UNIVERSIDADE DE SÃO PAULO

ESCOLA DE ENGENHARIA DE SÃO CARLOS

Adriano Ghigiarelli Bruschi

Classificação de eventos de PIO utilizando Redes Neurais Artificiais

São Carlos

2023

Adriano Ghigiarelli Bruschi

Classificação de eventos de PIO utilizando Redes Neurais Artificiais

Dissertação apresentada ao programa de Pós-Graduação em Engenharia Mecânica (PPGEM) Universidade de São Paulo, como requisito para obtenção do título de Mestre em Engenharia Mecânica.

Área de concentração: Aeronáutica.

Orientador: Prof Dr Jorge Henrique Bidinotto

ESTE EXEMPLAR TRATA-SE DA VESÃO CORRIGIDA, A VERSÃO ORIGINAL ENCONTRA-SE NA ESCOLA DE ENGENHARIA DE SÃO CARLOS

São Carlos

2023

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica elaborada pela Biblioteca Prof. Dr. Sérgio Rodrigues Fontes da EESC/USP com os dados inseridos pelo(a) autor(a).

Bruschi, Adriano Ghigiarelli
B912c Classificação de eventos de PIO utilizando Redes Neurais Artificiais / Adriano Ghigiarelli Bruschi; orientador Jorge Henrique Bidinotto. São Carlos, 2023.

Dissertação (Mestrado) - Programa de Pós-Graduação em Engenharia Mecânica e Área de Concentração em Aeronáutica -- Escola de Engenharia de São Carlos da Universidade de São Paulo, 2023.

1. PIO. 2. Escala PIOR. 3. Ensaios em Voo. 4. Rede Neural Artificial. 5. Tarefa Sintética. 6. Fatores Humanos. I. Título.

Eduardo Graziosi Silva - CRB - 8/8907

FOLHA DE JULGAMENTO

Candidato: Engenheiro **ADRIANO GHIGIARELLI BRUSCHI.**

Título da dissertação: "Classificação de eventos de PIO utilizando Redes Neurais Artificiais".

Data da defesa: 29/03/2023

Comissão Julgadora	**Resultado**
Prof. Dr. **Jorge Henrique Bidinotto (Orientador)** (Escola de Engenharia de São Carlos – EESC/USP)	**Aprovado**
Prof. Dr. **Ricardo Augusto Souza Fernandes** (Universidade Federal de São Carlos/UFSCar)	**Aprovado**
Dr. **Daniel Drewiacki** (Empresa Brasileira de Aeronáutica S/A - EMBRAER)	**Aprovado**

Coordenador do Programa de Pós-Graduação em Engenharia Mecânica:
Prof. Associado **Adriano Almeida Gonçalves Siqueira**

Presidente da Comissão de Pós-Graduação:
Prof. Titular **Carlos De Marqui Junior**

A Liciane, por tudo.

AGRADECIMENTOS

Agradeço a Deus, pela vida.

À Universidade de São Paulo e Departamento de Engenharia Aeronáutica por todo auxílio prestado.

Ao Prof Dr Jorge Henrique Bidinotto pelo excelente trabalho de coordenação nesta dissertação e paciência.

Aos meus pais Armando e Eleniza por me encorajarem a realizar este trabalho.

À Liciane por todo amor, compreensão, revisão e paciência nesta jornada.

Ao time de Ensaios em Voo da EMBRAER por ter me concedido a possibilidade de desenvolvimento deste trabalho.

Ao Matheus por ter me auxiliado imensamente nas atividades deste trabalho.

“A força não provém da capacidade física.
Provém de uma vontade indomável.”

(Mahatma Gandhi, 1948)

RESUMO

Bruschi, A. G. **Classificação de eventos de PIO utilizando Redes Neurais Artificiais.** 2023. 117p. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2023.

Durante a certificação e ensaios em voo de um novo modelo de aeronave, o processo de comprovação da baixa susceptibilidade à oscilação caracterizada como PIO é comumente feita com base na experiencia dos pilotos de prova envolvidos no projeto, desta forma, o resultado de comprovação da segurança da operação com relação ao PIO está intrínseca a subjetividade da análise, ou seja, o processo de certificação pelo qual novos projetos de aeronaves são submetidos está diretamente relacionado à experiencia da tripulação na qual realiza os ensaios de PIO daquele modelo. Novas aeronaves tendem a reduções de margens de estabilidade inerentes ao projeto, ou seja, maiores tendências ao PIO, e veículos autônomos com capacidade de voo completo sem tripulação, o que colabora para necessidade da redução da subjetividade na classificação do PIO para projetos futuros. Este trabalho trata do desenvolvimento de uma rede neural artificial capaz de classificar a oscilação de PIO de acordo com a escala de PIOR, e faz a análise da subjetividade na classificação do PIO. A assertividade do resultado obtido com a classificação via rede neural artificial foi superior ao obtido pela classificação dada pelos pilotos, quando a escolha das entradas segue as diretrizes estabelecidas nesta dissertação.

Palavra-chave: PIO, Escala PIOR, Ensaios em Voo, Rede Neural Artificial, Tarefa Sintética, Fatores Humanos

ABSTRACT

Bruschi, A. G. **PIO Classification Using Artificial Neural Networks.** 2023. 117p. Dissertação (Mestrado) – São Carlos School of Engineering, University of São Paulo, São Carlos, 2023.

During the certification and the flight tests of a new airplane, the verification process to prove the low susceptibility at PIO is usually done for the experience of the test pilots, thus, the result and safety operation regarding PIO is intrinsic the assessment subjectivity, in other words, the certification process of PIO is directly related with the test pilots experiences. New airplanes tend to reduce stability margins, that is, increasing PIO tendencies, and full autonomous airplanes with capacity to perform a complete flight without crew, for this reason it is necessary the reduction of the subjectivity of PIO assessment for next generation of aircraft. This project covers the development of a neural network that will be able to classify the PIO oscillations in accordance with the PIOR Scale and to the subjective assessment of PIO classification. Neural networks assertiveness was higher for PIO classification than the result done by pilots, when the choice of inputs follow the guidelines established for this work.

Keywords: PIO, PIOR Scale, Flight Test, Neural Network, Synthetic Task, Human Factors

LISTA DE ILUSTRAÇÕES

Figura 1 Exemplo de perfil de Tarefa Sintética..... 31
Figura 2 PIO A330-343 Air Canada. 37
Figura 3 Escala PIOR..... 43
Figura 4 Modelo Neurônio 49
Figura 5 Gráfico Função Degrau 52
Figura 6 Gráfico Função Logística 53
Figura 7 Representação da Divisão de Dados de um Neurônio 53
Figura 8 Hiperplanos x Topologia Perceptron Multicamadas 56
Figura 9 Topologia Perceptron Multicamadas 58
Figura 10 Configuração Neurônio utilizado na derivação do algoritimo Backpropagation..... 60
Figura 11 Sidestick do ambiente de simulação 64
Figura 12 Arquitetura da Tarefa Sintética 67
Figura 13 Horizonte Artificial Apresentado ao Piloto..... 68
Figura 14 Representação das Tarefas Sintéticas A, B, C e D..... 70
Figura 15 Representação dos Pitch Captures A, B, C e D 71
Figura 16 Fluxograma das atividades 79
Figura 17 Tarefa Sintética x Atuação Piloto x Theta 83
Figura 18 Gráfico de Energia Comando do Piloto Normalizada 85
Figura 19 Energia Pitch Rate Normalizada 86
Figura 20 Energia ângulo de fase aeronave com relação ao comando do piloto 87
Figura 21 Energia convolução entre comando do piloto e theta 88
Figura 22 Energia da convolução entre o comando do piloto e ângulo de fase 89
Figura 23 Pitch capture A x comando do piloto x Theta 91
Figura 24 Comando Longitudinal Máximo de Captura..... 92
Figura 25 Comando Longitudinal Máximo de Reversão..... 93
Figura 26 Theta Rate Inversão de Comando Longitudinal 94
Figura 27 Tempo de Inversão de Movimento Longitudinal 95
Figura 28 Overshoot Theta Captura 96
Figura 29 Frequência Máxima Potência Espectral 97

Figura 30 Máxima Potência Espectral 98
Figura 31 PIOR x Submodelo Tarefa Sintética 101
Figura 32 PIOR x Submodelo Pitch Capture 101
Figura 33 Desvio PIOR x Submodelo..... 102
Figura 34 Performance RNA - Tarefa Sintética..... 103
Figura 35 Gradiente RNA - Tarefa Sintética..... 104
Figura 36 Confusion Matrix - Tarefa Sintética..... 105
Figura 37 Performance RNA -Pitch Capture 105
Figura 38 Gradiente RNA - Pitch Capture 106
Figura 39 Confusion Matrix - Pitch Capture 107

LISTA DE TABELAS

Tabela 1 Valores de utilizados de $Cm\alpha$ para cada submodelo 66
Tabela 2 Matriz de Ensaios 73
Tabela 3 Número de camadas e neurônios por camada da RNA 81
Tabela 4 Resumo das entradas primeira fase (Tarefa Sintética) 98
Tabela 5 Resumo das entradas segunda fase Pitch Capture 99

LISTA DE ABREVIATURAS E SIMBOLOS

Abreviaturas:

AC	Advisory Circular
ANAC	Agência Nacional de Aviação Civil
AOA	Ângulo de ataque
CAR	Civil Airworthiness Requirements
CG	Centro de Gravidade
CPU	Central Process Unit
EASA	Europea Union Aviation Safety Agency
EESC	Escola de Engenharia de São Carlos
eVTOL	Electrical Vertical Take Off and Landing
FAA	Federal Aviation Administration
FAR	Federal Aviation Regulation
FBW	Fly-by-wire
ft	Feet
HOTAS	Hands on Throttle-and-Stick
KIAS	Knot-Indicated Air Speed
Mid	Mediano
PIO	Pilot-induced oscillation
PIOR	PIO Rating
PMC	Perceptron Multicamadas
Ret	Retraido
RNA	Rede Neural Artificial
TP	Test Point
UP	Representação de Trem de Pouso Recolhido
USP	Universidade de São Paulo

Símbolos:

b	Bias
$f(V)$	Função de Ativação
V	Campo Induzido

w_n	Peso de Entrada do Neurônio
x_n	Sinais de Entrada do Neurônio
y	Saída do Neurônio

Símbolos Gregos:

θ	Atitude em Arfagem
ϕ	Ângulo de Rolamento
η	Comando longitudinal de stick

SUMÁRIO

1. INTRODUÇÃO 21

1.1. MOTIVAÇÃO 21

1.2. CONTEXTO INDUSTRIAL E CIENTÍFICO 23

1.3. REQUISITOS DE AERONAVEGABILIDADE 25

1.4. OBJETIVO 31

1.5. ESTRUTURA DO DOCUMENTO 32

2. FUNDAMENTAÇÃO TEÓRICA 34

2.1. PILOT-INDUCED OSCILLATION 34

2.1.1. ENSAIOS DE PIO 40

2.1.2. ESCALA PIOR 42

2.2. REDES NEURAIS ARTIFICIAIS 43

2.2.1. PERCEPTRON MULTICAMADAS 54

3. MATERIAIS E MÉTODOS 63

3.1. AMBIENTE DE SIMULAÇÃO 63

3.2. AERONAVE MODELO 65

3.3. TAREFA SINTÉTICA / PITCH CAPTURE 67

3.4. MATRIZ DE ENSAIO 72

3.5. ESCOLHA DO MÉTODO DE TREINAMENTO DA REDE NEURAL ARTIFICIAL .. 74

4. RESULTADOS 76

4.1 ENSAIOS 76

4.2 ARQUITETURA DA REDE NEURAL ARTIFICIAL 80

4.3 ENTRADAS DA REDE NEURAL ARTIFICIAL 82

4.4. ANÁLISE SUBJETIVA DO PIO 100

4.5. CLASSIFICAÇÃO DO PIO UTILIZANDO REDES NEURAIS ARTIFICIAS 103

5. CONCLUSÕES E TRABALHOS FUTUROS 108

Referências Bibliográficas..... 111

1. INTRODUÇÃO

1.1. MOTIVAÇÃO

Durante o processo de desenvolvimento e certificação de um novo modelo de aeronave uma das fases de maior custo em todo o projeto é a campanha de ensaios em voo. Esta etapa demanda grande esforço por parte da indústria desenvolvedora que deve comprovar o atendimento aos requisitos estabelecidos pelos órgãos certificadores, como por exemplo ANAC, FAA e EASA (Celere, 2008).

A campanha de ensaios em voo se divide em dois grandes blocos: ensaios de sistemas e aeronáutica, onde os ensaios relacionados à aeronáutica têm como objetivo principal a comprovação da qualidade de voo, e performance.

Os ensaios de performance, por exemplo, possuem requisitos de certificação bem definidos e delimitados na qual comprovação do atendimento ao requisito é demonstrada com base em índices de desempenho e tolerância que garantem a segurança da operação e/ou desempenho esperado pelo mercado.

Da mesma forma, a comprovação da qualidade de voo segue o mesmo padrão de certificação, a menos da subparte que se trata da oscilação gerada pelo acoplamento entre o piloto e a aeronave, oscilação esta conhecida como PIO (Pilot-Induced Oscillation). Para este requisito a demonstração da baixa susceptibilidade a esta oscilação é feita pela análise subjetiva do piloto, baseando-se em formações especificas para ensaios em voo e experiências passadas (Celere, 2008).

A campanha de ensaios em voo para comprovação da baixa susceptibilidade ao PIO é realizada com diversas manobras consagradas durante o processo de certificação. Tais manobras serão apresentadas detalhadamente nos capítulos posteriores deste trabalho.

A abrangência do estudo do PIO está diretamente relacionada a aeronaves civis e militares. Em aeronaves de aplicações civis o PIO pode ser experimentado durante

pouso, capturas de condições de voo e correções necessárias em curto período de tempo. Em aeronaves militares o PIO pode ser evidenciado, além das situações mencionadas anteriormente, em condições de acoplamento de alvos, missões de reabastecimento em voo, lançamentos de carga, combate a incêndio florestal, voo de formatura, dentre outros.

Durante o processo de certificação, todas as manobras para análise do PIO devem ser realizadas em diversas configurações, como posições de Flap, trem de pouso, velocidade e altitude e etc. Desta forma, a quantidade de combinações de configurações geradas é excessivamente grande. Este fato aliado ao fato de que o requisito de certificação de PIO impõe a repetição de todas as manobras com diversos pilotos, de modo a contornar uma possível subjetividade pessoal na análise, demanda excessivo esforço e custo para esta fase da certificação.

Com diversos novos modelos de aeronaves em desenvolvimento em todo o mundo, aliado à novas tecnologias embarcadas que auxiliam no ganho em performance e aumento aparente de estabilidade, eventos de PIO tem sido cada vez mais objeto de estudo no meio científico, no intuito de aumentar a previsibilidade e até mesmo a capacidade de prover o amortecimento da oscilação. Desta forma, a motivação para este trabalho vem dos desafios científicos atuais envolvidos em PIO e a crescente demanda da indústria por certificar novos modelos que atendam de forma segura e com menor custo aos requisitos de qualidade de voo.

Ademais, a indústria atualmente caminha no sentido de redução da tripulação gerando aeronaves cada vez mais autônomas. Tal desenvolvimento se iniciou em etapas específicas do voo, como o pouso automático (Auto Landing), por exemplo, na qual a aeronave é capaz de realizar o pouso de forma completa sem a atividade direta de controle por parte do piloto.

Apesar da remoção do comando do piloto em novas aeronaves cada vez mais autônomas, a oscilação gerada pelo acoplamento entre o veículo e o comando atribuído à lei de controle podem eventualmente gerar oscilações caracterizadas como PIO. Desta forma, é evidente a preocupação durante o desenvolvimento de novos projetos com a integração entre a lei de controle e a resposta da aeronave, para garantir a segurança

da operação quanto à oscilação característica de PIO mesmo em aeronaves autônomas. Neste cenário, estudos para o aumento da assertividade da análise e diminuição da susceptibilidade ao PIO tem sido alvo recente em centros de pesquisa de todo o mundo.

Considerando todo o espectro de tipos e aplicabilidades de aeronaves para o amplo uso público civil e militar, a operação destes veículos tem influência direta e indireta com a atividade humana de forma a expor vidas e atividades comerciais com o transporte de pessoas e logístico. A motivação deste trabalho é agregar valor à análise de PIO feita durante processos de certificação diminuindo a subjetividade da comprovação dos requisitos e aumentando assim a assertividade da conclusão.

Por parte da indústria, uma maior eficiência na análise de PIO provê redução de custos, esforços e aumento da eficiência da campanha de ensaios para a certificação de um novo modelo, de modo a garantir a competitividade, sem abrir mão do atendimento aos critérios de seguranças estipulados pelos órgãos certificadores durante a vida operacional (Gaines, 2014).

Esta dissertação traz a proposta de análise dos dados gerados durante o ensaio de PIO a fim de melhorar a assertividade do resultado, garantindo assim maior segurança à operação. O trabalho realizado utilizou recursos, técnicas e conhecimentos desenvolvidos do espaço acadêmico da Escola de Engenharia de São Carlos, aliando o meio científico às necessidades da indústria, em benefício da sociedade.

1.2. CONTEXTO INDUSTRIAL E CIENTÍFICO

É notória a dificuldade das fabricantes de aeronaves em colocar um novo modelo no mercado que atenda aos requisitos de segurança específicos dos órgãos certificadores e aqueles de concorrência de mercado. Estes requisitos abrangem desde itens estruturais até itens sistêmicos, passando por todas as possíveis falhas dos sistemas e eventuais consequências (Celere, 2008).

Todo novo projeto passa por definições que tendem entre dois extremos: a necessidade de se inovar trazendo soluções de alta eficiência, aumentando assim as

possibilidades de sucesso do produto em termos de vendas e ganho de capital; e a necessidade de redução de custos do projeto atrelado à garantia de certificação e comercialização.

O processo de entrada no mercado de um novo modelo inicia-se com a análise de inteligência de mercado na avaliação de possíveis nichos, onde a aeronave atenda a alguma demanda futura. Desta forma, é evidente que a finalização da certificação do novo produto deva ser garantida dentro de uma margem de tempo para não se "perder" a oportunidade detectada pelo grupo de inteligência de mercado. O tempo entre a detecção deste novo nicho até a certificação final do produto pode levar entre 5 e 10 anos, dependendo da complexidade e variações de operações nele empregado.

Em conjunto com o desenvolvimento da aeronave a engenharia provê soluções durante todas as fases do projeto, seja na concepção inicial até a escolha de fornecedores, e também os requisitos de cada sistema para atender os critérios de qualidade do produto a ser desenvolvido.

Durante os últimos anos, a aviação tem se modificado com a inclusão de novas tecnologias e necessidades de mobilidade aérea urbana. Atualmente estão em pleno desenvolvimento aeronaves leves de decolagem e pouso vertical com propulsão elétrica e autônomas, conhecidas como eVTOL *"Electrical Vertical Take Off and Landing"*. Estas aeronaves tendem a suprir algumas necessidades de mobilidade aérea urbana, propondo baixa emissão de gás carbônico e baixo ruído.

Recentemente várias fabricantes estão desenvolvendo protótipos em escala para o entendimento e integração dos sistemas moto propulsores e de controle de voo. Para a certificação completa destes novos modelos de aeronave, serão necessários os cumprimentos de todos os requisitos que garantem a segurança do público geral conforme os processos de certificação. Desta forma, os requisitos próprios deste tipo de aeronave para qualidade de voo deverão ser seguidos e comprovados, evidenciando a necessidade de se quantificar e classificar oscilações como a de PIO.

Todo o processo de desenvolvimento é custoso e na maioria dos projetos é financiado por mais de uma instituição, seja ela governamental ou privada. Desta forma

qualquer ganho em eficiência durante o desenvolvimento é tido como crucial para a garantia de sucesso do produto e prazo de entrega (Celere, 2008).

1.3. REQUISITOS DE AERONAVEGABILIDADE

A idade contemporânea foi marcada por grandes desafios dentre eles a busca pela capacidade de voar. O voo do 14 Bis realizado por Santos Dumont em 1906 escreveu o início de uma nova era como a primeira aeronave a conseguir alçar voo por meios próprios e com controle direcional. Assim por mais de uma centena de anos o ser humano tem estudado e aprimorado técnicas que garantem à aeronave voo com margens de seguranças toleráveis.

Ao longo de décadas a comunidade científica incentivada por instituições privadas e governamentais iniciaram uma grande disputa por novas tecnologias que proporcionassem melhor dinâmica de voo. Evidentemente foram grandes os desafios para termos nos dias de hoje máquinas de alta complexidade e confiabilidade como as aeronaves modernas.

Muitos foram os acidentes durante os primórdios da aviação por vários motivos como, por exemplo, condições meteorológicas. Naquela época não se tinha grande entendimento de seus efeitos no voo, sejam eles estruturais, motores, aerodinâmicos, dentre outros. Ao longo dos anos os Estados Unidos estiveram sempre a vanguarda na utilização e consequentemente na regulação da atividade aeronáutica, demonstrando grande interesse na aplicabilidade de aviões para fins de transporte de mercadorias, pessoas e militar.

Assim o poder público americano lançou o primeiro regulamento com os requisitos aeronáuticos na tentativa de regular a nova classe de transporte em plena expansão (United States Army Air Corps, 1920). Porém este requisito inicial não continha grandes orientações do ponto de vista de certificação e garantia de segurança. Em 1926 foi publicado o primeiro requisito comercial sob o título de *Air Commerce Act*, onde nele

havia os primeiros regulamentos definidos com base na comunidade cientifica para a regulação e certificação da atividade aeronáutica (Celere, 2008).

Durante as décadas seguintes foram sendo publicadas pelo governo americano novas diretrizes para a regulação da aviação, com alvo na aeronavegabilidade e segurança da operação. Com este intuito, em 1949 no pós Segunda Guerra Mundial - início da guerra fria, foi lançado o CAR-3 e CAR-4 (Civil Aeronautics Board, 1949 / Bureal of Air Commerce, 1936).

Em 1958 o congresso americano aprovou a divulgação do *Code Of Federal Regulations – FAR25: Airworthiness Standard for Transport Categories Airplanes* (Federal Aviation Administration, 1965). Este documento continha as principais disciplinas para a certificação subdivididos em performance, qualidade de voo, sistemas e estruturas, onde cada subitem define seus critérios específicos de certificação como adequabilidade, confiabilidade, margens de segurança e falhas (Celere, 2008).

Este trabalho utilizou o *Code Of Federal Regulations – FAR25: Airworthness Standard for Transport Categories Airplanes* (Federal Aviation Administration, 1965) como guia. Ao longo do desenvolvimento deste trabalho, foram coletados os dados de PIO de uma aeronave de transporte certificada de acordo com FAR25.

Assim os requisitos referentes à certificação de qualidade de voo para PIO foram utilizados como base central para o desenvolvimento deste estudo, bem como a determinação da matriz de ensaios e combinações de configurações. No decorrer deste trabalho será apresentada a matriz de ensaio e aeronave utilizada no desenvolvimento da dissertação.

Em uma leitura dedicada ao FAR25 na seção referente à qualidade de voo fica evidente a falta de tratamento específico para a certificação de PIO. Desta forma durante a campanha de ensaios em voo a caracterização da aeronave como sendo de baixa susceptibilidade ao PIO é dada pela avaliação dos pilotos de prova envolvidos, adicionando possíveis erros à esta classificação que pode apresentar subjetividade. Este trabalho vem no intuito de melhorar o processo de classificação para um dado evento

de PIO maximizando a assertividade do resultado durante o processo de certificação da aeronave.

A seção do FAR 25.143 General (Federal Aviation Administration, 1965) traz a ideia principal para o processo de certificação de qualidade de voo, compondo a seguinte descrição:

§FAR 25.143 General

a) A aeronave deverá ser controlável e manobrável de maneira segura durante
    1) Decolagem
    2) Subida
    3) Voo nivelado
    4) Descida
    5) Pouso
b) Deverá ser possível fazer transição de uma para qualquer outra condição de voo sem habilidades excepcionais, força excessiva ou alerta excessivo dos pilotos e sem exceder os limites de cargas sob quaisquer condições operacionais prováveis, [...].

Na leitura desta pequena parte referente aos requisitos mínimos necessários para certificação da qualidade de voo é possível verificar a subjetividade do requisito. Dado este desafio, além de outros nos testes de certificação, a comunidade de certificadores na figura do FAA lançou um guia de ensaios em voo com a versão mais recente de 2018, intitulado *Advisory Circular AC25-7D* (Federal Aviation Administration, 2018).

No estudo detalhado da *AC 25-7D,* verifica-se algumas diretrizes operacionais relacionadas ao cumprimento da certificação de PIO. Na sequência serão destacados alguns excertos da *AC 25-7D* que foram usados como base o desenvolvimento desta dissertação.

A seção 5.1.4 desta Advisory Circular orienta as seguintes diretrizes para os ensaios de PIO:

Item 5.1.4.1.1: As seções FAR 25 §143 (a) e (b) requerem que a aeronave seja manobrável e controlável, de maneira segura sem habilidades excepcionais de pilotagem e sem perigo de exceder o fator de carga sob quaisquer condições operacionais prováveis.

A história de eventos em serviços indica que aeronaves de transporte moderno podem ser susceptíveis a acoplamento aeronave - piloto sob certas condições operacionais e não atenderiam às intenções do requisito (Federal Aviation Administration, 2018, Tradução).

Item 5.1.4.1.2: A situação clássica de acoplamento aeronave piloto é considerada quando alguma medida da resposta da aeronave está aproximadamente a 180 graus fora de fase com o sinal de controle do piloto [...] (Federal Aviation Administration, 2018, Tradução).

O texto acima traduzido da *Advisory Circular* introduz o conceito básico de entendimento do efeito de PIO. Nesta dissertação, posteriormente, será definido o PIO, com referências acadêmicas em um capítulo específico para tal.

Item 5.1.4.1.4: Experiencias anteriores concluíram que somente o atendimento aos requisitos quantitativos em malha aberta não garantem que níveis de qualidade de voo sejam atingidos. Portanto, para garantir que a aeronave tenha atingido os requisitos de qualidade de voo dos FAR §25.143 (a) e (b), a aeronave necessita ser avaliada por pilotos de ensaio conduzindo tarefas de alto ganho e malha-fechada para determinar que o potencial para encontrar tendências adversas são mínimas (Federal Aviation Administration, 2018, Tradução).

Com base no excerto extraído da AC 25-7D anterior, o desenvolvimento da dissertação deste trabalho foi realizado com pilotos de prova da indústria aeronáutica, bem como as manobras contemplam tarefas em malha-fechada e com alto ganho de acordo com a experiencia dos pilotos envolvidos.

