

ESCOLA DE GUERRA NAVAL

CC (FN) Raphael Augusto da Silva Nunes Soransso

POSSIBILIDADES DE UTILIZAÇÃO DO APRENDIZADO DE MÁQUINA NO
SUPORTE À DECISÃO EM JOGOS DE GUERRA

Rio de Janeiro

2021

CC (FN) Raphael Augusto da Silva Nunes Soransso

POSSIBILIDADES DE UTILIZAÇÃO DO APRENDIZADO DE MÁQUINA NO
SUPORTE À DECISÃO EM JOGOS DE GUERRA

Monografia apresentada à Escola de Guerra
Naval, como requisito parcial para a
conclusão do Curso Superior.

Orientador(a): CMG (RM1) Marcelo
William Monteiro da Silva

Rio de Janeiro
Escola de Guerra Naval

2021

AGRADECIMENTOS

A Deus, pela criação da vida.

Aos meus pais e agregados, pela educação e pelo exemplo de trabalho e dedicação.

À minha esposa Renata, pela paciência, suporte e companheirismo.

Ao CMG (RM1-IM) Marcelo William Monteiro da Silva, pela dedicação, disponibilidade e clareza com que me orientou no desenvolvimento deste trabalho.

Aos Instrutores do Curso Superior - C-Sup 2021 da Escola de Guerra Naval, por todos os ensinamentos transmitidos.

A todos os militares do EPSD-CFN que contribuíram no andamento das tarefas diárias, de forma que eu pudesse me dedicar melhor ao C-Sup.

Aos colegas do C-Sup 2021 pelo companheirismo e determinação para superarmos esta etapa de nossas carreiras.

Enfim, agradeço a todos, que direta ou indiretamente, contribuíram para a realização deste trabalho.

RESUMO

Os Jogos de Guerra são uma importante ferramenta de apoio na avaliação de capacidades, no exercício e no aprimoramento do processo decisório dos comandantes e líderes nos diversos níveis de comando nas quais seus processos sofrem influência significativa da evolução tecnológica. A evolução das técnicas de Aprendizado de Máquina(AM) possibilitam seu emprego em diversas áreas de negócio, tendo ampla aplicação também no aprimoramento dos processos que envolvem os Jogos de Guerra. Diante desse contexto, o presente estudo tem como objetivo apresentar algumas aplicações do Aprendizado de Máquina no suporte à decisão em Jogos de Guerra nos níveis operacionais e táticos, para o Ministério da Defesa (MD). Para embasamento do estudo, foi realizado uma pesquisa exploratória acerca de estudos que envolvem os Jogos de Guerra e o AM. Para alcançar o objetivo do presente estudo foi usado como exemplo a sua aplicação em Jogos de Guerra que simulem um Assalto Anfíbio, na qual foi demonstrado diversas aplicações no suporte à decisão a este tipo de operação, permitindo que seja vislumbrado o seu emprego também em outras operações do MD.

Palavras-chave: Jogos de Guerra. Aprendizado de Máquina. Processo Decisório. Assalto Anfíbio.

LISTA DE ABREVIATURAS E SIGLAS

AcdtCap - Acidentes Capitais

AEA - Adequabilidade, Exequibilidade e Aceitabilidade

ApSvCmb - Apoio e Serviço ao Combate

AM - Aprendizado de Máquina

Adbq - Área de Desembarque

AOp - Área de Operações

AssAnf - Assalto Anfíbio

CP - Cabeça de Praia

ComForDbq - Comandante da Força de Desembarque

ComForTarAnf - Comandante da Força Tarefa Anfíbia

CiaFuzNav - Companhia de Fuzileiros Navais

CPC - Comparação de Poderes Combatentes

CCT - Componente de Combate Terrestre

COpT - Conceito da Operação em Terra

EGN - Escola de Guerra Naval

ForDbq - Força de Desembarque

ForTarAnf - Força Tarefa Anfíbia

GptOpFuzNav - Grupamento Operativo de Fuzileiros Navais

GRUCON - Grupo de Controle

IA - Inteligência Artificial

JG - Jogo de Guerra

LA - Linha de Ação

Ldbq - Linhas de Desembarque

MB - Marinha do Brasil

MD - Ministério da Defesa

MMA - Mixed Martial Arts

MNT - Movimento Navio para Terra

OpAnf - Operação Anfíbia

PI - Possibilidades do Inimigo

PPM - Processo de Planejamento Militar

VA - Vias de Acesso

SUMÁRIO

1	INTRODUÇÃO.....	9
2	REFERENCIAL TEÓRICO	11
2.1	Jogos de Guerra	11
2.1.1	Fases de um Jogo de Guerra.....	13
2.2	Operação Anfíbia.....	14
2.2.1	Assalto Anfíbio.....	15
2.2.1.1	O Planejamento de um Assalto Anfíbio.....	16
2.2.1.2	A Execução de um Assalto Anfíbio.....	17
2.3	Aprendizado de Máquina.....	19
2.3.1	Conceitos básicos do Aprendizado de Máquina.....	20
2.3.1.1	Aprendizado de Máquina Supervisionado.....	20
2.3.1.2	Aprendizado de Máquina Não-Supervisionado.....	21
2.3.1.3	Outras Formas de Aprendizado.....	21
2.3.2	Tipos de Algoritmos de Aprendizado de Máquina.....	22
2.3.2.1	Regressão Linear.....	22
2.3.2.2	Regressão Logística.....	23
2.3.2.3	Naive Bayes.....	24
2.3.2.4	Máquina de Vetores de Suporte.....	24
2.3.2.5	Árvore de Decisão.....	24
2.3.2.6	Floresta Randômica.....	24
2.3.2.7	K-Vizinho mais próximo.....	25
2.3.2.8	K-Means.....	25
2.3.2.9	Redes Neurais.....	25
2.3.3	Técnicas de melhoria do desempenho dos algoritmos de Aprendizado de Máquina.....	26
2.3.3.1	A técnica comitê de Aprendizado de Máquina.....	26
2.3.3.2	A técnica Auto-Aprendizado.....	26
3	APLICAÇÃO DO APRENDIZADO DE MÁQUINA NOS JOGOS DE GUERRA QUE SIMULEM UM ASSALTO ANFÍBIO.....	27
3.1	Aplicações na Fase do Planejamento.....	27
3.1.1	Seleção de Praias de Desembarque.....	27
3.1.2	Objetivos da Força Tarefa Anfíbia(ForTarAnf) e da ForDbq.....	29

3.1.3	Conceito da Operação em Terra.....	29
3.1.3.1	Levantamento das características área de operações.....	30
3.1.3.2	Comparação de Poderes Combatentes.....	31
3.1.3.3	Linhas de Ação.....	32
3.1.4	Zonas de Desembarque e Zonas de Lançamento.....	33
3.2	Aplicações na Fase da Execução.....	34
4	CONCLUSÃO.....	37
	REFERÊNCIAS	39
	ANEXO.....	42

1 INTRODUÇÃO

Os jogos de guerra são uma importante ferramenta de apoio na avaliação de capacidades, no exercício e no aprimoramento do processo decisório dos comandantes e líderes nos diversos níveis de comando, de forma a simular situações mais aderentes à realidade e, assim, prepará-los para as decisões inerentes ao emprego de meios em combate.

O Processo de Planejamento Militar (PPM) de um Assalto Anfíbio (AssAnf) exige o levantamento e a análise de uma série de informações que em conjunto permitirão os comandantes decidirem qual Linha de Ação (LA) permitirá cumprir a sua missão da melhor forma possível.

Além de informações a respeito da Área de Operações (AOp) e do Inimigo, o processo decisório dos comandantes levará em consideração a aceitabilidade de cada LA e, normalmente, esta aceitabilidade será avaliada a partir dos riscos identificados caso a LA seja empregada.

Segundo Brasil (2018), a avaliação de danos ou das perdas de um Jogo de Guerra (JG), quando este não possui um suporte de sistemas de informação, depende sempre da experiência humana e do conjunto de informações a respeito do jogo, como as características dos meios e de seu poder combatente. Além disso outro aspecto que deve ser considerado para avaliação dos resultados de um jogo é a imprevisibilidade e a incerteza dos combates.

Com a evolução da tecnologia e o surgimento de inúmeras aplicações da inteligência artificial, uma técnica que vem sendo utilizada por diversas áreas para aperfeiçoar os seus processos decisórios é o “aprendizado de máquina” (*machine learning*) que, segundo Facelli (2011, p. 2), consiste na “indução de uma hipótese (ou aproximação de função) a partir da experiência passada”.

Atualmente, existem inúmeros estudos que demonstram como o Aprendizado de Máquina (AM) pode ser utilizado para melhorar diferentes tipos de processos. O trabalho de Miranda (2011) apresenta como o AM pode ser utilizado no reconhecimento de objetos em imagens, já o trabalho de Mangialardo (2011) teve como objetivo demonstrar como o AM pode ser utilizado na classificação de *malwares*.

Na atualidade os JG podem contar com ferramentas computacionais que podem cooperar no seu acompanhamento, bem como na simulação das situações de combate, permitindo que os jogadores analisem as suas decisões a partir de resultados gerados por essas

ferramentas. Entretanto, no contexto atual do Ministério da Defesa(MD), existe uma carência de estudos que apresentem as possibilidades de aplicação de técnicas de AM no suporte à decisão nos JG nos níveis operacionais e táticos.

Nesse sentido, este estudo tem por objetivo apresentar algumas aplicações do AM no suporte à decisão em JG nos níveis operacionais e táticos, para o MD.

Para tanto, devido à variedade de tipo de operações que o MD pode realizar, será utilizada como modelo de aplicação do AM em operações do MD, a sua aplicação em Jogos de Guerra que simulem um Assalto Anfíbio.

Como objetivos secundários constam:

a) Identificar os métodos e as técnicas de aprendizado de máquina que podem ser aplicados nos processos decisórios nas diversas etapas do planejamento e da execução de Jogos de Guerra que simulem um Assalto Anfíbio;

b) Identificar que tipo de predição é possível extrair a partir da aplicação do aprendizado de máquina nas etapas de um Jogo de Guerra que simulem um Assalto Anfíbio; e

c) Identificar de que forma as predições podem contribuir para o suporte à decisão nos diversos níveis decisórios representados num Jogo de Guerra.

A metodologia utilizada engloba a realização de pesquisa bibliográfica e documental. Para a condução da pesquisa bibliográfica e documental foi utilizada o *Google Acadêmico* e a Biblioteca virtual da Escola de Guerra Naval, como também foram utilizados trabalhos referenciados naqueles encontrados, onde o número de citações de trabalhos na área de AM confirma a relevância desta área de estudo.

Dessa forma, foi possível obter diversas de fontes bibliográficas e documentais, no qual foi possível apresentar a aplicação de diferentes técnicas de AM no suporte à decisão em duas etapas dos Jogos de Guerra que simulam um Assalto Anfíbio de forma semelhante ao demonstrado nas referências.

Neste trabalho, será apresentada a aplicação do AM na obtenção de informações que darão suporte à decisão dos comandantes nos escalões operacionais e táticos. Contudo, a aplicação do AM nos Jogos de Guerra de qualquer tipo ou modalidade de operação, não se limita à obtenção das informações apresentadas neste trabalho. Entretanto, este trabalho buscou mostrar o quanto o AM pode favorecer no suporte à decisão e estimular a Marinha do Brasil(MB) e o MD a investigar a aplicação desta ferramenta nas diversas operações militares.

