



**Simpósio de Métodos
Numéricos em Engenharia**

25 a 27 de outubro, 2017

Redes Neurais Aplicadas à Classificação de Performance em Jogos Digitais

Alexandre Pereira de Faria
PPGMNE-UFPR
UNIBRASIL
Curitiba, Brasil

Klaus de Geus
PPGMNE-UFPR
Copel Geração e Transmissão
Curitiba, Brasil

Paulo Henrique Siqueira
PPGMNE-UFPR
Curitiba, Brasil

Walmor Cardoso Godoi
PPGFA-UTFPR
Curitiba, Brasil

Resumo—Este trabalho apresenta os estudos iniciais sobre uma Rede Neural Multi-Camadas aplicada à classificação de performance de jogadores do jogo da velha. A partir do conjunto de dados "Tic-Tac-Toe End Game" disponibilizado no UCI Machine Learning, procurou-se determinar uma topologia otimizada que provesse a melhor taxa de classificação dos padrões de entrada. Para tanto foram realizados experimentos em relação à taxa de aprendizagem e números de unidades de processamento de uma rede com apenas uma camada oculta. Ao final do processo foi possível determinar uma topologia de rede que classificou corretamente 99.675% dos 320 padrões de treinamento apresentados e 81.37% dos 638 padrões do conjunto de teste.

Palavras-chave—Redes Neurais Artificiais; Classificação, Jogos Digitais

I. INTRODUÇÃO

A história da Inteligência Artificial e dos jogos de computadores parecem se confundir. Os jogos de tabuleiro, dentre outros, têm sido utilizados para o desenvolvimento de algoritmos capazes de simular as ações de jogadores [1]. Diferentes técnicas têm sido implementadas para mapear as estratégias que permitam ao computador aprender a jogar e, em última instância, conseguir ganhar uma partida contra jogadores humanos. Embora a concepção de algoritmos que permitam ao computador vencer uma partida seja um grande incentivo ao desenvolvimento de novas técnicas e implementações, vale ressaltar que o computador tem se convertido num tutor especialista permitindo

que humanos possam não apenas aprender a jogar, mas treinar e melhorar suas habilidades cognitivas, comportamentais e afetivas. Dessa forma, além do entretenimento, o desenvolvimento de máquinas inteligentes tem estendido suas potencialidades à área da educação e formação profissional. Neste sentido, espera-se que o resultado da interação humano-máquina vá além do mero conhecimento acerca da performance do usuário baseada no sucesso ou insucesso na realização de uma determinada tarefa. Para tanto é preciso que estes sistemas sejam capazes de prover uma classificação ponderada em relação às diversas etapas da realização da tarefa pelo usuário. Muitas técnicas de classificação podem ser implementadas para prover uma medida da performance como, por exemplo, árvores de decisão, máquinas de vetores de suporte e redes neurais artificiais [2]. Neste trabalho apresenta-se a implementação de uma rede neural artificial com uma única camada oculta para a classificação da performance de jogadores do conhecido "jogo da velha".

II. REVISÃO DA LITERATURA

1) *O Jogo da Velha*: O jogo da velha é um jogo de tabuleiro, cuja versão mais simples se constitui num tabuleiro quadrado com nove casas e dois tipos de peças (X ou O), o qual pode ser jogado por duas pessoas. A mecânica do jogo se baseia na ação alternada de cada jogador o qual deve preencher cada casa do tabuleiro com sua respectiva peça. O objetivo do jogo é que três peças do mesmo tipo sejam dispostas em três casas adjacentes na horizontal, na vertical, ou na diagonal do tabuleiro. O fim de partida do jogo da velha admite três possibilidades: empate, "X" ganha ou "O" ganha. Existem 255.168 configurações para o fim de partida, onde o jogador que inicia a partida, pode ganhar 131.184 ou, o outro jogador, pode ganhar 77.904,

Este trabalho está sendo desenvolvido pelo OneReal Research Group no âmbito do projeto de P&D PD-6491-0299/2013, proposto pela Copel Geração e Transmissão S.A., sob os auspícios do Programa de P&D da Agência Nacional de Energia Elétrica (ANEEL).

ou pode haver 46.080 empates [2]. É possível encontrar outras versões do jogo que ampliam o grid ou o formato do tabuleiro, além de versões 3D, no qual o tabuleiro é um reticulado tri-dimensional.

×	○	×	×	○	×	○	×	×
×	○	×	○	×		○	○	
○	×	○	×		○	○	×	×

Figura 1: Empate (dir.), "X" ganha (centro), "O" ganha (esq.)

