



INTELIGÊNCIA COMPUTACIONAL APLICADA AO FUTEBOL AMERICANO

Diego da Silva Rodrigues

Tese de Doutorado apresentada ao Programa de Pós-graduação em Engenharia Elétrica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia Elétrica.

Orientador: José Manoel de Seixas

Rio de Janeiro
Março de 2018

INTELIGÊNCIA COMPUTACIONAL APLICADA AO FUTEBOL
AMERICANO

Diego da Silva Rodrigues

TESE SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ
COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE)
DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR
EM CIÊNCIAS EM ENGENHARIA ELÉTRICA.

Examinada por:

Prof. José Manoel de Seixas, D.Sc.

Prof. Alexandre Gonçalves Evsukoff, D.Sc.

Prof. Aline Gesualdi Manhães, D.Sc.

Prof. Guilherme de Alencar Barreto, Ph.D

Prof. Sergio Lima Netto, D.Sc.

RIO DE JANEIRO, RJ – BRASIL
MARÇO DE 2018

Rodrigues, Diego da Silva

Inteligência Computacional Aplicada ao Futebol Americano/Diego da Silva Rodrigues. – Rio de Janeiro: UFRJ/COPPE, 2018.

XIV, 70 p.: il.; 29, 7cm.

Orientador: José Manoel de Seixas

Tese (doutorado) – UFRJ/COPPE/Programa de Engenharia Elétrica, 2018.

Referências Bibliográficas: p. 56 – 63.

1. Futebol Americano. 2. Modelos de Ranqueamento.
3. Ranqueamento Bayesiano. 4. Sport Science.
5. Redes Neurais. I. Seixas, José Manoel de.
- II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica. III. Título.

*Este trabalho é dedicado a todos
os atletas do país.*

Agradecimentos

Agradeço à minha família, por ter oferecido as condições necessárias para que, ao contrário da gigantesca maioria de brasileiros, eu tivesse acesso à educação da melhor qualidade possível neste país. Um agradecimento em especial à minha mãe, Angela Maria, e minha madrinha, Dora Cristina. Agradeço também ao meu padrinho Emidio Coimbra, por ter sido um dos engenheiros eletrônicos pioneiros da UFRJ, cuja trajetória até hoje ainda me inspira.

Agradeço ao meu orientador José Manoel de Seixas, por ser um grande mestre, na área acadêmica, pessoal e musical, por ter acreditado e me ajudado a defender minhas ideias ao longo de tantos anos. Além, é claro, de ter me “desfibrilado” diversas vezes ao longo do mestrado e doutorado.

Agradeço aos professores que aceitaram fazer parte da banca desta tese, e cederam seu tempo para avaliar este texto e colocar suas contribuições. Em especial, prof. Sergio Lima Netto, meu orientador na iniciação científica e na graduação.

Agradeço à essa grande escola, Universidade Federal do Rio de Janeiro, com sua pós-graduação, professores, funcionários, que me recebeu em 2003, onde me formei engenheiro e vivi tantas experiências inesquecíveis.

Agradeço meus grandes amigos do Eagle Scouting, que ao longo de anos estiveram juntos na louca ideia de ranquear atletas de futebol americano amadores. Rudá, Victor, Alexander, Bruno, Gabriel, muito obrigado amigos. Vamos continuar criando heróis.

Agradeço ao técnico Gabriel Mendes, da seleção brasileira, por ter acreditado no projeto e disponibilizado equipe de técnicos do Patriotas para conduzir a coleta e análise de dados.

Agradeço a todos os atletas que participaram deste trabalho. Em especial à equipe de classificação de vídeos, Raffael “FF”, Brenno “Costela”, Gabriel “Mãozinha”, Luiz “Antonio Brown”, Juan “Gostosa”. Sem vocês não teria sido possível classificar 4845 vídeos. Muito obrigado!

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

INTELIGÊNCIA COMPUTACIONAL APLICADA AO FUTEBOL AMERICANO

Diego da Silva Rodrigues

Março/2018

Orientador: José Manoel de Seixas

Programa: Engenharia Elétrica

Esta tese apresenta a aplicação de modelos de inteligência computacional para apoiar times de futebol americano em países nos quais o esporte ainda está em fase de desenvolvimento. Dois modelos foram desenvolvidos, voltados para apoiar técnicos e times, utilizando dados de diferentes fontes. Um comitê de redes neurais especialistas foi treinado, utilizando dados de um time de alto nível, de maneira a extrair quais características influenciam a escolha de jogadas de um time profissional de ponta. As escolhas identificadas contribuem para a preparação tática dos atletas. O comitê foi capaz de identificar um subconjunto reduzido de atributos relevantes. Numa segunda etapa do trabalho, utilizando dados de treinamento de atletas amadores, adquiridos de 4.845 vídeos gerados a partir de um protocolo sistemático proposto, foi desenvolvido um modelo de ranqueamento de atletas e identificados seus pontos fortes e fracos no esporte. O modelo transporta um algoritmo utilizado em jogos para situações de enfrentamento individual no futebol americano e foi ajustado aos dados coletados num treino aberto para atletas no Rio de Janeiro, ao longo de 2017 e serviu para identificar os melhores. O modelo de ranqueamento também foi utilizado em dados de uma equipe amadora do Rio de Janeiro, para ranquear seus atletas ao longo da temporada.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

COMPUTATIONAL INTELLIGENCE APPLIED FOR AMERICAN FOOTBALL

Diego da Silva Rodrigues

March/2018

Advisor: José Manoel de Seixas

Department: Electrical Engineering

This work presents the application of computational intelligence models to support amateur level american football teams. Two models were developed, with the goal of supporting coaches and athletes, using data from different sources. One specialist neural network ensemble was trained, using data from a high level american team, in order to extract what game characteristics affect playcall, for a professional team. The ensemble could identify a relevant set of attributes among the ones analyzed. Using data collected for amateur level players, a ranking algorithm was developed. This model was used to rank athletes on a weekly training camp opened to all players. The model was also use privately for an amateur team from Rio de Janeiro, to rank their players during the season.

Sumário

Lista de Figuras	x
Lista de Tabelas	xiii
1 Introdução	1
1.1 Motivação	2
1.2 Objetivo do Trabalho	3
1.3 Contribuições do Trabalho	5
1.4 Organização do Texto	6
2 Revisão Bibliográfica	7
2.1 Ranqueamento e Seleção Baseado em Dados	7
2.1.1 Algoritmos de Ranqueamento	9
2.1.2 Ranqueamento nos Esportes	11
2.1.3 Ranqueamento no Futebol Americano	13
2.2 Classificação de Padrões nos Esportes	14
2.2.1 Classificação de Padrões no Futebol Americano	15
2.3 Trabalhos Encontrados para Futebol Americano no Brasil	16
3 Método	17
3.1 Escopo de Exercícios	17
3.1.1 Big Cat	17
3.1.2 Tackle Box	19
3.1.3 Man Coverage	21
3.1.4 Pass Rush	22
3.1.5 Oklahoma Drill	24
3.1.6 Drills Por Posição	25
3.2 Coleta de Dados	25
3.2.1 Dados Time de Alto Desempenho	25
3.2.2 Dados de Treino de Atletas Amadores	26
3.3 Modelos Utilizados	28
3.3.1 Modelo para extração de tendências na seleção de jogadas	28

3.3.2	Algoritmo de Rating Probabilístico	30
4	Resultados	36
4.1	Rede Neural para Extração de Características	36
4.1.1	Discussão	39
4.2	Ranqueamento de Atletas de um Clube do Rio de Janeiro	41
4.2.1	Testemunho do Técnico	42
4.3	Ranqueamento Aberto de Atletas do Rio de Janeiro	43
4.3.1	Resultados do Ajuste do Modelo	47
4.3.2	Seleção de Equipe de Flag Football para amistoso	49
5	Conclusão	53
5.1	Trabalhos Futuros	54
	Referências Bibliográficas	56
A	Futebol Americano	64
A.1	Campo	64
A.2	Regras do Jogo	65
A.3	Setores de um Time de Futebol Americano	66
A.3.1	Time de Ataque	67
A.3.2	Time de Defesa	68
B	Trabalhos Publicados	70

Lista de Figuras

- 3.1 Diagrama de montagem do *Big Cat*. Os cones azuis são posicionados em um quadrado com 3 jardas de comprimento e 3 jardas de largura. Os cones vermelhos são posicionados em paralelo aos cones azuis, em uma distância de 3 jardas, para criar a zona de segurança. Os cones pretos devem sinalizar o meio da região do *drill*. A defesa ocupa a lateral superior do *drill*, e o ataque a lateral inferior. 18
- 3.2 Diagrama de montagem do *Tackle Box*. Os cones azuis são dispostos num retângulo com 10 jardas de comprimento e 7 jardas de largura. Os cones vermelhos são posicionados em paralelo aos cones azuis, em uma distância de 3 jardas, para criar a zona de segurança. Os cones pretos devem sinalizar o meio da região do *drill*. A defesa ocupa a lateral superior do *drill*, e o ataque a lateral inferior. 20
- 3.3 Diagrama de montagem do *drill Man Coverage*. Os cones azuis e vermelhos devem ser intercalados em pares (21 jardas de distância entre um e outro) a 5 jardas de distância entre os pares, a fim de demarcar as jardas no campo, na *sideline* e na *hashmark*. Um cone preto deve determinar o ponto do qual a bola sai para o *quarterback* (QB), e os 7 restantes devem ser posicionados 10 jardas atrás do *drill*, criando uma zona de segurança para movimentação do *quarterback*. A câmera deve estar posicionada atrás do recebedor, filmando-o de corpo inteiro, antes do início da jogada. 21
- 3.4 Diagrama de montagem do *drill Pass Rush*. Os jogadores de linha ofensiva devem se posicionar em linha horizontal, a meia jarda de distância um do outro, sendo o *center* (jogador central), responsável por segurar a bola em posição de *snap*. Os cones pretos devem ser dispostos a 6 jardas dos jogadores de linha ofensiva das extremidades, a partir de seu pé externo, criando uma área de segurança para o *drill*. O *dummy* deve ser posicionado 6 jardas atrás do *center* (jogador central). 23

3.5	Diagrama de montagem do <i>drill Oklahoma</i> . Os cones azuis devem ser dispostos em um retângulo com 10 jardas de comprimento e 7 jardas de largura. Os cones vermelhos devem ser posicionados em paralelo aos cones azuis, em uma distância de 3 jardas, para criar a zona de segurança. Os cones pretos devem sinalizar o meio da região do <i>drill</i> . A defesa ocupa a lateral superior do <i>drill</i> , e o ataque a lateral inferior.	24
3.6	Diagrama de treinamento do comitê neural.	30
3.7	Exemplo do efeito da dispersão β na probabilidade de vitória, dada as habilidades do primeiro e do segundo jogador. A região de empate (verde) é modelada como a região onde a probabilidade de vitória é menor que um determinado ϵ	31
3.8	Função Cumulativa Φ para o caso $\beta = 200$. A função relaciona à diferença de ratings com a probabilidade de vitória.	32
3.9	Exemplo de um grafo relacionado a um jogo com três times. O primeiro time tem como membro o jogador 1, com habilidade μ_1 . O segundo time tem como membros os jogadores 2 e 3, e o terceiro time tem como membro o jogador 4. O grafo exemplifica como as habilidades são combinadas na habilidade do time, t_n e no desempenho esperado d_n dos times. As setas mostram como, dada a evidência, as informações são propagadas de volta pelo grafo. Adaptado de [1]. . .	33
4.1	Relevância e correlação para cada rede expert.	38
4.2	Resultados da segunda fase de treinamento para o número de neurônios na camada oculta para (a) primeiro down e (b) segundo down.	39
4.3	Convergência do treinamento para a melhor rede expert: (a) primeiro (b) segundo e (c) terceiro down.	40
4.4	Exemplo do <i>Dashboard</i> enviado para a comissão técnica do clube carioca de primeira divisão, mensalmente, com os <i>ratings</i> calculados para os 52 atletas do plantel.	42
4.5	Videos coletados por treino e total acumulado, durante o ano de 2017.	43
4.6	Série temporal com o número de atletas distintos, por posição, presentes no treino.	44
4.7	Principais rotas utilizadas pelos wide receivers ao longo do ano. Rota Cross em primeiro lugar com 26% das jogadas.	44
4.8	A rota Corner, embora sendo usada em apenas 4% das tentativas, possui o maior percentual de vitórias, igual à 49%. A Rota Go, uma das mais populares, possui o segundo pior resultado das rotas consideradas.	45

4.9	Principais coberturas usadas pelos defensores. Press Square liderando com 34% das jogadas.	46
4.10	Off in apresentando o melhor resultado entre as coberturas utilizadas, com 64% de vitórias. Cobertura Soft identificada como ponto fraco comum dos atletas.	46
4.11	Resultado do ajuste do algoritmo TrueSkill, ancorados em $\mu = 6$. Melhores valores para os parâmetros confirmados pela busca em grid, $\beta = 1$ e $\tau = 0,02$	47
4.12	Evolução do <i>rating</i> dos <i>quarterbacks</i> ao longo do ano.	49
4.13	Evolução da habilidade dos wide receivers ao longo do ano.	50
4.14	Evolução da habilidade dos defensive backs ao longo do ano.	50
4.15	Odds Ratio das Rotas lançadas pelo quarterback DA. Melhor desempenho na rota Out e pior desempenho na rota Go. O desempenho do quarterback neste drill é diretamente influenciado pela qualidade do wide receiver.	51
4.16	Odds Ratio das rotas executadas pelo wide receiver RU. O atleta possui um arsenal de 5 rotas com percentual de vitórias maior do que 50%: out, comeback, corner, cross e post.	51
4.17	Com percentual de vitórias de 70%, o defensive back GO apresenta um percentual de vitórias maior do que 50% contra todas as principais rotas.	52
A.1	Campo de futebol americano. A região verde escura nos dois lados representam as duas <i>endzones</i>	64
A.2	Posições das equipes de ataque e defesa no futebol americano. Retirado de [2].	67

Lista de Tabelas

2.1	Esportes reconhecidos pelo comitê olímpico e por outras referências, segmentados na categorização proposta por [3].	8
2.2	Distribuição dos esportes pelo tipo de sistema de ranqueamento utilizado pela federação internacional correspondente.	9
2.3	Lista de esportes cujas federações utilizam algoritmos de <i>rating</i> para ranquear os atletas.	12
3.1	Resultados e pontuações consideradas para o <i>drill Big Cat</i>	19
3.2	Resultados e pontuações consideradas para o <i>drill Tackle Box</i>	19
3.3	Resultados e pontuações consideradas para o <i>drill Man Coverage</i>	22
3.4	Resultados e pontuações consideradas para o <i>drill Pass Rush</i>	23
3.5	Resultados e pontuações consideradas para o <i>drill Oklahoma</i>	25
3.6	Matriz relacionando os setores e para quais <i>drills</i> os atletas do setor tiveram habilidade mensurada.	25
3.7	Atributos utilizados no treinamento da redes especialistas.	26
3.8	Dados coletados, por jogadas, extraídos de vídeo e áudio, no treino aberto de <i>man coverage</i>	27
3.9	Dados coletados em planilha pelos técnicos assistentes do time de futebol americano carioca.	28
3.10	Valores padrão para o algoritmo TrueSkill.	35
4.1	Número de jogadas, por down, separados em passe e corrida.	36
4.2	Resultados para o primeiro round de jacknife, antes da remoção dos atributos usando a relevância normalizada. NE é o número de neurônios da camada oculta, μ é a taxa de acerto média, σ o valor RMS e Melhor é a acurácia da melhor rede encontrada pelo procedimento.	37
4.3	Relevância normalizada calculada para os atributos. Estão destacados os atributos com relevância acima de 0,2.	37

4.4	Comparação de resultados entre as redes <i>experts</i> por down (NN-1D, NN-2D, NN-3D), a rede neural [4] e duas árvores de decisão. NE é o número de neurônios na camada oculta, μ a taxa de acerto média, σ o valor RMS e Melhor para a acurácia da melhor rede encontrada pelo jackknife.	37
4.5	Parâmetros para o algoritmo TrueSkill, encontrados pela busca.	47
4.6	Leaderboard de Quarterbacks.	48
4.7	Leaderboard de Wide Receivers.	48
4.8	Leaderboard de Defensive Backs.	48

Capítulo 1

Introdução

A ciência de dados é uma área em crescimento. Aplicações surgem em diferentes campos da engenharia e outras áreas do conhecimento, integrando dados à rotina de trabalho. Essas aplicações buscam utilizar o poder computacional dos algoritmos, aliado ao volume crescente de informação, para obter melhores resultados em suas áreas de interesse.

Para os esportes, não é diferente. A área de *Sports Analytics* cresce em aplicações - times, atletas e confederações, buscando soluções que criem diferencial competitivo [5]. Cresce a competição interna nas equipes e a maior transparência na seleção de atletas, já que o processo de seleção migra de opiniões subjetivas de treinadores e “olheiros” para análises objetivas baseadas em informação coletada de jogos e treinos. Cresce também o público que aprende a acompanhar novas estatísticas de times e atletas. E, até, apostar, utilizando novas informações.

Como em qualquer área em ascensão, os esportes atingem níveis de maturidade individuais, no uso das informações disponíveis em seu meio. Dentro de um mesmo esporte, equipes também apresentarão níveis de maturidade distintos. Mas, um princípio é comum, independente do esporte ou do nível de maturidade: a informação coletada consegue traduzir objetivamente o real desempenho dos atletas ou times. Portanto, os dados coletados podem auxiliar equipes e atletas que desejem acelerar o amadurecimento num determinado esporte.

O objetivo deste trabalho é desenvolver o futebol americano em países amadores, através da sistematização do treinamento utilizando os dados. Diferentes modelos podem ser empregados em dados de treinamento ou dados de jogos, para obter *insights* e auxiliar o desenvolvimento de técnicos e atletas. Analisar dados de jogos de times profissionais pode auxiliar técnicos amadores a entender as considerações táticas tomadas pela elite do esporte. Dentro das equipes, dados do treinamento dos atletas podem ser utilizados para compará-los, auxiliando o processo interno de capacitação e escalação.

1.1 Motivação

Futebol americano, como o esporte é chamado fora dos Estados Unidos, cresce em número de times, jogadores e fãs diariamente. Dois dos maiores torneios de futebol americano do mundo ainda ocorrem nos Estados Unidos: a liga profissional NFL (*National Football League*) [6] e a liga universitária de futebol americano NCAA (*National Collegiate Athletic Association*) [7]. Ao redor do mundo, a Federação Internacional de Futebol Americano (IFAF) [8] lista 71 países filiados em 5 continentes. A federação é anfitriã de um torneio internacional, o qual acontece de quatro em quatro anos. Os países participantes encontram-se em diferentes níveis profissionais. Enquanto em alguns já há remuneração para atletas e comissão técnica, outros, como o Brasil, ainda possuem a maior parte do plantel trabalhando como amadores.

Embora o cenário seja em sua maioria, amador, no Brasil, o número de atletas praticantes do futebol americano e o interesse da audiência aumentam a cada dia. Uma notícia de 2017 relata um crescimento de 800% na audiência da NFL, no período de 2013 a 2016 [9]. Atualmente, o país conta com um campeonato a nível nacional, a BFA [10], que tem uma divisão de acesso, a Superliga Nacional, ambas chanceladas pela Confederação Brasileira de Futebol Americano (CBFA) [11]. A página da *wikipedia* brasileira sobre times de futebol americano já conta com 64 equipes em 16 estados [12].

No ano de 2015, o Brasil participou, pela primeira vez, do campeonato mundial de futebol americano. A federação brasileira conseguiu levar cerca de 60 atletas para Ohio, nos Estados Unidos, onde o torneio foi disputado. Das três partidas disputadas, a equipe venceu apenas uma. Após o encerramento da copa do mundo, a federação brasileira organizou um conjunto de diretorias esportivas nos estados, para aprimorar o trabalho de análise dos atletas, para a convocação. O objetivo é melhorar o desempenho da seleção no próximo mundial, que será disputado em 2019.

