

## PREDIÇÃO DE JOGADAS DE FUTEBOL AMERICANO UTILIZANDO REDES NEURASIS

DIEGO DA SILVA RODRIGUES\*, JOSE MANOEL DE SEIXAS\*

\*Laboratório de Processamento de Sinais  
COPPE/Poli - UFRJ  
Rio de Janeiro, RJ, Brasil

Emails: diegosrx@gmail.com, seixas@lps.ufrj.br

**Abstract**— This paper presents the results of applying neural networks to predict football plays. Based on attributes modeled from a game situation and used as the network input, the neural network predicts whether the play will be a pass or a run. The network achieved a correct estimative of 73%. The predictor may be used by artificial intelligence for games, to simulate the behavior of a particular team or to infer about the most likely move during a match.

**Keywords**— Neural Networks, Classification, Football Play Prediction.

**Resumo**— Este artigo apresenta os resultados da aplicação de redes neurais para a predição de jogadas de futebol americano. Baseada em atributos modelados a partir de uma situação de jogo e utilizados como entrada, a rede neural determina se a jogada mais apropriada é um passe ou uma corrida. O percentual de acertos da rede foi de 73%. O preditor de jogadas pode ser utilizado por softwares de inteligência artificial para jogos, simuladores de comportamento de determinada equipe ou para inferência sobre qual será a jogada mais provável durante uma partida.

**Palavras-chave**— Redes Neurais, Classificação, Previsão de jogada de Futebol Americano.

### 1 Introdução

O futebol americano é um esporte praticado principalmente nos Estados Unidos, sendo pouco conhecido no Brasil e praticado apenas em campeonatos amadores regionais. Além de ser um esporte conhecido pelo contato físico intenso, sua principal característica é a estratégia.

O campo de futebol americano tem 100 jardas (1 jarda = 0,9144 metros) de comprimento, mais duas endzones (zonas de fundo) de 10 jardas, totalizando 120 jardas. No final de cada uma das *endzones*, há uma trave de metal em forma de “Y”, chamado de *field goal*. O objetivo dos times é pontuar, atravessando ou recebendo um passe dentro da *endzone*, realizando um *touchdown*, ou chutando a bola através do “Y”, marcando um *field goal*. O *touchdown* vale seis pontos e o *field goal* vale três. Cada equipe conta com três sub-equipes: o ataque, responsável por tentar avançar dentro do campo e pontuar; a defesa, que deve impedir o avanço do ataque adversário e o time especial, que entra em campo em situações de troca de posse de bola e chute.

No início da partida, os times especiais se enfrentam no *kick-off* inicial, onde um time chuta a bola para o outro time retorná-la. O time de chute então tenta impedir o avanço do retornador - jogador que recebeu o chute adversário - e o time de retorno tenta abrir passagem para ele retornar o maior número possível de jardas. A jogada encerra-se quando o retornador é derrubado, dando início ao drive de ataque.

A bola é posicionada no centro do campo, paralelamente ao lugar onde o retornador foi derrubado ou saiu de campo. O time de ataque entra em campo, com o objetivo de avançar a bola rumo à endzone adversária. O ataque tem quatro tentativas (*downs*) para avançar dez jardas do campo, obtendo um *first-down* (mais quatro tentativas). A jogada tem início quando o *Quarterback* recebe a bola do *Center* no snap (movimentação onde o *Center* entrega a bola por debaixo das pernas para o *Quarterback*) e realiza a jogada, entregando a bola para um *Running Back* (corredor) para que ele possa avançar correndo com a bola ou arremessando para um *Wide-Receiver* (recebedor). Analogamente, o time de defesa deve derrubar o jogador que recebe a bola do *Quarterback* ou o próprio, impedindo o avanço do time de ataque no campo.

O jogo é disputado em dois tempos, cada um dividido em dois quartos de quinze minutos. Cada time conta com três *Time-outs* (tempos técnicos) para pedir em cada tempo de jogo. A contagem de tempo (pausas no relógio) tem um formato especial nos dois minutos finais de cada tempo, permitindo aos times manipular a fluência do tempo de jogo (*two-minute warning*). Ao final do jogo, vence o time que tiver realizado o maior número de pontos. Mais informações sobre a regra do esporte podem ser encontradas em (NFL, 2008).

