

Machine Learning to Improve Situational Awareness in Beyond Visual Range Air Combat

Joao P. A. Dantas, Marcos R. O. A. Maximo, Andre N. Costa, Diego Geraldo, Takashi Yoneyama

Abstract—This article presents an artificial intelligence model using artificial neural networks that provide parameters to improve the situational awareness of a Beyond Visual Range (BVR) air combat pilot. In this combat modality, it is necessary to make decisions based on information from sensors, mainly radars. Furthermore, since information regarding enemy aircraft systems is sometimes unknown, pilots' decisions are usually based on beliefs regarding the opponent. The presented model proposes to deal with such characteristics, generating behaviors for entities represented in a constructive simulation environment, i.e., simulated people operating simulated systems. We created BVR air combat simulations between two aircraft, with only one missile each, through Latin Hypercube Sampling (LHS) to choose input variables to cover almost homogeneously all their ranges. The aircraft have similar behaviors, and their parameters may change only at the beginning of the simulation. The simulation environment generated ten thousand air combat scenarios, varying thirty-six input parameters, for the analysis proposed in the case study. From this data, we could create supervised machine learning models that substantially improve the BVR air combat pilot's situational awareness regarding offensive situations, in which the reference aircraft employs a missile against a target, or defensive positions, in contrast to when the same reference aircraft tries to avoid a possible enemy's missile launched in its direction. The offensive and defensive models were consistent with the accuracy of 0.930 and 0.924 and the F1-score of 0.717 and 0.678, respectively. Thus, the contribution of this work is to use machine learning algorithms to generate responses concerning the tactical state to improve the pilot's situational awareness and, therefore, the in-flight decision-making process.

Index Terms—Air Combat, Artificial Intelligence, Artificial Neural Networks, Data Science, Machine Learning.

I. INTRODUÇÃO

No combate aéreo moderno, mundialmente as Forças Aéreas têm aprimorado suas aeronaves e armamentos [1]. O desenvolvimento de novas táticas de combate mais efetivas e o treinamento constante dos pilotos são de fato essenciais para garantir a soberania de uma nação. Os confrontos aéreos nos dias de hoje são divididos em combate por referências

visuais (*Within Visual Range – WVR*) e combate além do alcance visual (*Beyond Visual Range – BVR*) [2]. Esse último, sendo a parte mais crítica do combate [3], significa que os combatentes usam equipamentos de detecção aerotransportados para procurar o alvo inimigo e mísseis que fazem uso tanto do radar de bordo da aeronave lançadora quanto da parte interna do armamento. O combate BVR é caracterizado por sua dinamicidade devido às influências que as ações de uma aeronave têm nas outras [4].

Treinamentos reais de combate aéreo BVR são bastante custosos. Com uma estimativa de 4.700,00 dólares por hora, a aeronave sueca JAS 39 Gripen tem uma comparação muito favorável em relação ao Block 40/50 F-16, que é o concorrente mais próximo, com um valor por hora estimado em 7.000,00 dólares [5]. Outras aeronaves como o F-16, Rafale, Eurofighter e F-35 possuem custos ainda maiores, considerando os seguintes fatores: combustível de aviação, bens de consumo, operação e manutenção, mão de obra, melhorias dos sistemas, encargos de capital, depreciação e amortização.

Dessa forma, o uso de simulações, principalmente do tipo construtiva – agentes simulados em um ambiente simulado – vem-se tornando uma prática adotada pelas Forças Armadas em diversos países, a fim de reduzir custos [6]. Simulações dessa natureza podem ser utilizadas para a análise de cenários operacionais [7], a qual pode gerar conclusões nos níveis estratégico, operacional e tático [8].

Com base nos resultados de um grande número de simulações, é possível propor modelos que descrevam a situação tática do piloto em voo [9]. Entretanto, tal processo pode ser muito demorado e custoso, ainda mais em se tratando de simulações de elevado nível de fidelidade. Este trabalho propõe a utilização de um modelo de aprendizado de máquina supervisionado para fornecer uma resposta rápida e confiável com relação à situação tática de um piloto BVR, sem a necessidade de que novas execuções de simulações sejam realizadas. Tal modelo se baseia em resultados de simulações realizadas previamente, os quais são utilizados para treinamento, validação e testes do modelo proposto. Tais respostas podem auxiliar no processo de tomada de decisão de um piloto BVR em situações como a do momento ideal de lançamento de um míssil ou de realização de uma manobra defensiva.

Na literatura é possível encontrar trabalhos relacionados a estas decisões, fornecendo diferentes formas de modelar o comportamento do piloto. Grande parte delas utilizam teoria de jogos para modelar o combate aéreo [10]–[14]. Outras abordagens são baseadas em: redes Bayesianas [15]–[18], lógica nebulosa [19]–[21], modelagem baseada em agentes [22], diagramas de influência [23], aprendizado por reforço [24]–[27],

Joao P. A. Dantas is with the Decision Support Systems Subdivision, Institute for Advanced Studies, Sao Jose dos Campos (SP), Brazil, dantasj-pad@fab.mil.br

Marcos R. O. A. Maximo is with the Autonomous Computational System Lab, Computer Science Division, Aeronautics Institute of Technology, Sao Jose dos Campos (SP), Brazil, mmaximo@ita.br

Andre N. Costa is with the Decision Support Systems Subdivision, Institute for Advanced Studies, Sao Jose dos Campos (SP), Brazil, negraoanc@fab.mil.br

Diego Geraldo is with the Decision Support Systems Subdivision, Institute for Advanced Studies, Sao Jose dos Campos (SP), Brazil, diegogd@fab.mil.br

Takashi Yoneyama is with the Electronic Engineering Division, Aeronautics Institute of Technology, Sao Jose dos Campos (SP), Brazil, takashi@ita.br

algoritmos evolucionários [28], [29], método minimax [30] e árvores de comportamento [31].

Ao se analisar tais trabalhos, não se identificou abordagens com o uso de Redes Neurais Artificiais (RNA) para a predição da situação tática do piloto e melhoria de sua consciência situacional. Por essa razão e devido à sua versatilidade e eficiência em problemas com muitas variáveis de entrada [32], optou-se, no presente trabalho, por esse tipo de algoritmo de aprendizado de máquina supervisionado para abordar o problema do combate aéreo além do alcance visual.