Os Estados Unidos é a principal potência esportiva de futebol americano no mundo. Nesse país, a coleta e análise de estatísticas dos atletas já é uma prática habitual de técnicos e torcedores. Anualmente, os atletas que estão se graduando na universidade e pleiteando uma vaga nos times da NFL, participam de um evento chamado *NFL Combine* [13]. Nestes dias de treinamento, são coletadas informações de diversos exercícios dos atletas. Tais estatísticas são ofertadas aos times, para auxiliar no processo decisório de contratação, que ocorre anualmente em um evento chamado *NFL Draft*[14]. Neste evento, os jogadores são escolhidos pelos times. A ordem das escolhas é definida pelo desempenho dos times no ano anterior. Isto assegura que os times com piores resultados tenham a oportunidade de escolher os

melhores jogadores novatos, reequilibrando a liga. Além de beneficiar os próprios atletas, que podem acompanhar a evolução de seus resultados através da coleta de estatísticas, os times também são beneficiados por conhecer, no detalhe, o desempenho e os pontos fortes de cada um dos futuros jogadores.

O futebol americano, nos Estados Unidos, também conta com organizações como a *Pro Football Focus*[15]. Esta instituição possui um plantel de centenas de técnicos, em diferentes níveis de especialização. Os vídeos dos jogos de todos os atletas profissionais e das ligas universitárias são individualmente analisados, jogada a jogada, cada uma por dois analistas, sendo a avaliação respaldada por um terceiro analista sênior[16]. Este trabalho serve para graduar, todas as jogadas, em uma escala de qualidade de execução. Isso permite que todos os atletas sejam ranqueados, auxiliando as equipes a selecionar e acompanhar o desempenho dos jogadores.

A reprodução em larga escala destes modelos de agenciamento em países de nível amador, neste momento, não é possível, sendo esta a realidade do Brasil. O país carece de técnicos qualificados e está em estágio embrionário de gestão esportiva em muitas equipes. Desta maneira, não é possível ainda equiparar o processo de seleção de atletas com os métodos empregados pela liga americana. Nesta lacuna, surge a oportunidade de utilizar técnicas estatísticas e de inteligência computacional para apoiar o desenvolvimento do esporte.

1.2 Objetivo do Trabalho

O objetivo da pesquisa é desenvolver o esporte em países de nível amador, através da sistematização do uso de dados e de modelos de inteligência computacional. Para isto, dados de duas naturezas foram analisados para apoiar o treinamento das equipes. Um modelo foi treinado usando dados de uma equipe profissional americana, com o objetivo de identificar características relevantes que embasem a decisão de qual tipo de jogada utilizar. Este modelo busca agregar conhecimento de times de elite às decisões táticas de times amadores. Uma segunda instância desenvolve um modelo de ranqueamento de atletas amadores, baseado em dados de treinamento, coletados conforme um protocolo pré-definido. Busca-se identificar os melhores atletas, através da comparação com seus pares e mensurando o resultado em exercícios específicos, para fornecer ao técnico insumos reais de quais são os melhores jogadores para executar determinadas funções no jogo.

Embora seja mais conhecido pelo contato físico intenso, a principal característica do futebol americano é a estratégia: fatores circunstanciais do jogo, como posição em campo, tempo de jogo, diferença no placar, jogadas já realizadas, fatores ambientais e diversos outros influenciam a próxima escolha de jogada. As informações de *play-by-play* [17] de times da NFL estão disponíveis na internet. É possível trei-

nar um algoritmo classificador para prever se a equipe de ataque optará por duas opções táticas: correr ou passar a bola. A importância de cada um dos atributos relacionados à jogada está associada aos elementos táticos considerados pelo técnico ou *quarterback* adversário.

Utilizando um comitê de redes neurais [18], foi desenvolvido um algoritmo de extração de tendências, baseado na classificação do tipo de jogadas. O modelo foi treinado para uma base de dados do ano de 2006, de um time profissional da NFL. Diversas características da jogada foram usadas como atributos do classificador. Foi ajustado um modelo para cada tentativa da equipe de ataque: uma rede para classificar as jogadas do primeiro *down*, outros dois para o segundo e terceiro *down*. Para cada rede neural, foi utilizado o método de análise de relevância [19], para extrair as principais características associadas à escolha entre os dois principais tipos de jogada: corrida ou passe. Ao se concentrar em poucos atributos relevantes, o método pode orientar os técnicos amadores sobre quais são as considerações feitas por equipes profissionais para escolher suas jogadas. Ainda não há dados desta qualidade para os times no Brasil e nos países em que o esporte começa a acelerar seu desenvolvimento.

Quanto aos dados de treinamento de atletas, é possível realizar uma seleção mais justa, objetiva e eficiente, que transcenda a visão subjetiva dos técnicos. O livro [20], que romantiza como dados foram utilizados por uma equipe de *baseball* para selecionar seus atletas, serviu de inspiração. Em uma única jogada de futebol americano, diversas disputas em pequena escala, entre os diferentes setores específicos, acontecem em paralelo. Essas disputas podem ser isoladas em exercícios específicos, reduzindo a complexidade de uma jogada com toda equipe a uma disputa entre dois ou três atletas. Portanto, a execução deste exercício pode ser repetida em larga escala, como se fosse um jogo entre os atletas. Alguns destes *jogos* são chamados de *drill*, em inglês. É o nome dado às situações da partida que são intensamente repetidas para que o atleta aprimore suas técnicas na posição.

A execução de um *drill* pode ser comparada a uma disputa em jogos como o xadrez, ou jogos de video-game. Os atletas competem em uma pequena disputa, simulando uma situação específica do jogo. A vitória no *drill* indica que o atleta também teria competência para vencer o adversário, na situação análoga, dentro da partida. Portanto, o resultado dos *drills* pode ser utilizado em um modelo probabilístico de ranqueamento. Modelos como ELO [21], Glicko [22] e TrueSkill [1], são utilizados tanto nos esportes, em nível internacional, para ranquear atletas, como em jogos de video-game disponíveis para um extenso público, como será visto no capítulo de revisão bibliográfica.

O *rating* calculado para os atletas, nestes exercícios, pode ser utilizado para compará-los nas execuções das diferentes atribuições no campo. Embora o trei-

namento apenas simule a situação real de jogo, a quantidade de dados coletada é muito maior. Portanto, em um único dia, é possível colher dados suficientes para ajustar os parâmetros dos modelos de ranqueamento, sem a necessidade de possuir um plantel de técnicos qualificados para avaliar, individualmente, a técnica de cada jogador. Baseado nos *drills*, foi criado um sistema para apoiar a seleção de atletas, envolvendo:

- um conjunto de exercícios específicos, visando simular pequenas situações do jogo, para treinar e capturar informação de resultado dos atletas.
- Um protocolo de coleta de dados, que envolveu a captura por vídeo ou planilha.
- o ranqueamento dos atletas, por habilidade específica, mensurada nos exercícios aplicados.
- uma proposta de como combinar os dados dos diferentes exercícios, para sumarizar a habilidade do atleta.
- um método de detectar pontos fortes e fracos dos atletas, baseado nos dados de ranqueamento.

1.3 Contribuições do Trabalho

Um comitê de redes neurais foi ajustado aos dados de um time profissional de futebol americano para extrair os principais aspectos do jogo que levam à decisão de escolher uma jogada de corrida ou passe. A análise de relevância, conduzida sobre o modelo neural ajustado, permitiu reduzir a quantidade de atributos pelo modelo. Consequentemente, para o técnico amador, isso significa um número menor de fatores do jogo que precisam ser considerados, na hora de tomar a decisão entre corrida ou passe.

O modelo de treinamento de atletas usando dados foi aplicado em um treino aberto para atletas do Rio de Janeiro, de 2017 ao início de 2018. Os atletas foram ranqueados em um exercício específico, o *man coverage*. Foram executadas 4.845 repetições em 34 treinos. Os dados foram coletados utilizando um protocolo de treinamento. Com os dados coletados, foi possível ranquear os atletas. O *ranking* foi utilizado para selecionar jogadores para disputar um amistoso de *Flag Football*, no início de 2018. Tanto o protocolo de coleta e processamento de dados, quanto a própria base de jogadas são contribuições inéditas deste trabalho.

O mesmo modelo foi utilizado na pré-temporada de 2017 de um time da primeira divisão do campeonato nacional, oriundo do Rio de Janeiro. Dados foram coletados, desde o início da temporada, para ranquear atletas do time de base e do time

principal. Foram coletadas informações de 870 execuções de 5 exercícios, permitindo construir um *ranking* mensal, para o técnico da equipe. O *ranking* foi capaz de identificar potenciais novatos, que durante o ano alcançaram o *status* de titulares.

1.4 Organização do Texto

O Capítulo 2 apresenta trabalhos relacionados, envolvendo o ranqueamento de atletas e times em diferentes esportes. Também serão apresentados como modelos de inteligência computacional, como redes neurais, estão sendo utilizados para dados esportivos.

Para o sistema de apoio à seleção de atletas, o Capítulo de 3 detalha como funciona o procedimento de coleta, cálculo e feedback para os atletas:

- Como os dados de cada *drill* são gravados e analisados.
- Quais são as informações coletadas.
- Como o algoritmo de ranqueamento é ajustado, baseado nos dados.
- Como as informações são utilizadas pelos atletas e técnicos para melhorar os fundamentos.

O Capítulo 3 também apresenta o procedimento de treinamento da rede neural que embasa o sistema de extração de tendências. Em sequência, o Capítulo 4 apresenta os resultados de ambos experimentos. O Capítulo 5 discute os resultados, limitações e sugere a continuidade da pesquisa.

O apêndice A apresenta as regras de futebol americano, caso seja necessário uma contextualização maior no funcionamento do esporte.

Capítulo 2

Revisão Bibliográfica

O objetivo deste capítulo é determinar a contribuição deste trabalho para a área de *Sports Analytics*. O apoio à decisão para os técnicos pode usar diferentes fontes de dados. Os dados podem ser usados para de alguma maneira ranquear os atletas e auxiliar o processo de seleção. Os dados também podem ser utilizados para identificar padrões, seja no próprio time, em times adversários, ou até em times de outros países.

Dados de três naturezas foram utilizados para apoiar o treinamento de técnicos e atletas. Dados de execução de *drills* específicos foram utilizados para mensurar a habilidade dos atletas em diversas situações de um jogo de futebol americano, utilizando algoritmos de ranqueamento. A Seção 2.1 apresenta o que foi identificado na literatura sobre o uso de algoritmos de ranqueamento no cenário esportivo. Esta seção contextualiza os algoritmos existentes e aplicações encontradas nos esportes em geral e no futebol americano.

Paralelo ao esforço de seleção de atletas, dados foram utilizados para identificar padrões de jogo. Sobre os dados de treinamento, foram extraídos padrões buscando identificar oportunidades de melhoria na técnica dos atletas. Também foram analisados padrões nos jogos de um time profissional, buscando extrair características relevantes para decisão entre corrida ou passe. A Seção 2.2 apresenta o que foi encontrado na literatura de trabalhos similares, que envolvam análise de padrões para dados esportivos.

A Seção 2.3 finaliza o capítulo, apresentando o que foi encontrado de aplicações que usam dados para futebol americano, no Brasil.

2.1 Ranqueamento e Seleção Baseado em Dados

A literatura divide *Mind Sports* e *Physical Sports* [3]. Os esportes físicos são os esportes tradicionais, como atletismo, futebol, lutas. A categoria de esportes mentais

Tabela 2.1: Esportes reconhecidos pelo comitê olímpico e por outras referências, segmentados na categorização proposta por [3].

Instituição	Esportes	Combate	Independentes	Objeto
COI Verão	39	6	22	11
COI Inverno	15	0	13	12
COI Reconhecidos	52	3	22	27
Outras Referências	53	9	17	27
Total	159	18	74	67

conta com os jogos de tabuleiro como xadrez, go, damas, e mais recentemente com *e-sports*, video-games e jogos de computador.

A confederação de xadrez usa o algoritmo ELO desde 1970 [21]. A *MSN Gaming Zone*, desde 1996, usa o ELO para ranquear diversos jogos multiplayer [23]. O jogo Go, conta com ranqueamento internacional [24]. Mais recentemente, o jogo Dota 2, que possui torneios com as premiações mais valiosas da história dos e-sports [25], conta com um algoritmo de *rating* baseado no ELO [26].

Quanto aos esportes físicos, diversos já utilizam algoritmos de ranqueamento para determinar, baseado em dados, quem é o jogador ou time mais competente naquela modalidade. Os artigos [3] e [27] listam as modalidades reconhecidas pelo Comitê Olímpico Internacional (COI) e identificadas por outros meios, como a Wikipedia, e as categorizam em três grupos:

- **Esportes de Combate:** esporte no qual dois atletas entram em contato físico e devem controlar, neutralizar ou nocautear o adversário.
- **Esportes Independentes:** esporte no qual os atletas não entram em contato, controlando apenas seu corpo - natação, arco e flecha, ginástica, etc.
- **Esportes de Objeto:** esporte no qual os atletas disputam o controle de um objeto. Todos os esportes envolvendo bola, xadrez, etc.

A Tabela 2.1 segmenta os esportes nas categorias propostas. COI Verão são as modalidades pertencentes às Olimpíadas, COI Inverno as modalidades pertencentes à olimpíada de inverno e COI Reconhecidos são outras modalidades reconhecidas pelo comitê. Além de separar os esportes em categorias para possibilitar a comparação, Stefani[3] também organiza os sistemas de *rating* utilizados pelas federações de cada um dos esportes listados na Tabela 2.1. O nome *rating* é empregado para o valor numérico atribuído ao desempenho de um atleta ou time de determinado esporte, enquanto o nome *ranking* é a posição ordinal do atleta ou time, na lista ordenada de *ratings*. Desta maneira os sistemas de *ratings* utilizados pelos esportes são divididos em três categorias:

Tabela 2.2: Distribuição dos esportes pelo tipo de sistema de ranqueamento utilizado pela federação internacional correspondente.

Esporte	Quantidade	Nenhum	Subjetivo	Acumulativo	Adaptativo
Combate	18	12	2	3	1
Independentes	74	18	0	53	3
Objeto	67	30	0	28	9
Total	159	60	2	84	13

- **Subjetivos:** os *ratings* são definidos por especialistas que avaliam o desempenho dos atletas e times.
- **Acumulativo:** os *ratings* são acumulados ao longo de um período (temporada, ano). O valor do *rating* é não-decrescente, e visa estimular os competidores a participarem do maior número de competições possível no intervalo de tempo.
- **Adaptativo:** os *ratings* são gerados por algoritmos que se ajustam ao resultado de cada partida ou competição dos atletas. Neste caso, o valor do *rating* pode tanto aumentar quanto decrescer.

A Tabela 2.2 distribui os 159 esportes nos três tipos de sistema de *rating*. Apenas 13 utilizam sistemas de *rating* adaptativos, similares ao tipo utilizado no método proposto neste trabalho. A Subseção 2.1.1 apresenta os tipos de algoritmos de ranqueamento encontrados na literatura e a Subseção 2.1.2 apresenta as aplicações encontradas.

2.1.1 Algoritmos de Ranqueamento

Os algoritmos de ranqueamento adaptativos estão distribuídos em principais famílias, que exploram diferentes modelos matemáticos. As três principais identificadas na literatura são:

- Modelos probabilísticos de comparação de pares
- Modelos de regressão
- Modelos baseados em grafo

A primeira família se baseia no método de comparação de pares [28]. A Equação 2.1 descreve a premissa do modelo de Bradley-Terry, um dos modelos probabilísticos existentes.

$$P(h_1 \text{ vencer } h_2) = \frac{h_1}{h_1 + h_2} \quad (2.1)$$

Um jogador que tenha habilidade h_1 tem a probabilidade de vencer um jogador com habilidade h_2 calculada pela equação da fórmula. Outros modelos probabilísticos

existem, diferindo entre si quanto a premissa matemática, alinhada ao algoritmo de ajuste dos parâmetros a partir dos dados.

O modelo probabilístico pioneiro a ser utilizado em larga escala é o algoritmo ELO [21] desenvolvido pelo húngaro Arpad Elo. Este algoritmo é utilizado pela confederação internacional de xadrez desde 1970 [29]. O algoritmo parte da premissa de que o desempenho d_i de um determinado jogador é uma variável aleatória gaussiana com média igual a h_i , e desvio padrão igual a β . ou seja, $d_i \sim \mathcal{N}(h_i, \beta^2)$. A equação $P(h_i \text{ vencer } h_j)$ é baseada nos desempenhos d_i e d_j dos atletas. A modelagem gaussiana permitiu construir uma regra de atualização das habilidades, adaptativa a cada jogo. Isto simplificou a abordagem probabilística e o ELO se tornou um algoritmo popular para ranqueamento, como será visto mais a frente na subseção 2.1.2.

O pesquisador Mark Glickman aprimorou o algoritmo ELO, utilizando um modelo probabilístico bayesiano, no seu algoritmo Glicko [22][30]. Na parametrização bayesiana, a habilidade h_i torna-se uma variável aleatória gaussiana com um parâmetro de centralidade μ_i e incerteza associada σ_i , tal que $h_i \sim \mathcal{N}(\mu_i, \sigma_i)$. Desta maneira, este algoritmo informa a habilidade do jogador e um intervalo de credibilidade sobre essa mensuração. Logo, um jogador iniciante que no ELO possuía habilidade h_i igual a 1600, no Glicko é representado com μ_i igual a 1600 e incerteza σ_i igual a 250. Portanto, com 95% de probabilidade, a habilidade h_i deste jogador iniciante está entre 1100 e 2100. Esta nova parametrização permitiu estimar de maneira mais eficiente o *rating* de atletas iniciantes (que ainda possuem uma incerteza grande sobre o parâmetro) e jogadores inativos. Outra inovação do Glicko foi o permitir que a incerteza σ aumente com o tempo. Isso permite que h_i não convirja e possa assumir outros valores, refletindo a dinâmica temporal da habilidade do atleta.

A modelagem bayesiana inspirou os pesquisadores da Microsoft a desenvolverem o TrueSkill [1] que é a extensão do Glicko para times de múltiplos arranjos de jogadores. Desta maneira, os *ratings* podem ser calculados pelo TrueSkill para partidas com qualquer distribuição de jogadores, seja 1 contra 1, 2 contra 2, 2 contra 1, cada um por si, etc. Esta foi a principal característica do TrueSkill que favoreceu sua escolha como algoritmo utilizado neste trabalho, já que os exercícios de futebol americano apresentam diversas configurações na quantidade de atletas.

Alguns algoritmos mais recentes tentam aprimorar os previamente citados. O *Whole History Rating*[31] defende que, enquanto ELO, Glicko e TrueSkill são adaptáveis o suficiente para se ajustar à habilidade dos jogadores ao longo do tempo, eles não utilizam a informação completa dos jogos para isso. Por exemplo, se o jogador A enfrenta o jogador B e ganha, e o jogador B enfrenta o jogador C e ganha, o fato de B ser melhor que C não diz nada sobre A e C. Portanto, o autor propõe um algoritmo de otimização global que leva em consideração todos os dados, e não

ajustes locais, a cada jogo. Entretanto, o modelo ainda não aborda o caso de equipes desbalanceadas.

A família de modelos de regressão linear múltipla parte de uma premissa diferente. Nestes modelos, a variável dependente y_i é o resultado de cada i -ésimo jogo. A Equação 2.2 descreve o modelo genérico.

$$y_i = x_{i1}h_1 + x_{i2}h_2 + \dots + x_{in}h_n + e_i = \mathbf{x}_i^T \mathbf{h} + e_i \quad (2.2)$$

As componentes do vetor \mathbf{x}_i podem assumir os valores $\{-1, 0, 1\}$. x_{in} é igual a 1 quando o n -ésimo time é o vencedor do i -ésimo jogo, e assume o valor -1 para o perdedor. O valor 0 é atribuído aos times que não participaram do i -ésimo jogo. Existem diferentes parametrizações para y_i : pode adotar um valor binário $\{0, 1\}$ representando vitória/derrota, resultando em um modelo de regressão probit[3]; pode ser a diferença no placar, na qual pode ser aproximado um modelo linear por mínimos quadrados[32][33]. A variável e_i representa o resíduo.

A última família de algoritmos discutida neste artigo é a de modelos baseados em grafos. Nesta abordagem, o *rating* dos jogadores é uma medida de centralidade em uma rede de vitórias e derrotas[34]. O artigo [35] também cita algoritmos baseados em grafo como o *Page Rank* e o *Random Walk Rating*. Além disso, os autores fazem uma excelente comparação dos algoritmos de ranqueamento, utilizando dados de esportes universitários nos Estados Unidos.

A próxima Subseção discute as aplicações para esportes encontradas utilizando técnicas de ranqueamento descritas nesta Subseção.