Além da presente introdução, este trabalho está estruturado em mais três outros capítulos. No segundo é apresentado e discutido o referencial teórico, em que são abordados os conceitos a respeito dos Jogos de Guerra, Aprendizado de Máquina e Assalto Anfíbio e que servem como seu alicerce. A aplicação do AM em algumas atividades dos JG que simulam o AssAnf é discutida no terceiro capítulo. Por fim, este trabalho se encerra no quarto capítulo com a conclusão acerca da pesquisa em tela, destacando as contribuições e os principais resultados obtidos pelo presente trabalho.

2 REFERENCIAL TEÓRICO

Neste capítulo serão apresentados os conhecimentos básicos para a compreensão do problema de pesquisa. Inicialmente, será explicado os Jogos de Guerra e suas peculiaridades. Posteriormente, serão elucidados os principais aspectos do Assalto Anfíbio que podem ser explorados nos Jogos de Guerra e favorecidos pelo AM. Por fim, será apresentado o conceito de Aprendizado de Máquina e as principais técnicas que podem ser utilizadas por esta ferramenta da IA.

2.1 Jogos de Guerra

Segundo Burns(2015), Jogo de Guerra consiste em uma ferramenta para explorar as possibilidades decisórias em ambientes com informações imprecisas e incompletas, cuja possibilidade de observar situações novas e antecipar ações proporcionam um ganho adicional aos participantes e decisores.

De acordo com Curry e Perla (2012), “Jogo de Guerra” é uma simulação (ou modelagem) de guerra, na qual não há o emprego de meios reais, cujos eventos influenciam e são influenciados pelas decisões dos participantes (jogadores).

“No âmbito da Escola de Guerra Naval (EGN), Jogo de Guerra (JG) é definido como um conjunto de situações fictícias ou não, caracterizadas por conflito de interesses e apresentadas cronologicamente aos jogadores na forma de desafios, cuja superação implica no emprego simulado da expressão Militar do Poder Nacional, condicionado por aspectos ambientais, sócio-culturais e conjunturais”. (BRASIL, 2018, p. 1-9).

Segundo Brasil (2018), os JG possibilitam testar diferentes soluções para os problemas abordados, sem o risco de perdas materiais e de vidas humanas e sem alterar o

cotidiano das instituições envolvidas. Proporcionam uma redução significativa de recursos quando comparados com exercícios de adestramento no terreno que visem a exercitar a capacidade decisória dos Comandantes, avaliar possibilidades do inimigo e desenvolver novas táticas e estratégias (utilizando ou não novos meios). Além de servirem como excelentes ferramentas para a prática do trabalho em grupo (interações dentro do Estado-Maior do Comandante), possibilitam, como já dito, a identificação de situações não visualizadas anteriormente e de eventuais falhas de planejamento ou deficiência em termos de recursos (capacidades) disponíveis para fazer-se frente a um determinado cenário.

Entretanto, conforme Brasil(2018), os JG possuem algumas limitações, tais como a dificuldade em simular o cansaço físico e psicológico dos combatentes, a possibilidade dos participantes omitirem ou desconsiderarem fatos relevantes no decorrer das simulações, o que pode levar a obtenção de resultados sem aderência à realidade e, ainda, um possível despreparo para “raciocinar-se como o Inimigo”, em virtude de diferenças culturais entre as Forças em oposição ou de dados de Inteligência insuficientes ou desatualizados.

Segundo Brasil(2018), com o intuito de facilitar a identificação das particularidades e peculiaridades de cada JG, estes podem ser classificados de acordo com o nível decisório dos jogadores como Político, Estratégico, Operacional, Tático ou a combinação dos anteriores. A classificação quanto ao nível decisório dos JG corresponde ao nível de decisão desejado pelos jogadores, ou seja, decisões no nível político, estratégico, operacional, tático, ou a combinação desses.

Segundo a metodologia os JG também pode ser classificados como Sistêmico, Seminário e Híbrido. Um JG é Sistêmico quando a principal ferramenta de apoio é baseada em um Sistema Computacional de Simulação, Seminário quando não utiliza essa ferramenta e Híbrido quando parte do JG é apoiado por esta ferramenta.

De acordo com Burns(2015) o tempo nos jogos de guerra podem transcorrer em diferentes velocidades (“marchas do tempo”), entretanto devem permitir que haja tempo suficiente para as discussões, planejamento e avaliação das decisões. Além disso, podem existir momentos em que seja necessário darem-se “saltos no tempo”, pulando-se períodos onde ocorrerão eventos de pouca relevância e promovendo a otimização do período de tempo alocado para a atividade, tendo sempre como “farol” os objetivos do jogo.

O deslocamento de uma força terrestre, por exemplo, pode levar dias; caso o objetivo do jogo seja somente avaliar o confronto entre duas forças terrestres, o tempo

decorrido do deslocamento pode ser suprimido do jogo (sem deixar de computar os aspectos logísticos decorrentes daquele deslocamento).

Diversos recursos podem ser utilizados pelos avaliadores dos JG, conhecidos na Marinha do Brasil como Grupo de Controle (GRUCON), a fim de acompanhar o andamento dos jogos sem perda dos aspectos mais relevantes das ações. Tais recursos podem variar desde um simples tabuleiro a computadores munidos ou não de inteligência artificial (BRASIL, 2018).

Conforme Brasil(2018), quando um JG tem como propósito analisar e aprimorar uma ideia de manobra, este é um jogo dito como Analítico. Por outro lado, quando o propósito é promover e consolidar o aprendizado, este é classificado como Didático. Dependendo do propósito do jogo, alguns aspectos receberão uma abordagem diferente, como, por exemplo, o rigor dos resultados das interações entre meios/Forças e o número de partidos utilizados na simulação do combate.

Em um jogo Analítico, os resultados deverão ser mais rigorosos, buscando-se a maior aderência possível com a realidade (ainda que tratando-se de uma “modelagem”). Enquanto que, em um jogo didático, os resultados das interações serão mais flexíveis, podendo (se não devendo) ser ajustados de forma a proporcionarem as melhores condições para o atingimento dos objetivos educacionais estabelecidos (sem, é claro, desviarem-se demais da “realidade”).

2.1.1 Fases de um Jogo de Guerra

Os Jogos de Guerra, de acordo com Brasil(2018), são compostos por 06 (seis) fases: Especificação, Montagem, Teste e Validação, Planejamento, Execução e Análise e Avaliação.

Em cada uma dessas fases são realizadas diferentes atividades, nas quais aspectos distintos devem ser observados, de forma que esses aspectos são influenciados diretamente pelo propósito do jogo e os objetivos estabelecidos. Caso o JG seja de propósito Analítico, haverá questões a serem investigadas e respondidas, as quais constituirão os objetivos daquele jogo. Por outro lado, no caso dos JG Didáticos os objetivos serão norteados pelas disciplinas ou processos que estão sendo abordados com vistas ao aprendizado.

A Fase de Especificação consiste em definir o propósito do jogo, seus participantes, objetivos, o nível decisório dos jogadores, uma ideia de cronograma de

atividades e o esboço da situação/cenário; além de outros dos elementos essenciais citados no item 2.1 deste capítulo.

A Fase de Montagem é caracterizada pela preparação do jogo, na qual serão definidos os recursos das expressões do Poder Nacional que poderão ser empregados pelos Jogadores para a solução do problema apresentado (BRASIL, 2018), a preparação do ambiente computacional que apoiará a simulação, se for o caso, e a designação dos membros componentes do GRUCON.

Na Fase de Teste e Validação ocorre uma execução simplificada do jogo, de forma a testar procedimentos e processos, funcionamento das estruturas de apoio e recursos de TI, além de verificar se o jogo montado possibilitará o atingimento dos objetivos definidos e se os dados disponíveis para os Jogadores e os elementos essenciais idealizados, estão adequados para as Fases de Planejamento e de Execução do Jogo.

Por ocasião da Fase de Planejamento, inicia-se a participação efetiva dos Jogadores no JG, quando ocorrerá o planejamento para a solução do problema abordado, caso não se tenha um plano já pronto. Nesta fase ocorrem as primeiras interações entre Jogadores e GRUCON, o qual já poderá gerar novos incentivos e atualizações da situação (de jogo) vigente, tornando a atividade mais dinâmica e retratando de forma mais fidedigna a realidade.

Segundo Brasil(2018, p. 3-5), “a Fase de Execução consiste, basicamente, na simulação da execução dos Planos elaborados pelos Jogadores na fase anterior, ou do Plano ou procedimentos que se deseja testar ou exercitar”. Ao final desta fase pode ser realizada uma reunião de crítica na qual os juízes “apresentarão suas observações aos Jogadores, no que diz respeito às decisões tomadas e aos procedimentos adotados para fazer frente aos desafios apresentados” (BRASIL,2018, p. 3-6).

Na fase de Análise e Avaliação, por ocasião da Análise, serão expostos os aspectos relacionados ao processo de condução do jogo, como por exemplo, se os Objetivos do Jogo de Guerra foram atendidos e se a situação apresentada foi capaz de motivar os jogadores. Já a Avaliação do JG consiste em identificar o quanto o jogo pode contribuir para o aprendizado ou para aprimoramento da doutrina, bem como se os ensinamentos terão aplicabilidade. (BRASIL,2018).

2.2 Operação Anfíbia

Operação Anfibia (OpAnf) é uma Operação Naval na qual se pretende ocupar parcela de uma região terrestre, a partir de um ataque vindo do mar, com o intuito de cumprir tarefas específicas em terra. Essa região terrestre pode ser uma região ocupada ou não pelo inimigo. (BRASIL, 2020).

A MB divide a Operação Anfibia em cinco modalidades: Assalto Anfíbio, Demonstração Anfibia, Incursão Anfibia, Projeção Anfibia e Retirada Anfibia (BRASIL, 2020). Neste trabalho será apresentado como o aprendizado de máquina pode contribuir no processo decisório somente na modalidade AssAnf nas fases de Planejamento e Assalto, portanto neste capítulo não serão apresentadas as peculiaridades das demais modalidades de OpAnf, nem das demais fases do AssAnf.

As OpAnf acima citadas possuem cinco fases: Planejamento, Embarque, Ensaio, Travessia e Assalto. Devido ao objetivo que se quer cumprir e à necessidade de realizar a OpAnf em um curto espaço de tempo, a sequência das fases pode ser alterada, podendo até haver a necessidade de suprimir alguma das fases.

A fase de Planejamento consiste na fase em que são levantados os dados para a realização da operação, o estudo desses dados e a definição de como a OpAnf será realizada, o tamanho das forças componentes, qual modalidade de OpAnf será realizada, entre outras definições. Apesar de a fase de Planejamento ser a primeira de uma OpAnf, o planejamento propriamente dito ainda terá continuidade nas demais fases.

O Assalto corresponde a fase na qual a Força de Desembarque (ForDbq) é projetada em terra. Esta fase inicia quando os navios chegam na Área de Desembarque (ADbq) e termina após o cumprimento da missão do Comandante da Força Tarefa Anfibia (ComForTarAnf).

Após o Assalto, pode ser necessário o emprego das forças em terra em operações subsequentes, entretanto essas operações não fazem parte da OpAnf. Caso isto ocorra, deve ser considerada a possibilidade de manter os meios navais na Área de Operações de forma a fornecer o apoio logístico necessário para as operações subsequentes.

2.2.1 Assalto Anfíbio

Segundo Brasil (2020), Assalto Anfíbio é um ataque lançado do mar para estabelecer uma Força de Desembarque em terra por meio de um desembarque, podendo ocorrer em um litoral defendido ou não pelo inimigo.