Portanto, as principais contribuições deste trabalho são: identificar as variáveis mais importantes a serem analisadas em um combate BVR que contribuem para análises de problemas semelhantes neste contexto mesmo em se tratando de dados de outras plataformas de simulação; propor uma metodologia para o uso de aprendizado de máquina para criar ferramentas de apoio à decisão utilizando dados oriundos de simulações; e fornecer respostas ao piloto BVR com relação à sua situação tática pelo uso de técnicas de aprendizado supervisionado, mais especificamente RNAs, que podem aumentar a sua consciência situacional em um combate aéreo.

O restante do artigo é organizado da seguinte forma: na Seção II, apresenta-se a metodologia para treinar dois modelos baseados em RNA, um para uma situação de ataque e outro para uma de defesa, na Seção III é demonstrado os principais resultados e suas discussões acerca dos modelos propostos e na Seção IV as considerações finais e sugestões para trabalhos futuros.

II. METODOLOGIA

Nesta Seção, é descrito o estudo de caso de combate BVR analisado no presente trabalho, bem como as variáveis de entrada utilizadas para gerar os cenários descritos e as variáveis de saída obtidas após a execução das simulações. Além disso, a utilização de redes neurais artificiais e as métricas utilizadas para melhoria da consciência situacional do piloto BVR.

A. Estudo de Caso

Para obter os dados utilizados neste estudo, foi utilizado o protótipo do Ambiente de Simulação Aeroespacial (ASA) [33] [34], uma ferramenta de simulação desenvolvida pela Força Aérea Brasileira (FAB) para análise de cenários operacionais. O ASA, no presente momento, possui acesso restrito por ser tratar de uma plataforma de uso militar que incorpora modelos de alta fidelidade, com sistemas e subsistemas presentes em cenários militares tais como radares embarcados com diferentes modos de busca e rastreamento, mísseis radar-ativo e aeronaves modeladas com 6 graus de liberdade. O conceito de simulação abordado neste contexto é aquele no qual os elementos do cenário são representados por agentes autônomos capazes de tomar decisões com base em modelos de inteligência artificial. Simulações dessa natureza, ditas construtivas, podem ser empregadas no processo decisório para prever possíveis resultados de engajamentos entre forças oponentes e auxiliar na definição de linhas de ação [35].

A Fig. 1 descreve as principais fases do cenário do estudo de caso que consiste em um cenário BVR de combate um

contra um, onde inicialmente as duas aeronaves encontram-se em aproximação, desengajadas e fora do alcance radar de cada uma. Quando elas adentram os limites do radar da aeronave oponente, inicia-se o engajamento (Fig. 1a). A Fig. 1b apresenta o cálculo da trajetória de ambas as aeronaves até o final deste engajamento. Na modelagem proposta neste artigo, será considerado um cenário em que cada aeronave está equipada com um míssil radar-ativo de médio alcance. Sabe-se que o emprego de um míssil consiste tipicamente em três fases [36]. No início, quando a aeronave inimiga encontra-se dentro da zona de engajamento efetivo do armamento, também conhecida como Weapon Engagement Zone (WEZ) [37], a aeronave lançadora efetua o disparo e retransmite a informação do alvo ao míssil na fase de suporte (Fig. 1c). Na segunda fase, a aeronave realiza uma manobra evasiva, *cranking*, e o míssil continua em direção ao ponto de encontro esperado. Finalmente, o míssil inicializa a operação do seu próprio radar, tornando-se ativo, e tenta atingir a posição futura do alvo (Fig. 1d). É importante notar que, apesar da relativa simplicidade do estudo de caso proposto, este engajamento pode ser considerado a situação elementar para a construção de cenários de combate aéreo mais complexos.

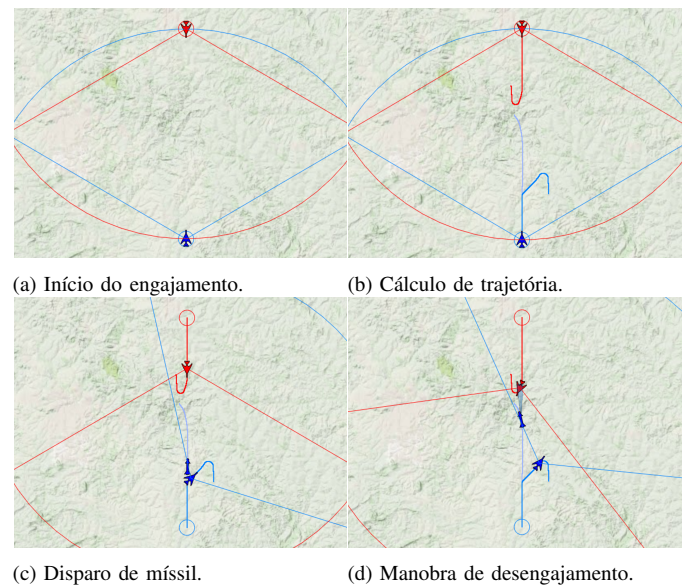


Fig. 1. Fases de engajamento do combate BVR.

B. Variáveis de Entrada e Saída

Foram determinadas as mais importantes variáveis para definir o andamento das simulações no estudo de caso proposto utilizando o conhecimento operacional dos pilotos da FAB. Além disso, a partir das variáveis descritas pelos especialistas, utilizou-se técnicas de seleção de variáveis através da análise de informação mútua para determinar aquelas utilizadas neste estudo. Há variáveis categóricas e numéricas com diferentes intervalos de abrangência. A definição desses intervalos de atuação das variáveis no simulador foi feita baseada em conversas com pilotos e especialistas de combate BVR.