2.1.2 Ranqueamento nos Esportes

O artigo [3] cita treze esportes que utilizam algoritmos de *rating* adaptativos. Eles estão sumarizados na tabela 2.3. Seis esportes possuem ranqueamento baseado no ELO, cinco possuem ranqueamento baseado na média histórica ponderada, e 3 esportes usam modelos de regressão probit. Alguns outros autores discutem aplicações de algoritmos adaptativos probabilísticos. Em [36], os autores usam uma base histórica de xadrez para analisar o rating dos grandes mestres ao longo do tempo. Em [37], os autores comparam alguns algoritmos para ranquear atletas de vôlei. Em [38], os autores ranqueiam equipes de futebol Gaulês. Diferente dos demais, [39] analisa dados de futebol, no contexto de apostas, utilizando modelos de Poisson. O circuito universitário americano também conta com o *Basketball Power Index* (BPI) que mede as habilidades dos jogadores de basquete [40].

Usando algoritmos de regressão, [41] utiliza um modelo de regressão logit para analisar dados de corrida de cavalos. Em [42], os autores usam regressão multinomial logit para ranquear atletas de críquete.

Tabela 2.3: Lista de esportes cujas federações utilizam algoritmos de *rating* para ranquear os atletas.

Esporte	Algoritmo
Sumo	ELO
Xadrez	ELO
Croqué	ELO
Damas	ELO
Go	ELO
Futebol Feminino	ELO
Arco e Flecha	Média Adaptativa
Frisbee Golf	Média Adaptativa
Golf	Média Adaptativa
Futebol Masculino	Média Adaptativa
Squash	Média Adaptativa
Cricket	Probit
Netball	Probit
Rugby	Probit

Baseados em grafos, uma grande quantidade de artigos foi encontrada. Três autores aplicam algoritmos utilizando grafos para ranquear atletas de tênis [43][44][45]. Em [46], dados de lutadores de luta greco-romana são ranqueados usando PageRank e ELO. [47] usa grafos para analisar o desempenho de arremessadores e rebatedores de baseball. No rugby, grafos foram usados para analisar a dinâmica de passes e *tackles* entre os jogadores dos diferentes times [48]. Para o futebol, no artigo [49] os autores utilizam modelos baseados em grafos para analisar a competitividade das ligas européias. Novamente no críquete, os autores de [50] combinam grafos com ELO para desenvolver um modelo hierárquico que leva em consideração a habilidade dos atletas para prever o vencedor dos jogos.

Em [51], o autor analisa o modelo de ranqueamento da FIFA e discute como é possível subir no ranking. Já em [52], Stefani compara os ranqueamentos utilizados nos esportes derivados do futebol: rugby, futebol e futebol americano. Os autores de [53] propõe um algoritmo alternativo à atual metodologia de ranqueamento das olimpíadas, baseado na ordem de medalhas.

Esta Subseção apresentou trabalhos encontrados de utilização de algoritmos de ranqueamento. A maior parte das aplicações encontradas é relacionada à aplicação de ranqueamento para decidir o melhor time ou melhor competidor em determinado esporte. Os artigos encontrados utilizam em sua maioria dados de partidas ou competições. Não foram encontrados exemplos utilizando metodologias de ranqueamento adaptativos em dados de treinamento.

2.1.3 Ranqueamento no Futebol Americano

A principal referência esportiva de ranqueamento de atletas de futebol americano é a plataforma Pro Football Focus [15]. Esta empresa é responsável pelo ranqueamento de todos os atletas da NFL e do circuito universitário, nos Estados Unidos. Os *ratings* utilizados oficialmente no site da NFL são oriundos desta plataforma. A página [16] descreve exatamente como funciona o modelo de ranqueamento. O vídeo de cada jogada, de cada jogador, da NFL e do universitário, é avaliado por três técnicos e classificado em uma nota que varia no intervalo $[-2, 2]$. Tal avaliação é posteriormente checada pela base de técnicos. Isto assegura uma precisão na avaliação individual das jogadas, permitindo que os jogadores sejam avaliados em quantos forem os critérios técnicos e táticos possíveis. Portanto, toda a cobertura dos atletas, depois que entram para universidade ou se profissionalizam, é avaliada pelo método da plataforma Pro Football Focus. Empresas como a RAPS [54] e SPARQ [55] oferecem serviços de avaliação baseados em exercícios atléticos. Os interessados, contratantes do seu programa, executam testes físicos e são avaliados por seus métodos proprietários. Tanto para o Pro Football Focus quanto estes outros sites de avaliação não divulgam no detalhe quais são as técnicas utilizadas para tratar as informações dos atletas. A ferramenta Hudl [56], que possui serviços para diferentes esportes, também possui funcionalidades para futebol americano. A ferramenta possui relatórios estatísticos que resumem informação de jogo, dependendo do usuário classificar as jogadas dos jogos no padrão da ferramenta. Isso dá acesso ao técnico a sumarizações das jogadas dos adversários, dependendo das categorias configuradas pelo usuário.

Há bastante material sobre ranqueamento de times universitários e profissionais, baseado no desempenho dos jogos. Em [33], é proposto um algoritmo de regressão baseado em mínimos quadrados para ranquear times universitários de basquete e futebol americano. Em [32], o autor desenvolve um algoritmo de regressão, usando como variável dependente a diferença do placar entre os times. O modelo também se baseia em mínimos quadrados para calcular os *ratings* dos times universitários de futebol americano, baseado em dados da temporada de 1996. Em [35], os autores comparam oito diferentes algoritmos de ranqueamento para quatro bases de dados. Uma das bases é composta de jogos de 56 temporadas da primeira divisão da liga americana de futebol americano universitário. Os oito algoritmos comparados são: percentual de vitórias, *Rating Percentage Index*, regressão usando norma L2, *Maximum posterior rating*, *Keener rating*, *Page Rank*, *random walker* e Elo. Em [57], os autores avaliam o desempenho dos algoritmos utilizados para selecionar as finais do campeonato universitário, que desde 1998 usa algoritmos, combinados com pesquisa pública para definir os finalistas. Os autores de [58] propõe um algoritmo baseado

em grafo, ainda com o objetivo de ranquear as equipes universitárias. O algoritmo descrito em [59] é utilizado pela NCAA, liga universitária americana. Nesta liga, não há um campeonato em nível nacional para determinar um campeão. Portanto, este algoritmo foi utilizado de 1998 a 2013 para escolher as partidas que seriam as finais da NCAA, no chamado *Bowl Championship Series*. Os autores do TrueSkill também desenvolveram seu método de análise para os times da NCAA em [60].

Sobre seleção de atletas de futebol americano, foram encontradas algumas fontes. No trabalho [61], estatísticas de desempenho dos atletas em *drills* atléticos foram correlacionados com a avaliação dos técnicos, numa tentativa de estimar quais as mensurações físicas realmente poderiam influenciar a habilidade dos atletas. Neste caso, a habilidade foi quantificada pela avaliação dos técnicos. Tanto em [62] e [63], dados de exercícios físicos e fisiológicos dos atletas titulares foram analisados, com o objetivo de encontrar os principais fatores que levariam os atletas a serem selecionados pelos técnicos. O site da referência [64] contém diversas análises para futebol americano, baseadas em dados. Em uma delas, os autores desenvolveram um modelo bayesiano para prever a posição de atletas no draft da NFL [65]. Foram usados dados de diversas fontes especializadas como insumo determinar as prováveis posições de seleção dos atletas no *draft*.

Até o momento não foi encontrada na literatura uma abordagem similar a deste trabalho, para o desenvolvimento de atletas amadores. Como os Estados Unidos já conta com um nível avançado de análise de vídeos, já existe uma fonte de dados confiável para o desempenho individual dos atletas em cada jogada. Portanto, o método proposto neste trabalho visa aproximar o desempenho do atleta de outra maneira: através do resultado agregado dos *drills*.

2.2 Classificação de Padrões nos Esportes

Este trabalho busca padrões em dados de treinamento de atletas e times amadores para explorar pontos de melhoria no desempenho. Adicionalmente aos dados de treinamento esportivo, dados de jogo foram utilizados para identificar tendência quanto ao tipo de jogada escolhida. Esta Seção apresenta trabalhos sobre detecção de padrões para esportes em geral e para futebol americano. Como a área é abrangente, foram escolhidas algumas referências para traçar um panorama geral de cada tipo de aplicação encontrada.

Existem muitos trabalhos utilizando tecnologia de GPS e micro-sensores para monitorar os atletas em tempo real. Em [66], os autores usam análise de GPS para monitorar o movimento dos atletas no futebol australiano (*Aussie Rules*), e comparam o uso da tecnologia com a coleta tradicional deste tipo de dados. Esse artigo contém diversas referências para o uso em outros esportes, como rugby e

futebol.

A referência [67] avalia o resultado de treinar atletas de futebol em conjuntos menores que 11 contra 11. Eles analisam efeitos metabólicos como taxa cardíaca, em treinamentos de 2x2, 3x3, 4x4, entre outras configurações. Um dos aspectos de inovação do trabalho proposto nesta tese é a setorização do treinamento, para colher habilidades específicas baseadas em dados. Os autores corroboram com a ideia de setorizar o treino para melhorar a eficiência. No caso dos autores, foi priorizado o estudo de aspectos fisiológicos. Para o futebol também foi encontrado o artigo [68], no qual os autores relacionam a velocidade dos atletas com dados metabólicos. Também para o futebol, o artigo [69] usou algoritmos de agrupamento (*cluster*) para avaliar atletas jovens de futebol. A ideia do trabalho é que, dentro da mesma faixa etária, os atletas sejam avaliados em comparação àqueles com características físicas e fisiológicas similares.

Em [70], os autores desenvolvem um sistema de extração de características de esportes baseado em vídeos. No ranqueamento proposto neste trabalho, dados de vídeos foram coletados manualmente. Portanto, esse tipo de tecnologia poderia ser combinada com a extração de dados de futebol americano para facilitar a mensuração dos atributos.

Em [71], os autores avaliaram diversas medidas ligadas à performance do jogo de futebol, como número de chutes, passes, e tentaram identificar qual delas tem influência no resultado. Por exemplo, os autores apontam como relevantes para a vitória: número total de chutes, chutes para o gol, assistências e posseção de bola. Isso sugere que manter a posse de bola e chutar muitas vezes ao gol é mais importante do que a precisão dos chutes, ou até mesmo do que a quantidade de gols feita pelo adversário. Esse tipo de análise agregada das partidas auxilia a preparação tática e estratégica dos times.

A análise reportada na referência [72] busca determinar se existe uma influência de jogar em casa. Os autores declaram que, entre diversos esportes, o futebol é o que apresenta a maior relação entre jogar em casa e vencer partidas.

2.2.1 Classificação de Padrões no Futebol Americano

Foram encontrados trabalhos de detecção de padrões de jogadas, para o futebol americano. Em [73], os autores tentam prever se o time realizará um passe ou corrida, o lado do campo e quantas jardas resultariam da tentativa, usando regressão logística. Os autores usaram como atributos do modelo: quarto e tempo de jogo, pontuação de cada time, número da tentativa, jardas remanescentes e posição no campo, para treinar o classificador logístico.

Em [74], um discriminante linear foi treinado, com o objetivo de prever a escolha

entre corrida ou passe, utilizando dados do time da NFL Atlanta Falcons. Foram usadas 988 jogadas ofensivas da temporada de 2005 do time. Além das variáveis usadas por [73], também foram usados como atributos o local do jogo (em casa ou fora), a formação do ataque, estatísticas de desempenho da defesa, condição climática durante o jogo e qual o tipo de gramado (turfe ou grama). Neste caso, o classificador tenta prever se o ataque realizará um passe curto, médio, longo, uma corrida, ou corrida do *quarterback*. Os autores defendem uma taxa de acerto de 40,38%.

Em [4], uma única rede neural foi ajustada para prever corrida ou passe, utilizando uma base de jogadas de 2006 do Indianapolis Colts. Com um escopo de atributos também similar à [73], o classificador neural foi treinado para prever se o ataque optaria por uma jogada de corrida ou passe, com uma taxa de acerto de 73%.

No trabalho [75], resultados foram obtidos usando um comitê de classificadores. O modelo foi treinado utilizando uma base de dados proprietária, contendo dados da temporada da NFL de 2012 até 2014. Neste trabalho, os diversos classificadores foram treinados, para subconjuntos específicos de jogadas: as combinações entre quarto e tentativa. Os autores declaram ser uma evolução de [76], [77] e [78]. A taxa de acerto obtida pelos autores, para o comitê, foi de 75,9%.

2.3 Trabalhos Encontrados para Futebol Americano no Brasil

Foram encontradas três aplicações no Brasil, na área de biomedicina. Em [79], foram analisadas características anaeróbicas e antropométricas dos atletas, buscando identificar o perfil atlético da equipe. O artigo [80] avalia características antropométricas de um time amador de futebol americano do nordeste e compara com [79]. Em [81], foram analisados dados de desempenho isocinético de flexores e extensores de joelho.

No Brasil, a área de biomedicina começa a publicar artigos analisando informações dos atletas amadores. Não foram encontradas outras aplicações utilizando dados, no cenário nacional.

Capítulo 3

Método

Neste capítulo serão descritos os métodos adotados para apoiar técnicos e atletas amadores. A primeira seção descreve os *drills* que foram considerados para mensurar a habilidade dos atletas. A segunda seção explica quais dados foram utilizados pelos modelos desenvolvidos no trabalho. A terceira seção descreve os métodos utilizados:

- o modelo probabilístico considerado para gerar os *ratings*, por *drill*.
- Como os dados gerados pelo modelo probabilístico foram tratados para informar aos atletas e técnicos.
- Como foram extraídos pontos fracos da base de execução de jogadas.
- Como a rede neural especialista foi treinada para extrair tendências de jogo de um time profissional da NFL.

3.1 Escopo de Exercícios

Junto com a equipe de técnicos do Vasco Patriotas, foi elencado um conjunto de cinco exercícios para compor o *card* de habilidade de cada atleta: *big cat*, *tackle box*, *man coverage*, *pass rush* e *oklahoma drill*. Esta Seção descreve quais foram os exercícios escolhidos, como funcionam e a quais setores são relevantes.

3.1.1 Big Cat

O primeiro *drill* tem como objetivo medir a força e a tração dos atletas. É muito parecido com uma partida de Sumô. Dois atletas trocam força, com o fim de empurrar o adversário para fora da região do exercício. A Figura 3.1 mostra o diagrama técnico de como o exercício deve ser montado.

Execução: O *drill* se inicia após o apito do técnico. Durante a execução, os jogadores devem utilizar sua força, recolocação de mãos, e movimentação de pernas



Figura 3.1: Diagrama de montagem do *Big Cat*. Os cones azuis são posicionados em um quadrado com 3 jardas de comprimento e 3 jardas de largura. Os cones vermelhos são posicionados em paralelo aos cones azuis, em uma distância de 3 jardas, para criar a zona de segurança. Os cones pretos devem sinalizar o meio da região do *drill*. A defesa ocupa a lateral superior do *drill*, e o ataque a lateral inferior.

Tabela 3.1: Resultados e pontuações consideradas para o *drill Big Cat*.

Resultado	Vencedor	Pontuação
Jogador de defesa desloca jogador de defesa para fora da região de <i>drill</i>	ataque	1
Jogador de defesa desloca jogador de ataque para fora da região de <i>drill</i>	defesa	1
Jogadores não conseguem derrubar ou remover o adversário da área de <i>drill</i> em menos de 10 segundos	empate	0

Tabela 3.2: Resultados e pontuações consideradas para o *drill Tackle Box*.

Resultado	Vencedor	Pontuação
Atacante alcançando a linha de fundo	ataque	1
Atacante derrubado pelo defensor na região de <i>drill</i>	defesa	1
Atacante empurrado para fora da região de <i>drill</i> pelo defensor	defesa	1

para deslocar o adversário para fora da área do *drill*. A Tabela 3.1 descreve os possíveis resultados e suas pontuações. O exercício se encerra quando um dos jogadores é removido da área de *drill*, cai no chão, ou após dez segundos de execução.

3.1.2 Tackle Box

O segundo *drill* tem como objetivo medir a habilidade de *tackle* dos defensores, e a capacidade de esquivar e força dos atacantes. Neste *drill*, dentro de uma região específica, o jogador de ataque tenta driblar ou atropelar o jogador de defesa, para conquistar uma quantidade pré-determinada de jardas. O jogador de defesa precisa impedir este avanço, derrubando o adversário ou o empurrando para fora da região de *drill*. A Figura 3.2 mostra o diagrama técnico de como o exercício deve ser montado.

Execução: Ao apito do técnico, o jogador de ataque deve atravessar a área do *drill*. O defensor deve impedir o avanço do jogador de ataque. O atacante deve usar técnicas de drible, manter o corpo o mais baixo possível e aguentar o impacto do defensor. O defensor deve utilizar técnicas de *tackle* para derrubar o adversário. A Tabela 3.2 descreve os possíveis resultados e suas pontuações. O exercício se encerra quando o atacante atravessa a linha de fundo do *drill*, ou quando é derrubado ou empurrado para fora da região válida.

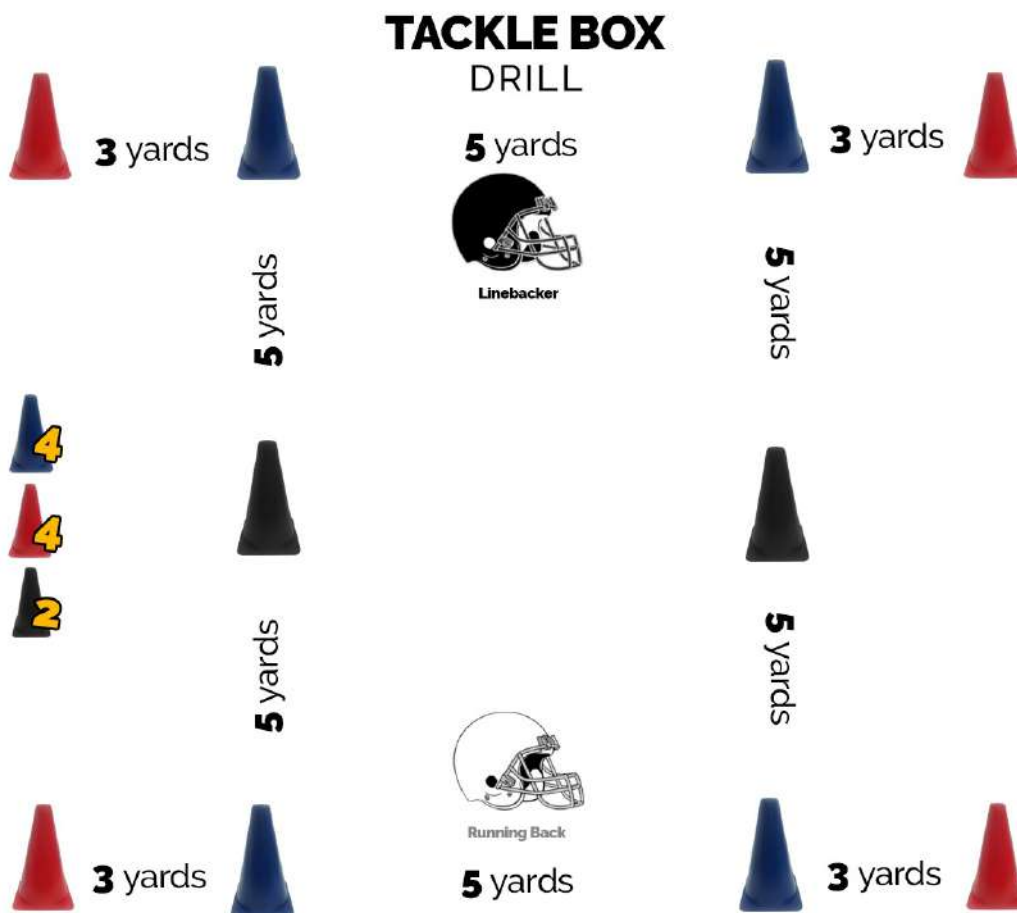


Figura 3.2: Diagrama de montagem do *Tackle Box*. Os cones azuis são dispostos num retângulo com 10 jardas de comprimento e 7 jardas de largura. Os cones vermelhos são posicionados em paralelo aos cones azuis, em uma distância de 3 jardas, para criar a zona de segurança. Os cones pretos devem sinalizar o meio da região do *drill*. A defesa ocupa a lateral superior do *drill*, e o ataque a lateral inferior.

