009 aplicando o método de classificação estatística. O objetivo do trabalho foi comparar a classificação nestes dois torneios e, pela primeira vez, avaliar quantitativamente o método de classificação nos campeonatos de xadrez por equipes.

Reingold et al (2001) utilizaram o padrão de movimentos oculares dos jogadores para realizar a classificação. Nesse trabalho, verificou-se que jogadores mais fortes percebem mais quadrados com uma fixação simples e que eles gastam menos tempo para inspecionar cada quadrado do que jogadores mais fracos. Além disso, o número de quadrados revisitados é, pelo menos, para problemas mais fáceis, significativamente menor para jogadores de maior força.

Erilli et al (2010), pelo uso da análise de clusterização *fuzzy*, classificam os jogadores de xadrez segundo os seus estilos em agressivo, defensivo e posicional. Para tal, usaram logica *fuzzy* e partidas de xadrez no Código de Classificação de Aberturas (ECO).

Assim, esse trabalho apresenta como proposta inovadora a aplicação de redes neurais artificiais para classificar jogadores de xadrez nos níveis iniciante, intermediário e avançado, mediante o uso de dados das partidas de xadrez disponíveis para análise no formato PGN.

2. Descrição das técnicas computacionais utilizadas

2.1. Multilayer Perceptron - MLP

As MLP são técnicas computacionais compostas por camadas de neurônios que tentam representar ou apresentar comportamento similar ao cérebro humano. São comumente usadas na impossibilidade de separação de dados por uma única reta (Silva et al, 2010). Representação generalista desta rede com uma única camada escondida, Figura 1, está baseada no modelo *perceptron* proposto por Rosenblatt, que continha algoritmos de treinamento supervisionado para a atualização dos pesos entre as sinapses, fase de retropropagação do erro (*backpropagation*).




Figure 1. Representação generalista de uma rede neural MLP

A determinação da quantidade de camadas ocultas, cuja finalidade é a extração de características mais complexas de um banco de dados, é dependente da quantidade de neurônios em sequência e pode ou não melhorar a acuidade média de um algoritmo. No entanto, o aumento da complexidade do problema está relacionado com o processamento das informações na camada oculta, e, assim, com o tempo necessário para treinamento da rede (Bishop, 1995). O treinamento da rede se baseia na atualização dos pesos sinápticos entre os neurônios, que transmitem a informação recebida da entrada pela rede, fornecendo a saída estimada, que é comparada ao resultado desejado produzindo o custo (feedback). Este, por sua vez, permite a atualização dos pesos (Chollet, 2018).

2.2. Radial Basis Function Neural Network - RBF

São redes neurais que têm tido significativo destaque ao se trabalhar com redes neurais artificiais, por sua simplicidade no processo de treinamento (*feedforward*), podendo ser supervisionado, e eficiência computacional. A estrutura da rede RBF pode ser do tipo múltiplas camadas ou híbrida, esta utilizada neste trabalho, no qual se combina um método não supervisionado e um supervisionado (Fernandes, 1999). Logo, os centros das funções de base radial são os pesos dos neurônios escondidos e o conjunto de funções de base são funções não lineares aplicadas aos neurônios da camada escondida. A saída é uma combinação ponderada das funções de base radial (Poggio, 1990).

A representação mais simplificada de uma rede RBF consiste de uma camada de entrada, apenas uma camada oculta, responsável pela transformação não-linear entre o espaço de entrada e o espaço oculto de alta dimensionalidade, e a camada de saída, que aplica uma transformação linear no espaço oculto fornecendo uma saída para a rede (Bonifácio, 2010), conforme ilustrada pela Figura 2.




Figure 2. Representação generalista de uma rede neural RBF

Em relação ao treinamento desta rede neural, tem-se que na primeira etapa, utiliza-se um algoritmo não-supervisionado para encontrar os centros das funções de base radial. Na segunda etapa, utilizam-se métodos heurísticos para determinar a largura de cada função. Por fim, na terceira etapa, um algoritmo supervisionado determina os pesos da camada de saída da rede (Hu, 2002). Alguns algoritmos não-supervisionados usados para a determinação dos centros das funções de base radial são as redes SOM de Kohonen (Kohonen, 1997), implementado neste trabalho, o ART e k-means.