Do item 5.1.4.2 Considerações Especiais:

Item 5.1.4.2.6: A avaliação da qualidade de voo de acordo com FAR §25.143 (a) e (b) é essencialmente qualitativa, especialmente as avaliações de susceptibilidade ao PIO. As tarefas de alto ganho devem ser realizadas por pelo menos três pilotos de prova. O uso de outros pilotos pode ser considerada uma avaliação adicional da qualidade de voo, porém o propósito de demonstração do requisito deve ser feito com a avaliação de pilotos de prova (Federal Aviation Administration, 2018, Tradução).

No excerto acima traduzido da *AC 25-7D* fica evidenciada a subjetividade com relação à análise da susceptibilidade ao PIO. Desta forma, foram utilizados pelo menos três pilotos de prova para a realização da mesma manobra nas mesmas condições, com treinamento e formações especificas para tal atividade.

Do item 5.1.4.3: Procedimentos de Ensaios em Voo

Item 5.1.4.3.2: As manobras para a certificação devem ser baseadas em situações operacionais, manobras de ensaios em voo ou dificuldades operacionais que induzem ao PIO [...]

Item 5.1.4.3.3: As tarefas descritas para a certificação da aeronave foram fundamentadas em situações operacionais vivenciadas no passado, [...]. Tarefas de capturas e manutenção proporcionam a avaliação do PIO. Dependendo das características da aeronave, é prudente a avaliação primeiramente das tarefas de capturas, e então a avaliação da manutenção da captura. Apenas após a avaliação destas características separadamente que se deve demonstrar em conjunto a captura e manutenção como apropriado (Federal Aviation Administration, 2018, Tradução).

O excerto acima traduzido da *AC25-7D* demonstra algumas características que devem ser seguidas para a definição dos procedimentos de ensaios durante a campanha de certificação. Para esta dissertação, as propostas das manobras levaram em conta tais condições sugeridas pela *Advisory Circular* partindo diretamente para manobras de captura e manutenção em conjunto.

Do item 5.1.4.5 Tarefas de Capturas e Manutenção:

Item 5.1.4.5.1: Estas tarefas podem ser utilizadas para a avaliação da susceptibilidade ao PIO como em um voo com atmosfera turbulenta. Nesta tarefa, a trajetória alvo a ser seguida é apresentada com variações de comandos de pitch e roll fazendo com que o piloto siga tais variações. [...]. Os comandos de pitch e roll podem ser em steps ou rampa. A sequência de variações de pitch e roll deve ser de tal forma que a aeronave não tenha variações maiores de 1000ft (Feet) e 10KIAS (Knot-Indicated Air Speed) com relação à altitude e velocidade inicial do ponto de ensaio. A sequência deve ser longa o suficiente e complexa o suficiente para que a o piloto não aprenda e antecipe os comandos. A não familiaridade do piloto com a tarefa aumenta a possibilidade da realização da manobra com alto ganho e impede compensações do piloto para realização da manobra. Tal compensação somada à execução com baixo ganho, pode mascarar tendências de PIO.

Item 5.1.4.5.4: Baseado em eventos de PIO, manobras de captura e manutenção em altas altitudes com variações de 4 graus de pitch com relação ao valor compensado e intervalos entre 2 e 5 segundos tem se demonstrado eficientes para avaliação da susceptibilidade ao PIO. Estas manobras coincidem com a condição de voo da aeronave com baixa margem de fator de carga e buffet onset. [...](Federal Aviation Administration, 2018, Tradução).

Tais pontos de atenção anteriores descritas pela *AC25-7D* foram consideradas durante a definição da matriz de ensaios, que será posteriormente descrita nesta dissertação.

A *AC25-7D* exemplifica o perfil de uma tarefa com variações de pitch. (Federal Aviation Administration, 2018).

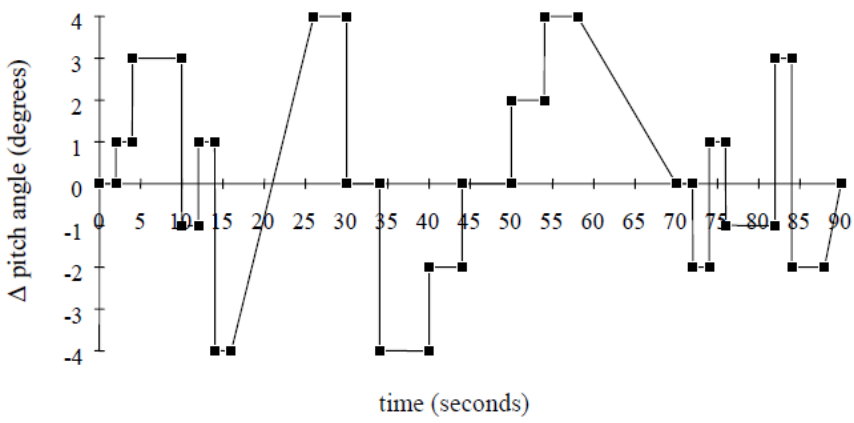

Figura 1 Exemplo de perfil de Tarefa Sintética. Fonte: AC 25-7D

A Figura 1 demonstra um exemplo de tarefa para indução do PIO pela variação de Pitch da aeronave induzindo oscilação no eixo longitudinal. A tarefa proposta pela Figura 1 segue as recomendações da *AC25-7D* com de variações em degraus e rampas. O perfil de variação longitudinal a ser utilizada neste trabalho será posteriormente descrito no capítulo Materiais e Métodos, item Tarefa Sintética / Pitch Capture.

1.4. OBJETIVO

Esta dissertação consiste na análise direta dos dados gerados com casos de PIO em diferentes níveis de acordo com a escala de PIOR *"PIO Rating"*. Tal escala será apresentada nos capítulos posteriores referentes ao estudo do PIO, na qual os dados dos ensaios foram gerados a partir de vários casos obtidos em um ambiente de simulação em bancada.

Este trabalho teve dois objetivos principais:

- A análise da dispersão entre as classificações de PIOR de manobras em condições idênticas executadas por diferentes pilotos.
- A classificação do evento de PIO de acordo com a escala PIOR utilizando uma rede neural artificial para tal, diminuindo assim a subjetividade hoje inerente à análise do PIO durante a certificação de uma nova aeronave.

A estrutura da rede neural artificial utilizada será melhor detalhada nos capítulos posteriores deste trabalho. Com o desenvolvimento da ferramenta baseada em rede neural artificial para classificação do PIO com a utilização dos dados de voo, obtém-se a maximização da assertividade do evento, de forma a melhorar a segurança na operação dos futuros projetos que hoje diferem dos conceitos comumente utilizados na aviação mundial.

Para análise de dispersão foram utilizados 20 pilotos para a geração completa dos dados, sendo 10 para Tarefa Sintética e 10 para a manobra de Pitch Capture. Vale ressaltar que os dois grupos de 10 pilotos que realizaram as manobras foram compostos na maioria em pilotos diferentes. Com o resultado analisou-se a subjetividade da classificação, ou seja, para uma mesma manobra e condições pilotos distintos classificam o PIO diferentemente. A análise do segundo item foi realizada com os mesmos dados de ensaios gerados para a obtenção da análise do primeiro item apresentado como objetivo.

1.5. ESTRUTURA DO DOCUMENTO

Este item é dedicado à apresentação do um resumo do conteúdo de cada capítulo desta dissertação.

O capítulo 1, de Introdução deste trabalho, contempla a motivação da proposta do trabalho, o contexto industrial e científico na qual este trabalho auxilia no desenvolvimento de novos projetos aeronáuticos, os requisitos de certificação de um novo modelo que moldaram as definições desta dissertação e os objetivos principais.

O capítulo 2, de Fundamentação Teórica, apresenta as fundamentações teóricas envolvidas nas ciências de PIO e Redes Neurais Artificiais, provendo o entendimento necessário para o desenvolvimento deste trabalho.

O capítulo 3, de Materiais e Métodos, expõe o ambiente de simulação utilizado como plataforma de ensaios, a modelagem da aeronave utilizada nos ensaios bem como

o desenvolvimento dos submodelos, as definições das manobras utilizadas nos ensaios, a matriz de ensaios e a metodologia empregada no treinamento da rede neural artificial.

O capítulo 4, de Resultados, traz a dinâmica das sessões de ensaios realizados, as definições da arquitetura da rede neural artificial e suas entradas e por fim os resultados da análise subjetiva do PIO e sua classificação utilizando redes neurais artificiais.

O capítulo 5, Conclusões e Trabalhos Futuros, expõe as conclusões obtidas com os resultados deste trabalho e também propostas de trabalhos futuros com possíveis continuidades desta dissertação.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. PILOT-INDUCED OSCILLATION

Durante décadas a aviação vem se modificando com relação ao design das aeronaves na busca incessante por projetos menos poluentes e mais eficientes em consumo, manutenção e produção. Tal demanda por eficiência aumentada gera, por consequência, grandes alterações de estabilidade. Projetos que em sua essência física são considerados instáveis em certas condições de voo recebem auxílio eletrônico de estabilidade, conhecido como sistema *"Fly-by wire"* (FBW), para garantirem assim o cumprimento dos requisitos anteriormente definidos pelos órgãos certificadores de qualidade voo (Neves, Bruschi, Bidinotto, 2021).

O sistema FBW opera por meio de eletrônica embarcada na qual sua arquitetura contempla processadores com confiabilidade comprovada sendo estes com multiplicidade e, em alguns casos, dissimilares. Neste sistema são processados os algoritmos de controle que proveem à tripulação estabilidade aparente por meio dos atuadores eletrônicos instalados diretamente nas superfícies primárias da aeronave (Celere, 2008).

A lógica associada ao sistema FBW provê monitoramento constante de variáveis definidas de controle por meio de malha fechada de forma a garantir que a aeronave não extrapole limites de projeto pré-estabelecidos, como, por exemplo, limites de AOA *"Angle of Attack"*, velocidades operacionais e fatores de cargas. Com esta garantia de não extrapolação dos limites de projeto associada a alta confiabilidade do sistema, fica possível o alívio estrutural do projeto e, por consequência, a redução do peso final, maximizando a eficiência da aeronave em sua vida operacional.

O FBW tem se destacado na utilização em aeronaves modernas, porém a arquitetura na qual o sistema é desenvolvido torna inevitável o aumento do atraso entre o comando do piloto e a efetiva atuação da superfície de comando, ou seja, a resposta

da aeronave. Este atraso associado à caraterística de baixa estabilidade inerente ao projeto físico em aeronaves modernas, aumenta as chances de oscilação com o descasamento entre o comando do piloto e a resposta da aeronave.

Ao longo de décadas de estudos de qualidade de voo foram feitas inúmeras tentativas de definição desta oscilação, hoje conhecida como PIO. A melhor e mais abrangente foi feita pelo Departamento de Defesa dos Estados Unidos e Publicada na Mil Standard 1797A, onde PIO é caracterizado pelo seguinte texto: (Celere, 2008).

> *PIO são oscilações sustentadas e não controláveis resultantes de uma ação direta para controlar a aeronave (Department of Defense Interface Standard, 1990, Tradução).*

Analisando a frase anterior tende-se a entender que os efeitos de oscilação proveniente de PIO são integralmente não controláveis. Tal definição, dada em 1990 não se aplica integralmente aos dias de hoje pois na indústria aeronáutica eventos caracterizados como PIO não são incontroláveis em sua totalidade. Atualmente utiliza-se a escala de PIOR *"PIO Rating"* a qual será posteriormente apresentada nesta dissertação. Esta escala define o nível de intensidade do PIO fornecendo o nível de controlabilidade da oscilação.

Matematicamente o PIO pode ser caracterizado pelo atraso de fase entre o input do piloto no comando desejado e a resposta efetiva da aeronave na ordem de 180°. Tal efeito de descasamento de fase do sistema piloto e aeronave é sempre consequente de uma pilotagem de alto ganho caracterizado por uma típica pilotagem de capturas abruptas para se executar uma determinada tarefa específica.

Tipicamente este tipo de pilotagem é mais marcante em aeronaves militares onde o piloto em treinamento ou executando uma operação real deve realizar uma determinada missão, como, por exemplo a busca de alvos, capturas de condições de voo ou manutenção de voo em formação.

Um exemplo de missão militar onde se evidencia comumente PIO é a de reabastecimento em voo na qual o piloto da aeronave recebedora deve se manter em voo de formação, muitas vezes com características de qualidade de voo e oscilações não típicas de um voo convencional. Neste tipo de missão, deve-se acoplar a haste recebedora de combustível na cesta da aeronave "tanker" e a captura desta cesta para acoplamento do sistema de transferência de combustível é feita com comandos que podem gerar PIO na aeronave recebedora. Para tal fim é pode haver a necessidade da modificação da resposta da aeronave por meio do sistema FBW diminuindo assim a susceptibilidade ao PIO.

Este tipo de oscilação não é caracterizada apenas em aeronaves militares. Na aviação civil muitos foram os eventos que levaram ao PIO e em alguns casos com perdas materiais e de vidas. Alguns destes eventos serão citados a seguir.

A tarefa de mudança repentina de direção de voo durante o pouso, por exemplo, pode ser um gerador de PIO ocasionado por um desvio de pássaro ou mesmo condições meteorológicas desfavoráveis. Tal desvio no pouso associado à necessidade de se corrigir rapidamente a aproximação da aeronave com a pista pode ser um gerador de oscilação a baixa altura, diminuindo assim as margens de segurança durante o pouso.

Esta oscilação pode ser experimentada em aeronaves civis e militares comprovando que o efeito de PIO pode estar presente em todo o espectro de aeronaves, sendo de grande valia o estudo direcionado a esta ciência.

Durante a transição do desenvolvimento de aeronaves com controles convencionais para sistemas mais modernos com controle eletrônicos foram evidenciados alguns eventos que demonstraram a importância do estudo do PIO. Em 1989 houve o caso da oscilação divergente encontrada durante o sexto pouso do primeiro protótipo do JAS 39 Gripen, onde o piloto testemunhou intensa oscilação divergente a baixa altura vindo a aeronave descontroladamente a colidir com o solo (Gaines, 2014). Tal evento foi intensificado por rajadas de vento que induziram a oscilação durante a manobra de pouso, onde atribui-se a variação abrupta do vento o efeito que desencadeou tal oscilação. O JAS 39 Gripen foi um dos modelos pioneiros de aeronave de combate com margens de estabilidade reduzidas.

Outro modelo que sofreu evento de PIO durante a campanha de ensaios foi o Lockheed YF-22 em 1992, uma aeronave de ataque moderna, na qual o segundo protótipo em campanha de ensaios reportou falha no sistema embarcado de prevenção de PIO. Logo após a falha, a aeronave entrou em oscilação divergente a baixa altura colidindo com a pista (Harris, Black, 1996).

Outro evento envolvendo PIO, destacando-se por caracterizar uma operação completamente distinta das descritas anteriormente, foi a saída de pista observada durante o pouso da aeronave Airbus A330-343 da Air Canada em 2014. Tal evento ocorreu em uma aeronave em operação de um modelo já certificado e civil. Neste evento, na etapa de aproximação até o pouso foi realizada durante chuva intensa com rajadas de ventos, o que demandou rápida correção do piloto a baixa altura para manutenção da rampa de aproximação desejada e captura da linha central da pista. A Figura 2 demonstra os dados obtidos durante o evento (Aviation Investigation Report A14Q0155, 2017).

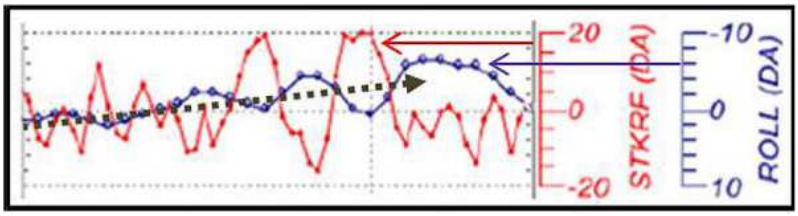

Figura 2PIO A330-343 Air Canada. Fonte: Aviation Invest. Report, 2017

Na análise da Figura 2 é possível verificar o descasamento entre o comando de rolamento do piloto em graus (STKFR - linha vermelha) e a resposta da aeronave em graus (ROLL - linha azul), demonstrando assim a inversão de fase entre comando e resposta lateral logo antes do toque no solo ocasionando a saída de pista durante a desaceleração.

É comumente verificado na literatura científica a respeito de PIO a necessidade de se analisar três características: piloto – veículo – gatilho. Para evidenciar o efeito de

oscilação induzida pelo piloto é estritamente necessária a atuação simultânea desta tríade, onde cada elo deve se compor de características peculiares que induzem à oscilação sustentada.

Do ponto de vista do piloto, e como já mencionado, este deve ter características de pilotagem de alto ganho. Ou seja, deve atuar nas superfícies de comando com ímpeto na busca de executar uma tarefa muitas vezes demandante em captura. O veículo deve ser propício a responder a estes comandos em defasagem com o piloto de forma a caracterizar o atraso de fase do sistema piloto – veículo.

O gatilho é o elo proveniente das intempéries associadas ao voo como, por exemplo, um ajuste necessariamente rápido de aproximação, desvio de pássaros etc. Estas induções de oscilação são frequentemente adicionadas a alguma captura em curto período, o que consequentemente leva o piloto a realizar a manobra com alto ganho (Celere, 2008).

Outra análise importante para o entendimento desta dissertação é quanto à susceptibilidade ao PIO. Aeronaves que apresentam baixa tendência são comumente conhecidas como *PIO Free.* Antagonicamente, aeronaves que são susceptíveis a oscilação induzida pelo piloto são conhecidas como *PIO Prone.* Estes termos são vastamente utilizados na literatura científica assim como nesta dissertação.

É evidente a dificuldade de se identificar o evento como sendo PIO dada a quantidade de variáveis anteriormente explanadas. A oscilação proveniente da defasagem entre o comando do piloto e a resposta da aeronave está muito atrelada ao piloto e sua característica de pilotagem e é possível identificar durante a campanha de ensaios quais são os pilotos que tem maiores aptidões em induzir eventos de PIO. O próprio instinto humano de manutenção da condição estável de voo faz com que um piloto, uma vez identificando tal oscilação, saia automaticamente do ciclo de pilotagem amortecendo-a, de forma a descaracterizar o evento.

Pilotos de prova são objetivamente treinados para realizar manobras que induzam PIO na tentativa de demonstrar que a aeronave tem baixa susceptibilidade a esta oscilação. Desta forma, é possível verificar que a modelagem matemática de um

piloto que induza PIO não é algo trivial de ser obtido. Portanto tem-se como ponto fundamental no desenvolvimento de uma nova aeronave que a campanha de certificação de PIO seja feita por uma equipe de Ensaios em Voo, utilizando o protótipo daquele novo modelo em fase de certificação e variando pilotos de prova em manobras excitadoras de PIO.

Durante a campanha de ensaios em voo pode-se observar algum evento de PIO. Se tal oscilação for declarada como não adequada para o cumprimento dos requisitos de certificação de qualidade de voo, pode-se utilizar artifícios como o FBW para amortecer a oscilação em uma dada condição de voo. É de comum entendimento na comunidade científica que uma aeronave certificada não é considerada livre de PIO, mas sim com baixa susceptibilidade ao evento, sendo comumente chamada de *non PIO Prone* (Celere, 2008).

É consenso a não existência de um método que seja comprovadamente garantida a não susceptibilidade ao PIO. Desta forma, atualmente não é possível garantir uma aeronave como sendo *PIO Free.*

A campanha de ensaios dedicada à certificação de PIO é sempre realizada com algumas manobras definidas como critério para cumprimento dos requisitos descritos de aeronavegabilidade de acordo com as normas de certificação (Federal Aviation Administration, 1965). Como guia prático para tais cumprimentos é utilizado a AC-25-7D (Federal Aviation Administration, 2018). Esta publicação apresenta diretrizes práticas de como cumprir os requisitos mínimos necessários para certificação de um novo modelo de aeronave, que por sua vez contempla as manobras necessárias a serem utilizadas como gatilho durante a campanha de certificação. Estas manobras serão posteriormente descritas nesta dissertação.

Pode-se subdividir as manobras de PIO em duas fases: *Gross Aquisition* e *Fine Tracking.* Estas duas subdivisões acontecem em momentos distintos. *Gross Aquisition* é a consequência primária gerada após o gatilho na qual o piloto inicia o movimento de captura de um dado parâmetro que momentaneamente foi considerado fora da posição esperada. Após a captura deste parâmetro e, por consequência, a oscilação inicia-se a

segundo segmento: *Fine Tracking*. Nesta fase o piloto executa a tarefa de manutenção desta captura mantendo-se na tentativa de ajuste fino (Celere, 2008).

Tais subdivisões podem ser exemplificadas em um cenário onde o piloto está realizando uma decolagem em condições atmosféricas não favoráveis, com alta possibilidade de variações de componente de vento e consequentemente turbulência durante a subida. O procedimento de decolagem operacional define que o piloto deve, após a saída do solo, realizar a subida da aeronave em um dado valor de θ *"Atitude em Arfagem"* constante até uma altitude pré-determinada. Dada as condições atmosféricas adversas, o valor de θ da aeronave varia constantemente devido à turbulência. Neste cenário o piloto executa capturas constantes de θ, *Gross Aquisition,* e posteriormente o *Fine Tracking* na tentativa de manter a atitude ideal durante a subida.

2.1.1. ENSAIOS DE PIO

Durante a campanha de ensaios de certificação de um novo modelo de aeronave são realizadas diversas manobras com o objetivo de avaliar a susceptibilidade ao PIO. Em sua totalidade tais manobras são tarefas de capturas e manutenção de parâmetros nas quais, adicionalmente, são testadas capturas envolvendo movimentos em eixos separados, como, por exemplo, capturas no eixo longitudinal e posteriormente látero-direcional.

Manobras de ensaio destinadas à exploração de PIO no eixo longitudinal são conhecidas como Capturas de θ "*Theta Capture"* ou *"Pitch Capture"*. Nestas manobras o piloto deve iniciar com estabilização da condição de voo por 10 segundos e realizar capturas de θ previamente definidos, mantendo entre 5 e 10 segundos na condição capturada de cada novo θ.

Utilizando do mesmo princípio de análise é realizada a manobra de captura de ângulo de inclinação de asa ϕ "*Bank Angle*". Neste caso, a manobra é realizada com a estabilização inicial de 10 segundos e, posteriormente, valores de ϕ são capturados com alto ganho simetricamente para direita e esquerda. Analogamente ao *Theta Capture,* é

realizada a manutenção da condição do ângulo de captura afim de avaliar a característica de *Fine Tracking* durante o ensaio.

O resultado idealmente esperado nestas duas manobras são traços de uma captura abrupta, *Gross Aquisition,* a uma nova condição de voo e, posteriormente, uma oscilação amortecida, *Fine Tracking*.

Outra manobra amplamente utilizada durante a campanha de certificação de PIO é o *Offset Landing* a qual consiste em realizar aproximação convencional para uma pista, porém com desvio lateral induzido. Em uma dada altitude o piloto inicia a correção buscando o centro da pista e, tentativamente, realizando o toque com o solo no local desejado. Tal situação induz o piloto a realizar a correção de forma rápida, ou seja, com alto ganho adicionado à necessidade de se pousar no local pré-definido. Esta manobra deve ser feita com *"Gradual Approach"*, que neste caso consiste na redução gradativa da altura de início da correção lateral para a definição da altitude de gatilho. Também deve ser previamente realizada em simuladores de voo de engenharia para minimizar possível PIO a baixa altura.

O *Offset Landing* é parte essencial do programa de certificação de uma nova aeronave, que aumenta a garantia do modelo não entrar em um evento de PIO durante a operação.

Análogo às manobras anteriores, tem-se a Tarefa Sintética. Nela o piloto segue um guia em sua tela de navegação. O perfil de movimentação deste guia induz o piloto a realizar a manobra com alto ganho o que pode fazer a aeronave entrar em oscilação, podendo ser no eixo lateral e/ou longitudinal. Como já mencionado, para a caracterização do PIO é necessário que o piloto em comando realize a busca com alto ganho, dado que só assim o sistema aeronave e piloto evidenciará corretamente se a aeronave é ou não *non PIO Prone.*

As manobras Tarefa Sintética e *Pitch Capture* foram utilizadas neste trabalho para indução de PIO. Estas serão descritas nos próximos capítulos desta dissertação, bem como a utilização de um ambiente de simulação provido pelo Departamento de

Engenharia Aeronáutica da Escola de Engenharia de São Carlos da Universidade de São Paulo como plataforma de obtenção dos dados de evento de PIO.

2.1.2. ESCALA PIOR

Conforme visto anteriormente, fica evidente que durante a campanha de ensaios em voo para a certificação de uma aeronave algumas características associadas à qualidade de voo ficavam a cargo única e exclusivamente do piloto, incorporando ao resultado do ensaio a subjetividade do ponto de vista de uma conclusão puramente experimental e humana. Tal subjetividade no resultado faz com que ensaios em condições iguais possam resultar em conclusões diferentes, agregando ao desenvolvimento do produto possíveis características inseguras que não foram corretamente percebidas e até mesmo corrigidas durante a campanha de ensaios.

A alternativa que melhor se adequou à campanha de ensaios foi a escala de Cooper – Harper (Cooper; Harper – 1969), sendo esta uma forma de padronizar o resultado obtido pelo piloto executante. A escala de Cooper – Harper define a divisão de um até dez, de forma que ao resultado excelente é tido como um e dez resultados com grandes deficiências.

Para ensaios de PIO a escala de Cooper – Harper mostrou-se de difícil aplicabilidade. Assim foi definida a Escala de PIO ou PIOR (PIO Rating) (MIL 1797A – Department of Defense Interface Standard, 1990), a qual tem como objetivo caracterizar as oscilações entre um e seis, sendo 1 para respostas de oscilações amortecidas e com resultados plenamente satisfatórios e 6 para oscilações de características divergentes (Celere, 2008).

A escala PIOR pode ser vista na Figura 3 com as definições dos critérios de caracterização das oscilações.