3.1.3 Man Coverage

O terceiro *drill*, chamado de *Man Coverage* ou marcação pessoal de passes, tem como objetivo medir a precisão no passe dos *quarterbacks*, a capacidade de se desmarcar e receber passes dos recebedores, e a capacidade de marcar individualmente o adversário, para os defensores. Dentro de uma região específica, o recebedor executa um dos padrões de movimentação, chamados de rotas, tentando se desvencilhar de seu marcador. O *quarterback* arremessa um passe para que o recebedor pegue a bola em um ponto pré-combinado, e o defensor precisa impedir isto, seguindo o recebedor e tentando atacar a bola. A Figura 3.3 mostra o diagrama técnico de como o exercício deve ser montado. Este foi o único exercício para quais dados foram coletados e analisados em vídeo, no treino aberto para atletas do Rio de Janeiro.




Figura 3.3: Diagrama de montagem do *drill Man Coverage*. Os cones azuis e vermelhos devem ser intercalados em pares (21 jardas de distância entre um e outro) a 5 jardas de distância entre os pares, a fim de demarcar as jardas no campo, na *sideline* e na *hashmark*. Um cone preto deve determinar o ponto do qual a bola sai para o *quarterback* (QB), e os 7 restantes devem ser posicionados 10 jardas atrás do *drill*, criando uma zona de segurança para movimentação do *quarterback*. A câmera deve estar posicionada atrás do recebedor, filmando-o de corpo inteiro, antes do início da jogada.

Tabela 3.3: Resultados e pontuações consideradas para o *drill Man Coverage*.

Resultado	Vencedor	Pontuação
Passe completo resultando em um avanço superior a 10 jardas	ataque	1
Passe completo para um avanço menor que 10 jardas	defesa	1
Passe Incompleto	defesa	1
Interceptação	defesa	1

Execução: Ao comando do *quarterback*, o recebedor deve se deslocar em sua rota, previamente estabelecida, e busca se desmarcar afim de criar uma área de recepção para o passe do *quarterback*. O defensor deve buscar manter-se próximo ao recebedor, a fim de tentar impedir a recepção do passe. O recebedor pode se utilizar de qualquer uma das 8 rotas básicas, e suas variações para tentar se desmarcar. O defensor pode se utilizar de qualquer um dos 3 alinhamentos de profundidade, ou suas 3 variações de posição, para iniciar o *drill* em seu ponto de vantagem. A dupla recebedor/*quarterback* ganha se o passe for completo, e o recebedor avançar, sem contato, até a linha de 10 jardas. O defensor ganhar, impedindo o adversário de receber a bola ou tocando-o antes dele alcançar a linha. A pontuação do *drill* se dá de acordo com a Tabela 3.3.

3.1.4 Pass Rush

O quarto *drill* serve para mensurar a capacidade de pressionar o *quarterback*, dos defensores, e a capacidade de proteger o *quarterback*, para os atacantes. O jogador de defesa precisa se desvinciliar do atacante e alcançar o *quarterback*, representado usualmente por um cone ou por um *dummy*. *Dummy* é um equipamento específico de futebol americano que serve para representar um jogador parado. A Figura 3.4 mostra o diagrama técnico de como o exercício deve ser montado.

Execução: Ao *snap* do *center*, o defensor, que estará posicionado, em alinhamento (interno ou externo, em referência ao jogador de linha ofensiva designado), deverá tentar ultrapassar o jogador de linha ofensiva, podendo se utilizar uma de suas técnicas de passagem, e mover o *dummy*, seja tocando-o, ou deslocando o jogador de linha ofensiva até que o mesmo mova o *dummy*. Analogamente, o jogador de linha ofensiva deve impedir que o defensor mova o *dummy*. O defensor tem 3 segundos para alcançar o *dummy*. A pontuação do *drill* se dá de acordo com a Tabela 3.4.

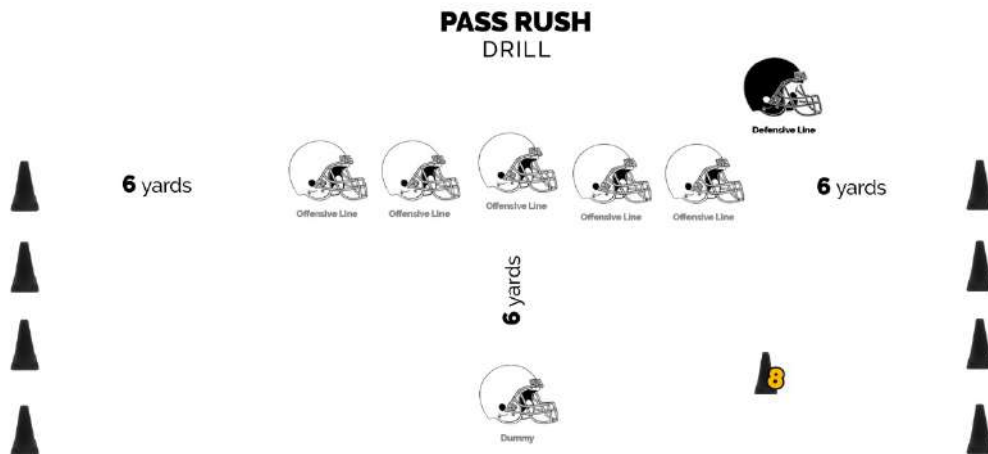


Figura 3.4: Diagrama de montagem do *drill Pass Rush*. Os jogadores de linha ofensiva devem se posicionar em linha horizontal, a meia jarda de distância um do outro, sendo o *center* (jogador central), responsável por segurar a bola em posição de *snap*. Os cones pretos devem ser dispostos a 6 jardas dos jogadores de linha ofensiva das extremidades, a partir de seu pé externo, criando uma área de segurança para o *drill*. O *dummy* deve ser posicionado 6 jardas atrás do *center* (jogador central).

Tabela 3.4: Resultados e pontuações consideradas para o *drill Pass Rush*.

Resultado	Vencedor	Pontuação
Jogador defensivo encosta no <i>Dummy</i> em menos de 3 segundos	defesa	1
Jogador defensivo projeta atacante em cima do <i>dummy</i> em menos de 3 segundos	defesa	1
<i>Dummy</i> não recebe contato dentro de 3 segundos	ataque	1

3.1.5 Oklahoma Drill

O último *drill* considerado para ranquear os atletas serve para mensurar a habilidade do jogo corrido. Dois jogadores de ataque enfrentam dois jogadores de defesa. Um atacante bloqueia para o outro correr com a bola. Os jogadores de defesa precisam se desvencilhar do atacante bloqueador, derrubar ou colocar para fora da área de *drill* o atacante corredor. A Figura 3.5 mostra o diagrama técnico de como o exercício deve ser montado.



Figura 3.5: Diagrama de montagem do *drill Oklahoma*. Os cones azuis devem ser dispostos em um retângulo com 10 jardas de comprimento e 7 jardas de largura. Os cones vermelhos devem ser posicionados em paralelo aos cones azuis, em uma distância de 3 jardas, para criar a zona de segurança. Os cones pretos devem sinalizar o meio da região do *drill*. A defesa ocupa a lateral superior do *drill*, e o ataque a lateral inferior.

Execução: Ao apito do técnico, o time de ataque deve atravessar a área do *drill*. A linha de fundo está à 10 jardas do início do *drill* e 5 jardas do primeiro jogador de defesa. O atacante bloqueador busca remover os adversários para liberar passagem ao atacante corredor. Ao final, os atletas vencedores ganham a pontuação indicada

Tabela 3.5: Resultados e pontuações consideradas para o drill *Oklahoma*.

Resultado	Vencedor	Pontuação
Corredor alcança a linha de fundo	ataque	1
Corredor derrubado pelos defensores	defesa	1
Corredor empurrado para fora da área de drill	defesa	1

Tabela 3.6: Matriz relacionando os setores e para quais *drills* os atletas do setor tiveram habilidade mensurada.

Setor	Big Cat	Tackle Box	Man Coverage	Pass Rush	Oklahoma
Linha Ofensiva	X	-	-	X	X
<i>Running Backs</i>	X	X	X	X	X
<i>Quarterbacks</i>	-	-	X	-	-
<i>Wide Receivers</i>	X	X	X	-	X
Linha Defensiva	X	X	-	X	X
<i>Linebackers</i>	X	X	X	X	X
<i>Defensive Backs</i>	X	X	X	-	X

na Tabela 3.5.

3.1.6 Drills Por Posição

Junto com a comissão técnica do time carioca, foram decididos quais *drills* compõem a métrica de habilidade de cada setor. A Tabela 3.6 apresenta o mapeamento utilizado.

3.2 Coleta de Dados

Dados de duas naturezas foram utilizados. Para o comitê neural desenvolvido, foram usados dados de uma equipe profissional da NFL. Para o trabalho com atletas amadores, dados dos *drills* foram coletados em um treino aberto no Rio de Janeiro e no treino de um clube carioca da primeira divisão, ao longo da temporada de 2017. Esta Seção descreve a natureza dos dados coletados em cada um dos experimentos.

3.2.1 Dados Time de Alto Desempenho

O objetivo do comitê neural é identificar o que influencia a escolha de um time de alto nível, no que tange a escolha entre corrida ou passe. Para isto, são considerados como atributos as características da jogada. Estas características podem ser divididas em dois subgrupos: fatores gerais da jogada e fatores circunstanciais do jogo. O grupo de fatores gerais da jogada tem relação com os conceitos utilizados pela equipe de

Tabela 3.7: Atributos utilizados no treinamento da redes especialistas.

N	Atributo	Unidade	Valores
1	Distância para o First Down	Jardas	{0, 99}
2	Posição no Campo	Jardas	{0, 99}
3	Diferença no Placar	Pontos	$-\infty, \infty$
4	Quarto de Jogo	Quarto	{1, 2, 3, 4}
5	Tempo	Segundos	{0, 3600}
6	Dois Minutos Finais	Binário	{0, 1}
7	Última Jogada - Passe	Binário	{0, 1}
8	Última Jogada - Corrida	Binário	{0, 1}
9	Última Jogada - Times Especiais	Binário	{0, 1}
10	Última Jogada - Jardas	Jardas	{-99, 99}
11	Tipo de Jogada (Corrida/Passe)	Classe	{-1, 1}

ataque. Um time pode utilizar mais conceitos de corrida e, naturalmente, ter uma propensão maior a correr na primeira descida. Um time pode utilizar mais conceitos de passe e, portanto, ter uma propensão maior em passar primeiro, para que a defesa ocupe os espaços e fique mais fácil usar jogadas de corrida. Os fatores circunstanciais do jogo tem a ver com influências locais, que mudam a cada jogo: placar, clima, tempo de jogo, etc.

Exemplos de fatores gerais da jogada são: qual é a tentativa; quantas jardas faltam para o *first down*; qual a posição no campo; qual a formação que o time de ataque está utilizando, ou seja, como está distribuída a equipe, quantos recebedores, quantos corredores em campo, etc; qual foi a jogada anterior.

No grupo de fatores circunstanciais do jogo estão inclusos: qual o tempo de jogo (quarto, minutos corridos, se está nos dois minutos finais); qual o placar; condições climáticas; *timeouts* restantes; produtividade atual do jogo de passe e corrida.

Do conjunto de atributos possíveis, o experimento foi realizado utilizando os listados na Tabela 3.7.

Foram utilizados os dados da temporada de 2006 de um time profissional da NFL: todas as jogadas dos 10 jogos da temporada regular. O *quarterback* do time neste ano era um grande astro, reconhecido como um dos melhores *quarterbacks* da história. Ele também é conhecido por ser um com a maior capacidade de alterar as jogadas no campo, dependendo do c6rum da equipe defensiva. As jogadas foram obtidas no *Play-by-play* da NFL [17]. As variáveis foram normalizadas para o treinamento.

3.2.2 Dados de Treino de Atletas Amadores

Os dados dos *drills* foram coletados de duas maneiras diferentes. No treino aberto para atletas do Rio de Janeiro, os dados foram coletados em vídeo. No treino privado para clube carioca, os dados foram anotados em planilhas. O primeiro processo

garantiu uma coleta de dados mais rica, e o segundo garantiu uma cobertura maior de posições.

Dados de Vídeo do Treino Aberto

Para garantir a qualidade da apropriação das informações associadas às jogadas, possibilitar a investigação das anomalias encontradas e até para auditar as informações colhidas é necessário que os resultados sejam capturados em vídeo. Desta maneira, as jogadas do treino aberto foram filmadas desde o princípio. Os dados foram capturados em uma câmera de celular, em uma posição específica para identificar os principais atributos do *drill* a serem categorizados.

Este treinamento abrangeu o *drill man coverage*. Além dos dados analisados em vídeo, informações referentes à jogada passaram a ser gravadas em áudio pelo câmera, ao vivo, de forma a facilitar a análise posterior. A Tabela 3.8 descreve os atributos coletados de cada vídeo.

Após a filmagem, são colhidas as informações da execução do exercício, já no vídeo. O trabalho se iniciou para o *drill* de cobertura mano-a-mano e os dados que já foram coletados serão usados para exemplificar o tipo de informação que é registrada (Tabela 3.8).

Tabela 3.8: Dados coletados, por jogadas, extraídos de vídeo e áudio, no treino aberto de *man coverage*.

Campo	Descrição
Video	Número do vídeo, para posterior identificação
Data	Dia do treino
Avaliador	Técnico responsável pela categorização do vídeo
Quarterback	Jogador que realizou o passe
Wide Receiver	Jogador que percorreu a rota
Alinhamento	Posição inicial do <i>Wide Receiver</i>
Rota	Padrão de movimentação escolhido
Defensive Back	Jogador que realizou a marcação
Cobertura	Padrão de marcação escolhido
Resultado	Qual foi o resultado do <i>drill</i> .
Vencedor	Ataque/Defesa/Empate

Dados de Treino do Clube Carioca

De janeiro a julho de 2017, foi desenvolvido em parceria com um time do Rio de Janeiro, um índice de desempenho para os atletas. O índice abrangiu frequência nos

treinos, estudo de vídeos, avaliação de vídeos do coletivo e *ratings* de *drills* de mano a mano.

As mesmas técnicas empregadas nos dados do treino aberto para ranquear o *drill* de *man coverage* foram utilizados no treinamento privado do time carioca para ranquear os atletas em todos os 5 *drills* descritos neste capítulo. Para o clube carioca, não foi possível armazenar as jogadas em vídeo, e os resultados foram anotados em planilhas, por técnicos assistentes. Desta maneira um escopo menor de dados foi coletado, conforme mostra a Tabela 3.9.

Tabela 3.9: Dados coletados em planilha pelos técnicos assistentes do time de futebol americano carioca.

Campo	Descrição
Data	Dia do treino
Ataque	Jogador(es) do Ataque
Defesa	Jogador(es) da Defesa
Vencedor	Ataque/Defesa/Empate

3.3 Modelos Utilizados

Para a análise dos dados de um time de alto rendimento, foi usado um comitê de redes neurais. O método de treinamento da rede será descrito na Subseção 3.3.1. Para a análise dos dados de atletas amadores, foi desenvolvido um modelo de ranqueamento usando o algoritmo de *rating* TrueSkill, que será descrito na seção 3.3.2.

3.3.1 Modelo para extração de tendências na seleção de jogadas

Para realizar a extração de tendências dos dados de um time de alto nível, foi usado um comitê de redes neurais do tipo MLP (*multilayer perceptron*), totalmente conectada e com uma camada escondida [18]. Todos os neurônios da rede utilizam a função de ativação tangente hiperbólica. Foi utilizado o algoritmo RPROP *resilient backpropagation* [82].

O comitê é composto de três redes neurais especialistas, cada uma treinada para classificar as jogadas de um dos três *downs*. O quarto *down* foi descartado por sua tendência de ser uma jogada de times especialistas.

A primeira parte do treinamento teve como objetivo encontrar o número de neurônios na camada oculta. Para este fim, foi utilizada busca exaustiva incremental no número de neurônios, começando por dois. Validação cruzada Jackknife [83], com 5 partições, foi aplicada para estimar as flutuações estatísticas sobre o desempenho do

classificador proposto. Para cada rede, em cada fase do treinamento, a base de dados foi dividida em 5 partições, mantendo o balanço de classes em cada uma. Para o terceiro *down*, foi necessário replicar jogadas de passe. Após essa divisão, mantendo cada partição como conjunto de validação, uma busca em *grid* foi realizada para determinar o número de neurônios. Média e desvio padrão da taxa de acerto foram usados como figuras de mérito para cada arquitetura de rede. O treinamento foi controlado por erro de validação, número máximo de épocas e gradiente mínimo.

Após o treinamento da rede, uma análise de relevância [19] foi executada para identificar quais atributos são os mais relevantes para a classificação. Do ponto de vista do jogo, permite evidenciar quais aspectos do jogo são mais importantes para seleção de passe ou corrida. Isso é importante para técnicos amadores, que podem desconsiderar todas as características irrelevantes, que não impactam a definição da jogada. A redução de dimensionalidade obtida por reter apenas os atributos relevantes também possibilita a redução da quantidade de neurônios na camada oculta, o aumento da taxa de acerto e redução do desvio padrão. A Equação 3.1 define a relevância $R(X_j)$ para um determinado atributo X_j .

$$R(X_j) = \frac{\sum_{i=1}^N |\hat{y}(\mathbf{x}_i) - \hat{y}(\mathbf{x}_i|_{x_{ij}=\bar{x}_j})|^2}{N} \quad (3.1)$$

Dada uma jogada \mathbf{x}_i da base de dados, $\hat{y}(\mathbf{x}_i)$ é a saída da rede, calculada para essa jogada, $\mathbf{x}_i|_{x_{ij}=\bar{x}_j}$ é a jogada \mathbf{x}_i com seu j -ésimo atributo substituído pela média. Como os atributos foram normalizados estatisticamente para terem média igual a zero, o procedimento é análogo a zerar o j -ésimo atributo. Se zerar um atributo não tem efeito na estimativa da classe \hat{y} , o atributo é irrelevante e pode ser eliminado. Os valores da relevância podem ser normalizados pelo máximo, para serem determinados aqueles mais importantes.

Após o cálculo da relevância, os modelos especialistas foram treinados novamente, considerando apenas os atributos com relevância normalizada maiores do que 0,2. A rede com o melhor resultado para esta nova etapa foi aquela considerada para modelar cada *down*. O diagrama da Figura 3.6 exemplifica o procedimento de treino.

Para validação do resultado, o comitê neural foi comparado com resultados obtidos por uma rede neural [4] e duas árvores de decisão utilizando os algoritmos See5 (C4.5) [87] e ID3[88].

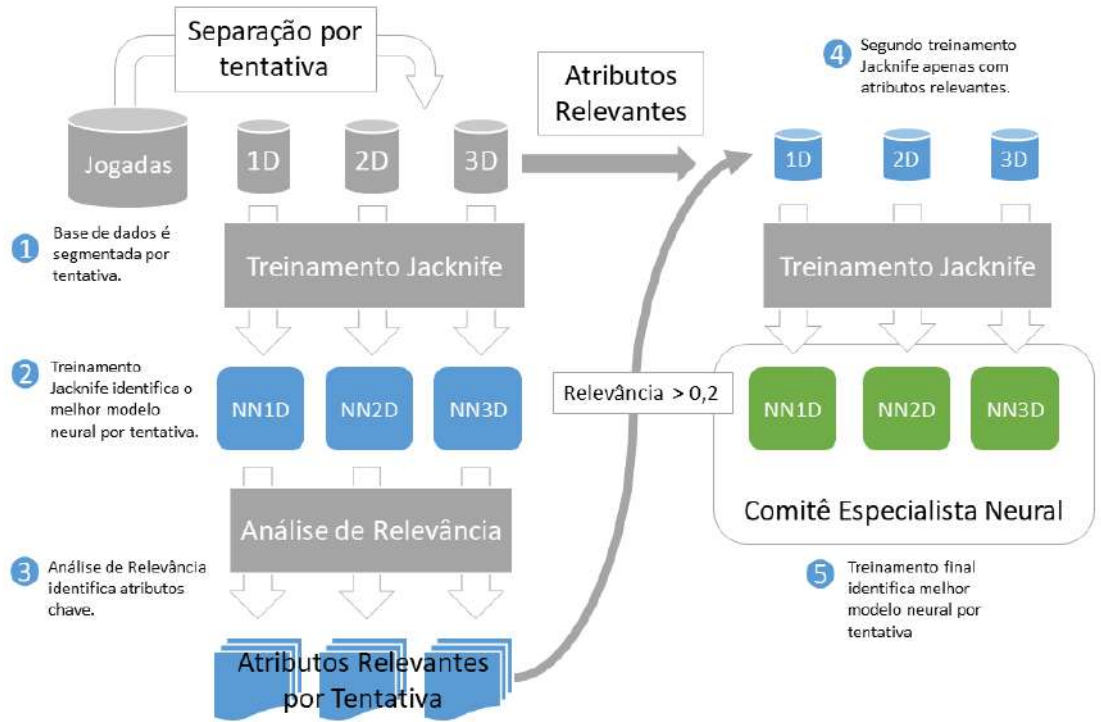


Figura 3.6: Diagrama de treinamento do comitê neural.

