



ESCOLA DE COMANDO E ESTADO-MAIOR DA AERONÁUTICA
COORDENADORIA ACADÊMICA
CURSO AVANÇADO DE COMANDO E ESTADO-MAIOR

HENRIQUE **EDUARDO** DE MACEDO, Ten Cel Av

**Redes neurais artificiais e a Ação de Vigilância Aérea com sistemas de aeronaves
remotamente pilotadas**

Rio de Janeiro

2022

ESCOLA DE COMANDO E ESTADO-MAIOR DA AERONÁUTICA
COORDENADORIA ACADÊMICA
CURSO AVANÇADO DE COMANDO E ESTADO-MAIOR

HENRIQUE **EDUARDO** DE MACEDO, Ten Cel Av

**Redes neurais artificiais e a Ação de Vigilância Aérea com sistemas de aeronaves
remotamente pilotadas**

Trabalho de conclusão de curso apresentado,
como requisito parcial para aprovação, no
Curso Avançado de Comando e Estado-Maior.
Linha de Pesquisa: Poder Aeroespacial.
Orientador: Davi Affonso da Silva.

Rio de Janeiro
2022

RESUMO

Esta pesquisa procurou determinar quais os principais aspectos da ação de Vigilância Aérea são influenciados pelo emprego de redes neurais artificiais na detecção de alvos móveis em imagens infravermelhas obtidas com sistemas de aeronaves remotamente pilotadas (SARP). Recorrendo a uma pesquisa bibliográfica, foram levantadas informações sobre possíveis impactos sobre a ação de Vigilância Aérea na Força Aérea Brasileira. Esta ação emprega principalmente SARPs para a detecção de alvos. Foram inicialmente destacados impactos gerais, assim como, vantagens e desvantagens do uso das redes neurais para essa atividade. Posteriormente, foram analisados os resultados obtidos com imagens reais de sensores em atividade na Força Aérea. Em seguida, foram verificadas as necessidades de *hardware* específico para o uso das redes neurais, seu custo-benefício e opções de uso. Ao final, foram observadas as possíveis consequências na adoção dessa tecnologia tanto da demanda de pessoal qualificado quanto na formação de novos operadores de sensores de SARP. Como resultado, foi verificado que a adoção de redes neurais artificiais para detecção de alvos em sistemas de aeronaves remotamente pilotadas, apesar de algumas desvantagens, pode trazer inúmeros benefícios operacionais, como uma alta taxa de acerto, mesmo com alvos múltiplos, e ainda, a possibilidade de uso em aplicações em tempo real. Entretanto, para sua implantação com sucesso há a necessidade de planejamento prévio para atender as demandas de *hardware* adequado e de recursos humanos bem treinados.

Palavras-chave: detecção de alvos; SARP; redes neurais; inteligência artificial.

ABSTRACT

This research sought to determine which aspects of Surveillance missions are impacted by using artificial neural networks to detect moving targets in infrared images obtained with remotely piloted aircraft system (RPAS). Using bibliographic research, information was gathered about possible impacts on Surveillance missions in the Brazilian Air Force. This mission most often employs RPAS for target detection. Initially, general consequences were highlighted, as well as the advantages and disadvantages of using neural networks for this activity. Subsequently, the results obtained in actual images of sensors in activity in the Air Force were analyzed. Then, the specific hardware needs for the use of neural networks, their cost-benefit and usage options were verified. In the end, the possible consequences of adopting this technology were observed regarding the demand for qualified personnel and training of new operators of RPAS sensors. As a result, it was verified that adopting artificial neural networks for target detection in remotely piloted aircraft systems, despite some disadvantages, can bring numerous operational benefits, such as a high performance, even with multiple targets, and the possibility of use in real-time applications. However, for its successful implementation there is a need for previous actions to meet the demands of adequate hardware and well-trained human resources.

Keywords: target detection; RPAS; neural networks; artificial intelligence.

LISTA DE ILUSTRAÇÕES

Figura 1 – Classificação e localização.....	15
Figura 2 – Detecção.....	15
Figura 3 – Perceptron de Rosenblatt.....	17
Figura 4 – Exemplo de rede neural formada por várias camadas.....	17
Figura 5 – Exemplo de gráfico precisão x recall.....	19
Figura 6 – Evolução taxa de erro no ILSVRC.....	23
Figura 7 – Detecção alvos múltiplos com RNA.....	25

LISTA DE TABELAS

Tabela 1 – Resultados de precisão e velocidade rede YOLO.....	24
---	----

LISTA DE ABREVIATURAS E SIGLAS

CNN	Convolutional Neural Network
Convnet	Convolutional Neural Network
Dataset	Conjunto de dados
FAB	Força Aérea Brasileira
GPU	Graphics Processing Unit
IA	Inteligência Artificial
ILSVRC	ImageNet Large Scale Visual Recognition Challenge
ISR	Intelligence, Surveillance and Reconnaissance
ISTAR	Intelligence, Surveillance, Target Acquisition, and Reconnaissance
MCA	Manual do Comando da Aeronáutica
NIIRS	National Imagery Interpretability Rating Scale
RNA	Rede Neural Artificial
SAR	Synthetic Aperture Radar
SARP	Sistema de Aeronaves Remotamente Pilotadas
Vig Ae	Vigilância Aérea

SUMÁRIO

1	INTRODUÇÃO.....	9
2	METODOLOGIA.....	11
3	REFERÊNCIAL TEÓRICO	13
3.1.	Detecção.....	13
3.2.	Redes neurais	16
3.3.	Métrica empregada	18
4	ANÁLISE.....	20
4.1.	Capacidades e desafios	20
4.2.	Desempenho na detecção de alvos móveis	22
4.3.	Requisitos de <i>Hardware</i>	25
4.4.	Recursos Humanos	27
5	CONCLUSÃO.....	29
	REFERÊNCIAS.....	31

1 INTRODUÇÃO

Na época contemporânea, a inovação tornou-se o ideal onipresente em todas as áreas do conhecimento. A cada nova descoberta e aperfeiçoamento, a forma como as atividades humanas são realizadas pode ser alterada profundamente.

Novas fronteiras de conhecimento como ciência de dados, *blockchain*, computação distribuída e inteligência artificial (IA) vêm chamando a atenção dos governos pelos bons resultados e têm provocado disputas de poder entre as maiores potências do mundo.

A inteligência artificial, mais especificamente a subárea do aprendizado profundo, tem prosperado em muitos domínios diferentes, como visão computacional e compreensão de linguagem natural.

Pode-se afirmar que os motores para esse desenvolvimento da aprendizagem profunda tem sido a disponibilidade de dados abundantes, as descobertas de algoritmos e os avanços em *hardware* (FINK et al., 2020).

Apresentando o potencial de construir agentes capazes de simular o raciocínio humano, a IA atualmente é um campo próspero em aplicações que impactam de forma radical a rotina diária das pessoas. Algoritmos dessa classe são capazes, por exemplo, de entender a linguagem humana e reconhecer com grande precisão rostos ou objetos em imagens.

Ainda sobre as técnicas de inteligência artificial na detecção de objetos em imagens, é perceptível o uso amplo e intenso das redes neurais artificiais (RNA) devido aos excelentes resultados obtidos, já tendo, inclusive, superado os humanos nessa tarefa.

Por conseguinte, os ganhos originados do emprego dos algoritmos de IA baseados em RNA podem contribuir para o aumento da eficiência operacional em várias ações de Força Aérea, em especial, na ação de Vigilância Aérea em relação à análise das imagens obtidas.

Sobre ação de vigilância aérea, a definição adotada por esse trabalho será a constante na Doutrina Básica da Força Aérea Brasileira (FAB), transcrita abaixo:

A ação de Vigilância Aérea (Vig Ae) é a ação que consiste em empregar meios aeroespaciais e de Força Aérea para detectar, identificar, acompanhar, coletar e difundir informações da área de interesse, por meio da coleta de sinais e imagens de um alvo específico ou não, em tempo real (BRASIL, 2020, p. 37).