1) *Posição relativa*: variável numérica que representa a relação posicional entre as aeronaves azul e vermelha. Essa

variável (*relative_position*) está definida no intervalo $[0, 60]^\circ$. A utilização desse intervalo se baseia no limite de alcance radial do radar também definido como 60° no simulador. Para as simulações propostas foi utilizada a aeronave azul como base para o cálculo da posição relativa. Portanto, a aeronave base foi fixada e aeronave vermelha variou sua posição de 0° a 60° , sempre com sua proa apontada para a reta que liga as duas aeronaves.

2) *Distância entre as aeronaves* : variável numérica que retrata a distância relativa entre as duas aeronaves, calculada em milhas (nautical miles – NM). Foi definido como intervalo para essa variável (*distance*) uma variação entre 25 NM e 50 NM.

3) *Altitude*: variável numérica muito importante em um combate aéreo BVR, pois é um fator determinante da quantidade de energia que cada aeronave possui. Uma maior quantidade de energia permite um melhor desempenho em um combate aéreo [38]. O intervalo de altitude para o time azul (*altitude_blue*) e vermelho (*altitude_red*) foi definido entre 20.000 ft e 35.000 ft.

4) *Velocidades*: variável numérica que influencia diversos aspectos do combate BVR. Velocidade maiores podem se traduzir em ataques e defesas mais eficazes. Porém, acabam gerando maior consumo de combustível, o que diminui a autonomia da aeronave. O intervalo de velocidades para a aeronave azul (*velocity_blue*) e vermelha (*velocity_red*) foi definido entre Mach 0,8 e Mach 1,00.

5) *Radar Warning Receiver (RWR)*: variável categórica que indica a utilização de RWR, o qual é bastante usado no combate BVR e se baseia na detecção de ondas eletromagnéticas emitidas por sistemas de radar [21]. Como as aeronaves oponentes estão a uma distância que não permite sua identificação visual, o combate BVR muito se baseia em informações desses sensores. A variável assume valores 1 quando a aeronave azul (*blue_rwr*) ou vermelha (*red_rwr*) possui o equipamento operante e 0 quando inoperante. A presença do RWR tem muita influência no combate BVR, pois permite ao piloto a realizações de manobras evasivas que garantem sua sobrevivência.

6) *Míssil*: variável categórica que representa o tipo de míssil utilizado no combate, podendo ser, para a aeronave azul e vermelha, AM-3AL (*missile_blue_a* e *missile_red_a*), AM-3BL (*missile_blue_b* e *missile_red_b*) e AM-3CL (*missile_blue_c* e *missile_red_c*), os quais estão em ordem decrescente de letalidade e são representados respectivamente por (1,0,0), (0,1,0) e (0,0,1). Serão computadas ainda as variáveis relativas à estimativa do tipo de míssil que a aeronave inimiga possui para ambos o lado azul (*missile_est_blue_a*, *missile_est_blue_b* e *missile_est_blue_c*) e vermelho (*missile_est_red_a*, *missile_est_red_b* e *missile_est_red_c*).

7) *Filosofia de Tiro*: variável categórica que representa as distâncias mínimas em que o disparo de um míssil deve ser efetuado. Tais distâncias são definidas com base na doutrina adotada, bem como nos recursos disponíveis, já que, caso não haja grande disponibilidade

de armamentos, por exemplo, é necessário que estes só sejam utilizados quando se tem maior certeza de sua efetividade [36]. A filosofia de tiro pode ser classificada em ordem crescente de distância do alvo da seguinte forma: *short* (*shotphi_blue_s* e *shotphi_red_s*), *medium* (*shotphi_blue_m* e *shotphi_red_m*) e *long* (*shotphi_blue_l* e *shotphi_red_l*). Serão computadas ainda as variáveis relativas à estimativa da filosofia de tiro que a aeronave inimiga adotou, tanto azul (*shotphi_est_blue_s*, *shotphi_est_blue_m* e *shotphi_est_blue_l*), quanto vermelha (*shotphi_est_red_s*, *shotphi_est_red_m* e *shotphi_est_red_l*).

8) *Thresholds*: variáveis numéricas que representam a aversão ao risco que o piloto possui em fases diferentes do combate. São considerados dois valores: o primeiro é utilizado para a fase anterior ao disparo (*threshold_bfr_blue* e *threshold_bfr_red*) e o segundo para a posterior (*threshold_aft_blue* e *threshold_aft_red*). Tal divisão foi feita para que se pudesse aumentar a propensão ao risco do piloto após ter realizado o tiro, posto que já se comprometeu com o disparo. Tais valores devem ser calibrados a fim de representarem comportamentos próximos ao que se espera de um piloto de combate BVR, considerando a doutrina vigente e as condições político-estratégicas em que o combate simulado se insere.

9) *Distância Final do Míssil ao Alvo*: variáveis numéricas referentes às menores distâncias que os mísseis das aeronaves azul (BM_RA) e vermelha (RM_BA) conseguiram atingir durante a simulação. Tomando a aeronave azul como referência, a distância BM_RA representa a situação de ataque, já que é referente à distância mínima atingida por seu míssil em relação ao alvo. Por outro lado, a distância RM_BA se refere à situação de defesa, sendo a mínima distância atingida entre o míssil lançado pela aeronave vermelha contra a referência (aeronave azul). Esses parâmetros permitem que se possa analisar o grau de sucesso na missão em termos de ofensividade e sobrevivência. Essas distâncias dizem respeito, tanto para ataque quanto para defesa, ao quanto o piloto BVR se empenhou em garantir um ataque ou uma defesa bem-sucedida. Ao se obter as distâncias mínimas atingidas pelos mísseis das simulações realizadas, utiliza-se um filtro para classificar os lançamentos que obtiveram ou não sucesso. Foi padronizada como 10 metros a distância mínima de atuação da espoleta de proximidade dos mísseis modelados levando em consideração o tipo de missão que se deseja realizar. Essa distância é importante para saber se o míssil conseguirá efetivamente cumprir seu objetivo de atingir o alvo desejado. A definição de um limite de distância para definir sucesso ou fracasso de uma missão aumenta substancialmente o número de possibilidades de análise de cenários. Caso se deseje que o míssil funcione apenas como uma advertência e mude a trajetória da aeronave inimiga, atingir uma distância de 10 quilômetros, por exemplo, possivelmente seria suficiente para atingir tal efeito desejado. Este trabalho foca apenas no caso do míssil neutralizar seu alvo. As variáveis binárias dos modelos de ataque e defesa que definem o sucesso ou o fracasso dos mísseis lançados em direção aos seus alvos são as saídas dos modelos e os

parâmetros que se deseja prever.