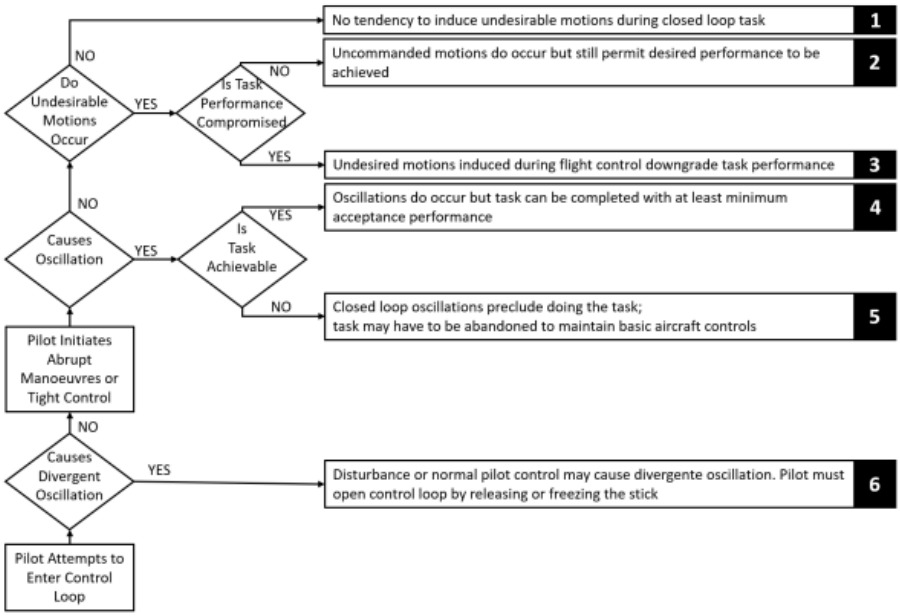

Figura 3 Escala PIOR Fonte: Neves, Bruschi, Bidinotto, 2021

A escala PIOR foi largamente utilizada neste trabalho visando sua aplicabilidade a uma rede neural artificial para o auxílio na classificação das intensidades e características da oscilação, de forma a garantir homogeneidade na conclusão a respeito da característica de *non PIO Prone*.

2.2. REDES NEURAIS ARTIFICIAIS

Redes neurais artificiais (RNA) são modelos computacionais inspirados no funcionamento dos sistemas nervosos dos seres vivos. A composição das redes neurais artificias é feita pela interligação entre neurônios modelados matematicamente, representada por matrizes de pesos sinápticos e vetores. Possuem capacidades correlatas aos sistemas biológicos como, principalmente, aprendizado para realização de tarefas. Dentre suas principais características destaca-se:

Adaptação por experiencia: a adaptação dos parâmetros é feita a partir da exposição sucessiva da rede a dados, possibilitando a aquisição do conhecimento por experimentação.

Capacidade de aprendizado: A partir da aplicação de um método de treinamento, a rede possui a capacidade de aprendizado com base na exposição de dados, ajustando seus pesos sinápticos de forma a garantir melhor execução da tarefa.

Habilidade de generalização: as redes neurais artificiais são de grande valia na utilização de sistemas com grande quantidade de dados de entrada e saídas, sendo estas capazes de definir intercorrelações entre os dados até então desconhecidas.

Tolerância à falha: devida à arquitetura estrutural entre os neurônios que compõem a rede neural artificial, essa se torna tolerável às falhas pontuais compensando eventuais distúrbios nos dados de entrada do sistema.

Facilidade de aplicação: uma vez treinada e finalizada a rede neural artificial, esta é facilmente prototipada em hardware e software, na qual sua execução se resume a simples operações matemáticas (Silva, Spatti, Flauzino, 2016).

Com a evolução da capacidade computacional aliada à necessidade de soluções complexas para os novos desafios da ciência, as redes neurais artificiais têm sido amplamente utilizadas para estes fins. Com a alta capacidade de processamento simultâneo, as redes neurais artificiais proporcionam soluções para sistemas não lineares com alto índice de confiabilidade. Estas RNAs modificam a arquitetura de processamento de dados anteriormente proposta por Von Neumann, na qual a CPU executa uma instrução de forma sequencial, causando assim limitações de desempenho no processamento. Esta arquitetura é utilizada desde 1940 e é a ela atribuída como base da evolução computacional até os dias de hoje.

Com a nova arquitetura proposta pelas redes neurais artificiais, é possível o processamento simultâneo de forma paralela, solucionando assim sistemas complexos e não lineares com maior eficiência (Haykin, 2009).

Redes neurais artificiais podem ser utilizadas em diversas áreas industriais devido à sua capacidade de processamento em múltiplas entradas e saídas e também classificações e controles (Suzuki, 2010). Sistemas aeronáuticos e aeroespaciais podem ser analisados a partir de redes neurais artificiais, como no caso de aplicação do seu uso

em *Flight Control System* (FCS) de forma adaptativa, utilizando entradas na rede com características de voo e saídas com a aplicação de comando nas superfícies primarias da aeronave, promovendo possíveis compensações em caso de falha (Mackall, Nelson, Schumann 2002).

Além do uso industrial, as redes neurais artificiais podem ser aplicadas nas mais variadas áreas como, por exemplo, na medicina. De acordo com (Ciresan, Giusti, Gambardella, Schmidhuber, 2013; Khan, Wei, Ringnér, Saal, Ladanyi 2001) se propõe o estudo da aplicação de redes neurais artificiais para o auxílio no diagnóstico de câncer com base no perfil genético, bem como a proposta de (Yan, Jiang, Zheng, Peng, Li, 2006) indicando o uso de redes neurais artificias para diagnóstico de problemas cardíacos.

Atualmente estão registrados trabalhos com a utilização de redes neurais artificiais também na área da química para a obtenção de novos compostos poliméricos, como proposto por (Steinera, Hisselb, Moçotéguy, Candussoc, 2011; Zhang, Friedrich, 2003). Outros estudos de química em conjunto com ecologia evidenciam o uso de redes neurais artificias no tratamento da água para consumo humano, bem como sua utilização para predição da qualidade da mesma, de forma a garantir melhor qualidade e eficiência no processo de tratamento (Han, Chen, Qiao, 2011; Zhang, Stanley, 2011).

Ainda no ramo da ecologia, estudos utilizam as redes neurais artificiais para determinação da relação entre a influência do clima e a taxa de crescimento de árvores (Lek, Guégan, 2012; Zhang, Hebda, Zhang, Alfaro, 2000).

Em alguns estudos da indústria farmacêutica é possível encontrar o emprego de redes neurais artificias para auxiliar na elaboração de fórmulas químicas (Deeb, 2010; Mendyk, Jachowicz, 2007).

Há também sua aplicabilidade para o reconhecimento de sons. Com a aplicação de redes neurais artificiais se torna possível o reconhecimento de espécies de morcego devida à classificação dos sinais de ecolocalização (biosonar) emitidos durante o voo (Armitage, Ober, 2010; Parsons, Jones, 2000). Na mesma linha de estudo (Tian, Shang, 2006) traz a classificação de espécies de ratos utilizando seus próprios sons.

No ramo de acústica pesquisas utilizam redes neurais artificias para classificar a impedância acústica de um ambiente (Too, Chen, Hwang, 2007). A capacidade das redes neurais artificias em diferenciar padrões e as classificar é expressa em (Fernandes, 2009), na qual as utiliza para obtenção de fontes de harmônicos em sistemas elétricos de distribuição.

Também em classificações de padrões, redes neurais artificiais são utilizadas até mesmo em etologia, no qual classifica os sentimentos humanos com base em expressões faciais (Agarwal, Agrawal, Jain, Kumar, 2010; Dailey, Cottrel, 2002).

Na área de economia, RNA são utilizadas para predição de tendências de mercado. Sistemas financeiros são inerentemente não-lineares e as RNA podem ser empregadas graças à sua capacidade de tratar as não-linearidades (Karaa, Boyacioglub, Baykan, 2011; Coakley, Brown, 2000).

Já na agricultura, a profundidade de penetração no solo pelos fertilizantes pode ser medida com auxílio de redes neurais artificiais, de forma a garantir uma aplicação segura e com possíveis medidas de contenção, caso necessário (Chowdhury, Alouani, Hossain, 2010; Tabach, Lancelot, Shahrour, Najjar, 2007).

Em toda vasta aplicação industrial tem-se o uso de redes neurais artificiais para o controle, predição e classificação de diversos processos. No setor automotivo e aeroespacial destaca-se sua aplicação para o controle de veículos aéreos não tripulados (Cho, Ma, Lee, 2006), já em (Vicente, Cezare, Silva, 2007) é proposta sua utilização para o controle de marcha lenta em motores a combustão.

Outro ramo é a aplicação de redes neurais artificiais em sistemas de inteligência computacional. Várias são as aplicações em sistemas *fuzzy* (Zadeh, 1992; Pedrych, Gomide, 2007; Buckley, Siler, 2004; Ross, 2004), computação evolutiva (Michalewicz, 1999; Dasgupta, Michalewicz, 1997; Goldberg, 1989), inteligência coletiva (Kennedy, Eberhart, 2001), sistemas imunológicos artificias (Dasgupta, 2006; Castro, Timmis, 2002) e agentes inteligentes (D'Inverno, Luck, 2004).

Como visto, diversas são as aplicações de redes neurais artificiais nos vários ramos do conhecimento. Essa dissertação propõe sua utilização para solução da subjetividade na classificação de PIO.

A base da estrutura computacional de uma rede neural artificial é a formação de sua arquitetura por unidades de processamento correspondentes aos neurônios em uma estrutura biológica. Os neurônios são interconectados pela sinapse que é representado por um ganho na estrutura computacional definido a partir do treinamento na qual a rede deve ser submetida para executar a tarefa proposta (Silva, Spatti, Flauzino, 2016).

Para o correto funcionamento da rede, deve-se treiná-la até que o resultado seja estatisticamente satisfatório para o resultado obtido pela rede neural artificial. Os dados a serem utilizados no treinamento da malha devem estar em conformidade com o resultado a ser esperado, ou seja, os dados de treinamento devem refletir o cenário ao qual será submetida a rede neural durante sua utilização. Os dados de entrada devem ter características que evidenciem e os distinguem, para assim aumentar a assertividade do resultado obtido.

Com base na característica de treinamento da rede é possível evidenciá-la como uma “máquina adaptativa”. Com a mesma estrutura de rede neural artificial obtém-se resultados diferentes consequentes de seu treinamento. (Haykin, 2001).

Após o treino correto e exaustivo é possível utilizá-la para a obtenção de resultados aos quais se espera alto grau de confiabilidade. É comum deparar-se com dados não ideais a serem utilizados na rede neural artificial e três anomalias básicas são comumente obtidas em dados experimentais, tais como:

Generalização: são dados que tem pouca semelhança de ordem comparativa, porém podem levar a um mesmo resultado. Como exemplo prático para esta dissertação seria a comparação pouco significativa entre dois pilotos executando uma mesma manobra e a ela ser atribuída uma a mesma classificação de PIO.

Ruído: são poluições da informação principal oriundas de outras fontes. Como, por exemplo para este trabalho, a execução da manobra de PIO em condições de turbulência, que caracterizam oscilações na aeronave sem o comando efetivo do piloto e não devem ser atribuídas ao ensaio.

Dados parciais: São dados gerados com possibilidades de partes faltantes. Ou seja, na qual não está composto em sua completude trazendo apenas informações que podem ou não serem suficientes para a caracterização. Neste trabalho não foi aceito qualquer dado com característica parcial, ou seja, apenas manobras realizadas integralmente (Graupe, 2007).

Com base nas possíveis divergências apresentadas anteriormente, enfatiza-se a necessidade da correta realização dos ensaios no ambiente de simulação, com a necessidade da validação da manobra e do dado, anteriormente à utilização na rede, além da escolha otimizada dos parâmetros de identificação para serem utilizados como entradas na rede neural artificial.

A rede pode ser comparada a uma malha de neurônios interconectados. Para melhor entendimento do funcionamento desta, se faz necessário o estudo do modelo matemático de um único neurônio sendo subparte desta rede. Este pode ser observado na Figura 4, que representa o modelo proposto por (McCulloch, Pitts, 1943), na qual engloba as principais características de uma rede neural biológica, isto é, paralelismo e alta conectividade.

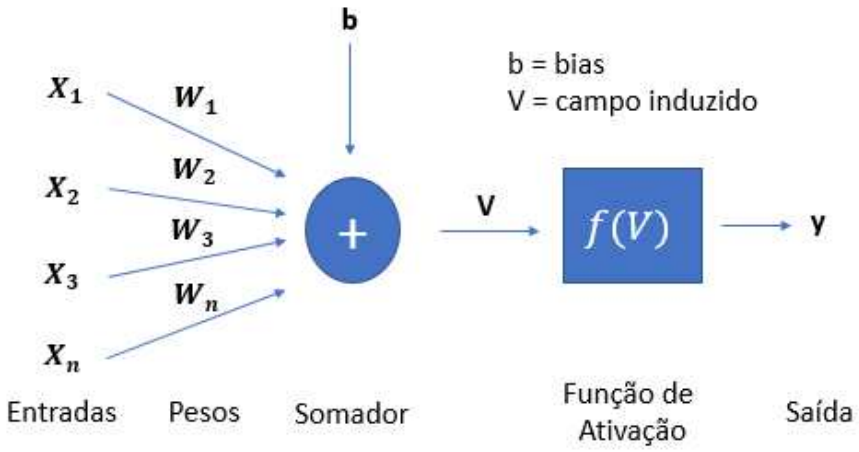

Figura 4 Modelo Neurônio Fonte: Autor

Na Figura 4 tem-se os valores representados por x_n como as entradas que podem ser sinais oriundos de sensores, arquivos de imagens, áudios ou entradas numéricas. Como visto, os valores de entradas foram escolhidos pois estão diretamente relacionadas com a capacidade de assertividade da rede neural artificial, as entradas podem ser quantas forem necessárias para garantirem o correto funcionamento da malha.

Posteriormente às entradas, tem-se a atribuição dos pesos sinápticos que estão representadas pelos valores de w_n, aos quais estão associados os ganhos respectivos, podendo ser positivo, negativo ou nulo (Silva, Spatti, Flauzino, 2016). Aos tais valores foram fixados ganhos durante o processo de treinamento da rede neural, onde será possível caracterizar a rede como específica para a realização de uma determinada atividade computacional. No caso deste trabalho, a atividade será a classificação de eventos de PIO de acordo com a tabela PIOR.

A comparação entre o treinamento da rede associando valores de ganhos positivos, negativos ou nulo, é equivalente ao treinamento do neurônio biológico na qual o indivíduo realiza repetidas tarefas até caracterizar o aprendizado, que biologicamente corresponde à intensidade da sinapse entre os neurônios. Ou seja, ao ganho sináptico que cada neurônio biologicamente interliga com o anterior e posterior,

provendo assim a capacidade do indivíduo de finalizar com êxito a atividade (Silva, Spatti, Flauzino, 2016).

Posteriormente às entradas e os pesos atribuídos tem-se o bloco somador, a função deste bloco é a aplicação matemática da função soma. Nela é atribuído também o valor de b chamado de bias. A saída do bloco somador será chamada de campo induzido representada pela letra V, contendo a soma dos valores das entradas com seus respectivos pesos e o valor correspondente ao bias.

O Campo Induzido será atribuído como entrada da função de ativação $f(V)$. A função de ativação tem como objetivo identificar a entrada e definir valores à saída, de forma a ativar ou não o output, sendo utilizado como resposta de ativação do neurônio a variável y. Como exemplo, os valores de y podem ser um ou zero, dependendo de a função ter ou não respectivamente ativado a saída do neurônio.

É possível resumir o modelo matemático do neurônio em duas equações, sendo a equação (1) do Campo Induzido onde:

$$V = \sum_{i=1}^{n} x_n w_n + b \qquad (1)$$

E a equação (2) que representa Função de Ativação, onde:

$$y = f(V) \qquad (2)$$

Para a Função de Ativação tem-se a divisão em dois grupos: funções parcialmente diferenciáveis e funções totalmente diferenciáveis.

As funções de ativação parcialmente diferenciáveis são aquelas que possuem pontos cujas derivadas de primeira ordem são inexistentes. As três principais são:

- Função Degrau: A função degrau é definida quando a saída do neurônio assume valores positivos para potenciais de ativação positivos ou iguais a zero, podendo ser expresso por:

$$f(V) = \begin{cases} 1, se\ V \geq 0 \\ 0, se\ V < 0 \end{cases} \qquad (3)$$

- Função Degrau Bipolar: A função degrau bipolar é aquela em que as saídas assumem valores positivos quando o potencial de ativação do neurônio for maior que zero, valor nulo quando o potencial for também nulo e valores unitários negativos quando o potencial de ativação for menor que zero, desta forma tem-se:

$$f(V) = \begin{cases} 1, se\ V > 0 \\ 0, se\ V = 0 \\ -1, se\ V < 0 \end{cases} \qquad (4)$$

- Função Rampa Simétrica: Os valores de saída de neurônios são modelados a partir de uma função rampa simétrica, são iguais aos próprios valores de ativação para intervalos definidos [-a, a], restringindo-se aos valores limites em casos contrários.

$$f(V) = \begin{cases} a, se\ V > a \\ V\ se - a \leq V \leq a \\ -a, se\ V < -a \end{cases} \qquad (5)$$

Outro grupo de funções de ativação são as totalmente diferenciáveis, que são aquelas cujas derivadas de primeira ordem são conhecidas em todos os pontos de seu domínio. As mais conhecidas são:

- Função Logística: A saída do neurônio modelado pela função logística assume sempre valores entre zero e um independente da ativação, matematicamente pode ser representada por:

$$f(V) = \frac{1}{1 + e^{-av}} \qquad (6)$$

- Função Tangente Hiperbólica: Neste caso os valores de saída sempre serão entre -1 e 1, na qual a expressão matemática é definida por:

$$f(V) = \frac{1 - e^{-av}}{1 + e^{-av}} \qquad (7)$$

- Função Gaussiana: A função gaussiana produzirá resultados iguais para valores distantes iguais da média seguindo o padrão de uma distribuição normal. A função gaussiana é definida matematicamente por:

$$f(V) = e^{-\frac{(u-c)^2}{2\sigma^2}} \qquad (8)$$

- Função Linear: A função linear tem como saída valores idênticos aos valores do potencial de ativação, portanto sua expressão é definida por:

$$f(V) = V \qquad (9)$$

Estas são as principais funções dos dois grupos parcialmente diferenciáveis e totalmente diferenciáveis.

As Figuras 5 e 6 representam dois gráficos Função Degrau (3) e Logística (6), respectivamente, compondo exemplo de funções parcialmente e totalmente diferenciáveis. É possível verificar a saída contida em valores do eixo vertical de forma a ativar ou não o neurônio de acordo com a entrada.

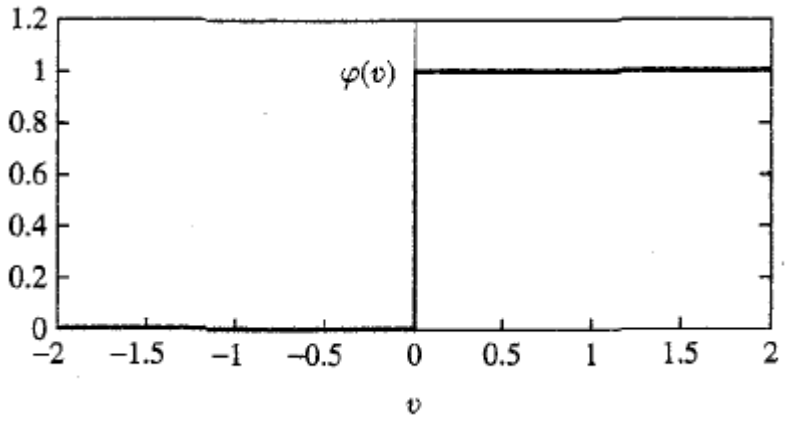

Figura 5 Gráfico Função Degrau Fonte: Haykin, 2001

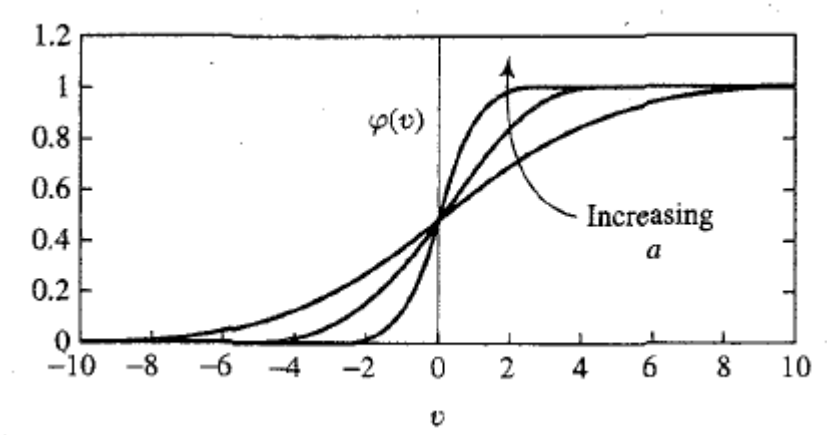

Figura 6 Gráfico Função Logística Fonte: Haykin, 2001

De acordo com a Equação (1) verifica-se que o campo induzido é composto por um somatório de equações da reta, onde cada reta representa uma dimensão ou entrada. Olhando para uma dimensão de apenas uma equação da reta, em conjunto com uma função de ativação, é possível identificá-la como um divisor dos dados que na Figura 7 está caracterizado por círculos e estrelas, podendo ser representados pela saída ativada ou não.

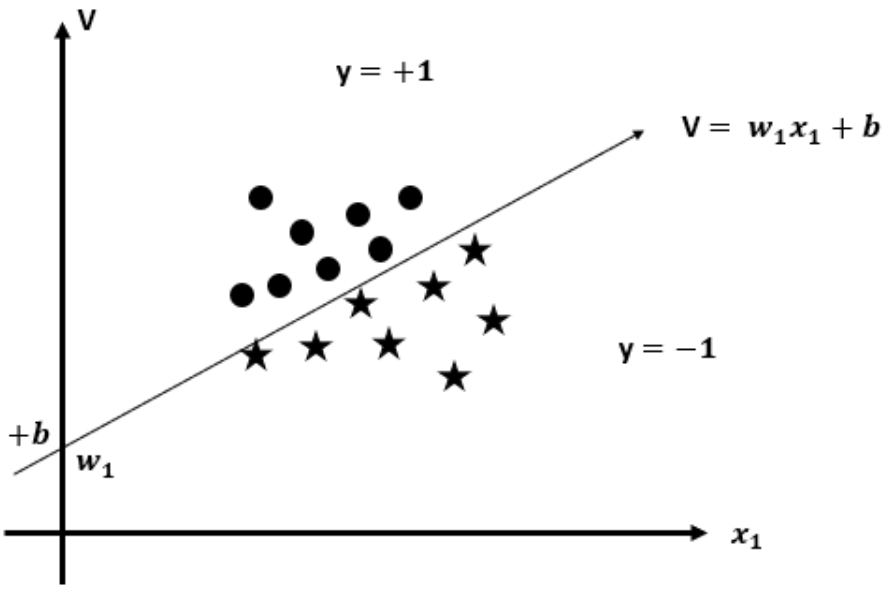

Figura 7 Representação da Divisão de Dados de um Neurônio Fonte: Autor

Com o treinamento da rede neural artificial define-se os valores de w_n e b de forma a maximizar a divisão entre os dois tipos de dados. Assim a rede neural artificial terá maior assertividade no resultado.

Olhando para a equação da reta pode-se caracterizar w_n como o coeficiente angular e b como o coeficiente linear, sendo considerados dois graus de liberdade que devem ser definidos como o ajuste de inclinação e deslocamento da reta, respectivamente, proporcionando ampla capacidade de ajuste do neurônio na identificação dos padrões de respostas e provendo a propriedade de alocar a reta de forma a gerar a melhor divisão entre os dados.

Com o uso da função Logística, equação (6) apresentada anteriormente, a transição entre regiões desconectadas tende a ser de forma gradual ponderando assim o valor da constante a. Quanto maior o valor de a mais abrupta é a transição entre regiões. Como a transição é ajustável de acordo com a necessidade de resposta da rede a fim de maximizar sua assertividade dentre outros ajustes já mencionados, desenvolveu-se os algoritmos de aprendizagem. Dentre eles, o “backpropagation” (Rumelhart, James, 1989) e também alguns outros com desenvolvimento recente, utilizando novas capacidades computacionais e sendo derivados dos conceitos de filtros adaptativos de Kalman. (Mahmood, Liou, 1992; Liguni, Sakai, Tokumaru, 1992; Scalero, Tepedelenlioglu, 1992).

Como visto, a rede neural artificial é tida como uma malha de conexões entre neurônios na qual lhe é atribuída uma ferramenta classificadora multidimensional de dados, de dimensão proporcional à quantidade de entradas e neurônios a ele associado (Silva, Spatti, Flauzino, 2016).

2.2.1. PERCEPTRON MULTICAMADAS

A arquitetura de interligação entre os neurônios para a rede neural perceptron foi idealizada por (Rosenblatt, 1958), sendo a forma mais simples de configuração de

uma rede neural artificial cujo propósito focava em implementar um modelo computacional inspirado na retina, objetivando-se então um elemento de percepção eletrônica de sinais (Silva, Spatti, Flauzino, 2016).

Na análise feita no capítulo anterior com o modelo de apenas um neurônio foi visto que é possível dividir a amostra de dados com uma reta. Porém, experimentalmente, sabe-se que nem todos as amostras podem ser divididas apenas com uma reta. Tal abordagem seria uma imensa simplificação, agregando assim grande incerteza na capacidade da rede neural em funcionar de forma assertiva. Desta maneira, a rede neural Perceptron Multicamadas tem como objetivo principal dividir a classe da amostra em hiperplanos com definidas ponderações. Sendo assim, a função de cada neurônio é de selecionar parte da amostra que atende aos requisitos definidos durante o treinamento da rede (Cordeiro, Netto, 1994).

Tais hiperplanos podem ser definidos de acordo com o exemplificado na Figura 8. O treinamento da rede é realizado para a definição dos valores dos pesos das ligações (sinapses) e os limiares de ativação de cada neurônio. Desta forma, após o treinamento, se garante a melhor performance do resultado assegurando a correta propagação dos sinais.

A Figura 8 apresenta diferentes exemplos de topologias de construção da rede neural artificial, onde as setas são representações das entradas e fluxos da informação e a circunferências são os neurônios.

