



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES



sid.inpe.br/mtc-m21d/2021/12.14.15.54-TDI

CONTROLE DE ATITUDE: UMA ABORDAGEM ATRAVÉS DE REDES NEURAIIS ARTIFICIAIS

Thadeu Augusto Medina de Carvalho

Dissertação de Mestrado do Curso de Pós-Graduação em Engenharia e Tecnologia Espaciais/Mecânica Espacial e Controle, orientada pelo Dr. Ronan Arraes Jardim Chagas, aprovada em 17 de dezembro de 2021.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/46239S2>>

INPE
São José dos Campos
2021

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE
Coordenação de Ensino, Pesquisa e Extensão (COEPE)
Divisão de Biblioteca (DIBIB)
CEP 12.227-010
São José dos Campos - SP - Brasil
Tel.:(012) 3208-6923/7348
E-mail: pubtc@inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):

Presidente:

Dra. Marley Cavalcante de Lima Moscati - Coordenação-Geral de Ciências da Terra (CGCT)

Membros:

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação (CPG)
Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia, Tecnologia e Ciência Espaciais (CGCE)
Dr. Rafael Duarte Coelho dos Santos - Coordenação-Geral de Infraestrutura e Pesquisas Aplicadas (CGIP)
Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon
Clayton Martins Pereira - Divisão de Biblioteca (DIBIB)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)

EDITORAÇÃO ELETRÔNICA:

Ivone Martins - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES



sid.inpe.br/mtc-m21d/2021/12.14.15.54-TDI

CONTROLE DE ATITUDE: UMA ABORDAGEM ATRAVÉS DE REDES NEURAIIS ARTIFICIAIS

Thadeu Augusto Medina de Carvalho

Dissertação de Mestrado do Curso de Pós-Graduação em Engenharia e Tecnologia Espaciais/Mecânica Espacial e Controle, orientada pelo Dr. Ronan Arraes Jardim Chagas, aprovada em 17 de dezembro de 2021.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/46239S2>>

INPE
São José dos Campos
2021

Dados Internacionais de Catalogação na Publicação (CIP)

Carvalho, Thadeu Augusto Medina de.

C253c Controle de atitude: Uma abordagem através de redes neurais artificiais / Thadeu Augusto Medina de Carvalho. – São José dos Campos : INPE, 2021.

xxviii + 126 p. ; (sid.inpe.br/mtc-m21d/2021/12.14.15.54-TDI)

Dissertação (Mestrado em Engenharia e Tecnologia Espaciais/Mecânica Espacial e Controle) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2021.

Orientador : Dr. Ronan Arraes Jardim Chagas.

1. Falhas em rodas de reação. 2. Controle inteligente.
3. Backpropagation. 4. Treinamento offline. 5. Julia language.
I.Título.

CDU 629.7.062.2:004.032.26



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**
Serviço de Pós-Graduação - SEPGR**DEFESA FINAL DE DISSERTAÇÃO DE THADEU AUGUSTO MEDINA DE CARVALHO**
BANCA Nº 339/2021, REG 797602/2019

No dia 17 de dezembro de 2021, às 14h, por teleconferência, o(a) aluno(a) mencionado(a) acima defendeu seu trabalho final (apresentação oral seguida de arguição) perante uma Banca Examinadora, cujos membros estão listados abaixo. O(A) aluno(a) foi APROVADO(A) pela Banca Examinadora, por unanimidade, em cumprimento ao requisito exigido para obtenção do Título de Mestre em Engenharia e Tecnologia Espaciais/Mecânica Espacial e Controle. O trabalho precisa da incorporação das correções sugeridas pela Banca e revisão final pelo(s) orientador(es).

Título: "CONTROLE DE ATITUDE: UMA ABORDAGEM ATRAVÉS DE REDES NEURAIS ARTIFICIAIS"

Membros da Banca:

Dr. Evandro Marconi Rocco - Presidente - INPE

Dr. Ronan Arraes Jardim Chagas - Orientador - INPE

Dr. Lamartine Nogueira Frutuoso Guimarães - Membro Interno - INPE

Dr. Carlos Renato Huaura Solórzano - Membro Externo - UFABC / CECS



Documento assinado eletronicamente por **Ronan Arraes Jardim Chagas, Tecnologista**, em 23/12/2021, às 09:31 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **CARLOS RENATO HUAURA SOLORZANO (E), Usuário Externo**, em 23/12/2021, às 09:41 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Lamartine Nogueira Frutuoso Guimarães (E), Usuário Externo**, em 24/12/2021, às 00:08 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Evandro Marconi Rocco, Tecnologista**, em 28/12/2021, às 14:21 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site <http://sei.mctic.gov.br/verifica.html>, informando o código verificador **8956130** e o código CRC **39080688**.

“ Mestre não é quem sempre ensina, mas quem de repente aprende ”.

JOÃO GUIMARÃES ROSA
em “Grande Sertão: Veredas”, 1956

*Às crianças: **Lucca e Melissa;**
meu amigo e minha sobrinha.*

AGRADECIMENTOS

Agradeço primeiramente aos meus amados pais, Geisa e Cláudio, os quais me concederam a vida e à ela tanto se dedicaram de maneira que minhas conquistas também os pertence. À minha amada irmã Thatyana, por ter acompanhado com tanto afeto e zelo minha jornada desde o momento em que nasci e por me presentear com a recém chegada e já muito amada sobrinha, Mel.

À minha amada avó Elenita pelo o carinho e apoio de sempre. Agradeço a minha avó Sebastiana (in memoriam) pela amável fortaleza que foi e que almejo um dia ser. Aos meus amados padrinhos, Janice e Osmar pela sabedoria e exemplo de caráter que tanto me inspiram.

Agradeço à minha amada companheira Silvia embora com palavras não seja possível traduzir minha gratidão pelo seu apoio em todas as horas desta jornada. Este trabalho também pertence a você e ao seu pequeno Lucca, que tanto me motivou com sua alegria e carinho. Agradeço também aos meus sogros Alícia e Rogélio, bem como minha cunhada Analía, os quais me abraçaram como família e pelos quais guardo inestimável gratidão.

Agradeço muito ao estimado mestre Dr. Ronan Chagas, primeiramente pela confiança e em seguida pela inspiração, paciência e por todas as oportunidades de aprendizado estendidas à mim. Para mim é uma grande honra ter trabalhado ao seu lado.

Aos demais mestres do INPE que contribuíram com esta etapa de minha formação, sendo eles: Dr. Evandro Rocco, Dr. Hélio Kuga, Dr. Marcelo Lopes, Dr. Mário Ricci, Dr. Rafael Costa, Dr. Renato Magalhães e Dr. Valdemir Carrara. Um agradecimento especial ao mestre Dr. Carlos Solórzano por todo apoio e incentivo desde os primeiros anos da graduação.

Aos colegas Pryscilla, Rebecca, Walter e Wilson pelo companheirismo. Agradeço imensamente todos os servidores do Instituto Nacional de Pesquisas Espaciais que tanto contribuem para a existência deste importante centro de pesquisa que orgulha tanto o Brasil.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 88882.444549/2019-01.

RESUMO

O presente trabalho consiste em uma abordagem do controle de atitude de satélite em três eixos através de uma *rede neural artificial* (RNA), treinada e empregada como controlador em malha fechada. O atual interesse pelos campos da *inteligência artificial* (IA) em diversas áreas do conhecimento e da indústria exige a investigação de suas vantagens e limitações diante de abordagens já estabelecidas. Neste contexto, foi projetado um sistema de controle de atitude baseado em técnicas e paradigmas de RNAs com o objetivo de identificar e analisar os resultados de sua implementação em comparação com uma abordagem bem conhecida para o problema de controle atitude. Os resultados foram obtidos a partir de simulações computacionais do movimento rotacional do satélite, considerado como corpo rígido e contendo rodas de reação como atuadores. A principal característica do sistema de controle proposto consiste na substituição da função do controlador por uma rede neural denominada *proportional derivative neural network* (PDNN). Além disso, foram simuladas e analisadas quatro estruturas variantes da rede PDNN. A saída da rede foi assumida como o vetor de torques comandados para o conjunto de rodas de reação. Com base na minimização da função custo que considerou o erro de atitude, foi implementado o algoritmo de *backpropagation* para atualizar os parâmetros da rede ao longo do processo de treinamento. Os resultados apresentados mostraram a capacidade da rede em lidar com o problema de controle de atitude para várias condições iniciais após um único treinamento offline. As comparações entre os desempenhos das variantes da rede PDNN e do controlador convencional *proporcional derivativo* (PD) ocorreram para diferentes condições de voo, sendo considerados os casos de falha em uma das rodas de reação e o caso de perturbação por torques externos instantâneos. Para ambas as situações críticas, foi observado um melhor desempenho da abordagem defendida neste trabalho, principalmente em relação ao requisito de rejeição de falhas.

Palavras-chave: Falhas em rodas de reação. Controle inteligente. Backpropagation. Treinamento *offline*. Julia language. Controlador PD.

ATTITUDE CONTROL: AN APPROACH THROUGH ARTIFICIAL NEURAL NETWORKS

ABSTRACT

This present work guides a satellite attitude control approach using a trainable *artificial neural network* (ANN) as a controller in the closed-loop. Our main motivation was to compare its performance with the conventional *proportional derivative* (PD) controller for some particular cases. Furthermore, account interest of *artificial intelligence* (AI) fields in many knowledge areas, becomes suitable to investigate the advantages and limitations of the proposed approach. We can simulate the attitude feedback data for the closed-loop attitude control system through the equations of motion for the rigid body dynamics and attitude propagation methods. The error of the current orientation of the body-fixed coordinate frame concerning the reference coordinate frame performs the ANN input signal. A general network architecture proposed, called *PD neural network* (PDNN), its composed for *proportional* (P) and *derivative* (D) neurons types. As a global result of each neuron process, the network output provides the commanded torques to a set of reaction wheels simulated as actuators. Based on minimizing the loss function that considers the attitude error, the *ackpropagation* algorithm updates the network weight parameters to perform a better control sequence of the attitude through to training. For the training process, we used the *machine learning* library, Flux. JI. Presented results showed the network's ability to solve the attitude control problem for several initial conditions after a single offline training. In addition, it was possible to compare the performance of the PDNN and the PD controller for different flight conditions. We have considered the case of failure in one of the reaction wheels and the case of disturbance by instantaneous external torques. For both critical situations, we observed better performance of the PDNN.

Keywords: Reaction wheels. Intelligent Control. Backpropagation. Offline training. Julia language. PD controller.

LISTA DE FIGURAS

	<u>Pág.</u>
3.1 Diagrama de blocos que descreve o sistema de controle em malha fechada.	28
3.2 Diagrama que descreve o controlador para saída da RNA representada no sistema (<i>b</i>).	31
3.3 Diagrama que descreve o controlador para saída da RNA representada diretamente no sistema (<i>w</i>).	31
3.4 Diagrama de blocos que descreve o sistema de atuadores.	34
4.1 RNA com múltiplas camadas e arquitetura direta (<i>feedforward neural network</i>).	36
4.2 RNA de múltiplas camadas com arquitetura recorrente (<i>recurrent neural network</i> ou <i>feedback network</i>).	37
4.3 Estrutura do controlador PIDNN empregado no controle de sistema com atraso.	38
4.4 Estrutura geral de processamento de sinais através de um neurônio P na iteração (<i>k</i>).	39
4.5 Estrutura geral de processamento de sinais através de um neurônio D na iteração (<i>k</i>).	39
4.6 Estrutura geral da rede PDNN.	41
4.7 Estrutura geral da rede PDNN com a camada invisível.	44
4.8 Diagrama de blocos de uma rede com aprendizagem supervisionada, <i>supervised learning</i>	47
4.9 Diagrama de blocos de uma rede com aprendizagem auto-organizada, <i>unsupervised learning</i>	48
4.10 Diagrama de blocos de aprendizagem por reforço de um sistema adaptativo heurístico.	49
5.1 Diagrama para uma configuração entre os sistemas de coordenadas (<i>b</i>), (<i>i</i>) e as rodas de reação.	54
5.2 Estrutura da rede PDNN-33.	58
5.3 Estrutura da rede PDNN-63.	59
5.4 Estrutura da rede PDNN-34.	60
5.5 Estrutura da rede PDNN-64.	61
5.6 Resultados em termos dos ângulos de Euler para as variantes da rede PDNN e com condições iniciais do Caso 1.	63

5.7	Resultados em termos dos ângulos de Euler para as variantes da rede PD e com condições iniciais do Caso 1.	64
5.8	Resultados em termos do erro absoluto de atitude para as variantes da rede PDNN e com condições iniciais do Caso 1.	64
5.9	Resultados em termos dos torques líquidos para as variantes da rede PDNN e com condições iniciais do Caso 1.	65
5.10	Resultados em termos das velocidades angulares das rodas de reação para as variantes da rede PDNN e condições iniciais do Caso 1.	66
5.11	(a) Evolução da velocidade angular das rodas para condições iniciais do Caso 2, com falha na roda RW-2 e considerando o controlador PD. (b) Evolução da velocidade angular das rodas para condições iniciais do Caso 2, com falha na roda RW-2 e considerando como controlador a rede PDNN-64.	68
5.12	(a) Evolução dos torques líquidos para condições iniciais do Caso 2, com falha na roda RW-2 e considerando o controlador PD. (b) Evolução dos torques líquidos para condições iniciais do Caso 2, com falha na roda RW-2 e considerando como controlador a rede PDNN-64.	69
5.13	Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-1 e com condições iniciais do Caso 3.	71
5.14	Evolução da velocidade angular da roda RW-1 em uma situação de falha para diversas abordagens de controle e com condições iniciais do Caso 3.	72
5.15	Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-2 e com condições iniciais do Caso 3.	73
5.16	Evolução da velocidade angular da roda RW-2 em uma situação de falha para diversas abordagens de controle e com condições iniciais do Caso 3.	74
5.17	Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-3 e com condições iniciais do Caso 3.	75
5.18	Evolução da velocidade angular da roda RW-3 em uma situação de falha para diversas abordagens de controle e com condições iniciais do Caso 3.	76
5.19	Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-4 e com condições iniciais do Caso 3.	77
5.20	Evolução da velocidade angular da roda RW-4 em uma situação de falha para diversas abordagens de controle e com condições iniciais do Caso 3.	78

5.21	Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-1 e com condições iniciais do Caso 4.	80
5.22	Evolução da velocidade angular da roda RW-1 em uma situação de falha para diversas abordagens de controle e com condições iniciais do Caso 4.	81
5.23	Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-2 e com condições iniciais do Caso 4.	82
5.24	Evolução da velocidade angular da roda RW-2 em uma situação de falha para diversas abordagens de controle e com condições iniciais do Caso 4.	82
5.25	Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-3 e com condições iniciais do Caso 4.	83
5.26	Evolução da velocidade angular da roda RW-3 em uma situação de falha para diversas abordagens de controle e com condições iniciais do Caso 4.	84
5.27	Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-4 e com condições iniciais do Caso 4.	85
5.28	Evolução da velocidade angular da roda RW-4 em uma situação de falha para diversas abordagens de controle e com condições iniciais do Caso 4.	85
5.29	Comparação da evolução do erro absoluto de atitude entre a abordagem de controle através da rede PDNN-64 e o controlador PD, para uma situação de falha na roda de reação RW-1 e com condições iniciais do Caso 5.	87
5.30	Comparação da evolução das velocidades angulares das rodas de reação e ângulos de Euler entre a abordagem de controle através da rede PDNN-64 e o controlador PD, para uma situação de falha na roda de reação RW-1 e com condições iniciais do Caso 5.	88
5.31	Comparação da evolução do erro absoluto de atitude entre a abordagem de controle através da rede PDNN-64 e o controlador PD, para uma situação de falha na roda de reação RW-2 e com condições iniciais do Caso 5.	89
5.32	Comparação da evolução das velocidades angulares das rodas de reação e ângulos de Euler entre a abordagem de controle através da rede PDNN-64 e o controlador PD, para uma situação de falha na roda de reação RW-2 e com condições iniciais do Caso 5.	90

5.33	Comparação da evolução do erro absoluto de atitude entre a abordagem de controle através da rede PDNN-64 e o controlador PD, para uma situação de falha na roda de reação RW-3 e com condições iniciais do Caso 5.	91
5.34	Comparação da evolução das velocidades angulares das rodas de reação e ângulos de Euler entre a abordagem de controle através da rede PDNN-64 e o controlador PD, para uma situação de falha na roda de reação RW-3 e com condições iniciais do Caso 5.	92
5.35	Comparação da evolução do erro absoluto de atitude entre a abordagem de controle através da rede PDNN-64 e o controlador PD, para uma situação de falha na roda de reação RW-4 e com condições iniciais do Caso 5.	93
5.36	Comparação da evolução das velocidades angulares das rodas de reação e ângulos de Euler entre a abordagem de controle através da rede PDNN-64 e o controlador PD, para uma situação de falha na roda de reação RW-4 e com condições iniciais do Caso 5.	94
5.37	Comparação dos ângulos de Euler entre a abordagem de com a rede PDNN-64 e o controlador PD para falha na roda de reação RW-3 no instante de 1200 segundos, considerando as condições iniciais do Caso 5.	97
5.38	Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-1 e com condições de cruzeiro.	99
5.39	Evolução da velocidade angular da roda RW-1 em uma situação de falha para diversas abordagens de controle e com condições de cruzeiro.	100
5.40	Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-2 e com condições de cruzeiro.	101
5.41	Evolução da velocidade angular da roda RW-2 em uma situação de falha para diversas abordagens de controle e com condições de cruzeiro.	101
5.42	Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-3 e com condições de cruzeiro.	102
5.43	Evolução da velocidade angular da roda RW-3 em uma situação de falha para diversas abordagens de controle e com condições de cruzeiro.	103
5.44	Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-4 e com condições de cruzeiro.	104

5.45	Evolução da velocidade angular da roda RW-4 em uma situação de falha para diversas abordagens de controle e com condições de cruzeiro.	104
5.46	Comparação da evolução do erro de atitude entre os controladores PDNN-64 e PD para uma perturbação instantânea em 2000 segundos (Caso 6).	107
5.47	(a)Evolução das velocidades angulares das rodas de reação com o controle através da PDNN-64 para o caso com torque perturbativo (Caso 6). (b) Evolução das velocidades angulares das rodas de reação com o controle PD para o caso com torque perturbativo (Caso 6).	109
5.48	(a) Evolução dos torques líquidos fornecidos pelas rodas de reação com o controle através da rede PDNN-64 para o caso com torques perturbativos (Caso 6). (b) Evolução dos torques líquidos fornecidos pelas rodas de reação com o controle PD para o caso com torque perturbativo (Caso 6).	110
5.49	Comparação da evolução do erro de atitude entre os controladores para uma perturbação instantânea em condições de cruzeiro.	112
5.50	Comparação da evolução do erro de atitude entre os controladores para uma perturbação instantânea em condições de cruzeiro.	113
5.51	Comparação da evolução do erro de atitude entre os controladores para uma perturbação instantânea em condições de cruzeiro.	114

LISTA DE TABELAS

	<u>Pág.</u>
5.1 Condições iniciais da simulação de atitude.	56
5.2 Características da estrutura da rede PDNN-33.	58
5.3 Características da estrutura da rede PDNN-63.	59
5.4 Características da estrutura da rede PDNN-34.	60
5.5 Características da estrutura da rede PDNN-64.	61
5.6 Máximo erro absoluto de atitude após a falha em cada uma das rodas de reação entre as diversas abordagens e considerando as condições iniciais do Caso 3.	78
5.7 Erro absoluto de atitude médio após a falha em cada uma das rodas de reação entre as diversas abordagens e considerando as condições iniciais do Caso 3.	79
5.8 Máximo erro absoluto de atitude após a falha em cada uma das rodas de reação entre as diversas abordagens e considerando as condições iniciais do Caso 4.	86
5.9 Erro absoluto de atitude médio após a falha em cada uma das rodas de reação entre as diversas abordagens e considerando as condições iniciais do Caso 4.	86
5.10 Máximo erro absoluto de atitude após a falha da roda de reação entre a abordagem de controle através da rede PDNN-64 e o controlador PD, e considerando as condições iniciais do Caso 5.	95
5.11 Erro absoluto de atitude médio após a falha em cada uma das rodas de reação entre as diversas abordagens e considerando as condições iniciais do Caso 5.	95
5.12 Condições em regime de cruzeiro.	99
5.13 Máximo erro absoluto de atitude após a falha em cada uma das rodas de reação entre as diversas abordagens nas condições de cruzeiro.	105
5.14 Erro absoluto de atitude médio após a falha em cada uma das rodas de reação entre as diversas abordagens nas condições de cruzeiro.	106

LISTA DE ABREVIATURAS E SIGLAS

INPE	– Instituto Nacional de Pesquisas Espaciais
NASA	– <i>Aeronautics and Space Administration</i>
RNA	– Rede Neural Artificial
IA	– Inteligência Artificial
ADALINE	– <i>Adaptative Linear Element</i>
MADALINE	– <i>Many Adaptative Linear Element</i>
CMAC	– <i>Cerebellar Model Articulation Controller</i>
RBFNN	– <i>Radial Base Function Neural Network</i>
PD	– Proporcional Derivativo
MLP	– <i>Multilayer Perceptron</i>
PDNN	– <i>Proportional Derivative Neural Network</i>
PIDNN	– <i>Proportional Integral Derivative Neural Network</i>
PDNN-33	– PDNN com 3 elementos de entrada e 3 de saída.
PDNN-34	– PDNN com 3 elementos de entrada e 4 de saída.
PDNN-63	– PDNN com 6 elementos de entrada e 3 de saída.
PDNN-64	– PDNN com 6 elementos de entrada e 4 de saída.

LISTA DE SÍMBOLOS

\mathbf{I}_b	– Tensor de inércia do satélite
$\boldsymbol{\omega}_{b,b}$	– Vetor de velocidade angular do satélite
$\mathbf{h}_{w,b}$	– Vetor de momento angular do satélite
$\boldsymbol{\tau}_{dist,b}$	– Vetor de torque perturbativo
$\boldsymbol{\tau}_{net,b}$	– Vetor de torque líquido
$\boldsymbol{\tau}_{net,w}$	– Vetor de torque líquido representado no sistema (w)
$\mathbf{h}_{w,w}$	– Vetor de momento angular do satélite representado no sistema (w)
\mathbf{I}_w	– Tensor de inércia do para o conjunto de rodas de reação
$\boldsymbol{\omega}_{w,w}$	– Vetor de velocidade angular do satélite representado no sistema (w)
τ_{drag}	– Componente de torque devido ao atrito nas rodas de reação
τ_{com}	– Componente de torque comandado às rodas de reação
τ_{comp}	– Componente de torque de compensação
K_p	– Ganho proporcional
T_i	– Constante de tempo
e_w	– Ere entre a velocidade real e a velocidade desejada das rodas de reação.
$\bar{\omega}_w$	– Velocidade angular desejada para as rodas de reação
ω_w	– Velocidade angular real para as rodas de reação
$\mathbf{G}_{w,b}$	– Matriz de transformação de coordenadas entre os sistemas (w) e (b)
$\mathbf{G}_{b,w}$	– Pseudo-inversa da matriz $\mathbf{G}_{w,b}$
\mathbf{q}	– Quatérnio que representa a atitude do satélite em relação aos sistema inercial.
Ω	– 4×4 Matriz anti-simétrica das componentes de velocidade angular do satélite
\mathbf{x}	– Vetor de estado de atitude.
\mathbf{x}_{ref}	– Vetor de estado de atitude de referência
\mathbf{p}	– Vetor dos parâmetros modificados de Rodrigues
$x_m(k)$	– Vetor que armazena os sinais de saída de m elementos
$w_{mn}(k)$	– Peso da conexão entre o m -ésimo e n -ésimo elemento de camadas distintas
$u_n(k)$	– Vetor que armazena os sinais de entrada de n elementos
$x_n^P(k)$	– Vetor que armazena os sinais de saída n elementos do tipo proporcional
$x_n^D(k)$	– Vetor que armazena os sinais de saída n elementos do tipo derivativo
$\mathbf{x}_m^\Psi(k)$	– Vetor que armazena os sinais de saída m elementos da camada invisível
Ψ_{nm}	– Peso da conexão entre o m -ésimo elemento da camada intermediária e o n -ésimo elem
$\mathbf{u}_n^O(k)$	– Vetor que armazena os sinais de entrada de n elementos da camada de saída
Ψ	– Matriz $n \times m$
J	– Função custo
$e(k)$	– Função de perda
T	– Tempo simulado em cada <i>epoch</i>

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
2 REVISÃO BIBLIOGRÁFICA	7
3 CONTROLE DE ATITUDE DE SATÉLITES	17
3.1 Dinâmica de corpo rígido com rodas de reação acopladas	17
3.2 Representações de atitude	19
3.3 Propagação de atitude	26
3.4 Sistema de controle de atitude	28
3.4.1 Abordagem convencional	29
3.4.2 Abordagem através de RNA	30
3.5 Modelagem dos atuadores	32
4 REDES NEURAIS ARTIFICIAIS	35
4.1 Modelos de RNAs	35
4.2 <i>Proportional Derivative Neural Network (PDNN)</i>	38
4.2.1 Neurônios tipo P e D	38
4.2.2 Topologia da rede PDNN	40
4.2.2.1 Camada invisível	43
4.3 Métodos de aprendizagem de RNAs	46
4.3.1 Treinamento através do algoritmo de <i>backpropagation</i>	49
5 ANÁLISE E RESULTADOS	53
5.1 Definições do problema	53
5.2 Variantes da rede PDNN	56
5.2.1 PDNN-33	58
5.2.2 PDNN-63	59
5.2.3 PDNN-34	60
5.2.4 PDNN-64	61
5.3 Comparação entre os controladores	62
5.4 Comparação entre os controladores para falhas nas rodas de reação	67
5.5 Comparação entre os controladores para falhas nas rodas de reação em condições de cruzeiro	98

5.6	Comparação entre os controladores para perturbações de torque externo	106
5.7	Comparação entre os controladores para perturbações de torque externo instantâneo em condições de cruzeiro	111
6	CONCLUSÕES	115
	REFERÊNCIAS BIBLIOGRÁFICAS	119

1 INTRODUÇÃO

O conceito de *inteligência artificial* (IA) não possui uma definição única na literatura e do ponto de vista de engenharia pode ser entendido como um conjunto de paradigmas ou algoritmos que permitem uma máquina emular tarefas desempenhadas pelo cérebro humano. De acordo com Haykin (2010), um sistema que possui IA deve contemplar três características básicas: (1) capacidade de armazenar aprendizado, (2) aplicação do conhecimento armazenado para solução de problemas e (3) aquisição de novos conhecimentos através de experiências.

A abordagem da IA dita de *baixo nível* é fundamentada em modelos biológicos do ponto de vista microscópico, dos quais fazem parte os modelos de rede neurais artificiais (RNAs) e algoritmos genéticos (AGs) (MUNAKATA, 1994). As RNAs são uma nova geração de técnicas de processamento de informação que fazem uso de certos princípios organizacionais similares aos existentes na estrutura do cérebro, que viabilizam a aprendizagem, recordação e generalização a partir de padrões ou dados armazenados (LIN et al., 1996). De acordo com Leondes (2000), as principais características que tornam as abordagens através das RNAs vantajosas em problemas práticos da engenharia são:

- Não-linearidade: uma RNA é capaz de mapear sinais de entradas em saídas de forma que suas relações não sejam lineares;
- Aprendizagem: as RNAs podem aprender através de um processo de treinamento a partir de interações com o ambiente, não sendo necessário assim reprogramar recorrentemente a rede para novas situações;
- Mapeamento complexo: as RNAs têm a capacidade de sintetizar ou aproximar mapeamentos complexos que podem ser muito difíceis ou mesmo impossíveis de serem expressos analiticamente;
- Generalização: como consequência da capacidade de aprendizagem, as RNAs podem lidar com novas situações que não foram experimentadas antes;
- Velocidade no processamento: devido à capacidade de processamento em paralelo das RNAs, após o treinamento, é possível realizar o mapeamento entrada/saída mais rápido do que muitos dos métodos convencionais;
- Robustez e tolerância a falhas: mesmo para dados de entrada incompletos

ou corrompidos por ruído, as RNAs podem fornecer resultados satisfatórios;

- Implementação em *very large scale integrated* (VLSI): a natureza massivamente paralela de uma RNA se torna interessante para aplicação em sistemas integrados.

O mesmo autor também descreve as principais desvantagens das RNAs, sendo elas:

- Comportamento de “caixa preta”: não há um consenso analítico bem definido para entender ou modificar o processo de tomada de decisão na construção das redes;
- Longo tempo de treinamento: quanto maior o tamanho da RNA e mais complexo o mapeamento a ser realizado, maior é o tempo de treinamento requerido;
- Estrutura da rede: a seleção do número de camadas e número de neurônios em cada camada não é uma tarefa trivial. Na prática, é um processo de tentativa e erro.

No contexto do controle de sistemas dinâmicos, a estrutura e as conseqüentes ações de um controlador são determinadas em resposta ao comportamento observado entre a entrada e a saída da planta, com referência mínima a um modelo matemático que a descreve (HARRIS et al., 1994). Sem perda de generalidade, tal característica pode ser extrapolada ao treinamento de RNAs, uma vez que esse processo consiste em uma série de repetições de pares entrada/saída com o objetivo de levar um estado do sistema até outro estado desejado, através do ajuste de pesos dos parâmetros das funções que compõem a RNA. Portanto, existe uma forte conexão entre o treinamento das RNAs e a teoria de controle adaptativo (ÅSTRÖM, 1991). O campo do *controle inteligente* é uma combinação das técnicas da IA, tais como as RNAs, juntamente com as técnicas da teoria de controle (WHITE; SOFGE, 1992), sendo esse termo difundido principalmente a partir dos anos de 1990. Atualmente, o *controle inteligente* oferece um grande potencial de desenvolvimento para áreas estratégicas do setor aeroespacial, fato evidenciado pela crescente produção acadêmica e interesse da indústria moderna pelo tema.

Embora o uso da teoria de controle clássico e moderno sejam abrangentes e de resultados satisfatórios nas aplicações em engenharia, o processo de projetar um sistema

de controle através dos diversos métodos encontrados nessas teorias possui algumas dificuldades práticas. Uma vez obtidos os modelos que descrevem a dinâmica da planta, sensores e atuadores, a etapa seguinte do projeto de um sistema de controle de atitude consiste na obtenção de um modelo matemático que descreve o controlador e que satisfaz em malha fechada os requisitos de operação em voo. Ou seja, o controlador é a solução matemática para o problema de projeto de um sistema de controle (OGATA, 1992).

Ainda segundo (OGATA, 1992), o projeto de um sistema de controle através de abordagens convencionais envolve um processo de tentativa e erro, já que muitas vezes o desempenho esperado para o controlador não é obtido logo após ser concebido pelos métodos convencionais. Neste caso, o projetista deve reajustar os parâmetros do sistema de controle preliminar até que os requisitos sejam satisfeitos. As principais técnicas que permitem o projeto e o reajuste dos sistemas de controles estão fundamentadas na teoria de controle clássico, na qual o controlador está relacionado diretamente com a obtenção da função de transferência do sistema. Já à luz da teoria do controle moderno, a obtenção de um controlador ótimo está relacionada com a escolha de um índice de desempenho apropriado, o qual deve ser minimizado pelas ações de controle. Em ambos os casos, as técnicas mais conhecidas são limitadas aos sistemas invariantes no tempo, lineares com entrada e saída simples.

Do ponto de vista do sistema controle de atitude, a função de transferência do controlador pode ser obtida pela relação entre o torque de controle e o erro de atitude (WERTZ, 1978). Sendo assim, quaisquer mudanças na dinâmica do satélite que alterem tal relação durante a fase de projeto implicam na necessidade de reprojeter os parâmetros do controlador. Portanto, um novo modelo matemático para o controlador deve ser obtido e testado.

Diante deste contexto, se torna relevante a hipótese de que a função que descreve o controlador pode ser obtida através de um processo de treinamento, considerando os estados do sistema de controle em malha fechada no qual o controlador seja descrito por uma RNA. Sendo assim, as características do sistema de controle podem ser alteradas sem a necessidade de recorrer aos exaustivos métodos analíticos ou numéricos para obter uma nova lei de controle. Em tais casos, pode-se apenas executar o treinamento da rede para as novas condições.

Ainda, as características das RNAs de não-linearidade, adaptação e tolerância à falhas reforçam a necessidade de se investigar suas potenciais aplicações para sistemas de controle que atuam em casos críticos de voo, como em manobras de estabilização

após o descarte de carga útil, correção orbital com propulsores ou ainda acoplamento com alvos não cooperativos, entre outras. Também, em situações de falhas em atuadores e sensores, nas quais os sistemas de controle convencionais podem atuar de forma limitada. Outra vantagem da abordagem com RNAs encontra-se na sua possibilidade de implementação em projetos de sistemas de controle para satélites de grande ou pequeno porte. Ou seja, uma mesma RNA pode ser treinada e implementada para diversas condições de voo e configurações de satélites.