Portanto, a partir das variáveis descritas, foram definidos 36 atributos previsores e 1 variável de saída para cada uma das situações de combate propostas (ataque e defesa) que serão utilizados nos modelos de aprendizado de máquina.

C. Amostragem e Simulação

A utilização do simulador de forma não-automatizada se torna inviável para geração de um grande número de amostras de entradas para as simulações do combate BVR. Para tornar o processo mais eficiente em termos de tempo de processamento, adotou-se um método de geração de dados de entrada que abrangesse todos os intervalos descritos na subseção II-B de modo que os valores escolhidos para as variáveis estivessem distribuídos de forma apropriada. Este método é chamado de amostragem por hipercubo latino ou *Latin Hypercube Sampling* (LHS) [39].

Utilizando o algoritmo do LHS, foram geradas 10.000 configurações distintas para as variáveis de entrada das simulações, uma para cada simulação, e com o uso do simulador de combate aéreo BVR, foi possível gerar, após dezessete dias, 10.000 simulações. A partir das variáveis de entrada e dos resultados obtidos nestas simulações, foi possível criar um modelo de aprendizado de máquina supervisionado baseado em RNA para fornecer uma resposta mais rápida e com um bom nível de confiança dos resultados das simulações.

D. Melhoria da Consciência Situacional

A Consciência Situacional, ou ainda *Situational Awareness* (SA), é definida como a percepção dos elementos em um ambiente dentro de um volume de tempo e espaço, a compreensão de seus significados e a projeção de seus status em um futuro próximo [40]. A importância da consciência situacional, no aspecto operacional, surgiu dos próprios operadores e pilotos, os quais compreenderam como é difícil de atingi-la e mantê-la em alto nível, aspecto considerado central em seus desempenhos e no cumprimento de missões [40].

Observada a importância de uma alta consciência situacional do piloto de combate aéreo BVR, propõe-se a criação de um meio que possibilite sua melhoria durante o combate. É possível obter uma resposta mais rápida do simulador BVR de informações relativas às possíveis distâncias finais que os mísseis lançados pela aeronave inimiga e pela própria aeronave atingiram de seus respectivos alvos. Portanto, baseado nos valores obtidos por essas distâncias, é possível prever a todo instante a situação final do combate aéreo BVR entre uma aeronave amiga e uma inimiga, ambas equipadas com somente um míssil. A informação relativa a essas distâncias aumenta a consciência situacional do piloto ao fornecer uma previsão do resultado final de um combate aéreo.

A implementação de um modelo de uma RNA requer a definição das variáveis de entrada e saída, a escolha da arquitetura a ser empregada e sua topologia além dos treinamentos e testes que são pertinentes para se realizar o aprendizado supervisionado.

E. Modelos RNA

As duas RNA de classificação, referentes aos cenários de ataque e defesa, possuem a mesma arquitetura com uma camada de entrada com trinta e seis neurônios ($I_n, n \in Z : 1 \leq n \leq 36$), duas camadas escondidas, que de acordo com [41] são suficientes para criar regiões de classificação de qualquer forma desejada, com dezoito e nove neurônios respectivamente ($H_{1,18}$ e $H_{2,9}$) e uma camada de saída com um neurônio (O_a para o modelo de ataque e O_d para o modelo de defesa), conforme pode ser observado na Figura 2. A escolha da quantidade de neurônios das camadas escondidas foi feita testando diferentes configurações de topologia sendo que a de melhor desempenho foi no caso em que se utilizou sucessivos decréscimos pela metade do número de neurônios da camada anterior.

Todas as camadas possuem a função de ativação *Rectified Linear Unit* (ReLU) [42], com exceção da camada de saída que usa sigmóide para realizar a classificação binária desejada. Foi utilizado também a técnica de *Dropout* que elimina alguns neurônios/pesos em cada iteração com base em uma probabilidade de 20% [43] para evitar *overfitting* durante o treinamento do modelo. Além disso, o otimizador *Adaptive Moment Estimation* (Adam) foi empregado, um algoritmo de treinamento extremamente popular para RNA [44]. Adam é um método de gradiente descendente estocástico baseado na estimativa adaptativa da função de momentos de primeira e segunda ordem [45], que, em nosso caso, teve como objetivo minimizar a entropia cruzada, monitorada por um método de parada antecipada responsável por verificar se a métrica escolhida do conjunto de validação continuava a melhorar ao longo do processo de treinamento (a paciência, ou seja, o número de períodos de espera antes da parada precoce se nenhum progresso no conjunto de validação, foi definido como 25 épocas, que se mostrou adequado para o nível de ruído do processo de otimização do modelo).

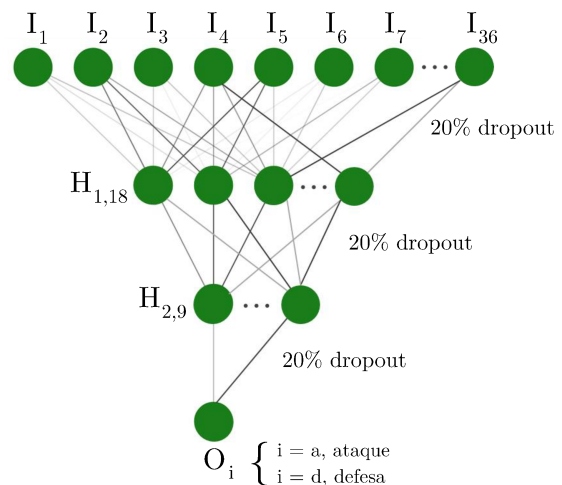


Fig. 2. Arquitetura de RNA proposta para os modelos de classificação de ataque e defesa.