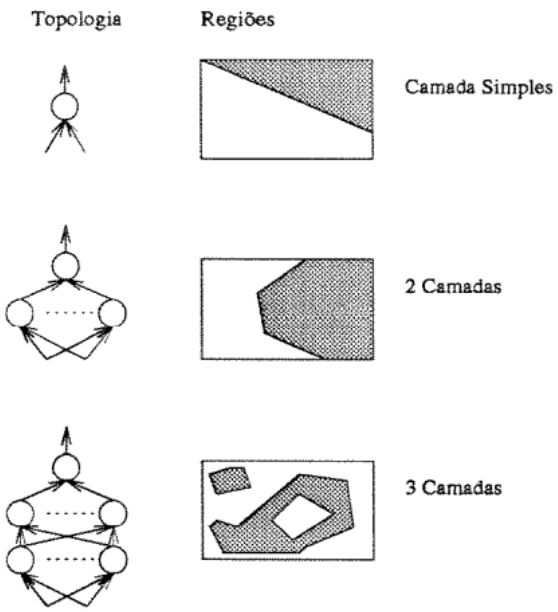

Figura 8 Hiperplanos x Topologia Perceptron Multicamadas Fonte: Cordeiro, Netto, 1994

Com a análise da Figura 8, a qual demonstra algumas possibilidades de arquitetura de redes neurais artificiais com a alteração da quantidade de neurônios e camadas em uma rede neural Perceptron Multicamadas, pode-se verificar que para uma quantidade constante de entradas, a variação da arquitetura da rede gera maior capacidade de selecionamento da amostra, aumentando assim a assertividade na resposta dada pela rede.

Vê-se na Figura 8 que para uma rede Perceptron de camada simples separa-se apenas um único plano, como exposto em apenas um neurônio. Para redes Perceptron de duas camadas, formam-se regiões convexas quaisquer de forma a otimizar a análise dos dados de entrada. Entretanto redes de duas camadas não são capazes de formar regiões desconectadas do plano principal formado, ao passo que redes de três camadas podem formar arbitrariamente qualquer tipo de região de decisão incluindo regiões desconectadas. Ou seja, a complexidade da região formada pela rede está diretamente relacionada à quantidade de neurônios em cada uma das suas camadas intermediárias. (Lippmann, 1987; Cordeiro, Netto, 1994).

Além da arquitetura na qual a rede neural perceptron é formada, tem-se que a rede seja utilizada como um classificador de padrões onde necessariamente as classes

do sistema a ser mapeado devem ser linearmente separáveis, princípio e condição proposto pelo Teorema de Convergência do Perceptron (Minsky, Papert, 1969).

Os processos utilizados para definição dos algoritmos de treinamento das redes neurais artificiais levam os princípios das regras de aprendizado proposto por (Hebb, 1949), na qual define os processos de comportamento com base em teorias neurofisiológicas.

Como boa prática proposta por (Silva, Spatti, Flauzino, 2016), deve-se atentar à algumas condições para o melhor desempenho da rede, bem como diminuição da quantidade de iterações necessárias para a sua convergência durante o processo de treinamento:

- A quantidade de iterações para o processo de treinamento deve ser limitada, a fim de evitar iterações divergentes para caso de problemas não linearmente separáveis.
- Quando a diferença entre as saídas necessárias da rede for muito pequena, o processo de treinamento pode implicar em instabilidade. Para esta dissertação foram definidas entradas suficientemente distintas para melhor adequação da rede ao processo de treinamento.
- A normalização das entradas para domínios apropriados contribui para incrementar o desempenho do treinamento. Durante o processo de definição das entradas e da matriz que compunham os valores de cada manobra, as entradas foram normalizadas entre 1 e 0, de forma a otimizar o desempenho da rede neural artificial.

A rede Perceptron Multicamadas (PMC) é caracterizada pela presença de pelo menos uma camada intermediária de neurônios, situada entre a camada de entrada e a camada neural de saída (Silva, Spatti, Flauzino, 2016).

Para a criação de uma rede Perceptron Multicamadas são necessárias as formações de camadas de neurônios interligados, seguido algumas regras básicas: (Cordeiro, Netto, 1994)

- Um neurônio da camada anterior faz conexões com todos os neurônios da camada posterior;
- Neurônios de uma mesma camada não se interconectam;
- A camada mais anterior corresponderá às entradas e a camada mais posterior se corresponderá às saídas;

Esta topologia é capaz de formar hiperplanos que podem ser orientados com o treinamento necessário da rede neural artificial. Analogamente ao sistema nervoso biológico, a rede tem a capacidade de interligar neurônios de modo que cada um exerça a específica função de processamento da entrada e ativação ou não da saída, subdividindo o processamento do dado em subcamadas.

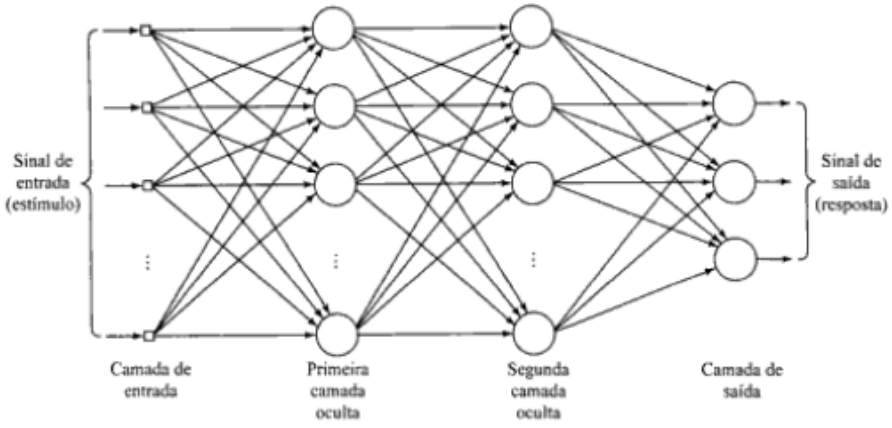

Figura 9 Topologia Perceptron Multicamadas Fonte: Haykin 2001

Na Figura 9 observa-se a arquitetura de construção da Rede Perceptron Multicamada, onde as quatro camadas são compostas por neurônios que são interligados entre todos os seus antecessores. A arquitetura também é composta da camada de entrada onde não ocorre processamento do dado, apenas leitura das variáveis de entrada, conforme descrito anteriormente. A camada de saída é composta por neurônios que ativam ou não, de acordo com o treinamento da rede. Tal camada é a responsável por orientar a resposta do sistema, ativando assim aquele neurônio de maior probabilidade correspondente a resposta correta, de acordo com o treinamento da rede anteriormente realizado.

Na análise da estrutura de uma rede Perceptron Multicamadas é possível verificar que a propagação dos sinais é sempre realizada em um único sentido durante sua operação. Ou seja, da camada de entrada em direção à camada neural de saída. Desta forma, o número de neurônios da saída deve ser igual ao número de respostas do processo a ser mapeado. Se o processo contempla a seleção de uma determinada amostra em *m* saídas, a rede deverá ter *m* neurônios em sua última camada neural (Silva, Spatti, Flauzino, 2016).

Portanto, para este trabalho foi utilizado uma rede Perceptron Multicamadas com seis neurônios na saída, coincidente com as seis possíveis classificações do PIO de acordo com a escala PIOR.

Com relação ao treinamento da rede, o método utilizado foi o algoritmo *backpropagation,* na qual o algoritmo contempla duas fases distintas conhecidas como *forward* e *backward.*

A Figura 9 representa a arquitetura de uma rede Perceptron Multicamadas. A fase *forward* é a primeira a ser aplicada e deve ser iniciada com a inserção de dados na entrada da rede a fim de coletar a resposta aos primeiros estímulos. Com isso, tem-se uma amostra da resposta da rede com relação aos pesos sinápticos e limiares de estímulo dos neurônios. Tais valores obtidos na saída são comparados com as respostas desejadas e a diferença entre os valores obtidos pela rede e o desejado é chamado de erro, que será utilizado como ajuste na próxima iteração do processo de aprendizado para refinamento dos valores dos ganhos sinápticos e limiares de ativação dos neurônios e para minimização do erro, aumentando a assertividade da resposta gerada pela rede (Silva, Spatti, Flauzino, 2016; Haykin, 2001).

Com base na Figura 9, apresentada anteriormente, e no equacionamento de um único neurônio é possível obter a equação representativa de um sistema de rede Perceptron Multicamadas, conforme representado na Figura 10 que foi adaptada da figura de um único neurônio para posterior equacionamento da rede com múltiplas entradas em um único neurônio e saída. Tal representação será utilizada no algoritmo de *backpropagation* (Silva, Spatti, Flauzino, 2016).

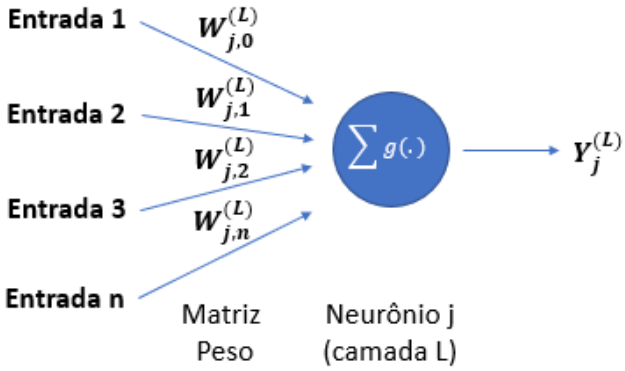

Figura 10 Configuração Neurônio utilizado na derivação do algoritimo Backpropagation. Fonte: Silva, Spatti, Flauzino, 2016. Adaptado pelo autor)

Na figura 10, cada camada da rede é representada pela letra L, neurônio pela letra j e função de ativação de cada neurônio por $g(.)$. A rede apresenta n entradas em um único neurônio e as matrizes $W_{ji}^{(L)}$ definem cada elemento da rede com o valor do peso sináptico conectado ao *j-ésimo* neurônio da entre camadas *(L)* ao *i-ésimo* neurônio da camanda *(L-1)*.

Adicionalmente à Figura 10, define-se os vetores $I_j^{(L)}$ cujos elementos denotam a entrada ponderada em relação ao *j-ésimo* neurônio da camada L. Assim é possível equacionar a propagação dos sinais conforme as Equações 10, 11 e 12.

$$I_j^{(1)} = \sum_{i=0}^{n} W_{ji}^{(1)}.x_i \leftrightarrow I_j^{(1)} = W_{1,0}^{(1)}.x_0 + W_{1,1}^{(1)}.x_1 + \cdots + W_{1,n}^{(1)}.x_n \qquad (10)$$

$$I_j^{(2)} = \sum_{i=0}^{n_1} W_{ji}^{(2)}.Y_i^{(1)} \leftrightarrow I_j^{(2)} = W_{1,0}^{(2)}.Y_0^{(1)} + W_{1,1}^{(2)}.Y_1^{(1)} + \cdots + W_{1,n_1}^{(2)}.Y_{n_1}^{(1)} \qquad (11)$$

$$I_j^{(3)} = \sum_{i=0}^{n_2} W_{ji}^{(3)}.Y_i^{(2)} \leftrightarrow I_j^{(3)} = W_{1,0}^{(3)}.Y_0^{(2)} + W_{1,1}^{(3)}.Y_1^{(2)} + \cdots + W_{1,n_2}^{(3)}.Y_{n_2}^{(2)} \qquad (12)$$

Na análise das Equações 11 e 12, os vetores $Y_j^{(L)}$, cujos elementos denotam a saída do *j-ésimo* neurônio em relação à entre subcamadas *L,* são definidos por: (Silva, Spatti, Flauzino, 2016).

$$Y_j^{(1)} = g\left(I_j^{(1)}\right) \qquad (13)$$

$$Y_j^{(2)} = g\left(I_j^{(2)}\right) \qquad (14)$$

$$Y_j^{(3)} = g\left(I_j^{(3)}\right) \qquad (15)$$

A continuação do equacionamento do algoritmo de *backpropagation* será a definição da função representativa do erro de aproximação, na qual o objetivo será medir a diferença entre as respostas produzidas pela rede neural com seus ganhos e ajustes originais e os valores esperados ao qual rede neural foi destinada.

Assim considerando a k-ésima amostra de treinamento, assume-se a função erro quadrático como aquela a ser utilizada, ou seja: (Silva, Spatti, Flauzino, 2016).

$$E(k) = \frac{1}{2}\sum_{j=1}^{n_3}(d_j(k) - Y_j^{(3)}(k))^2 \qquad (16)$$

Onde $Y_j^{(3)}(k)$ é o valor produzido pelo j-ésimo neurônio da saída da rede, considerando k-ésima amostra de treinamento, enquanto $d_j(k)$ é o seu respectivo valor desejado. Desta forma, assumindo um conjunto de treinamento composto por p amostras, a evolução do desempenho global do algoritmo *backpropadation* pode ser medido através do erro quadrático médio definido por: (Silva, Spatti, Flauzino, 2016).

$$E_M = \frac{1}{p}\sum_{k=1}^{p} E(k) \qquad (17)$$

O sequenciamento do algoritmo de *backpropagation* passa pelo ajuste da matriz de pesos sinápticos referente à camada neural de saída e dos pesos das matrizes associadas às camadas intermediárias. Após concluído, tem-se a rede neural artificial treinada para realização da tarefa proposta (Silva, Spatti, Flauzino, 2016).

3. MATERIAIS E MÉTODOS

3.1. AMBIENTE DE SIMULAÇÃO

Este trabalho utilizou como veículo condutor dos ensaios o ambiente de simulação provido pelo Departamento de Engenharia Aeronáutica da Escola de Engenharia de São Carlos EESC – USP. Este ambiente é fruto de trabalhos anteriores de alunos no desenvolvimento e concepção de um ambiente para prática e obtenção dos dados a serem utilizados nos trabalhos dos grupos de pesquisa do Departamento de Engenharia Aeronáutica (Moura, Alegre, Bidinotto, Belo, 2018; Bidinotto, Moura, Neves, 2022; Neves, Bruschi, Bidinotto, 2021; Moura 2018)

Foi utilizado o modelo do Boeing 747 como planta da aeronave que será melhor descrito no capítulo Aeronave Modelo. O sistema visual empregado foi uma réplica de um sinótico de orientação de atitude comumente utilizados na aviação. Ambos foram desenvolvidos em Matlab e executados em conjunto em uma mesma máquina, de forma a prover versatilidade durante a fase de execução dos ensaios.

A arquitetura de montagem do ambiente de simulação foi idealizada com a utilização de um computador com dois monitores e controle provido pela interface homem máquina, feito a partir de um sidestick réplica do utilizado pela Aeronave A-10 Thunderbolt, com o conceito HOTAS (Hands On Throttle and Stick). Este conceito preza pela doutrina de o piloto ficar em tempo integral com a mão em ambos os comandos de Stick e manete de potência comumente utilizado em aeronaves de combate, para que o piloto tenha reação mais rápida durante eventuais necessidades em combate real ou treinamento.

A Figura 11 apresenta o mesmo sidestick utilizado no ambiente de simulação da Escola de Engenharia de São Carlos.

Figura 11 Sidestick do ambiente de simulação Fonte: Site Thrustmaster

A interface homem máquina utilizada foi a de modelo *Warthog Flight Stick*, fabricado pela Thrustmaster com múltiplos botões que podem ser configurados como inputs para os modelos. As atuações comandadas a partir do Stick podem variar de acordo com a aeronave sendo simulada e configuração definida pelo usuário.

O console tem a capacidade de configuração do ajuste de rigidez o que aumenta a realidade do simulador e é provido por sensores de efeito Hall, que conferem sensibilidade ao movimento do piloto de forma a garantirem correta percepção de atuação, equiparando aos sidesticks certificados em aeronaves.

O sidestick é licenciado pela Força Aérea Americana como réplica oficial da aeronave A-10 Thunderbolt.

3.2. AERONAVE MODELO

Conforme descrito anteriormente foi utilizado o ambiente de simulação provido pelo Departamento de Engenharia Aeronáutica da Escola de Engenharia de São Carlos. O modelo utilizado como base para realização dos testes e geração dos dados foi o de um Boeing 747 em voo nivelado a 40.000ft de altitude e Mach 0.8 (Etkin, Reid, 1996).

Para o desenvolvimento desta dissertação foi necessária a geração dos dados de PIO em todas as possíveis classificações de acordo com a escala de PIOR de 1 até 6. O modelo base da aeronave Boeing 747 utilizado evidencia as características de oscilações originais da aeronave já certificada e em operação por muitas décadas, não obtendo assim dados de oscilações de classificações superiores.

Foi utilizado o estudo (Moura, Alegre, Bidinotto, Belo, 2018) na qual apresenta o desenvolvimento científico com base no mesmo modelo do Boeing 747 e define valores a serem modificados em algumas derivadas de estabilidade, de forma a alterar a característica de oscilação da aeronave no eixo longitudinal. Assim foram gerados novos modelos secundários com traços de oscilações diferentes, possibilitando a alteração da qualidade de voo e modificando a susceptibilidade ao PIO durante os ensaios. A utilização destes submodelos garantiu a adequada qualidade dos dados com base no objetivo de se obter todos os possíveis níveis de oscilação.

O trabalho (Moura, Alegre, Bidinotto, Belo, 2018) referenciado nesta dissertação, vem sendo amplamente utilizado por outros desenvolvimentos científicos dentro do Departamento de Engenharia Aeronáutica da USP de São Carlos, demonstrando a confiabilidade no cumprimento do objetivo da referência anteriormente proposta.

O estudo criterioso da análise de susceptibilidade ao PIO foi realizado com variações das derivadas de estabilidade C_{m_q} e $C_{m_{\dot{\alpha}}}$ isoladamente. Desta forma, inicialmente, foi mantido o valor de $C_{m_{\dot{\alpha}}}$ original do modelo, variando os valores de C_{m_q} entre -65,07 e 28,30. Na mesma linha de análise, posteriormente foi mantido o valor do modelo original de C_{m_q} e variando os valores de $C_{m_{\dot{\alpha}}}$ entre -89,73 e 25,21, com base no trabalho (Moura, Alegre, Bidinotto, Belo, 2018).

O processo de obtenção dos submodelos longitudinais foi realizado utilizando as matrizes de espaço de estados A e B e os valores das variáveis referentes à condição de voo do Boeing 747, ambos descritos em (Etkin, Reid, 1996). Em seguida obteve-se a função de transferência da relação entre o *Pitch* da aeronave e o comando aplicado pelo piloto. Foram gerados 10 submodelos com diferentes susceptibilidades ao PIO para C_{m_q} e 10 submodelos para o $C_{m_{\dot{\alpha}}}$.

Durante os testes de classificação, foi definido em conjunto com a avaliação do grupo de pilotos de prova da indústria que a melhor percepção de variação de susceptibilidade ao PIO era observada durante à variação de $C_{m_{\dot{\alpha}}}$. Desta forma, o valor de C_{m_q} foi mantido como o original.

Com base na tabela de PIOR e o grupo de pilotos de prova da indústria, foram definidos os valores de $C_{m_{\dot{\alpha}}}$ para cada intensidade de oscilação.

A definição das constantes constituiu-se neste trabalho como uma etapa prévia, de grande importância, de simulação e testes. As constantes para cada submodelo foram definidas com sucessivos testes de bancada e com base nos resultados de simulações. Uma vez definidas, foi necessária a validação dos submodelos junto aos pilotos de prova, de modo a garantir uma boa escolha que embasasse os testes deste trabalho e pudesse validar os resultados.

A Tabela 1 evidencia os valores de $C_{m_{\dot{\alpha}}}$utilizados para os testes com relação à susceptibilidade ao PIO, sendo de 1 a 6 do menor ao mais susceptível.

Tabela 1 Valores de utilizados de $C_{m_{\dot{\alpha}}}$ para cada submodelo

Susceptibilidade ao PIO (Submodelo)	$\boldsymbol{C_{m_{\dot{\alpha}}}}$
1	25,53
2	1,22

3	-0,36
4	-13,08
5	-25,88
6	-36,71

3.3. TAREFA SINTÉTICA / PITCH CAPTURE

Durante o desenvolvimento desta dissertação fez-se necessária a aplicação das manobras de Tarefa Sintética e *Pitch Capture* onde ambas foram utilizadas para o treinamento da rede neural artificial separadamente. O intuito foi maximizar a assertividade da resposta da rede. Inicialmente foi aplicada a manobra de Tarefa Sintética e posteriormente a manobra de *Pitch Capture*.

O capítulo de Resultados trará informações detalhadas dos motivos pelos quais fez-se necessária a utilização de uma segunda manobra para aumento da assertividade da rede.

A Figura 12 representa a arquitetura de construção da implementação da funcionalidade de Tarefa Sintética e Pitch Capture no ambiente de simulação da Escola de Engenharia de São Carlos.

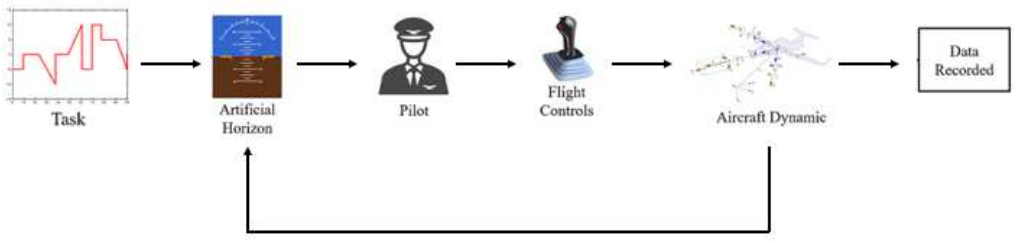

Figura 12 Arquitetura da Tarefa Sintética Fonte: Neves, Bruschi, Bidinotto, 2021 - Adaptado

O perfil da Tarefa Sintética e *Pitch Capture "SynTask"* representada na Figura 12, foi definida levando em conta a dinâmica da aeronave. O software desenvolvido de "*SysTask"* foi desenvolvido pelo próprio Departamento de Aeronáutica da Escola de Engenharia de São Carlos com propriedade intelectual sob o número SYNTASK – SOFTWARE DE TAREFAS SINTÉTICAS AERONÁUTICAS BR512022002377-6.

Vale ressaltar a necessidade de captura com alto ganho por parte do piloto, necessidade pela qual a manobra deve ser realizada por pilotos de prova que são formados para empregarem a técnica adequada durante execução de ensaios de PIO.

O "SynTask" é utilizado como entrada para o sinótico de apresentação ao piloto do horizonte artificial. O horizonte é representado pela divisão virtual entre terra e céu, a atitude "*pitch*" da aeronave é representada pelas marcações em laranja nas laterais e o guia longitudinal a ser seguido é caracterizado por uma linha vermelha. Tais representações podem ser observadas na Figura 13.

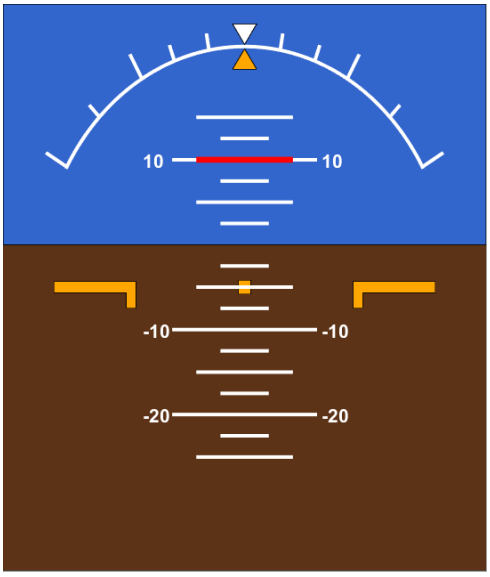

Figura 13 Horizonte Artificial Apresentado ao Piloto Fonte: Neves, Bruschi, Bidinoto, 2021

O sinótico de horizonte artificial representado na Figura 13 traz como exemplo a aeronave durante a execução da tarefa sintética, na qual apresenta voo com atitude em torno de cinco graus negativos e com objetivo de cabrar na busca de dez graus positivos de "*pitch"*.

A apresentação do sinótico de horizonte artificial é feito a partir do Matlab, com taxa de atualização da imagem rápida o suficiente para não interferir na execução da manobra, garantindo assim a qualidade dos dados gerados durante o ensaio.

Na arquitetura apresentada na Figura 12 o piloto representa o piloto de provas, bem como o controle de voo representa a interface de atuação utilizada pelo piloto descrita no capítulo Ambiente de Simulação.

O desenvolvimento do perfil da Tarefa Sintética e Pitch Capture que foram utilizadas nesta dissertação iniciou-se com a definição das amplitudes das variações longitudinais de forma a induzir o PIO durante a execução com base na dinâmica do Boeing 747, já experimentada em outros projetos do grupo de pesquisa de fatores humanos do Departamento de Engenharia Aeronáutica da USP de São Carlos.

Os perfis das manobras foram definidos com oscilações abruptas e rampas, e estabilizações entre 3 e 15 segundos, de forma a induzirem inicialmente o *Gross Aquisition* e posteriormente o *Fine Tracking.* O tempo de execução das manobras foi definido como suficiente para a obtenção dos dados necessários e não gerar fadiga de concentração no piloto, devido à necessidade de repetição de várias manobras durante um dia de teste. Os perfis utilizados de variação de Theta foram definidos com base em tarefas sintéticas usualmente utilizadas na indústria aeronáutica para certificação de novos modelos de aeronaves compatíveis com os mesmos perfis de tarefas propostas pelos órgãos certificadores.

Para a manobra de Tarefa Sintética, inicialmente foi definido um perfil base e a esta foi designada o nome Tarefa Sintética A. Esta a nomenclatura foi utilizada ao longo desta dissertação.

Com base nas orientações da *Advisory Circular AC25-7D* (Federal Aviation Administration, 2018) e nas definições técnicas de PIO, é mandatória a ativação do gatilho para obter o PIO, sendo este o efeito surpresa do piloto durante o teste. Para tal, foram desenvolvidas outras três tarefas sintéticas com base na Tarefa Sintética A, de forma a prover as Tarefas Sintéticas B, C e D.

A tarefa Sintética B foi criada com o espelhamento no tempo e inversão da A. A Tarefa Sintética C foi definida a partir da inversão da A e posterior divisão por segmentos e embaralhamento das partes. A Tarefa Sintética D, por sua vez, foi definida com o embaralhamento da Tarefa Sintética A espelhada.

Com os perfis de capturas distintos entre as manobras torna-se maior a dificuldade de aprendizagem por parte do piloto de provas durante o dia de ensaios com diversas repetições. Desta forma o critério de surpresa "gatilho" fica garantido.

A Figura 14 apresenta os quatro perfis de Tarefa Sintética desenvolvidos.