O objetivo central deste trabalho foi desenvolver através de simulações um controlador de atitude baseado em técnicas e modelos de RNAs de modo que substitua a função do controlador em um sistema de controle de malha fechada convencional. Desta forma, projetar um sistema de controle que não dependa dos processos tradicionais de determinação dos parâmetros do controlador (*controller tuning*). Para alcançar este objetivo, o presente trabalho partiu de uma revisão bibliográfica que buscou contextualizar o surgimento, desenvolvimento e as atuais fronteiras do conhecimento acerca das RNAs e suas aplicações em problemas de controle. Em seguida, foram adotados os métodos necessários para a simular o modelo dinâmico e cinemático de um satélite que contém rodas de reação como atuadores, bem como as técnicas de propagação de atitude. Além disso, foram investigadas algumas estruturas e propriedades de RNAs, as quais puderam fundamentar a construção de uma rede neural destinada ao controle de atitude, sendo tal rede denominada *proportional derivative neural network (PDNN)*. O treinamento da PDNN ocorreu através do algoritmo de *backpropagation*, com base no índice de desempenho em função do erro de atitude. Por fim, com a rede treinada, foi possível obter um conjunto de resultados que possibilitaram uma análise do controle de atitude do satélite para diversas condições. Para efeito de comparação, foi considerado o desempenho do controlador proposto em relação ao controlador *proporcional derivativo (PD)*, sintonizado por métodos convencionais para os mesmos requisitos. A conclusão do trabalho foi baseada nos resultados observados para certos casos críticos, sendo identificado um melhor desempenho da abordagem através da rede PDNN em comparação com o método convencional de controle de atitude. Por fim, temas de investigação para trabalhos futuros foram discutidos com bases nos resultados observados.

A organização dos assuntos tratados em cada capítulo ocorreu da seguinte maneira:

- Capítulo 2: revisão da literatura e contextualização histórica de importantes trabalhos publicados no campo da inteligência artificial, redes neurais artificiais, controle inteligente e suas aplicações na área de controle de ati-

tude.

- Capítulo 3: dedicado aos métodos que permitiram a simulação da dinâmica do satélite e da malha do sistema de controle de atitude. Na Seção 3.1, foram apresentadas as equações dinâmicas de corpo rígido utilizadas. A Seção 3.2 contém um resumo dos principais métodos utilizados na representação de atitude. A Seção 3.3 abordou o processo de obtenção das equações cinemáticas para propagação de atitude simulada. Já na Seção 3.4, descreveu os elementos da malha de controle utilizada nas simulações.
- Capítulo 4: abordou os principais métodos envolvidos na implementação e treinamento da rede PDNN proposta. A Seção 4.1 e Seção 4.2 consistiram em uma síntese das principais propriedades e estruturas de RNAs e a descrição geral da rede PDNN, respectivamente. Na Seção 4.3 são apresentados os principais paradigmas de aprendizagem e o processo de treinamento adotado na presente abordagem.
- Capítulo 5: apresentação dos resultados e discussões de casos especiais considerados. A Seção 5.1 apresentou as considerações acerca dos modelos adotados. Na Seção 5.2 se encontram a descrição das variantes da rede PDNN e seus diferentes resultados. Na Seção 5.3, foi apresentado a comparação entre a abordagem de controle através da rede PDNN e o controlador PD. Em seguida, na Seção 5.4, os controladores foram comparados para o caso de falha em uma das rodas de reação que ocorreu após a estabilização a partir de uma condição de atitude arbitrária. Na Seção 5.5 os controladores foram novamente comparados para o caso de falha em uma das rodas nas condições de cruzeiro, permitindo uma melhor comparação entre os desempenhos de cada abordagem. Finalmente, na Seção 5.6 e Seção 5.7 se encontram os resultados comparativos entre rede PDNN e do PD para os casos com perturbações de torques externos instantâneos.
- Capítulo 5: foram levantadas e discutidas as principais conclusões dos resultados observados e por fim, apresentou novas hipóteses a serem investigadas em trabalhos futuros.

2 REVISÃO BIBLIOGRÁFICA

O alvorecer do termo *inteligência artificial* (IA) nos meios acadêmicos ocorreu durante a conferência patrocinada pela Fundação Rockefeller na Universidade de Dartmouth em 1956 (*Dartmouth Summer Research Conference*), de acordo com Tsoukalas e Uhrig (1996). Essa conferência teve como escopo o debate e divulgação do potencial uso de computadores na realização de tarefas gerais através de processos que emulassem os mecanismos presentes no funcionamento do cérebro humano. A conferência foi organizada por pesquisadores de diversas áreas, os quais nos anos seguintes se destacaram nos diversos ramos da IA, entre eles: Marvin Minsky (aprendizagem de máquina), John McCarthy (linguagem simbólica), Nathaniel Rochester (sistemas neurais) e Claude Shannon (teoria da informação). No entanto, importantes conceitos acerca das redes neurais artificiais (RNAs) e outros temas relacionados à IA já haviam sido difundidos anos antes. Como ponto de partida, citamos o trabalho seminal de McCulloch e Pitts (1943), que à luz da lógica proposicional, formalizou matematicamente a modelagem das atividades e eventos neurais, bem como seus elementos básicos.

Já a obra de Wiener (1948) pode ser considerada a precursora da aplicação das RNAs nas áreas de controle, processamento de sinais e comunicações. Em sua obra, Robert Wiener abordou a natureza e transmissão da informação neural sob aspectos estatísticos e também da recém difundida teoria de controle clássico. Além disso, o autor vislumbrou a correspondência entre a mecânica estatística e os processos neurais, a qual foi observada e formalizada somente três décadas depois por John Hopfield.

No ano seguinte, Hebb (1949) propôs pela primeira vez um algoritmo de aprendizagem baseado no fato de que a conectividade entre os elementos neurais do cérebro são modificados constantemente na medida em que o organismo aprende diferentes tarefas. Portanto, uma conexão neural é reforçada cada vez que é estimulada. O algoritmo de aprendizagem proposto por Donald Hebb consistia então em incrementar os valores atribuídos entre as conexões neurais de pares entrada/saída, sempre quando a saída observada tivesse valor próximo ao da saída desejada. No mesmo ano, Marvin Minsky iniciou a tentativa de construir fisicamente uma RNA. Denominado SNARC, sigla em inglês para *Stochastic Neuro-Analog Reinforcement Computer*, consistia em um dispositivo com cerca de 40 elementos eletromecânicos com a finalidade de resolver simples tarefas lógicas, sendo o treinamento realizado a partir da regra de aprendizagem proposta por Hebb. O computador de Minsky foi

finalizado em 1951, sendo considerado um grande feito dado os recursos tecnológicos da época. Outros resultados obtidos a partir do desenvolvimento do SNARC foram publicados em [Minsky \(1952\)](#) e [Minsky \(1954\)](#). Na sequência, não podemos deixar de citar a obra de [Ashby \(1952\)](#), que se ocupou em explicar a origem do comportamento adaptativo do sistema nervoso a partir de uma hipótese mecanicista, a qual presumia que a capacidade de adaptação não é inata ao sistema, mas aprendida. Enfatizando o caráter dinâmico de um organismo vivo, visto como uma máquina.

Um grande salto no desenvolvimento da IA dado logo após a conferência de Dartmouth se deu através do trabalho de [Rosenblatt \(1958\)](#). Seu trabalho se baseou no modelo neural de McCulloch e Pitts, e também no algoritmo de aprendizagem de Hebb para criar um modelo do processo neural de reconhecimento de padrões, similar ao encontrado no funcionamento da retina. Esse modelo ficou conhecido como *perceptron*, sendo definido como uma rede de camada única com fluxo direto de informação (*feedforward network*), sem a presença de sinais de retro-alimentação (*feedback*) e sem conexões entre neurônios da mesma camada. Em seguida, [Rosenblatt \(1960\)](#) estudou redes com a presença de duas e três camadas de *perceptrons*. Para o primeiro caso, o autor obteve a convergência dos parâmetros do algoritmo usado no processo de aprendizagem, sendo esse resultado conhecido como *teorema de convergência do perceptron*. A prova para esse teorema também foi abordada mais tarde por [Singleton \(1962\)](#) e [Novikoff \(1963\)](#). No entanto, para o segundo caso estudado por Rosenblatt, com três ou mais camadas de perceptrons, não foi possível encontrar à época a convergência para os parâmetros do algoritmo de aprendizagem. Esse problema foi denominado de *credit assignment problem*, sendo definitivamente solucionado somente na década de 1980.

Outro importante resultado foi obtido por [Widrow e Hoff \(1960\)](#), que desenvolveram o conceito de *adaptive linear element* (ADALINE), consistindo em uma rede neural capaz de se adaptar aos sistemas na tentativa de minimizar o erro, através do método *Least-Mean-Square* (LMS) ou *Delta Rule*, atuando como um filtro para ordenar a entrada em duas categorias. Sua diferença para o *perceptron* encontra-se principalmente na quantização da saída a partir de uma função não-linear, limitada no intervalo $[-1, +1]$. Também se diferencia no processo de aprendizagem, o qual leva em consideração o erro entre os valores de saída antes de serem mapeados pela função não-linear de quantização e após serem mapeados por essa função. Outro importante aspecto da rede ADALINE é que sua convergência é geralmente rápida. No entanto, a natureza aleatória da escolha dos pesos iniciais influencia diretamente o tempo de convergência e para certos valores de pesos não há convergência. Outra

restrição desse tipo de rede se encontra na sua limitação em classificar padrões que não são linearmente separáveis, embora em sua aplicação com múltiplas camadas, o sistema pode adquirir maior capacidade em contornar esse problema. A maior aplicação da rede ADALINE encontra-se em sistemas de redução adaptativa de ruído. Outras aplicações desse tipo de rede ainda são comuns em tecnologias atuais, tais como: arranjos adaptativos de antenas, reguladores sanguíneos adaptativos, filtros adaptativos, reconhecimento de padrões sísmicos, dispositivos acústicos de cancelamento de interferência, dispositivos de comunicação de longa distância e via satélite, etc. A generalização da rede ADALINE foi apresentada por Widrow (1962) e é conhecida como *many adaptive linear elements* (MADALINE). Consistem em redes com três camadas, sendo a camada interna composta por diversas redes do tipo ADALINE.

O primeiro neuro-controlador foi desenvolvido por Widrow e Smith (1964) para o problema de controle de um pêndulo invertido utilizando a rede ADALINE. O problema do pêndulo invertido sobre uma plataforma foi amplamente abordado em trabalhos desenvolvidos nas décadas posteriores como demonstrações da capacidade de aplicação das RNAs em problemas de controle. Outro trabalho importante de aplicação de RNAs na teoria de controle foi o de Waltz e Fu (1965), o qual descreveu de forma heurística um sistema de controle baseado na aprendizagem por reforço ou *reinforcement learning* (termo introduzido primeiramente por Minsky em 1954) para uma planta não-linear e não-estacionária com a única premissa de que o controlador e a planta possuíssem a mesma ordem. A obra de Nilsson (1965) se dedicou à classificação de padrões através de reconhecimento por máquinas. Seu trabalho contava com uma exposição detalhada sobre padrões de entradas linearmente separáveis. Além disso, abordou procedimentos e teoremas de treinamento, bem como a teoria de máquinas com camadas adaptativas. Em seguida, podemos destacar o trabalho de Minsky e Papert (1969) como um divisor de águas no que diz respeito ao desenvolvimento da IA. Considerado como um trabalho crítico aos conceitos formalizados por Rosenblatt, os autores desse trabalho buscaram identificar as limitações das redes de *perceptrons*, principalmente sob o argumento da falta de generalizações matemáticas que pudessem dar sustentação e permitir extrapolar a convergência para redes com maior número de camadas de *perceptrons*. O trabalho de Minsky e Papert é considerado na literatura como um dos fatores contribuintes para a chamada “década da dormência” das RNAs, disseminando certo pessimismo e desconfiança acerca dos resultados da convergência para algoritmos de aprendizagem. A “década da dormência” é o período conhecido pelo desinteresse dos meios acadêmicos no desenvolvimento de aplicações de RNAs em áreas da engenharia e

computação, ocorrido durante a década de 1970. Segundo a literatura, outro fator que contribuiu para esse período foi a limitação dos recursos computacionais da época nos centros de pesquisas e universidades, que ainda não contavam com a existência de computadores pessoais ou estações de trabalho dedicadas apenas à experimentos com RNAs.

Ainda em meados da década de 1960 e início da década de 1970, podemos encontrar as primeiras tentativas de introdução de técnicas de *controle inteligente* em atividades da engenharia aeroespacial, tais como o trabalho de [Smith et al. \(1964\)](#) que buscou fazer a síntese de um controlador de voo adaptativo, assumindo variações dos parâmetros da planta e dos requisitos de voo. Se baseando na estratégia de um sistema capaz de realizar exaustivos cálculos durante a fase de projeto para obter as condições de voo possíveis para em seguida realizar o armazenamento das soluções de maneira especial em um controlador com memória física. Já o relatório técnico fomentado pela *National Aeronautics and Space Administration* (NASA), realizado por [Mendel \(1966\)](#), reuniu uma detalhada base teórica para investigar a aplicabilidade das técnicas de IA em problemas de controle de veículos espaciais. Esse relatório foi dividido em duas partes, tendo a primeira parte se concentrado na busca de identificar o estado da arte do *design* de controle de veículos espaciais e suas potenciais abordagens com técnicas presentes na fronteira do conhecimento do *controle inteligente*, abordando duas estratégias de aprendizagem: (1) aprendizagem *online* e (2) aprendizagem *offline*. A segunda parte do relatório apresentou o *design* preliminar de um controlador de atitude fino em um eixo com aprendizagem *online*. Já o trabalho de [Gilbert e Saridis \(1970\)](#) aplicou métodos de aprendizagem no projeto de um controlador adaptativo para o problema regulador de combustível em propulsores, com o objetivo de minimizar os efeitos das perturbações aleatórias e parâmetros desconhecidos da planta.

Embora a divulgação dos estudos sobre RNAs durante a década de 1970 tenha sido modesta, certos trabalhos obtiveram importantes resultados que permitiram a sobrevivência do tema em diversas áreas da ciência, engenharia e computação, possibilitando assim o ressurgimento do interesse acadêmico sobre RNAs nas décadas seguintes. Nesse mesmo período podemos citar alguns trabalhos fundamentais no desenvolvimento do *controle inteligente*. Entre eles, o trabalho de [Fu \(1970\)](#), que tratou dos conceitos básicos do controle por aprendizagem, descrevendo cinco classes de técnicas: (1) sistemas de controle treináveis a partir de classificação de padrões, (2) sistemas de controle com aprendizagem por reforço, (3) estimação bayesiana, (4) aproximação estocástica e (5) modelos estocásticos automáticos. Além de

abordar suas potenciais aplicações em problemas de engenharia de controle. Na sequência, temos a introdução do conceito de mapeamento auto-organizável através de aprendizagem competitiva, realizada por [Malsburg \(1973\)](#). Também o trabalho de [Albus \(1975\)](#) que desenvolveu o conceito de *cerebellar model articulation controller* (CMAC), consistindo em um sistema adaptativo para controle de sistemas dinâmicos envolvendo vários graus de liberdade e que atuam simultaneamente. Baseado no mapeamento dos comandos de entrada e dos sinais de *feedback* em tabelas de memória, que associavam o vetor de entrada às saídas apropriadas. O CMAC foi inspirado principalmente no processo encontrado nos cerebros, que é a região do cérebro responsável pela coordenação e equilíbrio dos movimentos nos animais. Uma vantagem da aplicação da CMAC em problemas de controle se deve principalmente à sua velocidade, permitindo aplicações em sistemas de tempo real.

Já nos anos de 1980, podemos destacar o avanço nos métodos de treinamento, que contribuíram com um novo período de desenvolvimento do tema das RNAs. Destacamos o trabalho de [Rumelhart et al. \(1986\)](#), que resultou em um importante avanço para a implementação prática das redes neurais através do desenvolvimento do algoritmo de *backpropagation*. Uma poderosa técnica capaz de suprimir certas limitações encontradas na convergência dos algoritmos de aprendizagem das redes *perceptrons*. É importante ressaltar que o algoritmo de *backpropagation* foi desenvolvido anteriormente de forma independente por [Werbos \(1974\)](#) em seu trabalho de Ph.D na Universidade de Harvard. O sucesso desse algoritmo ainda repercute nos dias atuais, uma vez que está presente na grande maioria das aplicações reais de RNAs de forma direta ou indireta. Ainda no início da década de 1980, o trabalho de [Barto et al. \(1983\)](#) teve grande impacto na área de controle, especialmente sobre o tema de aprendizagem por reforço. Seu trabalho demonstrou que um sistema com esse tipo de aprendizagem foi capaz de equilibrar um pêndulo invertido na ausência de um sistema *teacher*(entidade principal da aprendizagem supervisionada), exigindo apenas um sinal de reforço que ocorre quando a haste do pêndulo ultrapassa um certo valor de ângulo crítico em relação à vertical, ou quando a plataforma móvel chega ao fim da pista. Esse resultado foi obtido usando apenas dois elementos neurais: *adaptive critic element* (ACE) e *associative search element* (ASE). Na sequência do desenvolvimento da aprendizagem por reforço, citamos o trabalho de [Barto e Anandan \(1985\)](#), que introduziu o algoritmo de aprendizagem chamado *associative reward-penalty* (A_{R-P}) para elementos adaptativos denominados *elementos* A_{R-P} . Esse algoritmo teve importantes aplicações em várias classes de problemas de aprendizagem por reforço. Sua generalização pode ser encontrada em [Barto e Jordan \(1987\)](#) e [Hertz et al. \(1991\)](#) com detalhada análise teórica dos elementos A_{R-P} .

Vemos na segunda metade da década de 1980 e no início da década de 1990 um crescimento considerável do interesse acadêmico e industrial acerca das técnicas de IA e suas aplicações práticas. Podemos citar alguns trabalhos que fazem parte dessa nova fase do *controle inteligente*. Entre eles, o trabalho realizado por [Handelman et al. \(1990\)](#), que comparou os paradigmas de programação do ponto de vista dos sistemas baseados em conhecimento (*knowledge-based systems*) e das RNAs, desenvolvendo uma metodologia para aplicar as duas abordagens ao problema de controle de um manipulador robótico com duas articulações. Em seu trabalho, o sistema baseado em conhecimento foi utilizado inicialmente para gerar movimentos baseados em regras pré-estabelecidas, que em seguida foram ensinados para a RNA do tipo CMAC. Em seguida, os autores avaliaram o desempenho do treinamento para diversos regimes de movimentos. [Kraft e Campagna \(1990\)](#) comparou um controlador baseado em RNA, similar à rede CMAC, com outros dois controladores adaptativos tradicionais: *self-tuning regulator* (STR) e *Lyapunov-based model reference adaptive controller* (MRAC). A comparação foi feita de acordo com a estabilidade em malha fechada, velocidade de adaptação, rejeição de ruído, número de iterações, desempenho e grau de desenvolvimento teórico. Os controladores foram simulados para três cenários distintos, que consideraram: um sistema linear sem ruído, um sistema linear com adição de ruído e um sistema não-linear. O trabalho conseguiu demonstrar a capacidade de aplicação de RNAs em problemas de controle lineares e não-lineares, bem como sua aplicabilidade em sistemas em grande escala. Nesse contexto, o trabalho de [White e Sofge \(1992\)](#) reuniu um conjunto de estudos, resultados e aplicações reais na área de *controle inteligente*, os quais foram obtidos ao longo de importantes conferências sobre o tema e realizadas entre os anos de 1990 e 1991 com patrocínio da *National Science Foundation* (NSF). Como consequência, sua obra reúne uma ampla bibliografia composta por trabalhos nas áreas de robótica, engenharia de sistemas e aeroespacial. Outras obras, entre livros e artigos acerca dos fundamentos e aplicações das RNAs em diversas áreas, foram publicadas nos meados da década de 1990, citamos algumas utilizadas como referências teóricas no presente trabalho: [Levine \(1991\)](#), [Simpson \(1992\)](#), [Kong e Kosko \(1992\)](#), [Peretto e Pierre \(1992\)](#), [Kung \(1993\)](#), [Haykin \(1994\)](#), [Lin et al. \(1996\)](#) e [Tsoukalas e Uhrig \(1996\)](#), entre outros.

No campo da engenharia e tecnologias espaciais, encontramos a partir da década de 1990 um crescente aumento do interesse nas aplicações das RNAs em problemas práticos. Em 1991, a NASA promoveu uma conferência (*NASA Automated Rendezvous and Capture Review*), que ocorreu na cidade de Williamsburg, no estado de Virgínia, e que contou com cerca de 120 participantes de instituições governamentais e indústrias, e também de universidades. Essa conferência teve como objetivo reunir

o estado da arte acerca do desenvolvimento de sistemas autônomos, especificamente para o problema de acoplamento de veículos espaciais. O debate da conferência foi dividido em cinco categorias, entre elas a categoria relacionada ao desenvolvimento de algoritmos e sistemas de softwares com abordagens das técnicas de IA para problemas de guiagem, controle e navegação.

Kumar et al. (1995) implementou duas técnicas de RNAs distintas para simular o controle de apontamento do eixo longitudinal da estação espacial *Freedom*, que foi um projeto criado na década de 1980 para uma estação espacial estadunidense e posteriormente abandonado, servindo de precursora da *International Space Station* (ISS). As simulações foram feitas para o controle de atitude através de atuadores do tipo *control moment gyros* (CGMs). A primeira técnica utilizou uma RNA do tipo *multi-layer perceptrons* (MLPs) para obter um controlador com aprendizagem *online*. A segunda técnica utilizou uma RNA do tipo *textitfeedforward* com camada única, treinada com o algoritmo de *backpropagation* modificado, permitindo estimar as variações de momento de inércia da planta, bem como os distúrbios externos. As estimativas foram usadas para resolver duas equações do tipo Riccati para obter os ganhos variáveis, os quais melhoraram o desempenho do sistema no decorrer de sucessivas órbitas. Outro trabalho importante acerca do tema de controle de atitude de satélites foi desenvolvido por Carrara (1997), que buscou validar o uso de RNAs para esse tipo de problema. Seu trabalho considerou o satélite como um corpo rígido com articulações, que incrementaram as características não-linear da planta. A rede MLP usada atuou primeiramente de forma à obter o modelo dinâmico de forma inversa a partir do treinamento com sinal de *feedback* do erro. Em seguida, foi validado o problema de controle a partir da variação dos parâmetros do satélite. Os resultados mostraram a robustez e a capacidade de compensação da estratégia de controle proposta através de RNAs.

Já nos anos de 2000, Sadati et al. (2002) desenvolveram uma nova estratégia na abordagem do controle ótimo multivariável para o problema de atitude de satélites baseada na implementação de uma RNA do tipo *Radial Basis Function Neural Network* (RBFNN), juntamente com o controlador PD para estabilização inicial do corpo. A dinâmica foi simulada considerando quatro rodas de reação e a representação cinemática da atitude foi realizada através de quatérnios. Os autores puderam mostrar a capacidade do neuro-controlador ser treinado de forma *online* com técnicas de aprendizagem adaptativa. Ainda, puderam demonstrar a robustez, acurácia e velocidade de resposta do neuro-controlador através de diversos exemplos. O trabalho de Sivaprakash e Shanmugam (2005) abordou uma estratégia de controle de

atitude através de um neuro-controlador para estabilizar um micro-satélite em três eixos utilizando bobinas magnéticas como atuadores. O neuro-controlador proposto foi treinado pelo método de *backpropagation* com os dados fornecidos por um PD de ganhos constantes através de uma aprendizagem supervisionada. Após ser simulado para diversas condições iniciais e diferentes configurações de momento de inércia, o trabalho pôde demonstrar a capacidade de controlar a atitude em três eixos utilizando RNAs. No mesmo contexto de problemas de controle de atitude de satélites, [Hu e Xiao \(2012\)](#) utilizaram em conjunto com um controlador PD, uma RNA do tipo RBFNN como compensador de avanço de fase na malha de controle para apontamento de um satélite de corpo flexível. A compensação através da RNA teve como objetivo reduzir os efeitos não-lineares provenientes da saturação da entrada do sistema. Os resultados mostraram que dadas quaisquer restrições às condições iniciais, foi possível projetar um controle com ganhos elevados o suficiente para tornarem o sistema semi-globalmente estável. No trabalho de [Ajorkar et al. \(2014\)](#) foi proposto um algoritmo de controle adaptativo para o problema de atitude de um satélite com quatro rodas de reação, sendo consideradas as incertezas e perturbações sobre os parâmetros do tensor de momento de inércia do corpo do satélite. Tais parâmetros puderam ser estimados através de uma RNA com múltiplas camadas e treinada pelo algoritmo de *backpropagation*, sendo usados em seguida para linearização do sinal de *feedback* da lei de controle. Os autores desse trabalho ainda realizaram uma análise de desempenho do controlador proposto para diversos casos.

Neste ponto, torna-se relevante ressaltar que embora o tema central do presente trabalho tenha sido a aplicação das RNAs ao problema de controle de atitude de satélite, outra importante técnica de IA desenvolvida por Lotfali Askar-Zadeh em 1965 e conhecida como lógica *fuzzy* ou lógica nebulosa, tem sido recorrentemente utilizada no projeto de sistemas de aprendizagem e controle inteligente. O trabalho de [Rubaii e Young \(2011\)](#), por exemplo, utilizou técnicas da lógica nebulosa em conjunto com técnicas de RNAs para desenvolvimento de filtro de Kalman em um sistema de controle de velocidade e posição de rotores com aprendizagem online. Já o trabalho de [Wen e Wang \(2015\)](#) utilizou a lógica nebulosa em conjunto com as RNAs para melhorar o desempenho de um controlador PID para o problema de controle de atitude de satélites.

A ideia principal da lógica nebulosa é que grande parte da imprecisão associada ao processo de aprendizagem está ligada à falta de clareza (indefinição) e não à aleatoriedade de dados. Ao contrário de outros sistemas baseados em conhecimento, tais como as RNAs, que produzem comportamento inteligente ao representar uma

estrutura paralela de mapeamento entrada/saída baseada em um grande número de dados experimentado. Sendo assim, o presente trabalho tem como interesse principal o segundo caso, em que o mapeamento entrada/saída a ser realizado pelo sistema inteligente não tenha restrições de aprendizagem, interessando apenas o valor do apontamento final do satélite. No entanto, não se pode perder de vista as possibilidades oferecidas pela lógica nebulosa na melhoraria da abordagem proposta

Considerando ainda o problema de estabilização de um satélite após a captura de alvo não cooperativo em órbita, o trabalho de [Ma et al. \(2018\)](#) propôs a construção de uma RNA capaz de fornecer valores de torques discretos de controle para tal tarefa. A rede proposta foi treinada através de um algoritmo de aprendizagem por reforço (*Q Network*) em um cenário construído para simulação dinâmica. Os resultados mostraram que a estratégia proposta foi capaz de estabilizar o satélite em contraste com o resultado para a simulação com PD clássico, que não pôde estabilizar o sistema devido à dependência dos valores de ganhos da lei de controle com os parâmetros de massa. Recentemente, [Shakhovska et al. \(2019\)](#) também propôs o uso de neuro-controladores para o problema de atitude de satélites. Duas configurações distintas foram abordadas, sendo a primeira composta por uma RNA *feedforward* com treinamento através do método do *gradiente descendente em mini-lotes* e a segunda abordagem foi realizada através de uma rede neural de Elman modificada. Os autores puderam ainda comparar as duas abordagens através de diversas simulações para diferentes configurações de atuadores. Como complemento, buscaram relacionar a estabilidade do sistema com os critérios de escolha dos pesos das conexões entre as camadas das redes propostas. [Ghorbanpour e Sohrab \(2019\)](#) abordou o problema de estabilização de um satélite em três eixos para o caso de otimização com tempo final fixo, utilizando propulsores com intervalos de acionamento discretos no tempo. Buscou também estender a solução ótima para um domínio específico de interesse através de uma RNA para aproximar a função de índice de desempenho, sendo o método de treinamento feito de forma *online* para encontrar os pesos ideais das funções básicas que compõem a RNA. Em seguida, as funções obtidas foram usadas para gerar o chaveamento ótimo dos propulsores. Os autores puderam mostrar que a estratégia de controle é viável para aplicação em unidades de controle de atitude de micro satélites.

3 CONTROLE DE ATITUDE DE SATÉLITES

Neste capítulo são apresentados os métodos e modelos utilizados para simular um sistema controle de atitude de um satélite que possui rodas de reação como atuadores. Na Seção 3.1, foram apresentadas as equações dinâmicas de corpo rígido utilizadas. A Seção 3.2 contém um resumo dos principais métodos utilizados na representação de atitude. A Seção 3.3 abordou o processo de obtenção das equações cinemáticas para propagação de atitude simulada. Já na Seção 3.4, descreveu os elementos da malha de controle utilizada nas simulações.

3.1 Dinâmica de corpo rígido com rodas de reação acopladas

No presente trabalho, o movimento de atitude de um satélite que contém rodas de reação como atuadores foi descrito através das equações do movimento rotacional de um corpo rígido.

Dado um sistema de coordenadas fixo no corpo, denotado por (b) , com origem no centro de massa do satélite e com eixos x , y e z alinhados aos eixos de simetria do corpo. Seja ainda considerado um sistema formado pelos eixos de rotação das rodas de reação acopladas ao corpo, denotado por (w) , o momento angular total do conjunto descrito pode ser escrito como:

$$\mathbf{h} = \mathbf{h}_b + \mathbf{h}_w, \quad (3.1)$$

em que \mathbf{h}_b é o vetor momento angular do sistema (b) e \mathbf{h}_w é o vetor momento angular das contribuições das rodas de reação em relação ao centro de massa do satélite. Neste caso, é considerado que centro de massa do conjunto formado pelas rodas é coincidente com o centro de massa do corpo (HUGHES, 2012).

A derivada temporal do momento angular total do sistema em relação a um sistema inercial, denotado por (i) , pode ser escrito como (BEER; JOHNSTON, 2003):

$$\left(\frac{d\mathbf{h}}{dt} \right)_{(i)} = \frac{d\mathbf{h}}{dt} + \boldsymbol{\omega}_b \times \mathbf{h}, \quad (3.2)$$

na qual o termo derivativo do lado direito é a taxa de variação do vetor \mathbf{h} com relação ao sistema (b) e $\boldsymbol{\omega}_b$ é o vetor de velocidade angular do sistema (b) em relação aos sistema (i) . (WERTZ, 1978)

Da segunda lei de Newton para o movimento rotacional, pode-se escrever:

$$\left(\frac{d\mathbf{h}}{dt}\right)_{(i)} = \sum_{i=1}^n \mathbf{N}_i, \quad (3.3)$$

em que \mathbf{N}_i são vetores de torque individuais aplicados em relação ao seu centro de massa do satélite. Tais torques são provenientes de duas naturezas diferentes. De acordo com [Wertz \(1978\)](#), podem ser definidos como: (1) Toques perturbativos causados pelo ambiente e (2) Torques de controle.

Substituindo a Equação (3.3) na Equação (3.2), tem-se:

$$\sum_{i=1}^n \mathbf{N}_i = \frac{d\mathbf{h}}{dt} - \boldsymbol{\omega}_b \times \mathbf{h} \quad (3.4)$$

Seja assumido por enquanto que a soma dos torques externos seja nula, então:

$$\frac{d\mathbf{h}}{dt} = -\boldsymbol{\omega}_b \times \mathbf{h}. \quad (3.5)$$

Substituindo a Equação (3.1) na Equação (3.5), finalmente tem-se:

$$\frac{d\mathbf{h}_b}{dt} + \frac{d\mathbf{h}_w}{dt} = -\boldsymbol{\omega}_b \times (\mathbf{h}_b + \mathbf{h}_w). \quad (3.6)$$

O vetor \mathbf{h}_b pode ser escrito como:

$$\mathbf{h}_b = \mathbf{I}_b \boldsymbol{\omega}_b, \quad (3.7)$$

em que \mathbf{I}_b é o tensor de inércia do satélite, que considera o momento de inércia das rodas de reação. Considerando ainda que \mathbf{I}_b é invariante no tempo, pode-se reescrever a Equação (3.6) como:

$$\mathbf{I}_b \frac{d\boldsymbol{\omega}_b}{dt} = -\boldsymbol{\omega}_b \times (\mathbf{I}_b \boldsymbol{\omega}_b + \mathbf{h}_w) - \frac{d\mathbf{h}_w}{dt}. \quad (3.8)$$

O termo $d\mathbf{h}_w/dt$ tem como significado físico o torque líquido aplicado pelo corpo nas rodas de reação ([WERTZ, 1978](#)). Pela terceira lei de Newton, pode-se obter torque

líquido aplicado pelas rodas ao corpo do satélite invertendo o seu sinal. Este novo termo foi denotado por $\boldsymbol{\tau}_{net}$ e pode-se reescrever a última equação como:

$$I_b \dot{\boldsymbol{\omega}}_b = \boldsymbol{\tau}_{net} - \boldsymbol{\omega}_b \times (I_b \boldsymbol{\omega}_b + \mathbf{h}_w). \quad (3.9)$$

Voltando a considerar os torques de perturbação provocados por forças externas e denotando agora por $\boldsymbol{\tau}_{dist}$, pode-se escrever de forma mais completa o movimento do sistema (b) em relação ao sistema inercial como:

$$\dot{\boldsymbol{\omega}}_b = I_b^{-1} [\boldsymbol{\tau}_{net} - \boldsymbol{\omega}_b \times (I_b \boldsymbol{\omega}_b + \mathbf{h}_w) + \boldsymbol{\tau}_{dist}], \quad (3.10)$$

A integração numérica da Equação (3.10) permite simular computacionalmente a dinâmica do problema de atitude. Com o estado $\boldsymbol{\omega}_b$ obtido neste processo, pode-se propagar a atitude do corpo ao longo do tempo a fim de simular os dados de orientação obtidos pelos sensores de atitude e que definem as ações de controle a serem realizadas. A seguir, são introduzidos alguns conceitos acerca da representação e propagação de atitude.