Para a análise das RNAs, foram utilizadas as proporções de 85% para treinamento e validação e 15% para testes

dos conjuntos de dados de 10.000 amostras, onde cada uma representa uma simulação para os cenários de ataque e defesa simultaneamente. Nos dados de treinamento e validação foi utilizada a validação cruzada k -fold para que todas as observações fossem usadas para treinamento e validação e evitar possíveis ocorrências de *overfitting*. De acordo com [46], a escolha do número de *folds* não possui uma regra formal bem estabelecida, sendo que um maior valor de k leva a menores vieses com a contrapartida de aumentar o tempo computacional dos treinamentos. Dessa forma, foi utilizado $k = 5$, considerado um valor usual na literatura e que apresentou bons resultados. As métricas de desempenho utilizadas para avaliar as redes neurais artificiais de classificação foram a acurácia, precisão, sensibilidade e F1-score.

III. RESULTADOS E DISCUSSÕES

Nesta seção é demonstrado a análise de correlação dos dados do problema e as métricas dos modelos propostos.

A. Correlação

Observa-se na Tabela I que, devido à complexidade do problema de combate aéreo BVR, não há variáveis de entrada do modelo que tenha alguma correlação forte (positiva ou negativa) com as variáveis de saída da simulação, com exceção daquelas referentes à presença ou não de RWR na aeronave que apresentam valores levemente moderados de correlação negativa (por volta de $-0,38$) devido a sua influência na detecção de mísseis quando ativos e em direção ao alvo.

TABELA I
CORRELAÇÃO ENTRE AS VARIÁVEIS DE ENTRADA E DE SAÍDA DO MODELO.

	BM_RA ¹	RM_BA ²		BM_RA ¹	RM_BA ²
relative_position	-0,028	-0,034	blue_rwr	-0,019	-0,377
distance	-0,103	-0,093	red_rwr	-0,376	0,005
altitude_blue	0,051	-0,029	shotphi_blue_s	-0,233	0,135
altitude_red	-0,032	0,058	shotphi_blue_m	0,005	0,016
velocity_blue	0,031	-0,002	shotphi_blue_l	0,226	-0,149
velocity_red	0,012	0,030	shotphi_est_red_s	0,002	0,062
missile_blue_a	-0,096	0,034	shotphi_est_red_m	0,003	-0,015
missile_blue_b	-0,070	0,021	shotphi_est_red_l	-0,005	-0,047
missile_blue_c	0,165	-0,055	shotphi_red_s	0,141	-0,234
missile_est_red_a	0,001	0,030	shotphi_red_m	0,018	0,009
missile_est_red_b	-0,004	0,007	shotphi_red_l	-0,158	0,223
missile_est_red_c	0,004	-0,037	shotphi_est_blue_s	0,068	-0,005
missile_red_a	0,032	-0,092	shotphi_est_blue_m	-0,005	0,014
missile_red_b	0,038	-0,073	shotphi_est_blue_l	-0,063	-0,010
missile_red_c	-0,070	0,164	threshold_bfr_blue	0,022	0,036
missile_est_blue_a	0,019	0,003	threshold_aft_blue	-0,012	0,029
missile_est_blue_b	0,020	-0,001	threshold_bfr_red	0,047	0,035
missile_est_blue_c	-0,039	-0,002	threshold_aft_red	0,039	-0,026

¹ Mínima distância atingida entre o míssil azul e a aeronave vermelha.

² Mínima distância atingida entre o míssil vermelho e a aeronave azul.

Em vista dessas constatações, o fato de se tratar um problema não-linear de modelagem complexa contribuiu para a escolha do algoritmo de RNA para representar esse tipo de cenário operacional simulado, pois esse tipo de modelo de aprendizado de máquina supervisionado pode funcionar como um aproximador universal de funções [42].

B. Métricas

Utilizando o valor padrão de 0,5 como *threshold* para a sigmóide das camadas de saídas das duas RNA, é possível

observar na Tabela II os resultados médios de acurácia dos modelos de ataque e defesa que foram, respectivamente, 0,930 e 0,924. Observou-se que o conjunto de dados é desbalanceado, já que a classe minoritária, representada pelos casos de ataque bem sucedido do míssil, representa 15% dos casos em ambos os modelos. Dessa forma, a acurácia pode não ser a métrica mais adequada para a avaliação do modelo [47]. Contudo, caso o modelo fizesse sempre uma previsão para a classe minoritária, seria obtida uma acurácia de 0,851 e 0,848. Dessa forma, ainda é possível verificar uma melhoria dessa métrica com o modelo proposto de 0,079 e 0,076. Por outro lado, precisão, sensibilidade e a média harmônica destas duas métricas (F1-score) podem avaliar melhor essa base de dados [48].

Precisão apresentou os valores na média de 0,733 e 0,737 para os modelos de ataque e defesa respectivamente. Uma precisão baixa faz referência aos casos em que os modelos estão erroneamente informando que o míssil iria ter sucesso se fosse lançado, o que não aconteceria na realidade. Analisando em termos de custos associados ao combate, modelos com alta precisão são aconselhados para evitar disparos desnecessários de mísseis e manutenção da capacidade operacional da aeronave, já que há um limite para o número de mísseis a serem carregados na aeronave em um combate aéreo.

A métrica sensibilidade apresentou os valores médios de 0,703 para o modelo de ataque e 0,628 para o modelo de defesa. Baixos valores de sensibilidade estão relacionados aos casos em que o modelo sugere que o míssil não acertaria o alvo caso lançado em uma dada condição, recomendando que o disparo não seja efetuado, porém, na realidade, aquele míssil teria atingido o alvo com sucesso se fosse disparado. Como a neutralização do alvo é um fator muito importante no combate BVR, o não lançamento de um míssil que muito provavelmente atingiria um determinado alvo é um problema que deve ser evitado, o que mostra a importância de se ter uma alta sensibilidade. Observa-se que no modelo de defesa foi obtido uma sensibilidade mais baixa do que para o modelo de ataque, o que demonstra a dificuldade de se prever as possíveis ações da aeronave inimiga em um combate aéreo.