Para que seja possível a realização de um Assalto Anfíbio é necessária a existência de algumas condições. Entre essas condições, a existência da surpresa é um fator preponderante para que o inimigo disperse as suas forças e demore para receber reforços no local escolhido para o desembarque da ForDbq.

Os meios em um Assalto anfíbio devem possuir tecnologia suficientes para permitir a realização do Movimento Navio para Terra (MNT) a distâncias que garantam a segurança dos meios navais, mas que ainda possam manter a surpresa e ainda assim possam prosseguir em terra em combates mais profundos.

Em um Assalto Anfíbio, devido à grande desvantagem da força atacante, em partir de um valor de combate zero, é necessário que esta possua um valor substancialmente superior à força defensiva, além da condição indispensável de se ter a superioridade aérea.

Outros fatores que podem influenciar na execução de um Assalto Anfíbio são as condições hidrográficas e meteorológicas e o conhecimento que se tem sobre o inimigo e a área de operações.

2.2.1.1 O Planejamento de um Assalto Anfíbio

O Assalto Anfíbio é a modalidade de Operação Anfíbia mais completa, portanto para o planejamento de um Assalto Anfíbio é necessário um estudo minucioso do terreno, do inimigo, das condições climáticas e diversos outros aspectos que podem influenciar na sua execução.

Durante o planejamento de um Assalto Anfíbio são elencadas as “Decisões Fundamentais” que consistem nos aspectos fundamentais que permitirão a sua execução. Dentre as Decisões Fundamentais podemos citar as Áreas de Desembarque, as Praias de Desembarque, os Objetivos da ForTarAnf e do ForDbq, a Missão do ComForDbq, as Linhas de Desembarque (Ldbq), o limite da CP, o Conceito da Operação em Terra, as Zonas de Desembarque e Zonas de Lançamento e a Data e Hora do desembarque (Dia-D e Hora-H) (BRASIL, 2020).

Além disso outros dados serão levantados, como a força necessária para fazer frente a força oponente, os meios necessários para se atingir os objetivos, o período da operação e até mesmo a viabilidade da realização de um Assalto Anfíbio.

O Planejamento de um Assalto Anfíbio segue o Processo de Planejamento Militar (PPM) que possui três etapas, Exame da Situação, Desenvolvimento do Plano de Ação e

Elaboração da Diretiva e Controle da Ação Planejada (BRASIL, 2006), podendo ainda dividi-lo em preliminar e detalhado.

O Planejamento Preliminar de um Assalto Anfíbio ocorre por ocasião do Exame da Situação. Esta etapa é dividida em cinco fases, nas quais são levantadas as principais informações que darão suporte para a decisão do Comandante. Parcela dessas informações serão exploradas mais à frente nesse trabalho, onde mostraremos como essas poderão ser favorecidas pelo aprendizado de máquina. Entre essas informações podemos citar a identificação dos Objetivos Principais e Eventuais da missão, o levantamento da característica da Área de Operações e a Comparação de Poderes Combatentes.

Ao final do Exame da Situação são levantadas as Possibilidades do Inimigo (PI) e as possíveis Linhas de Ação (LA) que poderão fazer frente a essas PI. Uma das principais contribuições deste trabalho é mostrar como o aprendizado de máquina pode ser utilizado para facilitar esta última atividade.

No Desenvolvimento do Plano de Ação, o Comandante prepara a execução da operação, detalhando tudo aquilo que foi levantado no Exame da Situação (BRASIL, 2006), entretanto é nesta etapa que é realizado o planejamento detalhado de um Assalto Anfíbio.

O planejamento de um Assalto Anfíbio é contínuo, ou seja, este terá continuidade em cada uma de suas fases seguintes, entretanto, pode-se afirmar que a partir da fase de Embarque dos meios é iniciada a etapa do PPM chamada de Controle da Ação Planejada.

Nessa Etapa “o Comandante verifica se as operações estão sendo executadas conforme o planejado. Caso necessário, ele introduz as correções para assegurar o cumprimento de sua Missão” (BRASIL, 2006, p. 3-1).

Na fase de Planejamento de um Assalto Anfíbio também ocorre o planejamento do Embarque, do Ensaio e do MNT, de forma que estes permitam o cumprimento do Conceito da Operação (COp).

2.2.1.2 A Execução de um Assalto Anfíbio

A fase de Execução de um Assalto Anfíbio conhecida como Assalto, consiste basicamente no MNT e nas ações em terra e é dividida em seis etapas, preparação final da ADbq, MNT, desembarque dos elementos de assalto, ações em terra para conquista da CP, operação de junção, desembarque de outros elementos da ForDbq para a execução de tarefas

que possibilitem o prosseguimento das ações e provisão dos apoios logístico, aéreo e de fogo naval (BRASIL, 2020).

A preparação final da ADbq consiste da etapa na qual são realizadas as ações que permitem a aproximação e o desdobramento da ForTarAnf. Entre essas ações podemos citar a Varredura de minas, as Operações do Grupo de Reconhecimento e Demolição Submarina, a Divisão da Área Marítima da Área de Desembarque, as Operações aéreas, o Apoio de Fogo Naval e de Artilharia caso seja possível o seu desembarque em ilhas e promontórios.

O MNT consiste no deslocamento das tropas, meios e equipamentos a partir dos navios para as praias de desembarque, em uma ordem planejada de forma que possibilite o cumprimento da ideia de manobra em terra. Este deslocamento poderá ser realizado tanto por navios quanto por helicópteros (BRASIL, 2020).

A etapa de desembarque dos elementos de assalto consiste naquela em que os elementos de combate buscam conquistar os Objetivos Iniciais, de forma a permitir o prosseguimento das ações em terra. No momento inicial do desembarque a tropa em terra se encontra desorganizada taticamente, devido às limitações dos meios de desembarque. À medida que os objetivos iniciais são conquistados e o restante da tropa vai desembarcando, a ForDbq vai se organizando taticamente.

Esta etapa do Assalto Anfíbio é a mais crítica, pois será o momento na qual a ForDbq partirá de um poder de combate em terra zero e poderá se defrontar com um inimigo que esteja defendendo a praia fortemente.

Dependendo dos objetivos, das características do terreno e da organização do inimigo, parcela da força combatente pode ser desembarcada por helicópteros, de forma a conquistar os objetivos mais interiorizados, permitindo uma tomada mais rápida da CP e impedir em um curto espaço de tempo o reforço das tropas inimigas no seu interior.

Após a tomada dos objetivos iniciais é iniciada a etapa das ações em terra para a conquista da CP. Nesta etapa são realizadas as ações que permitirão o cumprimento da missão do ForDbq, normalmente caracterizada pela tomada da CP.

Para o cumprimento dessa missão o Componente de Combate Terrestre poderá contar com o apoio dos meios de engenharia, fogo naval, artilharia e de blindados, de forma a possuírem o máximo de mobilidade para a realização de suas tarefas e aumentar o seu poder de combate.

No final desta etapa o Componente de Combate Terrestre(CCT) já estará taticamente organizado e poderá prosseguir nas ações em terra realizando ataques coordenados. Portanto, os comandantes de diversos escalões poderão decidir diferentes formas de realizar as suas ações, conforme a situação de combate se desenvolva.

Um Assalto anfíbio se encerra quando a missão do ComForTarAnf é cumprida e a Força de Desembarque é estabelecida firmemente em terra ou quando a missão se torna inexecutável. Em um Assalto Anfíbio o firme estabelecimento da ForDbq é concretizado quando a Cabeça de Praia(CP) estiver segura, as forças em terra forem suficiente para permitir um desembarque contínuo das tropas e seja possível o exercício do comando e controle com os meios desembarcados.

2.3 Aprendizado de Máquina

Segundo Faceli(2011), Aprendizado de Máquina consiste na capacidade de uma máquina induzir hipóteses a partir da experiência anterior. Ou seja, um computador ou uma máquina, a partir de dados de experiências passadas é capaz de construir conhecimento e deduzir algum fato quando este utiliza o AM como uma de suas ferramentas.

O Aprendizado de Máquina também é um ramo da IA, porém diferente de outras técnicas de IA, o AM não necessita de uma pessoa especialista para resolver um determinado problema. A partir de um banco de dados de informações a respeito de um determinado assunto, os sistemas que usam Aprendizado de Máquina adquirem conhecimento e podem inferir funções ou regras que fornecerão uma solução para algum problema específico.

Sistemas Especialistas ou Sistemas Baseados em Conhecimento, são programas que usam técnicas de IA que dependem do conhecimento de algum especialista em determinado assunto, de forma que esses sistemas usam a lógica extraída dos especialistas para resolver um determinado problema. De forma genérica, pode-se afirmar que esses tipos de sistemas usam algoritmos da forma “Se, Então” (“If, Then”).

Apesar da capacidade dos Sistemas Especialistas, o uso do Aprendizado de Máquina vem sendo adotado cada vez mais, devido principalmente à necessidade de tratar um número de variáveis incontáveis, bem como ao surgimento de novos problemas a serem resolvidos, que demandariam um esforço muito grande caso os sistemas especialistas fossem utilizados.

Para melhor entendimento acerca das potenciais aplicações do AM, podemos tomar como exemplo a classificação dos *Malwares* de computador. Segundo Grimes (2018), existem oito tipos de *Malwares*, cada um com características diferentes. A cada dia, novos *Malwares* de computador são criados, de forma a burlar os antivírus existentes. Caso o novo *Malware* possua alguma característica diferente, um sistema especialista não será capaz de categorizar o tipo de *Malware*, a não ser que seja criada uma nova lógica para o novo tipo de *Malware*.

Entretanto, um antivírus que utiliza um algoritmo de Aprendizado de Máquina para classificar os *Malwares* não terá esse problema, pois ele será capaz de deduzir a partir da experiência anterior e de características semelhantes de outros *Malwares* qual a classificação do novo *Malware* ou até sugerir uma nova classificação caso as características sejam muito afastadas dos *Malwares* de classificação conhecida.

Na atualidade, existem inúmeras aplicações que podem utilizar o aprendizado de máquina, podendo citar como exemplo, o seu uso no reconhecimento de fala, na detecção de fraudes de cartão de crédito, na automatização de automóveis, na inteligência artificial de jogos como o xadrez e o gamão e na ajuda no diagnóstico do câncer, por meio da análise de dados de expressão gênica (FACELI, 2011).

Apesar dos algoritmos de aprendizagem de máquina já existirem há algumas décadas (FACELI, 2011), são incontáveis os campos de atuação em que o Aprendizado de Máquina pode ser usado que ainda não foram explorados, principalmente na área militar.

2.3.1 Conceitos básicos do Aprendizado de Máquina

Segundo Rocha(2020), o Aprendizado de máquina pode ser dividido em três categorias diferentes: Aprendizado Supervisionado, Não-Supervisionado e outras formas de aprendizado.

2.3.1.1 Aprendizado de Máquina Supervisionado

O Aprendizado de Máquina Supervisionado é aquele na qual, a partir de um conjunto de dados de entrada é gerada uma saída com um rótulo. O rótulo de saída pode ser tanto uma classificação quanto um valor numérico. Para facilitar o entendimento, utilizaremos como exemplo o trabalho de Silva(2015), que utilizou algoritmos de AM Supervisionados na predição de resultados de lutas de *Mixed Martial Arts*(MMA).

Naquele trabalho foram utilizados como dados de entrada as seguintes características de cada lutador: idade, percentual de vitórias, número de vitórias nas últimas cinco lutas, altura, peso, número de vitórias/derrotas (subdivididos em: por decisão, por decisão dividida, por decisão unânime, por nocaute, e por finalização), total de vitórias/derrotas, total de vitórias/derrotas nas últimas cinco lutas, percentual de vitórias contra o adversário, percentual de vitórias contra adversários comuns.