Atualmente, a Força Aérea Brasileira cumpre essa ação priorizando as imagens do espectro infravermelho juntamente com o emprego de sistemas de aeronaves remotamente pilotadas (SARP). A possibilidade dos sensores na faixa do infravermelho de obterem imagens com alta qualidade, inclusive à noite, aliada com a capacidade de permanência dos SARP por longos períodos de voo justificam essa decisão.

Devido à sua importância, a ação de vigilância aérea tem alta prioridade no contexto da guerra atual. Os sensores mais modernos utilizados têm capacidade de geração de uma grande quantidade de informação útil. Essa característica torna a atividade de detecção de alvos uma tarefa não-trivial para os operadores desses sistemas.

Esse obstáculo vem ao encontro das capacidades dos algoritmos de IA projetados para visão computacional. Esses algoritmos podem ser treinados para a detecção de padrões de interesse em imagens mesmo em conjuntos de dados volumosos. Além disso, suportam uma alta taxa de fluxo de informações, ou seja, também podem ser usados para a análise de vídeos em tempo real.

Sua aplicação em conflitos é uma tendência natural para as forças militares ao redor do mundo. Entretanto, apesar das boas perspectivas, sua aplicação nas missões realizadas pela Força Aérea Brasileira ainda é carente de uma análise mais aprofundada.

Deste modo, considerando essa necessidade, surgiu a oportunidade de elaborar o seguinte problema de pesquisa descrito abaixo:

Qual a influência do emprego de redes neurais artificiais na detecção de alvos móveis em imagens infravermelhas obtidas em sistemas de aeronaves remotamente pilotadas na FAB?

Para dirimir as dúvidas originadas pelo problema de pesquisa faz-se necessário definir questões norteadoras, conforme proposto abaixo:

- 1) Quais as capacidades atuais das redes neurais artificiais quando empregadas na detecção de alvos móveis em imagens infravermelhas obtidas por meio de SARP?
- 2) Quais as necessidades em termos de *hardware* para a implementação dessas técnicas em Unidades Operacionais da FAB?
- 3) Qual a consequência da sua implantação sobre os Recursos humanos envolvidos na ação de Vigilância Aérea?

Adicionalmente, considerando o problema e as questões norteadoras levantadas, o objetivo geral desta pesquisa é determinar quais os principais aspectos da ação de Vigilância Aérea são influenciados pelo emprego de redes neurais artificiais para detecção de alvos móveis em imagens infravermelhas obtidas com SARP.

Em complemento, este estudo possui como objetivos específicos:

OE1 – Identificar as possibilidades das redes neurais artificiais quando empregadas na detecção de alvos móveis em imagens infravermelhas na FAB;

OE2 – Elencar as necessidades materiais (*hardware*) para a implementação dessas técnicas em Unidades Operacionais da FAB; e

OE3 – Identificar o impacto da implantação das RNAs sobre os Recursos humanos envolvidos na ação de Vigilância Aérea.

Após inicialmente substituir as tarefas físicas e repetitivas, a automação proporcionada pela IA agora se apresenta como opção ao ser humano em tarefas que exigem conhecimento e aprendizado. Por conseguinte, é essencial reconhecer quais são seus possíveis impactos positivos e negativos nos conflitos armados.

2 METODOLOGIA

Conforme as definições apresentadas por Gil (2002), o estudo em tela pode ser considerado, quanto aos objetivos, como uma pesquisa exploratória, pois há intenção de aprimorar ideias e aumentar o conhecimento sobre o tema.

A metodologia proposta, quanto aos procedimentos técnicos é baseada em um levantamento da literatura já existente sobre o assunto. Adicionalmente, dentro das leituras realizadas, foi dado destaque a trabalhos e dados disponíveis de aplicações vinculadas ao âmbito militar para a ampliação do suporte necessário.

Desse modo, esta pesquisa tem a pretensão de delinear as consequências mais relevantes do emprego das redes neurais artificiais na detecção de alvos móveis apontadas com base em outros estudos, preferencialmente militares, e verificar sua semelhança com possíveis aplicações com SARPs na Força Aérea Brasileira. Dessa maneira, pode-se também classificá-la como qualitativa.

Os principais autores e publicações citados nesta pesquisa relativamente às definições sobre detecção de objetos em imagens foram John Johnson e o *National Imagery Interpretability Rating Scale*. O destacável critério de Johnson até hoje ainda está presente em muitas aplicações de relevância. Já as definições *National Imagery Interpretability Rating Scale*, pelo fato abarcarem tipos mais modernos de sensores, estão se tornando padrão na área da análise de imagens de inteligência.

Adicionalmente, os conhecimentos necessários sobre redes neurais artificiais foram baseados principalmente nas teorias de Frank Rosenblatt, um psicólogo notável no campo da inteligência artificial, também conhecido como pai do aprendizado profundo. Foram utilizados, ainda, alguns conceitos de Ian J. Goodfellow e Yoshua Bengio, ambos cientistas da computação amplamente conhecidos por trabalhos em redes neurais artificiais e aprendizado profundo.

Num primeiro momento, foi buscada a definição formal da atividade de detecção de alvos. Para tanto, foi necessário conciliar a definição de detecção empregada pela Força Aérea Brasileira com o conceito usado pela área de visão computacional.

Neste intuito, foram pesquisadas duas fontes recorrentemente citadas na FAB. Inicialmente, foi estudado o critério desenvolvido por Johnson (1985) que demonstrou os requisitos de resolução mínima em imagens para a execução das tarefas de detecção, orientação, reconhecimento e identificação de imagens.

Em seguida, foram consideradas as classificações e definições do *Civil National Imagery Interpretability Rating Scale* (NIIRS). O NIIRS (1996), diferentemente de Johnson, estabeleceu apenas três tarefas possíveis na análise de imagens: detecção, diferenciação e identificação.

Embora sejam de grande relevância os estudos de Johnson, esta pesquisa decidiu pela adoção das definições e termos do NIIRS, devido a sua previsão para classes de diversos tipos de imagens como o infravermelho.

A respeito da técnica de coleta de dados, as fontes de pesquisa empregadas foram os sites científicos Science Direct, o Scielo, assim como o Google acadêmico. Também foram pesquisados textos exclusivamente doutrinários como os manuais da aviação de Reconhecimento, encarregada na FAB pela execução da ação de Vigilância Aérea.

Como palavras-chaves para a pesquisa de conteúdo em sites de busca foram admitidos os seguintes termos: inteligência, artificial, convnet, ia, RNA, militar, aplicações, alvos, detecção, móvel, redes neurais, impactos, trabalho e produtividade, dentre outros. Todas as palavras-chaves usadas também foram empregadas juntamente com o seu similar na língua inglesa para ampliar o escopo da busca.

A partir do primeiro objetivo, foi dado início a análise das capacidades e desafios atuais da IA, especificamente as RNAs, quando empregadas na detecção de alvos móveis em imagens de SARP. Dessa forma, com objetivo de mensurar essas capacidades, foram considerados os seguintes itens para serem observados pelo processo de detecção da rede neural: a exatidão da detecção e a velocidade média de processamento de imagens entregue pelo algoritmo.

Para mensurar a capacidade de detecção de alvos dos algoritmos de IA, foram utilizados os resultados obtidos por Macedo (2020) em seu trabalho sobre detecção de alvos com redes neurais artificiais em imagens infravermelhas. Em seu trabalho, Macedo propôs o treinamento de uma rede neural de detecção de alvos móveis com um *dataset* composto de imagens do espectro infravermelho provenientes de missões reais realizadas por uma Unidade Aérea da FAB.

Todas as imagens foram geradas pelo mesmo tipo de sensor infravermelho e nas mesmas configurações. As amostras foram selecionadas procurando-se incluir imagens de diversos horários do dia e com alvos sendo imageados de vários ângulos e altitudes.

Sobre o segundo objetivo, com referência aos requisitos de *hardware* para implementação dessas técnicas, houve a necessidade de delimitar as atividades de treinamento e inferência das redes neurais. Ambas são atividades essenciais, todavia executadas em momentos distintos e com grande diferença na demanda por processamento computacional. Operacionalmente, a maior importância repousa na atividade de inferência.