2.3. Learning Vector Quantization - LVQ

É uma rede baseada na competição supervisionada entre neurônios para a classificação de entradas. Nesta rede, cada neurônio possui um vetor de sinapses equivalente aos valores do vetor de entrada e uma classe à qual ele pertence. Para cada entrada é definido um neurônio vencedor, no qual, caso seja da classe equivalente à entrada, seus pesos serão aproximados aos valores da entrada, senão, seus pesos serão afastados e o processo é repetido, até que o neurônio vencedor seja de mesma classe da entrada. Para a definição do vencedor é usado a fórmula da distância euclidiana, que verifica a proximidade entre dois vetores. O neurônio vencedor representa a menor distância entre o mesmo e a entrada apresentada (Santos, 2010).

Cada classe será referenciada a um vetor de pesos, os quais representam os centros de clusters que definem as superfícies de decisão das classes. Uma classe pode ser definida por um ponto único ou por um conjunto de pontos (para uma melhor representação no caso de superfícies de decisão irregulares). Este tipo de rede assume que um conjunto de padrões de treinamento de classificação conhecida é disponível, junto com uma distribuição inicial dos vetores de referência (Kugler, 2003).

3. Metodologia do trabalho

Para a aplicação das técnicas de inteligência computacionais supracitadas, inicialmente, realizou-se a coleta de 450 partidas de xadrez jogadas contra o programa *stockfish* no site *lichess.org* nos níveis 1, 5 e 8, os quais serão definidos, respectivamente, como iniciante, intermediário e avançado. Para cada nível foram coletadas 150 partidas de xadrez no formato PGN.

Realizou-se, então, a análise delas de maneira a extrair as características (métricas de avaliação) a serem usadas como entradas das redes neurais citadas anteriormente. Assim, como métricas de avaliação, tem-se: perdas médias em centésimos de peão, imprecisões, erros e erros graves, conforme pode ser visto no fluxograma da Figura 3.

A partir de cada partida de xadrez no formato PGN foram extraídas quatro variáveis (métricas de erro), as quais foram usadas como entrada das redes neurais. Como saída da rede, tem-se o nível da partida jogada (nível iniciante, nível intermediário ou nível avançado). Esse procedimento de extração de características foi realizado para todas as 450 partidas de xadrez coletadas. Por fim, o banco de dados obtido possui 450 instâncias, sendo quatro entradas (métricas de avaliação) e uma saída (nível do jogador).

Usaram-se como métricas de desempenho das redes neurais a média de acuidade, desvio padrão das acuidades, acuidade máxima, acuidade mínima e o MSE, uma vez que ao se usar técnicas heurísticas para a classificação, deve-se fornecer, para cada técnica usada, certa confiabilidade. Isto pode ser fornecido estatisticamente pelo cálculo da média, mediana, valores máximo e mínimo e desvio padrão de cada algoritmo, após repetições da mesma técnica para uma determinada configuração. Realizou-se, então, para cada técnica usada, 30 repetições.