F1-score sintetiza de forma mais ampla a performance do modelo. Os valores obtidos foram de 0,717 e 0,678 para os modelos de ataque e defesa, respectivamente, e parecem promissores para analisar esse tipo problema, considerando a complexidade do combate BVR. Por fim, os valores de desvio padrão de todas as métricas ficaram muito baixos, com o máximo coeficiente de variação de 0,078, que é abaixo do limite de 0,3 definido por [49], mostrando a baixa variabilidade de resultados entre os *folds* analisados.

IV. CONSIDERAÇÕES FINAIS

Ao se analisar a aplicação demonstrada, vê-se que o modelo proposto foi capaz de representar a dinâmica básica do combate BVR, permitindo ao analista avaliar os parâmetros que influenciam o resultado do confronto entre as aeronaves. Além disso, é possível fornecer ao piloto uma estimativa de sua performance, referente a ataque ou defesa, no combate BVR. Essa perspectiva de como está ocorrendo o combate e a

TABELA II

MÉTRICAS DOS MODELOS DE ATAQUE / DEFESA EM CADA *fold* COM SUAS MÉDIAS E DESVIOS-PADRÃO.

	Acurácia	Precisão	Sensibilidade	F1-score
1 ^o <i>fold</i>	0,931 / 0,925	0,735 / 0,735	0,707 / 0,639	0,721 / 0,683
2 ^o <i>fold</i>	0,925 / 0,919	0,686 / 0,735	0,745 / 0,565	0,714 / 0,639
3 ^o <i>fold</i>	0,931 / 0,926	0,749 / 0,730	0,681 / 0,655	0,713 / 0,696
4 ^o <i>fold</i>	0,937 / 0,921	0,782 / 0,734	0,686 / 0,592	0,731 / 0,655
5 ^o <i>fold</i>	0,927 / 0,931	0,712 / 0,751	0,697 / 0,681	0,704 / 0,714
Média	0,930 / 0,924	0,733 / 0,737	0,703 / 0,628	0,717 / 0,678
Desvio	0,004 / 0,005	0,036 / 0,008	0,025 / 0,049	0,010 / 0,030

qualidade das ações tomadas é mensurada a partir do cálculo das distâncias atingidas pelos mísseis durante o combate. A modelagem considerou tanto as características da aeronave e dos armamentos possuídos, quanto às crenças a respeito da aeronave oponente. Também foi analisada a influência da filosofia de tiro estabelecida para cada aeronave, bem como o nível de aversão ao risco de seu piloto.

As modelagens das RNA foram realizadas para a situação do míssil atingindo distâncias mínimas de 10 metros do alvo e obteve-se valores acima de 0,92 de acurácia e de 0,67 de F1-score para os modelos de aprendizado supervisionado propostos. Dessa forma, demonstra-se que é possível, através de dados obtidos por meio de simulações construtivas, desenvolver ferramentas de apoio à decisão utilizando RNA que são capazes de melhorar a qualidade do voo em um combate aéreo do tipo BVR. Esse tipo de contribuição ajuda na efetividade das missões de ataque, de modo que armamentos não sejam utilizados de forma errônea e descuidada, e auxilia em missões de defesa, nas quais a sobrevivência do piloto é um fator determinante, diminuindo o número de aeronaves abatidas em combates reais.

Para trabalhos futuros, sugere-se a aplicação do modelo em cenários mais complexos com múltiplas aeronaves e com possibilidade de carregamento de vários mísseis e análise de sensibilidade e aderência da modelagem proposta. Além disso, uma outra sugestão seria obter uma maior eficiência de resposta do simulador BVR para que mais dados de simulação possam ser coletados de forma mais rápida e mais amostras possam ser geradas para realizar as análises propostas. Adicionalmente, a utilização de técnicas de aprendizado profundo parece ser promissor para melhoria dos resultados das RNA utilizadas no trabalho. Por fim, recomenda-se o desenvolvimento de estratégias que permitam a escolha de outras variáveis de saída, ou uma combinação delas, para a construção de métricas que demonstrem, de forma mais completa, uma determinada característica do cenário BVR, a qual pudesse ser utilizada para melhorar ainda mais a consciência situacional do piloto em voo.

AGRADECIMENTOS

Este trabalho contou com o apoio da Finep (Referência nº 2824/20). O Prof. Dr. Takashi Yoneyama é parcialmente financiado pelo CNPq - Conselho Nacional de Desenvolvimento Científico e Tecnológico (Processo nº 304134/2-18-0).