2) *Classificação de Padrões e Redes Neurais Artificiais:* A aplicação de Redes Neurais Artificiais em problemas de classificação já tem uma história consolidada no âmbito do Reconhecimento de Padrões [3]. As redes neurais foram inspiradas no comportamento do sistema neural biológico e tem como principais características, primeiro, a capacidade de aprender a classificar a partir de um determinado conjunto de padrões apresentados à rede e, segundo, generalizar o aprendizado para a classificação automática de padrões desconhecidos. De forma simplista podemos classificar o aprendizado de uma rede neural em supervisionado, quando são apresentadas à rede as classes as quais pertencem os padrões de entrada, e não-supervisionado. Além disso, as redes neurais são classificadas segundo sua arquitetura e sua topologia (configuração das conexões entre suas camadas). Alguns parâmetros iniciais no projeto de uma rede neural incluem a definição da arquitetura (número de camadas ocultas) e da topologia (número de neurônios em cada camada). Outros parâmetros fundamentais a serem determinados são as funções de ativação dos neurônios (unidades de processamento) e a taxa de aprendizagem da rede. Estes últimos estão relacionados a um dos problemas fundamentais no projeto de uma rede neural, a saber, encontrar os valores dos pesos sinápticos entre os neurônios das camadas da rede de modo que estes pesos definam uma hypersuperfície de separação que permita classificar os padrões de entrada.

III. METODOLOGIA

O projeto da rede neural perceptron multi-camada (MLP) com treinamento supervisionado e algoritmo de treinamento *backpropagation* puro foi executado com base na metodologia estabelecida em [4]. O algoritmo de treinamento e operação foi implementado em C++.

3) *Os Dados:* Os dados utilizados neste trabalho foram obtidos a partir do repositório "Tic-Tac-Toe Endgame Data Set" do UCI Machine Learning. Este conjunto de dados reuni 958 configurações de fim de partida do jogo da velha. Os dados obtidos foram convertidos para padrões de entrada numéricos: "X" = 1, "O" = -1 e branco = "0" e as classes foram convertidas para o formato binário: "X" ganha = 1, e "X" não ganha = -1. Dos 958 padrões obtidos, 320 foram utilizados para o treinamento da rede. A apresentação dos padrões à rede foram randomizados a cada época durante os treinamentos.

4) *O Experimento:* Neste estudo inicial com uma rede MLP com uma única camada oculta foram realizados experimentos com

número de neurônios na camada oculta e taxa de aprendizagem. Os pesos sinápticos iniciais foram gerados randomicamente entre -0.5 e 0.5, e a função de ativação tangente hiperbólica foi escolhida dada a representação binária das classes. Durante o experimento variou-se o número de neurônios na camada oculta de 100 a 1 com um intervalo de 10 em 10. A taxa de aprendizagem foi fixada inicialmente em 0.1 e decrementada linearmente a cada época de treinamento. A partir das topologias que apresentaram os melhores resultados fez-se um refinamento em torno delas com uma variação menor do números de neurônios e, em relação a estes, procurou-se trabalhar com uma taxa de aprendizagem que minimizasse o tempo de execução. Ao final de cada treinamento a respectiva rede foi aplicada para a classificação do conjunto de teste constituído de 638 padrões restantes.

5) *Resultados:* Para aquelas topologias e taxas de aprendizagem que forneceram as maiores taxas de classificação dos padrões de entrada foram selecionadas duas: uma com 75 e, a outra, com 30 neurônios na camada oculta. Em ambos os casos a taxa de aprendizagem inicial de 0.4 apresentou a melhor relação classificação X número de épocas X tempo de processamento. Em relação a classificação do conjunto de treinamento em ambos os casos obteve-se uma taxa de 99.675% de padrões classificados corretamente. A validação das duas configurações, entretanto, apresentou uma pequena diferença percentual em relação a classificação correta dos padrões, com 80.4% no caso da rede com 30 neurônios e 81.37% no caso da rede com 75 neurônios.

IV. CONCLUSÃO

Embora os resultados tenham sido satisfatórios para testes iniciais, reitera-se que outras metodologias podem ser colocadas em prática. Testes com implementação do algoritmo de treinamento modificado, variação da arquitetura e a utilização de diferentes heurísticas associadas, como Algoritmos Genéticos, poderão otimizar a obtenção dos vetores dos pesos sinápticos e, portanto, aumentar a taxa de classificação dos padrões de entrada permitindo assim a sua efetiva utilização para a classificação da performance do usuário.

AGRADECIMENTOS

Agradecemos o apoio e discussão com os pesquisadores do Lactec, UFPR, UTFPR e da Copel durante os seminários do OneReal Research Group.

REFERÊNCIAS

- [1] J. Schaeffer; H. J. van den Herik *Games, Computers, and Artificial Intelligence*, Artificial Intelligence, 134, (1-7), 2002.
- [2] C-H. Chou *Using Tic-Tac-Toe for Learning Data Mining Classifications and Evaluations*, International Journal of Information and Education Technology, Vol. 3, No. 4, August, 2013.
- [3] S. Haykin *Redes neurais: princípios e prática*, 2 ed. Bookman, Porto Alegre, 2001.
- [4] I. N. Silva; D. H. Spatti; R. A. Flauzino *Redes neurais Artificiais para Engenharias e Ciências Aplicadas: fundamentos teóricos e práticos*, 2 ed. Artliber, São Paulo, 2010.