Assim sendo, no total foram utilizados 102 campos de entradas de dados, tendo como saída, somente um campo, o vencedor da luta.

Para o aprendizado de máquina foram utilizadas amostras de 32.878 lutas, na qual foram realizados testes na predição de 6.290 lutas, obtendo uma acurácia de aproximadamente 66% ao se utilizar um algoritmo de Regressão Logística.

No exemplo citado, todos os dados de entrada são dados contínuos, ou seja, possuem um valor gradativo, como a altura e o peso, entretanto, valores descritivos podem ser usados como parâmetros nos algoritmos de AM. Apesar de não haver um atributo sexo no conjunto de dados do exemplo apresentado, caso no futuro venha a acontecer lutas entre lutadores de sexo diferentes, este atributo que é um mero valor descritivo do sexo, pode ser utilizado como um atributo para a predição do resultado de lutas de MMA.

Ou seja, em um AM Supervisionado, a partir de uma amostra relevante de dados, cuja saída possua um rótulo validado é possível obter um rótulo para novas amostras.

2.3.1.2 Aprendizado de Máquina Não-Supervisionado

O AM Não-Supervisionado consiste naquele em que as amostras não possuem um rótulo de saída, porém são agrupadas conforme a proximidade das suas características, portanto, não se sabe ou não foi definido qual o domínio do resultado do conjunto de dados.

Na figura 1 do Anexo, podemos observar um exemplo de aplicação do AM Não-Supervisionado utilizado no trabalho de Rocha (2020), na qual as diferentes pétalas foram agrupadas conforme a proximidade de suas características, porém não havia uma nomenclatura prévia para as espécies de pétalas de características semelhantes.

Portanto, após a aplicação do AM Não-Supervisionado e o agrupamento de pétalas com características semelhantes, foi possível notar semelhanças entre algumas delas e definir aquelas que pertenciam à mesma espécie. Sendo possível então nomeá-las e classificá-las acordo com as suas espécies.

2.3.1.3 Outras Formas de Aprendizado

Além do AM Supervisionado e Não-Supervisionado, existem outras formas de Aprendizado de Máquina.

O AM Semi-Supervisionado é aquele na qual somente parte do conjunto de dados possui um rótulo ou se classificam conforme uma classificação pré-existente, podendo haver parcela do conjunto de dados que não possui classificação, por possuírem características muito distantes dos dados que possuem um rótulo.

Outro tipo de AM conhecido é o Aprendizado por Reforço. Neste tipo de AM, o agente melhora o seu desempenho por meio de tentativa e erro; sendo “recompensado” quando o desempenho é melhorado ou recebendo uma “punição”, caso seu desempenho seja piorado.

2.3.2 Tipos de Algoritmos de Aprendizado de Máquina

Normalmente cada tipo de algoritmo de AM é criado para solucionar um tipo limitado de problemas e um problema, quando é possível utilizar o AM na sua solução, poderá ser solucionado por mais de um tipo de algoritmo de AM. Isso ocorre pelo fato de existir uma grande variedade de algoritmos de AM com finalidades similares. Apesar disso, é habitual que esses algoritmos tenham eficiências distintas em diferentes problemas.

No trabalho de Silva (2015) por exemplo, o algoritmo de Regressão Logística teve uma maior acurácia que o Floresta Randômica (*Random Forest*) na predição de resultados de lutas de MMA, já no trabalho de Mangialardo (2015), o algoritmo Floresta Randômica obteve uma acurácia melhor do que o algoritmo C5.0 na classificação de *Malwares*.

Neste trabalho, descreveremos de forma resumida apenas alguns tipos de algoritmos de AM, com o intuito de demonstrarmos que existem algumas diferenças entre eles, pois a descrição de todos os algoritmos existentes na atualidade tornaria este trabalho demasiadamente extenso.

2.3.2.1 Regressão Linear

Segundo Rehbein(2020) Regressão Linear é uma técnica de Aprendizado de Máquina na qual é possível prever resultados quantitativos a partir de um conjunto de dados

de treinamento. A Regressão Linear simples possui somente uma variável de entrada e uma de saída, por isso sua função normalmente é uma linha reta como podemos observar na figura 2 do Anexo.

Já a Regressão Múltipla possui mais de uma variável de entrada e somente uma de saída. A equação 2.1 apresenta a definição de Regressão Múltipla, na qual α representa a constante, β_n representa o peso de cada variável, x_n o valor de cada variável e e_n os erros previstos.

$$Y_1 = \alpha + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \dots + e_n \quad (2.1)$$

2.3.2.2 Regressão Logística

A técnica de Regressão Logística é utilizada para prever a ocorrência ou não de um fato, dado um conjunto de variáveis de entrada. De acordo com Moraes (2012, p. 7) “a regressão logística tem por objetivo encontrar um modelo explicativo para o comportamento da probabilidade de sucesso, em termos das variáveis preditoras”.

A figura 3 do Anexo apresenta um modelo de função utilizada pela técnica de Regressão Logística.

2.3.2.3 Naive Bayes

O método Naive Bayes é considerado como um método “ingênuo” por considerar as variáveis que caracterizam o objeto a ser classificado como sendo independentes entre si. Este método tem a finalidade de deduzir que um evento ocorrerá baseado na probabilidade de ocorrência de um outro evento. Segundo Barros(2019), é um dos algoritmos de Aprendizado de Máquina mais utilizado, por ser simples e possuir uma boa capacidade preditiva.

Neste método é levada em consideração a probabilidade de ocorrência de cada uma das variáveis que caracterizam o objeto a ser classificado, tomando como base a frequência de ocorrência de um evento, dentro do número de amostras do conjunto de treinamento.

Como o método é baseado no teorema de Bayes, o cálculo da probabilidade de ocorrência de uma classificação pode ser feita a partir da fórmula abaixo:

$$P(y_i | x) = (P(x | y_i) * P(y_i)) / P(x)$$

Ao final do algoritmo o objeto receberá a classificação da classe que tiver uma maior probabilidade.

A figura 4 do Anexo representa um exemplo de classificação baseado no método Naive Bayes, nas quais os objetos da cor azul representam aqueles que receberão uma classificação específica.

2.3.2.4 Máquina de Vetores de Suporte

O Algoritmo Máquina de Vetores de Suporte, conhecido como algoritmo *SVM*, utiliza para a classificação de objetos a possibilidade de separar os objetos utilizando hiperplanos, na qual cada conjunto de objetos separados pelos hiperplanos será classificado em uma classe diferente. Não havendo um plano que separe as classes, uma função pode ser utilizada para separar os objetos das diferentes classes.

De acordo com Marinelo (2012) as instâncias posicionadas próximo às fronteiras críticas de cada classe são utilizadas para obter as funções que permitem separar as classes.

A figura 5 do Anexo representa um modelo de classificação utilizando Máquina de Vetores de Suporte, onde os objetos separados em cada lado do hiperplano receberão uma classificação diferente.

2.3.2.5 Árvore de Decisão

Como o próprio nome já diz, este método utiliza estruturas de árvores de decisão para classificar os objetos. Uma estrutura de árvore de decisão possui diversos nós e arcos. Para cada nó é realizado um teste do tipo “Se, Então” e um caminho é percorrido até o nó subsequente. Tal processo se repete sucessivamente até chegarmos a uma “folha da árvore”, a qual corresponderá a uma determinada classificação. As árvores de decisão, cujo exemplo pode ser visualizado na figura 6 do Anexo, são montadas a partir do conjunto de treinamento.

2.3.2.6 Floresta Randômica

De acordo com Carvalho(2014), este método utiliza um comitê de classificadores que utilizam árvores de decisão. Cada árvore de decisão é gerada a partir da seleção randômica de um conjunto de características. A classificação final de cada instância é obtida a partir da contagem de votos obtida a partir da classificação de cada árvore de decisão gerada.

A figura 7 do Anexo representa um exemplo de classificador que utiliza o algoritmo Floresta Randômica.

2.3.2.7 K-Vizinho mais próximo

Este método seleciona os k-objetos mais próximos à instância que se deseja classificar para inferir a sua classificação (CARVALHO, 2014). Ainda segundo Carvalho(2014), este algoritmo é muito utilizado quando o número de instâncias é muito grande, sendo muito eficiente para esses casos, porém o seu algoritmo é lento. Nesse método o peso dado para todas as características preditoras é igual, o que faz com que esse algoritmo seja descartado para algumas classificações onde certas características possuem maior preponderância sobre as outras.

A figura 8 do Anexo apresenta um modelo de classificação utilizando o método “K-Vizinho mais próximo”, onde os objetos próximos à bola verde receberão a mesma classificação desse objeto.

2.3.2.8 K-Means

Segundo Sousa (2020) o algoritmo K-Means é um algoritmo de aprendizagem de máquina não-supervisionado muito utilizado para tarefas de mineração de dados, que possibilita agrupar as instâncias em k agrupamentos diferentes, na qual as instâncias dentro de cada agrupamento possuem características semelhantes.

A figura 9 do Anexo representa um exemplo de agrupamento realizado por um algoritmo k-Means, nas quais os objetos mais próximos entre si poderão receber a mesma classificação.

2.3.2.9 Redes Neurais

Redes Neurais Artificiais são algoritmos que tentam simular o funcionamento do cérebro humano, utilizando uma sequência de nós de processamento na qual cada nó representa um neurônio (CARVALHO, 2014). Este tipo de algoritmo pode ser utilizado tanto para modelos supervisionados, quanto para não supervisionados, possuindo uma alta eficiência tanto em problemas lineares, quanto em problemas não-lineares.

“As Redes Neurais Artificiais são recomendadas para bases de dados que contenham muito ruído, ou seja, cujo conjunto de dados de treinamento apresente muitas inconsistências. Estas inconsistências

podem afetar severamente o modelo gerado por outros algoritmos de Aprendizado Supervisionado como Árvores de Decisão, mas os algoritmos de Redes Neurais Artificiais conseguem ser relativamente “imunes” a este ruído” (CARVALHO, 2014).

Apesar de serem considerados robustos, esses algoritmos são demasiadamente lentos, devido ao ajuste de pesos realizados nas suas arestas.

Na figura 10 do Anexo que apresenta um modelo de Rede Neural, cada bola representa um neurônio e as arestas representam as saídas e entradas dos neurônios, que poderão ou não receber algum peso.

2.3.3 Técnicas de melhoria do desempenho dos algoritmos de Aprendizado de Máquina

Além dos algoritmos de AM existem algumas técnicas que permitem aumentar o desempenho dos algoritmos. Abaixo apresentaremos algumas dessas técnicas.

2.3.3.1 A técnica Comitê de Aprendizado de Máquina

Segundo Barbosa (2009), comitês de algoritmos é o uso combinado de diferentes algoritmos de aprendizado de máquina com o intuito de melhorar o desempenho e a eficiência na classificação. Além disso, o uso de comitês de AM permite que não haja perda de informações devido a classificadores imperfeitos. O uso de comitês de AM tem sido muito utilizado recentemente em aplicações de reconhecimento de caligrafia e em diagnósticos médicos.

As máquinas que utilizam comitês podem combinar diversas organizações dos algoritmos de classificação, de forma que estes podem ser utilizados paralelamente em uma mesma tarefa, utilizando como resultado aquele que obteve o melhor desempenho, bem como podem ser utilizados sequencialmente, na qual cada classificador cumpre uma tarefa dentro de uma determinada sequência. Na figura 11 do Anexo podemos observar um modelo de comitê de AM.