3.3.2 Algoritmo de Rating Probabilístico

O algoritmo utilizado para calcular os rankings foi o TrueSkill. Como o modelo tem suas raízes no ELO [21], nesta Subsecção será descrita a evolução na parametrização, do ELO ao Trueskill.

O ELO assume que todos os jogadores possuem um *rating* associado a sua habilidade de execução de um determinado *drill*. O *rating* dado ao i -ésimo atleta neste *drill* será chamado μ_i . A cada partida, o atleta pode desempenhar acima ou abaixo do seu desempenho médio. Para representar essa variação, assume-se que a performance do atleta é uma variável aleatória. Neste exemplo, será usada a distribuição normal com média igual a μ_i e desvio padrão igual a β (Equação 3.2). O modelo atual para xadrez usa a curva logística ao invés da normal [21].

$$d_i \sim \mathcal{N}(\mu_i, \beta^2) \quad (3.2)$$

Em uma partida entre dois jogadores, o modelo assume que cada um exibe uma determinada performance d_i . Sendo $d_1 \sim \mathcal{N}(\mu_1, \beta^2)$ para o desempenho do jogador 1 e $d_2 \sim \mathcal{N}(\mu_2, \beta^2)$ para o desempenho do jogador 2, a equação 3.3 define a variável aleatória δ_1 , que representa o “saldo de desempenho” do jogador 1. Desta maneira, é possível calcular a **pontuação esperada** do i -ésimo jogador contra o j -ésimo

jogador, na equação 3.4.

$$\delta_1 \sim \mathcal{N}(\mu_1 - \mu_2, \sqrt{2}\beta) \quad (3.3)$$

$$p_{ij} = E[\delta_i] = \Phi\left(\frac{\mu_i - \mu_j}{\sqrt{2}\beta}\right) \quad (3.4)$$

A função Φ representa a função distribuição de probabilidade acumulada normal. Foi possível usar esta função padrão por conta da normalização de δ_1 por $\sqrt{2}\beta$. Portanto, a probabilidade do jogador 1 vencer o jogador 2 é análoga a $\sim P(\delta_1 > \delta_2 | \mu_1, \mu_2)$. A Figura 3.8 exemplifica a distribuição conjunta δ_1 .




Figura 3.7: Exemplo do efeito da dispersão β na probabilidade de vitória, dada as habilidades do primeiro e do segundo jogador. A região de empate (verde) é modelada como a região onde a probabilidade de vitória é menor que um determinado ϵ .

A Figura 3.8 é um exemplo adaptado de [84]. Mostra o comportamento da função Φ , para $\beta = 200$. Suponha que dois atletas com *ratings* $\mu_1 = 1200$ e $\mu_2 = 1000$ se enfrentem em uma partida. A diferença de *ratings* neste confronto é de $\mu_1 - \mu_2 = 200$. Pela curva, para $x = 200$ temos $y = 75\%$. Portanto, a expectativa de pontuação para o jogador 1 é igual a 0,75. Isto é o mesmo que $\Phi\left(\frac{1200-1000}{\sqrt{2} \cdot 200}\right) = \Phi\left(\frac{200}{\sqrt{2} \cdot 200}\right) = \Phi\left(\frac{1}{\sqrt{2}}\right) = 0,75$.

Até então a modelagem permitiu que dois atletas tivessem *ratings* associados ao seu desempenho, e que fosse possível estimar a pontuação/margem de vitória/probabilidade de vitória do atleta com maior *rating*. Falta definir a maneira com os *ratings* são atualizados dado vitória/derrota dos jogadores. A solução dada por ELO foi bastante simples. Os *ratings* são atualizados, de maneira linear, proporcionais à diferença entre o desempenho esperado p_i e a pontuação real do i -



Figura 3.8: Função Cumulativa Φ para o caso $\beta = 200$. A função relaciona à diferença de ratings com a probabilidade de vitória.

ésimo atleta, y_i . No caso de vitória/empate/derrota, y_i assume os valores $\{0, \frac{1}{2}, 1\}$. A equação 3.5 apresenta a atualização Δ_i , a ser aplicada sobre o rating do i -ésimo atleta, após a partida contra o j -ésimo atleta.

$$\Delta_i = K \left(y_i - \Phi \left(\frac{\mu_i - \mu_j}{\sqrt{2}\beta} \right) \right) = K (y_i - p_{ij}) \quad (3.5)$$

Após a partida, as habilidades μ_i são atualizadas, com $\mu_i \leftarrow \mu_i + \Delta_i$. A variável K é chamada de fator K (K factor) e controla a proporção da diferença entre resultado/expectativa que é aplicada ao rating dos jogadores. Um K grande faz com que os *ratings* oscilem. Um K pequeno faz com que o *rating* de um jogador novato convirja lentamente para o seu valor real. Isso fez com que diferentes heurísticas fossem inventadas para tratar o problema, como usar valores de K grandes para jogadores novatos, de forma a acelerar a convergência do *rating*, e K menores para jogadores veteranos, para assegurar estabilidade. A interpretação do K por [84] se baseia na memória dos resultados anteriores. Um K pequeno faz com que pouca informação do resultado presente seja considerado, aumentando o peso do histórico. Um K grande faz com que o resultado recente tenha mais peso no próximo valor do *rating*.

Mark Glickman propôs uma solução para isto, em seu algoritmo Glicko [22], como foi visto no capítulo 2. Na abordagem bayesiana, a habilidade do atleta é modelada utilizando dois parâmetros: uma habilidade μ com uma incerteza σ associada a este parâmetro. Portanto, no Glicko, existe uma incerteza associada ao *rating*. Os jogadores novatos possuem uma incerteza grande associada a seu *rating*. Jogadores veteranos possuem incerteza menor. Conforme o jogador participa em diversas partidas, ambos valores convergem para a estimativa de habilidade do atleta. A maneira de considerar os *ratings* também muda: agora os atletas tem, para

um nível de confiança representado por α , habilidade entre $[\mu_i - \alpha\sigma, \mu_i + \alpha\sigma]$. Glicko também introduz o “Fator K Dinâmico”, que basicamente soma uma constante τ ao desvio padrão σ antes de cada atualização. Isto faz com que σ nunca convirja para zero, permitindo que μ varie no tempo.

O procedimento de atualização de habilidades do TrueSkill extrapolou o Glicko para o caso de múltiplos jogadores. A atualização das habilidades é feita utilizando o teorema de Bayes e está descrita na equação 3.6. A variável μ representa a habilidade dos jogadores, \mathbf{y} representa o resultado da partida e A representa a configuração dos times.

$$p(\mu|\mathbf{y}, A) = \frac{P(\mathbf{y}|\mu, A) p(\mu)}{P(\mathbf{y}|A)} \quad (3.6)$$

A distribuição a priori $p(\mu)$ é a distribuição das habilidades dos jogadores anterior à partida. A distribuição a posteriori $p(\mu|\mathbf{r}, A)$ é a atualização nas habilidades μ , dado os times e o resultado. Não existe uma forma analítica para calcular esta probabilidade a posteriori. O TrueSkill utiliza um grafo de fatores para decompor as distribuições, e **atualiza as habilidades utilizando um algoritmo de *belief propagation***[85]. A figura 3.9 mostra um exemplo de grafo construído para um jogo entre três times.




Figura 3.9: Exemplo de um grafo relacionado a um jogo com três times. O primeiro time tem como membro o jogador 1, com habilidade μ_1 . O segundo time tem como membros os jogadores 2 e 3, e o terceiro time tem como membro o jogador 4. O grafo exemplifica como as habilidades são combinadas na habilidade do time, t_n e no desempenho esperado d_n dos times. As setas mostram como, dada a evidência, as informações são propagadas de volta pelo grafo. Adaptado de [1].

Na prática, o que o TrueSkill introduz é uma maneira de combinar os *ratings*

individuais nos *ratings* de um time, e como atualizar as distribuições marginais, que representa a habilidade de cada atleta, dada a distribuição a posteriori $p(\mu|\mathbf{y}, A)$.

Após o encerramento de um jogo, dado o resultado, o algoritmo de atualização calcula os novos valores para μ e σ . A Equação 3.7 reúne as equações de *belief propagation* derivadas para o caso de um jogo entre dois jogadores, para a habilidade μ_i e incerteza σ_i do vencedor e do perdedor.

$$\begin{aligned}
\mu_{\text{vencedor}} &\leftarrow \mu_{\text{vencedor}} + \frac{\sigma_{\text{vencedor}}^2}{c} \cdot v\left(\frac{(\mu_{\text{vencedor}} - \mu_{\text{perdedor}})}{c}, \frac{\epsilon}{c}\right) \\
\mu_{\text{perdedor}} &\leftarrow \mu_{\text{perdedor}} - \frac{\sigma_{\text{perdedor}}^2}{c} \cdot v\left(\frac{(\mu_{\text{vencedor}} - \mu_{\text{perdedor}})}{c}, \frac{\epsilon}{c}\right) \\
\sigma_{\text{perdedor}}^2 &\leftarrow \sigma_{\text{perdedor}}^2 \left[1 - \frac{\sigma_{\text{perdedor}}^2}{c^2} \cdot w\left(\frac{(\mu_{\text{vencedor}} - \mu_{\text{perdedor}})}{c}, \frac{\epsilon}{c}\right)\right] \\
\sigma_{\text{vencedor}}^2 &\leftarrow \sigma_{\text{vencedor}}^2 \left[1 - \frac{\sigma_{\text{vencedor}}^2}{c^2} \cdot w\left(\frac{(\mu_{\text{vencedor}} - \mu_{\text{perdedor}})}{c}, \frac{\epsilon}{c}\right)\right]
\end{aligned} \tag{3.7}$$

$$c^2 = 2\beta^2 + \sigma_{\text{vencedor}}^2 + \sigma_{\text{perdedor}}^2$$

As funções $v(t, \epsilon)$ e $w(t, \epsilon)$ são pesos calculados em função da diferença de habilidade t e a margem de empate ϵ . Quando a diferença é negativa, o valor de v é maior. Portanto, vencer um adversário com *rating* menor acarreta numa atualização pequena, enquanto vencer alguém com o *rating* superior gera um incremento no *rating* do vencedor. As derivações do algoritmo *belief propagation* para os casos com quaisquer arranjos de times podem ser obtidas em [1].

Por estas propriedades, o algoritmo TrueSkill foi escolhido para ranquear os atletas de futebol americano. Nem o ELO e nem o Glicko são modelados para partidas com mais de um jogador, ou com times desbalanceados: nem todos os *drills* são confrontos individuais. Foi utilizada uma biblioteca aberta, desenvolvida na linguagem *Python*, para desenvolver o sistema de ranqueamento. A biblioteca pode ser obtida em [86].

Calculando o Rating por Drill

O TrueSkill possui cinco parâmetros. Eles estão listados na Tabela 3.10. Parâmetro μ_0 determina o *rating* inicial de um atleta desconhecido pelo modelo. O parâmetro σ_0 representa a incerteza inicial associada ao *rating*. O parâmetro β , análoga ao ELO, representa a variabilidade no desempenho dos atletas. O parâmetro τ é o “K Factor dinâmico”. O valor τ impacta na estabilidade dos *ratings*. O último parâmetro, ϵ , modela o percentual de empates inerentes ao tipo de competição.

Foram utilizados os parâmetros do algoritmo sugeridos pelos autores, testada na base de jogos do XBOX com 650.00 jogadores [1]. A eficiência dos valores escolhidos foi confirmada por uma busca em *grid* nos parâmetros β e τ , usando os dados do

treino aberto. A figura de mérito utilizada foi a acurácia de cada configuração dos parâmetros. A acurácia foi medida comparando a estimativa do vencedor utilizando o modelo, com o resultado real da jogada. Esta estimativa foi obtida usando a Equação 3.8. Para $P(\text{ataque}) > 0,5$, foi estimado vitória da equipe de ataque. Nesta equação, os valores de μ e σ correspondem aos *ratings* para *quarterback*, *wide receiver* e *defensive back* participantes do *drill*.

Tabela 3.10: Valores padrão para o algoritmo TrueSkill.

Parâmetro	Valor Padrão
μ_0	25
σ_0	$\frac{25}{3}$
β	$\frac{\sigma_0}{2}$
τ	$\frac{\sigma_0}{100}$
ϵ	0, 1

$$P(\text{ataque}) = \Phi \left(\frac{\mu_{\text{qb}} + \mu_{\text{wr}} - \mu_{\text{db}}}{\sqrt{3\beta^2 + \sigma_{\text{qb}}^2 + \sigma_{\text{wr}}^2 + \sigma_{\text{db}}^2}} \right) \quad (3.8)$$

Após o cálculo dos parâmetros, os *ratings* de todos os atletas foram ajustados, usando toda a base de jogadas. O valor h_i foi usado como estimativa final da habilidade dos atletas (Equação 3.9) e corresponde ao limite inferior da estimativa de μ . Para serem reportados aos atletas, os *ratings* foram normalizados pelo *rating* h^* , do primeiro lugar (Equação 3.10). Isso assegurou uma distribuição de *ratings* no intervalo $[0, 1]$.

$$h_i = \mu_i - 3\sigma_i \quad (3.9)$$

$$\hat{h}_i = \frac{h_i}{h^*} \quad (3.10)$$

No caso do *ranking* gerado para o clube carioca, os *ratings* foram gerados para os cinco exercícios. A Equação 3.11 apresenta a fórmula que foi utilizada para sumarizar o *rating* dos atletas. O valor r_i é o *rating* do i -ésimo atleta, calculado como a média dos *ratings* normalizados \hat{h}_{ij} , ponderados pela quantidade de repetições n_{ij} que o atleta obteve no j -ésimo *drill*.

$$r_i = \frac{\sum_j n_{ij} \hat{h}_{ij}}{\sum_j n_{ij}} \quad (3.11)$$

Este capítulo apresentou o método proposto para treinar o comitê neural e como foram desenvolvidos os sistemas de treinamento aberto e privado. O próximo capítulo apresenta e discute os resultados.

Capítulo 4

Resultados

Esse capítulo apresenta os resultados do trabalho. A Seção 4.1 discute os resultados obtidos no treinamento das redes neurais especialistas. A Seção 4.2 apresenta os resultados do ranqueamento realizado no time carioca e a última seção discute os resultados para o treinamento aberto para atletas do Rio de Janeiro.

4.1 Rede Neural para Extração de Características

A base de dados utilizada para treinar o comitê neural contém 298 jogadas de passe e 233 jogadas de corrida. A Tabela 4.1 apresenta a distribuição por down. A Tabela 4.2 sumariza os resultados do primeiro round do treinamento Jackknife.

A Figura 4.1 apresenta o resultado da relevância e a correlação entre atributos e classe. Quarto de jogo, posição no campo e tempo foram identificado como os três atributos mais importantes para o primeiro *down*. Para o segundo *down*, distância para o *first down*, posição no campo e se a última jogada foi corrida ou passe, foram identificados como características importantes. Para o terceiro *down*, quarto, posição no campo e tempo de jogo foram identificados como os mais importantes. A Tabela 4.3 apresenta os valores da relevância, normalizados.

Após o cálculo da relevância, o segundo round de treinamento foi executado, eliminando os atributos com relevância menor que 0,2. A figura 4.2 apresenta o resultado de seleção dos neurônios para a segunda fase do treinamento.

Para o primeiro e segundo *down*, a eliminação dos atributos abaixo de 0,2 me-

Tabela 4.1: Número de jogadas, por down, separados em passe e corrida.

Tentativa	Passe	Corrida
Primeiro down	113	135
Segundo down	100	86
Terceiro down	85	12
Total	298	233

Tabela 4.2: Resultados para o primeiro round de jackknife, antes da remoção dos atributos usando a relevância normalizada. NE é o número de neurônios da camada oculta, μ é a taxa de acerto média, σ o valor RMS e Melhor é a acurácia da melhor rede encontrada pelo procedimento.

Tentativa	NE	μ (%)	σ (%)	Melhor(%)
1o down	20	61	6	71
2o down	9	67	6	78
3o down	8	94	5	97

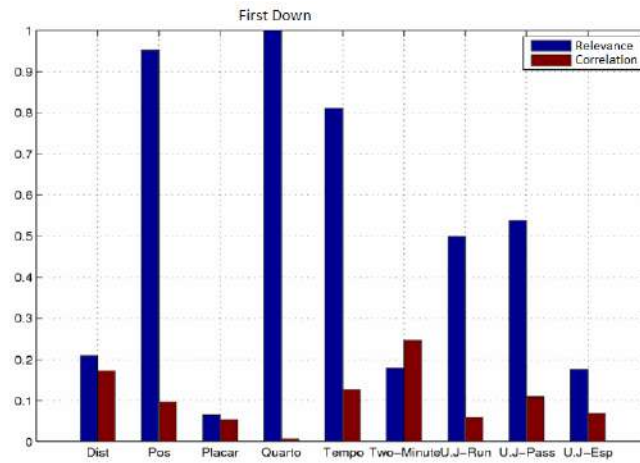
Tabela 4.3: Relevância normalizada calculada para os atributos. Estão destacados os atributos com relevância acima de 0,2.

Atributo	1D	2D	3D
Distância	21	76	52
Posição	95	75	98
Placar	6	34	41
Quarto	100	11	100
Tempo	81	15	63
2 Minutos	17	7	17
U.J. Corrida	49	82	4
U.J. Passe	53	100	31
U.J. Especial	17	-	-
U.J. Jardas	-	18	10

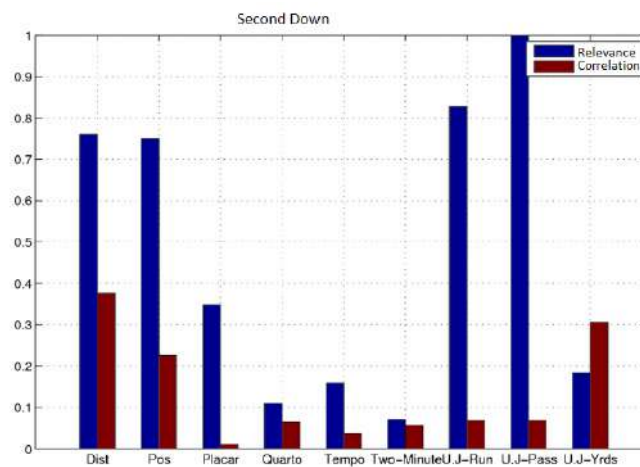
lhorou o resultado. A taxa de acerto do primeiro *down* aumentou e o número de neurônios na camada oculta diminuiu de 20 para 7, reduzindo a complexidade do modelo. O número de neurônios na camada oculta para o segundo *down* não mudou com o procedimento, mas a taxa de acerto aumentou de 67% para 73%. Para o terceiro *down*, a eliminação dos atributos não ajudou a melhorar o modelo, então todas as variáveis foram mantidas. A figura 4.3 mostra a convergência do treinamento para as melhores redes encontradas pelo jackknife. A tabela 4.4 sumariza os resultados finais.

Modelo	NE	μ (%)	σ (%)	Melhor (%)
NN-1D	7	61	5	74
NN-2D	9	73	5	81
NN-3D	8	94	5	97
NN	10	73	-	73
See5	-	69	-	69
ID3	-	64	-	64


Tabela 4.4: Comparação de resultados entre as redes *experts* por down (NN-1D, NN-2D, NN-3D), a rede neural [4] e duas árvores de decisão. NE é o número de neurônios na camada oculta, μ a taxa de acerto média, σ o valor RMS e Melhor para a acurácia da melhor rede encontrada pelo jackknife.