REFERÊNCIAS

- [1] L. C. P. Higby and U. Col, "Promise and reality: Beyond visual range (bvr) air-to-air combat," *Air War College (AWC) Electives Program: Air Power Theory, Doctrine, and Strategy: 1945–Present*, vol. 30, 2005.
- [2] B. Kurniawan, P. Vamplew, M. Papisimeon, R. Dazeley, and C. Foale, "An empirical study of reward structures for actor-critic reinforcement learning in air combat manoeuvring simulation," in *Australasian Joint Conference on Artificial Intelligence*, pp. 54–65, Springer, 2019.
- [3] K. Yuan, D. Liu, D. Jiang, Z. Zhang, and X. Lei, "Design of target aircraft auto air-combat tactics decision system," in *Theory, Methodology, Tools and Applications for Modeling and Simulation of Complex Systems*, pp. 288–296, Springer, 2016.
- [4] H. C. Marques, D. Geraldo, and L. H. Macêdo, "Arcabouço de Combate BVR - Plataforma de Apoio à Decisão e ao Treinamento de Pilotos," *Revista Spectrum*, n. 19, *Comando-Geral de Operações Aéreas*, Setembro 2015.
- [5] I. Jane's, "White Paper Fast Jet Cost Per Flight Hour (Cpfh)," 2012.
- [6] A. N. Costa, F. L. Medeiros, J. P. Dantas, D. Geraldo, and N. Y. Soma, "Formation control method based on artificial potential fields for aircraft flight simulation," *SIMULATION*, p. 00375497211063380, 2021.
- [7] A. N. Costa, R. L. Paes, M. Zawadzki, and D. Geraldo, "Scenario analysis as a decision-support tool: a maritime patrol case study," *Spectrum - Aplicações Operacionais Áreas de Defesa*, vol. 22, pp. 30–34, 2021.
- [8] A. G. Bruzzone and M. Massei, "Simulation-based military training," in *Guide to Simulation-Based Disciplines*, pp. 315–361, Springer, 2017.
- [9] J. P. Dantas, A. N. Costa, D. Geraldo, M. R. Maximo, and T. Yoneyama, "Engagement decision support for beyond visual range air combat," in *2021 Latin American Robotics Symposium (LARS), 2021 Brazilian Symposium on Robotics (SBR), and 2021 Workshop on Robotics in Education (WRE)*, pp. 96–101, IEEE, 2021.
- [10] J. Karelaiti, K. Virtanen, and T. Raivio, "Game optimal support time of a medium range air-to-air missile," *Journal of guidance, control, and dynamics*, vol. 29, no. 5, pp. 1061–1069, 2006.
- [11] K. Virtanen, J. Karelaiti, and T. Raivio, "Modeling air combat by a moving horizon influence diagram game," *Journal of guidance, control, and dynamics*, vol. 29, no. 5, pp. 1080–1091, 2006.
- [12] H. Mukai, A. Tanikawa, I. Tunay, I. Ozcan, I. Katz, H. Schättler, P. Rinaldi, G. Wang, L. Yang, and Y. Sawada, "Sequential linear-quadratic method for differential games with air combat applications," *Computational Optimization and Applications*, vol. 25, no. 1, pp. 193–222, 2003.
- [13] Y. Ma, G. Wang, X. Hu, H. Luo, and X. Lei, "Cooperative occupancy decision making of multi-uav in beyond-visual-range air combat: A game theory approach," *IEEE Access*, vol. 8, pp. 11624–11634, 2019.
- [14] J.-S. Ha, H.-J. Chae, and H.-L. Choi, "A stochastic game-based approach for multiple beyond-visual-range air combat," *Unmanned Systems*, vol. 6, no. 01, pp. 67–79, 2018.
- [15] J. Poropudas and K. Virtanen, "Analyzing air combat simulation results with dynamic bayesian networks," in *2007 winter simulation conference*, pp. 1370–1377, IEEE, 2007.
- [16] L. Fu, X. Long, and W. He, "Air combat assignment problem based on bayesian optimization algorithm," *Journal of Shanghai Jiaotong University (Science)*, pp. 1–7, 2021.
- [17] N. Rao, S. Kashyap, G. Gopalratnam, and D. Mandal, "Situation and threat assessment in bvr combat," in *AIAA Guidance, Navigation, and Control Conference*, p. 6241, 2011.
- [18] P. Du and H.-y. Liu, "Study on air combat tactics decision-making based on bayesian networks," in *2010 2nd IEEE International Conference on Information Management and Engineering*, pp. 252–256, IEEE, 2010.
- [19] S. Akabari, M. B. Menhaj, and S. Nikravesh, "Fuzzy modeling of offensive maneuvers in an air-to-air combat," in *Computational Intelligence, Theory and Applications*, pp. 171–184, Springer, 2005.
- [20] C. Tran, A. Abraham, and L. Jain, "Adaptation of a mamdani fuzzy inference system using neuro-genetic approach for tactical air combat decision support system," in *Australian Joint Conference on Artificial Intelligence*, pp. 672–680, Springer, 2002.
- [21] A. Prabhu, H. Manivannan, K. Sridhar, S. Ahmed, and L. Shrinivasan, "Decision fusion using type-1 fuzzy logic for situation assessment in aviation scenarios," in *2014 International Conference on Advances in Electronics Computers and Communications*, pp. 1–6, IEEE, 2014.
- [22] C. Heinze, B. Smith, and M. Cross, "Thinking quickly: Agents for modeling air warfare," in *Australian Joint Conference on Artificial Intelligence*, pp. 47–58, Springer, 1998.