A atividade de treinamento está relacionada ao processo de ajustes aplicado de forma iterativa aos pesos da rede até a obtenção de uma solução generalizada para o tipo do problema proposto. Após os ajustes, a rede está pronta para realizar a inferência que se trata da aplicação prática da rede na resolução de problemas.

Em seguida, foi verificada, dentre as arquiteturas de redes neurais disponíveis para a visão computacional, qual a necessidade típica de processamento para o seu emprego em uma atividade de detecção em tempo real.

Já com intuito de satisfazer o último objetivo, para as discussões a respeito da influência da detecção de alvos utilizando RNA sobre os recursos humanos na ação de Vigilância Aérea, foram discutidos os pontos de vista apresentados por Horowitz (2018), Cummings (2017), Daugherty (2017) e Souza (2018). Dessa forma, foi possível inferir a relação entre a automação proporcionada pelos algoritmos e as alterações na formação de pessoal.

No que concerne os limites desse estudo, é importante destacar que nem sempre os dados de aplicações militares estão disponíveis para acesso do público. Desse modo, formas de emprego e resultados importantes podem permanecer muito tempo sem visibilidade em centros de pesquisa. Além disso, o emprego a inteligência artificial ainda se encontra no início e muito do que é esperado dela na resolução de problemas pode não se concretizar.

3 REFERÊNCIAL TEÓRICO

3.1. Detecção

A detecção de alvos é de grande importância dentro da ação de Vigilância Aérea. Apesar disso, há carência de uma definição mais formal dessa atividade nos manuais militares da Força Aérea Brasileira.

Recorrentemente, são citados em trabalhos o critério desenvolvido por Johnson (1985) ao elencar as tarefas de detecção, orientação, reconhecimento e identificação de imagens.

Apesar do seu grande impacto inicial na área, não houve com o tempo uma atualização do critério para incluir outros tipos de imagem. Por exemplo, não há suporte para imagens produzidas por sensores na faixa do espectro infravermelho ou imagens SAR (*Synthetic Aperture Radar*).

Por outro lado, a *National Imagery Interpretability Rating Scale* (NIIRS) é uma escala baseada em níveis de riqueza de detalhes com capacidade de classificar imagens adquiridas de vários tipos de sistemas de imagens. Ela possui mais classes em seu conjunto, com previsão inclusive para o espectro infravermelho.

O NIIRS foi criado pela comunidade de Inteligência dos Estados Unidos da América e tornou-se rapidamente um padrão usado por diversos analistas de imagens, gerentes de coleção, cientistas de imagens e projetistas de sensores. O NIIRS inicial foi desenvolvido por uma iniciativa governamental e privada no início da década de 1970 (IRVINE, 1997).

As imagens no NIIRS são classificadas em níveis de 0 a 9, conforme a facilidade de identificação dos alvos como, por exemplo, instalações ou automóveis. Uma imagem no nível 0 configura uma amostra totalmente obscura. Por outro lado, uma amostra nível 9 é possuidora de grande clareza e riqueza de detalhes.

Inicialmente focado em imagens de equipamentos militares, o NIIRS foi expandido para incluir também a análise de imagens resultantes de tarefas executadas em atividades com finalidade de aplicação civil (IRVINE, 1997). Numa visão díspar de Johnson (1985), o NIIRS elencou os seguintes termos usados extensivamente na definição dos seus critérios: detectar, distinguir e identificar.

De acordo com o NIIRS (1996), a detecção pode ser descrita como a capacidade de encontrar ou descobrir a presença ou existência de uma instalação, objeto, atividade ou item de interesse, com base em sua forma geral e em outras informações contextuais na cena. Algum nível de identificação está implícito na detecção, para que o recurso detectado possa ser nomeado adequadamente.

Já na área da visão computacional, campo essencialmente prático, a definição apresentada é levemente diferente, entretanto, convergente com o conteúdo exposto até o momento. Como tarefas da visão computacional as mais importantes são a classificação, localização e identificação, e por fim, a detecção.

A classificação envolve o processamento de uma imagem e fornecimento de um rótulo, por exemplo, classificá-la com o rótulo de aeronave, blindado ou instalação militar. A localização e identificação envolve a tarefa adicional de demarcar a posição do alvo na imagem por meio de uma caixa delimitadora, conforme Figura 1.

Figura 1 – Classificação e localização



Fonte: Autor

Já a detecção requer a classificação e a localização de um ou mais alvos, de um ou mais tipos (ex. automóveis, blindados, etc.) conforme ilustrado na Figura 2. Por conseguinte, há a demanda por algoritmos mais refinados e mais poder de processamento.

Figura 2 – Detecção



Fonte: Autor

É possível ainda citar Zhang (2019) e definir a atividade de detecção como meramente reconhecer o objeto com caixa delimitadora na imagem, onde, na classificação de imagem, pode-se simplesmente categorizar (classificar) que é um determinado objeto na imagem, ou não, em termos de probabilidade.

No mesmo sentido, pode ser adotada a definição do *ImageNet Large Scale Visual Recognition Challenge (ILSVRC)*, competição internacional para avaliação do progresso de algoritmos nas tarefas de classificação e detecção de objetos em imagens.

Para o ILSVRC, a detecção de objetos em imagens ocorre quando algoritmos produzem uma lista de categorias de objetos presentes na imagem juntamente com uma caixa delimitadora alinhada ao eixo da imagem indicando a posição e escala de cada instância de cada categoria de objeto (RUSSAKOVSKY et al., 2015).

Embora originadas de campos diferentes, pode-se perceber que as definições apresentadas não se contradizem, ao contrário, se complementam. Dessa forma, a definição encontrada no NIIRS e o padrão de avaliação utilizado pelo ILSVRC podem ser adotados conjuntamente de forma complementar.

Após a definição do conceito de detecção de alvos móveis proposto nesta seção, há a necessidade de promover esclarecimentos acerca das redes neurais artificiais e de como elas podem ser empregadas na detecção de alvos móveis em imagens.

3.2. Redes neurais

Nos últimos anos, a inteligência artificial tem sido objeto de intensa publicidade na mídia. O aprendizado de máquina e o aprendizado profundo, ambos campos da IA, aparecem em inúmeros artigos, muitas vezes fora de publicações voltadas para a área de tecnologia (GOODFELLOW; BENGIO; COURVILLE, 2016).


Dentro do vasto campo da inteligência artificial, os tipos de algoritmos de IA mais proeminentes hoje são os que empregam redes neurais artificiais. As redes neurais artificiais são compostas de neurônios artificiais dispostos em camadas que acumulam conhecimento pelo paradigma do aprendizado supervisionado.

O aprendizado supervisionado é um padrão de treinamento que utiliza um conjunto de dados de entrada acompanhados com as suas respectivas saídas esperadas, também chamadas de rótulos. No decorrer do treinamento, os rótulos funcionam como críticos da rede neural. A cada iteração (ciclo) do treino, as saídas obtidas pela rede são comparadas com os rótulos. Dessa forma, é possível mensurar a taxa de acerto e implementar modificações na rede para obtenção de uma taxa de erro menor.

Conforme Chollet (2018), atualmente, quase todas as aplicações de aprendizado profundo que estão em destaque pertencem a essa classe, como as aplicações para reconhecimento óptico de caracteres, reconhecimento de fala e classificação de imagens, entre outras.

A base pioneira desses avanços foi o primeiro neurônio artificial, chamado de *perceptron*. Ele foi criado por Rosenblatt (1958) inspirado no trabalho de McCulloch e Pitts. Um neurônio artificial consiste basicamente de um conjunto de pesos (w) para cada entrada (x) e um viés (b), sendo que w e b são ajustados durante o treinamento da rede. A soma resultante do viés com o produto das entradas pelos pesos é aplicada a uma função de ativação (λ), constituindo a saída da rede, conforme descrito na Figura 3.