(a)

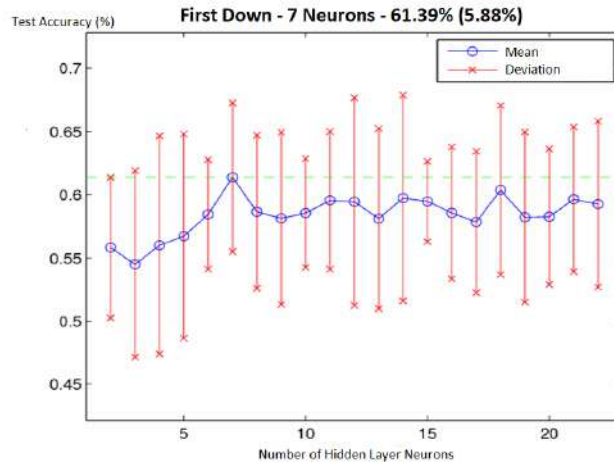


(b)

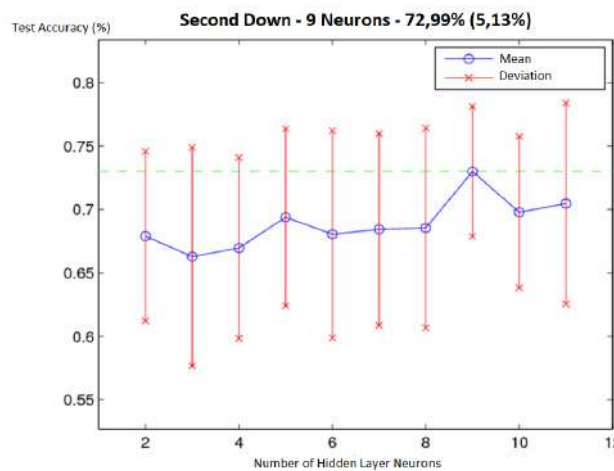


(c)

Figura 4.1: Relevância e correlação para cada rede expert.



(a)



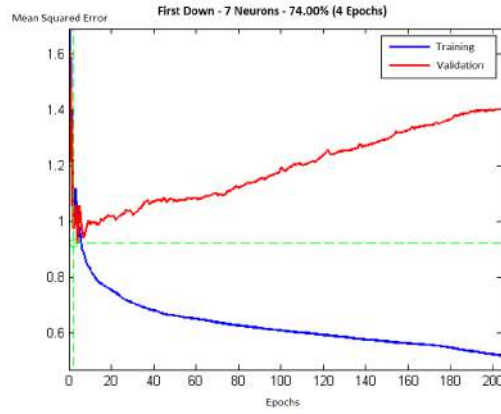
(b)

Figura 4.2: Resultados da segunda fase de treinamento para o número de neurônios na camada oculta para (a) primeiro down e (b) segundo down.

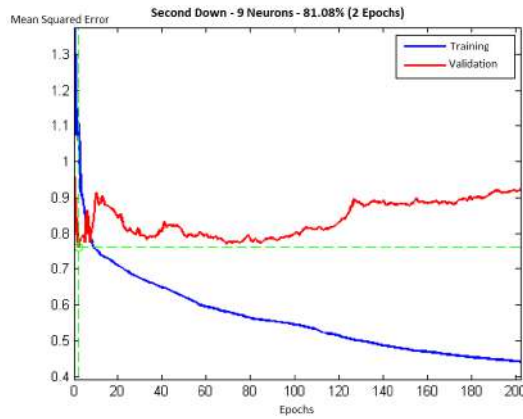
4.1.1 Discussão

A rede neural para o primeiro *down* teve a pior acurácia: no futebol americano, a escolha do primeiro *down* é a mais livre, pois ainda há duas tentativas para avançar. É esperado que os técnicos mantenham um balanço 50-50 entre corrida e passe, para manter a chamada de jogadas neste *down* sem vies. Análise de relevância mostrou que posição no campo e tempo de jogo são os critérios mais importantes para seleção de jogada neste *down*. Isso faz sentido para o segundo e quarto quartos, especialmente quando o time está “jogando contra o relógio” e precisa avançar muitas jardas em pouco tempo, forçando uma ênfase no jogo de passes. Uma análise mais profunda separando as redes por *down* e quarto, como sugerido por [75], pode identificar padrões mais específicos.

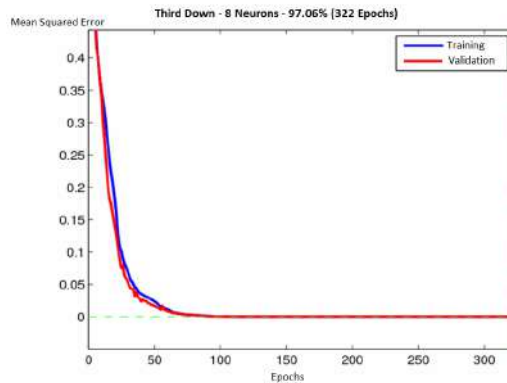
Para o segundo *down*, o desempenho obtido pelo classificador foi similar à implementação de [4] e, embora existisse um balanço aproximado de 50-50 entre corrida



(a)



(b)



(c)

Figura 4.3: Convergência do treinamento para a melhor rede expert: (a) primeiro (b) segundo e (c) terceiro down.

e passe, a taxa de acertos foi mais alta. Já que só existe uma única tentativa extra para ganhar jardas, dado que o quarto *down* costuma ser reservado para times especiais, a jogada deste *down* é mais dependente do que a do primeiro *down*. Isso foi confirmado pela relevância, que caiu significativamente para o tempo de jogo, mas aumentou a importância da distância para o *first down* e o que aconteceu na última jogada. Isso mostra que a jogada do segundo *down* depende do que aconteceu no

primeiro *down*. A diferença de relevância entre os dois *downs* mostra a capacidade do modelo em identificar características de jogo importantes, diferentes para cada *down*.

A rede neural para o terceiro *down* teve a maior acurácia, que já era esperado, já que a maior parte das jogadas deste *down* são passes. A análise de relevância identificou distância, posição e tempo como atributos relevantes. Pela perspectiva do jogo, isso faz sentido: com uma única tentativa remanescente, se a distância necessária é grande, o ataque é obrigado a executar um passe, dada a situação - posição no campo e tempo aumentando a necessidade de passar, se o time está perdendo. Para este *down*, todos os atributos foram mantidos, mesmo os com valor de relevância pequenos. A rede neural *expert* treinada com todos os atributos teve resultado melhor do que a treinada apenas com os atributos relevantes.

É importante destacar que a relevância identificou as relações que a correlação não indicaria. Isso destaca a influência de estatísticas de ordem superior nos dados de futebol americano: uma abordagem não-linear foi necessária para identificar a relação entre atributos e classe.

Do ponto de vista da classificação e da modelagem do *quarterback*, foi possível aumentar a acurácia da rede, treinando três classificadores ao invés de um. O resultado gerado pela combinação da melhor rede, por *down*, aplicado a todo o banco de dados, obteve uma taxa de acertos de 80%, ultrapassando os resultados obtidos por uma única rede, proposta em [4]. Isso foi possível por conta da especialização de cada rede, para os atributos relevantes identificados para cada *down*.

4.2 Ranqueamento de Atletas de um Clube do Rio de Janeiro

Durante a pré-temporada de 2017, o modelo de ranqueamento foi executado no treino de um clube carioca de primeira divisão, para todas as posições, utilizando o modelo de *rating* proposto. Em uma frequência mensal, os dados foram apresentados para o atleta.

Foram ranqueados 52 atletas, de fevereiro a junho, cobrindo o treinamento do time de base, continuando a temporada com o time principal. Alguns jogadores da base foram revelados pelo índice e foram selecionados para o time principal.

O índice de mano a mano foi integrado ao índice calculado para o atleta, correspondendo a 25% da nota final do atleta na pré-temporada e 15% durante a temporada. A Figura 4.4 é um exemplo do dashboard que foi gerado para a comissão técnica do clube carioca, uma vez por mês. Existem colunas para o *rating* dos atletas, obtidos em cada *drill* e normalizados. A coluna **SK** contém o resultado

combinado dos *ratings* individuais, ponderado pelo número de repetição em cada *drill*. A coluna **PV** contém o percentual de vitórias, e a coluna **#** contém o número de repetições.

Atleta	BIG CAT		MAN COVERAGE			PASS RUSH		TACKLEBOX		OKLAHOMA				TOTAL			
	AT	DEF	QB	WR	DB	OL	DL	RB	LB	BLK	HB	NT	TKL	SK	PV	#	Pontos
2			100%											100%	59%	110	15,0
1			98%											98%	57%	122	14,7
9				100%						70%				97%	79%	29	14,5
51					100%							65%	74%	96%	53%	45	14,4
22	82%					99%				90%				96%	73%	49	14,4
39		100%					100%					75%		96%	73%	30	14,4
23	65%					100%				55%				95%	74%	89	14,2
50		96%			94%							100%	78%	94%	56%	64	14,1
53					99%							26%	52%	89%	54%	35	13,4
26						89%								89%	73%	26	13,3

Figura 4.4: Exemplo do *Dashboard* enviado para a comissão técnica do clube carioca de primeira divisão, mensalmente, com os *ratings* calculados para os 52 atletas do plantel.

O índice obteve sucesso quanto à engajar os atletas no treinamento. A próxima Subseção apresenta um testemunho do técnico do clube sobre os resultados do índice.

4.2.1 Testemunho do Técnico

O Índice de Desenvolvimento foi um projeto pioneiro que contribuiu muito para a elevação do nível de competitividade e evolução dos atletas. O projeto piloto foi implantado ainda durante a pré-temporada de *rookies* (novatos). E foi replicado no time principal desde o primeiro treino. Os dados coletados ajudaram a comissão técnica a planejar treinos e priorizar determinados aspectos, cujos resultados se mostraram deficientes. O índice ajudou os *coaches* a tomarem decisões sobre quem escalar, com base em análises objetivas e estatísticas. E a divulgação periódica do *ranking* do índice promoveu uma competitividade maior do que nos anos anteriores, o que indiretamente fez os jogadores evoluírem física e tecnicamente. Além de ter gerado um maior comprometimento, com presença nos treinos, estudo de *playbook*, análise de vídeos e presença nas reuniões.

Apesar dos bons resultados, os objetivos do índice não foram plenamente alcançados devido às limitações de uma equipe amadora. Como a Comissão Técnica não é numerosa, não tínhamos um número suficiente de assistentes para fazer toda a coleta e processamento de dados necessários para gerar uma base de dados 100% confiável e eliminar possíveis distorções. Além disso, quando o campeonato começou, tivemos que desviar o foco para a análise de adversários e *game plan* e não conseguimos alimentar o índice da mesma forma que fizemos ao longo da pré-temporada.

Nossa comissão técnica também não foi capaz (por falta de tempo e recursos humanos) de avaliar todos os treinos filmados, para gerar as notas necessárias ao pleno funcionamento do índice. Dessa forma, entendemos que o índice é um projeto extremamente promissor. Mesmo com todas as limitações, colhemos bons frutos desse sistema no time. E acreditamos que, com mais recursos humanos e tempo, será possível ampliar e qualificar a base de dados. E dessa forma impactar ainda mais positivamente no plano de treinos, na avaliação dos atletas e na identificação de aspectos a serem melhorados, individual e coletivamente.

4.3 Ranqueamento Aberto de Atletas do Rio de Janeiro

Foram colhidos 4845 vídeos em 34 dias de treinamento, do início de 2017 à janeiro de 2018. Por dificuldades de agendamento de horário no campo, houve uma variabilidade grande na quantidade de atletas e jogadas, por treino. A Figura 4.5 apresenta a quantidade de jogadas por treino, que resultaram em vídeo coletado. A Figura 4.6 apresenta a quantidade de atletas distintos que treinaram por posição.




Figura 4.5: Vídeos coletados por treino e total acumulado, durante o ano de 2017.

Com base nos vídeos categorizados, é possível identificar as preferências dos jogadores do ataque e dos jogadores da defesa. A figura 4.7 mostra a distribuição das rotas escolhidas pelo ataque. A figura 4.8 relaciona a chance de escolha com o percentual de vitórias.




Figura 4.6: Série temporal com o número de atletas distintos, por posição, presentes no treino.

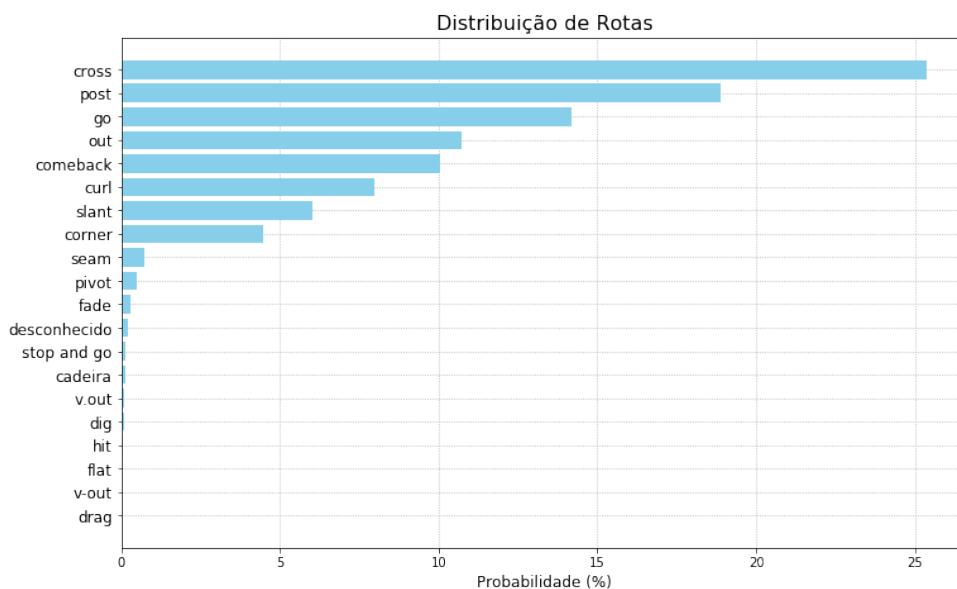


Figura 4.7: Principais rotas utilizadas pelos wide receivers ao longo do ano. Rota Cross em primeiro lugar com 26% das jogadas.




Figura 4.8: A rota Corner, embora sendo usada em apenas 4% das tentativas, possui o maior percentual de vitórias, igual à 49%. A Rota Go, uma das mais populares, possui o segundo pior resultado das rotas consideradas.

A figura 4.9 mostra a distribuição das coberturas escolhidas pela defesa. A figura 4.10 relaciona a chance de escolha com o percentual de vitórias.

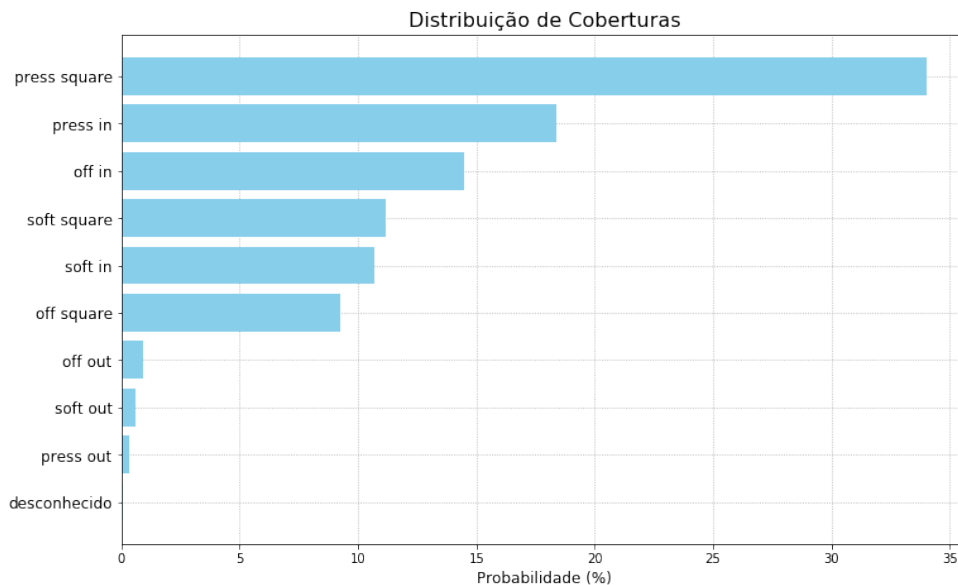


Figura 4.9: Principais coberturas usadas pelos defensores. Press Square liderando com 34% das jogadas.

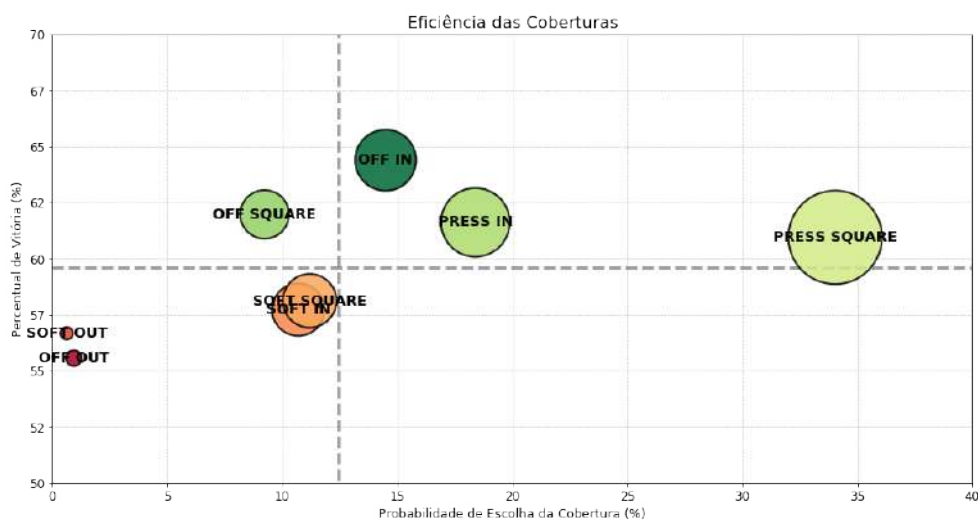


Figura 4.10: Off in apresentando o melhor resultado entre as coberturas utilizadas, com 64% de vitórias. Cobertura Soft identificada como ponto fraco comum dos atletas.

Estas análises permitem a identificação em larga escala de quais técnicas funcionam. Os técnicos podem aplicar exercícios para os setores, voltados a aprimorar os pontos fracos identificados.

4.3.1 Resultados do Ajuste do Modelo

O algoritmo TrueSkill foi utilizado para calcular o ranking dos atletas, baseado no resultado dos *drills*. Utilizou a busca descrita no capítulo 3 para confirmar a melhor configuração de parâmetros do modelo. A Figura 4.5 apresenta os resultados da busca e a tabela 4.5 os parâmetros encontrados para calcular os ratings.




Figura 4.11: Resultado do ajuste do algoritmo TrueSkill, ancorados em $\mu = 6$. Melhores valores para os parâmetros confirmados pela busca em grid, $\beta = 1$ e $\tau = 0,02$.

Parâmetro	Valor
μ_0	6
σ_0	2
β	1
τ	0,02

Tabela 4.5: Parâmetros para o algoritmo TrueSkill, encontrados pela busca.

Com os parâmetros selecionados, foi possível calcular o rating dos atletas para a base de dados de jogadas. As tabelas 4.6, 4.7 e 4.8 apresentam os cinco melhores atletas nas posições de *quarterback*, *wide receiver* e *defensive backs*. A coluna **N** é o número de repetições, **V** a quantidade de vitórias e **PV** o percentual de vitórias. As colunas μ , σ , h e \hat{h} são os parâmetros calculados para os atletas. Foram acentuados os melhores índices, por coluna.

Este resultado permite observar que, por ser um *drill* desbalanceado, onde o ataque tem dois jogadores e a defesa apenas um, o *rating* dos melhores *defensive backs* é próximo da soma dos *ratings* dos *quarterbacks* e *wide receivers*. Como

QB	N	V	PV	μ	σ	h	\hat{h}
DA	964	404	41%	2,6	0,2	2,0	100
TO	262	108	41%	2,5	0,2	1,9	93
SI	1322	589	44%	2,4	0,2	1,8	90
ED	94	19	20%	2,0	0,3	1,1	52
CA	36	7	19%	1,8	0,4	0,5	25

Tabela 4.6: Leaderboard de Quarterbacks.

WR	N	V	PV	μ	σ	h	\hat{h}
RU	700	375	53%	5,5	0,2	4,9	100
AN	625	276	44%	5,1	0,2	4,5	91
PH	649	248	38%	5,0	0,2	4,4	90
MA	352	144	40%	4,9	0,2	4,3	87
ME	80	27	33%	4,6	0,3	3,7	77

Tabela 4.7: Leaderboard de Wide Receivers.