3.2 Representações de atitude

Entre as representações de atitude em três eixos mais comuns estão: (1) Matrizes de cossenos diretores (*Direction Cosine Matrix*, DCMs), (2) Ângulos/Eixo de Euler, (3) Ângulos de Euler, (4) Parâmetros simétricos de Euler (Quatérnios), (5) Parâmetros modificados de Rodrigues. Todos estes métodos podem ser encontrados com maior detalhamento nos trabalhos de [Wertz \(1978\)](#), [Shuster et al. \(1993\)](#) e [Hughes \(2012\)](#).

Sejam dois sistemas definidos por duas bases ortonormais do espaço \mathbb{R}^3 , dadas por $\mathbf{B} = \{\hat{\mathbf{b}}_1, \hat{\mathbf{b}}_2, \hat{\mathbf{b}}_3\}$ e $\mathbf{B}' = \{\hat{\mathbf{b}}'_1, \hat{\mathbf{b}}'_2, \hat{\mathbf{b}}'_3\}$. Então, um vetor qualquer \mathbf{v} pode ser representado em cada base respectivamente como:

$$\mathbf{v} = v_1 \hat{\mathbf{b}}_1 + v_2 \hat{\mathbf{b}}_2 + v_3 \hat{\mathbf{b}}_3, \quad (3.11)$$

e

$$\mathbf{v}' = v'_1 \hat{\mathbf{b}}'_1 + v'_2 \hat{\mathbf{b}}'_2 + v'_3 \hat{\mathbf{b}}'_3. \quad (3.12)$$

A forma mais básica para representação de atitude é dada através da matriz de rotação ou matriz de cossenos diretores (*Direction Cosine Matrix, DCM*). Tal representação consiste na transformação de coordenadas que mapeia um vetor representado em um sistema de referência em outro sistema desejado. Por exemplo, uma transformação entre sistema inercial e sistema fixo no corpo do satélite.

Seja uma matriz de rotação \mathbf{R} que mapeia as coordenadas do vetor \mathbf{v} , representado na base \mathbf{B} , em um vetor \mathbf{v}' , representado na base \mathbf{B}' . Então, pode-se escrever:

$$\mathbf{v}' = \mathbf{R}\mathbf{v}. \quad (3.13)$$

Devido à característica especial de ortogonalidade da matriz \mathbf{R} , discutida em Shuster et al. (1993) e Chagas (2019), pode ser mostrado que existe um eixo ao longo da direção denotada por $\hat{\mathbf{e}}$, que é igualmente representado nas duas bases, ou seja, é invariante durante a transformação de coordenadas entre os sistemas. Além disso, esse eixo possui a direção dos autovetores da matriz de rotação associados ao autovalor 1. Portanto, existe um $\hat{\mathbf{e}}$ tal que:

$$\hat{\mathbf{e}} = \hat{\mathbf{e}}' = \mathbf{R}\hat{\mathbf{e}}. \quad (3.14)$$

A Equação (3.14) descreve o chamado eixo de Euler, o qual mostrou que dois sistemas de referência podem ser relacionados por uma rotação de um ângulo Φ (ângulo de Euler) em torno desse eixo. O ângulo de Euler pode ser obtido pela expressão:

$$\cos \Phi = \frac{1}{2}[\text{tr}(\mathbf{R}) - 1]. \quad (3.15)$$

A Equação (3.15) possui duas soluções para Φ , evidenciando que existem duas possibilidades de rotação em torno da direção do eixo de Euler para representar a transformação entre dois sistemas de referência. Tal representação de atitude é conhecida como eixo/ângulo de Euler.

Pode-se escrever de maneira geral a relação entre a matriz de rotação \mathbf{R} e a representação eixo/ângulo de Euler como:

$$\mathbf{R}(\hat{\mathbf{e}}, \Phi) = \begin{pmatrix} \cos \Phi + e_1^2(1 - \cos \Phi) & e_1 e_2(1 - \cos \Phi) + e_3 \sin \Phi & e_1 e_3(1 - \cos \Phi) - e_2 \sin \Phi \\ e_1 e_2(1 - \cos \Phi) - e_3 \sin \Phi & \cos \Phi + e_2^2(1 - \cos \Phi) & e_2 e_3(1 - \cos \Phi) + e_1 \sin \Phi \\ e_1 e_3(1 - \cos \Phi) + e_2 \sin \Phi & e_2 e_3(1 - \cos \Phi) - e_1 \sin \Phi & \cos \Phi + e_3^2(1 - \cos \Phi) \end{pmatrix}. \quad (3.16)$$

Euler demonstrou que através de três rotações consecutivas em torno dos eixos coordenados, qualquer mudança entre dois sistemas de referência pode ser representada. Seja o primeiro eixo coordenado, denotado por $\hat{\mathbf{1}}$, pode-se escrever a matriz que rotaciona um ângulo Φ em torno desse eixo a partir da Equação (3.16) como:

$$\mathbf{R}(\hat{\mathbf{1}}, \Phi) = \begin{pmatrix} 1 & 0 & 0 \\ 0 & \cos \Phi & \sin \Phi \\ 0 & -\sin \Phi & \cos \Phi \end{pmatrix}. \quad (3.17)$$

Para as outras duas rotações independentes nos eixos restantes, dados $\hat{\mathbf{2}}$ e $\hat{\mathbf{3}}$, pode-se escrever:

$$\mathbf{R}(\hat{\mathbf{2}}, \Phi) = \begin{pmatrix} \cos \Phi & 0 & -\sin \Phi \\ 0 & 1 & 0 \\ \sin \Phi & 0 & \cos \Phi \end{pmatrix}, \quad (3.18)$$

e

$$\mathbf{R}(\hat{\mathbf{3}}, \Phi) = \begin{pmatrix} \cos \Phi & \sin \Phi & 0 \\ -\sin \Phi & \cos \Phi & 0 \\ 0 & 0 & 1 \end{pmatrix}. \quad (3.19)$$

É possível mostrar que qualquer matriz de rotação entre dois sistemas de referência pode ser representada como a composição de rotações sucessivas de certos ângulos em

torno dos eixos coordenados do sistema atual ou do sistema desejado. A composição de rotações pode ser representada pela seguinte igualdade:

$$\mathbf{R}(\hat{\mathbf{1}}, \hat{\mathbf{2}}, \hat{\mathbf{3}}; \Phi_1, \Phi_2, \Phi_3) = R(\hat{\mathbf{3}}, \Phi_3)R(\hat{\mathbf{2}}, \Phi_2)R(\hat{\mathbf{1}}, \Phi_3) \quad (3.20)$$

Os ângulos Φ_1 , Φ_2 e Φ_3 são mais conhecidos como ângulos de Euler e geralmente representados pelas letra gregas: ϕ , θ e ψ .

A representação de atitude através dos ângulos de Euler não é única, existindo 12 possibilidades de composições de matrizes de rotação. Como exemplo, a composição denominada por 3 – 2 – 1 expressa sequencialmente uma rotação de um ângulo ϕ em torno do eixo z , θ em torno de y e ψ em torno x . Ainda, as sequências podem ser divididas em dois tipos: (1) Rotações sequenciais em torno de eixos distintos e (2) Primeira e terceira rotação ocorrem sempre em torno do mesmo eixo. Para o tipo (1), existem singularidades em $\theta = \pm 90^\circ$. Já para o tipo (2), existem singularidades em $\theta = 0^\circ$ e $\theta = 180^\circ$, como discutido por Zanardi (1990).

Para evitar singularidades na representação de atitude durante a simulação do movimento rotacional do satélite existem representações alternativas. Os parâmetros simétricos de Euler ou representação em quatérnios tem como principais vantagens: não possuir singularidades, não depender de funções trigonométricas e simplificar a composição de rotações. Sua principal desvantagem se encontra em não fornecer uma interpretação física mais direta da suas grandezas em relação ao movimento de rotação. Além de sempre possuir a redundância de um parâmetro da representação. (WERTZ, 1978)

Para o problema de composição de rotação é possível mostrar que a construção de certos parâmetros em função do ângulo e eixo de Euler obedecem a álgebra de quatérnios. Tais parâmetros são conhecidos como os parâmetros simétricos de Euler e podem ser definidos como:

$$\mathbf{q}^* \equiv \begin{bmatrix} e_1 \sin\left(\frac{\Phi}{2}\right) \\ e_2 \sin\left(\frac{\Phi}{2}\right) \\ e_3 \sin\left(\frac{\Phi}{2}\right) \end{bmatrix} \equiv \sin\left(\frac{\Phi}{2}\right) \hat{\mathbf{e}}, \quad (3.21)$$

e

$$q \equiv \cos\left(\frac{\Phi}{2}\right). \quad (3.22)$$

Os quatro parâmetros definidos através das equações (3.21) e (3.22) podem ser apresentados como componentes da matriz coluna:

$$\mathbf{q} \equiv \begin{pmatrix} \mathbf{q}^* \\ q \end{pmatrix} = \begin{pmatrix} q_1 \\ q_2 \\ q_3 \\ q_4 \end{pmatrix}. \quad (3.23)$$

Os componentes desta matriz coluna possuem o seguinte vínculo:

$$q_1^2 + q_2^2 + q_3^2 + q_4^2 = 1. \quad (3.24)$$

Através da fórmula de Euler, como mostrado em [Shuster et al. \(1993\)](#), é possível construir a matriz de rotação em função dos parâmetros simétricos de Euler, a qual é dada por:

$$\mathbf{R}(\mathbf{q}) = \mathbf{R}(\mathbf{q}^*, q) = \begin{pmatrix} q_1^2 - q_2^2 - q_3^2 + q_4^2 & 2(q_1q_2 + q_3q_4) & 2(q_1q_3 - q_2q_4) \\ 2(q_1q_2 - q_3q_4) & -q_1^2 + q_2^2 - q_3^2 + q_4^2 & 2(q_2q_3 + q_1q_4) \\ 2(q_1q_3 + q_2q_4) & 2(q_2q_3 - q_1q_4) & -q_1^2 - q_2^2 + q_3^2 + q_4^2 \end{pmatrix}. \quad (3.25)$$

De forma inversa, é possível obter os parâmetros simétricos de Euler em função dos elementos da matriz de rotação. Para $q_4 \neq 0$, pode-se escrever:

$$q_1 = \frac{1}{4q_4}(R_{23} - R_{32}), \quad (3.26)$$

$$q_2 = \frac{1}{4q_4}(R_{31} - R_{13}), \quad (3.27)$$

$$q_3 = \frac{1}{4q_4}(R_{12} - R_{21}), \quad (3.28)$$

e

$$q_4 = \pm \frac{1}{2} \sqrt{1 + \text{Tr}(\mathbf{R})} = \pm \frac{1}{2} \sqrt{1 + R_{11} + R_{22} + R_{33}}. \quad (3.29)$$

A análise das equações (5.8) - (3.29) mostra uma ambiguidade de sinal. Entretanto, como \mathbf{R} é um função quadrática de \mathbf{q} , o sinal do quatérnio não é fisicamente significativa. Portanto, assim como a representação em ângulo/eixo de Euler a representação em parâmetros simétricos de Euler não é única (SHUSTER et al., 1993).

Além disso, a partir da equação de vínculo dos parâmetros (Equação (5.6)) é possível obter outros três conjuntos de quatro equações semelhantes as equações (5.8) - (3.29). Embora sejam matematicamente equivalentes (desconsiderando o sinal) a escolha de outros conjuntos de equações podem fornecer resultados mais ou menos precisos dependendo do valor do argumento da raiz da Equação (3.29). Neste caso, quanto mais próximo de zero esse argumento, maior a imprecisão no cálculo dos demais parâmetros. Como exemplo, se $q_4 \approx 0$, deve-se escolher outro conjunto de equações para as quais o q_4 não se encontre no denominador.

Do ponto de vista computacional, a representação de atitude em função dos parâmetros simétricos de Euler oferece uma grande vantagem para expressar a composição de rotações como já citado anteriormente. Se a matriz de rotação $\mathbf{R}(\mathbf{q}'')$ associada ao quatérnio \mathbf{q}'' é uma composição de duas rotações dada por:

$$\mathbf{R}(\mathbf{q}'') = \mathbf{R}(\mathbf{q}')\mathbf{R}(\mathbf{q}), \quad (3.30)$$

em que $\mathbf{R}(\mathbf{q})$ representa a primeira rotação e $\mathbf{R}(\mathbf{q}')$ representa a segunda. Então:

$$\mathbf{q}'' = \mathbf{q}' \otimes \mathbf{q}. \quad (3.31)$$

O produto da Equação (3.31) pode ser obtido pela substituição da Equação (5.7) na Equação (3.30). Após certo esforço algébrico, pode-se escrever (WERTZ, 1978):

$$\mathbf{q}'' = \begin{pmatrix} q'_4 & q'_3 & -q'_2 & q'_1 \\ -q'_3 & q'_4 & q'_1 & q'_2 \\ q'_2 & -q'_1 & q'_4 & q'_3 \\ -q'_1 & -q'_2 & -q'_3 & q'_4 \end{pmatrix} \mathbf{q}. \quad (3.32)$$

A Equação (3.32) evidencia o ganho computacional do uso dos quatérnios para composição de rotações, uma vez que a composição nesta representação envolve 16 operações de multiplicação. Já a representação em *DCM*, dada pela Equação (3.30), contém 27 operações do mesmo tipo.

Finalmente, outra representação de atitude importante pode ser obtida indiretamente dos parâmetros simétricos de Euler, tal representação é conhecida como parâmetros modificados de Rodrigues.

Seja o vetor de Gibbs ou vetor de Rodrigues definido como:

$$\boldsymbol{\rho}^* \equiv \begin{bmatrix} q_1/q_4 \\ q_2/q_4 \\ q_3/q_4 \end{bmatrix} = \begin{bmatrix} e_1 \tan\left(\frac{\Phi}{2}\right) \\ e_2 \tan\left(\frac{\Phi}{2}\right) \\ e_3 \tan\left(\frac{\Phi}{2}\right) \end{bmatrix} = \tan\left(\frac{\Phi}{2}\right) \hat{\mathbf{e}}, \quad (3.33)$$

e

$$\rho \equiv q_4 = \cos\left(\frac{\Phi}{2}\right). \quad (3.34)$$

Então os chamados parâmetros modificados de Rodrigues são dados pelas duas seguintes formas distintas:

$$\mathbf{p} \equiv \frac{\boldsymbol{\rho}^*}{1 + \rho}, \quad (3.35)$$

ou

$$\mathbf{m} \equiv \frac{\boldsymbol{\rho}^*}{1 - \rho}. \quad (3.36)$$

As duas formas são equivalentes e podem ser escolhidas de acordo com a normaliza-

ção definida na representação de atitude. Portanto, observa-se que esta representação também não é única. A principal vantagem dessa representação consiste no fato de que para ângulos de rotação menores que 2π não ocorrem singularidades (SHUSTER et al., 1993).

No presente trabalho, também foi utilizado a representação em quatérnios para a propagação de atitude, assunto discutido na próxima seção. Ainda, utilizamos a representação em ângulos de Euler na apresentação de alguns resultados, uma vez que tal representação oferece uma interpretação física mais direta.

3.3 Propagação de atitude

Propagar a atitude do satélite significa determinar a sua orientação a cada instante. Esse processo de determinação consiste basicamente na integração das equações dinâmicas e cinemáticas do corpo do satélite em relação a um sistema de referência para obtenção dos estados desejados.

Neste trabalho, as relações cinemáticas utilizadas envolvem as relações de variação temporal da representação de atitude em parâmetros simétricos de Euler (quatérnios) e a velocidade angular do satélite para cada instante de simulação. Como mostrado anteriormente, essa representação de atitude torna-se interessante do ponto de vista da composição de rotações.

Seja a orientação do satélite representada no instante t dada por $\mathbf{q}(t)$ e a orientação representada no instante seguinte $t + \Delta t$ dada por $\mathbf{q}(t + \Delta t)$. Recorrendo à Equação (3.32), a transformação entre as duas representações consecutivas pode ser obtida através da matriz antissimétrica formada pelos elementos de \mathbf{q}' . Sejam esses elementos q'_1, q'_2, q'_3 e q'_4 definidos respectivamente como:

$$q'_1 = e_x \sin\left(\frac{\Phi}{2}\right), \quad (3.37)$$

$$q'_2 = e_y \sin\left(\frac{\Phi}{2}\right), \quad (3.38)$$

$$q'_3 = e_z \sin\left(\frac{\Phi}{2}\right), \quad (3.39)$$

e

$$q'_4 = \cos\left(\frac{\Phi}{2}\right). \quad (3.40)$$

Em que $\mathbf{e}_x, \mathbf{e}_y$ e \mathbf{e}_z são os versores alinhados aos eixos do sistema fixo no corpo.

Desta maneira, pode-se reescrever a Equação (3.32) como:

$$\mathbf{q}(t + \Delta t) = \left\{ \cos\left(\frac{\Delta\Phi}{2}\right)\mathbf{I} + \sin\left(\frac{\Delta\Phi}{2}\right) \begin{pmatrix} 0 & e_z & -e_y & e_x \\ -e_z & 0 & e_x & e_y \\ e_y & -e_x & 0 & e_z \\ -e_x & -e_y & -e_z & 0 \end{pmatrix} \right\} \mathbf{q}(t), \quad (3.41)$$

em que \mathbf{I} é a matriz identidade 4×4 e $\Delta\Phi$ é o ângulo de Euler entre os instantes. Para o caso mais geral do movimento de atitude, é conveniente colocarmos a Equação (3.41) em uma forma diferencial (WERTZ, 1978). Considerando as rotações em intervalos infinitesimais, tem-se $\Delta t \rightarrow 0$ e $\Delta\Phi = \omega\Delta t$, sendo ω a magnitude da velocidade angular instantânea do sistema fixo no corpo. Além disso, considerando ângulos pequenos entre cada instante:

$$\cos\left(\frac{\Delta\Phi}{2}\right) \approx 1, \quad (3.42)$$

e

$$\sin\left(\frac{\Delta\Phi}{2}\right) \approx \frac{1}{2}\omega\Delta t. \quad (3.43)$$

Então, substituindo as equações (3.42) e (3.43) na Equação (3.41), tem-se finalmente:

$$\mathbf{q}(t + \Delta t) \approx \left[\mathbf{I} + \frac{1}{2}\Omega\Delta t \right] \mathbf{q}(t), \quad (3.44)$$

sendo Ω a matriz antissimétrica composta pelas componentes da velocidade angular dos eixos do sistema fixo no corpo em relação ao sistema de referência, e representada no sistema fixo do corpo:

$$\Omega = \begin{pmatrix} 0 & \omega_z & -\omega_y & \omega_x \\ -\omega_z & 0 & \omega_x & \omega_y \\ \omega_y & -\omega_x & 0 & \omega_z \\ -\omega_x & -\omega_y & -\omega_z & 0 \end{pmatrix}. \quad (3.45)$$

Ainda, no limite de $\Delta t \rightarrow 0$, a derivada do quatérnio que representa a atitude no instante t pode ser escrita a partir da Equação (3.44) como (WERTZ, 1978)

$$\frac{d\mathbf{q}}{dt} = \frac{1}{2}\Omega\mathbf{q}. \quad (3.46)$$

A Equação (3.46) é a equação cinemática do movimento para representação de atitude através dos parâmetros simétricos de Euler e possui a grande vantagem de ser linear na variável \mathbf{q} .

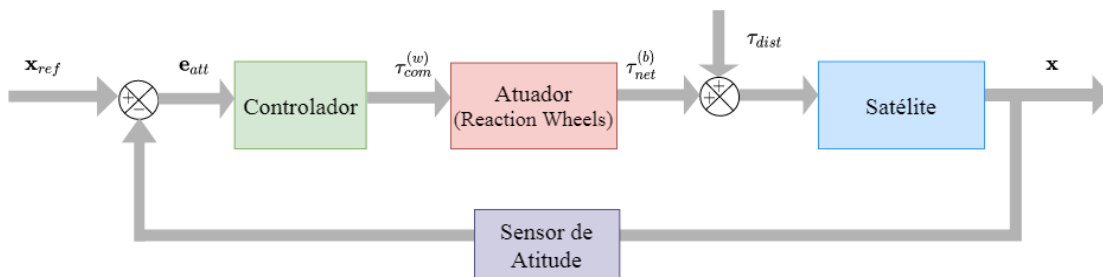
3.4 Sistema de controle de atitude

O sistema de controle em malha fechada implementado no presente trabalho pode ser descrito de forma mais geral pela Figura 3.1. A finalidade do sistema de controle de atitude é fornecer torques de controle τ_{com} , capazes corrigir o erro de atitude \mathbf{e}_{att} entre o sistema fixo no corpo e sistema inercial. O sinal de retroalimentação, denotado por $\mathbf{x}(\mathbf{t})$, representa o vetor de estado proveniente da leitura dos sensores ou estimadores de atitude. Pode-se escrever:

$$\mathbf{e}_{att} = \mathbf{x}_{ref} - \mathbf{x}, \quad (3.47)$$

em que \mathbf{x}_{ref} é o estado de atitude de referência.

Figura 3.1 - Diagrama de blocos que descreve o sistema de controle em malha fechada.



No caso do controle de atitude desenvolvido neste trabalho, o vetor de estado de

referência foi considerado como sendo o vetor nulo.

3.4.1 Abordagem convencional

Um dos métodos de controle empregado no problema de atitude de satélites consiste no uso do controlador *proporcional derivativo* (PD) (WERTZ, 1978), cuja lei de controle é definida por:

$$\tau_{com} = K_p \left[\mathbf{e}_{att} + T_d \frac{d\mathbf{e}_{att}}{dt} \right], \quad (3.48)$$

em que K_p é o ganho proporcional e T_d é o tempo derivativo. A determinação desses parâmetros pode ser feita a partir de diversos métodos que levam em consideração as características da função de transferência da planta e os requisitos da missão. Entre os métodos tradicionais da teoria de controle clássica estão o método do lugar das raízes e/ou de resposta em frequência (OGATA, 1992). Ainda, a teoria de controle moderno oferece a possibilidade de se obter analiticamente os parâmetros de um controlador ótimo para um dado índice de desempenho considerado.

3.4.2 Abordagem através de RNA

Neste trabalho, partindo da hipótese de que um controlador pode ser representado por uma RNA que é treinada para “aprender” as características dinâmicas envolvidas no sistema e assim realizar a tarefa de estabilização em três eixos, com referência a um índice de desempenho determinado.

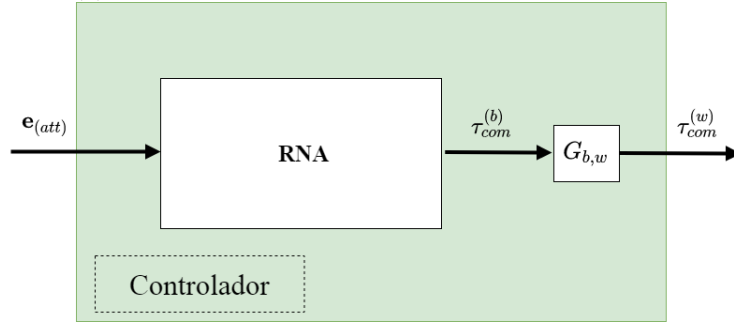
No presente trabalho foram definidas duas estratégias distintas acerca dos elementos do vetor de estado de entrada da RNA que substitui o controlador convencional. Na primeira estratégia considerou-se apenas os dados de atitude, representados pelos parâmetros modificados de Rodrigues, ou seja, $\mathbf{e}_{att} = \mathbf{p}$. A segunda estratégia consistiu em considerar o vetor de estado completo, ou seja, foram considerados os estados de velocidade angular do satélite em três eixos além dos estados de atitude. Portanto:

$$\mathbf{e}_{att} = \begin{bmatrix} \mathbf{p} \\ \boldsymbol{\omega}_b \end{bmatrix}. \quad (3.49)$$

Em ambos os casos, a escolha dos parâmetros modificados de Rodrigues como entradas da RNA se deu a partir da maior estabilidade durante o processo de treinamento, quando comparado com entradas diretamente em quatérnios.

Outra consideração importante foi feita acerca dos estados de saída do controlador através de uma RNA. Os elementos do vetor de torque comandado são dados em relação aos eixos de rotação de cada roda de reação, que por sua vez são representado no sistema (w). No entanto, os estados de entrada da RNA (atitude e/ou velocidade angular) são representados no sistema (b). Outra vez, foram adotadas duas estratégias neste sentido. Na primeira, considera-se a saída da rede o vetor de torque comandado representado no sistema (b), como ilustrado pela Figura 3.2.

Figura 3.2 - Diagrama que descreve o controlador para saída da RNA representada no sistema (b) .



Para este caso, devemos transformar o vetor de torques comandados para o sistema (w) . Ou seja, precisamos de uma matriz de transformação $\mathbf{G}_{b,w}$ que leva um vetor representado em (b) para uma representação em (w) . Sendo assim:

$$\tau_{com}^{(w)} = \mathbf{G}_{b,w} \tau_{com}^{(b)}. \quad (3.50)$$


Tal matriz é a chamada pseudo-inversa e pode ser obtida por (WERTZ, 1978):

$$\mathbf{G}_{b,w} = \mathbf{G}_{w,b}^T [\mathbf{G}_{w,b} \mathbf{G}_{w,b}^T]^{-1}, \quad (3.51)$$

em que $\mathbf{G}_{w,b}$ é a matriz que leva um vetor representado no sistema (w) para o sistema (b) . Tal matriz é obtida a partir da projeção dos eixos do sistema (w) nos eixos coordenado do sistema (b) .

A segunda estratégia, relativa à representação da saída da RNA que substitui o controlador, foi considerar o torque comandado diretamente no sistema (w) , como representado na Figura 3.3.

Figura 3.3 - Diagrama que descreve o controlador para saída da RNA representada diretamente no sistema (w) .



Neste último caso, a transformação entre os sistemas ocorre internamente no processamento da rede. Maiores considerações acerca da abordagem de controle com RNA's são apresentadas no Capítulo 4.

3.5 Modelagem dos atuadores

De acordo com [Wertz \(1978\)](#), as principais vantagens do uso de rodas de reação como atuadores para estabilização em três eixos são: (1) alta precisão, (2) manobras com grandes ângulos de rotação sem consumo de combustível e (3) compensação de torques sem consumo de combustível. Em geral, a estabilização de pequenos satélites usa três rodas de reação por simplificação e/ou devido aos requisitos de tamanho e volume da plataforma ([KING, 2020](#)). No entanto, o uso de quatro rodas de reação oferece a vantagem de redundância no caso de falha de uma delas ([JIN et al., 2008](#)). Além disso, diversas configurações entre o sistema (w) e o sistema (b) podem ser adotadas para o controle de atitude ([ISMAIL; VARATHARAJOO, 2010](#)).

O vetor de torque líquido fornecido pelas rodas de reação e que é representado no sistema (w) pode ser obtido pela relação:

$$\boldsymbol{\tau}_{net}^{(w)} = \dot{\mathbf{h}}_w^{(w)}, \quad (3.52)$$

na qual $\mathbf{h}_w^{(w)}$ é o vetor momento angular total das rodas de reação, representado no sistema (w), e o qual pode ser escrito como:

$$\mathbf{h}_w^{(w)} = I_w \boldsymbol{\omega}_w^{(w)}, \quad (3.53)$$

em que o parâmetro I_w é tensor de inércia do conjunto das rodas de reação em relação ao sistema (w) e $\boldsymbol{\omega}_w^{(w)}$ é o vetor velocidade angular das rodas representado no sistema (w). Substituindo a Equação (3.53) na Equação (3.52) e assumindo que I_w é invariante no tempo, o torque de controle líquido representado no sistema (w) é dado por:

$$\boldsymbol{\tau}_{net}^{(w)} = I_w \dot{\boldsymbol{\omega}}_w^{(w)}. \quad (3.54)$$

Então, é possível reescrever a Equação (3.54) como:

$$\dot{\omega}_w^{(w)} = I_w^{-1} \tau_{net}^{(w)}. \quad (3.55)$$

Sendo assim, uma vez conhecido o vetor $\tau_{net}^{(w)}$, pode-se obter a velocidade angular das rodas de reação, denotada por $\omega_w^{(w)}$, através da integração da Equação (3.55).

Devido à presença de atrito nos atuadores, o torque comandado pelo computador de bordo, denotado pelo vetor $\tau_{com}^{(w)}$, não é o mesmo transmitido pelas rodas de reação ao corpo do satélite. Portanto, na simulação do sistema de controle devemos considerar uma certa quantidade de torque de atrito a ser descontada. Tal quantidade pode ser representada pelo vetor $\tau_{drag}^{(w)}$. Neste trabalho foi considerado um sistema de compensação intrínseco aos sistema das rodas e capaz de fornecer torques denotados pelo vetor $\tau_{comp}^{(w)}$, de maneira que a perdas pelo atrito sejam suprimidas. Portanto, pode-se escrever $\tau_{net}^{(w)}$ como:

$$\tau_{net}^{(w)} = \tau_{com}^{(w)} + \tau_{comp}^{(w)} - \tau_{drag}^{(w)}. \quad (3.56)$$

Diversos modelos para o atrito podem considerar as componentes de atrito cinético (atrito viscoso), atrito estático (atrito de Coulomb), torques de arranque, etc. (OLS-SON et al., 1998; CARRARA; KUGA, 2013). Seja o efeito do atrito cinético assumido como predominante, pode-se escrever:

$$\tau_{drag}^{(w)} = b \overline{\omega}_w^{(w)}, \quad (3.57)$$

em que b é o coeficiente de atrito viscoso e $\overline{\omega}_w^{(w)}$ é o vetor de velocidade angular desejado para as rodas, representado no sistema (w) e obtido pela integração direta do torque comandado através da expressão:

$$\dot{\overline{\omega}}_w^{(w)} = I_w^{-1} \tau_{com}^{(w)}. \quad (3.58)$$

Ou seja, $\overline{\omega}_w^{(w)}$ contém as componentes de velocidade angular das rodas caso não houvesse atrito presente no mecanismo das rodas de reação. Já o vetor de torque de compensação na Equação (3.52) pode ser definido pela lei de controle dada por (OGATA, 1992):


$$\tau_{comp}^{(w)} = K_p \left[\mathbf{e}_w + \frac{1}{T_i} \int_{-\infty}^t \mathbf{e}_w dt \right], \quad (3.59)$$

em que K_p e T_i são a constante de ganho proporcional e a constante de tempo integral, respectivamente. O vetor de erro entre a velocidade atual e a velocidade de referência das rodas de reação, denotado por \mathbf{e}_w , pode ser escrito como:

$$\mathbf{e}_w = \overline{\overline{\omega}}_w^{(w)} - \omega_w^{(w)}. \quad (3.60)$$

A estrutura do atuador implementado na simulação do sistema de controle de atitude e que considera os modelos de atrito e compensação descritos é mostrada na Figura 3.4.

Figura 3.4 - Diagrama de blocos que descreve o sistema de atuadores.



4 REDES NEURAIS ARTIFICIAIS

Neste capítulo são abordadas as principais características, propriedades e paradigmas de treinamento das RNAs. Além disso, é apresentada a descrição da rede utilizada como controlador e seu respectivo processo de treinamento através do algoritmo de *backpropagation*. A Seção 4.1 e Seção 4.2 consistiram em uma síntese das principais propriedades e estruturas de RNAs e a descrição geral da rede PDNN, respectivamente. Na Seção 4.3 são apresentados os principais paradigmas de aprendizagem e o processo de treinamento adotado na presente abordagem.