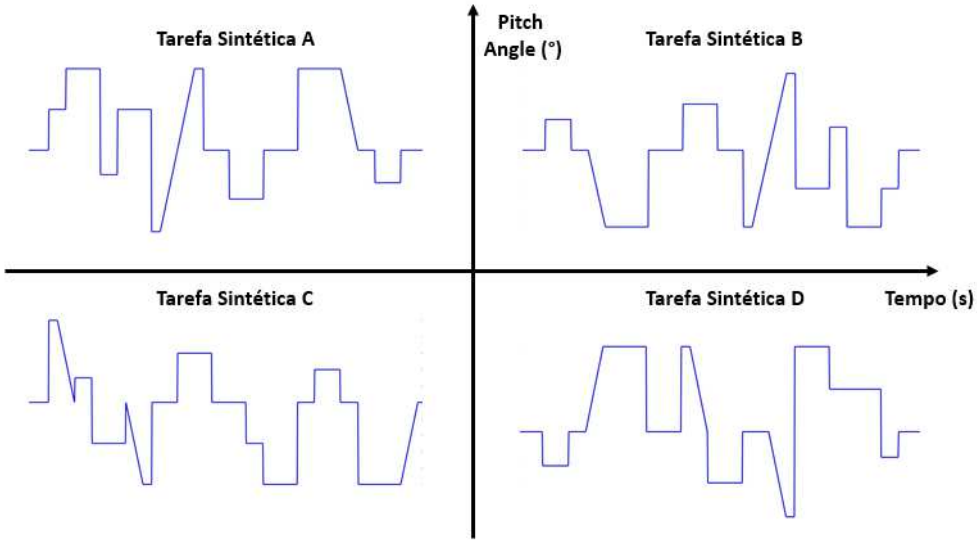

Figura 14 Representação das Tarefas Sintéticas A, B, C e D Fonte: Autor

A manobra de *Pitch Capture* foi também utilizada para a obtenção das conclusões desta dissertação. Os motivos pelos quais foi necessária a repetição do trabalho com outra manobra serão descritos no item Entradas da Rede Neural Artificial do Capítulo 4.

Durante o desenvolvimento do perfil a ser utilizado para as manobras de *Pitch Capture* foi convencionada a utilização de quatro perfis com três capturas cada e pelo menos uma variação de *theta* suficientemente grande, entre 10° e 15°, de modo a induzir comandos de grande amplitude para captura e manutenção por parte do piloto.

O tempo de estabilização da manobra no novo *theta* foi aumentado com relação à Tarefa Sintética, de forma a melhor definir a etapa de *Fine Tracking*, na tentativa de maximizar a assertividade da resposta, bem como definir novas entradas para a Rede Neural Artificial específicas desta dinâmica.

A Figura 15 apresenta os perfis das quatro manobras de Pitch Captures utilizadas nesta dissertação.

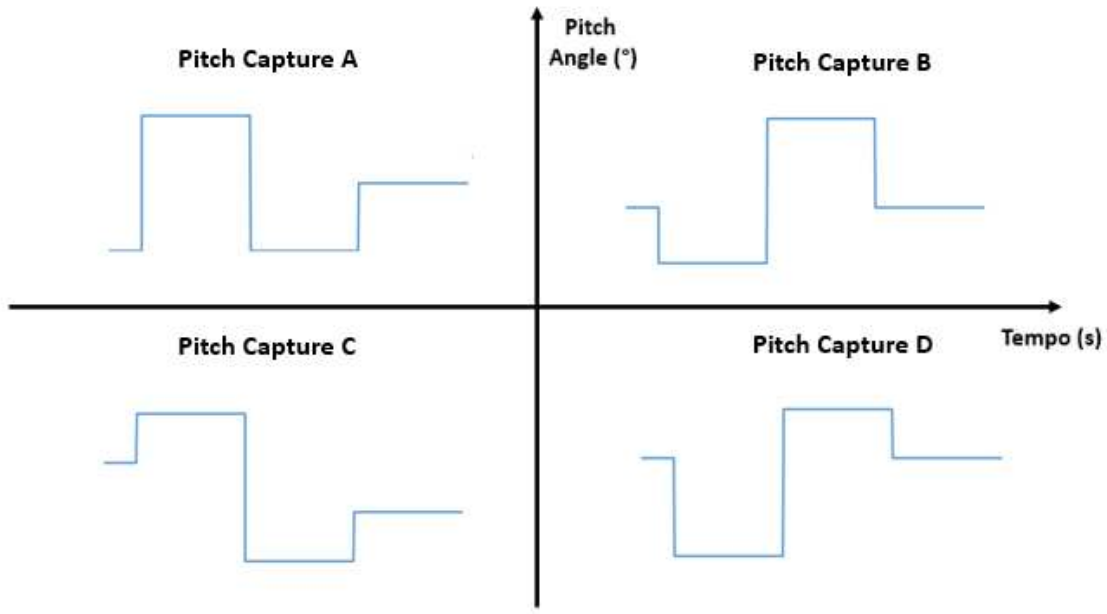

Figura 15 Representação dos Pitch Captures A, B, C e D Fonte: Autor

3.4. MATRIZ DE ENSAIO

Com base nas diretrizes oriundas da *Advisory Circular AC 25-7D* (Federal Aviation Administration, 2018) foi definida a matriz de ensaios que contemplam todas as variações de configuração para a obtenção dos dados necessários para o desenvolvimento da dissertação. Como visto, foram utilizados pilotos de prova da indústria aeronáutica EMBRAER S.A para a realização dos testes no ambiente de simulação da Escola de Engenharia de São Carlos. Os pontos de ensaio foram repetidos exatamente nas mesmas condições por 10 pilotos diferentes, a fim de minimizar quaisquer erros de classificação do PIO devido à subjetividade da análise. Desta forma, foram providenciados pilotos com experiencia em ensaios de PIO para execução dos testes, dado o acordo de operação entre o Departamento de Engenharia Aeronáutica e o grupo de pilotos de Provas da EMBRAER S.A.

O modelo da aeronave Boeing 747 disponível em (Etkin, Reid, 1996) contempla voo na altitude de 40000ft bem como configuração aerodinâmica de Flap recolhidos e trem de pouso recolhido. A influência de variações de Peso e Balanceamento não são objetos de estudos desta dissertação, portanto foram utilizadas as condições propostas pela referência bibliográfica, sendo estes valores utilizados os medianos do envelope de ambas as grandezas.

Foi evidenciado durante a execução da manobra variações de altitude e velocidade durante as capturas. Estas são aceitáveis para a realização do ensaio e não influenciando no resultado.

Os mesmos conceitos utilizados para a definição da matriz de ensaios da Tarefa sintética, apresentados anteriormente foram utilizados para a matriz de ensaios para *Pitch Capture*. Ambas as repetições dos testes foram realizadas com base na mesma matriz de ensaio.

A Tabela 2 representa a matriz de ensaios utilizada neste trabalho com a designação de pontos de ensaio, ou *"Test Point"*, que será referência para os capítulos posteriores deste trabalho. A matriz de ensaios contendo 24 pontos foi realizada totalmente para cada piloto de ensaio durante a fase de testes.

Tabela 2 Matriz de Ensaios Fonte: Autor

Test Point	Altitude [ft]	Vel. [Mach]	Flap	LG	Peso	CG	Manobra	Submodelo
1	40000	0.8	Ret	UP	Mid	Mid	A	1
2	40000	0.8	Ret	UP	Mid	Mid	A	2
3	40000	0.8	Ret	UP	Mid	Mid	A	3
4	40000	0.8	Ret	UP	Mid	Mid	A	4
5	40000	0.8	Ret	UP	Mid	Mid	A	5
6	40000	0.8	Ret	UP	Mid	Mid	A	6
7	40000	0.8	Ret	UP	Mid	Mid	B	1
8	40000	0.8	Ret	UP	Mid	Mid	B	2
9	40000	0.8	Ret	UP	Mid	Mid	B	3
10	40000	0.8	Ret	UP	Mid	Mid	B	4
11	40000	0.8	Ret	UP	Mid	Mid	B	5
12	40000	0.8	Ret	UP	Mid	Mid	B	6
13	40000	0.8	Ret	UP	Mid	Mid	C	1
14	40000	0.8	Ret	UP	Mid	Mid	C	2
15	40000	0.8	Ret	UP	Mid	Mid	C	3
16	40000	0.8	Ret	UP	Mid	Mid	C	4
17	40000	0.8	Ret	UP	Mid	Mid	C	5

18	40000	0.8	Ret	UP	Mid	Mid	C	6
19	40000	0.8	Ret	UP	Mid	Mid	D	1
20	40000	0.8	Ret	UP	Mid	Mid	D	2
21	40000	0.8	Ret	UP	Mid	Mid	D	3
22	40000	0.8	Ret	UP	Mid	Mid	D	4
23	40000	0.8	Ret	UP	Mid	Mid	D	5
24	40000	0.8	Ret	UP	Mid	Mid	D	6

Conforme diretriz da *AC 25-7D,* foram realizados os ensaios de tarefa sintética de forma a garantir o não aprendizado do piloto com relação à dinâmica da manobra e também com relação a susceptibilidade ao PIO. Assim, foi realizada uma escolha da sequência do *"Test Point"* para não haver repetição simultânea da tarefa e nível de PIO. Desta forma, a tarefa sintética a ser ensaiada em conjunto com as características dinâmicas do modelo tiveram o fator surpresa, requisito básico imposto pelo órgão certificador para garantia da qualidade na análise do PIO.

3.5. ESCOLHA DO MÉTODO DE TREINAMENTO DA REDE NEURAL ARTIFICIAL

Foi determinado o método de treinamento da rede neural artificial, sendo escolhido o *Levenberg-Maquardt* (Levenberg, K. 1944; Maquardt, D. 1963) Este método confere praticidade na implementação via Matlab e boa convergência para tarefas de classificação. O método de treinamento de redes neurais artificiais de *Levenberg-Maquardt* é amplamente utilizado no meio científico atualmente, envolvendo processos de classificação utilizando redes neurais artificiais.

Alguns trabalhos científicos recentes utilizaram Levenberg-Maquardt como algoritmo de treinamento, tais como (Raghuvaram, Kannayan, Govindan, 2019) que

sugere a classificação de materiais poliméricos de acordo com suas características físicas. Já na área da saúde (Sapna, Tamilarasi, Kumar, 2012) propõe o uso de uma rede neural artificial para a classificação da diabetes de um paciente utilizando dados clínicos como dados de entrada. No ramo de engenharia mecânica (Sharma, A., Sharma, H., Sahoo, P. K., Tripathi, R. K., Meher, L. C., 2015) indica o uso de uma rede neural artificial para a classificação da performance de emissão de gases de motores movidos a biodiesel. Também (Yurii, Luidmila, 2016) aplica o uso de redes neurais artificias para desenvolvimento de inteligência artificial de reconhecimento de problemas mecânicos em sistemas automobilísticos por classificação da falha. (Costa, Oliveira, Pinto, Tavares, 2019) sugere o uso de redes neurais artificiais para detecção de fadiga e distração em motoristas durante a condução e, no ramo financeiro, (Qi, Jin, Li, Qian, 2020) emprega redes neurais artificias para definição de tendencias de mercado utilizando informações publicadas na internet.

Com base nos trabalhos listados anteriormente é possível verificar que a aplicação de *Levenberg-Maquardt* possui ampla abrangência no uso de redes neurais artificias sendo empregada em trabalhos da comunidade científica recente.

O método consiste em obter o mínimo local de forma a convergir mais rapidamente que um algoritmo genético convencional, o processo de treinamento pelo método de *Levenberg-Maquardt* realiza o processo de obtenção da mínimo local pelo processo de mínimos quadrados de forma a obter o par de coordenadas correspondentes ao ponto de mínimo (x,y). Para o modelo da curva $f(x,\beta)$ o modelo define os valores de β nos quais a soma dos quadrados $S(\beta)$ é minimizado e definido por: (Levenberg, K. 1944; Maquardt, D. 1963).

$$\hat{\beta} \in argmin_{\beta} S(\beta) = argmin_{\beta} \sum_{i-1}^{m} [y_i - f(x_i, \beta)]^2 \qquad (18)$$

4. RESULTADOS

4.1 ENSAIOS

Para a execução dos ensaios deste trabalho, foi inicialmente realizada etapa de preparação dos submodelos a serem utilizados, definição dos perfis das manobras de tarefa sintética e *pitch capture* e integração do modelo e manobras no Matlab, proporcionando a capacidade de escolha entre todos os submodelos e todas as manobras, trazendo assim versatilidade durante os testes e possibilidade de execução de toda a matriz de ensaios em uma única sessão.

O ambiente de simulação foi montado de forma a prover ao piloto apenas a visualização do sinótico de atitude com as variações a serem capturadas, conforme exposto no capítulo Tarefa Sintética / *Pitch Capture*, impossibilitando-o de saber qual submodelo e manobras estavam sendo utilizadas no momento.

Foi observada também a necessidade de ajuste ergonômico para a realização das manobras de forma a poder adaptar a altura do *sidestick* com relação ao braço do piloto, com ajuste de altura da cadeira e posicionamento da interface homem máquina. Tais ajustes foram necessários para todas as rodadas de ensaios visto que o correto posicionamento ergonômico conferia melhor adaptabilidade à manobra.

A escolha das manobras seguindo a matriz de ensaios foi realizada de forma a tentar minimizar qualquer aprendizado por parte do piloto e possíveis características de pilotagem que poluíssem a análise do PIO, desta forma, o sequenciamento dos pontos foi definido de forma aleatória suprimindo repetições sequenciais de perfil da manobra e submodelo utilizado.

A rotina e cadência dos ensaios eram definidas de acordo com a disponibilidade dos pilotos de prova, onde cada piloto executava todos os 24 pontos de acordo com a

matriz de ensaios completa, passando por todos os submodelos e variações das manobras.

Anteriormente à etapa de execução dos testes foi solicitada a aprovação pelo comitê de ética da UFSCar sob o processo número CAAE 54768421.7.0000.5504, devido ao fato da parte experimental deste trabalho contemplar o uso de recursos humanos para execução dos ensaios.

Ao longo do trabalho foram realizadas 20 sessões de simulação com 24 pontos de ensaio cada, sendo 10 pilotos para cada manobra, totalizando 480 pontos de ensaios e 5:43:59h de dados totais.

Após cada ensaio era realizada a gravação dos dados e análise gráfica de modo a buscar qualquer desvio durante a execução. Uma vez validado o ensaio, foi requisitado ao piloto uma classificação de PIOR encontrada durante a execução. Vale ressaltar que anteriormente ao início dos testes era realizado o "briefing de ensaios" contemplando os objetivos, procedimentos e considerações para a execução dos testes.

Durante o "briefing" era também enfatizada a necessidade de se realizar a manobra com alto ganho com a devida orientação de se evitar a condição de "*overreaction".* Tal particularidade é comumente observada em ambientes de simulação sem a capacidade de *"motion"* (reprodução do fator de carga durante a manobra).

Os testes foram executados em um ambiente de base fixa, onde é comum a reação abusiva do piloto na tentativa de realizar a captura, pois fisiologicamente não se tem o feedback que o orienta na dosagem de intensidade de atuação na superfície de controle, levando o piloto a realizar a manobra de forma abrupta.

Os testes foram realizados com pilotos de prova que são devidamente treinados com o intuito de se evitar o *"overreaction".* Esta doutrina já é de comum hábito no ambiente de ensaios em voo quando se utiliza simuladores de base fixa para execução de ensaios.

Após todos os ensaios realizados iniciou-se a etapa de agrupamentos dos dados em diferentes características de acordo com os dois objetivos deste trabalho. Primeiramente foi realizada a divisão de todos os ensaios em grupos de mesma classificação de PIOR, independente da manobra e modelo. Em sequência foram divididos grupos de mesmo modelo independente da classificação dada pelo piloto.

O objetivo dos grupos de mesma classificação de PIOR é a análise dos dados para definição e obtenção das entradas da rede neural artificial. Para os grupos de mesmo modelo, o objetivo foi a análise da dispersão da classificação dada pelo piloto, analisando uma possível subjetividade na classificação de PIOR.

Para melhor entendimento da metodologia de trabalho adotada nesta dissertação, a Figura 16 apresenta as frentes de trabalho e suas respectivas interligações. A primeira frente foi a definição do modelo a ser utilizado e os procedimentos para obtenção dos submodelos, conforme descritos no capítulo Aeronave Modelo. Em sequência foram definidas as manobras e os perfis a serem empregados nos ensaios.

Outra frente de atuação foi com relação às definições da arquitetura da Rede Neural Artificial para posterior emprego das entradas oriundas dos ensaios, treinamento e análise dos resultados.

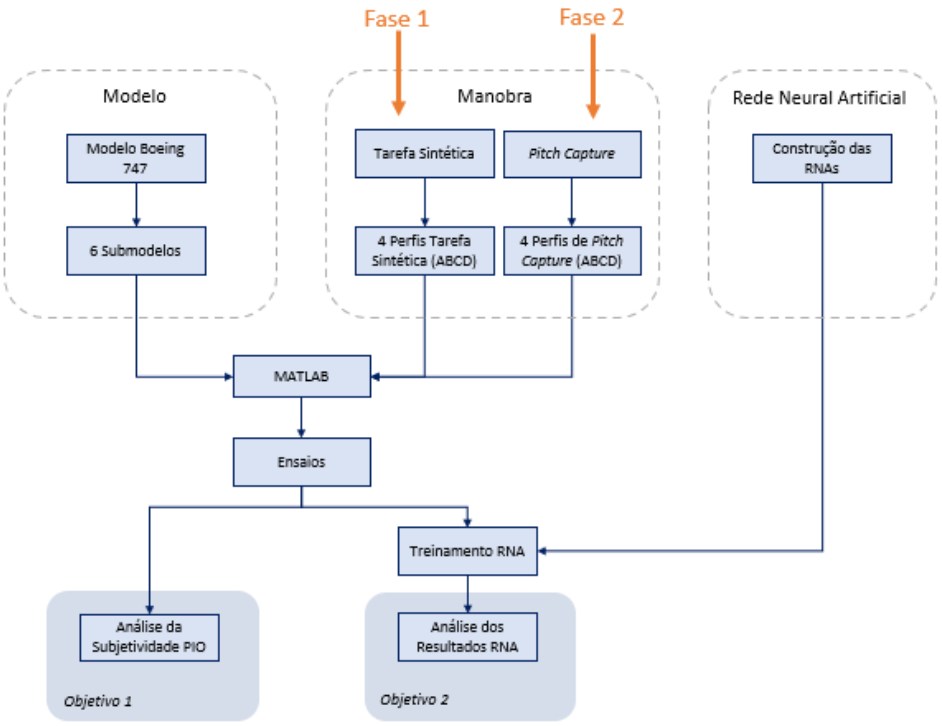

Figura 16 Fluxograma das atividades Fonte: Autor

Os ensaios e as análises com as manobras Tarefa Sintética e *Pitch Capture* foram realizadas de forma independentes

Os detalhes pelos quais fez-se necessária as repetições de todas as etapas do trabalho com a manobra *Pitch Capture* serão apresentadas no capítulo Entradas da Rede Neural Artificial.

Na primeira fase do projeto foram realizados os ensaios com a manobra Tarefa Sintética, sendo realizada a matriz completa com 24 pontos de ensaio e 10 pilotos de prova, totalizando 240 pontos de ensaio realizados. Na segunda fase foi repetida toda a matriz para a manobra de *Pitch Capture* com mais 10 pilotos. Vale ressaltar que alguns pilotos foram comuns em ambas as fases. Este fato foi considerado aceitável pois os perfis de captura das manobras eram distintas e não caracterizavam qualquer aprendizado entre ambas.

Foram levantadas algumas características dos grupos de pilotos:

- A idade dos pilotos em ambos os grupos foi entre 45 e 63 anos.
- O tempo de experiência para o grupo de pilotos da primeira fase foi levemente superior ao da segunda, sendo a primeira com a média de 25,3 anos e a segunda 22,1 anos.
- Em ambos os grupos 30% dos pilotos tiveram formação civil, passando por aeroclubes e formação de pilotagem conforme regras da ANAC, posteriormente realizando o curso de pilotos de prova, enquanto 70% tiveram formação integralmente militar.
- Em ambos os grupos as horas de voo de ensaios foram compatíveis, ficando aproximadamente as médias de 5500 horas de voo de teste aos pilotos de formação militar e 1500 horas aos pilotos de formação civil.

Na análise das características anteriores foi observada grande homogeneidade entre os dois grupos, pois os pilotos de provas da indústria têm como base as mesmas turmas de formação, bem como passaram pelos mesmos esquadrões ao longo de suas carreiras.

4.2 ARQUITETURA DA REDE NEURAL ARTIFICIAL

Parte do desenvolvimento desta dissertação foi a concepção da arquitetura da rede neural artificial a ser utilizada como classificadora das oscilações de PIO.

Foram definidas 2 redes neurais artificias, uma para Tarefa Sintética e outra para *Pitch Capture.* Estas redes foram desenvolvidas em Matlab em conjunto com os principais parâmetros que serão detalhadamente descritos a seguir. O software Matlab foi escolhido devido ao mesmo já possuir bibliotecas prontas para desenvolvimento e treinamento da rede, auxiliando assim a implementação e possíveis alterações na busca da convergência do resultado.

Uma vez finalizados todos os ensaios, foram compilados os dados de entrada e seus respectivos valores de saída em formato matricial em Excel. Os dados de saída são as classificações PIOR dados pelos pilotos ao final de cada ponto de ensaio.

A rede neural artificial se inicia com a leitura dos dados de entrada e saída desejada e, posteriormente, define-se a quantidade de camadas e neurônios por camada. Para esta dissertação foi atribuída à primeira camada a quantidade de neurônios que correspondia ao dobro da quantidade de entradas da rede. Para manobra de Tarefa Sintética foram utilizadas 18 entradas e a para o *Pitch Capture*, 7 entradas. Desta forma, as redes neurais artificias ficaram com 36 e 14 neurônios na primeira camada para as manobras de Tarefa Sintética e *Pitch Capture*, respectivamente.

Outro critério utilizado foi de que a última camada deveria ter o número exato de saídas para que tivessem correlação direta entre o neurônio ativado na saída e a classificação de PIOR. Portanto, ambas as redes neurais artificias ficaram com seis neurônios em suas camadas mais posteriores.

Como boa prática foi adotado um decaimento progressivo entre a primeira e a última camada. Também, para ambas as redes foram definidas mais três camadas intermediárias. Desta forma, a rede neural artificial designada à manobra de Tarefa Sintética ficou com 30, 20 e 10 neurônios, e para *Pitch Capture* foram 12, 10 e 8 neurônios nas camadas intermediárias.

Portanto a arquitetura completa com relação a quantidade de neurônios por camada ficou para as RNAs da seguinte forma:

Tabela 3 Número de camadas e neurônios por camada da RNA Fonte: Autor

Manobra	**Camada 1**	**Camada 2**	**Camada 3**	**Camada 4**	**Camada 5**
Tarefa Sintética	36	30	20	10	6
Pitch Capture	14	12	10	8	6

Para a definição da arquitetura da rede neural artificial é necessária a divisão dos dados totais em treinamento, validação e teste. Em ambas as redes desenvolvidas foram

adotadas as relações 50%, 25% e 25% respectivamente, dado que apresentaram a melhor performance empiricamente.

4.3 ENTRADAS DA REDE NEURAL ARTIFICIAL

Parte significativa do processo de desenvolvimento desta dissertação foram as escolhas das entradas das redes neurais artificiais que foram definidas com bases nas características de oscilação e dinâmica de atuação do piloto durante a realização das manobras.

Para ambas as manobras foram escolhidos os mesmos parâmetros básicos. Dentre os vários parâmetros possíveis, os escolhidos foram:

- perfil da manobra;
- θ (Theta);
- comando longitudinal do piloto;
- Pitch Rate; e
- ângulo de fase entre θ e comando longitudinal do piloto.

Após a análise dos resultados da primeira fase do desenvolvimento deste trabalho, foi observada excessiva atuação do piloto para a realização da tarefa sintética.

A Figura 17 apresenta a manobra de Tarefa Sintética D com o modelo número 3 conforme Tabela 1. A linha vermelha apresenta o perfil da Tarefa a ser seguida pelo piloto. As linhas em azul e verde expõem a atitude da aeronave e a atuação do piloto no *sidestick*, respectivamente.

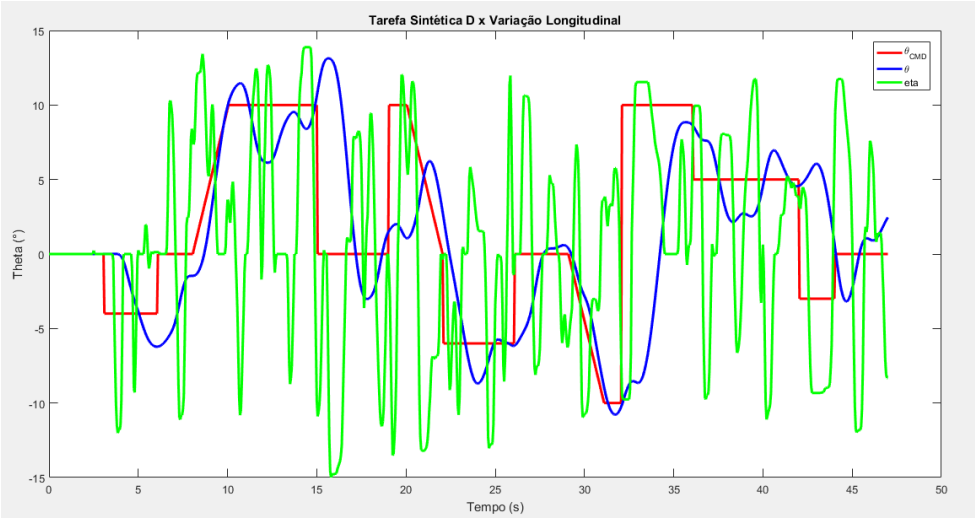

Figura 17 Tarefa Sintética x Atuação Piloto x Theta Fonte: Autor

Com base na Figura 17 é possível visualizar a intensa atuação do piloto no comando longitudinal e variações de atitude da aeronave na tentativa de realizar a tarefa. Fica evidente também a dificuldade de se relacionar graficamente a atuação nos controles com as variações de atitude e a tarefa sintética.

Outra característica, desta vez reportada pelos pilotos durante os ensaios de tarefa sintética, foi a dificuldade em realizar a manobra devido ao fato de a tarefa estar excessivamente dinâmica para modelos com alta susceptibilidade ao PIO. Tal percepção se deve ao fato de modelos com alta tendência à oscilação demorarem mais para se conseguir caracterizar a captura completa, enquanto a tarefa já atribuía ao piloto a demanda de nova atitude.

Como alternativa primária seriam utilizadas entradas que evidenciariam a dinâmica longitudinal da aeronave, dado que é este o critério levado em conta pelo piloto para a classificação do ensaio, porém para esta primeira fase a dinâmica da manobra ficou excessiva e observou-se grande dificuldade em obter uma relação gráfica entre os parâmetros das manobras de tarefa sintética, portanto foram escolhidas entradas relacionadas com a energia e potência dos principais parâmetros para cada ponto de ensaio, uma vez que foi observado durante os testes, significativas variações de intensidade de atuação no *sidestick* com relação ao modelo e tarefa proposto.