Como será visto na próxima seção, o objetivo deste trabalho é prever se determinada jogada será um passe ou uma corrida. Logo, o preditor usando redes neurais pode ser utilizado em simuladores do esporte, como, por exemplo, inteligência artificial

de jogos. Outra aplicação seria o auxílio à decisão durante o jogo, onde a rede neural realizaria uma inferência sobre a possibilidade de uma determinada jogada. O preditor foi concebido com esta função, e tal modelo requisitaria o treinamento da rede para cada *Quarterback* diferente para ser utilizado na prática. Dado que a rede foi treinada com a base de dados de jogadas de um determinado *Quarterback*, uma terceira aplicação seria simular o comportamento de tal equipe, para auxílio nos treinamentos pré-jogo, por exemplo.

Não foi encontrado nenhum outro estudo sobre predição de jogadas de futebol americano utilizando redes neurais. As implementações utilizando árvores de decisão através do algoritmo C4.5 (Quinlan, 1994) e ID3 (Quinlan, 1986) serviram como estudo prévio do problema e o resultado obtido pelos dois métodos foi comparado ao resultado obtido pela rede neural.

## 2 Objetivo

O objetivo deste trabalho é prever se o time de ataque optará por uma jogada de passe ou de corrida. Um passe permite ao time de ataque normalmente avançar mais jardas numa só jogada, com o risco do seu *Quarterback* ser derrubado ou a bola ser interceptada pelo time de defesa. Uma corrida em geral avança menos jardas que um passe, mas a bola permanece “protegida” nos braços de um jogador do time de ataque do começo ao fim da jogada.

Este compromisso entre passe e corrida gera momentos de jogo onde há possibilidade maior de determinada escolha: um time perdendo, no final de jogo, precisa fazer vários passes para avançar no campo o mais rápido possível; um time que precise avançar apenas uma jarda no campo pode fazê-lo de forma mais garantida correndo com a bola. Fora esses momentos característicos, a opção por passe ou corrida é afetada por características de jogo, do elenco do time de ataque e da preferência do *Quarterback* e coordenador de ataque. Logo, dadas as características que ilustram o momento de jogo para uma jogada, o objetivo é encontrar quais destas características são as mais relevantes e prever se será um passe ou uma corrida.

## 3 Modelagem

As características da jogada (atributos) podem ser divididas em dois grupos: fatores gerais da jogada e fatores circunstanciais do jogo.

No grupo de fatores gerais da jogada estão inclusos: qual é a tentativa; quantas jardas faltam para avançar dez jardas; qual a posição no campo; qual

o tempo de jogo (quarto, minutos corridos, se está nos dois minutos finais); qual a formação que o time de ataque está utilizando (como está distribuída a equipe: quantos são os recebedores, quantos corredores, etc).

No grupo de fatores circunstanciais do jogo estão inclusos: qual o placar atual; Qual foi a jogada anterior; condições climáticas (vento, chuva); quantos *time-outs* ainda podem ser pedidos; qual a produtividade do jogo corrido até agora (média de jardas alcançadas, jardas máximas alcançadas); produtividade do jogo de passes e muitos outros.

Todos os fatores gerais da jogada foram inclusos como variáveis de entrada da rede, exceto a formação de ataque. Dos fatores circunstanciais do jogo, foram considerados o placar e a última jogada.

## 4 Base de dados

Os dados utilizados neste trabalho são todas as jogadas dos 10 primeiros jogos do time da NFL Indianápolis Colts na temporada de 2006. O *Quarterback* deste time, Payton Manning, é um dos melhores da liga americana e é conhecido pela sua capacidade de modificar as jogadas dentro de campo, dependendo da configuração de defesa adversária. O banco de dados conta com 299 jogadas de passe e 234 jogadas de corrida. O banco de dados foi gerado a partir da informação do *Play-by-Play* de cada jogo, que é a descrição da sequência de jogadas, obtida no site da *National Football League* (N.F.L.) (NFL, 2006).