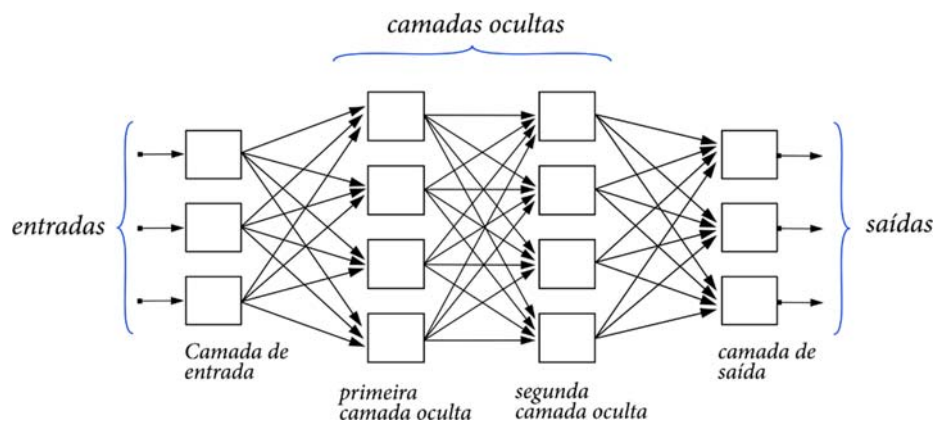
Figura 3 – Perceptron de Rosenblatt



Fonte: Adaptado de Haykin (2009, p. 48)

Para aumentar sua capacidade de aprender e reter padrões complexos, o próximo passo foi dispor os neurônios em camadas e interligar cada neurônio de uma camada com todos os demais neurônios da camada seguinte, conforme Figura 4.

Figura 4 – Exemplo de rede neural formada por várias camadas



Fonte: Adaptado de Haykin (2009, p. 124)

Essa estrutura é convencionalmente chamada de *perceptron* multicamadas. Nessa disposição, além das camadas de entrada e de saída, há ainda as camadas internas que são também referidas como camadas ocultas.

A possibilidade de acumular camadas sucessivas impactou a grande maioria dos estudos relevantes na área ao propiciar o surgimento do processo de aprendizado profundo. No aprendizado profundo, cada camada da rede neural aprende conceitos mais complexos a partir de conceitos mais simples da camada anterior.

O aprendizado profundo pode ser definido como um tipo particular de técnica de IA que alcança grande poder e flexibilidade ao representar o mundo como uma hierarquia aninhada de conceitos, com cada conceito definido em relação a conceitos mais simples e mais abstratos (GOODFELLOW; BENGIO; COURVILLE, 2016).

Devido a essas características, as técnicas de aprendizagem profunda têm sido utilizadas em diversas aplicações como processamento de linguagem natural, reconhecimento facial, classificação de doenças, carros autônomos, sistemas de recomendação, detecção de fraudes

financeiras e visão computacional.

Nesse último campo em especial, temos as redes neurais convolucionais (CNN, ou ConvNet). De acordo com Goodfellow (2016), as redes convolucionais são um tipo especializado de rede neural para processamento de dados que possuem uma topologia em grade. Os exemplos incluem dados de séries temporais e dados de imagem. Este último pode ser considerado como uma grade 2-D de pixels. As redes convolucionais têm sido tremendamente bem-sucedidas em aplicações práticas.

Uma rede neural convolucional pode ser definida ainda como um perceptron multicamadas projetado especificamente para reconhecer formas bidimensionais com um alto grau de invariância à translação, redimensionamento, inclinação e outras formas de distorção (HAYKIN et al., 2009).

3.3. Métrica empregada

Para o correto entendimento deste trabalho, será explicitada a métrica utilizada para mensurar a capacidade dos algoritmos voltados à detecção de alvos em imagens. A sua clara compreensão irá facilitar o entendimento das conclusões sobre a capacidade dos algoritmos no decorrer deste estudo.

Este estudo procurou adotar a métrica descrita por Everingham (2012) e utilizada nas competições internacionais de algoritmos na tarefa de detecção de objetos (neste trabalho tratado como alvo). Por conseguinte, o padrão adotado será a *mean average precision (mAP)*, calculada a partir da *average precision (AP)* de cada tipo de alvo, por exemplo, blindados, aeronaves etc.

Para o cálculo da *AP* de cada tipo de alvo é necessário plotar uma curva de *precisão x recall* do respectivo algoritmo para esse alvo. As medidas de *precisão* e *recall* são obtidas com base no número de verdadeiros positivos (*VP*), falsos positivos (*FP*) e falsos negativos (*FN*) percebidos durante o processamento das imagens.

Para a atividade de detecção de alvos, são tratadas como verdadeiros positivos (*VP*), as detecções realizadas pelo algoritmo que foram confirmadas. Em complemento, as detecções que foram realizadas de forma errônea são tratadas como falsos positivos (*FP*). Finalizando, são tratados como falsos negativos (*FN*) as detecções que deviam ter sido feitas, mas não foram.

Conforme Zheng (2015), as métricas de *precisão* e *recall* podem ser definidas matematicamente conforme as equações (1) e (2), respectivamente:

$$precisão = \frac{VP}{VP + FP} \quad (1)$$

$$recall = \frac{VP}{VP + FN} \quad (2)$$

Portanto, a *precisão* configura uma medida da relevância do resultado, enquanto que o *recall* é uma medida de quantos resultados relevantes são retornados do total. Ambas as métricas são relacionadas por um meio de um *trade-off*.


O gráfico de *precisão x recall* demonstra o *trade-off* para diferentes limites. Por exemplo, quando é solicitado uma maior *precisão* há geralmente um queda no *recall*. Uma grande área sob a curva representa alto *recall* e *precisão*, onde alta *precisão* está relacionada a uma baixa taxa de falsos positivos e alto *recall* está relacionado a uma baixa taxa de falsos negativos.

Um algoritmo com alto *recall*, mas baixa *precisão* retorna muitos resultados, mas a maioria estará incorreta enquanto um sistema com alta *precisão*, mas baixo *recall* retorna poucos resultados, mas a maioria correta.

O objetivo sempre é obter o máximo possível *precisão* e *recall*. Ou seja, o algoritmo ideal apontaria com grande *precisão* todos os elementos de uma classe presentes numa amostra. É possível construir um gráfico dessa relação *precisão x recall* variando um dos elementos.

Desse modo, após o cômputo de todas as variações possíveis, pode-se plotar o gráfico de *precisão x recall* conforme Figura 5.

Figura 5 – Exemplo de gráfico precisão x recall



Fonte: Adaptado de Scikit-learn (2022)

Em seguida, para cada tipo de alvo, a *average precision* é definida como a integral da função $precisão = p(r)$, ou seja, a área do gráfico conforme equação (3).

Ao final, para obter o mAP , basta calcular a média do AP de todos os tipos de alvos t , dado que $t \in \{t_1, t_2, \dots, t_m\}$ conforme equação (4).

$$AP_c = \int_0^1 p(r) dr. \quad (3)$$

$$mAP = \frac{1}{m} \sum_{n=1}^m AP_c \quad (4)$$

Ao final, a mAP irá indicar o quão capaz será um algoritmo de detectar o maior número possível de alvos mantendo a variável da precisão dentro dos limites estabelecidos como aceitáveis pelo operador do sistema. Atualmente, um algoritmo típico é capaz de obter um resultado superior a 0,80 mAP (máximo possível 1 mAP).

Feita a explanação do conhecimento básico necessário para o entendimento deste artigo, no próximo tópico, inicialmente será apresentado um resumo das capacidades e desafios no emprego da IA. Em seguida, a pesquisa irá abordar o desempenho das aplicações para detecção de alvos móveis, as suas necessidades de *hardware* e os possíveis impactos na formação dos recursos humanos na Força Aérea Brasileira.

4 ANÁLISE

4.1. Capacidades e desafios

No que concerne as potencialidades das redes neurais, é necessário inicialmente descrever as várias vantagens e desvantagens na sua utilização antes de observar seu valor em aplicações para detecção de alvos móveis.