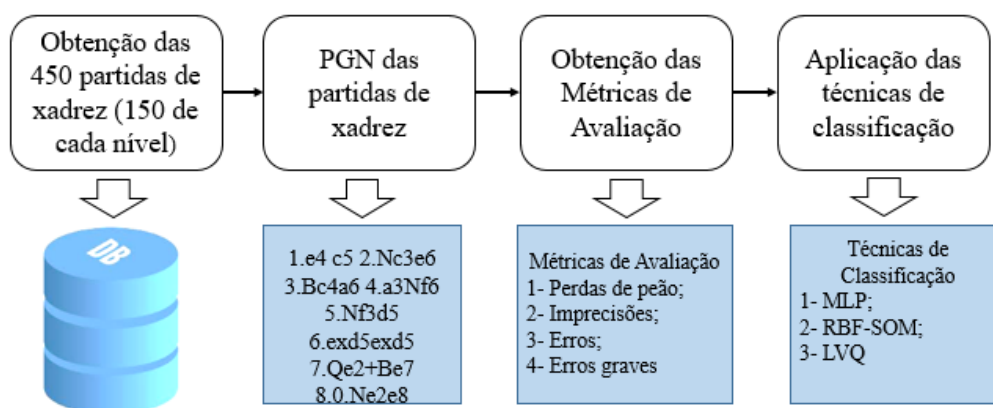


Figura 3. Fluxograma da metodologia adotada

A dificuldade do problema de classificação em questão pode ser verificada pela Figura 4, que apresenta a distribuição das amostras de cada classe em função de seus atributos (métricas). Nesta Figura, a primeira métrica corresponde às perdas médias em centésimos de peão, a segunda métrica às imprecisões, a terceira métrica aos erros e a quarta métrica aos erros graves. Ainda, verifica-se que as três classes do problema (nível iniciante, intermediário e avançado) estão muito próximas espacialmente (para todas as combinações entre as métricas de avaliação usadas) e que, além da proximidade, na maioria dos casos, existe a sobreposição das classes de dados no plano cartesiano, o que sugere um elevado grau de dificuldade na tarefa de classificação dos dados.

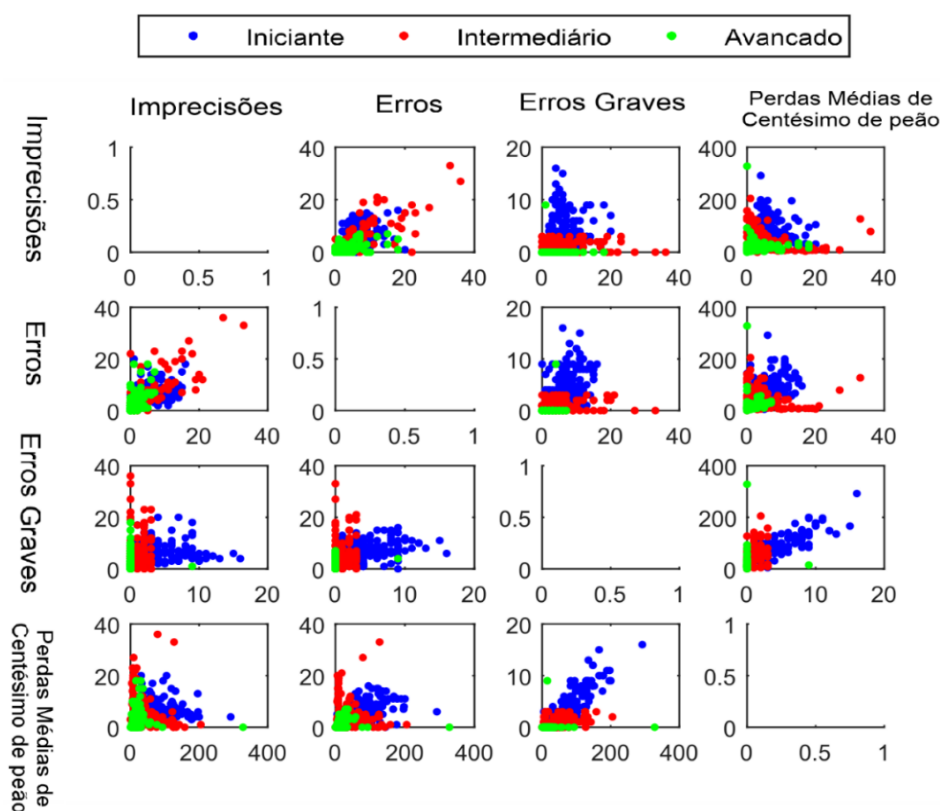


Figura 4. Matriz de dispersão do banco de dados de xadrez

4. Resultados e Discussões

Considerando as três redes neurais aplicadas, a saber: MLP, RBF-SOM e LVQ, implementaram-se quatro topologias, cada uma contendo uma camada de entrada, uma camada oculta (com 5,10,15 e 20 neurônios) e uma camada de saída (contendo 3 neurônios). Pode-se notar que de todas as técnicas usadas apenas a camada oculta teve a sua quantidade de neurônios variada. Usaram-se 80% dos dados para treinamento e 20% para teste e para cada topologia de rede, repetiu-se o teste por 30 vezes. Os resultados obtidos para as técnicas de classificação aplicadas estão mostrados na Tabela 1.