## 5 Arquitetura da rede

A rede escolhida foi a MLP (*Multilayer Perceptron*) com uma camada escondida (Haykin, 2007), utilizando o algoritmo de treinamento supervisionado de retropropagação de erro, baseado em gradiente descendente com momento. Todos os neurônios da rede utilizam a função de ativação tangente hiperbólica. O número máximo de neurônios na camada oculta foi estimado utilizando a aproximação abaixo (Haykin, 2007):

$$N = O\left(\frac{W}{e}\right) \quad (1)$$

Na equação 1,  $N$  é o total de vetores de entrada do banco de dados (533 jogadas),  $e$  o erro em porcentagem tolerado (25%) e  $W$  o número de parâmetros livres da rede. O valor do erro  $e$  foi definido baseado na eficiência de classificação do preditor utilizando árvores de decisão, que obteve taxa de acerto inferior a 70%, como será visto na seção de

resultados. Portanto,  $e = 25\%$  foi escolhido como limiar aceitável. Isto levou a um número máximo de onze neurônios na camada oculta.

Para a escolha da taxa de aprendizado e do momento, foram realizados testes para todos os números de neurônios na camada oculta (de um a onze neurônios). Os testes foram realizados utilizando a seguinte metodologia. Para cada treinamento da rede, os conjuntos de vetores de cada classe (corrida e passe) foram divididos aleatoriamente em três subconjuntos, respeitando a proporção 80% (A), 10% (B) e 10% (C). Os subconjuntos A das duas classes foram, então, misturados aleatoriamente, compondo o conjunto de treino da rede. Os subconjuntos B foram misturados gerando o conjunto de validação e os subconjuntos C foram misturados gerando o conjunto de teste.

Após a geração dos três conjuntos, a rede neural foi treinada. O critério de parada do treinamento foi o erro de validação. Durante a etapa de testes, duas medidas foram utilizadas como critério de escolha da melhor arquitetura. O primeiro critério foi chamado de critério de dúvida. Para um vetor aplicado na entrada da rede, a resposta poderia pertencer a três grupos distintos: passe, corrida ou dúvida. Para um patamar pré-definido  $L$ , caso a saída da rede não superasse em módulo, a resposta era considerada como dúvida e não como nenhuma das classes de saída. Portanto, os vetores cuja saída estivessem dentro do intervalo  $[-L, L]$ ,  $L < 1$  não eram considerados no cálculo do percentual de acertos da rede.

Obedecendo o critério de dúvida, para cada treinamento foi gerado um percentual de acerto sobre os vetores classificados durante o teste. A média dos erros para cada treinamento foi a segunda medida utilizada como critério de escolha da melhor arquitetura e vinte treinamentos foram realizados para cada configuração.

Para as configurações de arquitetura foram considerados os valores indicados na tabela 1. A figura 1 mostra o comparativo da taxa média de acertos para a variação de neurônios na camada oculta de um a onze, com taxa de aprendizado  $\gamma = 0,1$  e momento  $\lambda = 0$ . O resultado para 10 neurônios foi o melhor obtido para todas as variações encontradas na tabela 1.

Tabela 1: Valores para a arquitetura da rede.

Neurônios na camada oculta	1 a 11
Taxa de Aprendizado $\gamma$	0,1 e 0,05
Momento $\lambda$	0, 0,1 e 0,9
Limiar de dúvida $L$	0,5

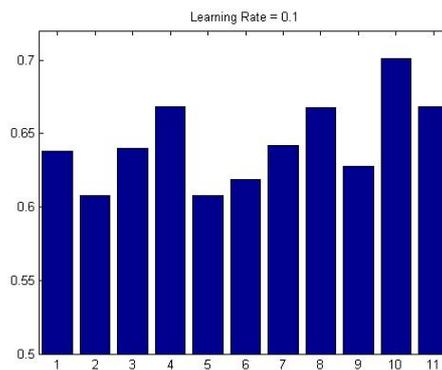


Figura 1: Resultados para diferentes números de neurônios na camada oculta com  $\gamma = 0,1$  e  $\lambda = 0$ .