Há uma crescente preocupação sobre as consequências do seu uso no contexto militar. Por exemplo, Svenmarck (2018) afirma que a IA tem potencial para estar presente em todos os domínios e níveis da guerra nos próximos anos.

O autor destaca ainda que, nos níveis mais altos, a IA pode ser usada para desestabilizar um inimigo ao disseminar informações falsas. Já em níveis mais táticos, ela pode melhorar o controle de sistemas autônomos não tripulados, provendo mais eficiência para, em última análise, aumentar o impacto de sua aplicação no campo de batalha.

Apesar disso, Svenmarck destaca alguns pontos a serem considerados com precaução sobre essa tecnologia. O primeiro deles é o desafio da transparência do seu funcionamento para a sua aplicação em atividades críticas como vigilância e agentes autônomos.

Especificamente sobre as redes neurais, Facelli (2011) segue na mesma linha ao ressaltar que as críticas mais frequentes têm sido sobre como as RNAs chegam as suas conclusões. O autor prossegue afirmando que o principal obstáculo a esse entendimento é o fato do conhecimento estar armazenado em um número muito grande de parâmetros a serem manipulados por intrincadas fórmulas matemáticas, constituindo, assim, quase uma caixa-preta.

Sobre essa afirmação, pode-se citar o experimento realizado por Gichoya (2022), onde uma IA treinada com imagens de raio-x foi capaz de identificar a etnia dos pacientes utilizando apenas exames de imagens de diversas partes do seu corpo (e.g. tórax, manografia e cervical) com taxa de acerto superior a 90%. A surpresa é originada do fato que, em contraste com outros fatores como idade e sexo, há um consenso amplamente aceito entre os radiologistas de que a identificação do grupo étnico de um paciente a partir de imagens médicas é quase impossível.

O segundo fato levantado como desafio é a possível vulnerabilidade dos algoritmos à ataques adversários. Há situações na quais um adversário com mais conhecimento pode manipular os dados de entrada do algoritmo para obter uma saída não desejada. Modelos de detecção de objetos embutidos em ARPs podem ser enganados por padrões de camuflagem cuidadosamente projetados.

Svenmarck ainda alerta sobre a dependência de dados para construção dos modelos e como os procedimentos para coleta de dados em atividades militares não são amigáveis para a produção de algoritmos de inteligência artificial. Por conseguinte, ao contrário de aplicações voltadas para finalidades civis, muitas vezes é difícil encontrar conjuntos de dados de alta qualidade e suficientemente grandes que possam ser usados para aprender e desenvolver bons modelos. Pode-se ainda citar as questões envolvendo restrições de acesso aos dados gerados por sistemas de armas ou sensores.

Outros autores como Chhaya, Khanzode e Sarode (2020) ressaltam alguns fatos sobre o seu uso. É possível destacar, por exemplo, a capacidade de entregar tarefas em tempos menores enquanto apresenta uma taxa de acerto igual ou superior em comparação aos humanos.

Em contrapartida, também pode ser percebida uma acomodação intelectual e uma dependência da tecnologia. Ao final, Khanzode et al (2020) agrupa suas observações do uso da IA em dois grupos. No primeiro grupo, estão relacionadas as vantagens no seu uso, conforme segue:

- Execução de tarefa mais rápido que um ser humano;
- Inexistência de fadiga da execução de trabalhos complexos;
- Capacidade de executar tarefas em paralelo;
- Alta taxa de acerto;
- Mais eficiência; e
- Capacidade de cálculo de situações complexas e de longo prazo.

É válido destacar ainda que uma das principais vantagens da IA é que suas decisões são baseadas em dados ao invés de emoções. É um fato bem conhecido que as decisões humanas são sempre afetadas de forma negativa pelas emoções (KHANZODE et al, 2020). Já como desvantagens no uso da IA, o autor cita os seguintes pontos:

- Pode ser mal utilizada, levando à destruição em grande escala;
- Pode provocar desemprego;
- A criatividade depende do desenvolvedor do sistema;
- Falta o toque humano;
- Causa acomodação intelectual nas pessoas;
- Requer recursos em grande monta; e
- Aumento da dependência tecnológica dos humanos.

Apesar das críticas empreendidas, grande quantidade de experimentos relevantes na área aponta para um saldo final positivo no seu emprego. Conforme será demonstrado no próximo tópico, a inteligência artificial abre janelas de oportunidades na detecção de alvos móveis que podem ser exploradas pela FAB.


4.2. Desempenho na detecção de alvos móveis

É possível ter a dimensão da evolução dos algoritmos de IA nessa área ao observar a diminuição das taxas de erro nas competições internacionais. Langlotz (2019) relata, por exemplo, que o erro de classificação no ILSVRC diminuiu mais de oito vezes, no período de 2010 a 2017, até alcançar uma taxa de erro abaixo de 3%.

Langlotz (2019) considera a taxa de erro humano em aproximadamente 5% para a atividade de reconhecimento de imagens. Na Figura 6 é possível verificar a evolução da taxa de erro durante os anos analisados. Pode-se observar que em 2015 os algoritmos superaram a

capacidade humana com uma margem significativa.

Figura 6 – Evolução taxa de erro no ILSVRC



No cenário militar nacional, ainda há poucos trabalhos na literatura demonstrando o desempenho desses algoritmos treinados a partir de conjuntos de dados produzidos por sensores utilizados pela Força Aérea Brasileira.

Atualmente, grande parte dessas missões é realizada com sensores embarcados em sistemas de aeronaves remotamente pilotadas. Na FAB, um dos sensores usados é DCoMPASS, equipamento israelense desenvolvido para missões de *Intelligence, Surveillance, Target Acquisition, and Reconnaissance* (ISTAR).

O sensor é equipado com uma câmera de TV em cores de alta definição e um imageador termal. Além disso, também possui um telêmetro e um designador de alvos, ambos a laser. Especificamente sobre o imageador termal, é usado um detector de antimônio de índio que cobre o comprimento de onda do infravermelho médio de 3,4 a 4,8 μm , com definição de 512×640 pixels e 25 quadros por segundo (ELBIT, 2016).

Um dos objetivos do emprego dos SARP no lugar de aeronaves tripuladas é aproveitar sua capacidade de permanência nas missões de vigilância. Dessa maneira, a detecção de alvos em movimento no vídeo em tempo real é uma das principais funções dos SARP em missões de Vigilância Aérea. Análises de imagens estáticas podem ocorrer. Entretanto, esse tipo de atividade serve principalmente como apoio e confirmação das informações obtidas.

Utilizando um conjunto de dados extraído de imagens do sensor DCoMPASS, Macedo (2020) treinou uma rede neural convolucional especializada em detecção de alvos e obteve bons resultados ao utilizar um conjunto de dados real de uma Unidade Aérea de SARP da FAB.

A rede empregada foi a YOLO (*You Only Look Once*), uma rede construída com foco em aplicações de tempo real. A primeira versão dessa rede foi apresentada por Redmon (2016) e logo se tornou um divisor de águas na área da visão computacional.

Redes anteriores empregavam vários algoritmos e métodos diferentes em sequência com a finalidade de detectar os objetos nas imagens. Esse sequenciamento tornava o processo total lento e custoso. Por outro lado, a rede YOLO pode realizar a mesma tarefa de localizar e classificar os objetos de interesse sem sequências de procedimentos.

O conjunto de dados usado no treinamento foi composto por 3415 amostras. Todas as imagens foram extraídas de vídeos de missões reais produzidos pelo sensor DCoMPASS, por meio de *software* livre. As amostras finais foram *frames* de 576×720 pixels, com tamanho em torno de 30 kB cada, todas em tons de cinza. Apesar do número reduzido de amostras e da baixa qualidade disponível, foi possível efetuar o treinamento de forma satisfatória.

Os índices alcançados, em termos de *mAP* e velocidade em frames por segundo, demonstram um grande potencial para a sua aplicação operacional, apesar das restrições sobre o conjunto de dados. A Tabela 1, abaixo, indica os resultados obtidos.

