

UNIVERSIDADE DO ESTADO DE SANTA CATARINA – UDESC
CENTRO DE CIÊNCIAS TECNOLÓGICAS – CCT
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA – PPGEEL

CLAUDINEI DIAS

TESE DE DOUTORADO

FLOW PSICOFISIOLÓGICO EM JOGOS DIGITAIS:

Inteligência Artificial em Jogos Sérios Multimodais para Reabilitação Respiratória

JOINVILLE

2024

CLAUDINEI DIAS

FLOW PSICOFISIOLÓGICO EM JOGOS DIGITAIS:

Inteligência Artificial em Jogos Sérios Multimodais para Reabilitação Respiratória

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, do Centro de Ciências Tecnológicas, da Universidade do Estado de Santa Catarina, como requisito parcial para obtenção do grau de Doutor em Engenharia Elétrica, área de concentração em Sistemas Eletroeletrônicos.

Orientador: Prof. Dr. Marcelo da Silva Hounsell

Coorientador: Prof. Dr. André Bittencourt Leal

JOINVILLE

2024

Ficha catalográfica elaborada pelo programa de geração automática da
Biblioteca Universitária Udesc,
com os dados fornecidos pelo(a) autor(a)

Dias, Claudinei

Flow Psicofisiológico em Jogos Digitais : inteligência artificial em jogos sérios multimodais para reabilitação respiratória / Claudinei Dias. -- 2024.

222 p.

Orientador: Marcelo da Silva Hounsell

Coorientador: André Bittencourt Leal

Tese (doutorado) -- Universidade do Estado de Santa Catarina, Centro de Ciências Tecnológicas, Programa de Pós-Graduação em Engenharia Elétrica, Joinville, 2024.

1. Projeto de Jogos Digitais. 2. Reabilitação Física. 3. Ajuste Dinâmico de Dificuldade. 4. Inteligência Artificial. 5. Jogos Sérios. I. Hounsell, Marcelo da Silva. II. Leal, André Bittencourt. III. Universidade do Estado de Santa Catarina, Centro de Ciências Tecnológicas, Programa de Pós-Graduação em Engenharia Elétrica. IV. Título.

CLAUDINEI DIAS

FLOW PSICOFISIOLÓGICO EM JOGOS DIGITAIS:

Inteligência Artificial em Jogos Sérios Multimodais para Reabilitação Respiratória

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, do Centro de Ciências Tecnológicas, da Universidade do Estado de Santa Catarina, como requisito parcial para obtenção do título de Doutor em Engenharia Elétrica, área de concentração em Sistemas Eletroeletrônicos.

BANCA EXAMINADORA

Marcelo da Silva Hounsell, Dr.
CCT/UDESC-SC (Orientador/Presidente)

André Bittencourt Leal, Dr.
CCT/UDESC-SC (Coorientador)

Nelson Francisco Serrão Júnior, Dr.
UNIPAMPA-RS

Maria Eduarda Lima, Dra.
UNISOCIESC-SC

Douglas Wildgrube Bertol, Dr.
CCT/UDESC-SC

Fabício Noveletto, Dr.
CCT/UDESC-SC

Joinville-SC, 26 de agosto de 2024.

Aos professores da Universidade do
Estado de Santa Catarina, pela inspiração
de sempre!

AGRADECIMENTOS

Agradeço ao meu orientador e ao meu coorientador por aceitarem conduzir o meu trabalho. Em especial, agradeço ao ilustríssimo professor Dr. Marcelo da Silva Hounsell pelas centenas de horas de dedicação. Meus agradecimentos ao professor Dr. André Bittencourt Leal por toda ajuda ao longo dessa jornada. Agradeço também a todos os meus professores da Universidade do Estado de Santa Catarina – Udesc pela excelência da qualidade técnica de cada um. Agradeço aos professores Helton Eckermann da Silva e Antonio Vinicius Soares pelas contribuições didáticas da área da fisioterapia.

Meus agradecimentos a todos que contribuíram com *feedbacks*, colaborações e discussões que enriqueceram este trabalho. Em especial, agradeço aos pesquisadores *Laboratory for Research on Visual Applications*, Jhonatan Thallisson Cabral Nery, Monique Hemily Almeida Mendes, Carlos Augusto Belo da Silva Filho e Leonardo Cordeiro da Silva dos Santos. Agradeço também aos meus alunos que eu orientei em trabalhos de conclusão de curso, cujas pesquisas contribuíram para os avanços no ecossistema *I Blue It*.