## 6 Seleção dos Atributos

O critério de relevância (Seixas and Calôba, 1996) foi utilizado para identificar quais atributos de entrada têm maior importância para a classificação da rede. Isto serve tanto para identificar quais dos atributos definem a escolha da jogada, como para reduzir o ruído na entrada na rede e melhorar a classificação.

$$R(x_j) = \frac{\sum_{i=1}^N \|out(x_i) - out(x_i|x_{i,j} = \langle x_j \rangle)\|^2}{N} \quad (2)$$

Tabela 2: Atributos de Entrada.

Nº	Atributo	Tipo	Relev.
1	Número da tentativa	Discreto	0,92
2	Distância para o <i>first-down</i>	Contínuo	0,40
3	Posição no campo	Contínuo	0,19
4	Diferença no placar	Contínuo	0,02
5	Quarto de jogo	Discreto	0,38
6	Tempo	Contínuo	0,27
7	<i>Two-Minute Warning</i>	Binário	0,45
8	Última jogada - Passe	Binário	0,50
9	Última jogada - Corrida	Binário	0,59
10	Última jogada - Especial	Binário	0,10
11	Última jogada - Jardas	Binário	0,18

A relevância é definida da seguinte forma: dado um vetor aplicado na entrada da rede, a relevância da entrada  $x_i$  é definida pelo quadrado da norma da diferença entre a saída medida no modelo treinado e esta saída quando, no vetor de entrada aplicado,  $x_i$  é substituído pela sua média. A relevância é a média de todos esses desvios quadráticos para todos os vetores da base de treino ( $N$  é o número de vetores do conjunto de treino). A figura 2 mostra os resultados para os atributos considerados no modelo e a tabela 2 os valores para os atributos.

A metodologia de definição de arquitetura foi utilizada novamente considerando dois limiares de rele-

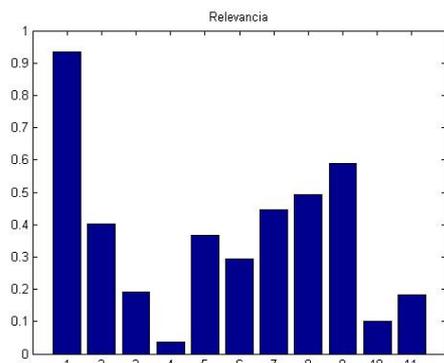


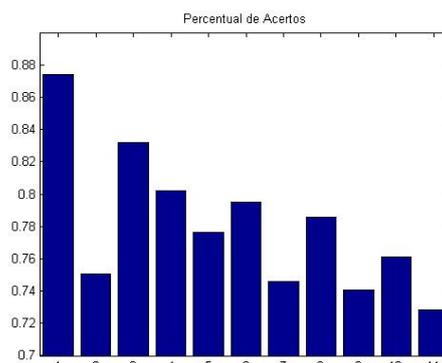
Figura 2: Relevância dos atributos de entrada 2.

vância, 0,1 e 0,2. Para o limiar de 0,1 os atributos 4 e 10 foram eliminados. Para o limiar de 0,2 os atributos 3,4,10 e 11 foram eliminados. O treinamento com os atributos obtidos utilizando o limiar de 0,2 obteve melhor resultado em relação ao limiar de 0,1 e em relação ao modelo considerando todos os atributos definindo a seleção das entradas consideradas no treinamento final (tabela 2). O critério utilizado para a comparação foi a média da taxa de acertos.

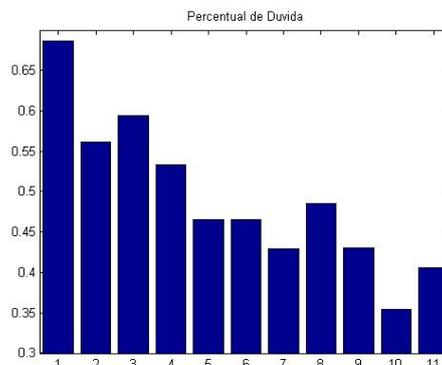
A figura 3 mostra a média da taxa de acertos, o percentual de dúvida, enquanto que a figura 4 mostra o produto da média da taxa de acertos pelo complemento do percentual de dúvidas. Sendo  $TA$  a taxa de acerto e  $DU$  o percentual de dúvidas, o gráfico mostra  $TA(1 - DU)$ . Esta medida pode ser interpretada como a taxa de acertos para todos os vetores do banco, não apenas para os vetores que superaram o limiar de dúvida. Vencedora foi aquela com dez neurônios na camada oculta e esta rede foi utilizada para o treinamento final.