- [23] Z. Lin, T. Ming'an, Z. Wei, and Z. Shengyun, "Sequential maneuvering decisions based on multi-stage influence diagram in air combat," *Journal of Systems Engineering and Electronics*, vol. 18, no. 3, pp. 551–555, 2007.
- [24] D. Hu, R. Yang, J. Zuo, Z. Zhang, J. Wu, and Y. Wang, "Application of deep reinforcement learning in maneuver planning of beyond-visual-range air combat," *IEEE Access*, vol. 9, pp. 32282–32297, 2021.
- [25] A. Toubman, J. J. Roessingh, P. Spronck, A. Plaat, and J. van den Herik, "Rapid adaptation of air combat behaviour," in *Proceedings of the Twenty-Second European Conference on Artificial Intelligence, ECAI'16*, (NLD), p. 1791–1796, IOS Press, 2016.
- [26] H. Piao, Z. Sun, G. Meng, H. Chen, B. Qu, K. Lang, Y. Sun, S. Yang, and X. Peng, "Beyond-visual-range air combat tactics auto-generation by reinforcement learning," in *2020 International Joint Conference on Neural Networks (IJCNN)*, pp. 1–8, IEEE, 2020.
- [27] Y. Weilin, D. Wei, P. Shuangchun, X. Yu, and P. Liang, "Decision-making of one-on-one beyond-visual-range air combat based on improved q-network," in *2018 IEEE International Conference on Mechatronics and Automation (ICMA)*, pp. 809–815, IEEE, 2018.
- [28] G. Li, Y. Wang, C. Lu, and Z. Zhang, "Multi-uav air combat weapon-target assignment based on genetic algorithm and deep learning," in *2020 Chinese Automation Congress (CAC)*, pp. 3418–3423, IEEE, 2020.
- [29] Z. Yang, D. Zhou, H. Piao, K. Zhang, W. Kong, and Q. Pan, "Evasive maneuver strategy for ucav in beyond-visual-range air combat based on hierarchical multi-objective evolutionary algorithm," *IEEE Access*, vol. 8, pp. 46605–46623, 2020.
- [30] Y. Kang, Z. Liu, Z. Pu, J. Yi, and W. Zu, "Beyond-visual-range tactical game strategy for multiple uavs," in *2019 Chinese Automation Congress (CAC)*, pp. 5231–5236, IEEE, 2019.
- [31] J. Yao, Q. Huang, and W. Wang, "Adaptive cgfs based on grammatical evolution," *Mathematical Problems in Engineering*, vol. 2015, 2015.
- [32] I. N. Da Silva, D. H. Spatti, R. A. Flauzino, L. H. B. Liboni, and S. F. dos Reis Alves, "Artificial neural network architectures and training processes," in *Artificial neural networks*, pp. 21–28, Springer, 2017.
- [33] "https://youtu.be/o3huzycjdda,"
- [34] J. P. A. Dantas, A. N. Costa, V. C. F. Gomes, A. R. Kuroswski, F. L. L. Medeiros, and D. Geraldo, "ASA: A Simulation Environment for Evaluating Military Operational Scenarios," in *The 20th International Conference on Scientific Computing (CSC'22)*, The 2022 World Congress in Computer Science, Computer Engineering & Applied Computing (CSCE'22), 2022.
- [35] A. N. Costa, "Sequential Optimization of Formation Flight Control Method Based on Artificial Potential Fields," Master's Thesis, Instituto Tecnológico de Aeronáutica, São José dos Campos, SP, Brazil, 2019.
- [36] J. P. A. Dantas, "Apoio à decisão para o combate aéreo além do alcance visual: uma abordagem por redes neurais artificiais," Master's Thesis, Instituto Tecnológico de Aeronáutica, São José dos Campos, SP, Brazil, 2018.
- [37] J. P. A. Dantas, A. N. Costa, D. Geraldo, M. R. A. O. Maximo, and T. Yoneyama, "Weapon engagement zone maximum launch range estimation using deep neural network," in *Intelligent Systems (A. Britto and K. Valdivia Delgado, eds.)*, vol. 13074 of *Lecture Notes in Computer Science*, Springer, Cham., 2021.
- [38] F. A. Administration, *Airplane Flying Handbook*. Oklahoma City, OK: United States Department of Transportation, Airman Testing Standards Branch, 2021.
- [39] M. McKay, R. Beckman, and W. Conover, "A Comparison of Three Methods for Selecting Values of Input Variables in the Analysis of Output from a Computer Code," *Technometrics*, vol. 21, no. 2, pp. 239–245, 1979.
- [40] M. R. Endsley, "Toward a Theory of Situation Awareness in Dynamic Systems," *Human Factors: The Journal of the Human Factors and Ergonomics Society*, vol. 37, no. 1, pp. 32–64, 1995.
- [41] R. Lippmann, "An introduction to computing with neural nets," *IEEE ASSP Magazine*, vol. 4, no. 2, pp. 4–22, 1987.
- [42] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2016. <http://www.deeplearningbook.org>.
- [43] G. E. Hinton, N. Srivastava, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Improving neural networks by preventing co-adaptation of feature detectors," *ArXiv*, vol. abs/1207.0580, 2012.
- [44] S. Bock and M. Weiß, "A proof of local convergence for the adam optimizer," in *2019 International Joint Conference on Neural Networks (IJCNN)*, pp. 1–8, IEEE, 2019.
- [45] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *arXiv preprint arXiv:1412.6980*, 2014.
- [46] M. Kuhn, K. Johnson, *et al.*, *Applied predictive modeling*, vol. 26. Springer, 2013.
- [47] G. Menardi and N. Torelli, "Training and assessing classification rules with imbalanced data," *Data mining and knowledge discovery*, vol. 28, no. 1, pp. 92–122, 2014.
- [48] L. A. Jeni, J. F. Cohn, and F. De La Torre, "Facing imbalanced data—recommendations for the use of performance metrics," in *2013 Humaine Association Conference on Affective Computing and Intelligent Interaction*, pp. 245–251, 2013.
- [49] C. E. Brown, "Coefficient of variation," in *Applied multivariate statistics in geohydrology and related sciences*, pp. 155–157, Springer, 1998.



Joao P. A. Dantas received his B.Sc. degree in Mechanical-Aeronautical Engineering (2015) and his M.Sc. degree in Electronic and Computer Engineering (2018) from the Aeronautics Institute of Technology (ITA), Brazil. Currently, he is pursuing his Ph.D. degree at ITA and working as a researcher for the Brazilian Air Force at the Institute for Advanced Studies and the Robotics Institute at Carnegie Mellon University. His research interests include Simulation, Machine Learning, and Robotics.



Marcos R. O. A. Maximo received the B.Sc. degree (Hons.) (summa cum laude) in Computer Engineering (2012), and the M.Sc. (2015) and Ph.D. (2017) degrees in Electronic and Computer engineering from the Aeronautics Institute of Technology (ITA), Brazil. He is currently a Professor at ITA, being a member of the Autonomous Computational Systems Laboratory (LAB-SCA) with research interests in Robotics and Artificial Intelligence.



Andre N. Costa received his B.Sc. degree in Mechanical-Aeronautical Engineering (2014) and his M.Sc. degree from the Graduate Program in Electronic and Computer Engineering (2019) from the Aeronautics Institute of Technology, Brazil. Currently, he is a researcher for the Brazilian Air Force at the Institute for Advanced Studies with research interests in Modeling & Simulation and Machine Learning.



Diego Geraldo was commissioned in 2005 as a graduate of the Brazilian Air Force (FAB) Academy and a fighter pilot in 2006. He received his M.Sc. degree from the Graduate Program in Aeronautical and Mechanical Engineering at the Aeronautics Institute of Technology in 2012. Since then he has been a researcher for FAB at the Institute for Advanced Studies, focusing on Modeling & Simulation and Artificial Intelligence.



Takashi Yoneyama received the bachelor's degree in Electronic Engineering from the Aeronautics Institute of Technology (ITA), Brazil, in 1975, the M.D. degree in Medicine from the Taubate University, Brazil, in 1993, and the Ph.D. degree in Electrical Engineering from the Imperial College London, U.K., in 1983. He is a Professor of Control Theory with the Department of Electronic at ITA. His research is focused on Stochastic Optimal Control Theory.