Sou profundamente grato à minha família pelo apoio incondicional ao longo dos meus estudos e que sempre estiveram ao meu lado me apoiando ao longo de toda a minha trajetória. Em especial, agradeço à minha querida esposa, Andréa Cristina Camilo Dias, que esteve comigo em todos os momentos desta jornada de doutoramento, me apoiando e dando forças para continuar, e aos meus filhos Lucas e Samara por toda inspiração, carinho e amor que me ajudaram a seguir em frente.

Deixo um agradecimento especial ao meu grande amigo e irmão de coração, Odil Bernstorff Neto, pelos incentivos e conselhos que foram fundamentais para que eu continuasse com resiliência em meu projeto de pesquisa, e pelas conversas incansáveis e sábias sobre a área da Inteligência Artificial.

Meus agradecimentos aos especialistas da área da Fisioterapia, Engenharia e Computação que participaram dos estudos de campo.

“No ambiente acadêmico, a recompensa às ações de pesquisa é o conhecimento e a sabedoria, que enriquecem o psíquico e fortalecem o físico”.
Elaborado pelo autor (2024).

RESUMO

Jogos sérios ativos (*exergames*) são recursos complementares às modalidades terapêuticas tradicionais, promovendo exercícios que induzem demandas fisiológicas similares aos métodos convencionais, além de oferecer entretenimento. Diante disso, destaca-se a necessidade de equilibrar os aspectos educacionais com a diversão em jogos sérios, controlando as ações de ajuste de dificuldade durante os exercícios fisioterapêuticos para evitar riscos de exaustão, que podem expor o paciente a perigos ao utilizar o jogo. Propõe-se a extensão da Teoria do Flow, que é peculiar aos jogos digitais, para o conceito Flow Psicofisiológico em jogos sérios ativos multimodais destinados à fisioterapia, que visa ajustar o esforço exigido à condição de saúde do paciente. Uma revisão da literatura revelou uma lacuna na abordagem de ajuste de dificuldade dos *exergames* conforme a condição de saúde do paciente utilizando Inteligência Artificial. O Flow Psicofisiológico foi implementado no *serious exergame* I Blue It para fisioterapia respiratória, após a coleta de requisitos para promover o treinamento muscular respiratório, por entrevista semiestruturada com 10 especialistas e análise de conteúdo. Para alcançar o Flow Psicofisiológico, foi utilizado o método de Ajuste Dinâmico de Dificuldade por meio de Aprendizado por Reforço e Redes Neurais Artificiais, intitulada DeepDDA. Os resultados obtidos consideram múltiplas valências psicofisiológicas do paciente para promover segurança (análise dos biosinais), conforto físico (*flow* fisiológico), conforto motivacional (*flow* psíquico) e diversão (jogo digital). O agente DeepDDA utilizou a técnica *Proximal Policy Optimization*, onde o modelo aprendeu a balancear os desafios do *exergame* com as capacidades dos jogadores. O estado de Flow Psicofisiológico evita fadiga ou marasmo na dimensão do *flow* físico, evita frustração ou tédio na dimensão psíquica e, equilibra o objetivo sério da terapia com a diversão do *exergame*. O conceito de Flow Psicofisiológico introduz o princípio do equilíbrio tridimensional entre os eixos de dificuldade, desempenho psíquico e desempenho terapêutico e, se beneficia de tecnologias multimodais, multidados e inteligência artificial. Os resultados do Flow Psicofisiológico têm potencial de uso em exercícios terapêuticos em outras áreas da saúde.

Palavras-chave: Projeto de Jogos Digitais; Reabilitação Física; Ajuste Dinâmico de Dificuldade; Inteligência Artificial; Jogos Sérios.