## 7 Treinamento

Utilizando a rede com dez neurônios na camada oculta e os atributos definidos pelo critério de relevância, a última parte do treinamento consistiu em testar o resultado para diferentes limiares de dúvida. Isso serviu para avaliar o compromisso entre acertos da classificação e saídas consideradas como duvidosas. A rede foi treinada utilizando critério de parada pelo erro de validação padrão do MATLAB: duzentas épocas com erro de validação sem diminuir. A figura 5 mostra o percentual de acertos para diferentes valores de  $L$  e o percentual de dúvidas. Como esperado, o percentual da taxa de acertos e o percentual de dúvidas crescem com o valor de  $L$ . Isto acontece porque a rede passa a classificar menos padrões de entrada e com mais “certeza”, já que os valores classificados ficam mais próximos de 1 e -1.



(a)



(b)

Figura 3: Percentual de acertos (a) e de dúvida (b) em relação ao número de neurônios na camada escondida para o treinamento considerando os atributos selecionados pela relevância 0,2.

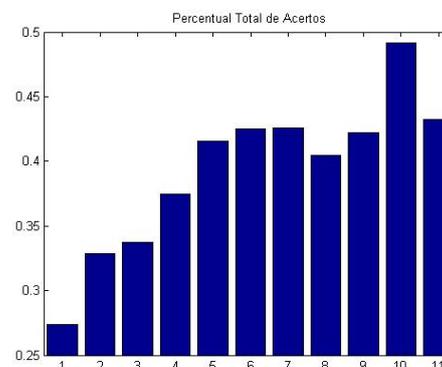


Figura 4: Produto do percentual de acertos pelo percentual de dúvida.

## 8 Resultados

O preditor de jogadas de futebol americano foi desenvolvido anteriormente utilizando árvores de decisão. Os resultados apresentados neste artigo comparam o desempenho da implementação utilizando redes neurais com a implementação utilizando árvores. O valor utilizado para comparação foi a média do percentual de acertos de classificação, mesmo critério utilizado para definição da melhor arquitetura da rede. Para redes neurais, o percentual de dúvidas também foi utilizado para comparação.

Na tabela 3 estão os resultados. “NN” é o preditor utilizando redes neurais com  $L$  sendo o limiar de dúvida, See5 é o programa de árvores de decisão que utiliza o algoritmo C4.5/C5 (Quinlan, 1994), ID3 é o preditor desenvolvido anteriormente utilizando o algoritmo de geração de árvores de decisão ID3 (Quinlan, 1986).  $\bar{A}$  é a média do percentual de acertos e  $\bar{D}$  é a média do percentual de dúvida para a implementação utilizando redes neurais.

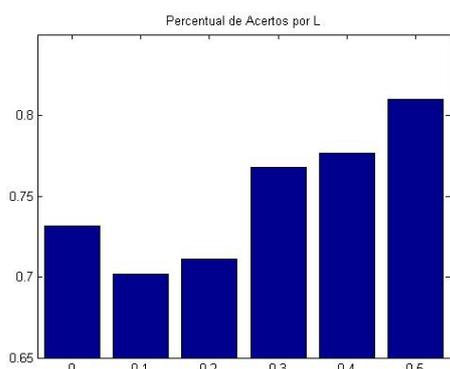
Tabela 3: Desempenho dos modelos neurais (vide texto).

Sistema	$\bar{A}$	$\bar{D}$
NN $L = 0$	73%	0%
NN $L = 0.1$	70%	12%
NN $L = 0.2$	71%	22%
NN $L = 0.3$	77%	34%
NN $L = 0.4$	78%	48%
NN $L = 0.5$	81%	60%
See5	69%	0%
ID3	64%	0%

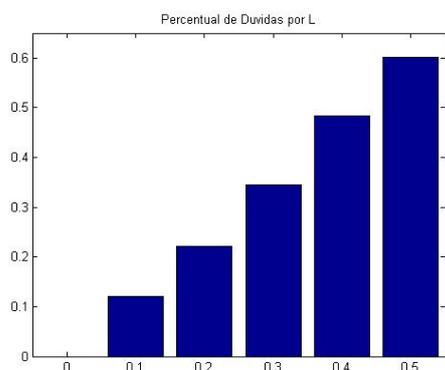
Os dois modelos utilizando árvores consideram uma terceira classe de saída, jogada de time especial, que foi desconsiderada no modelo de redes neurais. Esta classe acontece em circunstâncias previsíveis por um especialista (normalmente, as quartas tentativas são sempre jogadas de time especial) e isto serviu para aumentar a média de acertos das implementações utilizando árvores.