2.3.3.2 A técnica Auto-Aprendizado

Por vezes o número de amostras classificadas de um conjunto de dados não é grande o suficiente para obter um bom desempenho na classificação de todas as amostras que necessitam ser classificadas. Isso ocorre porquê a acurácia da classificação não é alta o suficiente para a classificação de uma nova instância.

Entretanto, para resolver esse problema, é possível utilizar uma técnica conhecida como Auto-Aprendizado, que consiste em ir adicionando ao conjunto de treinamento algumas instâncias que puderam ser classificadas com uma acurácia mínima aceitável, incrementando a capacidade de classificação dos algoritmos aos poucos, permitindo que novas amostras sejam classificadas e adicionadas ao conjunto de treinamento (MIHALCEA, 2004). Dessa forma, ao utilizar essa técnica, o número de amostras classificadas, com uma acurácia desejável, será muito maior do que se um conjunto de treinamento único for utilizado.

3 APLICAÇÃO DO APRENDIZADO DE MÁQUINA NOS JOGOS DE GUERRA QUE SIMULEM UM ASSALTO ANFÍBIO

Neste capítulo apresentaremos como o Aprendizado de Máquina pode contribuir no suporte à decisão em cada fase dos Jogos de Guerra que simulem um Assalto Anfíbio.

3.1 Aplicações na Fase do Planejamento

Durante a Fase de Planejamento de um Assalto Anfíbio, algumas Decisões Fundamentais, citadas no capítulo anterior, poderão ser tomadas mais facilmente se o AM for utilizado nos simuladores de JG como uma ferramenta de apoio à decisão.

3.1.1 Seleção de Praias de Desembarque

Para Seleção das Praias de Desembarque é necessário analisar algumas das suas características para averiguar a possibilidade de desembarque dos meios em cada delas e selecionar aquelas darão melhores condições para o cumprimento da missão da ForDbq.

Entre essas características podemos citar: o escalão do CCT, a distância para os objetivos, a natureza do terreno após a praia, as características dos meios de desembarque, o gradiente da praia, o tamanho das ondas previstas no momento do desembarque, a distância entre a Linha de Baixa-Mar e a Linha de Costa, a densidade de obstáculos ao largo, a densidade de obstáculos em águas rasas, baixa-mar, preamar, extensão da praia seca, extensão da saída de praia, classificação das saídas de praia, tipo de praia, comprimento da praia, tipo de arrebentação, angulação das correntes marítimas e a força das correntes marítimas.

Em vez de utilizar um especialista para analisar cada uma dessas características e concluir a respeito da capacidade de utilização das praias de desembarque, essas características podem ser utilizadas pelos algoritmos de AM, que podem ser usados tanto

para informar se uma praia é própria para o desembarque, quanto para comparar as praias de desembarque selecionadas.

Ao analisarmos as características apresentadas, podemos notar que algumas possuem grandeza escalar, como a extensão da saída de praia e o comprimento da praia e outras possuem um valor descritivo como, por exemplo, a classificação das saídas de praia.

Dentre as características descritivas, podemos diferenciar ainda dois tipos: as que já possuem um rótulo ou categorização pré-definida em manuais e as que ainda não possuem.

Para as características que já possuem rótulos pré-definidos em manuais, o AM Supervisionado pode ser utilizado diretamente para classificar cada uma das características, entretanto, para as que ainda não possuem, será necessário utilizar o AM Não-supervisionado para a criação dos rótulos, de forma a possibilitar o uso posterior do AM Supervisionado na classificação dessas características, utilizando os novos rótulos criados.

Apesar de ser possível utilizar o AM na criação dos rótulos das características acima citadas, neste trabalho limitaremos em explicar somente como esta ferramenta pode contribuir nos aspectos decisórios mais importantes. Portanto, o detalhamento de quais algoritmos e técnicas de AM podem ser utilizados para auxiliar na criação de rótulos e na classificação de alguns elementos, como os acima citados, não serão apresentados.

Portanto, para apoiar a seleção das praias de desembarque o AM pode ser utilizado para duas finalidades diferentes, selecionar as praias possíveis de desembarque e para indicar, dentre as praias possíveis, qual possui as melhores características. Para a primeira finalidade o algoritmo de Regressão Logística, devido à sua característica, apresenta-se como o mais adequado, já para o segundo caso, qualquer algoritmo de AM, diferente da Regressão Logística ou Linear, pode ser utilizado, pois qualquer um pode fornecer como resultado valores com grandeza escalar.

Para utilizar esses dois algoritmos será necessário criar dois conjuntos de treinamento distintos, um cuja saída representa a classificação da praia em boa ou ruim para o desembarque e outro cuja saída representa uma nota para a praia de desembarque.

Por vezes é possível utilizar mais de um tipo diferente de algoritmo de AM para extrair alguma classificação ou predição, entretanto, prever qual é melhor para certo problema exige uma série de experimentos, conforme demonstrado em Silva(2015) e em Mangialardo(2015). Portanto, não será possível definir neste trabalho qual é o melhor algoritmo para resolver um determinado problema, mas vamos sugerir aqueles possíveis de

serem usados, de acordo com as características dos algoritmos apresentados no capítulo anterior.

3.1.2 Objetivos da Força Tarefa Anfíbia(ForTarAnf) e da ForDbq

Normalmente os objetivos da ForTarAnf e do ForDbq são selecionados a partir dos Acidentes Capitais (AcdtCap) que são levantados por ocasião estudo tático do terreno. Os AcdtCap se caracterizam por ser “qualquer acidente no terreno cuja posse, conquista, manutenção ou controle, assegure uma vantagem marcante a qualquer um dos contendores” (BRASIL, 2020, p. 5-33).

Podemos citar como exemplo de Acidentes Capitais os aeroportos, os portos, as localidades e as elevações que possuem certa dominância sobre as demais e sobre as vias de acesso principais.

No trabalho de Miranda(2011), os algoritmos SVM, Redes Neurais e K-Vizinhos mais próximos foram utilizados de forma a reconhecer e classificar objetos a partir de imagens. De forma semelhante ao apresentado neste trabalho, os algoritmos de AM também são capazes de distinguir parte desses Acidentes Capitais apenas pelas características do seu desenho nas cartas topográficas.

Entretanto, apesar dos algoritmos de AM serem capazes de sinalizar as elevações de uma região, para classificá-las como AcdtCap é necessário analisar as características do terreno no seu entorno. Dentre essas características podemos citar a distância para as demais elevações, a diferença de altitude entre essas elevações e a classificação da vegetação presente nessas elevações.

Portanto, ao considerarmos que cada uma dessas características podem ser lidas nas cartas topográficas e que cada característica será um atributo dos algoritmos de AM, é possível utilizar um algoritmo de Regressão Logística para comparar, uma a uma, as elevações em uma região delimitada e classificar algumas como AcdtCap.

Contudo, apesar de não ser capaz de selecionar diretamente os objetivos da ForTarAnf e da ForDbq, a sinalização dos possíveis acidentes capitais do terreno, utilizando o AM, pode facilitar de alguma forma a seleção desses objetivos.

3.1.3 Conceito da Operação em Terra

A definição do Conceito da Operação em Terra(COpT) ocorre na etapa de Desenvolvimento do Plano de Ação do PPM, etapa esta que depende substancialmente das informações levantadas na etapa anterior, ou seja, no Exame da Situação.

No item 3.1.2 foi apresentado como o AM pode ser utilizado na identificação dos AcdtCap e assim facilitar a escolha dos Objetivos. Nos itens a seguir será apresentado como o AM pode ser utilizado para facilitar algumas outras atividades realizadas por ocasião do Exame da Situação.

3.1.3.1 Levantamento das características área de operações

Dentre os diversos levantamentos das características área de operações que são utilizados na construção do COpT e que podem ser facilitadas pelo uso do AM, podemos citar a comparação das Vias de Acesso(VA), que são faixas do terreno utilizadas para o deslocamento ou para o desdobramento dos efetivos por ocasião da realização de alguma ação nos AcdtCap.

Para a comparação das VA as seguintes características de cada uma delas são levantadas: A extensão da VA, sua dominância de vistas e fogos, seu espaço disponível para manobra, seu espaço para tomada do dispositivo, sua orientação para o objetivo, o espaço para Progressão de Carro de Combate e Infantaria, bem como a existência de cobertas e abrigos para a tropa, a possibilidade do uso do Apoio de Fogo e a existência de vias para o deslocamento das armas de apoio.

Para a classificação das VA e a comparação entre elas é possível utilizar dois métodos diferentes de AM.

O primeiro método consiste em utilizar Redes Neurais, na qual cada característica acima citadas corresponderia a um neurônio da rede, que teria como saída a classificação correspondente de cada característica. Portanto, os algoritmos de AM utilizados em cada neurônio também deverão ser treinados para poderem classificar cada uma das características.

De forma semelhante às características dos AcdtCap, a classificação de cada característica das VA poderá ser realizada a partir de informações obtidas nas imagens de cartas topográficas. Nas Redes Neurais existe ainda a possibilidade de ser dado um peso diferente para cada uma das saídas dos neurônios, permitindo que as notas finais de cada VA seja influenciada por uma preferência de cada decisor, caso este julgue que algumas características tenham mais importância que outras.

O segundo método de AM possível de ser utilizado na comparação das VA é o método comitê, onde cada característica da VA deverá receber uma classificação utilizando algum algoritmo de AM e essas classificações servirão de entrada para um outro algoritmo de AM final que dará uma nota final para a VA.

Portanto, para cada característica das VA poderão ser utilizados diferentes tipos de algoritmo de AM, havendo necessidade de analisar para cada uma qual algoritmo se ajustaria melhor. Entretanto, ao considerarmos que nos exercícios práticos, para cada característica das VA são atribuídas notas de 0 (zero) a 10 (dez) e se considerarmos que as saídas das classificações de cada característica estarão dentro desses valores, podemos afirmar que um algoritmo de Árvores Aleatórias terá uma acurácia satisfatória tanto para as classificações das características das VA, quanto para a classificação final que dará a nota de cada VA.

3.1.3.2 Comparação de Poderes Combatentes

Segundo Brasil(2006), o estudo da Comparação de Poderes Combatentes(CPC) tem o intuito de avaliar quantitativamente a força empregada para fazer frente ao inimigo. Neste estudo são analisados os seguintes componentes de cada força oponente: as Forças Combatentes, as Comunicações e Eletrônica, a Logística e os Fatores de Tempo e Distância.

Para obter o resultado final da CPC poderá ser utilizado um algoritmo de Regressão Linear que dará como saída o quanto uma força tem de vantagem sobre a outra, levando em consideração a característica de todos os seus meios. Os dados de entrada desse algoritmo são oriundos das saídas de quatro comitês de AM, usados para classificar os componentes citados no parágrafo anterior. Portanto, esse algoritmo permitirá os comandantes avaliar se a força utilizada é suficiente para atingir o efeito desejado.

Cada um dos comitês de classificação dos quatro componentes, poderão utilizar diferentes tipos algoritmos de AM. A análise aprofundada desses quatro comitês, se tornaria demasiadamente extensivo, portanto, para exemplificar, explicaremos mais detalhadamente somente o comitê utilizado para a classificação das Forças Combatentes, cuja modelagem pode ser visualizada na figura 12 do Anexo.