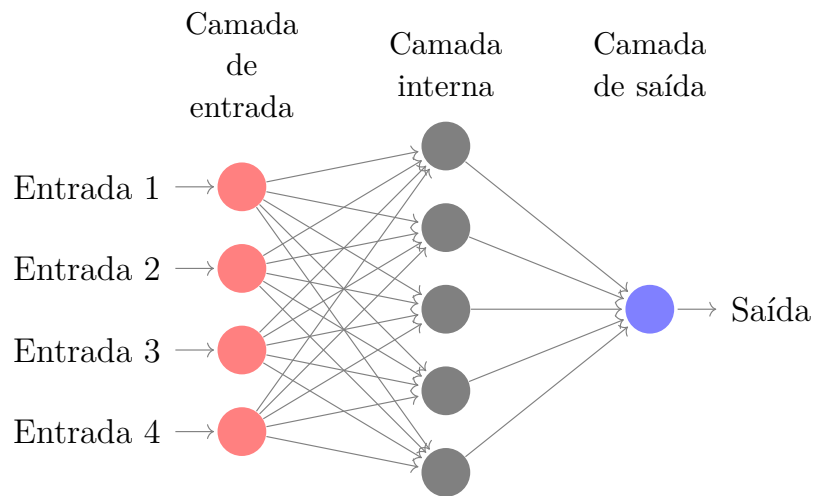
4.1 Modelos de RNAs

Os modelos de redes neurais são compostos basicamente por três entidades fundamentais (LIN et al., 1996): modelos de processamento dos neurônios (função de integração e ativação), modelos de conexões entre seus elementos (topologia de rede) e paradigmas de aprendizagem.

Diferentes estruturas de redes já foram utilizadas em problemas de controle de atitude. Entre as mais comuns, se encontram as redes do tipo direta com múltiplas camadas (*multilayer feedforward network*), que foram abordadas para o problema de atitude no trabalho de Choi e Flashner (2000). Esse tipo de arquitetura de rede se caracteriza principalmente pela presença de uma ou mais camadas internas de neurônios (*hidden layer*), com fluxo direto de informação (Figura 4.1). Podendo ser ainda classificada como completamente ou parcialmente conectada.

As redes do tipo multi layer perceptron (MLP) são uma generalização dessa classe, as quais foram também aplicadas em problemas de controle de atitude de satélites, como demonstrado pelos trabalhos de Carrara et al. (1998) e Cheng e Shu (2010). Um caso especial de rede do tipo *feedforward* é conhecida como *radial basis function neural network* (RBFNN), que foi implementada para o controle de atitude nos trabalhos de Sadati et al. (2002) e Xia et al. (2019). A sua variação é denominada *hypercomplex radial basis function neural network* (HRBFNN), sendo também abordada para o problema de controle de atitude em Fortuna et al. (2001).

Figura 4.1 - RNA com múltiplas camadas e arquitetura direta (*feedforward neural network*).

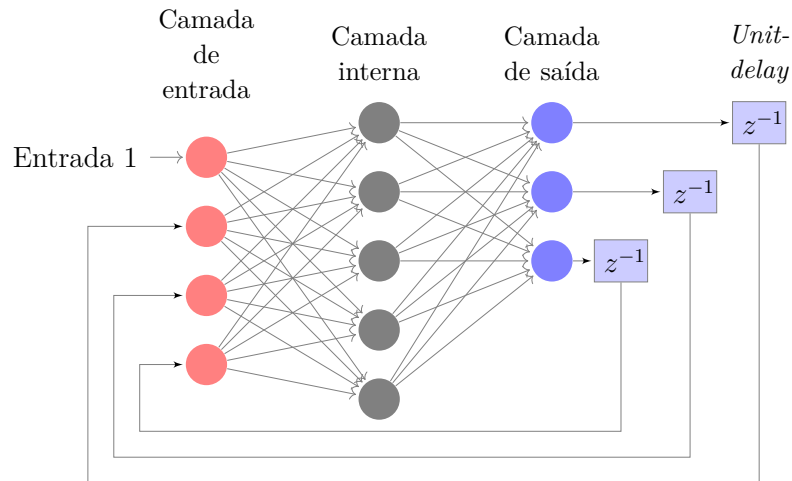


Ainda no contexto de redes do tipo *feedforward*, atentamos para uma ambiguidade encontrada na literatura. A rede denominada pela abreviação HMLP pode se referir a duas redes distintas, ambas já utilizadas em problemas de controle de atitude. A rede *hybrid multi layered perceptron* (HMLP) é uma variação da rede MLP, que tem como característica a presença de conexões diretas entre os neurônios da camada de entrada e os neurônios da camada de saída, o que aumenta significativamente a complexidade. Essa rede foi abordada no trabalho de Sharun et al. (2011) para o problema de atitude. Já a rede do tipo *hypercomplex multi layered perceptron* (HMLP) é outro caso especial de rede MLP. Esta é definida a partir da extrapolação de suas propriedades para incorporar a álgebra complexa, da qual faz parte a álgebra de quatérnios, sendo abordada no trabalho de Fortuna et al. (1999) para o problema de controle de atitude.

Outra importante classe de arquitetura de RNA é a rede recorrente com múltiplas camadas, *recurrent neural network* (RNN) ou ainda *feedback neural network* (FNN). Caracterizada pela presença de sinais de retro-alimentação entre os neurônios. As redes mais conhecidas que empregam essa arquitetura são as redes de Hopfield e sua generalização, conhecida como máquina de Boltzman (HAYKIN, 2010). Embora a aplicação desse tipo de rede em problemas de controle de atitude não seja comumente encontrada na literatura, é certo que as RNAs com essa característica possuem vantagens em problemas com comportamento dinâmico, uma vez que os sinais de saídas dos neurônios em uma iteração k estão relacionados com os sinais de saída da iteração anterior, $k - 1$. Além disso, podem aumentar a velocidade do processo


de treinamento para certas condições (TSOUKALAS; UHRIG, 1996). Esse tipo de rede possui atualmente diversas aplicações em sistemas de reconhecimento de imagens e também em navegação de veículos autônomos como abordado em Kim e Bae (2019).

Figura 4.2 - RNA de múltiplas camadas com arquitetura recorrente (*recurrent neural network* ou *feedback network*).



Outro interessante tipo de RNA com presença de sinal de recorrência foi desenvolvida no trabalho de Shu e Pi (2000), o qual desenvolveu a aplicação de uma rede denominada *PID neural network* (PIDNN) para o controle de um sistema dinâmico com atraso em malha fechada (Figura 4.3). Unindo as vantagens do controle *proporcional-integral-derivativo* (PID) clássico e as propriedades das RNAs. Esse tipo de rede é constituída por neurônios ditos: proporcional (P), integral (I) e derivativo (D). Com a presença de sinal de recorrência nos dois últimos. Os pesos são ajustados por algoritmos de *backpropagation* durante a fase de treinamento. Ainda, de acordo com Shu e Pi (2000), esse tipo de rede apresenta bom desempenho no controle diferentes tipos de sistemas, além de rápida aprendizagem.

Figura 4.3 - Estrutura do controlador PIDNN empregado no controle de sistema com atraso.



4.2 Proportional Derivative Neural Network (PDNN)

Desenvolvemos para o presente trabalho uma rede neural cuja estrutura contém na camada interna neurônios do tipo P e D tendo como objetivo emular as características dos termos proporcionais e derivativos das leis de controle convencionais tal, como em Shu e Pi (2000). Para a presente aplicação, a escolha desses neurônios deveu-se ao fato de se buscar o mesmo comportamento de melhora na resposta transitória do sistema verificada através do controle PD convencional. Ainda, foi considerado que nas camadas de entrada e saída da rede proposta encontra-se apenas neurônios do tipo P, sendo tal rede denominada *proportional derivative neural network* (PDNN) e descrita na seções a seguir.


4.2.1 Neurônios tipo P e D

Seja $x_m(k)$ um sinal de saída proveniente de uma camada m , então a função de integração que pondera cada sinal e o transforma em um sinal de entrada da próxima camada n é dada por:

$$u_n(k) = \sum_{m=1}^M w_{mn}(k) \cdot x_m(k), \quad (4.1)$$

em que M é o número de neurônios na camada m que estão conectados ao respectivo neurônio da camada n . Para um neurônio dito P, como mostrado na Figura 4.4, a função de ativação que determina o seu sinal de saída é dada por:

Figura 4.4 - Estrutura geral de processamento de sinais através de um neurônio P na iteração (k).




$$x_n^P(k) = \tanh(u_n(k)) , \quad (4.2)$$

Para o caso de neurônio definido como D (Figura 4.5), pode-se escrever a seguinte função de ativação:

$$x_n^D(k) = \tanh\left(\frac{u_n(k) - u_n(k-1)}{\Delta t}\right) , \quad (4.3)$$

Figura 4.5 - Estrutura geral de processamento de sinais através de um neurônio D na iteração (k).



em que $u_n(k-1)$ é o sinal de recorrência com o valor da entrada da iteração anterior e Δt é o intervalo de tempo entre cada iteração. A última equação tem a característica de taxa de variação dos sinais de saída do neurônio no tempo, o que de forma mais elementar é a própria definição da derivada do sinal de saída.

4.2.2 Topologia da rede PDNN

Na Seção 3.4 foi brevemente discutido as possibilidades acerca da representação das entradas e saídas para a RNA que substitui o controlador. A seguir, são descritos com maiores detalhes o processamento dos sinais e a estrutura mais geral da rede PDNN, mostrada pela Figura 4.6.


Sejam os elementos de entrada da rede as componente de erro de atitude dado pelo vetor $\mathbf{u}^I = [e_{att_x} \ e_{att_y} \ e_{att_z}]^T$. Então, pode-se definir as componentes de entrada dos neurônios P da camada de entrada como:

$$u_1^I = e_{att_x} \tag{4.4}$$

$$u_2^I = e_{att_y} \tag{4.5}$$

$$u_3^I = e_{att_z} \tag{4.6}$$

Figura 4.6 - Estrutura geral da rede PDNN.



As funções de ativação definem os sinais de saída dos neurônios da camada de entrada como:

$$x_1^I = \tanh(u_1^I) \quad (4.7)$$

$$x_2^I = \tanh(u_2^I) \quad (4.8)$$

$$x_3^I = \tanh(u_3^I) \quad (4.9)$$

Portanto, pode-se representar os sinais que saem de camada de entrada por x_m^I , com $m = 1, 2, \dots, M$ designando o neurônio provedor de cada sinal em questão. Para o caso de estabilização em três eixos, considerou-se $M = 3$.

Cada neurônio P da camada interna recebe um sinal da camada de entrada ponderado pelos parâmetros w_{mp}^{IP} , em que o índice p designa o número do neurônio do tipo P, ou ainda o número de conexões entre a camada de entrada e os neurônios do tipo P referente a cada eixo. Da mesma forma, cada neurônio do tipo D da camada interna recebe um sinal da camada de entrada ponderado pelos parâmetros w_{md}^{ID} , em que d é o índice que designa os neurônios do tipo D na camada interna respectivos

a cada eixo.

Sendo assim, pode-se expressar a função de integração dos sinais de entrada dos neurônios da camada interna através da forma vetorial:

$$\mathbf{u}_{mp}^P = x_m^I \mathbf{w}_{mp}^{IP} = \begin{bmatrix} x_m^I w_{m1}^{IP} \\ x_m^I w_{m2}^{IP} \\ \vdots \\ x_m^I w_{mp}^{IP} \end{bmatrix}, \quad (4.10)$$

e

$$\mathbf{u}_{md}^D = x_m^I \mathbf{w}_{md}^{ID} = \begin{bmatrix} x_m^I w_{m1}^{ID} \\ x_m^I w_{m2}^{ID} \\ \vdots \\ x_m^I w_{md}^{ID} \end{bmatrix} \quad (4.11)$$

Portanto, a função de ativação que define os sinais de saída da camada interna pode ser escrita na forma:

$$\mathbf{x}_{mp}^P = \tanh(\mathbf{u}_{mp}^P), \quad (4.12)$$

para os neurônios do tipo P e

$$\mathbf{x}_{md}^D = \tanh\left(\frac{\mathbf{u}_{md}^D - \mathbf{u}_{md}^D(k-1)}{\Delta t}\right), \quad (4.13)$$

para o tipo D. Finalmente, pode-se escrever a função de integração que define o sinal de entrada em cada neurônio da camada de saída através da seguinte forma:

$$u_m^O = [\mathbf{x}_{mp}^P]^T [\mathbf{w}_{mp}^{PO}] + [\mathbf{x}_{md}^D]^T [\mathbf{w}_{md}^{DO}] \quad (4.14)$$

Para $m = 1, 2, 3$, respectivamente, tem-se:

$$u_1^O = \sum_{p=1}^P x_{1p}^P w_{1p}^{PO} + \sum_{d=1}^D x_{1d}^D w_{1d}^{DO}, \quad (4.15)$$

$$u_2^O = \sum_{p=1}^P x_{2p}^P w_{2p}^{PO} + \sum_{d=1}^D x_{2d}^D w_{2d}^{DO}, \quad (4.16)$$

e

$$u_3^O = \sum_{p=1}^P x_{3p}^P w_{3p}^{PO} + \sum_{d=1}^D x_{3d}^D w_{3d}^{DO}. \quad (4.17)$$

Por fim, pode-se obter os torques comandados pela rede PDNN que substitui o controlador convencional a partir da função de ativação dos neurônios da camada de saída como:

$$\tau_{com_x}^{(b)} = x_1^O = s_1 \tanh(u_1^O), \quad (4.18)$$

$$\tau_{com_y}^{(b)} = x_2^O = s_2 \tanh(u_2^O), \quad (4.19)$$

e

$$\tau_{com_z}^{(b)} = x_3^O = s_3 \tanh(u_3^O), \quad (4.20)$$

em que s_1 , s_2 e s_3 são parâmetros que permitem definir a saturação dos torques comandados pelo computador de bordo ao sistema de atuação, os quais operam com valores limitados de sinais de controle. É importante observar que neste caso as saídas do controlador são os valores de torques comandados em relação ao sistema de coordenadas formado pelo sistema fixo (b).

4.2.2.1 Camada invisível

Para o caso em que a saída do controlador é dada pelos torques comandados a cada roda de reação no sistema (w). O processamento dos sinais pela rede deve levar em conta a transformação entre os sistemas (w) e (b). Já que as equações do movimento

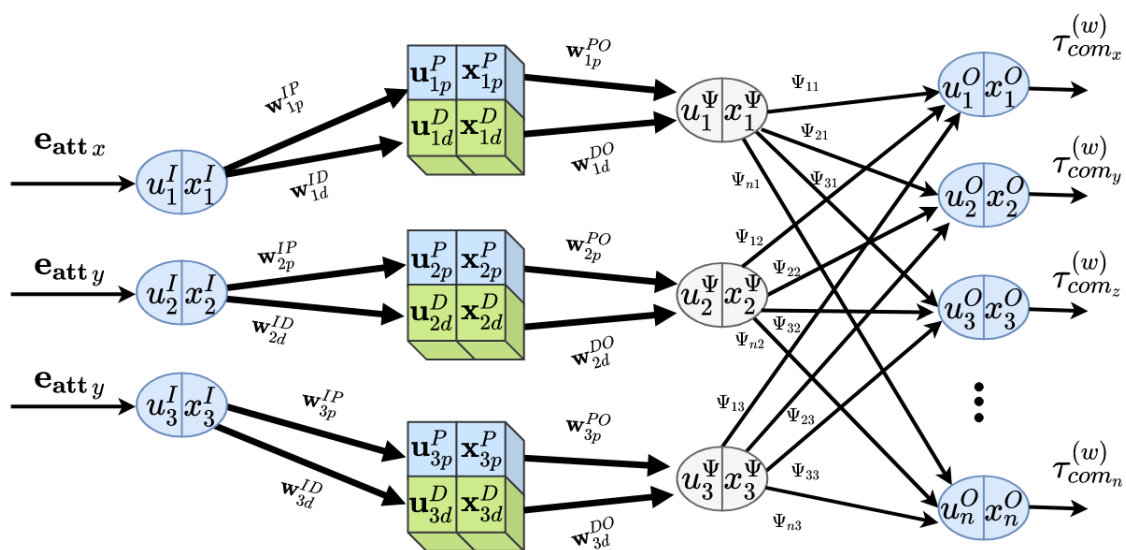
são definidas nesse último sistema.

Foi definida uma camada, denominada “invisível”, na qual o sinal de entrada é igual ao sinal de saída para cada neurônio e o algoritmo de atualização dos pesos durante o processo de treinamento não atua nas conexões de saída desta camada. Em outras palavras, foi desenvolvido na implementação da rede PDNN uma camada para realizar a transformação entre o sistemas (b) e (w) internamente, uma vez que as entradas da rede são componentes de vetores representadas no sistema (b) e a saída do controlador pode ser fornecida como as componentes do vetor de torque comandado no sistema (w) , ou seja $\tau_{com}^{(w)}$.

Uma estratégia semelhante à implementada através da camada invisível pode encontrada na literatura nas redes de links funcionais, desenvolvidas por Pao (1989). Esse tipo de rede fornece informações que atuam nas conexões da rede de modo que incorporem certos padrões definidos entre a entrada e saída, com o objetivo de mapear o vetor de entrada em um maior espaço de padrões¹ maior. (TSOUKALAS; UHRIG, 1996)

A implementação dessa estratégia do ponto de vista do algoritmo que descreve a rede PDNN consistiu em realizar a transformação de coordenadas entre a camada interna e a camada de saída da rede como mostrado na Figura (4.7).

Figura 4.7 - Estrutura geral da rede PDNN com a camada invisível.



¹Um espaço de padrão é uma representação gráfica de um conjunto de padrões de entrada e suas respostas desejadas. (DAWSON, 2008)

Para esta configuração, pode-se definir de forma geral a função de integração da camada de saída como:

$$u_n^O = \sum_{m=1}^3 \Psi_{nm} x_m^\Psi. \quad (4.21)$$

As ponderações das conexões entre a camada invisível e a camada de saída são definidas pelos pesos Ψ_{nm} , em que n é a quantidade dos neurônios da camada de saída e m é a quantidade de neurônios da camada invisível. Tais elementos podem ser organizados em uma matriz $n \times m$, dada por:

$$\Psi_{n \times m} = \begin{pmatrix} \Psi_{11} & \Psi_{12} & \dots & \Psi_{1m} \\ \Psi_{21} & \Psi_{22} & \dots & \Psi_{2m} \\ \vdots & \ddots & \vdots & \\ \Psi_{n1} & \Psi_{n2} & \dots & \Psi_{nm} \end{pmatrix}. \quad (4.22)$$

Se definirmos um vetor \mathbf{x}_m^Ψ que contém em seus elementos os sinais de saída da camada invisível, que por vez são iguais aos sinais de entrada dessa mesma camada e cujas funções de integração são equivalentes às equações (4.15- 4.17). Então:

$$\mathbf{x}_m^\Psi = \begin{bmatrix} x_1^\Psi \\ x_2^\Psi \\ \vdots \\ x_m^\Psi \end{bmatrix}. \quad (4.23)$$

Da mesma forma, assumindo um vetor \mathbf{u}_n^O que contém os sinais de entrada dos neurônios da camada de saída como:

$$\mathbf{u}_n^O = \begin{bmatrix} u_1^O \\ u_2^O \\ \vdots \\ u_n^O \end{bmatrix}. \quad (4.24)$$

Então, pode-se escrever:

$$\mathbf{u}_n^O = \Psi \mathbf{x}_m^\Psi. \quad (4.25)$$

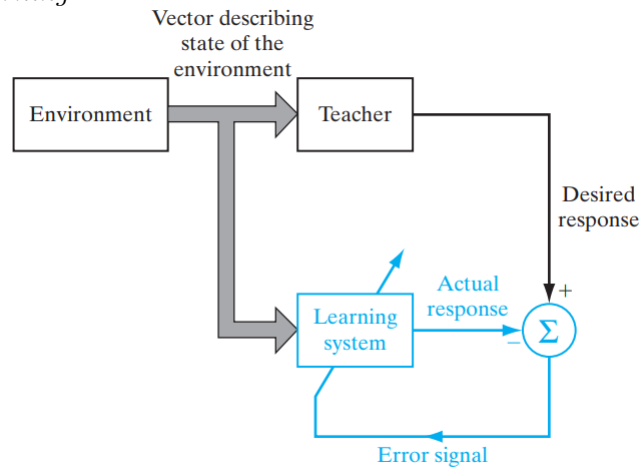
Se \mathbf{x}_m^Ψ é um vetor que assumimos representado no sistema (b), então pode-se selecionar a matriz de pesos Ψ para que \mathbf{u}_n^O seja o mesmo vetor representado no sistema (w). Entre as diversas formas de se converter o torque desejado no sistema do corpo para o conjunto de rodas de reação, a maneira ótima é utilizar a pseudo-inversa definida pela Equação (3.51) no lugar da matriz Ψ .

4.3 Métodos de aprendizagem de RNAs

Existem três paradigmas principais de aprendizagem de RNAs, sendo eles: aprendizagem supervisionada (*supervised learning*), aprendizagem auto-organizada (*unsupervised learning*) e aprendizagem por reforço (*reinforcement learning*).

A aprendizagem supervisionada tem como essência a presença de um agente externo (*teacher*), que fornece á RNA os sinais de referência para os pares entrada/saída durante o processo de treinamento (Figura 4.8). Portanto, os parâmetros da rede são ajustados de maneira a imitar o comportamento esperado para o *teacher*. Esse tipo de rede pode operar *online* e *offline* (HAYKIN, 1994). Como exemplo de aplicações de controle, o *teacher* pode ser substituído por um PID clássico, o qual fornecerá uma saída desejada como referência para a RNA ao longo do treinamento. Deve-se atentar para o fato de que neste caso, o desempenho da RNA não poderá se igualar ao desempenho do PID. No entanto, o controle através de uma rede supervisionada pode fornecer um ponto de partida para sistemas mais sofisticados, que possam melhorar o desempenho de outro sistema integrado (TSOUKALAS; UHRIG, 1996). Outra desvantagem da aprendizagem supervisionada é a de que a rede não pode criar novas estratégias para novas condições que não fazem parte do conjunto já treinadas com auxílio do *teacher*. Para estas situações, a aprendizagem por reforço pode ser mais viável.


Figura 4.8 - Diagrama de blocos de uma rede com aprendizagem supervisionada, *supervised learning*.



Fonte: Haykin (2010)

Já as redes neurais auto-organizadas não recebem nenhuma informação de agente externos como mostrado na Figura 4.9. A rede deve extrair do próprio ambiente os padrões, recursos, regularidades, correlações ou categorias das entradas para caracterizar as saídas, sendo esse processo chamado de auto-organização (LIN et al., 1996). Esse tipo de processo pode ser realizado através de regras de aprendizagem competitivas, como por exemplo a estratégia conhecida como *winner-takes-all* (HAYKIN, 1994). O tempo de treinamento para aprendizagem supervisionada pode aumentar exponencialmente com o número de camadas da RNA, tornando este processo extremamente lento. Já as redes auto-organizáveis podem ser uma solução plausível para esse problema, uma vez que seus processos ocorrem de maneira sequencial, onde uma camada é processada por vez, permitindo que o tempo de treinamento de redes profundas se mantenha linear com o aumento do número de camadas.

Figura 4.9 - Diagrama de blocos de uma rede com aprendizagem auto-organizada, *unsupervised learning*.

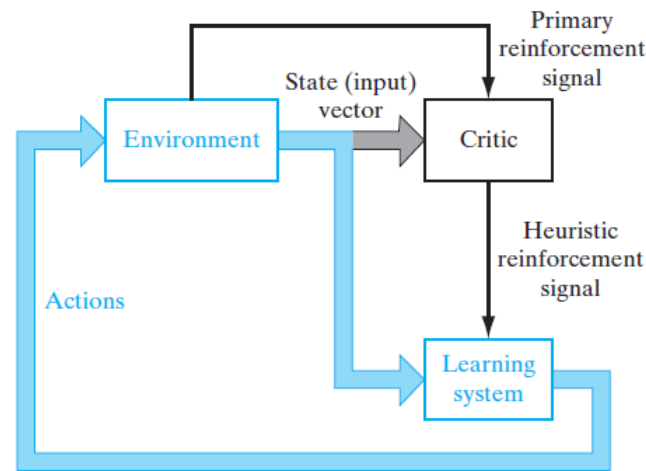


Fonte: Haykin (2010)

Por fim, a aprendizagem por reforço (*reinforcement learning*) se baseia na aprendizagem por mapeamento entrada/saída *online*, através de tentativa e erro para maximizar um índice de desempenho ou sinal de reforço. Pode ser dividida em dois segmentos, (1) não-associativa e (2) associativa. O primeiro é caracterizado pelo fato de que o sistema de aprendizagem tem a tarefa de selecionar uma única ação ótima em vez de associar ações diferentes a estímulos diferentes. Nesse problema de aprendizagem, o reforço é a única entrada que o sistema aprendiz recebe do ambiente, se baseando assim em algoritmos genéticos e na teoria de aprendizagem estocástica autônoma (HAYKIN, 1994). O segundo segmento trabalha com o fato de que o ambiente fornece informações adicionais e a aprendizagem ocorre através do mapeamento entre estímulos e ação, se baseando na teoria das RNAs e possuindo aplicações diretas na teoria de controle ótimo (WERBOS, 1989; SUTTON et al., 1992; WATKINS, 1989; BARTO, 2018).

A Figura 4.10 mostra o diagrama de blocos com os elementos básicos da aprendizagem por reforço para um sistema heurístico adaptativo (*Adaptative Heuristic Critic*), o qual usa um ‘avaliador’ (*critic*) que recebe um sinal escalar do ambiente e o transforma em um sinal com valor mais adequado para o sistema aprendiz, na forma de um dito ‘reforço heurístico’ (*heuristic reinforcement*). Algumas características da aprendizagem por reforço podem dificultar sua implementação em um processo de treinamento *online* devido ao fato de ser um método que envolve tentativa e erro, além da existência de atraso do sinal de reforço (LIN et al., 1996).

Figura 4.10 - Diagrama de blocos de aprendizagem por reforço de um sistema adaptativo heurístico.



Fonte: Haykin (2010)

4.3.1 Treinamento através do algoritmo de *backpropagation*

Segundo Werbos (1992), do ponto de vista do controle inteligente ou ainda controle neural, existem cinco abordagens principais que são casos especiais de aprendizagem supervisionada, sendo elas:

- 1 Controle Supervisionado (*supervised control*): a rede é treinada a partir de uma base de dados com sinais de controle “corretos” a serem aplicados em determinada situação;
- 2 Controle inverso (*direct inverse control*): as redes aprendem a realizar o mapeamento de acordo com trajetórias determinadas. Ou seja, um conjunto de entradas diferentes são processados de forma a gerar um único conjunto de saídas desejadas;
- 3 Controle neural adaptativo (*neural adaptive control*): ocorre quando o mapeamento linear do controle adaptativo padrão é realizado por uma RNA;
- 4 *Backpropagation*: os sinais de controle são obtidos a partir da rede com base na maximização de um índice de desempenho, ou minimização de

uma função do erro;

- 5 Métodos adaptativos críticos (*adaptive critic methods*): as RNAs são usadas como aproximações da programação dinâmica usada no controle ótimo.

Entre as abordagens mais utilizadas para problemas práticos com aprendizagem supervisionada, se encontra o algoritmo de *backpropagation* (WERBOS, 1974; RUMELHART et al., 1986). Essa poderosa técnica consiste no processo de variação dos pesos entre as conexões da rede de forma que a função custo seja minimizada ao longo do treinamento. Tal processo tem como base a implementação do algoritmo do gradiente descendente no espaço de estados formados pelos pesos que compõem a rede (HAYKIN, 2010).

A primeira etapa do algoritmo de *backpropagation* é chamada de caminho direto (*forward propagation*). Esta etapa descreve o processamento camada por camada do sinal de entrada da rede e é dada pelas funções de integração e ativação mostradas na Seção (4.2). A segunda etapa consiste na propagação do erro entre o sinal de saída da rede e o sinal desejado no sentido inverso (*back propagation*) camada por camada.

Seja a saída de uma RNA obtida analiticamente por uma função $\mathbf{F}(\mathbf{w}; \mathbf{x})$, em que \mathbf{w} é o vetor que contém os pesos entre todas as conexões da rede e \mathbf{x} é o vetor de entrada. A técnica de *backpropagation* permite o cálculo eficiente das derivadas parciais da função \mathbf{F} com relação a \mathbf{w} , dada uma entrada \mathbf{x} .

Os incrementos $\Delta\mathbf{w}(k)$ são calculados a partir do gradiente instantâneo $\partial J(k)/\partial\Delta w(k)$. A função $J(k)$ é chamada de função custo (*cost function*) e pode ser escrita pela forma geral:

$$J = \frac{1}{T} \sum_{k=0}^T e(k), \quad (4.26)$$

onde T é o tempo de voo simulado em cada cenário e $e(k)$ é a função de erro (loss function), a qual relaciona o erro entre a saída da rede, definida por \mathbf{F} , e a saída desejada. Além disso, a função J não é única e pode ser definida por qualquer função diferenciável que relaciona os estados atuais de saída da rede e o estado desejado. (LIN et al., 1996)

Em geral, a regra de atualização dos pesos pode ser escrita na forma:

$$\Delta w(k) = -\eta \nabla J(k) + \alpha \Delta w(k-1) \quad (4.27)$$

em que η é a constante de aprendizagem e α é o chamado *momentum*. Ambos os parâmetros afetam diretamente a convergência do processo de *backpropagation*. O processo do gradiente descendente pode ser muito lento para pequenos valores de η e pode oscilar para valores muito grandes. No entanto, a escolha deste parâmetro é feita de forma experimental para cada caso de estudo, geralmente é escolhido para valores entre 10^{-3} até 10 (LIN et al., 1996). Já o parâmetro α tem como objetivo evitar largas oscilações do gradiente, partindo da ideia de dar certa inércia aos pesos da rede.

Outro fator importante que afeta a convergência do treinamento de uma RNA se encontra na escolha dos pesos iniciais da rede. Um boa prática de acordo com Wessels et al. (1992) é inicializar um dado peso w_{ij} , através da escolha aleatória de valores dentro do intervalo $[-3/\sqrt{b_i}, 3/\sqrt{b_i}]$, em que b_i representa a quantidade de sinais provenientes de elementos i que são entradas de um elemento j .

5 ANÁLISE E RESULTADOS

Neste capítulo encontram-se as principais considerações acerca dos modelos adotados bem como a apresentação e análise dos principais resultados dos casos de estudo. A Seção 5.1 apresentou as definições acerca da dinâmica do problema simulado. Na Seção 5.2 se encontram a descrição das variantes da rede PDNN e seus diferentes resultados. Na Seção 5.3, foi apresentado a comparação entre a abordagem de controle através da rede PDNN e o controlador PD. Em seguida, na Seção 5.4, os controladores foram comparados para o caso de falha em uma das rodas de reação. Finalmente, na Seção 5.6 se encontram os resultados comparativos entre rede PDNN e do PD para os casos com perturbações de torques externos instantâneos.

5.1 Definições do problema


Foi considerado um satélite com parâmetros de massa próximos aos do Amazônia 1, projetado, integrado e operado pelo Instituto Nacional de Pesquisas Espaciais (INPE) e colocado em órbita em 28 de fevereiro de 2021. A lei de controle para o PD implementado bem como os dados dos atuadores foram fornecidos cordialmente pela equipe da engenharia de sistemas da referida missão.

Seja o sistema fixo no corpo do satélite (b) com origem no seu centro de massa e eixos coordenados alinhados com os eixos principais do corpo, o tensor de inércia adotado e representado no sistema (b) é dado por:

$$I_b = \begin{pmatrix} 300,0 & 0 & 0 \\ 0 & 360,0 & 0 \\ 0 & 0 & 530,0 \end{pmatrix} [kg.m^2]. \quad (5.1)$$

A configuração adotada para o sistema das rodas de reação (w) em relação ao sistema fixo no corpo (b) pode ser visualizada pela Figura (5.1).

Figura 5.1 - Diagrama para uma configuração entre os sistemas de coordenadas (b) , (i) e as rodas de reação.



Como visto na Figura (5.1), as rodas de reação denotadas por RW-1, RW-2 e RW-3 têm seus eixos de rotação alinhados respectivamente com os eixos x_b , y_b e z_b do sistema (b) . Já o eixo de rotação da roda RW-4 se encontra alinhado com a direção diagonal do cubo com arestas definidas pelos eixos do sistema fixo. Para essa configuração a transformação entre o sistema (w) e o sistema (b) é expressa pela matriz $\mathbf{G}_{w,b}$, dada por:

$$\mathbf{G}_{w,b} = \begin{pmatrix} 1 & 0 & 0 & \frac{\sqrt{3}}{3} \\ 0 & 1 & 0 & \frac{\sqrt{3}}{3} \\ 0 & 0 & 1 & \frac{\sqrt{3}}{3} \end{pmatrix}. \quad (5.2)$$

A matriz de transformação dada pela Equação (5.2) é necessária para transformar os vetores representados no sistema (w) para o sistema (b) . A pseudo-inversa dessa matriz é obtida pela Equação (3.10) para realização da transformação inversa, ou seja, é utilizada para levar os vetores representados no sistema (b) para uma representação no sistema (w) .