Tabela 1 – Resultados de precisão e velocidade rede YOLO

<i>Mean average precision (mAP)</i>	Velocidade (<i>frames/seg.</i>)
0,8463	29,8

Fonte: Adaptado de Macedo (2020)

O desempenho apresentado pelo algoritmo demonstra seu potencial para ser aplicado em atividades operacionais reais. Com uma precisão de quase 85%, fica evidente que a utilização desse tipo de técnica pode colaborar para a melhora do desempenho das missões Vigilância Aérea prolongadas que são típicas dos SARPs.

Já a velocidade de aproximadamente 30 *frames/seg* torna possível sua aplicação em tempo real sobre o vídeo de sensores. A velocidade mínima necessária para haver essa capacidade seria em torno de 24 *frames/seg* para suportar a fluidez das imagens sequenciais do vídeo.

O controle de aeronaves remotamente pilotadas, apesar de estar livre dos fatores físicos como aceleração e temperatura, demanda um alto nível de atenção. O longo tempo de autonomia desse tipo de aeronave e a necessidade de acompanhamento de alvos múltiplos em movimento nas missões exigem grande concentração em especial dos operadores dos sensores. Desse modo, a grande eficiência das redes neurais na detecção de alvos múltiplos constitui uma outra vantagem do seu uso, conforme ilustrado na Figura 7.

Figura 7 – Detecção alvos múltiplos com RNA



Fonte: Macedo (2020)

Em um cenário denso e complexo com vários elementos em movimento, a atenção do operador fica dividida entre diversos alvos e o seu foco é bastante degradado. Dessa forma, há perda considerável na riqueza dos detalhes descritos, podendo chegar até o ponto de comprometer o resultado da missão.

É importante destacar, ainda, que todas as dependências e bibliotecas de *software* necessárias para o experimento citado foram instaladas em um ambiente Ubuntu 18.04 com uma GPU (*graphics processing unit*) Nvidia GeForce GTX 1080 Ti. Ou seja, o *software* e o *hardware* eram comerciais e de fácil acesso. A GPU é uma peça de *hardware* especializada no processamento de cálculos para apresentação de gráficos.

4.3. Requisitos de *Hardware*

Para as capacidades mais elaboradas, como lidar com mais de um alvo simultaneamente, é necessário ressaltar os requisitos de *hardware*, essencialmente as GPU's. Apesar de relativamente custosas, as GPUs ainda possuem ótimo custo-benefício e são de fácil acesso comercial. Por conseguinte, é possível obter um desempenho satisfatório mesmo com recursos limitados.

As GPUs foram inicialmente desenvolvidas como uma peça dedicada a auxiliar na apresentação de gráficos em computadores, entretanto, acabaram apropriadas pela inteligência artificial por causa da sua grande capacidade de processamento computacional de cálculos.

Conforme Hwang (2018), do ponto de vista da tecnologia militar a IA é um software que requer substancial *hardware* para sua criação. Os custos de *hardware* associados especialmente para aplicações avançadas de IA podem ser potencialmente significativos.

Quanto mais complexo o algoritmo, mais *hardware* computacional inicial é necessário para “treinar” esse algoritmo.

O estágio de treinamento está relacionado ao processo de ajustes aplicado de forma iterativa aos pesos da rede, sendo o estágio mais custoso em termos de processamento. Já o estágio de inferência está relacionado ao emprego da rede pronta, por exemplo, uma situação na qual a rede recebe uma imagem e necessita detectar os objetos de interesse presentes em determinada cena.

Pode-se notar que a capacidade de realizar cálculos em paralelo é muito útil para a IA, pois ajuda a reduzir consideravelmente o tempo de treinamento. A falta de acesso a esse tipo de equipamento pode tornar o treinamento de redes praticamente inexecutável.

O aprendizado de máquina é um processo computacional. Para esse fim, está inextricavelmente ligado ao poder computacional, o material tangível de semicondutores nos quais os algoritmos de inteligência artificial operam. Obviamente, o poder computacional e as arquiteturas de computação moldam a velocidade de treinamento e inferência no aprendizado de máquina e, portanto, influenciam a taxa de progresso na tecnologia (HWANG, 2018, p. 01, tradução nossa).

A influência na taxa de progresso na tecnologia diz respeito principalmente ao estágio de treinamento. A capacidade de processamento necessária nos dois estágios de uma RNA, treinamento e inferência, são muito diferentes. Durante a etapa de treinamento, a rede é alimentada com grandes quantidades de amostras rotuladas e, usando métodos iterativos, seus parâmetros são otimizados para uma tarefa específica. Uma vez treinada, a rede é usada para inferência onde apenas alguns dados de entrada, como uma imagem, são enviados pela rede para computar o resultado desejado (WETZSTEIN et al., 2020).

Um importante fator, que favorece um menor custo das GPUs, é a característica de aplicação dual (civil e militar) da inteligência artificial. Ou seja, devido à alta demanda, existe um estímulo para a produção em escala de *hardware* especializado. Ademais, trata-se de uma tecnologia habilitadora para outras e não tem um propósito específico. Por exemplo, conforme Horowitz (2018), diferentemente da tecnologia *stealth*, que foi concebida com um propósito fundamentalmente militar, a inteligência artificial tem outros usos tão variados quanto compras, agricultura e negociação de ações.

Ao observarmos o custo-benefício oferecido, o uso de GPUs de qualidade intermediária ainda pode entregar bons resultados, conforme registrado na Tabela 1 da seção anterior, o que já traria significantes ganhos operacionais para a FAB com a mínima aplicação de recursos em equipamentos.

Outro fato a ser considerado é a possibilidade de tirar vantagem do baixo custo computacional da inferência. Os treinamentos dos algoritmos da FAB poderiam ser centralizados em locais especializados. Dessa maneira, seria reduzida a demanda por equipamentos nas Unidades Operacionais. Nesses centros o insumo principal seria o conjunto de dados e o efetivo técnico, seja ele civil ou militar. Dessa maneira, as Unidades operacionais ficariam responsáveis apenas pela sua aplicação.

Já existe, inclusive, a possibilidade de utilizar poder computacional sob demanda, conhecida também como computação em nuvem. Recentemente, o Google disponibilizou acesso a um ambiente de programação com disponibilidade de GPUs virtuais no seu serviço Google Colaboratory. Assim, é possível desenvolver aplicativos de aprendizado profundo usando bibliotecas populares como Keras, TensorFlow e PyTorch de uma máquina doméstica através de seu navegador de internet com uma conta Google.

Apesar da inteligência artificial apresentar inicialmente grandes possibilidades de avanços para a Força Aérea mesmo com o emprego de *hardware* comercial intermediário, para uma visão estratégica de mais longo prazo, é indubitável à necessidade de estudos futuros visando investimentos em pesquisa e *hardware*.

Nesse caso, equipamentos ainda mais especializados e capazes como TPUs (*Tensor Process Units*) e ASICs (*Application-Specific Integrated Circuits*), ambos semicondutores desenvolvidos especificamente para acelerar aplicações de IA, deveriam estar disponíveis, sem citar ainda os recursos humanos com especialização na área.

4.4. Recursos Humanos

Conforme Horowitz (2018), o “caráter da guerra” em um período pode ser definido como a forma dominante de lutar e vencer conflitos dadas as tecnologias, organizações e políticas existentes. O caráter da guerra muda de acordo com as ferramentas que se tornam disponíveis e como elas influenciam a forma como os militares se organizam para nela lutar.

Nesse sentido, aumenta o debate militar sobre o impacto da IA nos conflitos. Surgiram termos como *hyperwar*, expressão proposta pelo General da reserva John R. Allen, U.S. Marine Corps em artigo do instituto naval americano intitulado *On Hyperwar*. Para Allen (2017), *hyperwar* seria um tipo de conflito em que a tomada de decisão humana está quase totalmente ausente do ciclo observar-orientar-decidir-agir (OODA). Como consequência, o tempo associado a um ciclo OODA será reduzido a respostas quase instantâneas.