Para a classificação das Forças Combatentes será necessário utilizar um comitê de classificadores com quatro níveis de profundidade. No primeiro nível deve ser realizada a classificação de cada meio que se opõe, podendo portanto utilizar um algoritmo do tipo Árvore Aleatória a partir das características de cada meio. No segundo nível será apresentado

o resultado do confronto dos meios que se opõem. Para esse resultado poderá ser utilizado os mesmos algoritmos apresentados em Silva(2015), ou seja, Árvore Aleatória, Regressão Logística ou Regressão Linear.

O resultado dos confrontos dos meios que se opõem servirão de entrada para os algoritmos de AM que classificarão a comparação das Forças Navais, Terrestres e Aéreas e então a partir destas comparações será realizada a classificação das Forças Combatentes. Para esse último classificador poderão ser utilizados algoritmos do tipo Regressão Linear, que darão como resultado o quanto aquele componente é superior ao mesmo componente da força inimiga.

Na predição da CPC, invés de utilizar um comitê de algoritmos também é possível utilizar Redes Neurais, de forma que o classificador poderá dar pesos diferentes para cada componente da CPC analisado.

Entretanto, para permitir uma predição da CPC será necessário criar classes para cada meio no nível mais baixo da árvore de classificação, bem como para os classificadores nos níveis intermediários, podendo utilizar para facilitar esta tarefa o AM Não-Supervisionado. Posteriormente, também será necessário realizar o treinamento dos algoritmos com um conjunto de dados suficientes para o aprendizado dos classificadores nos diferentes níveis.

3.1.3.3 Linhas de Ação

A última fase do Exame da Situação a ser realizada antes da elaboração do Conceito da Operação é a enunciação da Linha de Ação(LA) a ser tomada em termos de Decisão. Porém, antes desta fase foi necessário levantar todas as possíveis LA, fazer o confronto dessas com as Possibilidades do Inimigo (PI), elencar as vantagens e desvantagens de cada LA e ao final realizar a comparação entre elas para escolher a melhor LA.

Durante esse processo de escolha da melhor LA, em dois momentos é realizado o teste de Adequabilidade, Exequibilidade e Aceitabilidade(AEA) das LA: antes do confronto das LA com as PI e depois do levantamento das Vantagens e Desvantagens de cada LA.

Por ocasião do teste de Aceitabilidade são levantadas as prováveis perdas se determinada LA for executada. E é neste teste que o AM poderá cooperar significativamente, pois este pode realizar uma predição do número de baixas para cada LA, baseado no resultado passado de ações semelhantes à LA escolhida, realizadas em áreas de operações com

características próximas, cujo inimigo também possua uma força oponente cujo efetivo e dispositivo tenha alguma semelhança com o do inimigo atual.

Para caracterizarmos que o AM pode ser empregado na previsão de perdas na realização de uma determinada LA é necessário supor que as técnicas de reconhecimento de imagens utilizadas em Miranda(2011) são capazes de identificar as características do terreno a partir da análise de imagens de cartas topográficas digitais.

Portanto, partindo do pressuposto acima apresentado, se adicionarmos às características do terreno a classificação das forças oponentes de forma similar à realizada por ocasião da CPC, apresentada no item anterior, o dispositivo inimigo e os dados que representam as ações de determinada LA, o AM pode ser utilizado de forma a realizar a predição do número de baixas, caso uma determinada LA seja realizada.

Entretanto, de forma semelhante à CPC, é necessário construir um conjunto de dados com o resultado de ações reais ou de ações simuladas cujo resultado final seja confiável, com o intuito de treinar os algoritmos classificadores.

Tanto na classificação realizada por ocasião da CPC, quanto na predição de perdas de uma LA, caso haja um conjunto reduzido de dados de jogos anteriores ou de ações reais anteriores, é possível construir um conjunto de dados maior para o treinamento dos classificadores se a técnica de Auto-Aprendizado for utilizada em conjunto com técnicas de Aprendizado por Reforço.

O Aprendizado por Reforço, conforme mencionado, pode ser utilizado de forma a variar em alguma característica das LA existentes no banco de dados e criar uma predição para esta nova LA modificada. Desta forma esta nova amostra de LA com uma predição de um resultado poderá ser adicionada ao conjunto de treinamento dos algoritmos.

Além da previsão do número de baixas de uma LA, também é possível treinar os algoritmos de AM para que estes estimem o tempo de execução da LA, bem como o esforço logístico necessário para a execução daquela LA. Entretanto, para o esforço logístico será necessário criar categorias de esforço logístico de acordo com a forma que este for organizado, as quantidades e os tipos de suprimentos, podendo também utilizar o AM apoiar na categorização dos tipos de esforço logístico.

3.1.4 Zonas de Desembarque e Zonas de Lançamento

De forma semelhante à utilização do AM na identificação dos AcdtCap, o AM também pode ser utilizado para identificar possíveis Zonas de Desembarque e de Lançamento, também considerando a possibilidade do uso do AM no reconhecimento de imagens e dos mesmos algoritmos utilizados para identificação dos AcdtCap.

3.2 Aplicações na Fase da Execução

Apesar de existirem inúmeras aplicações do AM na Fase de Planejamento de um Jogo de Guerra que simule um Assalto Anfíbio, é na Fase da Execução dos JG que o emprego do AM fornecerá uma maior contribuição.

Atualmente os resultados de interações de forças de grande vulto nos Jogos de Guerra da MB são obtidos por meio do resultado final do confronto de diversas peças de manobra de menor vulto. Entretanto, este resultado não é muito confiável, tendo em vista que ele não leva em consideração as características da força como um todo, pois uma peça de manobra incluída em uma força de grande vulto não atua sozinha, onde a existência ou não de outros componentes com determinadas características poderá influenciar significativamente o resultado das iterações de uma peça de manobra e da força como um todo.

Além disso, dependendo da complexidade da operação que será analisada, o tempo para execução de um JG completo, para que se tenha resultados mais confiáveis, pode se tornar um empecilho, dependendo da urgência da decisão ou da iminência da ocorrência do confronto de forças que está sendo simulado.

Contudo, devido às atuais capacidades dos algoritmos de AM, essa ferramenta pode ser usada de forma a considerar as características dos meios como um todo e assim cooperar de forma mais eficaz na avaliação das decisões tomadas pelos comandantes no decorrer dos JG.

Dessa forma o uso do AM durante a execução dos JG dará maior confiabilidade, eficiência e eficácia na validação do planejamento e das ações dos comandantes tanto em JG analíticos quanto em jogos didáticos.

Grande parte do que foi apresentado no item anterior a respeito da forma que o AM pode ser utilizado para facilitar a construção do Conceito da Operação terá aplicação na predição de resultados de confrontos durante a execução do jogo, principalmente no subitem 3.1.3.3 que apresenta o uso do AM na escolha da LA. Entretanto, a modelagem da

comparação dos poderes combatentes nesta fase pode ser diferente da realizada por ocasião da escolha da LA na fase do planejamento.

Ao considerarmos a necessidade de obter resultados de iterações entre forças de grande vulto, o AM não deverá ser utilizado para realizar a predição de confrontos entre meios de menor escalão que se opõem. Seu melhor emprego, neste caso, será para a predição do confronto entre as forças como um todo, levando em consideração todas as suas capacidades.

Em um Assalto Anfíbio as forças oponentes podem ser de diferentes escalões, nas quais os meios empregados podem ter características diversas. Logo, para um Assalto Anfíbio a utilização do AM na caracterização das forças oponentes deverá utilizar um comitê de classificadores, para permitir unir as características dos diversos meios e considerar todas as capacidades das forças.

A partir do conjunto de características das forças oponentes e das características da área de operações é possível extrair dos algoritmos de AM as mesmas informações por ocasião da escolha da LA na fase de planejamento, ou seja, a porcentagem de baixas, o tempo estimado das ações e o esforço logístico para a execução da ação, permitindo desta forma que os comandantes optem por manter as ações inicialmente escolhidas ou as alterar, mesmo antes da execução completa das ações.

Adicionalmente, no decorrer de um JG, à medida que fatos novos forem ocorrendo, seja por identificação de novas capacidades das forças oponentes, seja por uma evolução na situação de combate, os algoritmos de AM são capazes de recalculas as previsões acima mencionadas, subsidiando os comandantes de forma mais eficiente para que estes ajustem as suas ações.

Com o uso do AM da forma mencionada acima, os comandantes podem obter o resultado das ações de forma mais rápida, tornando possível o teste de diferentes linhas de ação dentro de um tempo satisfatório e assim realizar aquela que terá melhores resultados.

Dependendo ainda da quantidade de dados e da capacidade dos algoritmos de AM, esses também são capazes de fornecer aos comandantes a LA que garantirá a menor porcentagem de baixas, o menor tempo estimado das ações e o menor esforço logístico, dando ainda mais agilidade na tomada das decisões.

Além do uso do AM nos JG no suporte à decisão quando são consideradas as capacidades das forças oponentes como um todo, o AM de máquina também pode ser utilizado para subsidiar as decisões de frações menores.

Contudo, diferentemente do que ocorre nos JG atuais da MB a predição dos resultados das iterações poderá levar em consideração a capacidade de outros elementos existentes nas forças oponentes, como por exemplo o apoio de fogo aéreo ou de artilharia.

Com o intuito de exemplificar o acima exposto, suponhamos que uma Companhia de Fuzileiros Navais(CiaFuzNav) tem a missão de atacar uma elevação, tomada por um efetivo inimigo de um pelotão, em posição defensiva.

Por ocasião do planejamento do ataque, o comandante da CiaFuzNav pode decidir realizar um ataque frontal com os três pelotões, ou um desbordamento com um ou dois pelotões, ou realizar um ataque frontal com um ou dois pelotões e deixar ou não um pelotão na reserva.

Ao utilizar os algoritmos de AM com os dados da CiaFuzNav, dos apoios que este pode contar, do inimigo e seus apoios e das características do terreno, o comandante da CiaFuzNav poderá obter uma informação mais confiável da previsão das perdas geradas e do tempo necessário para a conquista da elevação antes mesmo de realizar a ação no jogo e assim decidir qual LA melhor atende à sua missão.

De forma semelhante ao uso do AM na previsão de resultados do confronto de forças de grande vulto, também será necessário utilizar comitês de algoritmos de AM para a predição de resultados de frações menores, tendo em vista a necessidade de realizar diversas predições ou classificações em sequência ou em paralelo, como por exemplo, classificar os meios terrestres oponentes, o dispositivo defensivo e o terreno no entorno do confronto.

Além das possibilidades anteriormente apresentadas, o AM também pode ser utilizado para melhorar a estimativa da eficiência no emprego dos diversos armamentos de acordo com a forma que forem empregados.

O emprego centralizado dos fogos de um Batalhão de Artilharia no apoio de fogo a uma peça de manobra, por exemplo, é mais eficiente do que o seu emprego descentralizado, assim como o tipo de explosivo utilizado pode influenciar na quantidade de baixas ocasionadas ao inimigo. Portanto, o AM pode ser utilizado para melhorar essas estimativas, que atualmente são calculadas com algoritmos mais simples.

Para essas estimativas podem ser utilizados algoritmos do tipo Floresta Aleatório, pois diversas decisões serão tomadas pelos algoritmos de acordo com as características dos armamentos e da forma que esses forem empregados.

4 CONCLUSÃO

A evolução tecnológica, aliada ao surgimento de novas técnicas e métodos de aplicação da Inteligência Artificial, mais especificamente, o Aprendizado de Máquina, faz com que aumente, a cada dia, o número de ofícios ou serviços que tirem vantagem do uso dessa ferramenta para melhorar os seus processos e isso não pode ser diferente nos processos envolvidos nos Jogos de Guerra.