Para a velocidade angular de saturação das rodas de reação foi assumido um valor absoluto de 6.000 *rpm*. Além disso, o valor absoluto do torque máximo fornecido por cada roda foi considerado de 0,075 *N.m*. Ainda, para modelo de atrito que considera apenas a componente cinética, adotamos o valor da constante de atrito viscoso como $b = 0.025/200\pi$ *N.m.s*. Já a função de erro de atitude, termo $e(k)$ na Equação (4.26), a qual deve ser minimizada através do algoritmo de *backpropagation*; foi definida como:

$$e(k) = \frac{1}{2}(1 - q_4(k))^2 + \frac{\zeta}{2}[\boldsymbol{\tau}_{net}^{(w)}(k)][\boldsymbol{\tau}_{net}^{(w)}(k)]^T. \quad (5.3)$$

Nesta última equação, o primeiro termo do lado direito leva em consideração o erro de atitude e o segundo considera o valor de torque líquido fornecido pelas rodas de reação. A minimização de ambos ocorre através da atualização dos pesos da rede ao longo do treinamento. O parâmetro ζ foi escolhido para ajustar a sensibilidade da função $e(k)$ em relação ao torque produzido pelas rodas de reação.

O algoritmo de *backpropagation* foi implementado com base nas funções da biblioteca de *machine learning*, Flux.jl (INNES et al., 2018; INNES, 2018) da linguagem de programação Julia (BEZANSON et al., 2017). Tal biblioteca permite a utilização de otimizadores para o cálculo do gradiente descendente. Entre eles o gradiente descendente estocástico, sendo um dos métodos mais populares de otimização em problemas em grande escala e amplamente estudado no campo de sistemas inteligentes, redes neurais profundas e aprendizagem de máquina (HE; LIU, 2018). Adotamos o otimizador chamado RMSProp na implementação do algoritmo de *backpropagation* através da biblioteca Flux.Jl. Tal otimizador estocástico de gradiente descendente é um dos mais usados no processo de treinamento de redes neurais (ZOU et al., 2019). Além disso, é mais indicado para redes com sinais recorrência (HINTON et al., 2012). Para os valores da constante de aprendizagem e de *momentum*, escolhemos: $\eta = 0.005$ e $\alpha = 0.9$, respectivamente.

Os resultados apresentados foram divididos de acordo com o estado de atitude inicial, mostradas na Tabela (5.1). Os valores iniciais de velocidade angular foram escolhidos aleatoriamente dentro do intervalo para o qual a soma das magnitudes das velocidades angulares em torno de cada eixo não ultrapassasse 0,024 *rad/s* em três eixos. Os estados iniciais de posição angular também foram definidos de forma aleatória entre $-\pi$ e π .

Tabela 5.1 - Condições iniciais da simulação de atitude.

Simulação	$(\phi[^\circ], \theta[^\circ], \psi[^\circ], \omega_{b_x}[\frac{rad}{s}], \omega_{b_y}[\frac{rad}{s}], \omega_{b_z}[\frac{rad}{s}])_{t=0}$
Caso 1	$(-85.94, -45.84, -22.92, 0.009, -0.002, 0.01)$
Caso 2	$(59.68, -53.95, 3.35, -0.013, 0.005, -0.005)$
Caso 3	$(-94.06, 65.41, -134.16, 0.009, -0.002, 0.01)$
Caso 4	$(-63.06, 40.11, 68.75, 0.009, -0.002, 0.01)$
Caso 5	$(166.16, 68.75, 40.12, -0.013, 0.005, -0.005)$
Caso 6	$(0.0, 85.94, 126.05, -0.002, 0.0015, 0.003)$

Com a finalidade de comparar os resultados do controle de atitude da abordagem defendida no presente trabalho com a abordagem convencional, foi considerada a seguinte lei de controle proporcional derivativa, cujo processo de sintonia foi realizado pela Engenharia de Satélites do INPE, que pode ser escrita em termos do torque comandado como:

$$\tau_{com} = \begin{pmatrix} 0,6253 & 0 & 0 \\ 0 & 0,6748 & 0 \\ 0 & 0 & 1,019 \end{pmatrix} \begin{bmatrix} q_1 \\ q_2 \\ q_3 \end{bmatrix} + \begin{pmatrix} 25,95 & 0 & 0 \\ 0 & 28,03 & 0 \\ 0 & 0 & 42,21 \end{pmatrix} \begin{bmatrix} \omega_x \\ \omega_y \\ \omega_z \end{bmatrix} [N.m] \quad (5.4)$$

5.2 Variantes da rede PDNN

Quatro estruturas diferentes para a rede PDNN foram investigadas. A nomenclatura de tais variantes são denominadas de acordo com o número de elementos de entrada e o número de elementos de saída da rede. Por exemplo, uma rede denominada PDNN-XY possui X entradas e Y saídas. Sendo assim, neste trabalho foram investigadas as seguintes variantes: PDNN-33, PDNN-63, PDNN-34 e PDNN-64. Suas estruturas podem ser visualizadas respectivamente nas figuras (5.2-5.5). A descrição de cada estrutura adotada se encontra respectivamente nas tabelas (5.2-5.5).

Quanto ao número de sinais de entrada, as redes apresentadas podem ser divididas em duas classes. A primeira é formada pelos elementos de um vetor 3×1 definido como o vetor \mathbf{p} , o qual contém os parâmetros modificados de Rodrigues. A outra classe consiste nas redes realimentadas pelos dados do vetor de estado completo, ou

seja, os parâmetros modificados de Rodrigues juntamente com os dados de velocidade angular em torno dos três eixos.

As redes investigadas também podem ser divididas em duas classes quanto ao número de saídas. Na primeira, consideramos a saída da rede como um vetor 3×1 , representando o torque comandado no sistema (b) , o qual *a posteriori* foi transformado para o sistema (w) através da pseudo-inversa dada pela Equação (3.51). Outra maneira de proceder considerou que a saída da rede forneceu um vetor 4×1 de torques comandados diretamente no sistema (w) . Nesse último caso, a transformação entre os sistemas ocorreu internamente no processamento da rede como discutido anteriormente na Seção (4.2).

5.2.1 PDNN-33

Figura 5.2 - Estrutura da rede PDNN-33.




Tabela 5.2 - Características da estrutura da rede PDNN-33.

Sinais de entrada	Vetor 3×1 com as componentes do vetor \mathbf{p}
Camada de entrada	- 3 neurônios P - função de ativação $\tanh()$
Camada interna	- 45 neurônios P - 45 neurônios D - função de ativação $\tanh()$
Camada de saída	a) 3 neurônios P b) função de ativação $\tanh()$ c) limita o torque comandado dentro do intervalo de saturação $[-0.075, 0.075]N.m$
Sinais de saída	Vetor 3×1 com as componentes do torque comandado no sistema b

5.2.2 PDNN-63

Figura 5.3 - Estrutura da rede PDNN-63.




Tabela 5.3 - Características da estrutura da rede PDNN-63.

Sinais de entrada	Vetor 6×1 com as componentes do vetor \mathbf{p} e ω_b
Camada de entrada	- 6 neurônios P - função de ativação $\tanh()$
Camada interna	- 90 neurônios P - 90 neurônios D - função de ativação $\tanh()$
Camada de saída	a) 4 neurônios P b) função de ativação $\tanh()$ c) limita o torque comandado dentro do intervalo de saturação $[-0.075, 0.075]N.m$
Sinais de saída	Vetor 3×1 com as componentes do torque comandado no sistema b

5.2.3 PDNN-34

Figura 5.4 - Estrutura da rede PDNN-34.

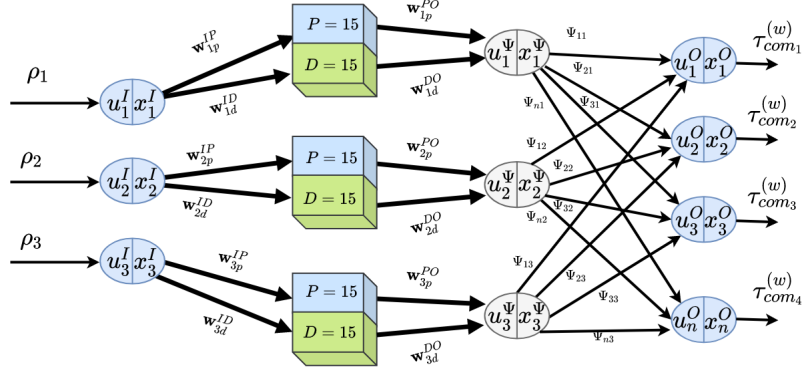


Tabela 5.4 - Características da estrutura da rede PDNN-34.

Sinais de entrada	Vetor 3×1 com as componentes do vetor \mathbf{p}
Camada de entrada	- 3 neurônio P - função de ativação $\tanh()$
Camada interna	- 45 neurônios P - 45 neurônios D - função de ativação $\tanh()$
Camada invisível	- Cada elemento desta camada recebe 2 sinais da camada interna - Os neurônios desta camada são inativos - Os sinais de saída desta camada são ponderados pelos elementos da pseudo-inversa. Que transforma a saída da rede do sistema b para o sistema w
Camada de saída	a) 4 neurônios P b) função de ativação $\tanh()$ c) limita o torque comandado dentro do intervalo de saturação $[-0.075, 0.075]N.m$
Sinais de saída	Vetor 4×1 com as componentes do torque comandado no sistema w

Inicialmente, as estruturas apresentadas foram pensadas a partir de uma rede mais simples capaz de executar a tarefa de controle de atitude em torno de apenas um eixo coordenado.

A escolha da estrutura básica da rede para o problema em um eixo foi determinada como sendo uma estrutura 1-30-1. Ou seja, um neurônio proporcional na camada de entrada, 30 neurônios na camada interna, dos quais 15 foram escolhidos como neurônios do tipo P e 15 do tipo D.

Devido a especificidade do problema aqui estudado, bem como as peculiaridades da implementação do algoritmo de treinamento, a tarefa de estimar o número de neurônios na camada interna consistiu na prática um processo arbitrário de tentativa e erro. No entanto, a escolha do número de neurônios na camada interna assumida teve como referência o trabalho de Carrara e Neto (1999), que utilizou uma MLP com 24 neurônios e 2576 pontos de treinamento para um erro de torque em regime permanente de 1 % do máximo valor disponível de torque.

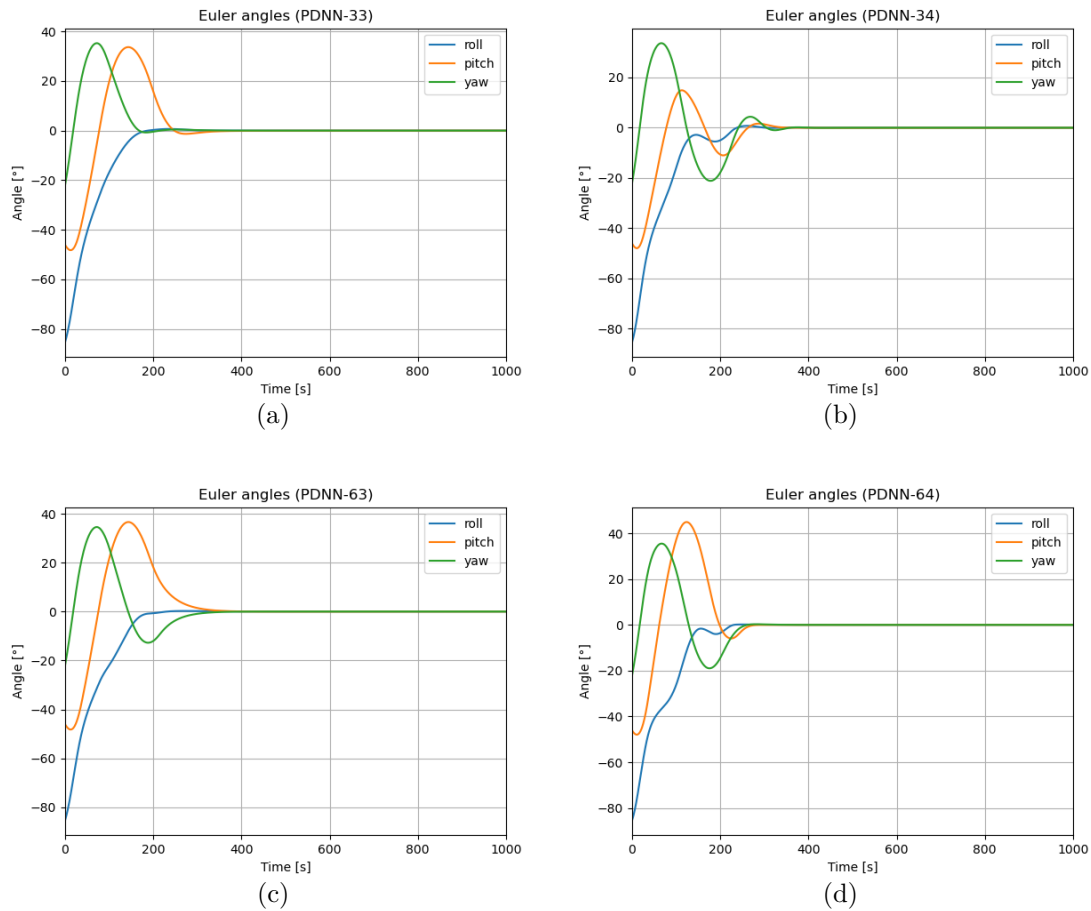
Após serem observados, para o controle em um eixo, valores de erro absoluto de atitude menores que $0,005^\circ$ em regime permanente e observado um treinamento com 10000 *epochs* realizável em um tempo razoável. Tal estrutura básica foi extrapolada e implementada em paralelo para controlar a atitude em cada um dos três eixos.

Muitos modelos de RNAs adotam a implementação de *bias* na modelagem do processamento de sinais dos neurônios. No entanto, para o problema tratado neste trabalho não houve vantagem em considerá-lo. Uma vez que a saída da rede foi definida como o torque de controle comandado, tal parâmetro deve ser nulo após o apontamento para manter a atitude desejada. Portanto, a adição do *bias* resulta no aumento do número de variáveis a serem definidas durante o *backpropagation*, o que retarda o treinamento e produz resultados com consideráveis valores de erro em regime permanente.

5.3 Comparação entre os controladores

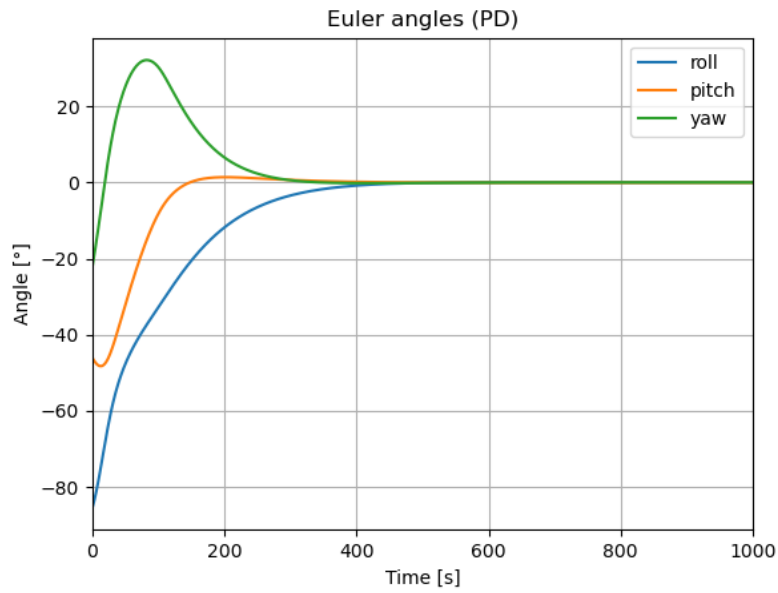
Com a finalidade de observar as diversas estruturas da rede PDNN empregadas como controladores de atitude, os resultados em termos dos ângulos de Euler para condições iniciais do Caso 1, são apresentados na Figura 5.6.

Figura 5.6 - Resultados em termos dos ângulos de Euler para as variantes da rede PDNN e com condições iniciais do Caso 1.



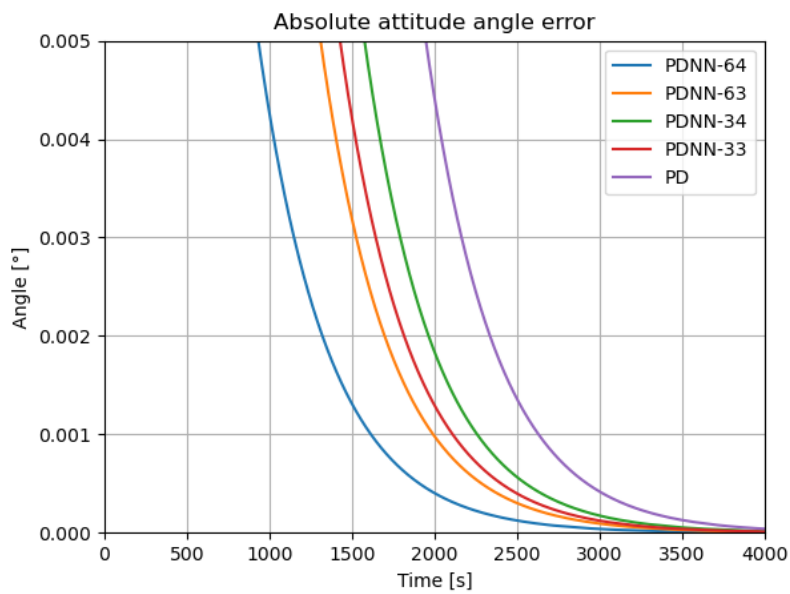
Pôde-se observar que a estabilização em três eixos do satélite ocorreu em instantes próximos em todos os casos. Além disso, o comportamento observado durante a resposta transitória indicou que as diferentes estruturas foram capazes de comandar diferentes sequências de torques de controle para realizarem a tarefa de controle. Para efeitos de comparação, na Figura 5.7 é mostrado o resultado para o ângulo de Euler para o mesmo caso anterior para o controlador PD sintonizado. Embora observado um menor efeito oscilatório no regime transitente para o caso do controlador PD, em termos de tempo de acomodação e sobre sinal não foi observado grandes diferenças diante das abordagens através da red PDNN.

Figura 5.7 - Resultados em termos dos ângulos de Euler para as variantes da rede PD e com condições iniciais do Caso 1.



A Figura 5.8 mostra os resultados anteriores do ponto de vista do erro absoluto em regime permanente.

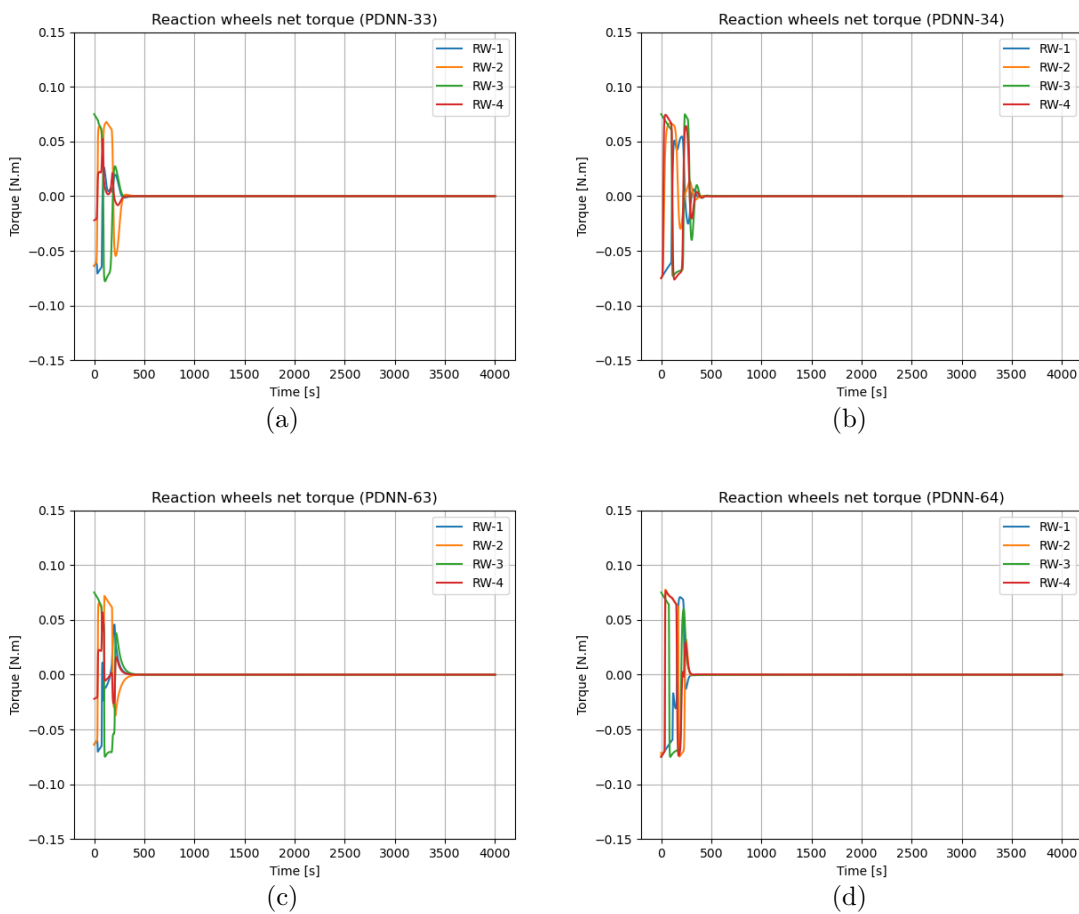
Figura 5.8 - Resultados em termos do erro absoluto de atitude para as variantes da rede PDNN e com condições iniciais do Caso 1.



Tais resultados evidenciam a capacidade das variantes da rede PDNN em praticamente anular o erro de atitude em três eixos ao longo das simulações. Além disso, mostram a superioridade dessas variantes em apontar e estabilizar o satélite com maior precisão em um menor tempo de voo.

Ainda para as condições iniciais do Caso 1, os resultados em termos dos torques de controle líquido fornecidos pelas rodas de reação são mostrados na Figura 5.9.

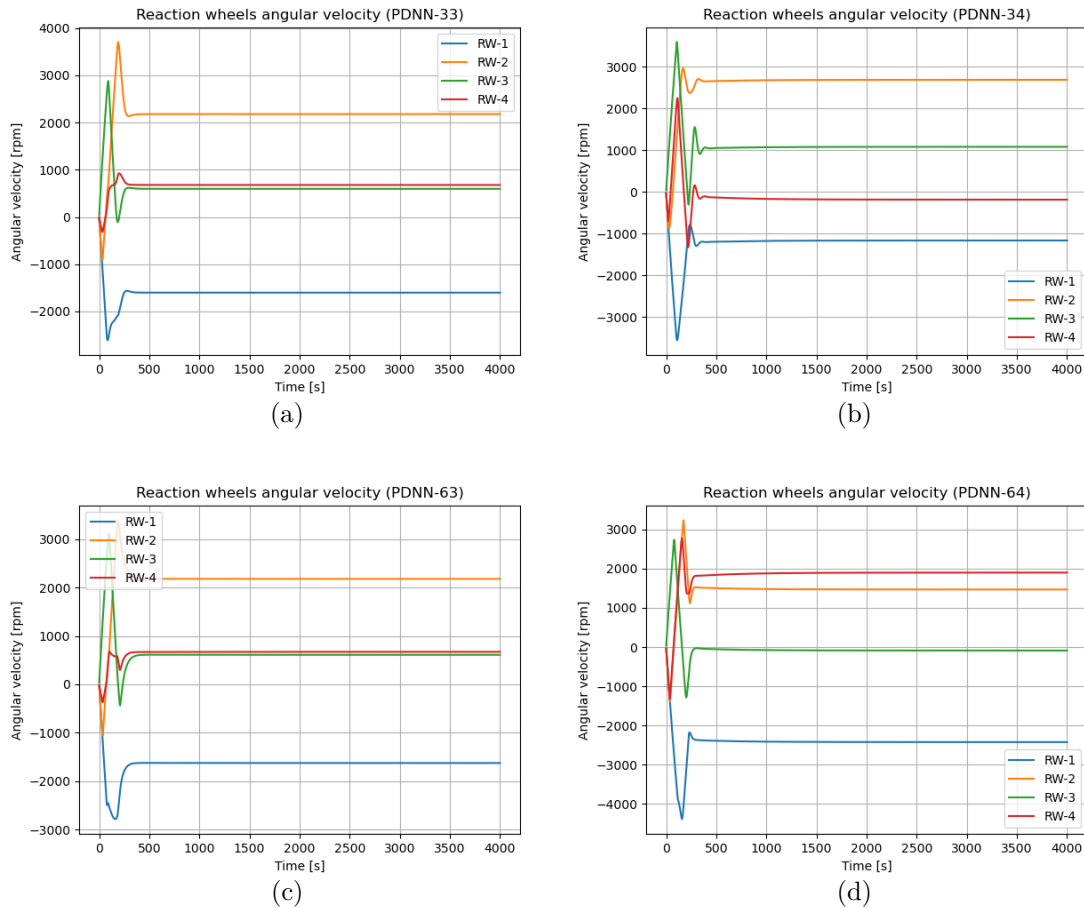
Figura 5.9 - Resultados em termos dos torques líquidos para a variantes da rede PDNN e com condições iniciais do Caso 1.



As diferentes curvas de torques mostram novamente que cada variante da rede PDNN foi capaz de resolver o mesmo problema de controle de diferentes maneiras após seus respectivos processos de treinamento. Conseqüentemente, diferentes curvas para a velocidade angular de cada roda de reação foram observadas entre as variantes,

considerando as mesmas condições iniciais, como mostrado na Figura 5.10.

Figura 5.10 - Resultados em termos das velocidades angulares das rodas de reação para as variantes da rede PDNN e condições iniciais do Caso 1.



Observa-se que em nenhum dos casos os valores de saturação das rodas de reação foram alcançados. Além disso, o módulo e sentidos da rotação de uma mesma roda podem variar entre as variantes PDNN pra manter o corpo do satélite apontado para o sistema de referência. Fato observado para o caso da roda RW-4, entre os resultados da rede PDNN-34 (Figura 5.11(b)) e PDNN-64 (Figura 5.11(d)).

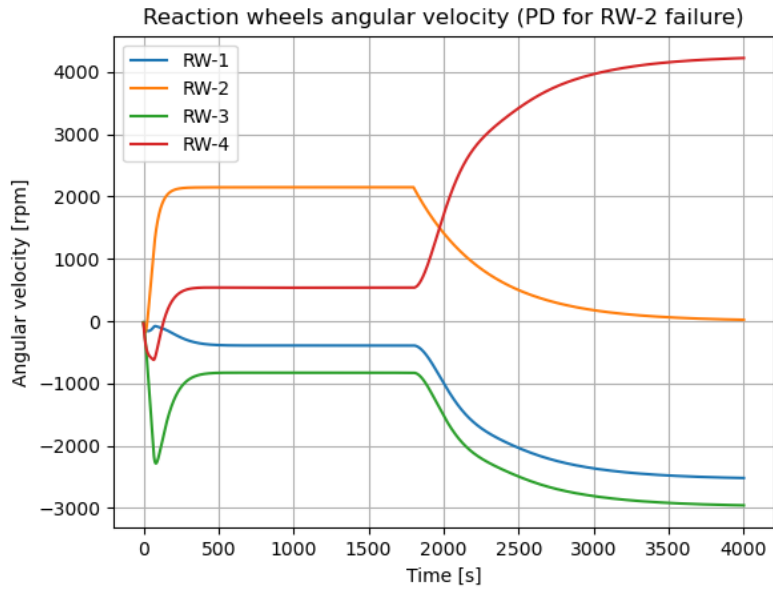
5.4 Comparação entre os controladores para falhas nas rodas de reação

Nesta seção, com a finalidade de se comparar as diferentes abordagens através das redes PDNN e a abordagem convencional de controle PD, foram apresentados alguns resultados de simulações de casos críticos em que ocorreram falhas em uma das rodas durante o voo. Tais resultados permitiram ainda observar a capacidade de generalização das redes PDNN como controladores, uma vez que estas foram treinadas uma única vez para um cenário sem falhas.


A falha foi simulada para ocorrer em um instante aleatório. Além disso, foi considerada a natureza mais comum na ocorrência de falhas em rodas de reação. Neste caso, por muitos fatores, o computador de bordo deixa de enviar sinais de comando para determinada roda de reação, que por sua vez deixa de contribuir com torques de controle ao sistema do corpo do satélite. Para que o controle de atitude não seja afetado, os torques fornecidos pelas demais rodas devem compensar essa perda.

A seguir são apresentadas algumas simulações para falhas na roda de reação RW-2, considerando as condições iniciais do Caso 2 da Tabela 5.1. Tais resultados são apresentados com a finalidade de elucidar o comportamento esperado para a atuação das rodas de reação na ocorrência da falha discutida anteriormente. Na Figura 5.11 é comparada a evolução da velocidade angular das rodas de reação para o controle através do controlador PD e da rede PDNN-64. Já do ponto de vista do torque de controle líquido, a comparação entre essas abordagens pode ser visualizada na Figura 5.12.

Figura 5.11 - (a) Evolução da velocidade angular das rodas para condições iniciais do Caso 2, com falha na roda RW-2 e considerando o controlador PD. (b) Evolução da velocidade angular das rodas para condições iniciais do Caso 2, com falha na roda RW-2 e considerando como controlador a rede PDNN-64.

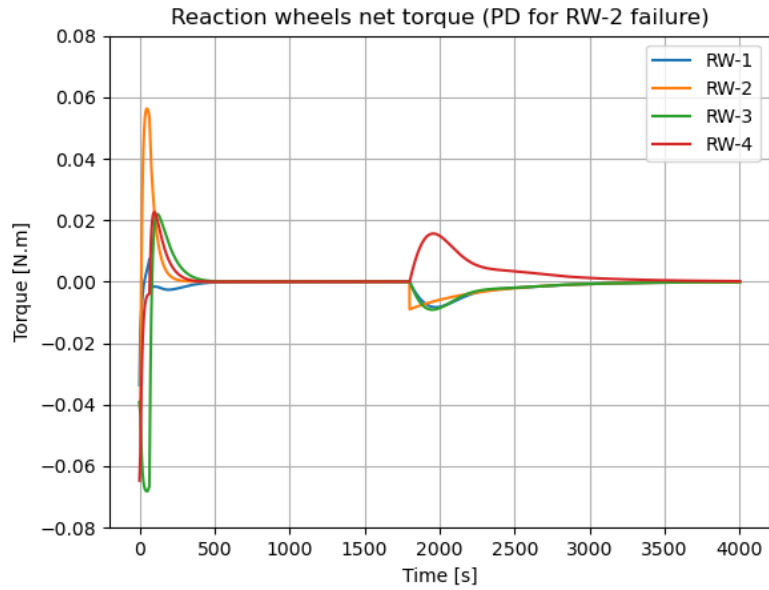


(a)

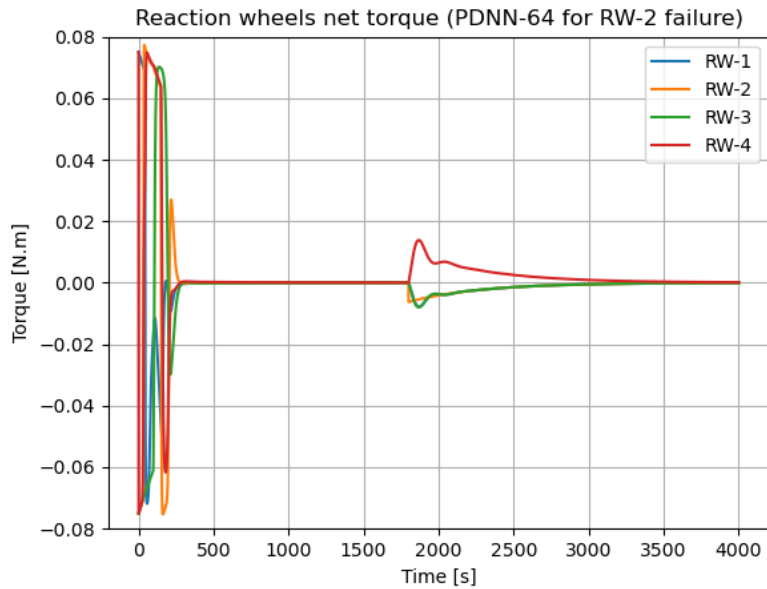


(b)

Figura 5.12 - (a) Evolução dos torques líquidos para condições iniciais do Caso 2, com falha na roda RW-2 e considerando o controlador PD. (b) Evolução dos torques líquidos para condições iniciais do Caso 2, com falha na roda RW-2 e considerando como controlador a rede PDNN-64.