Tabela 1 – Métricas de desempenho das técnicas de classificação usadas

| Técnica | Topologia | Média (%) | Mediana (%) | Máximo (%) | Mínimo (%) | Desvio (%) | MSE |
|---------|-----------|-----------|-------------|------------|------------|------------|------|
| MLP | 5 | 83,04 | 82,22 | 95,56 | 68,89 | 5,79 | 0,16 |
| | 10 | 87,26 | 86,67 | 95,56 | 77,78 | 6,33 | 0,15 |
| | 15 | 86,30 | 86,67 | 93,33 | 77,78 | 4,45 | 0,15 |
| | 20 | 85,26 | 84,44 | 95,56 | 73,33 | 5,07 | 0,15 |
| LVQ | 5 | 65,19 | 68,89 | 80,00 | 35,56 | 12,51 | - |
| | 10 | 71,26 | 71,11 | 88,89 | 53,33 | 6,75 | - |
| | 15 | 70,59 | 71,11 | 80,00 | 55,56 | 7,16 | - |
| | 20 | 72,52 | 73,33 | 86,67 | 57,78 | 7,32 | - |
| RBF-SOM | 5 | 75,11 | 75,56 | 88,89 | 62,22 | 6,56 | 0,28 |
| | 10 | 80,15 | 80,00 | 93,33 | 62,22 | 6,85 | 0,21 |
| | 15 | 79,56 | 77,78 | 86,67 | 73,33 | 4,62 | 0,19 |

| | | | | | | | |
|--|----|-------|-------|-------|-------|------|------|
| | 20 | 82,37 | 82,22 | 97,78 | 71,11 | 6,17 | 0,19 |
|--|----|-------|-------|-------|-------|------|------|

Os resultados apresentados mostram que a rede MLP com 10 neurônios na camada oculta obteve os melhores desempenhos de acuidade média. Em contrapartida, o menor desvio padrão dentre todas as técnicas usadas no processo de classificação dos jogadores de xadrez foi obtido pela rede MLP com 15 neurônios. Uma vez que em termos práticos as variações em até 5% não é tão significativa, pode-se concluir que a rede MLP com 10 ou 15 neurônios apresentará os melhores desempenhos para o problema abordado.

As redes RBF-SOM e LVQ apresentaram desempenho inferior ao da MLP por se basearem em quantizadores vetoriais, logo, usam a distância Euclidiana para determinar a classe a qual cada amostra de dados pertence. Portanto, devido à dificuldade inerente ao banco de dados (proximidade excessiva), as distâncias calculadas são semelhantes e não permitem a classificação com precisão superior à técnica MLP.

Observando-se que a maior acuidade média foi de 87,26%, percebe-se que este trabalho abre margem para a realização de futuros trabalhos que venham a melhorar os resultados obtidos neste artigo. Logo, uma possível solução seria a aplicação de outras técnicas de classificação, como a rede Neural ELM (*Extreme Learning Machine*).

Tabela 2 – Matriz de confusão para a classificação usando a MLP

| | Iniciante | Intermediário | Avançado |
|---------------|-----------|---------------|----------|
| Iniciante | 28 | 5 | 0 |
| Intermediário | 2 | 25 | 6 |
| Avançado | 0 | 0 | 24 |

A análise da disposição espacial das três classes de dados, conforme verificado na Figura 4, bem como a observação da matriz de confusão da Tabela 2 dos dados de teste, mostra que existe grande proximidade entre os dados das classes “nível intermediário” e “nível avançado”, o que justifica a dificuldade no processo de classificação dos jogadores pertencentes a tais classes.

5. Conclusão

Utilizando-se as redes neurais MLP, RBF-SOM e LVQ para a classificação, percebeu-se aptidão satisfatória para resolução do problema de classificação dos jogadores de xadrez, usando-se métricas de erros extraídas de partidas de xadrez no formato PGN. Tal fato não descarta a possibilidade de aplicação de outras técnicas de classificação, como a rede ELM, buscando-se melhorar os desempenhos de classificação apresentados, uma vez que a hipótese levantada na metodologia do problema sobre a dificuldade do mesmo pode ser comprovada após a obtenção dos resultados.