ABSTRACT

Serious exergames are complementary resources to traditional therapeutic modalities, promoting exercises that induce physiological demands similar to conventional methods, while providing entertainment. In this context, the need to balance educational aspects with fun in serious games is highlighted, controlling difficulty adjustment actions during physiotherapeutic exercises to avoid possible exhaustion, which could expose the patient to dangers while using the game. The extension of the Flow Theory, which is unique to digital games, is proposed to the concept of Psychophysiological Flow in multimodal serious exergames aimed at physiotherapy to adjust the required effort to the patient's health condition. A literature review revealed a gap in the approach to difficulty adjustment in exergames based on the patient's health condition using Artificial Intelligence. The Psychophysiological Flow was implemented in the serious exergame I Blue It for respiratory physiotherapy thanks to requirements gathered to promote respiratory muscle training using semi-structured interviews with 10 specialists and content analysis. The Psychophysiological Flow was realized using the Dynamic Difficulty Adjustment method through Reinforcement Learning and Artificial Neural Networks and called DeepDDA. The results consider multiple psychophysiological valences of the patient to promote safety (biosignal analysis), physical comfort (physiological flow), motivational comfort (psychic flow), and fun (digital game). The DeepDDA agent used the Proximal Policy Optimization technique, where the model learned to balance the challenges of the exergame against the players' abilities. The state of Psychophysiological Flow avoids fatigue or apathy in the physical flow dimension, avoids frustration or boredom in the psychic dimension, and balances the serious therapeutic goal with the fun of the exergame. The concept of Psychophysiological Flow introduces the principle of three-dimensional balance between the axes of difficulty, psychic performance, and therapeutic performance, and benefits from multimodal, multidata, and artificial intelligence technologies. The results of Psychophysiological Flow have potential to be used in therapeutic exercises in other health areas.

Keywords: Digital Game Design; Physical Rehabilitation; Dynamic Difficulty Adjustment; Artificial Intelligence; Serious Games.

LISTA DE ILUSTRAÇÕES

Figura 1 - Arquitetura 123-SGR.....	27
Figura 2 - Canal do Flow	35
Figura 3 - Neurônio do cérebro e Neurônio Artificial	39
Figura 4 - Camadas em uma ANN	39
Figura 5 - <i>Markov Decision Processes (MDP)</i>	46
Figura 6 - Fisiologia Respiratória.....	55
Figura 7 - Padrões respiratórios	60
Figura 8 - Fluxograma de triagem e seleção de artigos	66
Figura 9 - Representação do Flow Psicofisiológico (FPF).....	89
Figura 10 - Combinação para DDA do Flow Psicofisiológico (FPF)	94
Figura 11 - DeepDDA para Arquitetura 123-SGR	105
Figura 12 - Plano de Treinamento.....	106
Figura 13 - Projeto de Integração do Módulo DeepDDA com I Blue It	108
Figura 14 - Limiares e Normalização da Posição e Tamanho dos Objetos	110
Figura 15 - Flow da Função de ΔDJ	113
Figura 16 - Ciclo de Progressão.....	114
Figura 17 - Ciclo de Monitoramento da SpO ₂	120
Figura 18 - Ciclo de Comunicação com a API ML-Agents	121
Figura 19 - Ciclo de Treinamento e Otimização PPO.....	122
Figura 20 - Recompensa Cumulativa Média (Treinamento 1)	126
Figura 21 - Métricas de Ambiente	128
Figura 22 - Métricas de Perda	129
Figura 23 - Métricas de Política.....	130
Figura 24 - Ambiente do I Blue It.....	132
Figura 25 - Testes aplicados no I Blue It.....	133
Figura 26 - Diagrama resumo dos Requisitos Funcionais.....	197
Figura 27 - Recomendações de perfis de pacientes	206
Figura 28 - Parâmetros de <i>Setup</i> do <i>Exergame</i>	208
Figura 29 - Parâmetros de Comportamento do Agente DeepDDA.....	216
Figura 30 - Escala de Borg.....	218

LISTA DE GRÁFICOS

Gráfico 1 - Número de artigos publicados ao longo dos anos	170
Gráfico 2 - Tipos de Publicação	170
Gráfico 3 - Relação entre gêneros da narrativa e origens	171
Gráfico 4 - Sinais utilizados	171
Gráfico 5 - Uso de IA	172
Gráfico 6 - Relação entre Uso de IA, Origem e Sinal	172
Gráfico 7 - Local de uso da IA	173
Gráfico 8 - Ênfase do esforço do usuário	173
Gráfico 9 - Técnicas de IA	174
Gráfico 10 - Doenças associadas	175
Gráfico 11 - Tratamentos mencionados	176
Gráfico 12 - Biosinais utilizados	176
Gráfico 13 - Relação entre Técnicas de IA, Tratamentos e Doenças	177

LISTA DE EQUAÇÕES

3.1 - Função de Ativação	40
3.2 - Função de Pesos	40
7.1 - Distância Euclidiana	104
7.2 - K-Vizinhos Mais Próximos.....	104
7.3 - Recomendação de Parâmetros.....	104
7.4 - Limiares de Velocidade	109
7.5 - Desempenho do Jogador	111
7.6 - Flow Psíquico	112
7.7 - Flow Fisiológico.....	112
7.8 - Estado Atual.....	117
7.9 - Ação de Ajuste de Nível de Dificuldade	117
7.10 - Função de Recompensa	117