(a)



(b)

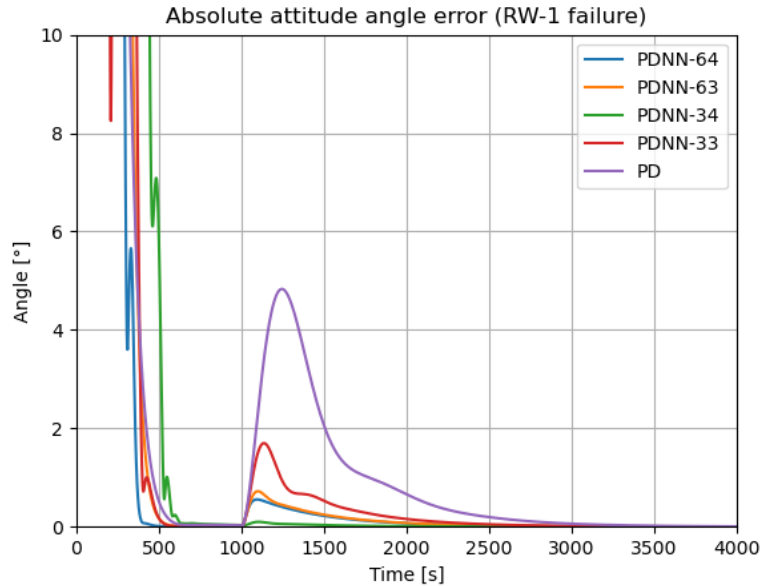
A Figura 5.12(a) permite observar o controle com o PD em termos da velocidade angular de cada roda de reação. Para este caso, nota-se que após a ocorrência da falha, no instante de 1800 segundos, a velocidade da roda RW-2 tende a zero. Já as rodas que permanecem atuantes são requisitadas alterando suas velocidades para distribuir o momento angular e manter o apontamento correto do sistema de coordenadas do satélite.

Na Figura 5.12(b) observa-se o mesmo comportamento descrito anteriormente, mas agora para a abordagem com a rede PDNN-64. Além disso, nota-se que antes da ocorrência da falha as velocidades de rotação necessárias para manter o apontamento são diferentes em comparação com os resultados na Figura 5.12(a). No entanto, após a falha as curvas tendem a valores próximos para corrigir a ausência da roda RW-2.

A Figura 5.13(a) e Figura 5.13(b) permitiram observar a mudança abrupta no valor de torque líquido fornecido pela RW-2 no momento da falha. Esta situação ocorreu em decorrência da presença da componente de torque oriunda do atrito cinético considerado, o qual passa a agir de forma predominante na RW-2 após a ocorrência da falha. Em contrapartida, as variações das velocidades angulares nas rodas remanescentes produziram torques de correção nos respectivos eixos, mantendo assim o corpo estabilizado e apontado na atitude desejada.

Com o objetivo de comparar o controlador PD e as variantes da rede PDNN no caso de falhas nas rodas de reação, foram consideradas simulações para as condições iniciais do Caso 3 da Tabela 5.1. Além disso, os resultados são apresentados em termos do erro de atitude absoluto e da evolução da velocidade angular da roda que falhou, obtidos de acordo com cada abordagem de controle. Na Figura 5.13, encontram-se os resultados para falha na roda RW-1.

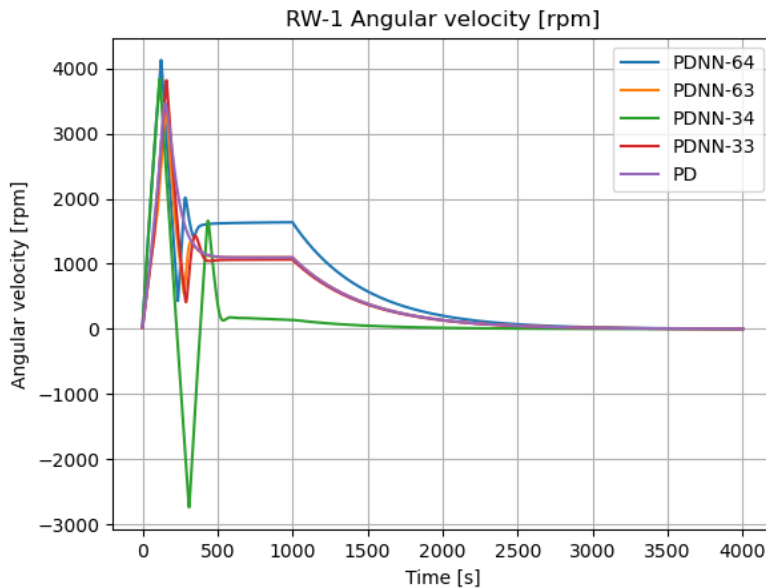
Figura 5.13 - Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-1 e com condições iniciais do Caso 3.



Observou-se que o controle através da rede PDNN-64 estabilizou mais rapidamente o satélite dentre as demais abordagens. Além disso, cada uma das abordagens apresentou um erro máximo de atitude específico após a ocorrência de uma mesma falha e para as mesmas condições. Nessa simulação, o controlador PD apresentou maior erro absoluto de atitude devido à perturbação causada pela falha. Em contrapartida, os controladores baseados em RNA's apresentaram uma melhor rejeição à falha.

Na Figura 5.14, a seguir, é possível comparar a evolução da velocidade angular da roda RW-1 em todas as abordagens de controle investigadas.

Figura 5.14 - Evolução da velocidade angular da roda RW-1 em uma situação de falha para diversas abordagens de controle e com condições iniciais do Caso 3.




Nota-se que a velocidade angular da roda RW-1, para o controle com a rede PDNN-34, se estabilizou em uma baixa velocidade para manter o apontamento requisitado. Desta forma, a falha de RW-1 não afetou de forma considerável a redistribuição das velocidades angulares das demais rodas para o caso do controle com rede PDNN-34. Fato que contribuiu com o pequeno valor de erro observado.

Já para a rede PDNN-64, observou-se que mesmo com uma velocidade angular da roda RW-1 em um valor relativamente alto após a estabilização, o erro absoluto de atitude não foi consideravelmente expressivo quando comparado com as outras abordagens após a falha da referida roda, como pôde ser visto anteriormente na Figura 5.13.

A Figura 5.14 mostra que as velocidades alcançadas pela roda RW-1 são praticamente as mesmas nos casos do controle com as redes PDNN-63, PDNN-33, e no caso do controle com o PD. Esse resultado foi observado nos demais casos que se seguem.

A seguir, na Figura 5.15 são apresentados os resultados para as simulações em que a roda RW-2 sofreu uma falha durante o voo.

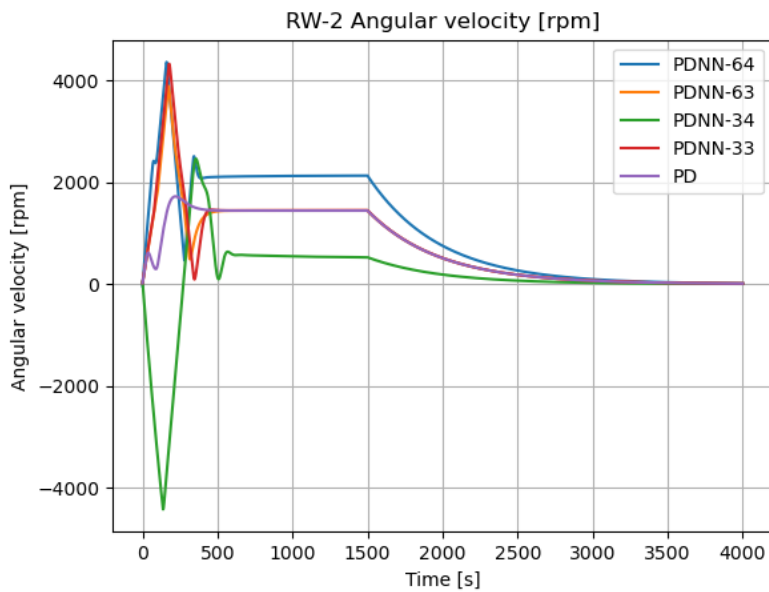
Figura 5.15 - Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-2 e com condições iniciais do Caso 3.



Nesse caso, as redes PDNN-34 e PDNN-64 apresentaram desempenhos praticamente equivalentes diante da falha na roda RW-2. Já as redes PDNN-63 e PDNN-33 apresentaram desempenhos intermediários. Por fim, a abordagem com o PD mostrou-se, mais uma vez, menos interessante do ponto de vista de rejeição à perturbação causada pela falha.

Comparando a evolução da velocidade angular da roda RW-2 entre as abordagens de controle, obtém-se os resultados mostrados na sequência pela Figura 5.16.

Figura 5.16 - Evolução da velocidade angular da roda RW-2 em uma situação de falha para diversas abordagens de controle e com condições iniciais do Caso 3.




Os resultados para a evolução da velocidade angular da roda RW-2 mostrados são semelhantes aos analisados anteriormente para o caso da roda RW-1.

Nota-se que para o caso da roda RW-2 em questão, a rede PDNN-34 requisitou maior velocidade do que no caso anterior para a roda RW-1 durante a estabilização do satélite. Após a falha, nota-se que o erro máximo de atitude para a rede PDNN-34 também aumentou de forma relativa, indicando que o erro de atitude foi mais sensível à redistribuição das velocidades das rodas após a falha para essa abordagem.

Os próximos resultados, mostrados na Figura 5.17, trazem o comportamento do erro absoluto de atitude entre os controladores na situação de falha da roda RW-3.


Figura 5.17 - Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-3 e com condições iniciais do Caso 3.



Diferentemente dos resultados anteriores, para a falha na roda RW-3 foi observado um melhor desempenho do controle com as redes PDNN-63 e PDNN-33. Já as redes PDNN-64 e PDNN-34 apresentaram valores de máximo erro de atitude maiores que a abordagem com o PD, logo após a falha.

A seguir, na Figura 5.18, pode-se comparar a evolução da velocidade angular da roda RW-3 para as diferentes abordagens.


Figura 5.18 - Evolução da velocidade angular da roda RW-3 em uma situação de falha para diversas abordagens de controle e com condições iniciais do Caso 3.



Observa-se que para as redes que obtiveram melhor desempenho neste caso (PDNN-63 e PDNN-33), a velocidade angular adquirida pela roda RW-3 antes da falha foi próxima de zero. O mesmo ocorreu para a abordagem com o PD. Deste modo, a perda da roda RW-3 não foi tão crítica em termos do valor do erro de atitude nesses casos, como evidenciado pela Figura 5.16.


Finalmente, a comparação entre as abordagens em um caso de falha na roda RW-4 é mostrada na Figura 5.19

Figura 5.19 - Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-4 e com condições iniciais do Caso 3.



Neste caso, observa-se um desempenho consideravelmente melhor da rede PDNN-64 em relação às outras abordagens. Analisando as velocidades angulares adquiridas pela roda RW-4 em cada abordagem através da Figura 5.20, mais uma vez é possível observar que um maior valor relativo da velocidade adquirida pela roda, implicou em um aumento considerável do erro de atitude após a falha no caso da abordagem com a rede PDNN-34. Mais um vez, analisando a Figura 5.20 juntamente com a Figura 5.19, também foi observado que as abordagens com as redes PDNN-63, PDNN-33, e o controlador PD, forneceram velocidades angulares aproximadas para a roda RW-4 antes da falha. No entanto, após a ocorrência da falha a redistribuição do momento entre as rodas remanescentes produziu menor erro de atitude nas abordagens neurais.

Figura 5.20 - Evolução da velocidade angular da roda RW-4 em uma situação de falha para diversas abordagens de controle e com condições iniciais do Caso 3.



Na Tabela 5.6 os controladores foram comparados em termos dos valores de erro absoluto de atitude máximo alcançado após as ocorrências de falhas em cada roda, para simulações com condições iniciais do Caso 3 da Tabela 5.1.

Tabela 5.6 - Máximo erro absoluto de atitude após a falha em cada uma das rodas de reação entre as diversas abordagens e considerando as condições iniciais do Caso 3.

Controlador	Erro [°]			
	RW-1	RW-2	RW-3	RW-4
PDNN-64	0,554	1,356	0,693	0,089
PDNN-63	0,722	2,253	0,040	0,403
PDNN-34	0,098	1,332	1,202	1,580
PDNN-33	1,698	3,382	0,082	0,692
PD	4,832	5,382	0,416	1,482

Em uma análise isolada dos resultados mostrados na Tabela 5.6 não foi possível

inferir qual a melhor abordagem em termos do erro máximo de atitude atingido após a falha, dado que a falha pode ocorrer em qualquer uma das rodas.

Do ponto de vista prático, torna-se interessante que o sistema de controle seja capaz de restaurar o estado de apontamento no menor tempo possível, ainda que apresente um alto valor de máximo para o erro após a falha. Sendo assim, foi analisado o desempenho em termos da integral do erro de atitude, ou seja, foi analisada a média do erro de atitude após a falha para cada cenário.

A seguir, na Tabela 5.7, são apresentados os valores médios do erro durante o intervalo entre a ocorrência da falha e o instante final da simulação de cada caso. Além disso, são apresentados os valores médios totais obtidos considerando todas as quatro rodas de reação em cada caso.


Tabela 5.7 - Erro absoluto de atitude médio após a falha em cada uma das rodas de reação entre as diversas abordagens e considerando as condições iniciais do Caso 3.

Controlador	Erro médio [°]				
	RW-1	RW-2	RW-3	RW-4	Total
PDNN-64	0,092	0,208	0,136	0,027	0,116
PDNN-63	0,104	0,404	0,009	0,141	0,164
PDNN-34	0,014	0,001	0,199	0,460	0,169
PDNN-33	0,222	0,533	0,019	0,218	0,248
PD	0,805	1,170	0,110	0,557	0,661

Os resultados da Tabela 5.7 permitiram inferir que para as condições assumidas o melhor desempenho global foi obtido pela abordagem com a rede PDNN-64, seguida das demais abordagens com as variantes da rede PDNN. Entre todas as estratégias, a abordagem com o PD convencional se mostrou inferior diante dos critérios avaliados.

Considerando agora as condições iniciais do Caso 4 da Tabela 5.1, foi possível realizar mais uma vez uma análise pelos mesmos critérios apresentados anteriormente em termos do erro absoluto de atitude e das velocidades angulares adquiridas pelas rodas de reação. A seguir na Figura 5.21 é mostrada a comparação entre as abordagens para o caso de falha na roda RW-1, para simulações com as novas condições iniciais.

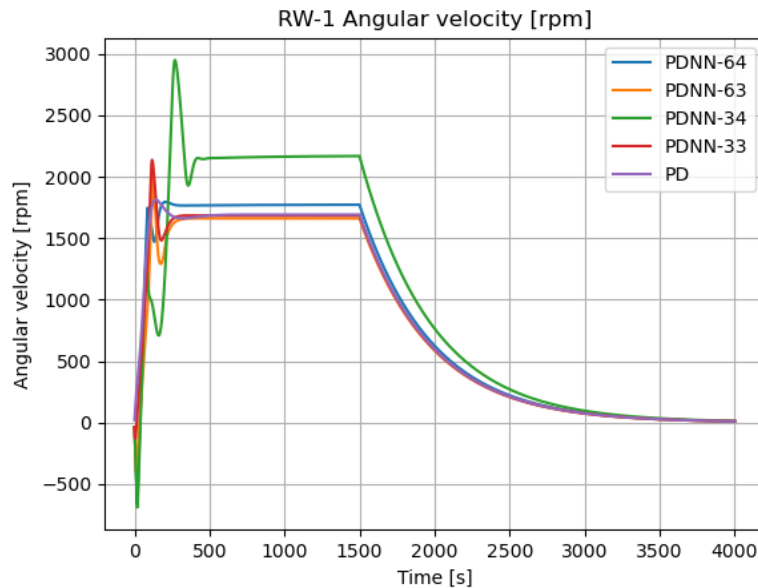
Figura 5.21 - Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-1 e com condições iniciais do Caso 4.



Mais uma vez, observou-se um melhor desempenho das abordagens com as variantes da rede PDNN em comparação com o controlador PD. Neste último caso, também se observou que a rede PDNN-64 foi relativamente mais exitosa na tarefa de controle dentre as cinco abordagens. Tal rede executou a estabilização do satélite mais rapidamente e rejeitou de maneira mais efetiva a perturbação causada pela falha da roda RW-1.

Na Figura 5.22 são mostradas as curvas para a velocidade angular da roda RW-1 referentes às respectivas abordagens.

Figura 5.22 - Evolução da velocidade angular da roda RW-1 em uma situação de falha para diversas abordagens de controle e com condições iniciais do Caso 4.



Observou-se que a velocidade angular adquirida pela roda RW-1 após a estabilização do satélite e antes da ocorrência da falha apresentou valores aproximados para as abordagens com as variantes PDNN-64, PDNN-63, PDNN-33 e controlador PD. Da comparação entre a Figura 5.22 e a Figura 5.13 observou-se ainda que para as condições do Caso 4, a curva de velocidade angular da roda RW-1 para a variante PDNN-64 se aproximou mais das curvas para PDNN-63, PDNN-33 e PD em relação aos resultados da condições do Caso 3. Por fim, a curva para a abordagem com a rede PDNN-34 apresentou maior diferença em relação as outras abordagens. Este padrão observado no comportamento da velocidade angular da RW-1 persistiu na análise para demais rodas durante as simulações com condições iniciais do Caso 4 da Tabela 5.1.

Seguindo com os resultados deste caso, a Figura 5.23 mostra a comparação entre as abordagens em termos do erro de atitude absoluto para um cenário de falha na roda RW-2. Mais adiante, é mostrada na Figura 5.24 a comparação do ponto de vista da evolução da velocidade angular da roda RW-2 para cada uma das abordagens.

Figura 5.23 - Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-2 e com condições iniciais do Caso 4.





Figura 5.24 - Evolução da velocidade angular da roda RW-2 em uma situação de falha para diversas abordagens de controle e com condições iniciais do Caso 4.



Através dos últimos resultados nota-se um melhor desempenho da variante PDNN-64 na tarefa de controle. Também pode-se observar, através da Figura 5.24, que apesar da abordagem com a variante PDNN-63 ter produzido um erro máximo de atitude relativamente maior que o produzido com o controlador PD após a falha, tal abordagem apresenta uma recuperação relativamente mais rápida da perturbação causada pela falha do que o controlador PD.

O padrão das curvas para a velocidade angular mostradas na Figura 5.24 são semelhantes aos resultados anteriores da falha na roda RW-1. No entanto, neste caso, o sentido de rotação da roda RW-2 foi sempre o mesmo entre todas as abordagens.

A comparação entre as abordagens para o caso de falha na roda RW-3 é mostrada em termos do erro de apontamento absoluto na Figura 5.25 e em função da velocidade angular, como mostrada na Figura 5.26.

Figura 5.25 - Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-3 e com condições iniciais do Caso 4.





Figura 5.26 - Evolução da velocidade angular da roda RW-3 em uma situação de falha para diversas abordagens de controle e com condições iniciais do Caso 4.



Neste caso de falha na roda RW-3, todas as abordagens com as variantes da rede PDNN obtiveram melhor desempenho quanto ao erro de atitude absoluto após a falha na roda. A rede PDNN-34 apresentou a melhor rejeição à perturbação dentre as abordagens com a rede PDNN.

Levando em consideração essa última observação juntamente com os resultados apresentados na Figura 5.26, nota-se que para a abordagem com a rede PDNN-34 a velocidade angular adquirida pela roda RW-3 foi consideravelmente menor dentre todas as abordagens, o que favoreceu o melhor desempenho na rejeição à falha observado para essa abordagem.

A mesma conclusão pode ser feita acerca dos resultados para as simulações em que foram consideradas uma falha na roda RW-4, mostrados a seguir na Figura 5.27 e Figura 5.28.

Figura 5.27 - Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-4 e com condições iniciais do Caso 4.





Figura 5.28 - Evolução da velocidade angular da roda RW-4 em uma situação de falha para diversas abordagens de controle e com condições iniciais do Caso 4.



Na Tabela 5.8, são mostrados os valores máximos atingidos pelo erro absoluto de atitude após a ocorrência da falha.

Tabela 5.8 - Máximo erro absoluto de atitude após a falha em cada uma das rodas de reação entre as diversas abordagens e considerando as condições iniciais do Caso 4.

Controlador	Erro [°]			
	RW-1	RW-2	RW-3	RW-4
PDNN-64	0,600	0,824	1,136	0,211
PDNN-63	1,244	1,829	0,678	0,310
PDNN-34	1,935	4,620	0,386	0,054
PDNN-33	3,136	2,658	1,448	0,535
PD	7,694	4,340	2,568	1,191

Mais uma vez foi comparado o erro de atitude médio após a falha em cada roda entre as diferentes abordagens e os resultados são mostrados na Tabela 5.9.

Tabela 5.9 - Erro absoluto de atitude médio após a falha em cada uma das rodas de reação entre as diversas abordagens e considerando as condições iniciais do Caso 4.

Controlador	Erro médio [°]				
	RW-1	RW-2	RW-3	RW-4	Total
PDNN-64	0,119	0,148	0,231	0,061	0,140
PDNN-63	0,196	0,390	0,162	0,102	0,212
PDNN-34	0,312	0,002	0,067	0,015	0,099
PDNN-33	0,441	0,506	0,336	0,159	0,360
PD	1,484	1,119	0,702	0,423	0,932


Observa-se que para essas condições, a rede PDNN-34 apresentou melhor desempenho médio global na rejeição da perturbação causada por falha em uma das quatro

rodas de reação.

Dos resultados apresentados anteriormente, pôde-se observar novamente certa vantagem das abordagens baseadas na rede PDNN em comparação com o controle PD, principalmente em termos da rejeição média das perturbações causadas por falha em uma das rodas e do tempo de acomodação para estabilização do satélite, antes e após a falha.

Para certas condições foram observados grandes diferenças no desempenho entre os controladores baseados na rede PDNN e o controlador PD. Como exemplo, as seguintes são apresentadas a comparação do controle de atitude com as abordagens PDNN-64 e PD convencional. Foram considerados os cenários de falha em cada uma das rodas e as condições iniciais do Caso 5 da Tabela 5.1. Na Figura 5.29 é mostrada a comparação em termos do erro absoluto de atitude entre as duas abordagens.

Figura 5.29 - Comparação da evolução do erro absoluto de atitude entre a abordagem de controle através da rede PDNN-64 e o controlador PD, para uma situação de falha na roda de reação RW-1 e com condições iniciais do Caso 5.

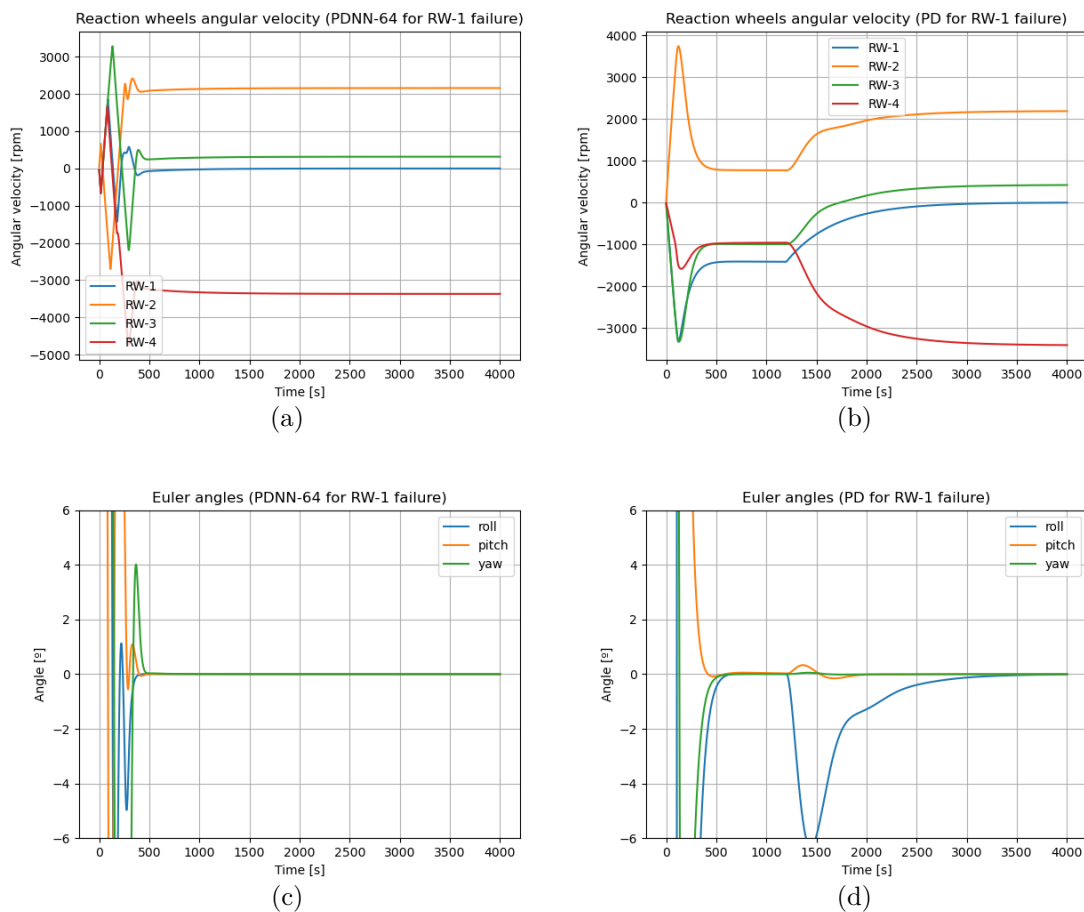


Para uma falha na roda RW-1 foi observado uma grande diferença na evolução do erro absoluto após a falha, entre o controlador PD e a rede PDNN-64 que rejeitou praticamente de forma total a perturbação causada em decorrência da falha. Também, mais uma vez, foi observado um menor tempo de acomodação para a abordagem com a rede PDNN-64, ou seja, o apontamento do satélite em três eixos

ocorreu de forma mais rápida para tal abordagem.

Na busca por compreender melhor a resposta do sistema aos efeitos causados pela falha, são mostrados na Figura 5.30 os resultados comparativos entre as abordagens PDNN-64 e a abordagem convencional com o PD em termos da evolução das velocidades angulares das rodas e dos ângulos de Euler para o cenário de falha na roda RW-1.

Figura 5.30 - Comparação da evolução das velocidades angulares das rodas de reação e ângulos de Euler entre a abordagem de controle através da rede PDNN-64 e o controlador PD, para uma situação de falha na roda de reação RW-1 e com condições iniciais do Caso 5.




Observa-se na Figura 5.31(a) a evolução da velocidade angular de cada roda de reação para a abordagem com a rede PDNN-64. Devido ao fato da velocidade angular da roda RW-1 se estabilizar em um valor relativamente baixo durante o apontamento do satélite na atitude desejada, a falha dessa mesma roda não foi tão relevante e

o sistema manteve sua resposta praticamente inalterada após a falha. Já para a abordagem com o PD, mostrada na Figura 5.31(b), nota-se que a falha da roda RW-1 causou um maior efeito de perturbação nas velocidades das demais rodas na tentativa do sistema de controle de compensar a perda de uma delas.

Os efeitos da redistribuição de momento entre as rodas na abordagem com a rede PDNN-64 são praticamente irrelevantes do ponto de vista do ângulos de Euler, como visto na Figura 5.31(c). Já na Figura 5.31(d), referente aos resultados obtidos com o controlador PD, nota-se um grande erro de apontamento em torno do eixo x_b do sistema fixo no satélite em relação ao sistema inercial. Além disso, nota-se também uma perturbação de menor intensidade sobre a evolução dos demais ângulos de Euler.

Seguindo a mesma estrutura de apresentação dos resultados, a seguir são mostradas as comparações entre as duas abordagens em questão para o cenário de falha na roda RW-2 (Figura 5.31 e Figura 5.32), RW-3 (Figura 5.33 e Figura 5.34) e RW-2 (Figura 5.35 e Figura 5.36).

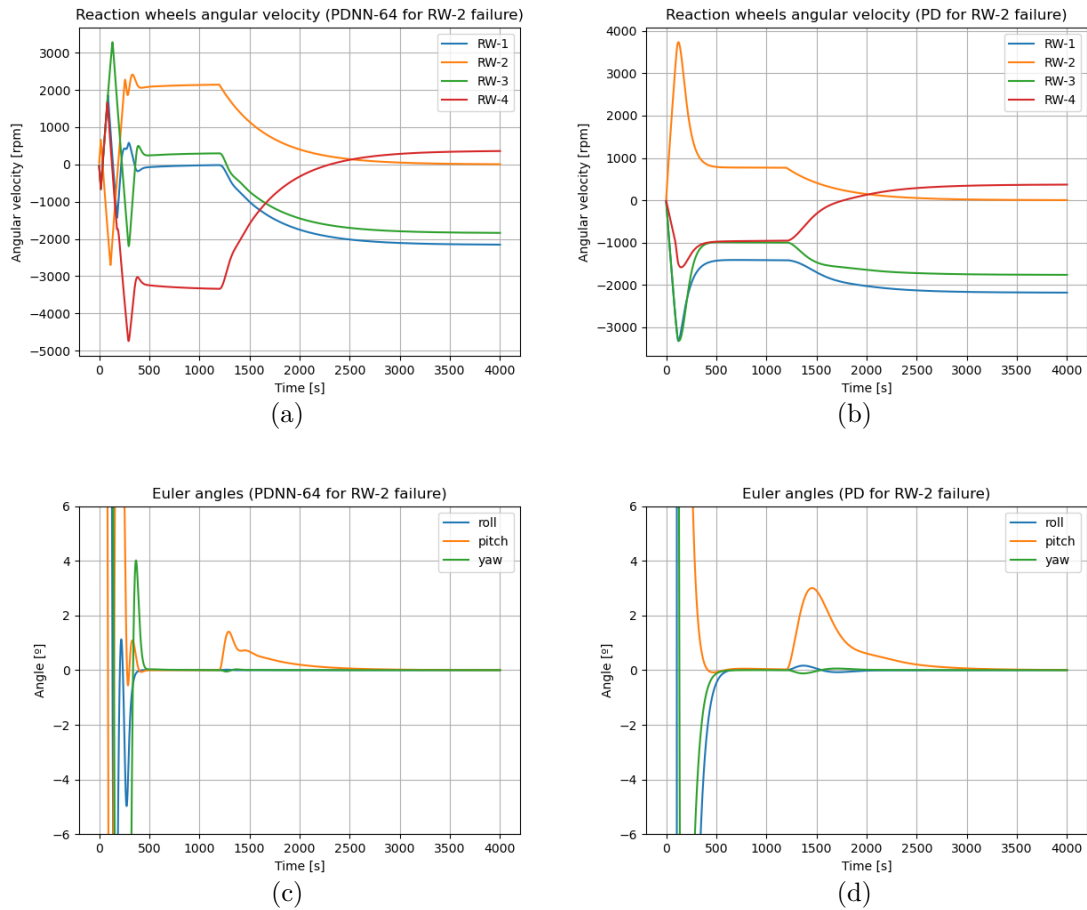
Figura 5.31 - Comparação da evolução do erro absoluto de atitude entre a abordagem de controle através da rede PDNN-64 e o controlador PD, para uma situação de falha na roda de reação RW-2 e com condições iniciais do Caso 5.



Para o caso de falha na roda RW-2, mais uma vez, a abordagem através da rede PDNN-64 apresentou melhor rejeição à perturbação causada pela falha, como visto


na Figura 5.31.

Figura 5.32 - Comparação da evolução das velocidades angulares das rodas de reação e ângulos de Euler entre a abordagem de controle através da rede PDNN-64 e o controlador PD, para uma situação de falha na roda de reação RW-2 e com condições iniciais do Caso 5.



Comparando a Figura 5.33(a) com a Figura 5.33(b), nota-se que a velocidade na qual a roda RW-2 se estabilizou antes da falha foi maior na abordagem com a rede PDNN-64 do que para a mesma roda na abordagem com o controlador PD. Apesar disso, a redistribuição das velocidades entre as rodas após a falha não implicou em uma perturbação considerável sobre a atitude para a abordagem com a PDNN-64 quando comparada com a abordagem convencional através do PD. Tal fato pode ser observado na comparação entre a Figura 5.33(c) e a Figura 5.33(d).