DB	N	V	PV	μ	σ	h	\hat{h}
GO	942	661	70%	8,1	0,2	7,5	100
FF	63	50	79%	8,4	0,3	7,5	99
CO	270	172	63%	7,7	0,2	7,1	95
CL	67	42	62%	7,9	0,3	7,0	94
SL	610	357	58%	7,6	0,2	7,0	94

Tabela 4.8: Leaderboard de Defensive Backs.

a habilidade do time é a composição da habilidade dos atletas, naturalmente os *ratings* das posições acaba representando a influência da posição, no resultado do *drill*. Ou seja, o desempenho do *wide receiver* neste *drill* é mais importante para o resultado do que o desempenho do *quarterback*.

O ranking foi disponibilizado para os atletas em uma frequência semanal, sendo anunciado em uma página do *facebook* e por mensagem, em um grupo privado de celular. Os atletas tiveram a oportunidade de acompanhar sua evolução no *ranking*. As figuras 4.12, 4.13 e 4.14 apresentam a evolução do *rating* dos líderes das três posições, ao longo do tempo.




Figura 4.12: Evolução do *rating* dos *quarterbacks* ao longo do ano.

Também foi possível identificar pontos fortes e fracos dos atletas. As Figuras 4.15, 4.16 e 4.17 apresentam o Odds Ratio, por rota, para os líderes de cada posição.

Mais uma vez, o detalhamento permite aos técnicos aprofundar o conhecimento sobre cada um dos atletas. É possível personalizar cada vez mais a abordagem de treino para cada um.

4.3.2 Seleção de Equipe de Flag Football para amistoso

Em fevereiro de 2018, a equipe responsável pelo ranqueamento aberto foi convidada à convocar uma equipe para um amistoso de *Flag Football*. O *Flag* é uma modalidade do futebol americano sem contato físico. Os líderes do ranking de 2017 foram convocados para disputar o amistoso. Um dos atletas não pode participar, e foi substituído pelo sexto atleta do ranking de *defensive backs*. A equipe convocada




Figura 4.13: Evolução da habilidade dos wide receivers ao longo do ano.




Figura 4.14: Evolução da habilidade dos defensive backs ao longo do ano.

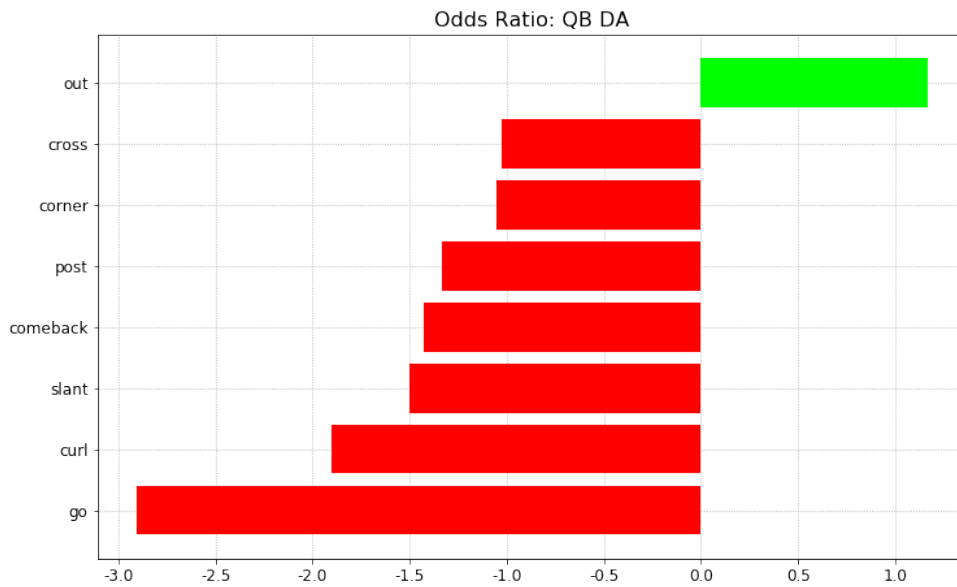


Figura 4.15: Odds Ratio das Rotas lançadas pelo quarterback DA. Melhor desempenho na rota Out e pior desempenho na rota Go. O desempenho do quarterback neste drill é diretamente influenciado pela qualidade do wide receiver.




Figura 4.16: Odds Ratio das rotas executadas pelo wide receiver RU. O atleta possui um arsenal de 5 rotas com percentual de vitórias maior do que 50%: out, comeback, corner, cross e post.




Figura 4.17: Com percentual de vitórias de 70%, o defensive back GO apresenta um percentual de vitórias maior do que 50% contra todas as principais rotas.

enfrentou o uma outra equipe de flag do Rio no evento, que ocorreu na Barra da Tijuca, no Rio de Janeiro.

Capítulo 5

Conclusão

Neste trabalho foram desenvolvidos modelos de apoio à decisão que buscaram sistematizar o uso de dados no desenvolvimento do futebol americano. Os modelos podem ser utilizados por técnicos brasileiros, ou por técnicos em países com nível de desenvolvimento esportivo similar. Também é possível replicar a abordagem para outros esportes, cuja natureza seja similar ao futebol americano, seja na forma particionada de treinar atletas, seja na dinâmica de escolha de jogadas baseada em situações do jogo.

Foi desenvolvido um sistema de ranqueamento para atletas de futebol americano, baseado em algoritmos de *rating*, aplicados a diferentes *drills*. As informações do *drill* de *man coverage* foram utilizados para ranquear os atletas do Rio de Janeiro, ao longo do ano de 2017, em um treino semanal no aterro do Flamengo. Mais de 4845 vídeos foram coletados ao longo do ano. Com os *ratings* coletados, um time de *flag football* foi selecionado para disputar um amistoso, sendo o projeto pioneiro em selecionar atletas baseados em dados, no futebol americano nacional. Os dados agregados permitiram identificar qualidades e fraquezas do conjunto de atletas, em larga escala, e apontar pontos fortes e fracos individuais dos atletas. Estas análises permitem aos técnicos individualizar o treinamento de cada atleta, auxiliando cada um a alcançar seu potencial.

Paralelo ao treino aberto de futebol americano, o sistema de *rating* foi implantado num clube carioca de primeira divisão, ao longo da temporada de 2017. O sistema abrangiu o treinamento de 52 atletas, com uma cobertura de 5 *drills*. Um indicador foi proposto, para combinar os *ratings* dos diferentes *drills*, de forma a gerar um único *rating* para o atleta. O ranqueamento foi gerado para o time mensalmente durante a pré-temporada. Além de estimular a competição no time, o sistema foi capaz de identificar jogadores novatos que se tornaram titulares ao longo do ano.

Outro modelo desenvolvido foi um comitê neural, treinado sobre dados de um time da NFL, para identificar as tendências associadas à seleção de corrida ou passe, por um time da elite do futebol americano. Os *insights* obtidos ajudam a entender

quais os principais fatores considerados por times desse nível para escolher jogadas. O método de treinamento da rede neural pode ser utilizado com o mesmo propósito para dados de outros times.

Algumas limitações podem ser listadas. Quanto ao ranqueamento, muitas vezes não foi possível agendar o horário do campo, nem todos os atletas puderam estar sempre presentes no treino, o que prejudicou a amostragem contínua de habilidade ao longo do tempo. Tentou-se implantar ao longo do ano mais de um drill no treino aberto, mas faltaram recursos de captura de vídeo e posterior classificação. Isso limitou o escopo de habilidades que pode ser medido para esses atletas.

No treino privado, não foi possível ajustar o algoritmo com especificidades diferentes para os outros 4 drills. O *big cat*, por exemplo, pode resultar em empate. Isso necessitaria de uma melhor configuração do parâmetro ϵ para o *drill*. Assegurar o ajuste do algoritmo para cada *drill* é fundamental, pois o *rating* agregado pode ser impactado por um valor calculado de maneira errônea.

O comitê de especialistas neurais poderia ter se beneficiado de uma maior coleta de dados. As informações de *play-by-play* foram coletadas manualmente. O trabalho foi bastante oneroso, e uma base de dados maior ajudaria a amostrar algumas situações com mais jogadas, como por exemplo, as jogadas de terceira descida.

5.1 Trabalhos Futuros

A inclusão de dados físicos dos atletas é fundamental para entender a relação entre o atletismo e o desempenho técnico. Como já apontado como uma das limitações experienciadas durante o trabalho, o escopo do treinamento aberto pode aumentar para que mais habilidades sejam mensuradas.

O algoritmo gaussiano de *rating* pode ser estendido, de maneira a modelar cada uma das técnicas escolhidas pelos atletas, como um μ_{ik} específico da k -ésima técnica. Isso ajudaria a decompor pontos fortes e fracos de maneira automática, pelo próprio algoritmo. Além disso, diferentes resultados dos *drills* podem ter pontuações diferentes, como por exemplo, uma interceptação de defesa valer mais do que simplesmente derrubar a bola, já que no jogo, a posse de bola seria tomada do adversário.

Com as habilidades mensuradas, é possível construir um algoritmo de otimização de conceitos, que selecione automaticamente os atletas para um determinado esquema tático preferido pela comissão técnica.

Os especialistas neurais podem ser evoluídos de diversas maneiras. O comitê pode ser ampliado para especializar ainda mais cada rede. Mais dados podem ser coletados, de mais características de jogadas.

O sistema de ranqueamento está sendo desenvolvido em parceria com uma startup chamada Eagle Scouting. O plano é expandir o sistema dentro dos times de

futebol americano do Brasil. Já está em negociação uma parceria com a federação brasileira, para que a empresa se torne fornecedora de dados oficial. O desdobramento comercial da utilização do *ranking* é mais um resultado significativo desta pesquisa.

Referências Bibliográficas

- [1] HERBRICH, R., GRAEPEL, T. *TrueSkill(TM): A Bayesian Skill Rating System*. Relatório Técnico MSR-TR-2006-80, Microsoft Research Ltd., 2006. Disponível em: <<http://research.microsoft.com/apps/pubs/default.aspx?id=74419>>.
- [2] “Stuff About Sports Football”. <http://thewaysofk.org/2015/01/stuff-about-sports-football/>, . [Online; acessado Mar-2018].
- [3] STEFANI, R. “The Methodology of Officially Recognized International Sports Rating Systems”, v. 7, 10 2011.
- [4] RODRIGUES, D. S. SEIXAS, J. “Football play prediction using neural networks”. In: *IX Brazilian Congress on Neural Networks*, Ouro Preto - MG, 2009. [In Portuguese].
- [5] FORBES. “Big Data: The Winning Formula in Sports”. <https://www.forbes.com/sites/bernardmarr/2015/03/25/big-data-the-winning-formula-in-sports/#1ca053a634de>, 2018. [Online; acessado Mai-2018].
- [6] “National Football League”. <http://www.nfl.com>, . [Online; acessado Mar-2018].
- [7] “NCAA Football”. <https://www.ncaa.com/sports/football>, 2018. [Online; acessado Mar-2018].
- [8] “2015 IFAF World Championship”. https://en.wikipedia.org/wiki/2015_IFAF_World_Championship, . [Online; acessado Mar-2018].
- [9] “ESPN relata crescimento de 800% na audiência de futebol americano”. <http://www1.folha.uol.com.br/esporte/2017/02/1855099-crescimento-do-interesse-por-futebol-americano-no-brasil-atrai-nfl.shtml>, . [Online; acessado Mar-2018].
- [10] “Brasil Futebol Americano”. <https://www.ligabfa.com/>, 2018. [Online; acessado Mar-2018].

- [11] “Confederação Brasileira de Futebol Americano”. <https://www.facebook.com/CBFA.oficial/>, 2018. [Online; acessado Mar-2018].
- [12] “Times de Futebol Americano do Brasil”. https://pt.wikipedia.org/wiki/Categoria:Times_de_futebol_americano_do_Brasil, . [Online; acessado Mar-2018].
- [13] “NFL Combine”. <http://www.nfl.com/combine>, . [Online; acessado Mar-2018].
- [14] “NFL Draft”. <http://www.nfl.com/draft>, . [Online; acessado Mar-2018].
- [15] “Pro Football Focus”. <http://www.profootballfocus.com>, . [Online; acessado Mar-2018].
- [16] “Pro Football Focus - Player Grades”. <https://www.profootballfocus.com/pff-player-grades>, . [Online; acessado Mar-2018].
- [17] “NFL Play-by-Play”. <http://www.nfl.com/teams/schedule?team=IND&season=2006&seasonType=REG>, 2006. [Online; acessado Mar-2018].
- [18] HAYKIN, S. *Neural Networks. A Comprehensive Foundation*. Prentice-Hall, Inc., 2008.
- [19] SEIXAS, J. M., CALÔBA, L. P., DELPINO, I. “Relevance Criteria for Variable Selection in Classifier Design”. In: *International Conference on Engineering Applications of Neural Networks*, pp. 451–454, London, England, 1996.
- [20] LEWIS, M. *Moneyball: The Art of Winning an Unfair Game*. Norton paperback. W.W. Norton, 2003. ISBN: 9780393057652. Disponível em: <https://books.google.com.br/books?id=RWOX_2eYPcAC>.
- [21] ELO, A. E. *The rating of chessplayers, past and present*. New York, Arco Pub., 1978. ISBN: 0668047216 9780668047210. Disponível em: <<http://www.amazon.com/Rating-Chess-Players-Past-Present/dp/0668047216>>.
- [22] GLICKMAN, M. *Pairwise comparison models with time varying parameters*. Tese de Doutorado, Harvard University, Cambridge, Massachusetts, 7 1993. An optional note.
- [23] “MSN Gaming Zone”. <http://zone.msn.com/en/support/article/ratings.htm>, . [Online; acessado Mar-2018].
- [24] “Go Ratings”. <http://gobase.org/>, 2005. [Online; acessado Mar-2018].

- [25] “Largest Overall Prize Pools in eSports”. <https://www.esportsearnings.com/tournaments>, 2005. [Online; acessado Mar-2018].
- [26] “Dota 2 Ranking Algorithm”. https://dota2.gamepedia.com/Matchmaking_Rating, 2005. [Online; acessado Mar-2018].
- [27] STEFANI, R. “Survey of the major world sports rating systems”, v. 24, pp. 635–646, 02 1997.
- [28] BRADLEY, R. A., TERRY, M. E. “Rank Analysis of Incomplete Block Designs: I. The Method of Paired Comparisons”, *Biometrika*, v. 39, n. 3/4, pp. 324–345, 1952. ISSN: 00063444. Disponível em: <<http://www.jstor.org/stable/2334029>>.
- [29] “ELO Rating System”. https://en.wikipedia.org/wiki/Elo_rating_system, . [Online; acessado Mar-2018].
- [30] GLICKMAN, M. E. “Parameter Estimation in Large Dynamic Paired Comparison Experiments”, *Journal of the Royal Statistical Society Series C*, v. 48, n. 3, pp. 377–394, 1999. Disponível em: <<https://EconPapers.repec.org/RePEc:bla:jorssc:v:48:y:1999:i:3:p:377-394>>.
- [31] COULOM, R. “Whole-History Rating: A Bayesian Rating System for Players of Time-Varying Strength”. In: van den Herik, H. J., Xu, X., Ma, Z., et al. (Eds.), *Computers and Games*, pp. 113–124, Berlin, Heidelberg, 2008. Springer Berlin Heidelberg. ISBN: 978-3-540-87608-3.
- [32] MASSEY, K. *Statistical Models Applied to the Rating of Sports Teams*. Relatório técnico, Bluefield College.
- [33] “Football and Basketball Predictions Using Least Squares”, *IEEE Transactions on Systems, Man, and Cybernetics*, v. 7, n. 2, pp. 117–121, Feb 1977. ISSN: 0018-9472. doi: 10.1109/TSMC.1977.4309667.
- [34] MOTEGI, S., MASUDA, N. “A network-based dynamical ranking system for competitive sports”, *Scientific Reports*, v. 2, 2012.
- [35] DANIEL, B., IAN, D., PETER, E., et al. “Ranking rankings: an empirical comparison of the predictive power of sports ranking methods”, *Journal of Quantitative Analysis in Sports*, v. 9, n. 2, pp. 187–202, June 2013. Disponível em: <<https://ideas.repec.org/a/bpj/jqsprt/v9y2013i2p187-202n7.html>>.

- [36] DANGAUTHIER, P., HERBRICH, R., MINKA, T., et al. “TrueSkill Through Time: Revisiting the History of Chess”. In: Platt, J. C., Koller, D., Singer, Y., et al. (Eds.), *Advances in Neural Information Processing Systems 20*, Curran Associates, Inc., pp. 337–344, 2008. Disponível em: <<http://papers.nips.cc/paper/3331-trueskill-through-time-revisiting-the-history-of-chess.pdf>>.
- [37] GLICKMAN, M., HENNESSY, J., BENT, A. *A comparison of rating systems for competitive women’s beach volleyball*. Relatório técnico, 2017.
- [38] S., M., COLLINS, K. “A Rating System For Gaelic Football Teams: Factors That Influence Success”, *International Journal of Computer Science in Sport*, v. 15, pp. 78–90, 2016.
- [39] DIXON, M. J., COLES, S. G. “Modelling Association Football Scores and Inefficiencies in the Football Betting Market”, *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, v. 46, n. 2, pp. 265–280, 1997. ISSN: 00359254, 14679876. Disponível em: <<http://www.jstor.org/stable/2986290>>.
- [40] “Basketball Power Index”. <http://espn.go.com/mens-college-basketball/bpi>, . [Online; acessado Mar-2018].
- [41] BOLTON, R. N., CHAPMAN, R. G. “Searching for Positive Returns at the Track: A Multinomial Logit Model for Handicapping Horse Races”, *Management Science*, v. 32, n. 8, pp. 1040–1060, 1986. doi: 10.1287/mnsc.32.8.1040. Disponível em: <<https://doi.org/10.1287/mnsc.32.8.1040>>.
- [42] AKHTAR, S., SCARF, P., RASOOL, Z. “Rating players in test match cricket”, *Journal of the Operational Research Society*, v. 66, n. 4, pp. 684–695, Apr 2015. ISSN: 1476-9360. doi: 10.1057/jors.2014.30. Disponível em: <<https://doi.org/10.1057/jors.2014.30>>.
- [43] RADICCHI, F. “Who Is the Best Player Ever? A Complex Network Analysis of the History of Professional Tennis”, *PLOS ONE*, v. 6, n. 2, pp. 1–7, 02 2011. doi: 10.1371/journal.pone.0017249. Disponível em: <<https://doi.org/10.1371/journal.pone.0017249>>.
- [44] ANN KOVALCHIK, S. “Searching for the GOAT of tennis win prediction”, v. 12, 01 2016.

- [45] BREZNIK, K. “Revealing the best doubles teams and players in tennis history”, *International Journal of Performance Analysis in Sport*, v. 15, n. 3, pp. 1213–1226, 2015. doi: 10.1080/24748668.2015.11868863. Disponível em: <<https://doi.org/10.1080/24748668.2015.11868863>>.
- [46] BIGSBY, K. G., OHLMANN, JEFFREY, W. “Ranking and prediction of collegiate wrestling”, *Journal of Sports Analytics*, v. 3, n. 1, pp. 1–19, 2017.
- [47] SAAVEDRA, S., POWERS, S., MCCOTTER, T., et al. “Mutually-Antagonistic Interactions in Baseball Networks”, .
- [48] CINTIA, P., COSCIA, M., PAPPALARDO, L. “The Haka Network: Evaluating Rugby Team Performance with Dynamic Graph Analysis”. In: *DyNo Workshop – ASONAM*, 2016.
- [49] CRIADO, R., GARCÍA, E., PEDROCHE, F., et al. “A new method for comparing rankings through complex networks: Model and analysis of competitiveness of major European soccer leagues”, *CoRR*, v. abs/1307.3412, 2013. Disponível em: <<http://arxiv.org/abs/1307.3412>>.
- [50] AGARWALLA, A., MANTRI, M., SINGH, V. “Hierarchical Ranking of Cricket Teams Incorporating Player Composition”. In: Shankar, B. U., Ghosh, K., Mandal, D. P., et al. (Eds.), *Pattern Recognition and Machine Intelligence*, pp. 633–638, Cham, 2017. Springer International Publishing. ISBN: 978-3-319-69900-4.
- [51] LASEK, J., SZLÁVIK, Z., GAGOLEWSKI, M., et al. “How to improve a team’s position in the FIFA ranking? A simulation study”, *Journal of Applied Statistics*, v. 43, n. 7, pp. 1349–1368, 2016. doi: 10.1080/02664763.2015.1100593. Disponível em: <<https://doi.org/10.1080/02664763.2015.1100593>>.
- [52] STEFANI, R., POLLARD, R. “Football Rating Systems for Top-Level Competition: A Critical Survey”, v. 3, pp. 3–3, 01 2007.
- [53] GOMES JÚNIOR, S., MELLO, J., ANGULO-MEZA, L. “Sequential use of ordinal multicriteria methods to obtain a ranking for the 2012 Summer Olympic Games”, v. 13, pp. 223–230, 04 2014.
- [54] “RAPS Rating”. <http://rapsrating.com/athletes/>, . [Online; acessado Mar-2018].