Neste trabalho, foram apresentadas algumas aplicações do AM e suas técnicas, visando à obtenção de informações que facilitarão parte das decisões dos comandantes durante um planejamento, inseridos ou não no contexto de um Jogo de Guerra, bem como na avaliação das ações e na predição de perdas em combate, tanto na Fase de Planejamento, quanto na de Execução.

Apesar de ter sido apresentado um possível modelo de aplicação do AM somente em um Jogo de Guerra que simule um Assalto Anfíbio, grande parte das técnicas descritas podem ser utilizadas em outros tipos de operações, seja no âmbito do MD ou das Forças Singulares, nos níveis de decisão tático, operacional ou estratégico.

Entretanto, este estudo mostrou que a aplicação do AM em qualquer tipo de operação carece de um estudo profundo das características dos meios empregados pelas forças oponentes, do tipo de ação que cada tipo de operação pode realizar e do tipo de ambiente em que o confronto ocorre, uma vez que essas características servirão de base para os atributos dos algoritmos de AM a serem utilizados e a omissão de alguma característica importante poderá gerar resultados duvidosos.

Portanto, para caracterização dos meios, dos tipos de operação e do ambiente operacional é necessário reunir especialistas de cada tipo de operação e de cada meio para a realização de tal tarefa, bem como para possibilitar que seja gerado um conjunto de dados iniciais confiáveis para o treinamento dos algoritmos de AM.

Além disso, o estudo também deixou claro a necessidade de se obter e registrar dados fidedignos de combates reais e de Jogos de Guerra, realizados em exercícios no terreno

ou em simuladores, de forma a possibilitar a formação de um banco de dados atualizado, robusto e confiável, que servirá como base de dados para o treinamento dos algoritmos de AM utilizados para prever os resultados dos combates simulados.

Com relação aos objetivos da pesquisa, uma das dificuldades enfrentadas foi a quantidade limitada de fontes de consulta científicas que versam sobre os Jogos de Guerra.

Para trabalhos futuros, sugere-se pesquisas junto a especialistas que permitam identificar as características fundamentais dos meios e dos diferentes ambientes operacionais de forma a viabilizar o uso do AM nos Jogos de Guerra em diferentes tipos de operações, bem como experimentos que permitam avaliar a acurácia dos algoritmos e métodos de AM na obtenção das informações necessárias para a melhoria dos diversos processos que envolvem os Jogos de Guerra, incluindo a simulação de diferentes tipos de operações, também na fase de Análise e Avaliação dos JG.

Espera-se, com este trabalho, contribuir para o Centro de Análise de Sistemas Navais, e para o Centro de Jogos de Guerra da Escola de Guerra Naval, quanto à possibilidade de uso dos algoritmos de AM na melhoria dos processos presentes nos seus JG, bem como incentivar a obtenção dos dados que viabilizem o aproveitamento mais amplo dessa ferramenta, em um futuro próximo.

REFERÊNCIAS

- ALVES G. **Regressão Linear**. out. 2019 Disponível em: < <https://medium.com/@gisely.alves/regress%C3%A3o-linear-7d9d3b2ec815/> >. Acesso em: 12 jul. 2021.
- BARBOSA, Bruno Henrique. **Computação evolucionária e máquinas de comitê na identificação de sistemas não-lineares**. Tese (Doutorado em Engenharia Elétrica) - Programa de Pós-Graduação em Engenharia Elétrica. Universidade Federal de Minas Gerais. Belo Horizonte, p. 44. 2009.
- BARROS, Cesar Borges. **Classificadores de regressão logística, Naive Bayes e Random Forest na análise do Tropismo do HIV-1 de subtipo B**. Dissertação (Mestrado em Engenharia Biomédica). Programa de Pós-graduação em Engenharia Biomédica, COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro, p. 89. 2019.
- BRASIL. Comando-Geral do Corpo de Fuzileiros Navais. **CGCFN-1-1: Manual de Operações da Força de Desembarque**. Rio de Janeiro, 2020.
- BRASIL. Escola de Guerra Naval. **EGN-181: Jogos de Guerra**. Rio de Janeiro, 2018.
- BRASIL. Estado-Maior da Armada. **EMA-331: Manual de Planejamento Operativo da Marinha**. v.1. Processo de Planejamento Militar. Brasília, 2006.
- BURNS, Shawn et al. **War gamers handbook: A guide for professional war gamers**. Naval War College Newport United States, 2015.
- CARVALHO, Hialo Muniz. **Aprendizado de máquina voltado para mineração de dados: árvores de decisão**. Monografia (Bacharelado em Engenharia de Software) - Universidade de Brasília, Brasília, p. 98. 2014.
- CLUSTERING k-means totalmente explicado com python. **Ichi.Pro**. Disponível em: < <https://ichi.pro/pt/clustering-k-means-totalmente-explicado-com-python-254857545193322/> >. Acesso em: 13 jul. 2021.
- CURRY, John; PERLA, Peter. **Peter Perla's the Art of Wargaming: a guide for professionals and hobbyists**. 2. ed. Maryland, EUA: United States Naval Institute, p. 404. 2012.
- DA SILVA, Antonio de Lemos Pecli. **Um Estudo Comparativo de Estratégias de Seleção de Variáveis Aplicadas na Abordagem de Aprendizado Supervisionado para Predição de Links**. Dissertação (Mestrado em Sistemas e Computação). Instituto Militar de Engenharia, Rio de Janeiro, p. 89. 2015.
- DE OLIVEIRA, Luiz Henrique Rodrigues et al. Previsão de Valores de Aquisições Governamentais: o Uso dos Conceitos de Data Science e Machine Learning. **XVI Congresso USP de Iniciação Científica em Contabilidade**. São Paulo, jul. 2019.

FACELI, Katti et al. **Inteligência Artificial: Uma abordagem de aprendizado de máquina**. Rio de Janeiro. LTC, v. 2, p. 192, 2011.

GONZALEZ, Leandro de Azevedo. **Regressão logística e suas aplicações**. Monografia (Bacharelado em Ciência da Computação) - Universidade Federal do Maranhão, São Luís, p. 46. 2018.

GRIMES R.A. **8 tipos de malware e como reconhecê-los**. Jul. 2018. Disponível em: <<https://cio.com.br/tendencias/8-tipos-de-malware-e-como-reconhece-los/>>. Acesso em: 12 jul. 2021.

K-VIZINHOS mais próximos do zero. **Ichi.Pro**. Disponível em: <<https://ichi.pro/pt/k-vizinhos-mais-proximos-do-zero-109117870622528/>>. Acesso em: 13 jul. 2021.

LETS open the black box of random forests. **Analytics Vidhya**. Dez. 2020. Disponível em: <<https://www.analyticsvidhya.com/blog/2020/12/lets-open-the-black-box-of-random-forests/>>. Acesso em: 13 jul. 2021.

MANGIALARDO, R. J. **Integrando as Análises Estática de Dinâmica na Identificação de Malwares Utilizando Aprendizado de Máquina**. Dissertação (Mestrado em Sistemas e Computação). Instituto Militar de Engenharia, Rio de Janeiro, p. 99. 2015.

MARINELLO, Sérgio HM et al. Determinando posições relativas de nós móveis por meio de bluetooth e aprendizado de máquina. **Revista de Exatas e Tecnológicas**, Rondonópolis, v. 3, n. 1, p. 28-37, 2012. Disponível em <<http://retec.eti.br/retec/index.php/retec/article/view/20>> Acesso em: 13 jul. 21.

MIRANDA, Bruno de Souza. **Algoritmos clássicos de aprendizado de máquina, aplicados ao problema do reconhecimento de imagens**. Monografia (Bacharelado em Ciência da Computação) - Universidade Federal do Pampa, Alegrete, p. 87. 2011.

MIHALCEA, Rada. Co-training and self-training for word sense disambiguation. **Proceedings of the Eighth Conference on Computational Natural Language Learning** Boston, Massachusetts. p. 33-40. 2004.

MORAES, Luciane de Godói. **Uma abordagem alternativa de behavioral scoring usando modelagem híbrida de dois estágios com regressão logística e redes neurais**. Monografia (Bacharelado em Ciência da Computação) - Universidade Federal do Pampa, Alegrete, p. 87. 2012.

RASCHKA, Sebastian. **Naive bayes and text classification i-introduction and theory**. arXiv preprint arXiv:1410.5329, 2014. Disponível em <<https://arxiv.org/abs/1410.5329>> Acesso em: 13 jul. 21.

REHBEIN, Matheus Henrique. **Estudo comparativo de Deep Learning e regressão linear na predição de mensagens processadas pela plataforma de integração guaraná**. Monografia (Bacharelado em Ciência da Computação) - Universidade Regional do Noroeste do Estado do Rio Grande do Sul, Ijuí, p. 44. 2020.

ROCHA, Daniel de Almeida. **Simulação do comportamento humano em jogos utilizando aprendizado de máquina**. Dissertação (Mestrado em Sistemas e Computação). Instituto Militar de Engenharia, Rio de Janeiro, p. 79. 2020.

SILVA, Leandro A. A. et al. Algoritmos de Aprendizado de Máquina para Predição de Resultados das Lutas de MMA. **Simpósio Brasileiro de Banco de Dados**, Petrópolis, RJ, p. 21-26, 2015.

SOUSA, Maria Cristina Cordeiro Sousa. **Uma análise do algoritmo K-means como introdução ao aprendizado de máquinas**. Monografia (Licenciatura em Matemática) - Universidade Federal do Tocantins, Araguaína, p. 75. 2020.

SZABO, Mauricio. **Redes Neurais For Dummies**. Jan. 2013. Disponível em: <<https://mauricioszabo.wordpress.com/2013/01/16/redes-neurais-for-dummies/>>. Acesso em: 07 ago. 2021.

ANEXO

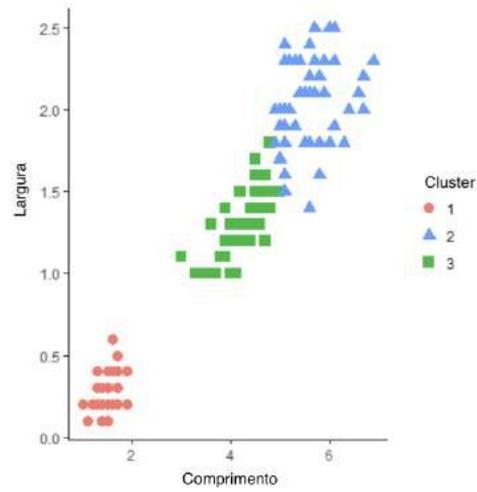


Figura 1: Exemplo de Agrupamento utilizando AM Não Supervisionado

Fonte: Rocha (2020, p. 36)

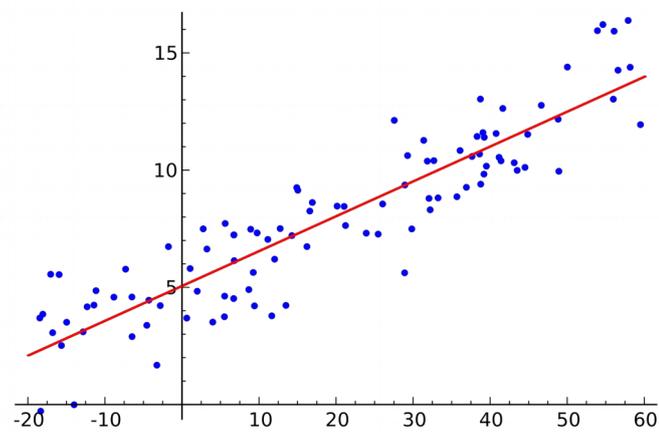


Figura 2. Exemplo de Regressão Linear.