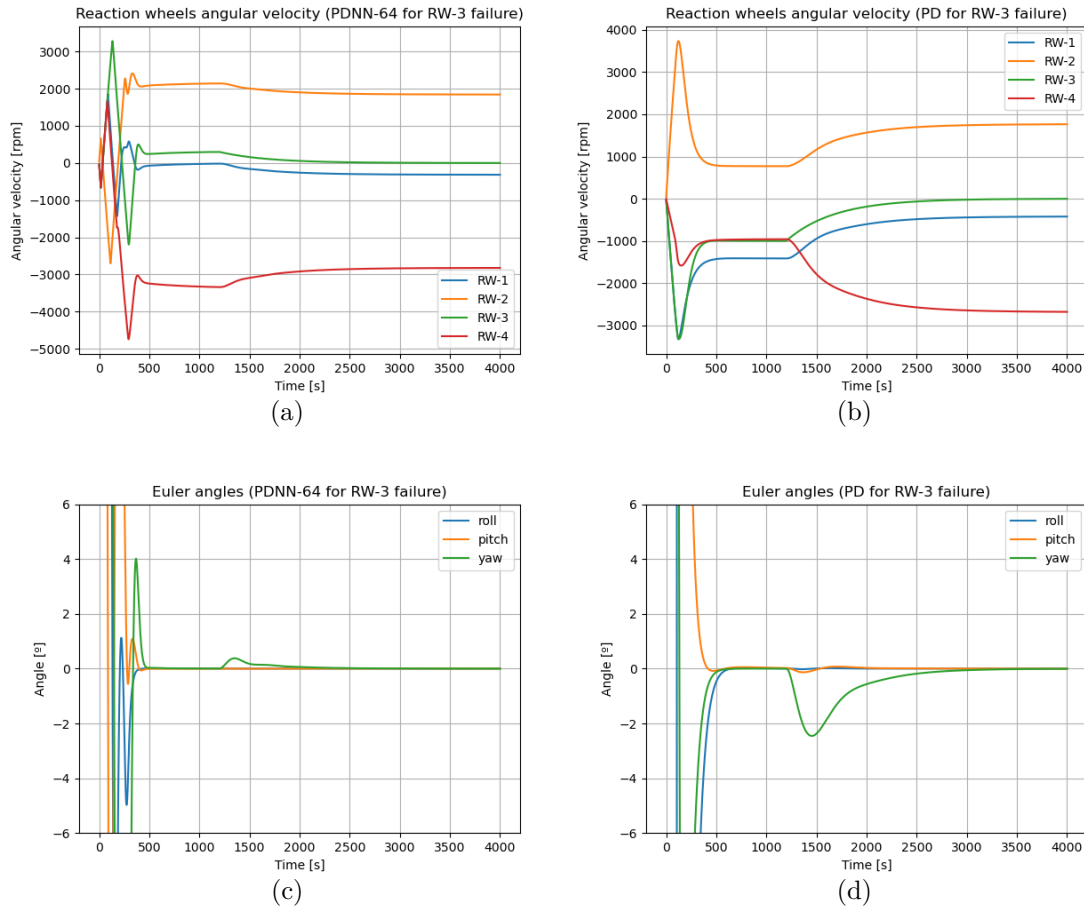
Figura 5.33 - Comparação da evolução do erro absoluto de atitude entre a abordagem de controle através da rede PDNN-64 e o controlador PD, para uma situação de falha na roda de reação RW-3 e com condições iniciais do Caso 5.



Nessas condições apresentadas, uma falha na roda RW-3 também se mostrou menos crítica do ponto de vista do erro absoluto de atitude para o controle com a rede PDNN-64. Uma simples análise qualitativa das curvas da Figura 5.33 mostra ainda que a atitude do satélite é corrigida mais rapidamente após a falha para a rede PDNN-64 como controlador, além de apresentar um menor erro médio ao longo do período de correção da atitude.

A seguir, são mostradas as simulações considerando a falha da roda RW-3 que permitem comparar as distintas abordagens.

Figura 5.34 - Comparação da evolução das velocidades angulares das rodas de reação e ângulos de Euler entre a abordagem de controle através da rede PDNN-64 e o controlador PD, para uma situação de falha na roda de reação RW-3 e com condições iniciais do Caso 5.




Na Figura 5.35(a), nota-se que na abordagem com a rede PDNN-64 não houve uma redistribuição das velocidades das rodas tão significativas quanto as mostrada na Figura 5.35(b) na situação em que a roda RW-3 falhou.

Na comparação entre a Figura 5.35(c) e a Figura 5.35(d) é confirmado mais uma vez o melhor desempenho da abordagem com a rede PDNN-64 em relação ao controlador PD sintonizado, para os conjuntos de condições simuladas.

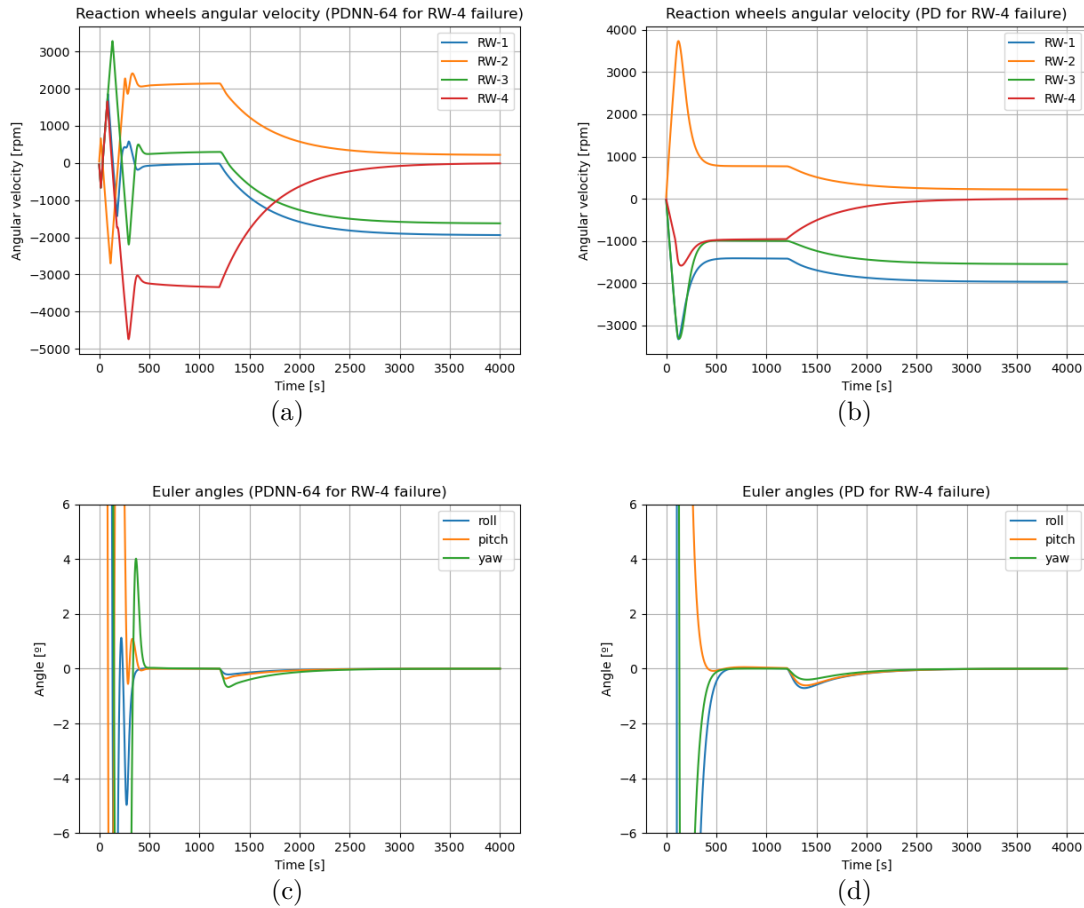
São mostrados na sequência os resultados comparativos para o cenário de falha na roda RW-4 através da Figura 5.35 e Figura 5.36.

Figura 5.35 - Comparação da evolução do erro absoluto de atitude entre a abordagem de controle através da rede PDNN-64 e o controlador PD, para uma situação de falha na roda de reação RW-4 e com condições iniciais do Caso 5.



Para falha na roda RW-4, a diferença entre o erro do valor máximo do erro absoluto de atitude após a falha foi menor entre as duas abordagens, em relação aos outros cenários analisados.

Figura 5.36 - Comparação da evolução das velocidades angulares das rodas de reação e ângulos de Euler entre a abordagem de controle através da rede PDNN-64 e o controlador PD, para uma situação de falha na roda de reação RW-4 e com condições iniciais do Caso 5.



Comparando os resultados na Figura 5.37(a) com os resultados da figura Figura 5.37(b), nota-se que na primeira abordagem o valor da velocidade angular da roda RW-4 é maior que a velocidade comanda para a mesma roda pelo controle PD, durante a fase de apontamento anterior à falha.

Analisando a Figura 5.37(a) em comparação com a Figura 5.37(b), observa-se que a perturbação causada pela falha afetou a evolução da atitude, representada em ângulos de Euler, de forma semelhante em ambas abordagens de controle.

Ainda, devido ao fato do eixo de rotação da roda RW-4 possuir componentes alinhadas aos demais eixos coordenados do sistema fixo no satélite, é esperado que a falha nessa roda induza uma distribuição maior do erro de atitude em três eixos. Essa

característica pôde ser observada na comparação da Figura 5.37(a) e Figura 5.37(b) com os resultados equivalentes obtidos para a falha nas rodas RW-1, RW-2 e RW-3.

A Tabela 5.10 mostra a comparação quantitativa dos resultados apresentados para o valor do máximo erro absoluto de atitude após a falha em cada uma das rodas .

Tabela 5.10 - Máximo erro absoluto de atitude após a falha da roda de reação entre a abordagem de controle através da rede PDNN-64 e o controlador PD, e considerando as condições iniciais do Caso 5.

Falha	Erro [°]	
	PD	PDNN64
RW-1	6,337	0,004
RW-2	3,006	1,408
RW-3	2,457	0,378
RW-4	1,017	0,781

A Tabela 5.11 a seguir, mostra a comparação para o erro absoluto de atitude médio após a falha em cada uma das rodas, juntamente com a média total obtida em nas quatro rodas de reação em cada abordagem.

Tabela 5.11 - Erro absoluto de atitude médio após a falha em cada uma das rodas de reação entre as diversas abordagens e considerando as condições iniciais do Caso 5.

Controlador	Erro médio [°]				
	RW-1	RW-2	RW-3	RW-4	Total
PDNN-64	0.001	0,188	0,055	0,131	0.094
PD	1,116	0,562	0,482	0,213	0,593

Dos resultados observados, destaca-se o fato de que, sob certas condições, a abordagem com a rede PDNN-64 foi capaz de manter o erro de atitude em cerca de 10^{-3} [°] após a perturbação devido à falha em uma das rodas. Para o mesmo caso,

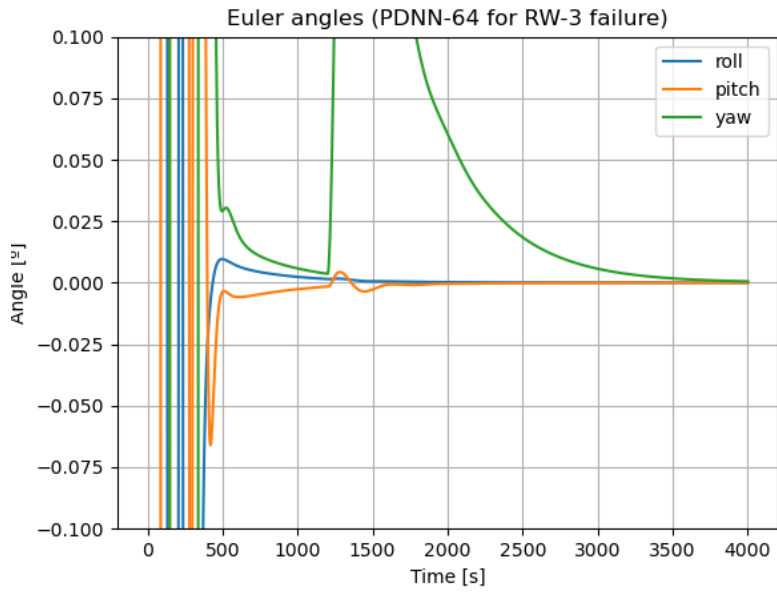
o resultado do controlador PD apresentou uma amplitude média do erro absoluto de aproximadamente $1,116$ [°] após a falha, podendo chegar ao valor máximo de erro em três eixos de $6,337$, como observado nos resultados anteriores para falha em RW-1.

A falha em uma roda de reação sempre produzirá uma redistribuição do momento através da variação das velocidades angulares entre todas as quatro rodas para uma nova configuração que ainda permita o apontamento desejado. Portanto, o erro de atitude será notado nos três eixos que definem a orientação do sistema fixo no corpo em relação ao sistema de coordenadas inercial adotado.


Dos resultado obtidos, foi possível observar ainda que na abordagem com a rede PDNN-64, a falha em uma roda não produziu grandes desvios no apontamento referente às direções ortogonais coincidentes aos eixos de rotação das rodas de reação remanescentes. Em outras palavras, além da rede PDNN-64 produzir um menor erro absoluto de atitude após a falha, tal abordagem também mostrou a capacidade de rejeitar de forma mais efetiva os efeitos da perturbação nas direções ortogonais ao eixo de rotação da roda que falhou.

Para ilustrar esse fato, é mostrado a seguir na Figura 5.37 o mesmo resultado apresentado em termos dos ângulos de Euler na Figura 5.34 com uma escala ampliada, permitindo verificar os desvios na atitude em torno dos eixos associados com roda RW-1 e RW-2, para uma falha na roda RW-3.

Figura 5.37 - Comparação dos ângulos de Euler entre a abordagem de com a rede PDNN-64 e o controlador PD para falha na roda de reação RW-3 no instante de 1200 segundos, considerando as condições iniciais do Caso 5.



(a)



(b)

Nota-se que na abordagem com a rede PDNN-64 a falha na roda RW-3 não promoveu grandes desvios nos movimentos de rolamento (*roll*) e arfagem (*pitch*), sendo a perturbação predominantemente no movimento de guinada (*yaw*) do satélite, o qual representa o movimento de rotação em torno do eixo z_b e que coincide com o eixo de rotação da roda RW-3 que falhou. Já no mesmo resultado para o PD, observou-se uma maior perturbação em torno dos eixos ortogonais ao eixo relativo à roda que falhou.

5.5 Comparação entre os controladores para falhas nas rodas de reação em condições de cruzeiro

Os resultados apresentados na seção anterior permitiram comparar os desempenhos entre as abordagens de controle através das diferentes rede do tipo PDNN e do controlador convencional PD durante uma manobra na qual o satélite parte de uma atitude arbitrária para uma condição de apontamento. No entanto, como visto, cada estratégia simulada apresentou uma sequência de ações de controle distinta, fazendo com que as velocidades de rotação de cada uma das rodas de reação em regime permanente adquirissem determinados valores e padrões que se distinguem entre cada abordagem. Assim, ao avaliar o comportamento para o erro de atitude após uma falha em uma determinada roda para tais casos é importante notar que tais diferenças observadas são esperadas uma vez que as redistribuições do momento angular entre as rodas também são diferentes.

Na busca de uma comparação mais precisa entre os desempenhos das abordagens, são apresentados nesta seção os resultados para falhas em uma das rodas de reação em situações de voo em que o satélite está previamente apontado. Neste caso, as velocidades das rodas de reação são colocadas na chamada condição de cruzeiro, a qual consiste numa condição em que as velocidades das rodas são constantes e determinadas de forma a garantirem o apontamento na maior parte do tempo de operação do satélite.

Portanto, nas simulações presentes nesta seção as velocidades das rodas de reação são equivalentes entre todas as abordagens de controle em regime permanente. Sendo assim, a simulação de falha em uma dessas rodas permite uma melhor interpretação do desempenho obtido entre as abordagens no que diz respeito ao erro de apontamento após a falha.


As condições para as simulações em regime de cruzeiro são apresentadas a seguir na Tabela 5.12.

Tabela 5.12 - Condições em regime de cruzeiro.

Parâmetro	Valor
Velocidade de rotação RW-1	1000 <i>rpm</i>
Velocidade de rotação RW-2	1000 <i>rpm</i>
Velocidade de rotação RW-3	1000 <i>rpm</i>
Velocidade de rotação RW-4	$-1000\sqrt{3}$ <i>rpm</i>
$e_{att} = [\mathbf{p}^T \boldsymbol{\omega}_b^T]^T$	$[0 \ 0 \ 0 \ 0 \ 0 \ 0]$

Na Figura 5.38 é mostrada a primeira comparação entre os controladores para o caso de falha na roda RW-1 em regime de cruzeiro. Em seguida, a Figura 5.39 mostra a comparação dos valores de velocidade de rotação assumidos pela a roda RW-1 em cada abordagem.


Figura 5.38 - Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-1 e com condições de cruzeiro.



Observou-se novamente o melhor desempenho das abordagens em que foram utilizadas as variantes da rede PDNN em relação ao controlador convencional PD na rejeição à perturbação causada pela falha da roda RW-1, além de restabelecerem o apontamento mais rapidamente do que o controle PD. Destaca-se ainda o desempenho da abordagem com a PDNN-64, a qual apresentou menor valor de erro absoluto

de atitude após a falha.

Figura 5.39 - Evolução da velocidade angular da roda RW-1 em uma situação de falha para diversas abordagens de controle e com condições de cruzeiro.



Os resultados para as velocidades de rotação da roda RW-1 mostram que a velocidade da roda que falhou foi equivalente para todas as abordagens no momento da falha. O que permitiu uma comparação mais precisa quanto à rejeição às falhas causadas pela perda de uma dada roda.

Os desempenhos dos controladores para as condições de cruzeiro considerando uma falha na roda RW-2 são mostrados a seguir do ponto de vista do erro absoluto de atitude (Figura 5.40) e velocidade de rotação da RW-2 (Figura 5.40).

Figura 5.40 - Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-2 e com condições de cruzeiro.

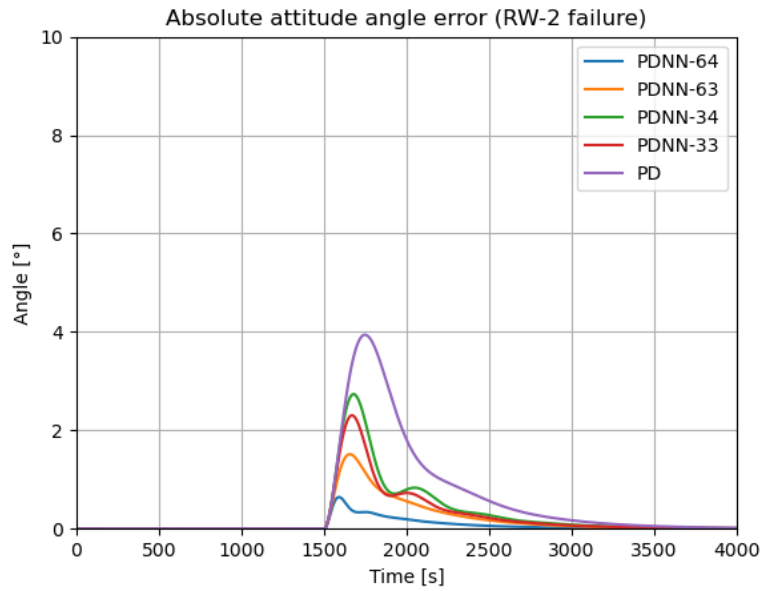




Figura 5.41 - Evolução da velocidade angular da roda RW-2 em uma situação de falha para diversas abordagens de controle e com condições de cruzeiro.



Para o caso de falha na roda RW-2 destacou-se mais uma vez o desempenho do controle com a rede PDNN-64 entre as outras variantes da rede PDNN, sendo que em todas elas o erro absoluto de atitude após a falha foi menor que o erro apresentado com a abordagem através do controlador PD, dadas as mesmas condições de velocidade de rotação da roda que falhou.

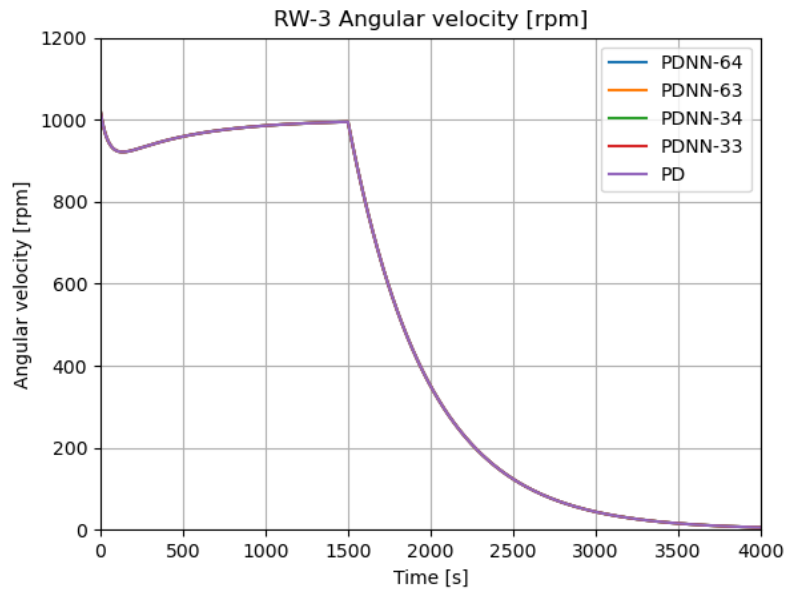
Na sequência são mostrados os resultados comparativos para o caso de falha na RW-3 em condições de cruzeiro, para o erro absoluto de atitude (Figura 5.42) e velocidade de rotação da roda RW-3 (Figura 5.42).

Figura 5.42 - Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-3 e com condições de cruzeiro.



Neste último caso, as diferenças entre os erros de atitude após a falha entre as abordagens foram notadamente menores. No entanto, mais uma vez, as abordagens com as variantes PDNN se mostraram mais eficazes na rejeição à falha em relação a abordagem com o controlador PD. Além disso, numa primeira análise qualitativa a abordagem com a variante PDNN-63 destacou-se entre as demais.

Figura 5.43 - Evolução da velocidade angular da roda RW-3 em uma situação de falha para diversas abordagens de controle e com condições de cruzeiro.



Mais uma vez o comportamento para a velocidade de rotação da roda que falhou se mostrou dentro do esperado.

Finalmente, a Figura 5.44 mostra os resultados comparativos do ponto de vista do erro de atitude absoluto e a Figura 5.44 mostra os resultados para a velocidade de rotação da roda RW-4, considerada nesses casos coma a roda que apresentou a falha.

Figura 5.44 - Evolução do erro absoluto de atitude para as diversas abordagens de controle em uma situação de falha na roda de reação RW-4 e com condições de cruzeiro.


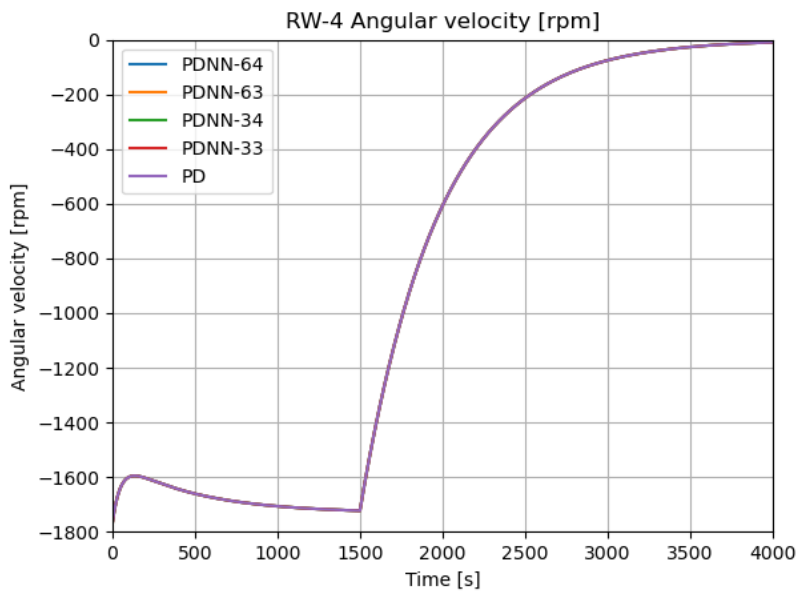


Figura 5.45 - Evolução da velocidade angular da roda RW-4 em uma situação de falha para diversas abordagens de controle e com condições de cruzeiro.



Observou-se com este último resultado que as abordagens de controle com as variantes da rede PDNN apresentaram melhores resultados do ponto de vista do erro de atitude absoluto após a ocorrência de falha em uma das rodas de reação, quando comparadas com a abordagem convencional através do controlador PD. Além disso, neste último caso para falha na roda RW-4, observou-se uma menor diferença nas respostas entre as abordagens através da rede PDNN.

Mais uma vez, foi observado o resultado esperado para o comportamento da velocidade angular da roda que falhou nas condições de cruzeiro em todas as abordagens.

A Tabela 5.13 mostra a comparação quantitativa dos resultados apresentados anteriormente considerando os valores máximos de erro absoluto de atitude observados após a falha em cada uma das rodas para todas as abordagens.

Tabela 5.13 - Máximo erro absoluto de atitude após a falha em cada uma das rodas de reação entre as diversas abordagens nas condições de cruzeiro.

Controlador	Erro máximo [°]				
	RW-1	RW-2	RW-3	RW-4	média
PDNN-64	0,331	0,643	1,235	0,399	0,652
PDNN-63	0,637	1,514	0,678	0,488	0,829
PDNN-34	0,848	2,735	0,918	0,860	1,340
PDNN-33	1,537	2,303	1,424	0,847	1,528
PD	4,212	3,942	2,607	1,876	3,159

Também foi comparado o erro de atitude médio após a falha em cada roda entre as diferentes abordagens e os resultados são mostrados na Tabela 5.14.

Tabela 5.14 - Erro absoluto de atitude médio após a falha em cada uma das rodas de reação entre as diversas abordagens nas condições de cruzeiro.

Controlador	Erro médio [°]				
	RW-1	RW-2	RW-3	RW-4	Total
PDNN-64	0,067	0,097	0,194	0,076	0,108
PDNN-63	0,113	0,274	0,125	0,105	0,154
PDNN-34	0,144	0,001	0,120	0,157	0,105
PDNN-33	0,248	0,359	0,253	0,165	0,256
PD	0,877	0,813	0,538	0,437	0,666

Dos resultados mostrados na Tabela 5.13, pode-se inferir que entre as abordagens consideradas os controladores PDNN-64 e PDNN-63 obtiveram respectivamente maior sucesso em relação ao erro máximo de atitude atingido em um instante após a falha. Já dos resultados da Tabela 5.14, pode-se concluir que as abordagens através das variantes PDNN-34 e PDNN-64 rejeitaram a perturbação de forma mais eficaz dentre todas as abordagens simuladas. Uma vez que as respostas de controle dessas variantes forneceram menores valores médios para o erro de atitude após a ocorrência da falha em uma roda de reação.

Na próxima seção foram analisados e comparados alguns resultados entre as simulações com a rede PDNN-64 e o controlador PD, sendo considerado a presença torque externo instantâneo sobre o corpo satélite.

5.6 Comparação entre os controladores para perturbações de torque externo

Considerando para um dado instante um vetor de torque representado no sistema fixo no corpo, como τ_{dist} na Equação (3.10), pode-se simular uma perturbação externa instantânea agindo sobre o satélite.

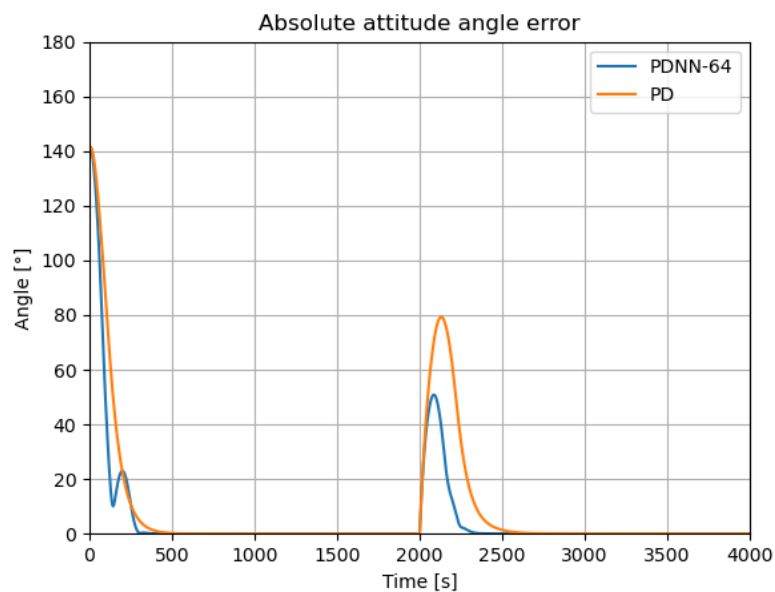
Tal perturbação pode ocorrer na situação em que uma força externa age de maneira instantânea em torno do centro de massa do satélite. Por exemplo, seja um satélite equipado com propulsores para correção orbital, a resultante das forças fornecidas pelo acionamento de tais propulsores em uma manobra pode gerar um torque externo resultante que age de maneira à perturbar o apontamento do satélite.

A seguir, na busca de investigar e comparar os resultados entre as abordagens de controle para essa condição, foi considerado de forma arbitrária o seguinte vetor de torque externo instantâneo:

$$\tau_{dist} = \begin{pmatrix} 1, 0 \\ 5, 0 \\ 10, 0 \end{pmatrix} N.m. \quad (5.5)$$

Na Figura 5.46 é mostrada uma comparação entre a rede PDNN-64 e o controlador PD, considerando as condições iniciais do Caso 6 da Tabela 5.1.

Figura 5.46 - Comparação da evolução do erro de atitude entre os controladores PDNN-64 e PD para uma perturbação instantânea em 2000 segundos (Caso 6).



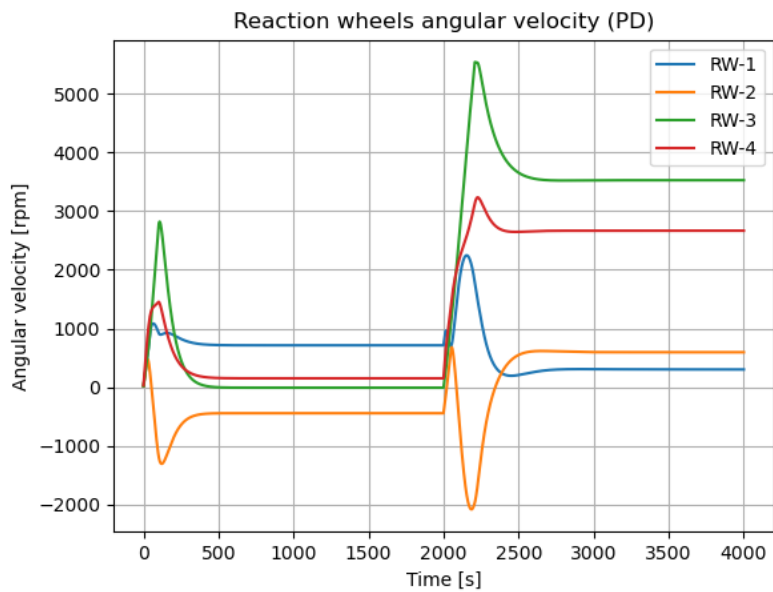
O resultado observado sugere mais uma vez uma melhor rejeição à perturbações para uma abordagem de controle através de uma RNA. Uma vez que a amplitude máxima do erro de atitude foi 51.60° para o caso com a variante PDNN-64 e de 79.30° para o PD.

Nesta simulação foram considerados altos valores para os torques de perturbação, principalmente em torno dos eixos y e z do sistema de referência fixo no corpo do

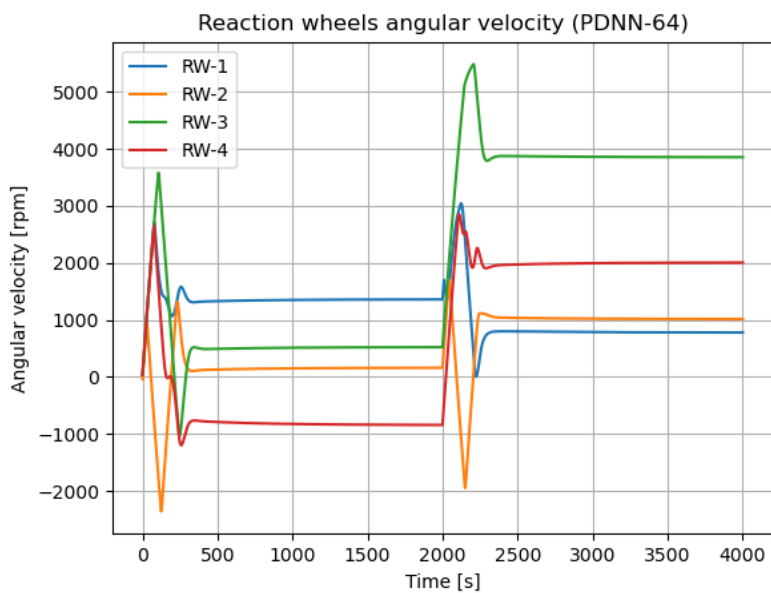
satélite. Embora tais valores não sejam representativos, as simulação apresentadas forneceram um bom indicativo do comportamento de uma abordagem com a rede PDNN em relação à resposta obtida com o controle PD.

Os resultados em termos dos torques líquidos fornecido pelas rodas de reação são mostrados na Figura 5.48 e em termos das velocidades das rodas na Figura 5.47.