Dentre as redes aplicadas, a MLP apresentou os melhores resultados, obtendo 87,26% de acuidade média na tarefa de classificação e 4,45% de desvio padrão, enquanto que a rede LVQ apresentou os resultados menos expressivos, em sua melhor configuração obteve-se 72,52% para a acuidade média e 7,32% de desvio padrão.

A classificação de jogadores de xadrez mediante a utilização da avaliação de partidas de xadrez jogadas pode ser usada como ferramenta para acompanhar a evolução do desempenho de jogadores ao longo da evolução dos estudos. Além disso, essa metodologia pode ser usada para avaliar o desempenho de jogadores de xadrez em torneios e competições de maneira a apontar o nível do desempenho do jogador.

Referências

- Bishop, Christopher M. et al. Neural networks for pattern recognition. Oxford university press, 1995.
- Bonifácio, F. N. Comparação entre as Redes Neurais Artificiais MLP, RBF e LVQ na Classificação de Dados. Paraná: Universidade Estadual do Oeste do Paraná, 2010.
- Chollet, F. Deep Learning mit Python und Keras: Das Praxis-Handbuch vom Entwickler der Keras-Bibliothek. MITP-Verlags GmbH & Co. KG, 2018. D'Agostini, Orfeu Gilberto. Xadrez básico. Ediouro Publicações, 2002.
- D'Agostini, Orfeu Gilberto. Xadrez básico. Ediouro Publicações, 2002.
- Dauvergne, P. The case for chess as a tool to develop our children's mind. University of Sidney. Disponível em: <<http://www.auschess.org.aurticles/chessmind.htm>> Acesso em: 20 de março de 2019.
- Erilli, N. A. et al. (2010) Classifying Chess Players with Fuzzy Clustering Analysis in Fuzzy Data Using Eco Codes. In: 1st International Symposium on Computing in Science & Engineering Proceedings Book. p. 1105-1110.
- Fernandes, M. A. C. Aplicação das Redes RBF na Detecção Inteligente de Sinais Digitais. Proceeding of the IV Brazilian Conference on Neural Networks. Pp 226-230. São José dos Campos. São Paulo. Brazil.
- HU, Yu Hen; HWANG, Jenq-Neng. Introduction to neural networks for signal processing. Handbook of neural network signal processing, p. 12-41, 2002.
- Jeremic, V. M.; Radojicic, Z. (2010) A new approach in the evaluation of team chess championships rankings. Journal of Quantitative Analysis in Sports, v. 6, n. 3.
- Kohonen, T. K. (1997) Self-Organizing Maps. Springer-Verlag, Berlin, Heidelberg, 2nd extended edition.
- Kugler, M., Júnior, J.T., Lopes, H. S. (2003) Desenvolvimento de uma Rede Neural LVQ em Linguagem VHDL para Aplicações em Tempo-Real. Proceedings of the VI Brazilian Conference on Neural Networks - VI Congresso Brasileiro de Redes Neurais pp. 103-108, June 2-5, 2003 - Centro Universitário da FEI, São Paulo - SP - Brazil.
- Reingold, E. M. et al. (2001) Visual span in expert chess players: Evidence from eye movements. Psychological Science, v. 12, n. 1, p. 48-55.
- Santos, A. B., Castanho, M. J. P., Hernandes, F., Ré, A. M. (2010) Rede Neural LVQ em Câncer de Próstata. Anais do XXXIII Congresso Nacional de Matemática Aplicada e Computacional.
- Silva, IN da; SPATTI, Danilo H.; Flauzino, R. A. Redes neurais artificiais para engenharia e ciências aplicadas. São Paulo: Artliber, v. 23, n. 5, p. 33-111, 2010.
- Silva, W. (2010) Raciocínio logico e o jogo de xadrez = em busca de relações. 2 v. Tese (doutorado) - Universidade Estadual de Campinas, Faculdade de Educação, Campinas, SP. Disponível em: <<http://www.repositorio.unicamp.br/handle/REPOSIP/251446>>. Acesso em: 20 de março de 2019.
- Poggio, T., Girosi, T. (1990) Networks for approximation and learning. Proceedings of the IEEE, 78:1481-1497.