Por óbvio, a influência sobre os recursos humanos militares é muito intensa. Tanto nos níveis mais altos, a exemplo do conceito de *hyperwar* descrito por Allen, quanto do ponto de

vista tático, na supervisão dos algoritmos atuando em campo.

Novamente, Horowitz (2018) avalia que o sucesso em batalhas gerenciadas em algum nível pela IA provavelmente exigirá novas especialidades ocupacionais e mudanças no recrutamento, treinamento e política de promoção, para capacitar indivíduos que entendem tanto de operações militares como as formas que determinados sistemas de IA funcionam.

Neste sentido, Cummings (2017) discorda da crença usual que o aprendizado de máquina e o aprendizado profundo se aproximam da inteligência humana. Na sua visão, essas ferramentas detectam basicamente padrões que são significativamente ajustados por humanos e devem ser interpretados por humanos para serem úteis.

Na Força Aérea Brasileira, é evidente que hoje ainda não há demanda por militares com esse perfil a ponto de provocar mudanças estruturais como, por exemplo, promoções diferenciadas ou criação de novos quadros. Entretanto, a Força deve entender fatos assim como alertas para as transformações nas habilidades necessárias que possivelmente o emprego da IA irá requisitar na formação dos recursos humanos.

Para ilustrar esse fato, se essas habilidades já fossem requeridas atualmente, haveria uma lacuna na formação dos operadores de sensor de SARP em relação à IA. As competências essenciais esperadas para a especialidade de fotointeligência, a especialidade encarregada nos SARP da FAB pela operação dos sensores, constam no Manual do Comando da Aeronáutica 39-6/2021, Padrão de Desempenho de Especialidade do Quadro de Suboficiais e Sargentos. Neste caso, o interesse deste estudo se volta especificamente para o seu anexo B7.1: Competências para terceiros sargentos da Especialidade de Fotointeligência.

Conforme descrito nesse anexo, espera-se do militar de fotointeligência, por exemplo, que ele seja capaz de listar as características essenciais das aeronaves de IVR (Inteligência Vigilância e Reconhecimento), conforme as práticas da Inteligência Operacional e saiba operar *softwares* para análise de imagens. Entretanto, apesar ter uma boa abrangência, no documento não há ênfase no conhecimento sobre as novas tecnologias como a inteligência artificial (BRASIL, 2021).

Por fim, estudo realizado por Sousa (2018), indicou a habilidade de lidar com a inteligência artificial como uma das habilidades tecnológicas disruptivas que serão críticas em pouco tempo. Neste mesmo estudo, uma pesquisa entre estudantes de todos os níveis confirmou a inteligência artificial em primeiro lugar como habilidade crítica. Ela veio antes mesmo de outras muito citadas na mídia, como robótica ou internet das coisas.

5 CONCLUSÃO

Este estudo se propôs, com base em uma pesquisa bibliográfica, levantar quais os principais aspectos da ação de Vigilância Aérea são influenciados pelo emprego de redes neurais artificiais para detecção de alvos móveis em imagens infravermelhas obtidas com SARP.

Inicialmente, foi discorrido sobre as capacidade e desafios presentes no emprego da IA no campo militar sobre seu uso em atividades como a vigilância e agentes autônomos. Foram elencadas, ainda, diversas vantagens e desvantagens no seu uso. Em seguida, tratou-se de forma mais específica do desempenho que as redes neurais artificiais podem entregar no reconhecimento de objetos em imagens e como essa capacidade, superior a humana, pode ser utilizada na missão de vigilância aérea na Força Aérea Brasileira. Foi citado exemplo prático de uma aplicação com um conjunto de dados reais de uma Unidade Aérea da FAB. Neste estudo, o resultado obtido foi muito satisfatório em termos de capacidade de detecção mesmo com alvos múltiplos e apresentou, ainda, possibilidade de ser usado em aplicações em tempo real típicas de missões de Vig Ae com SARPs.

Em seguida, foi ressaltada a importância e a necessidade das GPUs para o desenvolvimento dos algoritmos de inteligência artificial. Apesar de custosas, elas são produzidas em grande escala devido ao seu uso civil, assim sendo, é possível treinar algoritmos de IA bem satisfatórios com uma boa relação de custo-benefício. Adicionalmente, pode-se realizar treinamento de algoritmos empregando computação em nuvem, hoje já disponível comercialmente. No âmbito a Força Aérea Brasileira, há a opção de concentrar o treinamento das redes neurais (a fase mais custosa em termos de processamento) em centros destinados apenas para esse fim equipados com *hardware* de última geração.

Em seguida, foram tratados aspectos ligados ao gerenciamento dos recursos humanos empregados na ação da Vigilância Aérea. Foi demonstrado que a IA pode atuar transversalmente em todos os níveis do conflito ao agir de situações táticas até os níveis estratégicos. Na sequência, foram apontados exemplos das consequências do uso dessas técnicas para a gerenciamento dos recursos humanos, como no caso da formação e demanda por pessoal especializado.

Por fim, foi logrado êxito no atingimento dos objetivos de pesquisa. A principal contribuição foi observar a necessidade de envidar esforços em estudos mais completos sobre os impactos na FAB das novas tecnologias que estarão presentes nos conflitos do futuro. Foi observada a possibilidade de obtenção de bons resultados e grandes melhorias operacionais

mesmo com poucos recursos.

Durante toda a história, somente as Forças Armadas que acompanharam a evolução tecnológica obtiveram sucesso no longo prazo. As Forças que por algum motivo, desprezaram esse fato, foram relegadas a segundo plano. Portanto, ter o conhecimento da maneira como o emprego dos novos avanços tecnológicos afeta as ações de Força Aérea é de extrema importância para manter a instituição atual e relevante.

Uma correta avaliação dos impactos gerados pelos algoritmos de IA, especificamente as redes neurais, sobre a ação de Vigilância Aérea será de grande valia em uma possível implementação futura, contribuindo para a operacionalidade da Força Aérea Brasileira.

Como sugestão de trabalhos futuros sobre o tema, há a opção de incluir a ciência de dados no debate. Com as ferramentas existentes atualmente, o gerenciamento dos dados e a sua análise podem trazer grandes benefícios e economia de meios para a Força Aérea Brasileira.