Foram compilados todos os valores de entradas selecionados para todas os pontos de ensaio e os mesmos normalizados entre 0 e 1, bem como as classificações de PIO dado pelo piloto a cada execução. Estes valores foram definidos como saída da rede neural artificial atribuindo a eles os valores de 0 ou 1.

Segue a lista das entradas bem como as características observadas durante a análise dos dados:

1- *Energia e Potência da Tarefa Sintética*: Não foram observadas variações significativas entre os valores de energia e potência dos sinais das quatro tarefas sintéticas, sendo esta característica já esperada pois todas a tarefas sintéticas foram derivadas de um único perfil. Os valores foram utilizados como entradas da rede neural artificial, porém auxiliando pouco na convergência do resultado, devido a não ser possível estabelecer uma relação direta entre as grandezas e os pontos de ensaio.

2- *Energia e Potência de* θ *(Theta)*: Com a análise dos valores de energia e potência do sinal de θ empregado durante a primeira fase da dissertação, observou-se também pequena variação nos valores de tais grandezas para cada um dos 240 pontos de ensaios realizados. Atribui-se a pequena dispersão entre os pontos de ensaios ao fato de que em todos foram executados com excessiva variação de θ.

3- *Energia e Potência do Comando do Piloto*: Para este par de entradas foram observadas maiores variações entre os pontos de ensaios. Foi evidenciada maior tendência de aplicação de energia no controle da aeronave para classificações de PIO maiores dada pelos pilotos. A Figura 18 apresenta os valores normalizados de energia do sinal de controle do piloto por classificação de PIO.

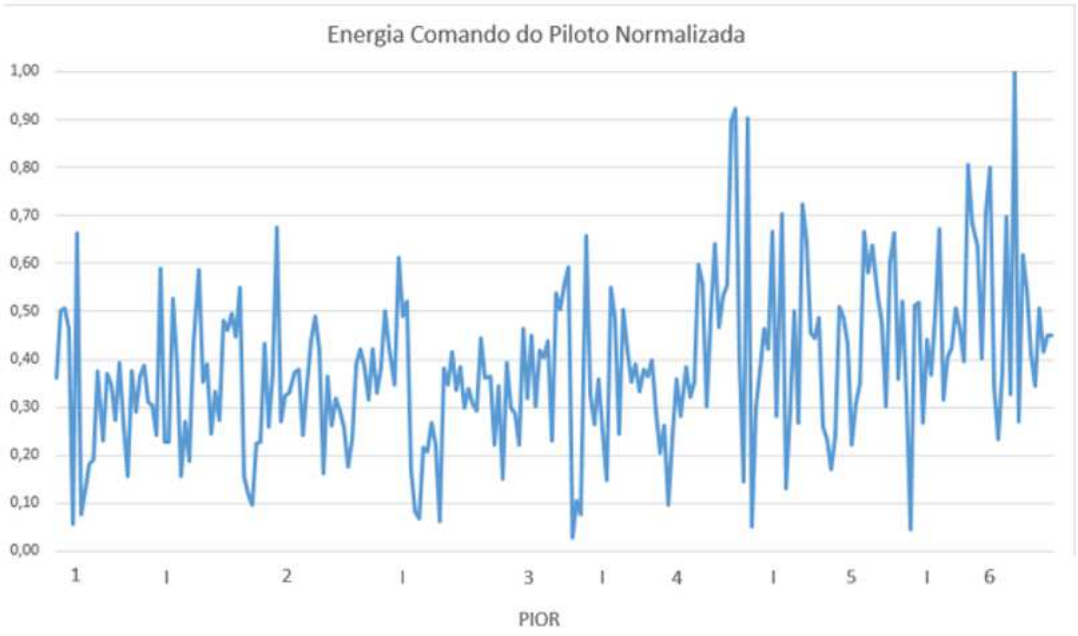

Figura 18 Gráfico de Energia Comando do Piloto Normalizada Fonte: Autor

Na análise da Figura 18 é possível observar uma tendência de aumento da energia aplicada pelo piloto no comando de controle da aeronave para valores de PIOR maiores que 3. Ou seja, para as classificações de 1 a 3 o piloto tende a aplicar mesma energia para execução do ensaio, o que vai de encontro com os requisitos necessários de certificação que aceitam como satisfatórias classificações de PIOR abaixo de 3 para todas as manobras.

4- *Energia e Potência de Pitch Rate*: Para o par de entradas de Pitch Rate não foram observadas tendências com relação à classificação de PIO. A Figura 19 apresenta o gráfico da energia normalizada do sinal de Pitch Rate com relação à classificação de PIOR.

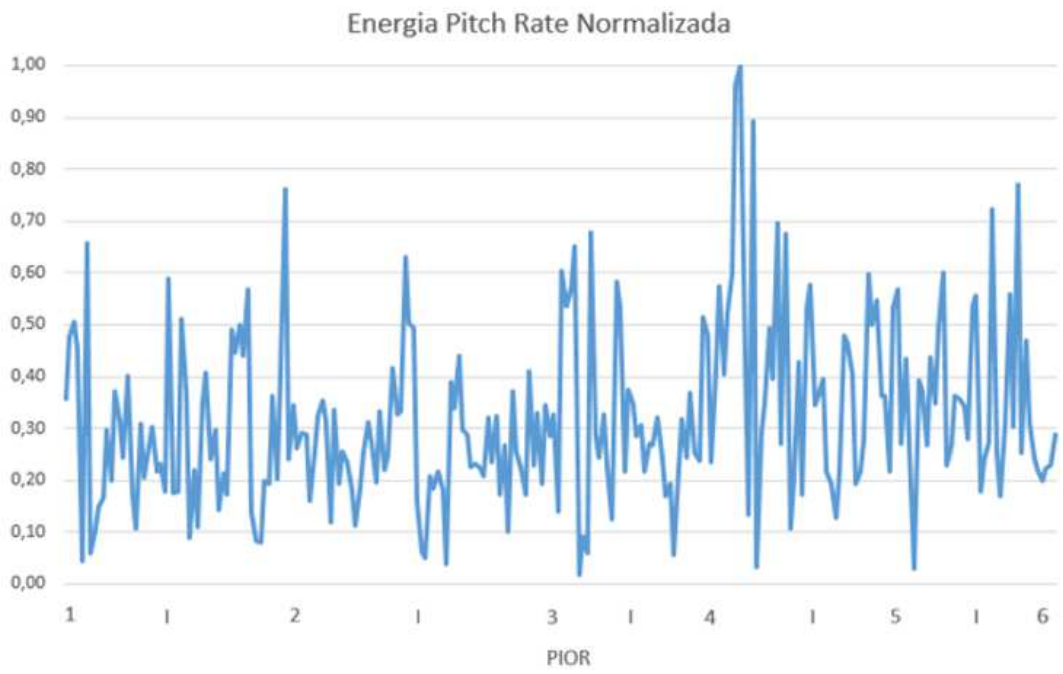

Figura 19 Energia Pitch Rate Normalizada Fonte: Autor

5- *Energia e Potência do Ângulo de Fase entre Aeronave e Comando do Piloto*: na análise destas grandezas não foi identificada alguma tendência de variação do ângulo de fase com relação à classificação de PIO. A Figura 20 apresenta os valores normalizados de energia do sinal de ângulo de fase normalizados com relação ao PIOR.

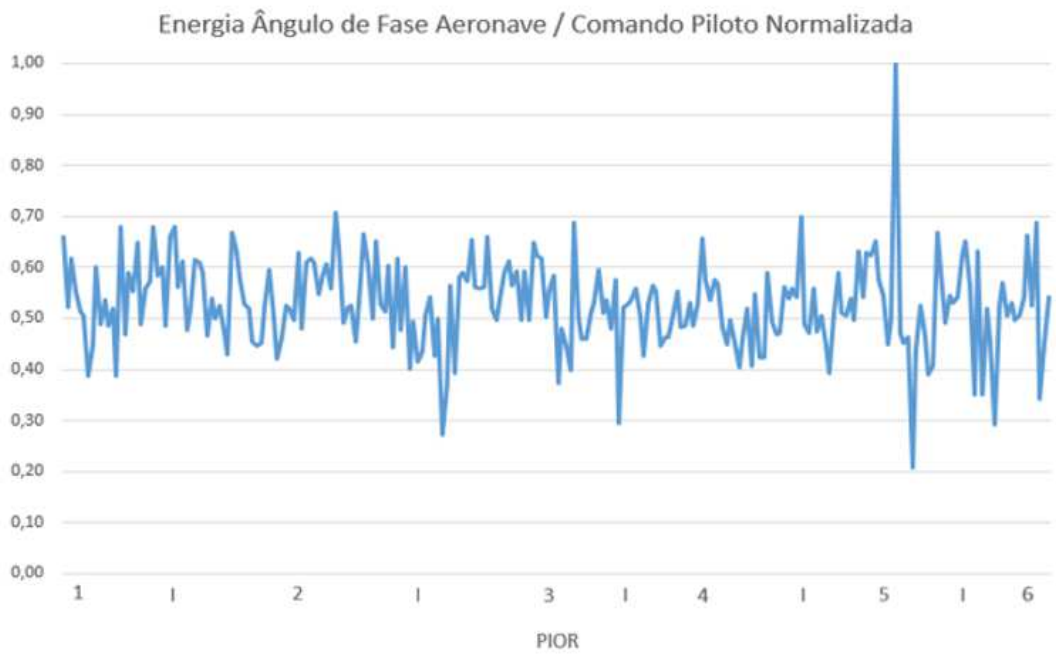

Figura 20 Energia ângulo de fase aeronave com relação ao comando do piloto Fonte: Autor

6- *Energia e Potência da Convolução entre Comando Longitudinal do Piloto e* θ: A convolução entre a aplicação de comando longitudinal e θ foi utilizada para verificar o perfil da diferença entre o comandado pelo piloto e a resposta da aeronave. Foi observado que para valores maiores de classificação de PIO tal diferença era maior. A Figura 21 apresenta os valores normalizados da Energia de convolução entre o comando do piloto e θ.

Figura 21 Energia convolução entre comando do piloto e theta Fonte: Autor

7- *Energia e Potência da Convolução entre a Tarefa Sintética e* θ: Com a análise do perfil da diferença entre a tarefa sintética e a atitude, verificou-se que a relação era inconclusiva e sem qualquer linha de tendência que se possa caracterizar tais grandezas à classificação de PIO. Tal conclusão é embasada na característica do excesso de variação de atitude da aeronave com relação à dinâmica da tarefa sintética.

8- *Energia e Potência da Convolução entre Comando Longitudinal do Piloto e Ângulo de Fase*: Na análise da energia e potência da convolução entre o comando longitudinal do piloto e o ângulo de fase, observou-se tendência de energia e potência mais dispersas para maiores classificações de PIO. A Figura 22 apresenta tal característica.

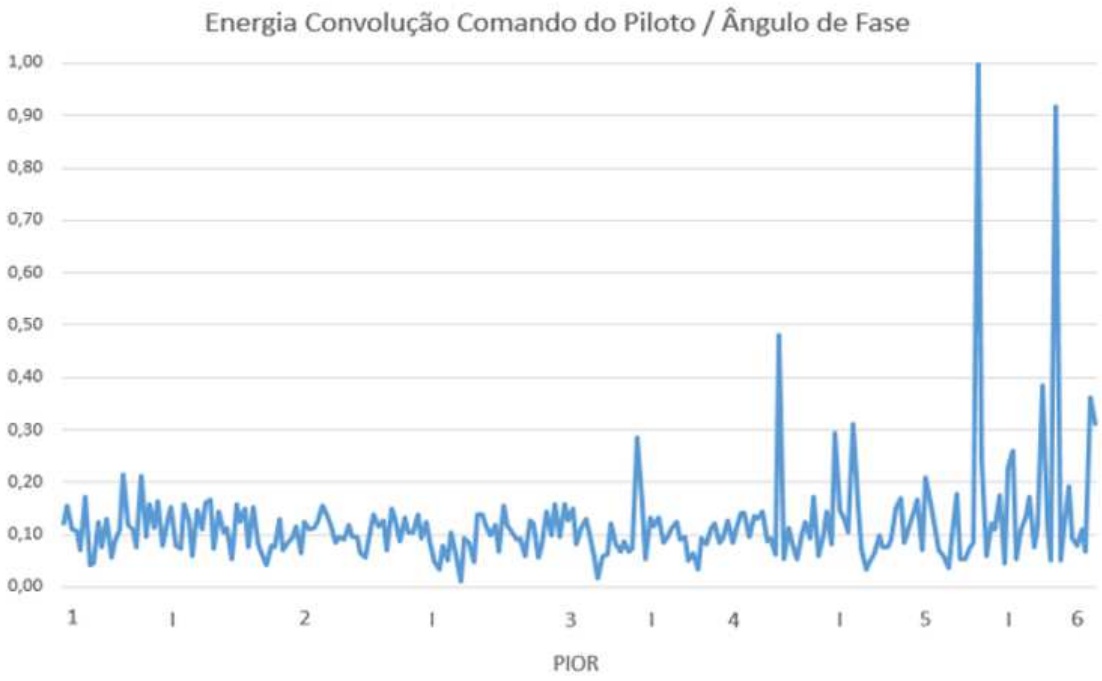

Figura 22 Energia da convolução entre o comando do piloto e ângulo de fase Fonte: Autor

9- *Energia e Potência da Convolução entre Pitch Rate e Ângulo de Fase*: Na análise desta grandeza não foi observada relação de tendência na comparação entre a energia ou potência da convolução entre Pitch Rate e ângulo de fase e com relação à classificação de PIO.

Vale ressaltar que são equânimes os perfis dos gráficos de energia e potência para todas as grandezas comuns, ou seja, a avaliação anteriormente descrita pode ser aplicada a todos os pares energia e potência.

Na análise dos gráficos anteriores de algumas entradas da rede neural artificial durante a primeira fase deste trabalho, observa-se a dificuldade de definição de um padrão de relação entre as variáveis das entradas e a classificação de PIO para garantia da convergência e aumento da assertividade da rede neural artificial. Tal característica levou a rede neural artificial da primeira fase a ter baixa assertividade na classificação do PIO. Os resultados obtidos serão apresentados no item 4.5 Classificação Utilizando Redes Neurais Artificiais.

Posteriormente foram levantados os motivos pelos quais levaram à baixa assertividade na primeira fase, sendo eles:

- Dinâmica Excessiva da Tarefa Sintética: Foi observado e reportado pelos pilotos que realizaram os ensaios a dificuldade em realizar a tarefa devido à sua dinâmica excessiva, principalmente para modelos de maior susceptibilidade ao PIO.
- Tempo de Estabilização: Foi identificado que o tempo de estabilização na nova atitude de captura estava abaixo do esperado para caracterização da fase de *Fine Tracking.*
- Excesso de Comando Longitudinal do Piloto: Por consequência da dinâmica excessiva da tarefa, o piloto em comando atuava demasiadamente na busca da execução da tarefa, ofuscando as características inerentes à oscilação de PIO.

Por estas razões foi definida uma nova manobra a ser realizada seguindo novamente o fluxograma desta dissertação em sua completude. Foram determinadas as premissas para a definição do perfil da nova manobra. Tais são:

- Redução da quantidade de capturas: Foram definidas apenas 3 capturas de atitude para cada ponto de ensaio.
- Aumento do tempo de estabilização: Foi aumentado o tempo de estabilização para redução da atividade de comando longitudinal do piloto e melhor definição da fase de *Fine Tracking.*

Assim a manobra que continha maior aderência com as premissas definidas foi a de *Pitch Capture*, conforme descrito no capítulo Materiais e Métodos, item Tarefa Sintética / Pitch Capture. Após a conclusão completa dos testes foram analisados traços de todos os mesmos parâmetros da primeira fase para todos os 240 pontos de ensaios.

A Figura 23 apresenta os mesmos parâmetros da Figura 17 anteriormente apresentada e o modelo com a mesma característica de estabilidade. É possível verificar a diminuição na atividade de comando do piloto para a execução das capturas, bem como melhores estabilizações na fase de *Fine Tracking.*

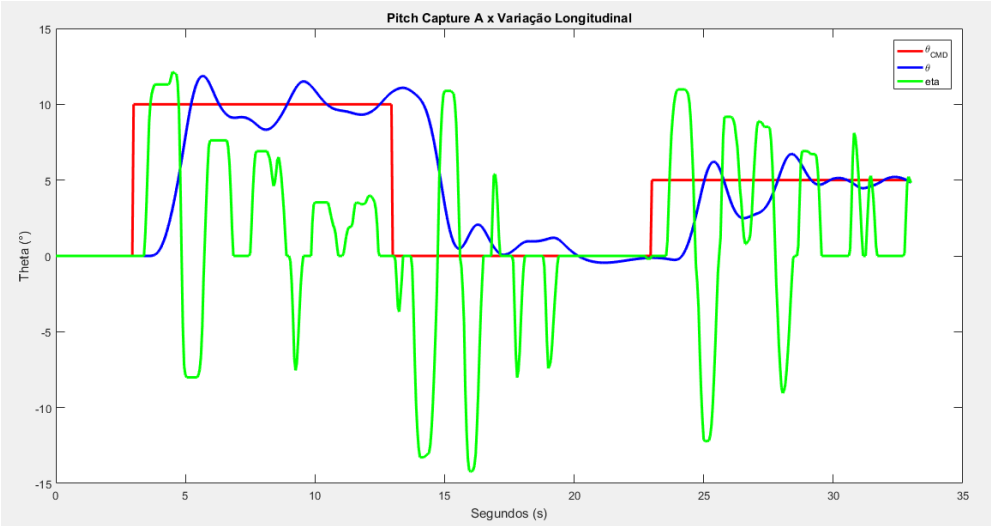

Figura 23 Pitch capture A x comando do piloto x Theta Fonte: Autor

Dada a redução da dinâmica na segunda fase, foi possível utilizar a alternativa primária de escolha das entradas, ou seja, entradas que evidenciariam as características longitudinais da aeronave e podendo assim serem obtidas com a análise do gráfico. As novas entradas da rede neural artificial foram escolhidas de forma a caracterizarem a resposta da aeronave com relação à atuação do piloto no comando longitudinal. Tais entradas foram definidas com base nas características de qualidade de voo, diferentemente da primeira fase em que não se conseguia estabelecer um critério de comparação gráfica devido à excessiva dinâmica do ensaio.

Durante a análise dos traços de todos os parâmetros dos ensaios de Pitch Capture foi constatado que a captura que melhor expressava as características dinâmicas longitudinais eram as de maiores variações em graus de Theta, pois esta continha a mesma dinâmica de atuação no comando longitudinais pelos pilotos, independente do modelo. Ou seja, era aplicado comando de grande amplitude na captura e reversão do movimento longitudinal, podendo utilizar a resposta da aeronave a tais comando como critério de comparação para as classificações de PIO.

Desta forma, todas as entradas escolhidas para treinamento da segunda rede neural artificial continham grandezas dos parâmetros no dado momento da captura de maior variação de Theta.

Abaixo segue a lista das entradas utilizadas e a base lógica para definição de cada uma.

1. *Comando Longitudinal Máximo Utilizado para a Captura:* Na análise desta entrada foi observada a homogeneidade de atuação para a captura de Theta. A Figura 24 apresenta os valores normalizadas de comando máximo na captura do Theta.

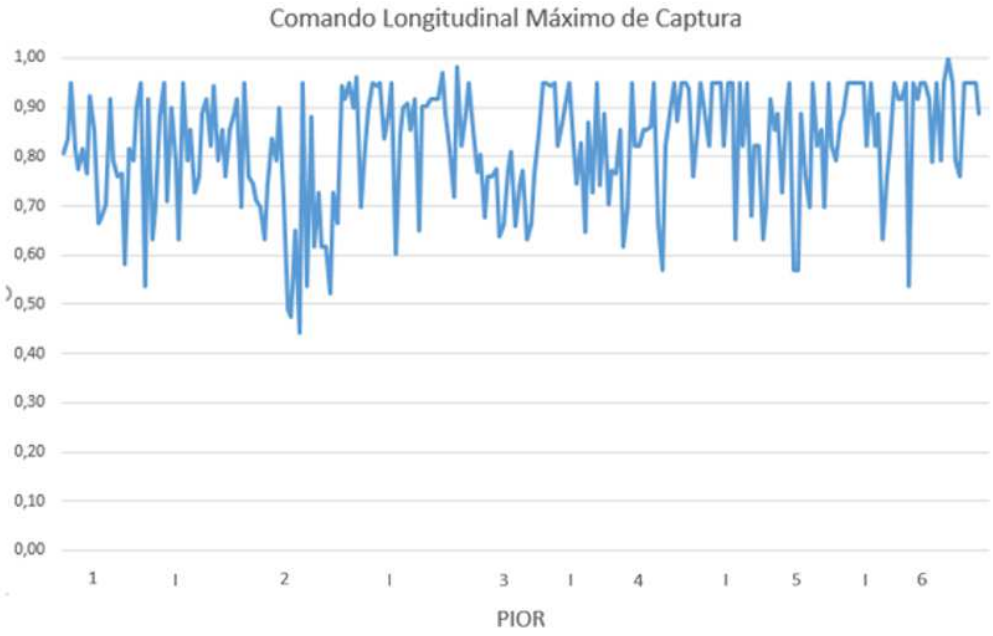

Figura 24 Comando Longitudinal Máximo de Captura Fonte: Autor

2. *Comando Longitudinal Máximo de Reversão da Captura*: Em par de análise com a entrada anterior foi observado o valor máximo de comando longitudinal empregado pelo piloto para a reversão do movimento de captura. Na análise da Figura 25 é possível observar tendência de comandos maiores para reversão do movimento de captura, sendo atribuído ao fato de que modelos menos estáveis necessitam de maiores comandos para reversões do movimento.

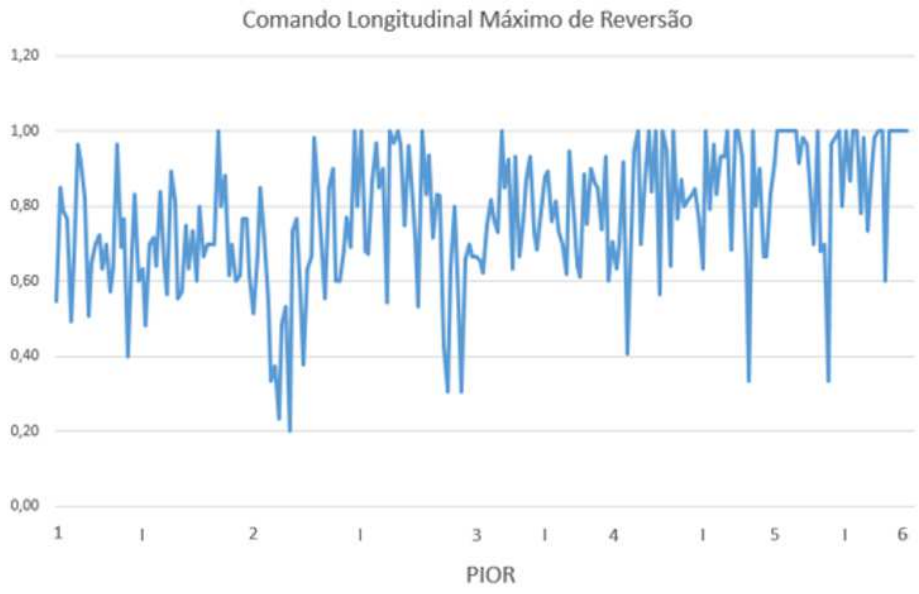

Figura 25 Comando Longitudinal Máximo de Reversão Fonte: Autor

3. *Pitch Rate Inversão de Comando Longitudinal:* Tal entrada foi escolhida para dimensionar o valor em graus por segundo de Theta no momento em que foi comandada reversão de movimento pelo piloto. A Figura 26 apresenta os valores de Pitch Rate normalizados na reversão, evidencia-se tendência de maiores valores de Pitch Rate para maiores classificações de PIO.

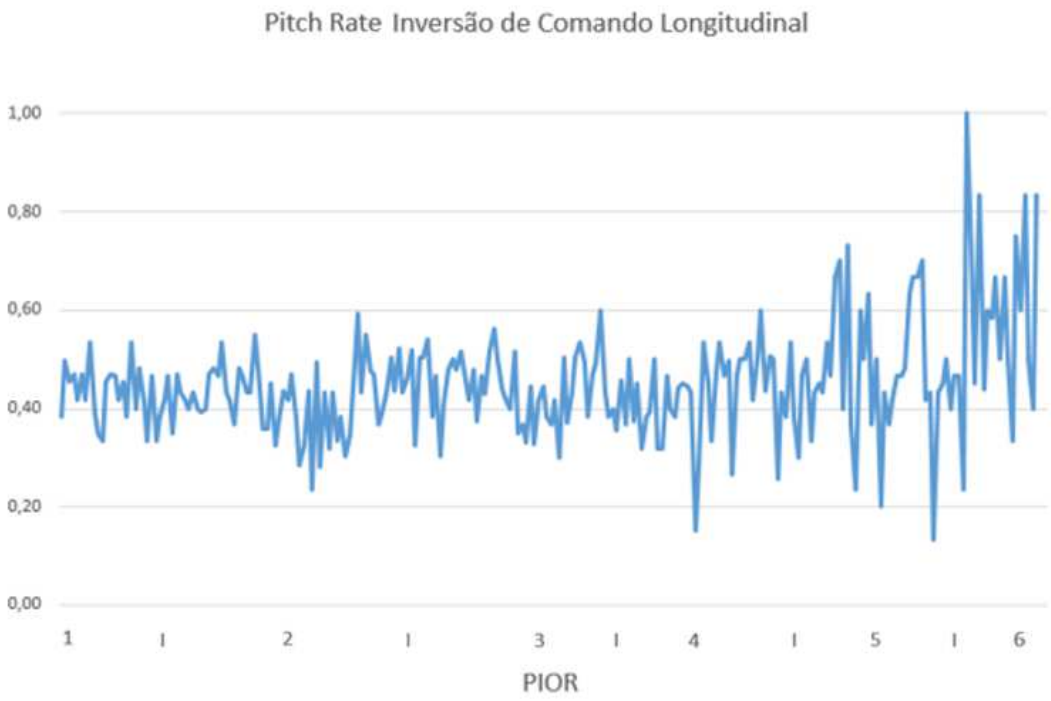

Figura 26 Theta Rate Inversão de Comando Longitudinal Fonte: Autor

4. *Tempo de Reversão do Movimento Longitudinal:* Outra variável de entrada para a rede neural artificial foi o tempo na qual a aeronave levava para reverter o movimento longitudinal durante a captura do Theta de maior variação. A Figura 27 apresenta os valores normalizados do tempo de reversão. É possível verificar tempos maiores para classificações de PIO entre 4 e 6, devido ao fato da dinâmica longitudinal da aeronave para classificações de PIO maiores ser mais lenta.