O melhor resultado obtido foi o de redes neurais com  $L = 0$ , média de acertos igual a 73%. Isso permite observar que mesmo quando o resultado é inferior a 0,1 para uma das classes a rede consegue acertar. Aplicando todos os vetores da classe “passe” na rede com  $L = 0$ , o percentual de acertos foi de 77% enquanto para a classe “corrida” o percentual foi de 69%. O resultado maior no percentual para a classe “passe” era esperado, já que o *Quarterback* Peyton Manning costuma utilizar mais jogadas desse tipo. Na figura 6 é possível ver a curva ROC para a melhor rede.

Os resultados mostram a superioridade das redes



(a)



(b)

Figura 5: O percentual de acertos (a) e o de dúvidas (b) crescem com o limiar de dúvida.

neurais em relação às árvores de decisão para o problema de predição de jogadas, e o compromisso entre o acerto e o percentual de dúvidas.

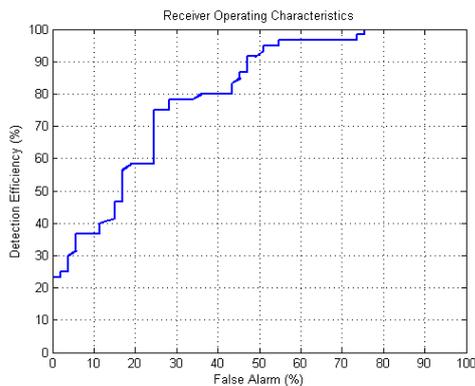


Figura 6: ROC da saída da Rede FPP-NN  $L = 0$  para a classe passe.

Outras conclusões importantes foram a respeito do resultado da relevância para os atributos do modelo. Ao contrário do que parece trivial, o placar exclusivamente não é influente na escolha das jogadas, bem como o avanço em jardas da última jogada. Para gerar novas conclusões sobre a relevância dos atributos de entrada, um outro método de escolha de atributos poderia ser utilizado para melhorar esta análise. O placar pode não ser relevante independentemente dos outros atributos, mas ele pode ter relevância quando **combinado** com outros atributos, como tempo de jogo e *Two-Minute Warning*, já que no final do jogo, se o time está perdendo, ele quer ganhar território rapidamente e portanto há uma tendência maior ao jogo de passes.

Outras melhorias que podem ser consideradas são: acréscimo de novos atributos, principalmente o da formação utilizada pelo ataque, que é um dos mais relevantes para a escolha da jogada; a aquisição de novos vetores - novas jogadas - também é essencial para o aumento do percentual de acertos da rede.

## 9 Agradecimentos

Agradecemos ao apoio do CNPq e FAPERJ (Brasil) ao trabalho e aos jogadores da equipe de futebol americano do América (América Red Lions) pelo incentivo, colaboração e apoio.

## Referências

Haykin, S. (2007). *Redes Neurais - Princípios e Práticas*, 2nd edn, Bookman.

NFL (2006). N.f.l. play-by-play, <http://www.nfl.com/teams/schedule?team=IND&season=2006&seasonType=REG>.

NFL (2008). N.f.l. beginner's guide to football, <http://www.nfl.com/rulebook/beginnersguidetofootball>.

Quinlan, R. (1986). Induction of decision trees, *Machine Learning, Volume 1, Número 1* pp. 81–106.

Quinlan, R. (1994). *C4.5 Programs for Machine Learning*, Morgan Kaufmann.

Seixas, J. and Calôba, L. (1996). Relevance criteria for variable selection in classifier design, *International Conference on Engineering Applications of Neural Networks. Londres, Inglaterra*.