- [55] “SPARQ Ratings”. <http://www.topendsports.com/testing/sparq-rating-system.htm>, . [Online; acessado Mar-2018].
- [56] “Hudl”. <https://www.hudl.com/>, . [Online; acessado Mar-2018].
- [57] MARTINICH, J. “College Football Rankings: Do the Computers Know Best?” *Interfaces*, v. 32, n. 5, pp. 85–94, 2002. doi: 10.1287/inte.32.5.85.33. Disponível em: <<https://pubsonline.informs.org/doi/abs/10.1287/inte.32.5.85.33>>.
- [58] PARK, J., NEWMAN, M. E. J. “A network-based ranking system for US college football”, *Journal of Statistical Mechanics: Theory and Experiment*, v. 2005, n. 10, pp. P10014, 2005. Disponível em: <<http://stacks.iop.org/1742-5468/2005/i=10/a=P10014>>.
- [59] CALLAGHAN, T., MUCHA, P. J., PORTER, M. A. “The Bowl Championship Series: A Mathematical Review”, *Notices of the American Mathematical Society*, v. 51, pp. 887–893, 2004.
- [60] *Knowing what we don't know in NCAA Football ratings: Understanding and using structured uncertainty*, February 2014. MIT Press. Disponível em: <<http://research.microsoft.com/apps/pubs/default.aspx?id=217536>>.
- [61] SAWYER, D., OSTARELLO, J., SUESS, E., et al. “Relationship between football playing ability and selected performance measures”, *J Strength Cond Res*, v. 16, November 2002.
- [62] BLACK, W., ROUNDY, E. “Comparisons of Size, Strength, Speed, and Power in NCAA Division 1-A Football Players”, *Journal of Strength and Conditioning Research*, v. 8, pp. 80–85, 1994.
- [63] SCHMIDT, W. D. “Strength and Physiological Characteristics of NCAA Division III American Football Players”, *Journal of Strength and Conditioning Research*, v. 13, pp. 210–213, 1999.
- [64] “Advanced Football Analytics”. <http://www.advancedfootballanalytics.com>, 2018. [Online; acessado Mar-2018].
- [65] “Bayesian Draft Prediction Model”. <http://archive.advancedfootballanalytics.com/2014/04/bayesian-draft-prediction-model.html>, 2014. [Online; acessado Mar-2018].

- [66] R.J, A., C., F. “Real-time versus post-game GPS data in team sports”, *Journal of Science and Medicine in Sport*, v. 13, pp. 348–9, May 2010.
- [67] AGUIAR, M., BOTELHO, G., PEÑAS, C., et al. “A Review on the Effects of Soccer Small-Sided Games”, v. 33, pp. 103–13, 06 2012.
- [68] GAUDINO, P., IAIA, F., ALBERTI, G., et al. “Monitoring Training in Elite Soccer Players: Systematic Bias between Running Speed and Metabolic Power Data”, v. 34, 04 2013.
- [69] E.A., A., B.V., G., A.M., S., et al. “Classifying your soccer players by training performances”, *Perceptual and Motor Skills*, v. 119, pp. 971–984, December 2014.
- [70] ZHONG, D., FU CHANG, S. “Structure Analysis of Sports Video Using Domain Models”, *IEEE ICME*, pp. 22–25, 2001.
- [71] LAGO-BALLESTEROS, J., LAGO-PEÑAS, C. “Performance in Team Sports: Identifying the Keys to Success in Soccer”, *Journal of Human Kinetics*.
- [72] R., P. “Home advantage in soccer: a retrospective analysis”, *Journal of Sport Sciences*, v. 4, pp. 237–248, 1986.
- [73] PINES, J. MARZ, N. “Machine Learning in Football Play-Calling”. <http://www.stanford.edu/class/cs229/proj2005/PinesMarz-BeatCal.pdf>, 2005.
- [74] HEINY, ERIK L; BLEVINS, D. “Predicting the Atlanta Falcons Play-Calling Using Discriminant Analysis”, *Journal of Quantitative Analysis in Sports*, v. 7, 01 2011.
- [75] LEE, P., CHEN, R., LAKSHMAN, V. *Predicting Offensive Play Types in the National Football League*. Relatório técnico, University of Stanford, 2016.
- [76] BURTON, W., DICKEY, M. “NFL Play Predictions”. In: *JSM 2015*, Seattle, United States, 2015.
- [77] HAMILTON, A. B. “Assessing the Predictability of an NFL Offense”. In: *MIT Sloan Sports Analytics Conference*, 2016.
- [78] BORONICO, JESS S.; NEWBERT, S. L. “An empirically driven mathematical modelling analysis for play calling strategy in American football”, *European Sport Management Quarterly*, v. 1, 03 2001.

- [79] COMACHIO, J., RIETJENS, P., COMACHIO, G., et al. “Desempenho anaeróbio e características antropométricas de jogadores de futebol americano de uma equipe brasileira”, *Revista Brasileira de Prescrição e Fisiologia do Exercício*, v. 9, n. 51, 2015.
- [80] LEMOS, C. F. “Perfil Antropométrico e Somatotipológico de Jogadores de Futebol Americano”. In: *2o Congresso Internacional de Atividade Física, Nutrição e Saúde*, n. 1, 2016.
- [81] SEVERO-SILVEIRA, L., FRITSCH, C. G., MARQUES, V. B., et al. “Iso-kinetic Performance of Knee Flexor and Extensor Muscles in American Football Players from Brazil”, *Revista Brasileira de Cineantropometria e Desempenho Humano*, v. 19, pp. 426 – 435, 08 2017. ISSN: 1980-0037. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1980-00372017000400426&nrm=iso>.
- [82] RIEDMILLER, M. *Rprop - Description and Implementation Details*. Relatório técnico, University of Karlsruhe, January 1994.
- [83] DUDA, R. O., HART, P. E. *Pattern Classification*. 2nd ed. Corporate Headquarters, 111 River Street, John Wiley and Sons Inc, 2000.
- [84] “Computing your Skill”. <http://www.moserware.com/2010/03/computing-your-skill.html>, . [Online; acessado Mar-2018].
- [85] MINKA, T. *A family of algorithms for approximate Bayesian inference*. Tese de Doutorado, MIT, 2001.
- [86] “trueskill.org”. <http://trueskill.org/>, . [Online; acessado Mai-2018].
- [87] QUINLAN, J. R. “Induction of Decision Trees”, *Machine Learning*, v. 1, n. 1, pp. 81–106, 1986. ISSN: 0885-6125.
- [88] QUINLAN, J. R. *C4.5: Programs for Machine Learning*. San Francisco, CA, USA, Morgan Kaufmann Publishers Inc., 1993. ISBN: 1-55860-238-0.

Apêndice A

Futebol Americano

Neste capítulo serão dados detalhes do esporte necessários para contextualizar o esporte e permitir que o leitor aprenda o necessário para entender a metodologia de treinamento.

A.1 Campo

O futebol americano é um esporte disputado por duas equipes, cada uma com onze atletas em campo, em um campo retangular de 120 jardas de comprimento e 54 jardas de largura. O campo é composto de duas *endzones* com 10 jardas de comprimento. Duas traves em formato de “Y” estão posicionadas em cada *endzone*. A Figura A.1 ilustra o campo de futebol americano.




Figura A.1: Campo de futebol americano. A região verde escura nos dois lados representam as duas *endzones*.

A.2 Regras do Jogo

O esporte é disputado em dois tempos, divididos em quatro quartos de quinze minutos. As equipes possuem três tempos técnicos para cada tempo de jogo. Os dois últimos minutos de cada tempo apresentam uma dinâmica diferente do resto do tempo, e ao início deste período é dado o nome *two minute warning*. O número de substituições é ilimitado.

O objetivo do futebol americano é pontuar, marcando *touchdowns* ou *field goals*. Quando um dos times tem a posse de bola, seu objetivo é levá-la até a *endzone* do campo do adversário. Um jogador pode correr com a bola em mãos, atravessando a linha da *endzone* e marcando um *touchdown*, ou receber um passe, quando já dentro da *endzone*. Um *touchdown* vale seis pontos. O time que não tem a posse de bola tem a responsabilidade análoga de impedir o time de ataque adversário de avançar.

A qualquer momento a equipe ofensiva pode chutar um *field goal*. O campo conta com duas traves em forma de Y atrás das *endzones*. Caso o chute passe por dentro da trave, o ataque marca três pontos.

A partida tem início após a disputa do cara e coroa. O time vencedor pode escolher entre receber a bola, chutar a bola ou postergar sua escolha para o segundo tempo, oferecendo a escolha do primeiro tempo para o adversário. Após um dos times escolher chutar ou receber a bola, o outro escolhe o lado do campo que deseja iniciar a partida.

Escolhido quem chuta e quem recebe a bola, os times se posicionam em campo para o chute de início, chamado de *kick-off*. A bola é posicionada na linha de 20 jardas, do time que optou por chutar. Este time defenderá sua *endzone*, após o chute. A partida inicia-se com este chute de bola parada, para dar a posse de bola para o time de adversário, que recebe o chute próximo da sua própria *endzone* e tenta avançar o máximo possível. No ponto final desta jogada inicial - ponto onde o jogador que recebe a bola é derrubado ou sai de campo - é a linha de início da primeira jogada.

Um time de futebol americano tem sub-equipes especializadas para jogar quando tem a posse de bola e quando não tem. A equipe que está em campo quando o time tem a posse de bola é chamada equipe de ataque. A equipe responsável por impedir o avanço do ataque adversário, é a chamada equipe de defesa. Portanto, após a recepção da bola, se o retorno não culmina em um *touchdown*, a equipe de ataque assume a responsabilidade de avançar a bola, e a equipe de chute é substituída pela equipe de defesa.

Quando está em campo, a equipe de ataque tem quatro tentativas para caminhar dez jardas. Cada uma destas tentativas é chamada de *down*. Existem dois principais tipos de jogada. Nas jogadas de corrida, todos os dez jogadores da equipe de ataque

tentam bloquear os jogadores de defesa, abrindo espaço para o décimo primeiro jogador, que carrega a bola, avançar no campo. Nas jogadas de passe, uma fração dos jogadores impede que os jogadores de defesa alcancem e derrubem o *quarterback*, que é o jogador de ataque responsável por fazer os passes. O *quarterback* tenta fazer um passe para um dos outros jogadores de ataque aptos a receber a bola. Quando a equipe de ataque consegue avançar dez jardas no campo em menos de quatro tentativas, recebe mais quatro novas tentativas. Desta maneira, o time avança em campo.

O time de defesa reage às escolhas do time de ataque. Quando o ataque seleciona uma jogada de corrida, cabe a defesa impedir o avanço do jogador que está com a bola, empurrando os bloqueadores até que seja possível derrubar quem está carregando a bola. Quando o ataque seleciona uma jogada de passe, a defesa busca pressionar o *quarterback* com vários jogadores, para tirar sua concentração e derrubá-lo, enquanto marca os jogadores de ataque aptos a receber a bola com os jogadores de defesa disponíveis para marcação. O objetivo da defesa é impedir que o ataque avance dez jardas, forçando-o a devolver a posse de bola. Normalmente a quarta tentativa é uma jogada de troca de posse, onde entram em campo os times especiais: atletas especializados em jogadas de troca de posse.

Ambos os times contam com setores específicos para executar as diferentes funções no campo. Jogadores maiores são usados para abrir empurrar os jogadores de defesa e abrir espaço para as jogadas de corrida. Jogadores mais ágeis são utilizados para correr grandes distâncias e receber passes em profundidade no campo. Portanto cada um dos setores possui atletas com um biotipo específico, a executar fundamentos que cabem apenas à sua dinâmica de jogo. Isso possibilita a setorização do treinamento. A próxima Seção detalha os setores específicos do time de ataque e defesa, para embasar a escolha dos treinamentos específicos.

A.3 Setores de um Time de Futebol Americano

A figura A.2 contém todas as posições de ataque e defesa. Os círculos vermelhos correspondem à equipe de ataque. Os quadrados azuis correspondem a equipe de defesa. É possível distinguir três principais setores dos times de ataque e defesa, que se equiparam em força física e velocidade, e disputam embates específicos dentro de cada jogada. Nas próximas subseções serão descritos os setores existentes nos times de ataque e defesa.

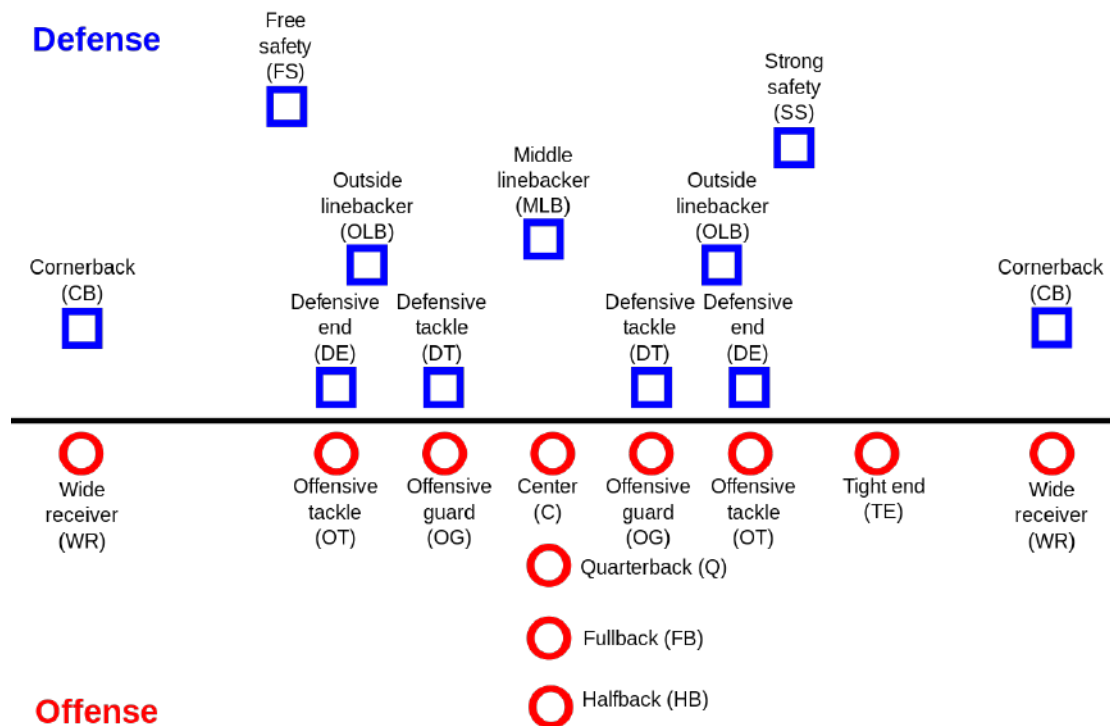


Figura A.2: Posições das equipes de ataque e defesa no futebol americano. Retirado de [2].

A.3.1 Time de Ataque

O time de ataque tem o objetivo de avançar o campo, através de escolher jogadas capazes de avançar a bola dez jardas, conquistando o *first down*, que é o novo conjunto de quatro tentativas. O time de ataque tem três principais setores.

Linha Ofensiva: composta por 5 jogadores, os *offensive tackles*, *guards* e o *center*, a linha ofensiva tem como principal responsabilidade empurrar os jogadores de defesa, abrindo passagens para os jogadores de ataque correrem e proteger o *quarterback* dos jogadores de defesa, nas jogadas de passe. Jogadores da linha ofensiva costumam pesar entre 110 e 160kg, dependendo da altura. Portanto, em cada jogada, o jogador da linha estará tentando deslocar um adversário igualmente grande para abrir espaço para a corrida ou proteger o seu *quarterback* da pressão dos adversários. Força, tração, velocidade, técnicas de bloqueio e condicionamento são os principais fundamentos dos jogadores das linhas.

Corredores: os *quarterbacks*, *running backs* e *fullbacks* iniciam a jogada posicionados atrás da linha, e são a ameaça de jogo corrido. O *quarterback* é o responsável por passar a bola, mas também é acionado para correr com ela muitas vezes. Esses jogadores precisam ser velozes e ágeis o suficiente para conquistar o maior número de jardas possível em poucos segundos, mas precisam ser fortes para aguentar os *tackles* dos defensores.

Recebedores: os *wide receivers* e *tight ends* são responsáveis por dar profun-

didade ao jogo do ataque, correndo em direção à endzone adversária. Isto obriga jogadores de defesa à acompanhá-los, facilitando o funcionamento do jogo corrido. Além disso, são os responsáveis por jogadas com o maior ganho de jardas, sendo fundamentais para o time de ataque pontuar. Esses jogadores precisam ser rápidos e ágeis, altos e pegar a bola em qualquer situação, com muita segurança.

A.3.2 Time de Defesa

O objetivo da equipe defensiva é impedir o avanço do ataque adversário, proteger a *endzone* e impedir que o adversário marque *field goals*. A equipe é composta de três setores análogos a equipe de ataque.

Linha Defensiva: os *defensive tackles* e *ends* são responsáveis por impedir o avanço do jogo corrido adversário nas jogadas de corrida e atacar o *quarterback* nas jogadas de passe. Tem o porte físico similar aos da linha de ataque, e precisam desenvolver as mesmas capacidades físicas deste setor.

Linebackers: o segundo nível da defesa é composto pelos *linebackers*, identificados pelas siglas OLB e MLB no diagrama da figura A.2. Estes costumam ser os jogadores mais atléticos da defesa. Nas jogadas de corrida, são responsáveis por ocupar os espaços que a linha de ataque tenta abrir e derrubar o *running back*, que é o jogador de ataque com maior costume de correr com a posse de bola. Nas jogadas de passe, são responsáveis por marcar passes curtos e impedir o *quarterback* de correr com a bola. Enquanto os principais fundamentos das linhas envolvem força, tração e bloqueio, os *linebackers* precisam ser mais ágeis para correr atrás dos *runnings back* e marcar os passes. Um *linebacker* costuma pesar entre 95kg e 115kg.

Secundária: o terceiro nível da defesa é composto pelos jogadores da secundária (*corner backs* e *safeties*). Este são os jogadores mais velozes da equipe, e são os responsáveis por marcar os *wide receivers* e *tight ends*. Na maior parte das jogadas, os *defensive backs* estarão marcando passes, seja em cobertura individual, ou distribuídos em diversas zonas pelo campo. Costumam ter participação no jogo corrido quando o adversário busca a lateral do campo.

Ficam evidentes os três principais tipos de confronto que ocorrem em cada jogada e as principais habilidades envolvidas.

- Linhas: bloqueio, tração, força física, abertura de gaps.
- *Running Backs* e *Linebackers*: Movimentação, preenchimento de *gaps*, *tackle*, cobertura de passes.
- *Wide Receivers* e *Defensive Backs*: Execução e cobertura de passes. Velocidade, agilidade, troca de direção, recepção de passes.

Essa diferença de fundamentos e habilidades determina quais são os exercícios escolhidos para mensurar a habilidade de cada jogador. A relação entre os exercícios e os setores foi descrita no Capítulo 3.

Apêndice B

Trabalhos Publicados

Este apêndice visa mostrar a produção de artigos científicos durante o período de desenvolvimento da tese.

- Trabalhos em periódicos

- Trabalhos Submetidos

1. RODRIGUES, D. S; J. M. Seixas. Supporting American Football development in amateur level countries through neural network play prediction models. JOURNAL OF SPORTS SCIENCES, 2018. Abstract: American football is played mostly in the United States. In Brazil and other countries belonging to the International Federation of American Football (IFAF), the sport is growing, but coaching staff is still mostly on amateur level. This paper presents the usage of an artificial neural network to predict whether a team will run or pass. Expert neural networks were fitted to a high level team's data. Fitting the model to a professional team's play choice is a way to understand what are the main trends considered by a high level team while choosing its plays, and may be seen as a good target for amateur-level players. With the expert networks trained to guess run or pass, a normalized relevance mapping was applied to identify which attributes are the most relevant for deciding pass/run. The success rate for the network trained for the first down attempt was 61%, for the second down it was 72%, and for the third, 94%. This sort of analysis supports amateur-level coaches in their decisions in order to improve offensive and defensive results.

- Trabalhos em Submissão

1. RODRIGUES, D. S; J. M. Seixas. Applying a bayesian ranking model for rating american football athletes. 2018.