Figura 27 Tempo de Inversão de Movimento Longitudinal Fonte: Autor

5. *Overshoot de Theta na Captura:* Esta entrada foi considerada pois observou-se variações de overshoot diretamente proporcionais às classificações de PIO maiores. A Figura 28 apresenta os valores normalizados de cada overshoot para os pontos de ensaios de Pitch Capture.

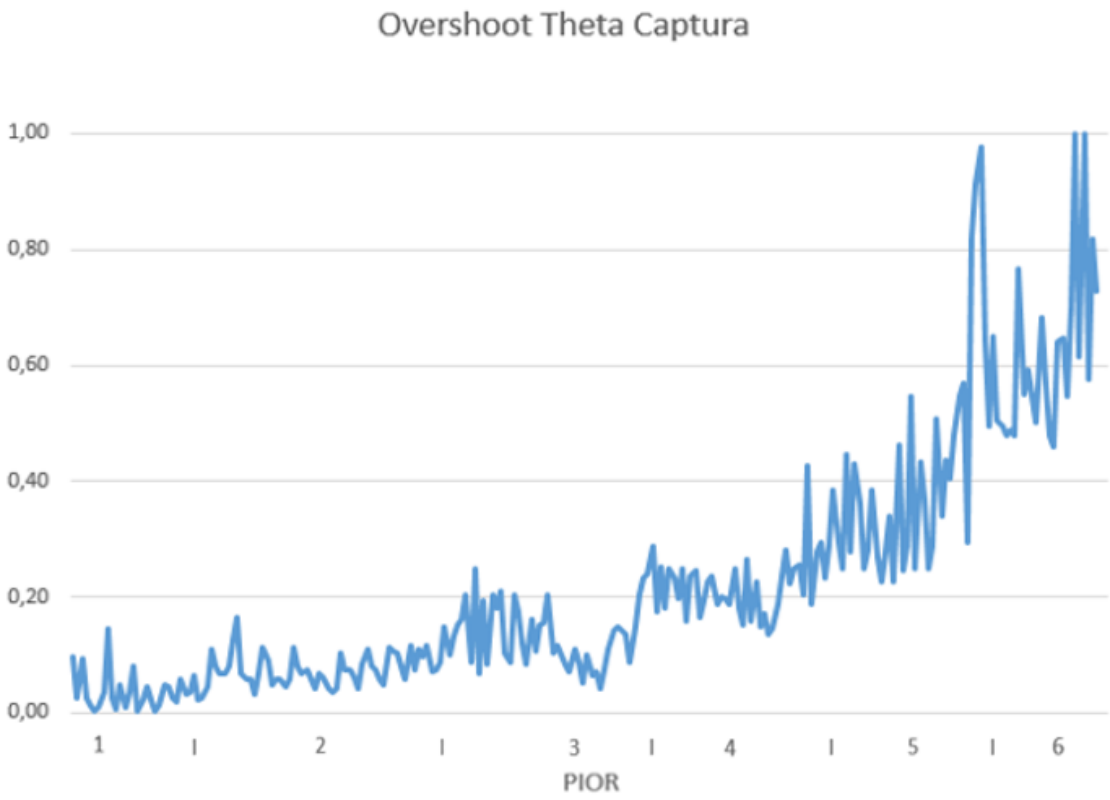

Figura 28 Overshoot Theta Captura Fonte: Autor

A variáveis de entrada para a Rede Neural Artificial anteriormente descritas foram escolhidas com base na observação do perfil dos parâmetros, objetivando a característica de resposta da aeronave ao comando longitudinal do piloto.

Foi atribuída à entrada *Overshoot de Theta na Captura* como a variável que mais tendeu à convergência da rede aumentando assim sua assertividade, porém a mesma poderia conter possíveis antecipações de reversão de comando do piloto mascarando os valores de overshoot. Para este caso as outras entradas tenderiam a evidenciar tal antecipação, contribuindo assim para a convergência global da rede neural artificial.

Adicionalmente às entradas anteriores foi utilizada a análise espectral de potência do sinal de comando do piloto, as entradas atribuídas a esta análise foram:

6. *Frequência Máxima de Potência do Sinal:* Foi atribuído a entrada como o valor da frequência na qual apresentava a máxima potência espectral.

7. *Máxima Potência do Sinal:* Na mesma análise anterior foi atribuída outra entrada contendo o máximo valor de potência espectral do sinal de comando longitudinal do piloto.

Para as duas entradas referentes à análise espectral descritas anteriormente, foram observadas tendências de padrão inversamente proporcionais, dado que para valores maiores de classificação de PIO houve o aumento da potência do sinal e a redução da frequência. As Figuras 29 e 30 apresentam tais tendências.

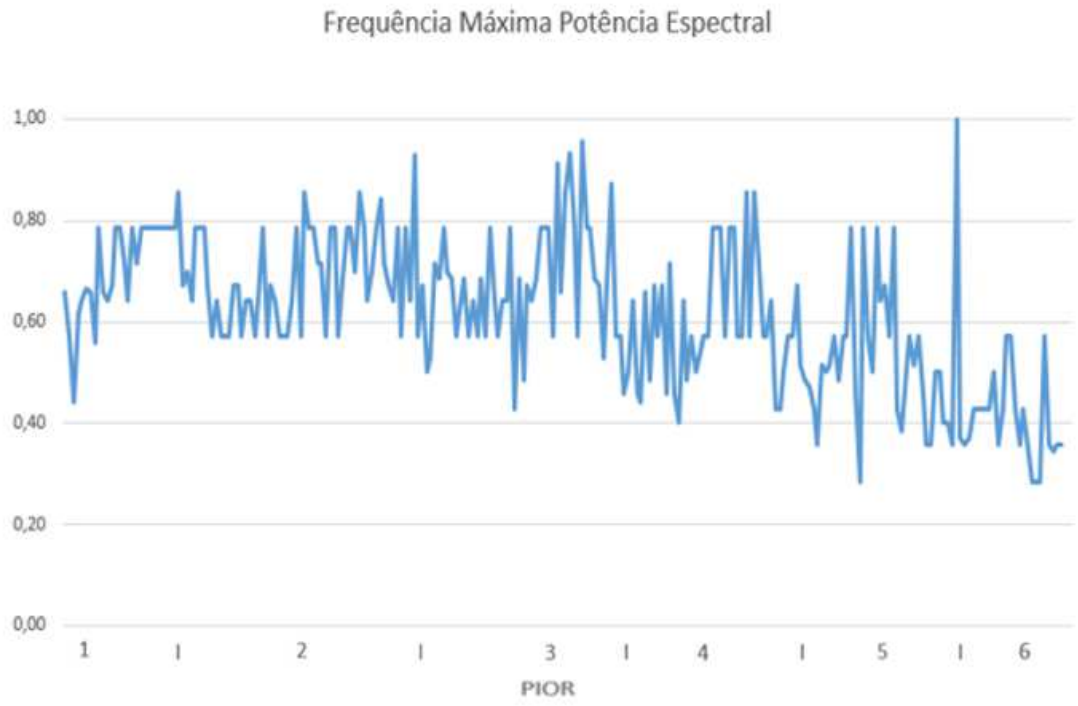

Figura 29 Frequência Máxima Potência Espectral Fonte: Autor

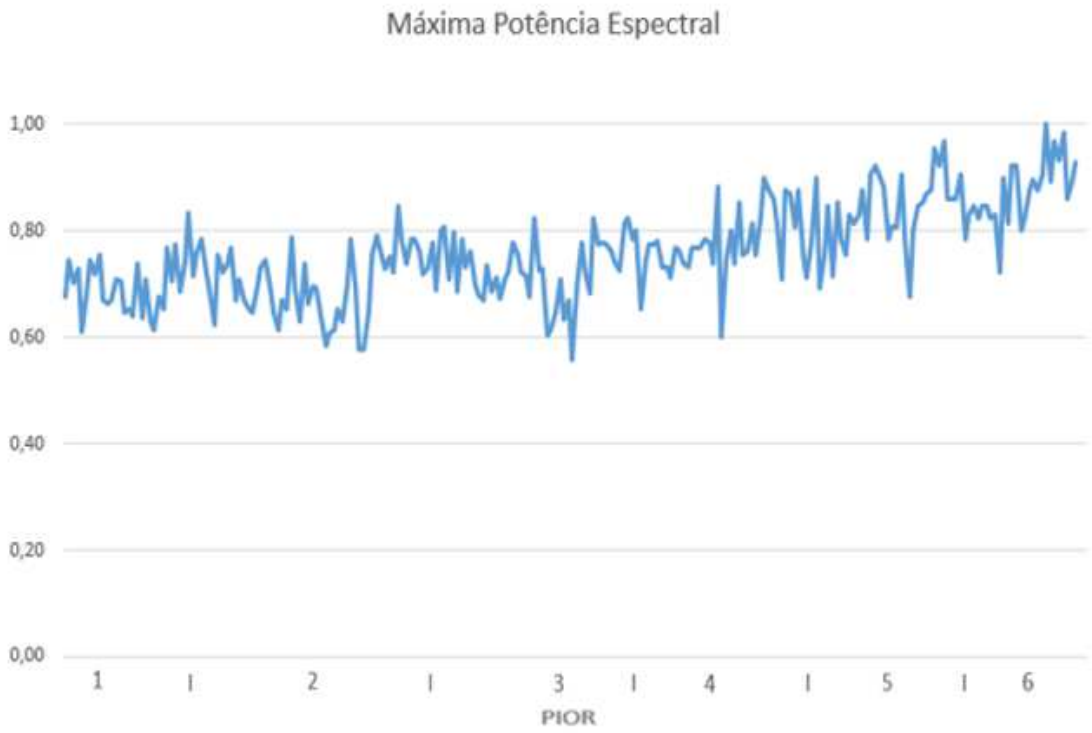

Figura 30 Máxima Potência Espectral Fonte: Autor

A análise da classificação de PIO utilizando a rede neural artificial para a segunda fase será apresentado posteriormente no item 4.5 Classificação de PIO Utilizando Redes Neurais Artificiais.

As Tabelas 4 e 5 apresentam os resumos das conclusões anteriormente descritas para cada uma das entradas em ambas as fases.

1. Primeira fase (Tarefa Sintética):

Tabela 4 Resumo das entradas primeira fase (Tarefa Sintética) Fonte: Autor

#	Entrada	Conclusão
1	*Energia e Potência da Tarefa Sintética*	Não apresentou tendências ao PIOR

2	*Energia e Potência de* θ *(Theta)*:	Não apresentou tendências ao PIOR
3	*Energia e Potência do Comando do Piloto*:	Diretamente proporcional ao PIOR
4	*Energia e Potência de Pitch Rate*:	Não apresentou tendências ao PIOR
5	*Energia e Potência do Ângulo de Fase entre Aeronave e Comando do Piloto*	Não apresentou tendências ao PIOR
6	*Energia e Potência da Convolução entre Comando Longitudinal do Piloto e* θ:	Diretamente proporcional ao PIOR
7	*Energia e Potência da Convolução entre a Tarefa Sintética e* θ	Não apresentou tendências ao PIOR
8	*Energia e Potência da Convolução entre Comando Longitudinal do Piloto e Ângulo de Fase*:	Diretamente proporcional ao PIOR
9	*Energia e Potência da Convolução entre Pitch Rate e Ângulo de Fase*:	Não apresentou tendências ao PIOR

2. Segunda fase (*Pitch Capture*):

Tabela 5 Resumo das entradas segunda fase Pitch Capture Fonte: Autor

#	Entrada	Conclusão
1	*Comando Longitudinal Máximo Utilizado para a Captura:*	Constante independente do PIOR
2	*Comando Longitudinal Máximo de Reversão da Captura*:	Diretamente proporcional ao PIOR

3	*Pitch Rate Inversão de Comando Longitudinal:*	Diretamente proporcional ao PIOR
4	*Tempo de Reversão do Movimento Longitudinal:*	Diretamente proporcional ao PIOR
5	*Overshoot de Theta na Captura:*	Diretamente proporcional ao PIOR
6	*Frequência Máxima de Potência do Sinal:*	Inversamente proporcional ao PIOR
7	*Máxima Potência do Sinal:*	Diretamente proporcional ao PIOR

Na análise comparativa entre as Tabelas 4 e 5 é possível verificar que na segunda fase as entradas estabeleceram melhores condições de proporcionalidade com relação ao PIOR, o que garantiu resultados mais assertivos da rede neural artificial.

4.4. ANÁLISE SUBJETIVA DO PIO

Para a conclusão do primeiro objetivo desta dissertação, iniciou-se a divisão dos dados das duas fases agrupando-os de acordo com os submodelos testado. Desta forma obteve-se seis grupos para cada uma das manobras testadas.

Para cada grupo foi feito o levantamento das classificações dadas pelos pilotos a cada um dos 240 pontos de ensaio. Com esta divisão foi possível a avaliação da dispersão da classificação a cada submodelo ensaiado.

As Figuras 31 e 32 apresentam as quantidades de classificações para cada valor de PIO, em cada um dos seis submodelos testados para as manobras de Tarefa Sintética e Pitch Capture respectivamente.

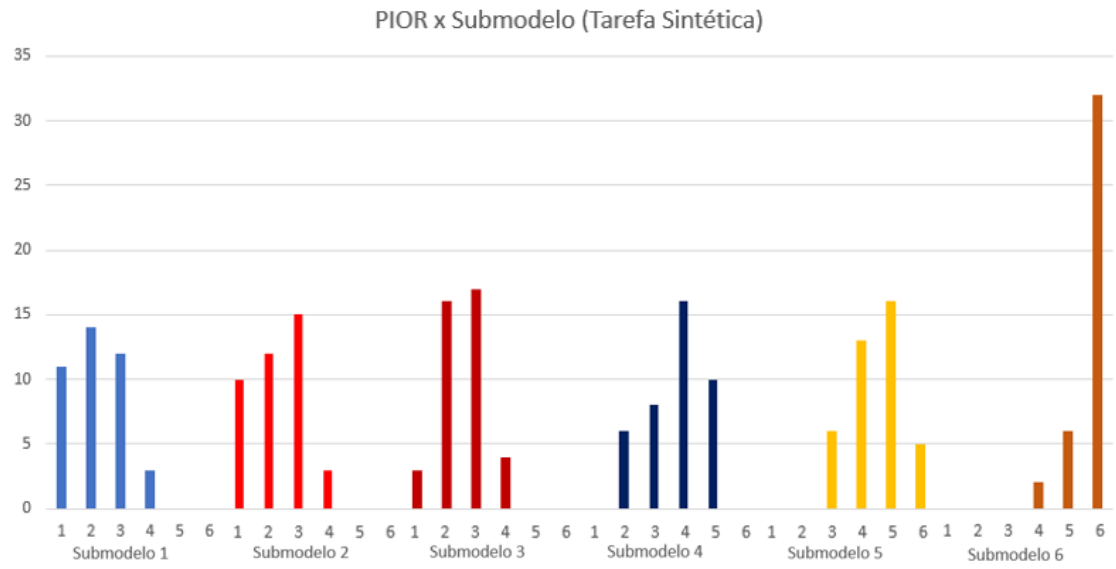

Figura 31 PIOR x Submodelo Tarefa Sintética Fonte: Autor

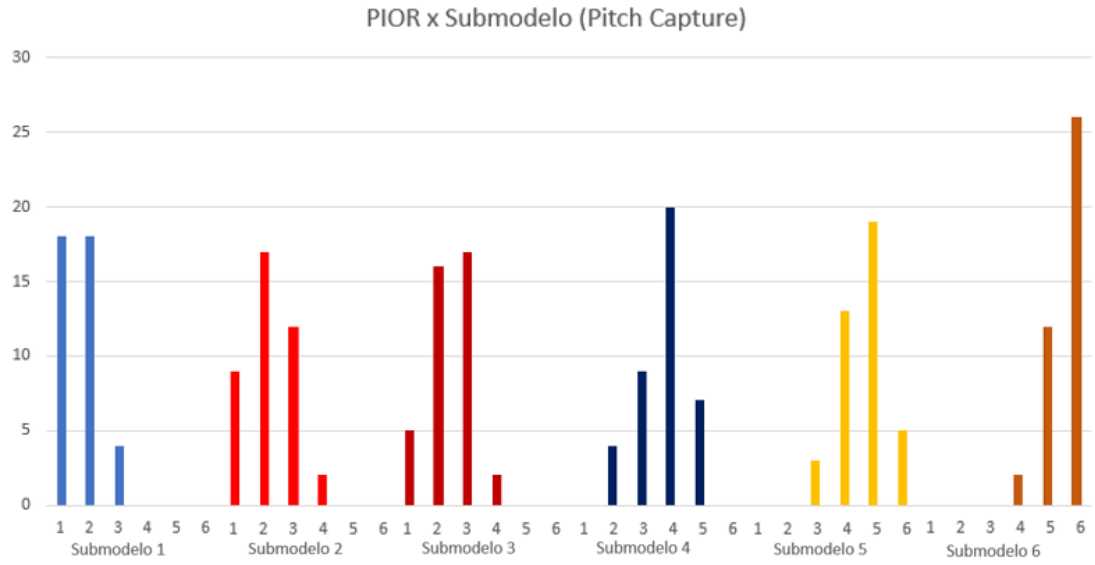

Figura 32 PIOR x Submodelo Pitch Capture Fonte: Autor

Com a análise dos gráficos apresentados é possível identificar a tendencia das classificações para cada submodelo correspondente com sua intrínseca tendência à oscilação.

Para complementar a análise anterior foi gerado um único gráfico (figura abaixo) contemplando os 480 pontos de ensaio (240 pontos da fase 1 e 240 pontos da fase 2). Este gráfico apresenta o desvio da classificação dada pelo piloto com relação ao valor correspondente do submodelo.

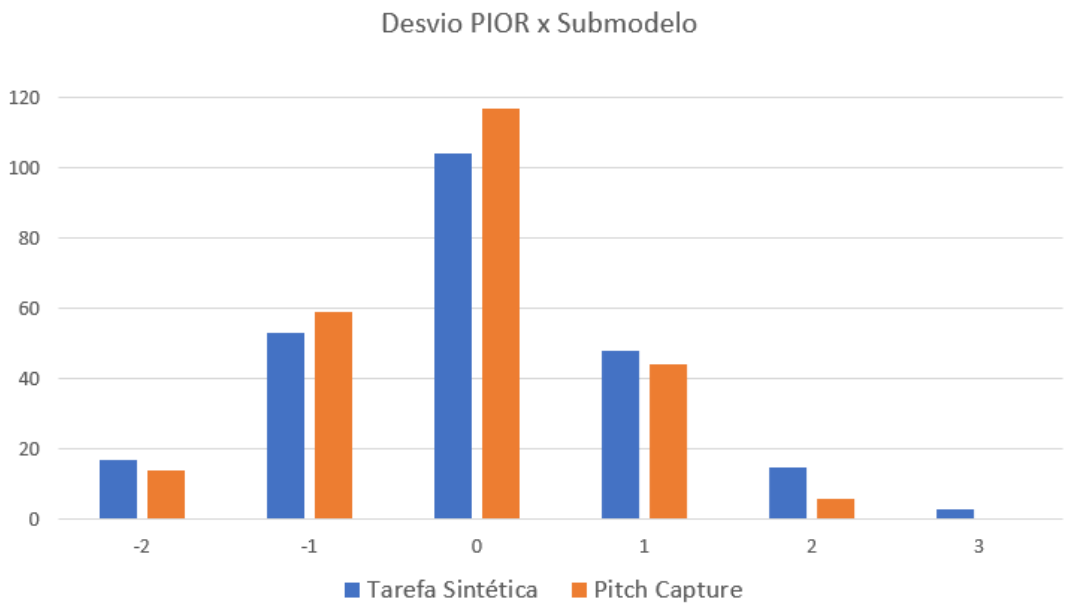

Figura 33 Desvio PIOR x Submodelo Fonte: Autor

A Figura 33 apresenta o desvio da classificação de PIOR com relação ao submodelo utilizado para ambas as manobras, onde 0 representa a correspondência exata com o submodelo, valores positivos para classificações PIOR maiores e negativos para PIOR inferiores.

É possível identificar que na segunda fase do trabalho onde foram realizados os ensaios com a manobra de Pitch Capture, houve maior tendência de agrupamento dos dados na mesma classificação de PIOR ensaiados com mesmo submodelo.

Na análise dos dados de obtenção do gráfico de desvio na classificação de PIOR por submodelo, obteve-se 104 pontos com desvio 0 para a manobra de Tarefa Sintética e 117 pontos sem desvio para a manobra de Pitch Capture. Perfazendo assim 43,33% e 48,75% de assertividade para as manobras de Tarefa Sintética e Pitch Capture respectivamente.

4.5. CLASSIFICAÇÃO DO PIO UTILIZANDO REDES NEURAIS ARTIFICIAS

O segundo objetivo desta dissertação foi a análise da capacidade da rede neural artificial em realizar a classificação do evento de PIO com base na tabela PIOR. Para tal, os procedimentos de desenvolvimento da rede neural artificial, definições das entradas e realização dos ensaios foram executados conforme descrito nos capítulos anteriores.

O projeto foi desenvolvido em duas fases distintas com a realização das manobras de Tarefa Sintética na primeira e *Pitch Capture* na segunda fase. Desta forma, foram obtidos resultados distintos das classificações para cada manobra.

A Figuras 34 e 35 apresentam, respectivamente, os índices de Performance e Gradiente da rede neural artificial durante o processo de treinamento para a primeira fase do projeto. Ou seja, são resultados de desempenho obtidos com relação ao treinamento da rede neural artificial com as entradas definidas para a manobra de Tarefa Sintética.

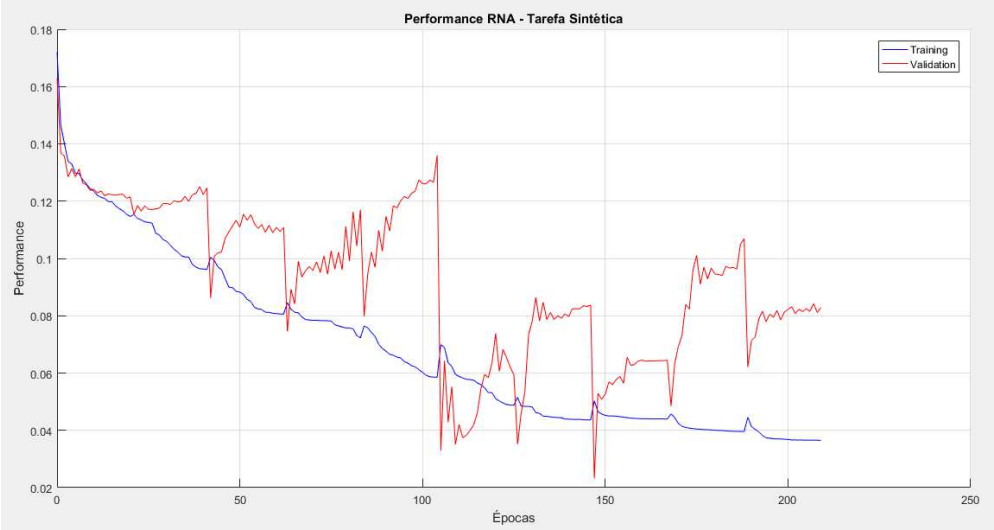

Figura 34 Performance RNA - Tarefa Sintética Fonte: Autor

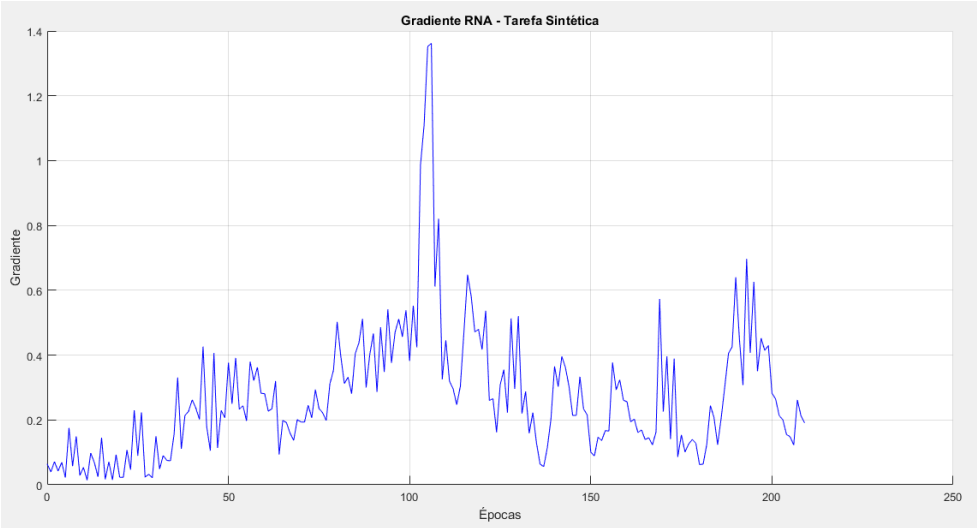

Figura 35 Gradiente RNA - Tarefa Sintética Fonte: Autor

Na análise das Figuras 34 e 35 é possível verificar a convergência global da rede durante o treinamento após aproximadamente 200 iterações.

Utiliza-se a matriz de confusão como ferramenta para avaliar o desempenho do resultado da rede neural artificial. A Figura 36 apresenta a matriz de confusão para a manobra de Tarefa Sintética. É possível evidenciar uma assertividade global de 67,2% na classificação do evento de PIO. Destaca-se também o resultado das colunas Target Class 1 e 6, onde foram classificados valores no extremo oposto da classificação de PIOR, ou seja, manobras tidas como PIOR = 6 foi classificada como 1 e vice-versa. Tal divergência na classificação é oriunda da característica intrínseca das entradas e pela ausência de tendências com relação ao PIOR.

Tal analogia pode ser feita também no Output Class linhas 1 e 6, onde houve classificação de PIOR 1 e 6 em todas as manobras, confirmando a baixa capacidade da rede em determinar os dois extremos da classificação PIOR.