Figura 5.47 - (a)Evolução das velocidades angulares das rodas de reação com o controle através da PDNN-64 para o caso com torque perturbativo (Caso 6). (b) Evolução das velocidades angulares das rodas de reação com o controle PD para o caso com torque perturbativo (Caso 6).



(a)




(b)

Figura 5.48 - (a) Evolução dos torques líquidos fornecidos pelas rodas de reação com o controle através da rede PDNN-64 para o caso com torques perturbativos (Caso 6). (b) Evolução dos torques líquidos fornecidos pelas rodas de reação com o controle PD para o caso com torque perturbativo (Caso 6).



(a)



(b)

Nota-se que em ambos os casos mostrados na Figura 5.48(a) e Figura 5.48(b), as rodas de reação atuaram de forma instantânea no sentido de redistribuir o momento angular para manterem o satélite apontado na orientação desejada. Nesta situação, observa-se uma grande variação da velocidade angular das rodas até o erro de atitude ser anulado novamente. Nota-se ainda, nessa segunda fase transiente, uma maior suavidade nas curvas dos resultados para o controlador PD em relação aos resultados da PDNN-64.

Da comparação entre a Figura 5.49(a) e Figura 5.49(b) pode-se observar que a rede PDNN-64 requisitou maiores torques das rodas de reação após a perturbação. O que permitiu manter o erro de atitude em um nível relativamente menor em relação a abordagem com o PD convencional.

Na seção a seguir, são apresentados os resultados comparativos para a situação de torque externo agindo sobre o satélite, visando estabelecer uma relação de desempenho entre as abordagens investigadas no presente trabalho.


5.7 Comparação entre os controladores para perturbações de torque externo instantâneo em condições de cruzeiro

Nesta seção são apresentados os resultados comparativos entre as abordagens para as condições de cruzeiro da Tabela 5.12 e considerando a ação de um torque externo instantâneo arbitrário. Visando simular valores de torques instantâneos mais representativos, foram considerados valores dentro da faixa encontrada nos propulsores de correção orbital do satélite amazônia um AMAZONIA-1, que por sua vez são alinhados com os eixos y e z do sistema de referência fixo no referido satélite.

A seguir, na Figura 5.49 são mostradas as curvas para evolução do erro de apontamento considerando um torque externo instantâneo dado por:

$$\boldsymbol{\tau}_{dist} = \begin{pmatrix} 0, 0 \\ 0, 75 \\ 1, 5 \end{pmatrix} N.m. \quad (5.6)$$

Figura 5.49 - Comparação da evolução do erro de atitude entre os controladores para uma perturbação instantânea em condições de cruzeiro.




Observa-se que para a perturbação simulada houve um desvio máximo do apontamento aproximado entre as abordagens, exceto para o controle com a variante PDNN-64, o qual produziu um desvio máximo abaixo de 2^{deg} nos três eixos. Além disso, pode-se observar um retorno à atitude de desejada mais rapidamente para as abordagens com as variantes da rede PDNN.

A Figura 5.50 mostra a evolução do erro de apontamento considerando um novo torque externo instantâneo dado por:

$$\boldsymbol{\tau}_{dist} = \begin{pmatrix} 0, 0 \\ -1.75 \\ -0.75 \end{pmatrix} N.m. \quad (5.7)$$

Figura 5.50 - Comparação da evolução do erro de atitude entre os controladores para uma perturbação instantânea em condições de cruzeiro.

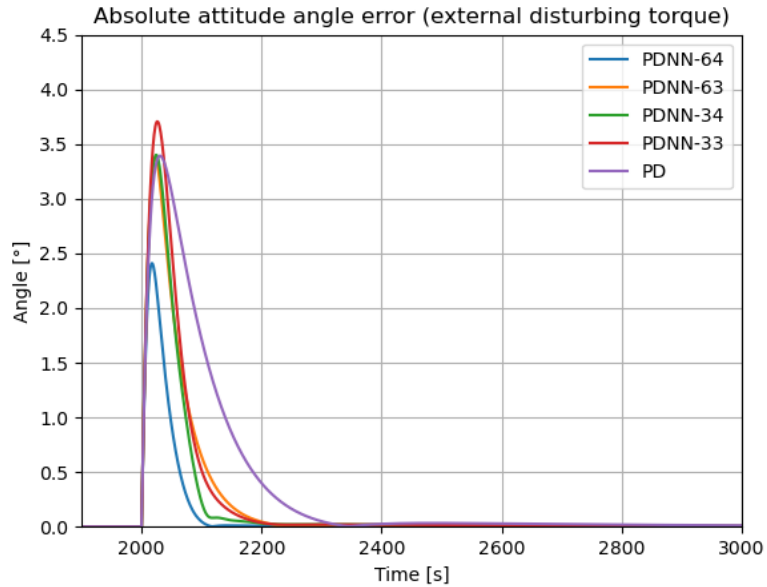


Neste caso, observou-se novamente um melhor desempenho relativo da variante PDNN-64, tanto na rejeição à perturbação, o que é evidenciado por um menor sobre-sinal, quanto no tempo de acomodação. Embora as variantes PDNN-34 e PDNN-33 apresentem neste caso um maior valor no desvio de atitude em relação ao PD, ambas abordagens foram capazes de restabelecer a atitude desejada mais rapidamente que a abordagem convencional.

A Figura 5.51 mostra mais um caso em que um torque instantâneo age sobre o satélite. Neste caso, o vetor de torque simulado é dado por:

$$\boldsymbol{\tau}_{dist} = \begin{pmatrix} 0.0 \\ 1.5 \\ 1.5 \end{pmatrix} N.m. \quad (5.8)$$

Figura 5.51 - Comparação da evolução do erro de atitude entre os controladores para uma perturbação instantânea em condições de cruzeiro.



Mais uma vez, pode-se observar um melhor desempenho das abordagens com as variantes PDNN em relação ao PD. Seja do ponto de vista do máximo sobre-sinal após a perturbação ou seja pelo menor tempo de acomodação para ações de controle comandadas pelas RNAs investigadas.

Na seção a seguir foram apresentadas as principais conclusões com base nos resultados observados. Além disso, novos temas para trabalhos futuros são levantados a fim de dar continuidade ao estudo desenvolvido no presente trabalho.

6 CONCLUSÕES

Uma RNA composta por neurônios proporcionais e derivativos, denominada *proportional derivative neural network* PDNN, foi capaz de apontar e estabilizar em três eixos um satélite equipado com quatro rodas de reação. Tal rede foi treinada para produzir um efeito global de ações de controle de forma à substituir a função do controlador em um sistema de controle de atitude convencional.

Quatro diferentes estruturas da rede PDNN puderam ser simuladas e comparadas com as ações de controle oferecidas pela abordagem convencional do controlador proporcional derivativo PD, previamente sintonizado e validado para as mesmas condições aqui assumidas. As variantes da rede PDNN se distinguiram quanto à quantidade de estados de entrada e saída. Também, quanto ao número de neurônios da camada interna.

As variantes da rede PDNN investigadas e as principais diferenças entre elas são:

- PDNN-33: possui três entradas em termos dos parâmetros modificados de Rodrigues e três saídas em termos dos torques comandados no sistema (*b*).
- PDNN-34: possui três entradas em termos dos parâmetros modificados de Rodrigues e quatro saídas em termos dos torques comandados no sistema (*w*).
- PDNN-63: possui três entradas em termos dos parâmetros modificados de Rodrigues, mais três entradas de velocidades angulares, e três saídas em termos dos torques comandados no sistema (*b*).
- PDNN-64: possui três entradas em termos dos parâmetros modificados de Rodrigues, mais três entradas de velocidades angulares, e quatro saídas em termos dos torques comandados no sistema (*w*).

Portanto, foram investigadas redes com entradas apenas de posição angular (parâmetros modificados de Rodrigues) e outras com entradas de posição e velocidade angular, ou seja, o estado completo. Em ambos os casos, os estados de entrada são referentes ao sistema de coordenadas fixo no centro de massa do satélite, sistema (*b*), o qual gira em relação ao sistema de coordenadas inercial (*i*).

Já em relação à quantidade de sinais de saída das redes, duas estratégias foram analisadas. Na primeira, foi considerado que a rede forneceu valores de torques de

comandos diretamente no sistema (b), em seguida esses torques foram transformados através da chamada pseudo-inversa, que transformou os torques comandados para o sistema formado pelos eixos de rotação das rodas de reação, sistema (w). A segunda estratégia foi realizar tal transformação de coordenadas através de modificações no processamento do algoritmo que modelou a rede.

Devido ao fato da construção da rede proposta direcionar cada elemento de entrada, referente a cada eixo, para cada um dos 30 neurônios da camada intermediária (15 proporcionais e 15 derivativos), a quantidade de neurônios nessa camada para as redes PDNN-63 e PDNN-64 foi de 180 neurônios no total. Já as redes PDNN-33 e PDNN-34 foram constituídas de 90 neurônios na camada interna.

As diferentes abordagens descritas foram simuladas e analisadas em termos dos principais parâmetros que descrevem o movimento de atitude. Com base na precisão do erro de atitude em regime permanente observada, foi possível inferir que todas as variantes PDNN obtiveram sucesso em substituir o controlador de atitude convencional em malha fechada.

Na busca de identificar e estabelecer uma relação de desempenho entre as variantes PDNN e o controlador PD, foram comparadas as abordagens em situações críticas, como a falha em uma das rodas de reação e também para um caso em que foi considerado uma ação perturbadora externa sobre o satélite.

Nas simulações com falha em uma das rodas, observou-se que a abordagem através das rede PDNN-64 e PDNN-34 obtiveram um melhor desempenho com base no valor máximo atingido pelo erro absoluto de atitude e o seu valor médio observado após a ocorrência da falha. No geral, as redes PDNN-63 e PDNN-33 obtiveram desempenhos intermediários nos casos investigados. Já o controlador convencional PD obteve um pior desempenho em termos da rejeição à perturbação causada pela falha.

Com base nos resultados das diferentes estruturas da rede PDNN, pôde-se inferir que a transformação dos torques comandados pela rede entre os sistemas (b) e (w), mostrou-se mais interessante quando realizada internamente pela rede através da implementação da dita *camada invisível*.

Além disso, os resultados mostraram uma boa capacidade das redes que possuem como entrada o vetor de estado incompleto, ou seja, apenas os dados de posição angular, em executarem o controle para casos críticos de falha. Em muitos casos as redes PDNN-34 e PDNN-33 obtiveram melhor ou equivalente desempenho em

rejeitar a falha em uma das rodas de reação em relação à a bordagem convencional.

Dentre as abordagens investigadas, destacou-se a rede PDNN-64 que apresentou um menor tempo de acomodação. Além disso, baseado em sua comparação com controlador PD, foi observado que dada a falha em uma roda, que tem seu eixo de rotação alinhado com um eixo do sistema (*b*), a correção da falha pelo controlador não provocou grandes variações no apontamento em torno dos demais eixos ortogonais ao eixo associado à falha. Ou seja, a rede PDNN-64 foi capaz de contornar a falha de uma roda redistribuindo de forma mais suave o momento entre as rodas remanescentes.

A PDNN-64 conseguiu em certos casos rejeitar a perturbação causada pela falha em uma das rodas praticamente de forma total em comparação com a abordagem convencional através do controlador PD. Em um dos casos apresentados, o erro de atitude médio observado após em falha em uma das rodas foi cerca de seis vezes menor para a abordagem com a PDNN-64 em relação ao mesmo caso com a abordagem convencional.

Na busca de verificar o poder de interpolação da rede PDNN-64 em relação à abordagem convencional, foi simulado e comparado um caso em que uma perturbação de torques externos agiu de forma instantânea sobre o satélite. Outra vez, a rede PDNN-64 mostrou maior superioridade quanto à evolução do erro de atitude após a perturbação.

Em termos gerais, os resultados observados evidenciaram as características de generalização e adaptação das RNAs para realizar a tarefa de controle. Uma vez que as redes foram treinadas para condições iniciais diferentes e para cenários de voo em que não foram consideradas nenhuma falha ou perturbação.

A maior contribuição deste trabalho foi verificar as potenciais vantagens no uso de abordagens com RNAs para o problema de controle de atitude, principalmente nos casos em que as abordagens convencionais não fornecem bons resultados. Observou-se a possibilidade de superar o desempenho de um controlador convencional, baseado em métodos mais sofisticados, através de um controlador constituído de um RNA simples, submetida à um processo de treinamento que não requereu grande capacidade de processamento ou tempo de execução.

Entretanto, por se tratar de uma abordagem não convencional do ponto de vista das teorias de controle, a abordagem aqui apresentada requer um maior aprofundamento teórico, principalmente no sentido de uma investigação acerca da estabilidade do

sistema de controle que contém uma RNA em sua estrutura. São listados a seguir este e outros temas que podem contribuir com escopo de futuros trabalhos.

- Desenvolver um estudo da relação entre a quantidade de neurônios da camada interna da rede PDNN e a precisão do erro absoluto de apontamento. Em seguida, propor uma rede PDNN ideal com o menor número de neurônios possível que satisfaça os requisitos de precisão;
- Investigar acerca da estabilidade do sistema de controle que possui uma rede PDNN ideal como controlador;
- Desenvolver um algoritmo de *backpropagation* otimizado para a rede PDNN;
- Realizar um estudo da carga computacional exigida pela implementação de um controlador através da rede PDNN em simulações mais completas e representativas.

Além das possibilidades citadas e com desenvolvimento atual de tecnologias que permitem a miniaturização dos satélites e seus componentes para fins de pesquisa, pode-se vislumbrar através deste trabalho a implementação da rede PDNN em um computador de bordo de *microsats* ou *nanosats* para uma futura validação em voo da abordagem aqui defendida.

Por fim, o trabalho aqui apresentado contribuiu, ainda que de forma pontual e documental, com as atividades atuais e futuras do Instituto Nacional de Pesquisas Espaciais (INPE) e do curso de pós-graduação em Engenharia e Tecnologias Espaciais (ETE), ambas referências no desenvolvimento técnico e científico desta área tão importante e que repercute diretamente na vida dos brasileiros e em sua longa jornada pela emancipação e soberania científica.

REFERÊNCIAS BIBLIOGRÁFICAS

- AJORKAR, A.; FAZLYAB, A.; SABERI, F. F.; KABGANIAN, M. Design of an adaptive-neural network attitude controller of a satellite using reaction wheels. **Journal of Applied and Computational Mechanics**, v. 1, n. 2, p. 67–73, 2014. 14
- ALBUS, J. S. A new approach to manipulator control: the cerebellar model articulation controller (cmac). **Journal of Dynamic Systems, Measurement, and Control**, v. 97, n. 3, p. 220–227, 1975. 11
- ASHBY, W. ROSS. **design for a brain**. [S.l.]: Chapman and Hall, London, 1952. 8
- ÅSTRÖM, K. J. Adaptive control. In: HINRICHSEN D.; PRITCHARD, A. J. E. (Ed.). **Mathematical system theory**. [S.l.]: Springer, 1991. p. 437–450. 2
- BARTO, A. G. Some learning tasks from a control perspective. In: NADEL L.; STEIN, D. L. E. (Ed.). **1990 Lectures in complex systems**. [S.l.]: CRC Press, 2018. p. 195–224. 48
- BARTO, A. G.; ANANDAN, P. Pattern-recognizing stochastic learning automata. **IEEE Transactions on Systems, Man, and Cybernetics**, n. 3, p. 360–375, 1985. 11
- BARTO, A. G.; JORDAN, M. I. Gradient following without back-propagation in layered networks. In: IEEE FIRST ANNUAL CONFERENCE ON NEURAL NETWORKS, San Diego, CA. **Proceedings...** [S.l.]: SOS Printing, 1987. p. II629–II636. 11
- BARTO, A. G.; SUTTON, R. S.; ANDERSON, C. W. Neuronlike adaptive elements that can solve difficult learning control problems. **IEEE Transactions on Systems, Man, and Cybernetics**, n. 5, p. 834–846, 1983. 11
- BEER, F. P.; JOHNSTON, E. R. **Vector mechanics for engineers**. [S.l.]: New York: McGraw-Hill, 2003. 17
- BEZANSON, J.; EDELMAN, A.; KARPINSKI, S.; SHAH, V. B. Julia: a fresh approach to numerical computing. **SIAM Review**, SIAM, v. 59, n. 1, p. 65–98, 2017. Disponível em: <<https://doi.org/10.1137/141000671>>. 55

CARRARA, V. **Redes neurais aplicadas ao controle de atitude de satélites com geometria variável**. São José dos Campos, INPE: INPE, 1997. 13

CARRARA, V.; KUGA, H. K. Estimating friction parameters in reaction wheels for attitude control. **Mathematical Problems in Engineering**, Hindawi, v. 2013, 2013. 33

CARRARA, V.; NETO, A. R. A neural network satellite attitude controller with error based reference trajectory. In: XIV INTERNATIONAL SYMPOSIUM ON SPACE FLIGHT DYNAMICS, BRAZIL. **Proceedings...** [S.l.], 1999. 62

CARRARA, V.; VAROTTO, S. E. C.; NETO, A. R. Satellite attitude control using multilayer perception neural networks (aas 98-345). In: PRADO, A. F. B. A. E. (Ed.). **Advances in space dynamics**. [S.l.]: FAPESP, 1998. 35

CHAGAS, R. A. J. **Notas de aula do curso de Movimento de um sólido (CMC-202-4)**. São José dos Campos: INPE, mar. 2019. 20

CHENG, C.-H.; SHU, S.-L. Application of ga-based neural network for attitude control of a satellite. **Aerospace Science and Technology**, Elsevier, v. 14, n. 4, p. 241–249, 2010. 35

CHOI, M.-T.; FLASHNER, H. Neural-network-based spacecraft attitude control. In: AIAA GUIDANCE, NAVIGATION, AND CONTROL CONFERENCE AND EXHIBIT. **Proceedings...** [S.l.]: AIAA, 2000. p. 4145. 35

DAWSON, M. R. **Minds and machines: connectionism and psychological modeling**. [S.l.]: John Wiley & Sons, 2008. 44

FORTUNA, L.; MUSCATO, G.; XIBILIA, M. G. Attitude feedforward neural controller in quaternion algebra. **Intelligent Automation & Soft Computing**, v. 5, n. 3, p. 191–199, 1999. 36

_____. A comparison between hmlp and hrbf for attitude control. **IEEE Transactions on Neural Networks**, v. 12, n. 2, p. 318–328, 2001. 35

FU, K.-S. Learning control systems—review and outlook. **IEEE transactions on Automatic Control**, v. 15, n. 2, p. 210–221, 1970. 10

GHORBANPOUR, A.; SOHRAB, M. Fixed final time three-axis satellite attitude control with thrusters based on dynamic programming and neural networks. **arXiv preprint arXiv:1908.10677**, 2019. 15

- GILBERT, H.; SARIDIS, G. Self-organizing solution of the stochastic fuel regulator problem. **IEEE Transactions Systems Science and Cybernetics**, 1970. 10
- HANDELMAN, D.; LANE, S. H.; GELFAND, J. J. Integrating neural networks and knowledge-based systems for intelligent robotic control. **IEEE Control Systems Magazine**, v. 10, n. 3, p. 77–87, 1990. 12
- HARRIS, C.; MOORE, C.; BROWN, M. **Intelligent control**. [S.l.]: World Scientific, 1994. 2
- HAYKIN, S. **Neural networks: a comprehensive foundation**. [S.l.]: Prentice Hall PTR, 1994. 12, 46, 47, 48
- _____. **Neural networks and learning machines**. [S.l.]: Pearson Education India, 2010. 1, 36, 47, 48, 49, 50
- HE, W.; LIU, Y. To regularize or not: revisiting SGD with simple algorithms and experimental studies. **Expert Systems with Applications**, v. 112, p. 1–14, 2018. 55
- HEBB, D. O. **The organization of behavior: a neuropsychological theory**. [S.l.]: John Wiley; Chapman & Hall, 1949. 7
- HERTZ, J.; KROGH, A.; PALMER, R. G.; HORNER, H. Introduction to the theory of neural computation. **Physics Today**, v. 44, p. 70, 1991. 11
- HINTON, G.; SRIVASTAVA, N.; SWERSKY, K. Neural networks for machine learning lecture 6a overview of mini-batch gradient descent. **Cited on**, v. 14, n. 8, 2012. 55
- HU, Q.; XIAO, B. Intelligent proportional-derivative control for flexible spacecraft attitude stabilization with unknown input saturation. **Aerospace Science and Technology**, v. 23, n. 1, p. 63–74, 2012. 14
- HUGHES, P. C. **Spacecraft attitude dynamics**. [S.l.]: Courier Corporation, 2012. 17, 19
- INNES, M. Flux: elegant machine learning with julia. **Journal of Open Source Software**, 2018. 55
- INNES, M.; SABA, E.; FISCHER, K.; GANDHI, D.; RUDILOSSO, M. C.; JOY, N. M.; KARMALI, T.; PAL, A.; SHAH, V. Fashionable modelling with flux. 2018.

Disponível em: <https://learningsys.org/nips18/assets/papers/58CameraReadySubmissionFlux_NIPS.pdf>. 55

ISMAIL, Z.; VARATHARAJOO, R. A study of reaction wheel configurations for a 3-axis satellite attitude control. **Advances in Space Research**, v. 45, n. 6, p. 750–759, 2010. ISSN 0273-1177. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0273117709007078>>. 32

JIN, J.; KO, S.; RYOO, C.-K. Fault tolerant control for satellites with four reaction wheels. **Control Engineering Practice**, v. 16, n. 10, p. 1250–1258, 2008. ISSN 0967-0661. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0967066108000233>>. 32

KIM, H.-U.; BAE, T.-S. Deep learning-based gnss network-based real-time kinematic improvement for autonomous ground vehicle navigation. **Journal of Sensors**, v. 2019, 2019. 37

KING, J. T. Increasing agility in orthogonal reaction wheel attitude control systems. **Acta Astronautica**, v. 177, p. 673–683, 2020. ISSN 0094-5765. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0094576520305245>>. 32

KONG, S.-G.; KOSKO, B. Adaptive fuzzy systems for backing up a truck-and-trailer. **IEEE transactions on Neural Networks**, v. 3, n. 2, p. 211–223, 1992. 12

KRAFT, L. G.; CAMPAGNA, D. P. A comparison between cmac neural network control and two traditional adaptive control systems. **IEEE Control Systems Magazine**, v. 10, n. 3, p. 36–43, 1990. 12

KUMAR, R. R.; SEYWALD, H.; DESHPANDE, S. M.; RAHMAN, Z. Artificial neural networks in space station optimal attitude control. **Acta Astronautica**, v. 35, n. 2-3, p. 107–117, 1995. 13

KUNG, S. Y. **Digital neural networks**. [S.l.]: Prentice-Hall, Inc., 1993. 12

LEONDES, C. T. **Knowledge-based systems, four-volume set: techniques and applications**. [S.l.]: Elsevier, 2000. 1

LEVINE, D. S. **Introduction to cognitive and neural modeling**. [S.l.]: L. Erlbaum Associates Inc., 1991. 12

- LIN, C.-T.; LEE, C. G.; LIN, C.-T.; LIN, C. **Neural fuzzy systems: a neuro-fuzzy synergism to intelligent systems**. [S.l.]: Upper Saddle River, NJ: Prentice Hall, 1996. 1, 12, 35, 47, 48, 50, 51
- MA, Z.; WANG, Y.; YANG, Y.; WANG, Z.; TANG, L.; ACKLAND, S. Reinforcement learning-based satellite attitude stabilization method for non-cooperative target capturing. **Sensors**, v. 18, n. 12, p. 4331, 2018. 15
- MALSBURG, C. Von der. Self-organization of orientation sensitive cells in the striate cortex. **Kybernetik**, v. 14, n. 2, p. 85–100, 1973. 11
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, Springer, v. 5, n. 4, p. 115–133, 1943. 7
- MENDEL, J. **Applications of artificial intelligence to spacecraft control**. [S.l.: s.n.], 1966. 10
- MINSKY, M. **A neural-analogue calculator based upon a probability model of reinforcement**. Cambridge: Harvard University: [s.n.], 1952. 8
- MINSKY, M. **Neural Nets and the Brain Model Problem**. Thesis (Master) — Princeton University, Princeton, 1954. 8
- MINSKY, M.; PAPERT, S. **Perceptrons**. Cambridge: MIT Press, 1969. 9
- MUNAKATA, T. Commercial and industrial ai. **Communications of the ACM**, v. 37, n. 3, p. 23–26, 1994. 1
- NILSSON, N. J. **Learning machines**. New York: Morgan Kaufmann Publishers, 1965. 9
- NOVIKOFF, A. B. **On convergence proofs for perceptrons**. [S.l.: s.n.], 1963. 8
- OGATA, K. **Engenharia de controle moderno**. [S.l.]: Prentic/Hall do Brasil, 1992. 3, 29, 33
- OLSSON, H.; ÅSTRÖM, K.; WIT, C. C. de; GäFVERT, M.; LISCHINSKY, P. Friction models and friction compensation. **European Journal of Control**, v. 4, n. 3, p. 176–195, 1998. ISSN 0947-3580. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S094735809870113X>>. 33
- PAO, Y. **Adaptive pattern recognition and neural networks**. Reading, MA (US): Addison-Wesley Publishing, 1989. 44

- PERETTO, P.; PIERRE, P. **An introduction to the modeling of neural networks**. [S.l.]: Cambridge University Press, 1992. 12
- ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, n. 6, p. 386, 1958. 8
- _____. **On the convergence of reinforcement procedures in simple perceptrons**. [S.l.]: Cornell Aeronautical Laboratory, 1960. 8
- RUBAAI, A.; YOUNG, P. Ekf-based pi-/pd-like fuzzy-neural-network controller for brushless drives. **IEEE Transactions on Industry applications**, IEEE, v. 47, n. 6, p. 2391–2401, 2011. 14
- RUMELHART, D.; HILTON, G.; WILLIAMS, R. Learning representations by backpropagating errors. **Nature**, v. 323, p. 533–536, 1986. 11, 50
- SADATI, N.; MEGHDARI, A.; TEHRANI, N. D. Optimal tracking neuro-controller in satellite attitude control. In: IEEE INTERNATIONAL CONFERENCE ON INDUSTRIAL TECHNOLOGY, 2002. **Proceedings...** [S.l.]: IEEE, 2002. p. 54–59. 13, 35
- SHAKHOVSKA, N.; MONTENEGRO, S.; KRYVENCHUK, Y.; ZAKHARCHUK, M. The neurocontroller for satellite rotation. **International Journal of Intelligent Systems and Applications**, v. 11, n. 3, p. 1, 2019. 15
- SHARUN, S.; MASHOR, M.; NORHAYATI, M.; YAACOB, S.; YAAKOB, M.; JAAFAR, W. N. W. Adaptive neuro-controller based on hmlp network for innosat attitude control. In: IEEE CONFERENCE ON ELECTRICAL, CONTROL AND COMPUTER ENGINEERING 2011. **Proceedings**. [S.l.]: IEEE, 2011. p. 355–360. 36
- SHU, H.; PI, Y. Pid neural networks for time-delay systems. **Computers & Chemical Engineering**, v. 24, n. 2-7, p. 859–862, 2000. 37, 38
- SHUSTER, M. D. et al. A survey of attitude representations. **Navigation**, v. 8, n. 9, p. 439–517, 1993. 19, 20, 23, 24, 26
- SIMPSON, K. Foundations of neural networks. In: SANCHEZ-SINENCIO E.; LAU, C. E. (Ed.). **Artificial neural for patter recognition**. New York: IEEE Press, 1992. 12
- SINGLETON, R. C. **A test for linear separability as applied to self-organizing machines**. [S.l.: s.n.], 1962. 8

SIVAPRAKASH, N.; SHANMUGAM, J. Neural network based three axis satellite attitude control using only magnetic torquers. In: IEEE DIGITAL AVIONICS SYSTEMS CONFERENCE, 2005. **Proceedings...** [S.l.]: IEEE, 2005. 13

SMITH, F. B.; LEE, J. F.; BUTZ, A. R.; PROM, G. J. **Trainable flight control system investigation.** [S.l.: s.n.], 1964. 10

SUTTON, R. S.; BARTO, A. G.; WILLIAMS, R. J. Reinforcement learning is direct adaptive optimal control. **IEEE Control Systems Magazine**, v. 12, n. 2, p. 19–22, 1992. 48

TSOUKALAS, L. H.; UHRIG, R. E. **Fuzzy and neural approaches in engineering.** [S.l.]: John Wiley & Sons, 1996. 7, 12, 37, 44, 46

WALTZ, M.; FU, K. A heuristic approach to reinforcement learning control systems. **IEEE Transactions on Automatic Control**, IEEE, v. 10, n. 4, p. 390–398, 1965. 9

WATKINS, C. J. C. H. Learning from delayed rewards. Cambridge, 1989. 48

WEN, X.; WANG, J. Fuzzy pid controller based on improved neural network for satellite attitude. In: 2015 FIFTH INTERNATIONAL CONFERENCE ON INSTRUMENTATION AND MEASUREMENT, COMPUTER, COMMUNICATION AND CONTROL (IMCCC). **Proceedings...** [S.l.], 2015. p. 1206–1211. 14

WERBOS, P. Beyond regression:"new tools for prediction and analysis in the behavioral sciences. Cambridge, p. 454, 1974. 11, 50

_____. Back-propagation and neurocontrol: a review and prospectus. In: IEEE INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS. **Proceedings...** [S.l.]: IEEE, 1989. p. 1–I209. 48

WERBOS, P. J. **Handbook of intelligent control, neural, fuzzy and adaptive approaches, chapter 3. neurocontrol and supervised learning: an overview and evaluation.** [S.l.]: Van Nostrand Reinhold, 1992. 49

WERTZ, J. R. **Spacecraft attitude determination and control.** [S.l.]: Springer, 1978. 3, 17, 18, 19, 22, 24, 27, 28, 29, 31, 32

WESSELS, L. F.; BARNARD, E. et al. Avoiding false local minima by proper initialization of connections. **IEEE Transactions on Neural Networks**, v. 3, n. 6, p. 899–905, 1992. 51

WHITE, D. A.; SOFGE, D. A. **Handbook of intelligent control: neural, fuzzy, and adaptative approaches**. [S.l.]: Van Nostrand Reinhold Company, 1992. 2, 12

WIDROW, B. Generalization and information storage in networks of adaline neurons. self organizing systems. In: . [S.l.: s.n.], 1962. p. 435–461. 9

WIDROW, B.; HOFF, M. E. **Adaptive switching circuits**. [S.l.: s.n.], 1960. 8

WIDROW, B.; SMITH, F. W. **Pattern-recognizing control systems**. Washington, DC: Spartan, 1964. 9

WIENER, N. **Cybernetics or control and communication in the animal and the machine**. [S.l.]: Technology Press, 1948. 7

XIA, K.; LEE, T.; PARK, S.-Y. Adaptive saturated neural network tracking control of spacecraft: theory and experimentation. **International Journal of Aerospace Engineering**, v. 2019, 2019. 35

ZANARDI, M. Fundamentos da astronáutica. **Apostila do ITA**, 1990. 22

ZOU, F.; SHEN, L.; JIE, Z.; ZHANG, W.; LIU, W. A sufficient condition for convergences of adam and rmsprop. In: IEEE/CVF CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2019. **Proceedings...** [S.l.]: IEEE, 2019. p. 11127–11135. 55

PUBLICAÇÕES TÉCNICO-CIENTÍFICAS EDITADAS PELO INPE

Teses e Dissertações (TDI)

Teses e Dissertações apresentadas nos Cursos de Pós-Graduação do INPE.

Manuais Técnicos (MAN)

São publicações de caráter técnico que incluem normas, procedimentos, instruções e orientações.

Notas Técnico-Científicas (NTC)

Incluem resultados preliminares de pesquisa, descrição de equipamentos, descrição e ou documentação de programas de computador, descrição de sistemas e experimentos, apresentação de testes, dados, atlas, e documentação de projetos de engenharia.

Relatórios de Pesquisa (RPQ)

Reportam resultados ou progressos de pesquisas tanto de natureza técnica quanto científica, cujo nível seja compatível com o de uma publicação em periódico nacional ou internacional.

Propostas e Relatórios de Projetos (PRP)

São propostas de projetos técnico-científicos e relatórios de acompanhamento de projetos, atividades e convênios.

Publicações Didáticas (PUD)

Incluem apostilas, notas de aula e manuais didáticos.

Publicações Seriadas

São os seriados técnico-científicos: boletins, periódicos, anuários e anais de eventos (simpósios e congressos). Contam destas publicações o Internacional Standard Serial Number (ISSN), que é um código único e definitivo para identificação de títulos de seriados.

Programas de Computador (PDC)

São a seqüência de instruções ou códigos, expressos em uma linguagem de programação compilada ou interpretada, a ser executada por um computador para alcançar um determinado objetivo. Aceitam-se tanto programas fonte quanto os executáveis.

Pré-publicações (PRE)

Todos os artigos publicados em periódicos, anais e como capítulos de livros.