REFERÊNCIAS

- ALLEN, John R.; HUSAIN, Amir. **On Hyperwar | Proceedings - July 2017 Vol. 143/7/1,373**. 2017. Disponível em: <https://www.usni.org/magazines/proceedings/2017/july/hyperwar>. Acesso em: 25 maio. 2022.
- BRASIL. Comando da Aeronáutica. Portaria nº 1.224/GC3, de 10 de novembro de 2020. Aprova a reedição da Doutrina Básica da Força Aérea Brasileira - volume 2 (DCA 1-1). **Boletim do Comando da Aeronáutica**, Rio de Janeiro, nº 205, f. 14971, 12 nov., 2020.
- BRASIL. Comando da Aeronáutica. Portaria COMGEP nº 136/3SC2, de 26 de março de 2021. Aprova o Padrão de Desempenho de Especialidade (PDE) do Quadro de Suboficiais e Sargentos (QSS). **Boletim do Comando da Aeronáutica**, Rio de Janeiro, nº 062, f. 3862, 06 abr., 2021.
- CHHAYA, Ku; KHANZODE, A.; SARODE, Ravindra D. Advantages and Disadvantages of Artificial Intelligence and Machine Learning: A Literate Review. **International Journal of Library & Information Science (IJLIS)**, [S. l.], v. 9, p. 3, 2020. Disponível em: <http://iaeme.com>. Acesso em: 22 fev. 2022.
- CHOLLET, François. **Deep Learning with Python**. [s.l.] : Manning Publications, 2018. Disponível em: <http://faculty.neu.edu.cn/yury/AAI/Textbook/Deep Learning with Python.pdf>. Acesso em: 13 abr. 2022.
- CUMMINGS, Missy. Artificial Intelligence and the Future of Work. **Chatham House for the Royal Institute of International Affairs**, London, 2017.
- DAUGHERTY, Paul R.; JAMES WILSON, H.; MICHELMAN, Paul. The jobs artificial intelligence will create. **MIT Sloan Management Review**, [S. l.], v. 60, n. 4, p. 14, 2017. Disponível em: <http://mitsmr.com/2odREFJ>. Acesso em: 21 mar. 2022.
- ELBIT. **ELOP DCoMPASS Digital Compact Multi-Purpose Advanced Stabilized System-UAV**. Haifa. Disponível em: www.elbitsystems.com. Acesso em: 20 maio. 2020.
- EVERINGHAM, Mark; WINN, John. **The PASCAL Visual Object Classes Challenge 2012 (VOC2012) Development Kit**. 2012. Disponível em: http://host.robots.ox.ac.uk/pascal/VOC/voc2012/html/doc/devkit_doc.html. Acesso em: 3 maio. 2022.
- FACELI, Katti; LORENA, Ana Carolina; GAMA, João; DE CARVALHO, André C. P. L. F. **Inteligência Artificial - Uma Abordagem de Aprendizado de Máquina**. São Paulo: LTC - Livros Técnicos e científicos Editora, 2011.
- FINK, Olga; WANG, Qin; SVENSÉN, Markus; DERSIN, Pierre; LEE, Wan Jui; DUCOFFE, Melanie. Potential, challenges and future directions for deep learning in prognostics and health management applications. **Engineering Applications of Artificial Intelligence**, [S. l.], v. 92, 2020. DOI: 10.1016/j.engappai.2020.103678.
- GICHOYA, J. W. et al. AI recognition of patient race in medical imaging: a modelling study. **The Lancet Digital Health**, [S. l.], 2022. DOI: 10.1016/S2589-7500(22)00063-2. Disponível em: <https://doi.org/10.1016/S2589-7500>. Acesso em: 23 maio. 2022.

GIL, Antônio Carlos. **Como Elaborar Projetos de Pesquisa**. 4. ed. São Paulo: Atlas, 2002.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning**. [s.l.] : MIT Press, 2016. Disponível em: <http://www.deeplearningbook.org>.

HAYKIN, Simon et al. **Neural Networks and Learning Machines Third Edition**. Third ed. New York: Prentice Hall, 2009.

HOROWITZ, Michael C. Artificial Intelligence, International Competition, and the Balance of Power. **Texas National Security Review**, [S. l.], v. 1, n. 3, p. 36–57, 2018. DOI: 10.1093/qje/qjr035. Disponível em: <https://doi.org/10.1093/qje/qjr035>. Acesso em: 23 fev. 2022.

HWANG, Tim. Computational Power and the Social Impact of Artificial Intelligence. **SSRN Electronic Journal**, [S. l.], 2018. DOI: 10.2139/ssrn.3147971.

IRVINE, John M. National imagery interpretability rating scales (NIIRS): overview and methodology. *In*: AIRBORNE RECONNAISSANCE XXI 1997, **Anais [...]** : SPIE, 1997. p. 93–103. DOI: 10.1117/12.279081.

JOHNSON, John. Analysis of image forming systems. *In*: SPIE - THE INTERNATIONAL SOCIETY FOR OPTICAL ENGINEERING 1985, **Anais [...]**. [s.l: s.n.] p. 761.

LANGLOTZ, Curtis P. et al. A roadmap for foundational research on artificial intelligence in medical imaging: from the 2018 NIH/RSNA/ACR/The Academy Workshop. **Radiology**, [S. l.], v. 291, n. 3, p. 781–791, 2019. DOI: 10.1148/RADIOL.2019190613/ASSET/IMAGES/LARGE/RADIOL.2019190613.TBL3.JPEG. Disponível em: <https://pubs.rsna.org/doi/abs/10.1148/radiol.2019190613>. Acesso em: 21 fev. 2022.

MACEDO, Henrique Eduardo; DE OLIVEIRA, Jose Maria Parente; MÁXIMO, Marcos Ricardo Omena de Albuquerque. Convolutional Neural Networks for target detection in thermal images. *In*: SYMPOSIUM ON OPERATIONAL APPLICATIONS IN DEFENSE AREAS 2020, São José dos Campos. **Anais [...]**. São José dos Campos: Technological Institute of Aeronautics, 2020. Disponível em: https://www.sige.ita.br/edicoes-antiores/2020/ST/ST_03_3.pdf?t=1609272537. Acesso em: 17 fev. 2022.

NIIRS. **Civil NIIRS Reference Guide**. 1996. Disponível em: https://irp.fas.org/imint/niirs_c/guide.htm. Acesso em: 29 mar. 2022.

REDMON, Joseph; DIVVALA, Santosh; GIRSHICK, Ross; FARHADI, Ali. You Only Look Once: Unified, Real-Time Object Detection. *In*: 2016 IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR) 2016, **Anais [...]** : IEEE, 2016. p. 779–788. DOI: 10.1109/CVPR.2016.91. Disponível em: <http://ieeexplore.ieee.org/document/7780460/>. Acesso em: 4 mar. 2022.

ROSENBLATT, F. THE PERCEPTRON: A PROBABILISTIC MODEL FOR INFORMATION STORAGE AND ORGANIZATION IN THE BRAIN. **Psychological Review**, [S. l.], v. 65, n. 6, p. 19–27, 1958.

RUSSAKOVSKY, Olga et al. ImageNet Large Scale Visual Recognition Challenge. **International Journal of Computer Vision**, [S. l.], v. 115, n. 3, p. 211–252, 2015. DOI:

10.1007/S11263-015-0816-Y/FIGURES/16. Disponível em:
<https://link.springer.com/article/10.1007/s11263-015-0816-y>. Acesso em: 16 abr. 2022.

SCIKIT-LEARN. **Precision-Recall** — **scikit-learn 1.0.2 documentation**. 2022. Disponível em: https://scikit-learn.org/stable/auto_examples/model_selection/plot_precision_recall.html. Acesso em: 3 maio. 2022.

SOUSA, Maria José; WILKS, Daniela. Sustainable Skills for the World of Work in the Digital Age. **Systems Research and Behavioral Science**, [S. l.], v. 35, n. 4, p. 399–405, 2018. DOI: 10.1002/SRES.2540. Disponível em:
<https://onlinelibrary.wiley.com/doi/full/10.1002/sres.2540>. Acesso em: 21 mar. 2022.

SVENMARCK, Peter; LUOTSINEN, Linus; NILSSON, Mattias; SCHUBERT, Johan. Possibilities and Challenges for Artificial Intelligence in Military Applications. *In*: NATO BIG DATA AND ARTIFICIAL INTELLIGENCE FOR MILITARY DECISION MAKING SPECIALISTS' MEETING 2018, Bordeaux, France. **Anais [...]**. Bordeaux, France. Disponível em:
https://www.researchgate.net/publication/326774966_Possibilities_and_Challenges_for_Artificial_Intelligence_in_Military_Applications. Acesso em: 17 fev. 2022.

WETZSTEIN, Gordon; OZCAN, Aydogan; GIGAN, Sylvain; FAN, Shanhui; ENGLUND, Dirk; SOLJAČIĆ, Marin; DENZ, Cornelia; MILLER, David A. B.; PSALTIS, Demetri. Inference in artificial intelligence with deep optics and photonics. **Nature** **2020** **588**:7836, [S. l.], v. 588, n. 7836, p. 39–47, 2020. DOI: 10.1038/s41586-020-2973-6. Disponível em:
<https://www.nature.com/articles/s41586-020-2973-6>. Acesso em: 23 maio. 2022.

ZHANG, Aston; LIPTON, Zachary C.; LI, Mu; SMOLA, Alexander J. **Dive into Deep Learning**. 0.17.5 ed. [s.l: s.n.]. Disponível em: <http://www.d2l.ai>.

ZHENG, Alice. **Evaluating Machine Learning Models**. 1st. ed. Sebastopol, CA: O'Reilly Media, 2015.