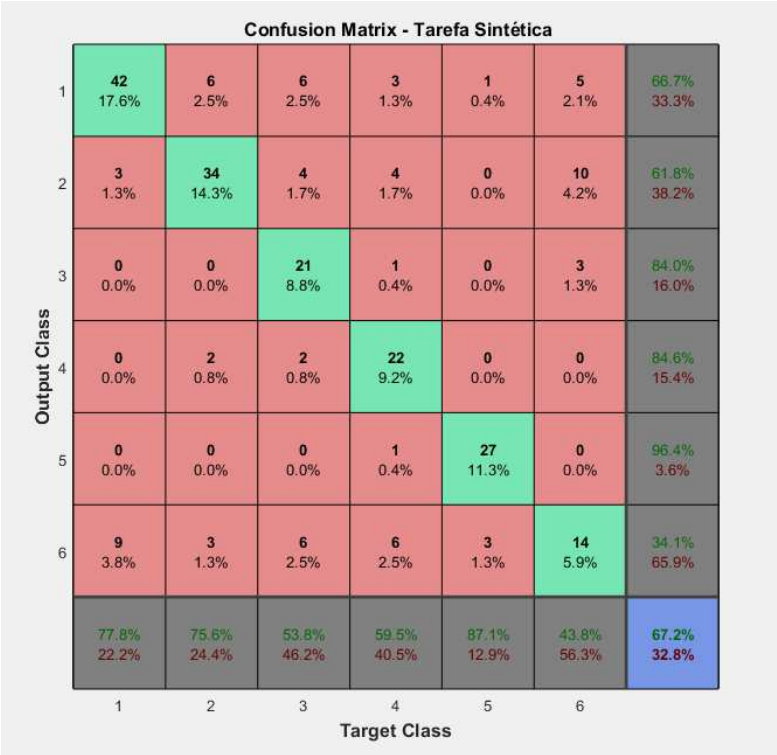

Figura 36 Confusion Matrix - Tarefa Sintética Fonte: Autor

As figuras 37 e 38 apresentam, respectivamente, os índices de Performance e Gradiente para a segunda fase deste trabalho com a execução da manobra de Pitch Capture.

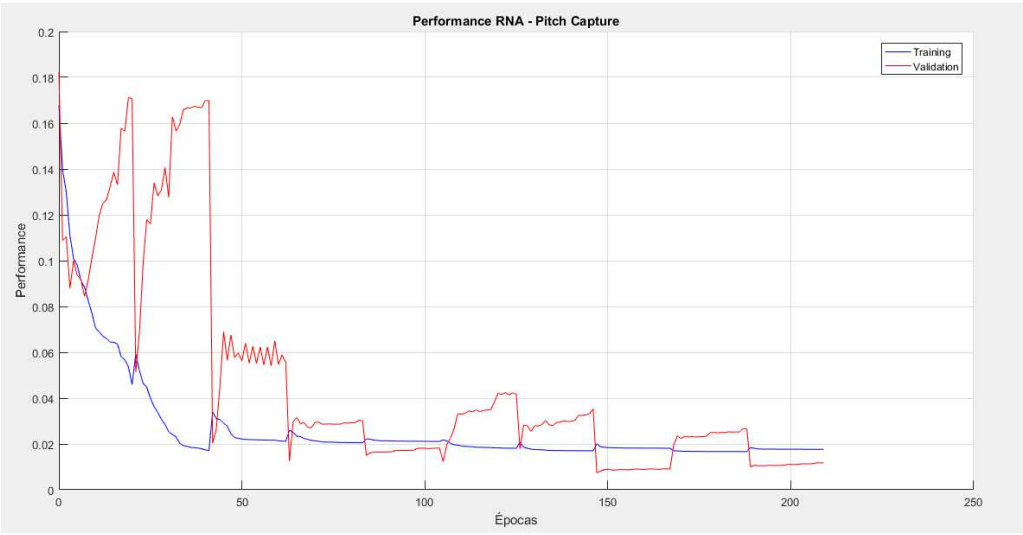

Figura 37 Performance RNA -Pitch Capture Fonte: Autor

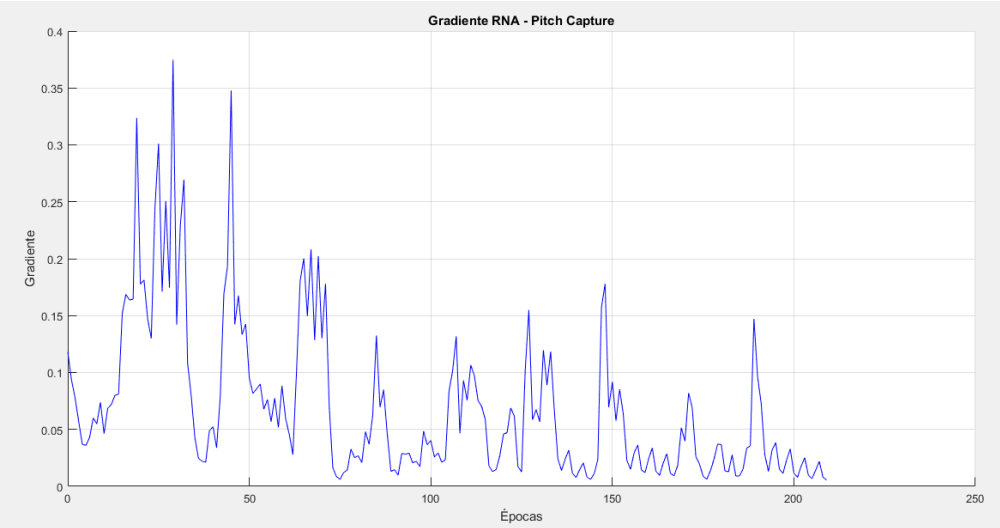

Figura 38 Gradiente RNA - Pitch Capture Fonte: Autor

Na análise das Figuras 37 e 38 é possível verificar que a rede neural artificial da segunda fase apresentou melhor tendência de convergência em comparação com a primeira, obtendo-a durante o processo de treinamento com menos de 50 iterações.

Houve também menor dispersão do gradiente após a concreta convergência do treinamento, sendo este variando entre 0 e 0,15, em contraponto com a primeira rede neural em que apresentou variação da convergência entre 0,1 e 0,7. Tal melhora na convergência se deve a característica de as entradas para a segunda fase que apresentaram tendências mais bem definidas com relação à classificação do PIO, levando ao processo de treinamento ser mais eficiente.

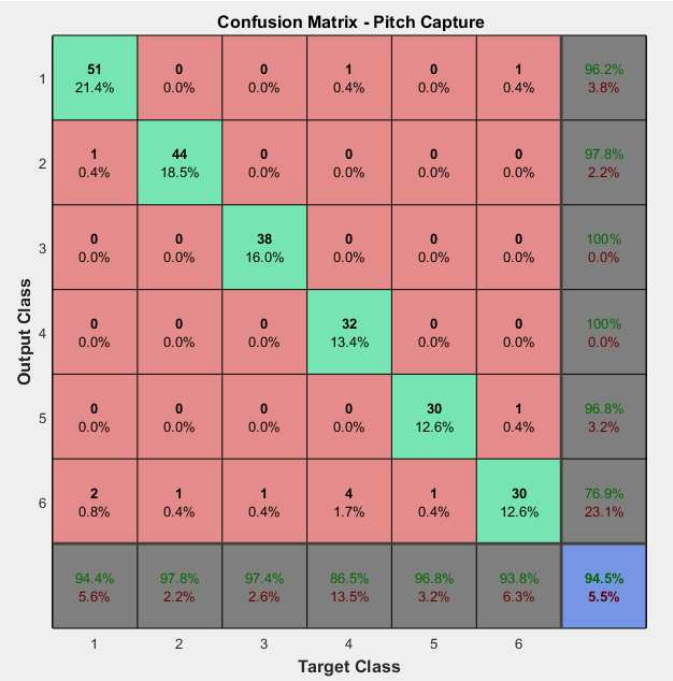

Figura 39 Confusion Matrix - Pitch Capture Fonte: Autor

A Matriz de Confusão para a manobra de Pitch Capture apresenta melhor assertividade global, com 94,5% das classificações sendo feitas corretamente. É possível observar expressiva melhora para todas as classificações de PIOR.

5. CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho apresentou estudos de classificação de PIO com base na escala de PIOR, onde os focos foram na execução de pontos de ensaios de PIO com todas as possíveis classificações de PIOR, e no desenvolvimento de uma rede neural artificial para a classificação das oscilações. Também como parte do ensaio e utilizando os mesmos dados gerados nos pontos de ensaio, foi realizado o estudo da subjetividade na classificação do PIO feita pelo piloto.

Primeiramente foi realizado o desenvolvimento do trabalho em três frentes, tais são:

- O modelamento da aeronave a ser utilizada nos ensaios de PIO bem como os submodelos com variação da estabilidade longitudinal propensos à obtenção de todos os níveis de oscilação de acordo com a escala de PIOR;
- A definição da manobra a ser utilizada como excitadora do PIO seguindo as premissas levantadas pela Advisory Circular AC 25-7-D; e
- O desenvolvimento da rede neural artificial para realização da classificação das oscilações de PIO.

Posteriormente à execução dos ensaios, foi realizado o estudo da subjetividade à classificação do PIO e também a classificação via rede neural artificial. Todo o trabalho foi desenvolvido em duas fases, sendo a primeira com a aplicação da manobra de Tarefa Sintética e a segunda com a repetição em sua totalidade com a manobra de Pitch Capture.

Na análise da subjetividade da classificação do PIO tomando como referência somente a classificação dada pelos pilotos de teste, conclui-se que na ordem de 50% das manobras executadas com o mesmo modelo (com mesma característica de qualidade de voo no eixo longitudinal), foram classificadas com o mesmo índice na escala de PIOR. O resultado refere-se a ambas as fases.

Na classificação utilizando redes neurais artificiais concluiu-se que a assertividade do resultado foi maior para a segunda fase do trabalho com 94,5% contra 67,2% para a primeira fase. Tal aumento da assertividade da resposta da rede da segunda fase em comparação à primeira, deve-se ao fato de que as entradas da segunda fase foram objetivadas nas características dinâmicas da aeronave e a manobra foi definida de tal modo que evidenciasse tais características.

Na comparação direta entre os procedimentos e os resultados obtidos da classificação do PIO via análise subjetiva e RNA, é possível concluir que a aplicação da RNA aumenta a assertividade da classificação e sua resposta tem ligação direta com a característica da manobra e das entradas.

Conclui-se que a rede neural artificial apresentou assertividade satisfatória quando utilizada com base na dinâmica da aeronave, podendo ser utilizada como ferramenta auxiliadora na definição da certificação de *Non PIO Prone* de um novo modelo de aeronave.

A principal vantagem na classificação do PIO utilizando redes neurais artificiais é o fato de que a ferramenta consegue realizar tal distinção com relação ao PIO apenas com base nas características de voo da aeronave, removendo a subjetividade da variável de classificação do PIO que depende da capacidade e treinamento adequado do piloto com relação a este tipo de ensaio.

Como desvantagem a classificação via redes neurais artificiais apresenta uma mudança na doutrina já utilizada como base da certificação do PIO. Portanto, para sua implementação seria necessária uma mudança de paradigma na comunidade de Ensaios em Voo.

As perspectivas de trabalho futuro para este trabalho envolvem estudos considerando alterações do modelo utilizado, bem como na definição de uma nova manobra especificamente desenhada para evidenciar características da dinâmica da aeronave, não se restringindo a empregar manobras comumente utilizadas pela comunidade de ensaios em voo.

Pode-se realizar o estudo com foco na alteração da rede neural artificial, modificando assim a capacidade de classificação de novas redes, bem como estabelecer comparações entre redes e entradas diferentes.

Além disso, pode-se explorar o uso de simuladores de base móvel para a realização dos ensaios e estudos das influências destes simuladores à classificação do PIO.

Referências Bibliográficas

AGARWAL, M. AGRAWAL, H. JAIN, N. KUMAR, M. Face recognition using principle component analysis eigenface and neural networks. Proceedings of the IEEE International Conference on Signal Acquisition and Processing, Bangalore, India, pp. 310-314, 2010.

AVIATION INVESTIGATION REPORT A14Q0155. Runway Excursion Air Canada A330-343. Transportation Safety Board, 2017.

ARMITAGE, D. W., OBER, H. K., A comparison of supervised learning techniques in the classification of bat echolocation calls. Ecological Informatics, vol. 5, n°. 6, pp. 456-473, 2010.

BIDINOTTO, J. H., MOURA, H. C., and NEVES, G. D. A., Universidade de São Paulo, São Carlos, SP, Brazil. Patent Application for a SynTask – Software de Tarefas Sintéticas Aeronáuticas No. BR512022002377-6, filed 06 Sep. 2022.

BUCKLEY, J. J., SILER, W., Fuzzy expert system and fuzzy reasoning. John Wiley, New York, USA, 2004.

BUREAL OF AIR COMMERCE. CAR-4: Civil Airworthiness Requirements. Washington, D.C., 1936.

CASTRO, L. N., TIMMIS, J., Artificial immune system – a new computational intelligence approach. Springer – Verlag, London, UK, 2002.

CELERE, A.L. Método para Avaliação do Ganho Empregado Pelo Piloto para Ensaios de PIO, Escola de Engenharia de São Carlos – Universidade de São Paulo USP – São Carlos, 2008.

CHASE, W.D., 1967. “Piloted Simulator Display System Evaluation: Effective Resolution and Pilot Performance in Landing Approach”. In: Proceedings of the Third Annual NASA-University Conference on Manual Control. Los Angeles (NASA SP-144).

CHO, K. C., MA, Y. B., LEE, J. S., Design of computational grid-based intelligence ART-1 classification system for bioinformatics applications. Proceedings of 5 International Conference on Grid and Cooperative Computing Workshops, Changsha, China, pp. 367-370, 2006.

CHOWDHURY, M., ALOUANI, A., HOSSAIN, F. Comparising of ordinary kriging and artificial neural network for spatial mapping of arsenic contamination of groundwater. Stochastic Environmental Research and Risk Assessment, vol. 24, n°.1, pp. 119-144, 2010.

CIRESAN, D.C., GIUSTI, A., GAMBARDELLA, L.M., SCHMIDHUBER, J., Mitosis detection in breast cancer histology images with deep neural networks. Lecture Notes in Computer Science, vol. 8150, pp. 411-418, 2013.

CIVIL AERONAUTICS BOARD. CAR-3: Airworthiness Requirements Normal, utility, Acrobatic and Restricted Purpose Categories. Washington, D.C., 1949.

COAKLEY, J. R., BROWN, C. E., Artificial neural networks in accounting and finance: modeling issues. International Journal of Intelligenct Systems in Accounting, Finance & Management, vol.9, n°.2, pp. 119-144, 2000.

COOPER, G; HARPER, R. The use of pilot rating in the evaluation of aircraft handling qualities. Washington, D.C., 1969. (NASA Technical Note, TN D-5153)

CORDEIRO, L. E. F.; NETTO, M. L. A., Reconhecimento de Fonemas da Língua Portuguesa Pelo Uso de Redes Neurais do Tipo Perceptron Multicamadas. 1994. Campinas – SP.

COSTA, M., OLIVEIRA, D., PINTO, S. TAVARES, A., Detecting Driver´s Fatigue, distraction and activity using non-intrusive ai based monitoring system, Journal of Artificial Intelligence and Soft Computing Research, 9(4): 247-266. 2019.

D'INVERNO, M., LUCK, M., Understanding agent system. Springer – Verlag, Berlin, Germany, 2004.

DAILEY, M. N. COTTRELL, G. W. Empath: a neural network that categorizes facial expressions. Journal of Cognitive Neuroscience, vol. 14, pp. 1158-1173, 2002.

DASGUPTA, D., Advances in artificial immune system. IEEE Computational Intelligence Magazine, vol. 1, n°.4, pp. 40-49, 2006.

DASGUPTA, D., MICHALEWICZ, Z., Evolutionary algorithms in engineering applications. Springer-Verlag, Berlin, Germany, 1997.

DEEB, O., Correlation ranking and stepwise regression procedures in principal components artificial neural networks modeling with application to predict toxic activity and human serum albumin binding affinity. Chemometrics and Intelligent Laboratory System, vol. 104, n°.2, pp 181-194, 2010.

DEPARTAMENT OF DEFENSE INTERFACE STANDARD. *Mil Standard MIL1797A*: Flying Qualities of Piloted Airplanes. Washington, D.C. 1990.

ETKIN, B.; REID, L. D. Dynamics of flight stability and control. 3rd Edition. New York: New York Wiley, 1996.

FEDERAL AVIATION ADMINISTRATION. Code of Federal Regulations. *Advisory Circular AC25-7D*: Flight test Guide for Transport Category Airplanes. Washington, D.C., 2018.

FEDERAL AVIATION ADMINISTRATION. Code of Federal Regulations. *FAR 25*: Airworthiness Standards: Transport Category Airplanes. Washington, D.C., 1965.

FERNANDES, R. A. S., Identificação de fontes de correntes harmônicas por redes neurais artificiais. Dissertação de mestrado (Engenharia Elétrica), Universidade de São Paulo, São Carlos, 2009.

GAINES, M. "Software Fault Caused Gripen Crash". Flight International. London, UK: Reed Business Information. p. 4. ISSN 0015-3710. Archived from the original on 12 January 2014.

GOLDBERG, D.E., Genetic algorithms in search, optimization and machine learning. Addison Wesley, Reading, Massachusetts, USA, 1989.

GRAUPE, D. Principes of Artificial Neural Networks Vol 6, 2nd ed. Singapore, World Scientific Publishing, 2007.

HAN, H. G., CHEN, Q.L., QIAO, J. F., An efficient self-organizing RBF neural networks for water quality prediction. Neural Networks, vol.24, n°.7, pp. 717-725, 2011.

HARRIS, J.; BLACK, G.T. "F-22 Control Law Development and Flying Qualities." AIAA Paper 96-3379 (A96-35101), p. 156, 1996.

HAYKIN, S. Neural Networks and Learning Machines, 3rd ed. New Jersey: Pearson Prentice Hall, 2009.

HAYKIN, S. Redes Neurais Princípios e Práticas, 2º Ed. São Paulo, Bookman, 2001.

HEBB, D. O. The organization of behavior: a neuropsychological theory. Wiley, New York, USA, 1949.

KARAA, Y., BOYACIOGLUB, M. A., BAYKAN, O. K., Predicting direction of stock price index movement using artificial neural networks and support vector machines: The Sample of the Istanbul Stock Exchange. Expert System with Applications, vol. 38, n°.5, pp. 5311-5319, 2011.

KENNEDY, J., EBERHART, R. C., Swarm intelligence. Morgan Kaufmann Publishers, San Diego, California, USA, 2001.KHAN, J., WEI, J. S., RINGNÉR, M. SAAL, L. H., LADANYI, M., WESTERMANN, F., BERTHOLD, F., SCHWAB, M., ANTONESCU, C.R., PERTERSON, C., MELTZER, P.S.; Classification and diagnostic prediction of cancers using genes expression profiling and artificial network. Natural Medicine, Vol 7, n°.6, pp 673-679, 2001.

LEK, S., GUÉGAN, J. F., Artificial neural networks – Application to Ecology and Evaluation. Springer-Verlag, Berlin, Germany. 2012.

LEMES, R. C. Desenvolvimento de um Algoritmo Adaptativo Fuzzy-Washout Clássico para uma Plataforma de Stewart, Universidade De São Paulo – Esxcola de Engenharia de São Carlos, São Carlos 2018.

LEVENBERG, K. A Method for the Solution of Certain Non-Linear Problens in Least Square, Quartely of Applied Mathematics. 1944

LIGUNI, Y. SAKAI, H. ; TOKUMARU, H. A Real Time Learning Algorithm for a Multilayered Neural Networks Based on The Extended Kalman Filter. IEEE Trans on Signal Processing, 40(4): 959-966, April 1992.

LIPPMANN, R. P. An Introduction to Computing with Neural Networks. IEEE AASP Magazine pages 4-22, April 1987.

MACEDO, J. P. C. A. Loss of Control in Flight: A Redefnition Based on Qualitative and Quantitative Optics, Universidade de São Paulo – Escola de Engenharia de São Carlos, São Carlos 2019.

MACKALL, D. NELSON, S. SCHUMANN, J. "Verification and Validation of Neural Networks for Aerospace Systems" NASA / CR – 2002 – 211409 – California.

MAHMOOD, R. A. LIOU, R.J. fast Learning Process of Multilayer Neural Network Using Recursive Least Square Method. IEEE Trans. On Signal Processing, 40(2): 446-450, Feb 1992.

MAQUARDT, D. An Algorithm for Least-Squares Estimation of Nonlinear Parameters, SIAM Journal on Applied Mathematics, 1963.

MCCULLOCH, W. S. PITTS, W. A logical calculus of the ideas immanent in nervous activity, Bulletin of Mathematical Biophysics, Vol. 5, pp. 115-133, 1943.

MENDYK, A., JACHOWICZ, R., Unified methodology of neural analysis in decision support system built for pharmaceutical technology. Experts System with Application, vol. 32, n°.4, pp. 1124-1131, 2007.

MICHALEWICZ, Z., Genetic algorithms + data structures = evolution programs. Springer – Verlag, 3 edition, Berlin, Germany, 1999.

MINSKY, M.L., PAPERT, S. A. Perceptrons: an Introduction to Computational Geometry. The MIT Press, Cambridige, Massachusetts, USA, 1969.

MOURA, H.C., Supressão adaptativa de PIO em Sistemas FBW. Dissertação de Mestrado. Universidade de São Paulo, 2018.

MOURA, H.C., ALEGRE, G.S.P., BIDINOTTO, J.H., BELO, E.M., 2018. “PIO Susceptibility in Fly-by-Wire Systems”. In Proceedings of the 31st Congress of the International Council of the Aeronautical Sciences – ICAS 2018. Belo Horizonte, Brazil.

NEVES, G.D.A., BRUSCHI, A.G., BIDINOTTO, J.H., 2021. “Development of a Tool for Pilot Induced Oscillations (PIO) Testing in flight Simulator” 26th International Congress of Mechanical Engineering 2021 – COBEM 2021 – Virtual Congress Brazil.

PARSONS, S., JONES, G., Acoustic identification of twelve species of echolocation bat by discriminant function analysis and artificial neural networks. Journal of Experimental Biology, vol. 203, n°. 17, pp. 2642-2656, 2000.

PEDRYCZ, W., GOMIDE, F., Fuzzy system engineering – toward human-centric computing. John Wiley & Sons, Hoboken, New Jersey, USA, 2007.

QI, S., JIN, K., LI, B., QIAN, Y., The Exploration of Internet Finance by Using Neural Network, Journal of Computational and Applied Mathematics. 369:112030. 2020.

RAGHUVARAN, J. G. T., KANNAYAN, M., GOVINDAN, K., Prediction of Specific Wear Rate for LM25/ZrO2 Composites Using Levenberg-Maquardt Backpropagation Algorithm. Journal of Materials Research and Technology. November 2019.

ROSENBLATT, F. The Perceptron: a probabilistic model for information storage and organization in the brain. Psychological Review, vol. 65, pp. 386-408.

ROOS, T. J., Fuzzy logic with engineering application, John Willey, New York, USA, 2004.

RUMELHART, D. E. ; JAMES L. at al McClelland. Parallel Distributed Processing, vol I and II, The MIT Press, 1989.

SAPNA, S., TAMILARASI, A., KUMAN, M. P., Bacjpropagarion Learning Algorithm Based on Levenberg-Maquardt Algorithm. College Engineering, Tamilnadu, India, 2012.

SCALERO, R. S. ; TEPEDELENLIOGLU, N. A Fast New Algorithm for Training Feed-Forward Neural Network. IEEE Trans. On Signal Processing, 40(1): 202-210. Jan 1992.

SHARMA, A., SHARMA H., SAHOO, P. K., TRIPATHI, R.K., MEHER, L. C., ANN Based Modeling od Performance and Emission Characteristics of Diesel Engines with Poland Biodiesel at Different Injection Pressure. Inst of Energy, 2015.

SILVA, I. N. ; SPATTI, D. H. ; FLAUZINO, R. A. ; "Redes Neurais Artificiais para Engenharia e Ciências Aplicadas" 2ª Edição. ArtLiber Editora. São Paulo 2016.

STEINERA, N. Y., HISSELB, D., MOÇOTÉGUY, Ph, CANDUSSOC, D., Diagnosis of polymer electrolyte fuel cells failure models (flooding / drying out) by neural networks modeling. International Journey of Hydrogen Energy, vol. 36, no. 4, pp. 3067-3075, 2011.

SUZUKI, K; "Artificial Neural Network – Industrial and Control Engineering Applications" Intech – Croatia – 2010.

TABACH, E. E., LANCELOT, L., SHAHROUR, I., NAJJAR, Y., Use of artificial neural network simulation metamodeling to assess groundwater contamination in a road project. Mathematical and Computer Modelling, vol.45, n°.7-8, pp.766-776, 2007.

TIAN, H., SHANG, Z., Artificial neural network as a classification method of mice by their calls. Ultrasonics, vol.44, pp. 275-278, 2006.

TOO, G. P. J., CHEN, S.R., HWANG, S., Inversion of acoustics impedance of a wall by using artificial neural network. Applied Acoustics, vol.68, n°.4, pp. 377-389, 2007.

VICENTE, B.G. L. Z., CEZARE, M. J., SILVA, I. N., Controlador neural de marcha lenta para motores de combustão interna. Anais do VIII Simposio Brasileiro de Automação Inteligente, Florianópolis, CD-ROM (paper n° 30909, 6 pags), 2007.

UNITED STATES ARMY AIR CORPS. 1920 Regulations for Operation of Aircrafts. Washington, D.C. 1920.

YAN, H. JIANG, Y. ZHENG, J. PENG, C. LI, Q. A multilayer perceptron-based medical decision support system for heart disease diagnosis. Expert System with Applications, vol. 30, n°.2, pp. 272-281, 2006.

YURII, K., LUIDMILA, G., Application of Artificial Neural Networks in Vehicles design self-diagnostic for Safety Reasons. Transport Research Procedia, 12th International Conference. St Petersburg Russia. 2016.

ZADEH, L. Fuzzy logic, neural networks and soft computing. Processing of the 2 International Conference on Fuzzy Logic and Neural Networks, Iizuka, Japan, pp.13-14, 1992.

ZHANG, Q., STANLEY, S. J., Real-time water treatment process control with artificial neural networks. Journal of Environmental Engineering, vol. 125, n°.2, pp. 153-160, 1999.

ZHANG, Q. B., HEBDA, R. J., ZHANG, Q.J., ALFARO, R.J., Modeling tree-ring growth responses to climatict variables using artificial neural networks. Journal of Forest Science, vol.46, n°.2, pp. 229-239, 2000.

ZHANG, Z. FRIEDRICH, K., Artificial neural networks applied to polymer composites: a review. Elsevier Science, composites Science and Technology, vol. 63, n°14, pp. 2029-2044, 2003.