Fonte: Alves(2019, n.p).

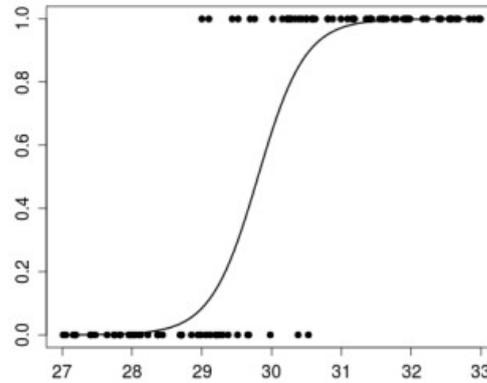


Figura 3. Exemplo de Regressão Logística.

Fonte: Gonzalez (2018, p.19)

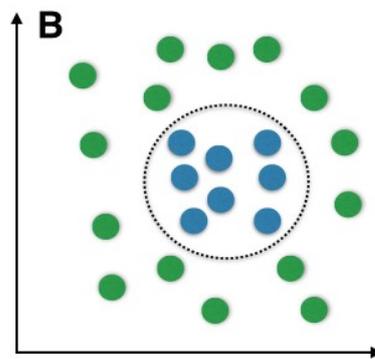


Figura 4. Exemplo de classificação usando o algoritmo Naive Bayes.

Fonte: Raschka (2014, n.p)

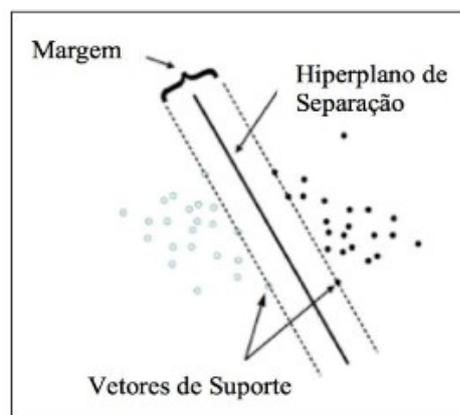


Figura 5. Exemplo de classificação usando o algoritmo Máquina de Vetores de Suporte.

Fonte: De Oliveira(2019, p.5).

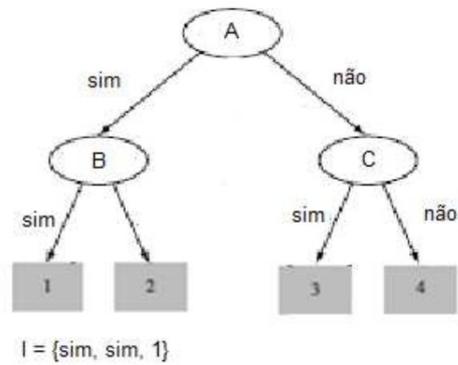


Figura 6. Exemplo de Árvore de Decisão.

Fonte: Carvalho (2014, p.47).

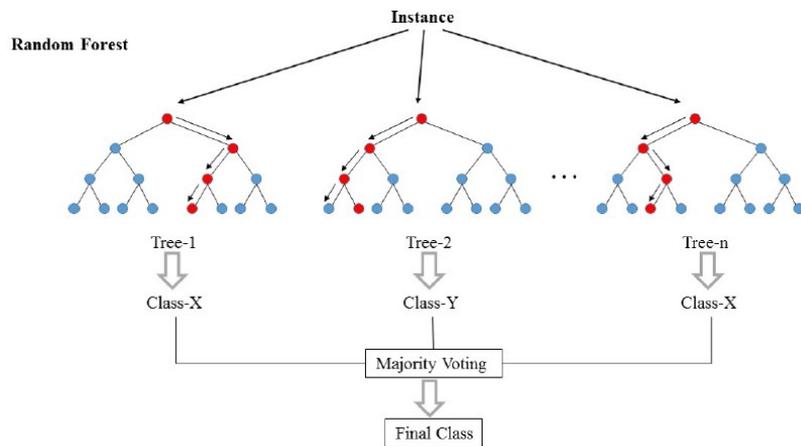


Figura 7. Exemplo de Floresta Randômica.

Fonte: Lets (2021, n.p)

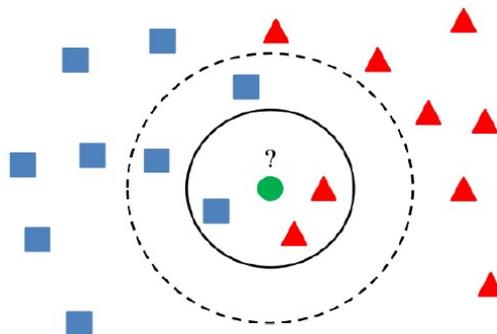


Figura 8. Exemplo de Classificação usando o algoritmo K-Vizinhos Mais Próximos.

Fonte: K-Vizinhos (2021, n.p)

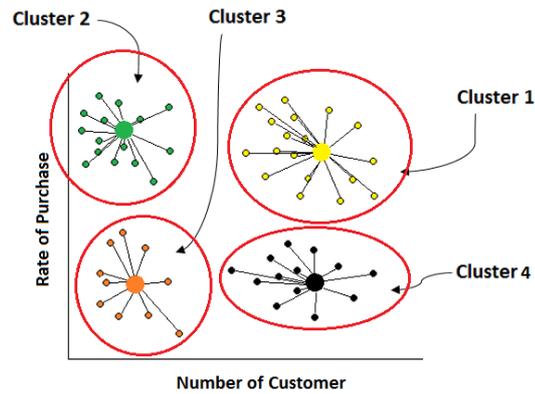


Figura 9: Exemplo de agrupamento usando o algoritmo K-Means.

Fonte: Clustering (2021, n.p)

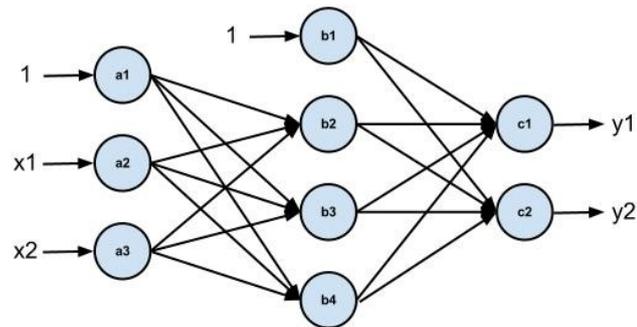


Figura 10. Exemplo de Rede Neural.

Fonte: Szabo (2021, n.p)

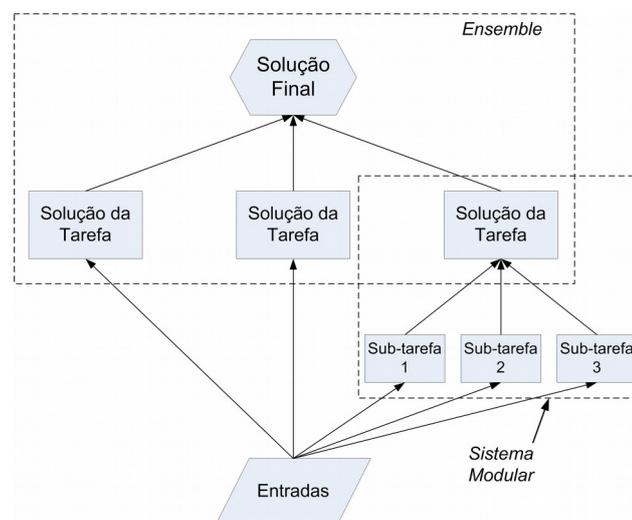


Figura 11: Exemplo de comitê de AM.

Fonte: Barbosa (2009, p.9).

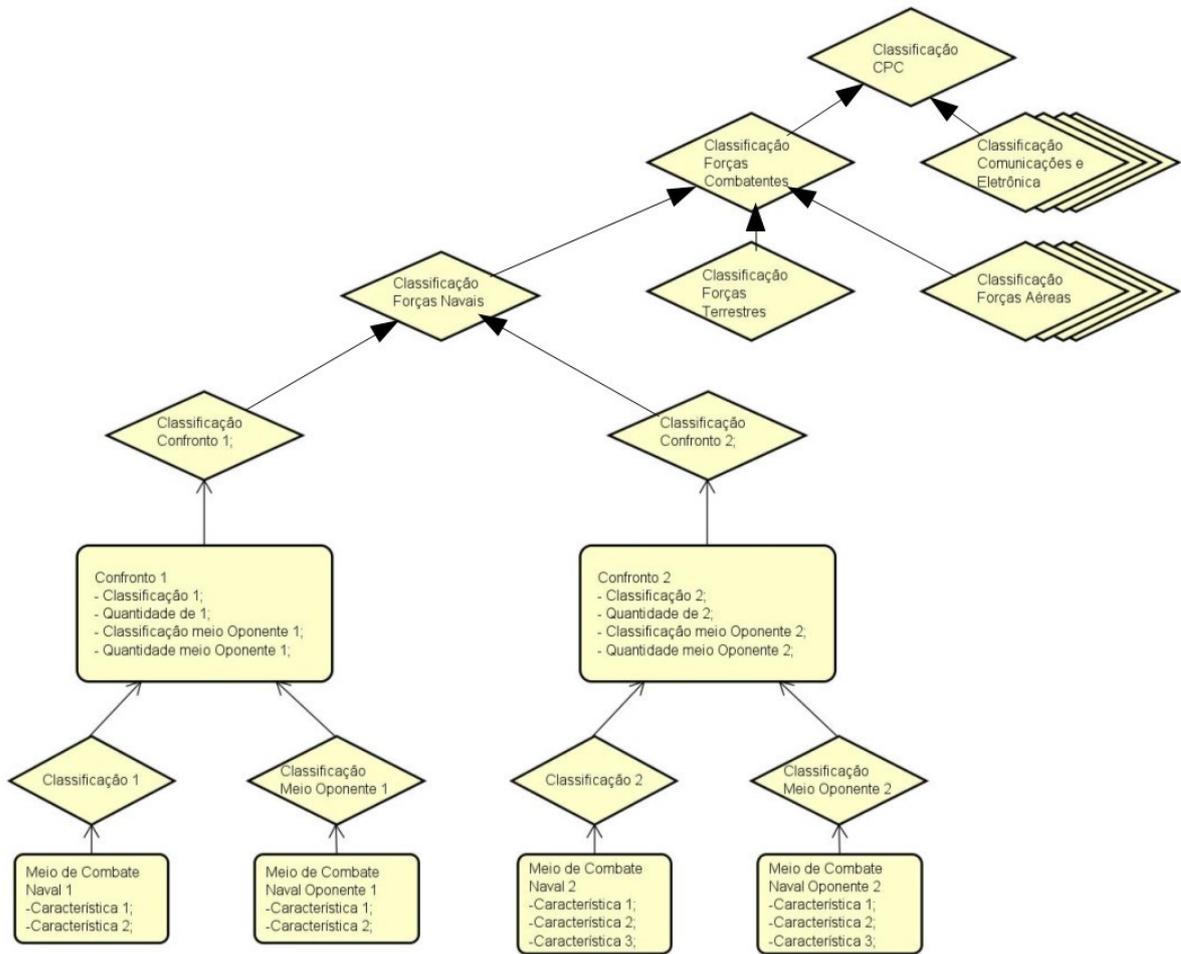


Figura 12: Modelo de comitê de AM para classificação da CPC.