LISTA DE TABELAS

Tabela 1 - Características dos estudos	67
Tabela 2 - Principais instrumentos e resultados	68
Tabela 3 - Características dos artigos relevantes sobre o método DDA	77
Tabela 4 - Funções da IA em JS	85
Tabela 5 - Resumo dos <i>Insights</i> adotados no JSA I Blue It 5.0.....	99
Tabela 6 - Observações do Agente	116
Tabela 7 - Recompensa do Monitor de Sinais.....	120
Tabela 8 - Ajustes de Hiperparâmetros	127
Tabela 9 - Ajuste da Estratégia de Recompensa do Agente	127
Tabela 10 - Abordagem do Flow Psicofisiológico	147
Tabela 11 - Frases de Busca em MBAs	164
Tabela 12 - Número de Artigos Identificados	168
Tabela 13 - Artigos Relevantes em cada MBA.....	168
Tabela 14 - Artigos Relevantes	169
Tabela 15 - Comportamento inteligente percebido.....	175
Tabela 16 - Frequências dos códigos sobre especialidade.....	182
Tabela 17 - Frequências dos códigos sobre protocolo e prescrição de exercício ...	185
Tabela 18 - Frequência dos códigos sobre ajustes de progressão ou regressão ...	187
Tabela 19 - Frequências dos códigos sobre ajustes das variáveis	188
Tabela 20 - Frequências dos códigos sobre picos e tempos respiratórios.....	189
Tabela 21 - Frequências dos códigos sobre incentivos respiratórios	189
Tabela 22 - Frequências dos códigos sobre avaliação	190
Tabela 23 - Frequências dos códigos sobre monitoramento.....	191
Tabela 24 - Frequências dos códigos sobre paciente	192
Tabela 25 - Dicionário de parâmetros definido pelo 'Terapeuta' antes do jogo.....	194
Tabela 26 - Dicionário de parâmetros definido pelo 'Paciente'.....	195
Tabela 27 - Dicionário de parâmetros definido pelo ' <i>Exergame</i> ' durante o jogo	196
Tabela 28 - Modelo e definições padrões para os Requisitos Funcionais.....	196
Tabela 29 - Hiperparâmetros de Treinamento com PPO	220

LISTA DE ABREVIATURAS E SIGLAS

ANN	Redes Neurais Artificiais (<i>Artificial Neural Network</i>)
CNN	Redes Neurais Convolucionais (<i>Convolutional Neural Networks</i>)
DDA	Ajuste Dinâmico de Dificuldade (<i>Dynamic Difficulty Adjustment</i>)
DL	Aprendizado de profundo (<i>Deep Learning</i>)
DPOC	Doenças Pulmonares Obstrutivas Crônicas
DRC	Doenças Respiratórias Crônicas
DRL	Aprendizado por reforço profundo (<i>Deep Reinforcement Learning</i>)
EB	Escala de Borg
FC	Frequência Cardíaca
FFN	Redes Neurais <i>Feedforward</i> (<i>Feedforward Neural Networks</i>)
FPF	<i>Flow Psicofisiológico</i>
FR	Frequência Respiratória
IA	Inteligência Artificial
JD	Jogos Digitais
JS	Jogos Sérios
JSMM	Jogos Sérios Multimodais
KNN	K-Vizinhos mais próximos (<i>K-Nearest Neighbors</i>)
MDP	Processos de Decisão Markoviano (<i>Markov Decision Process</i>)
ML	Aprendizado de máquina (<i>Machine Learning</i>)
MLP	Perceptron Multicamadas (<i>Multilayer Perceptron</i>)
MSB	Ministério da Saúde do Brasil
MSL	Mapeamento Sistemático de Literatura
PP	Pergunta Primária
PPO	Otimização de Política Proximal (<i>Proximal Policy Optimization</i>)
PS	Pergunta Secundária
RL	Aprendizado por reforço (<i>Reinforcement Learning</i>)
RNN	Redes Neurais Recorrentes (<i>Recurrent Neural Networks</i>)
RR	Reabilitação Respiratória
RSL	Revisão Sistemática de Literatura
JSA	Jogos Sérios Ativos (<i>Serious Exergames</i>)
SL	Aprendizado Supervisionado (<i>Supervised Learning - SL</i>)
SRS	Especificação de Requisitos de Software (<i>Software Requirement Specification</i>)
SpO2	Saturação de Oxigênio
TMR	Treinamento da Musculatura Respiratória
UFE	Usuário Final Entendido
UL	Aprendizado não Supervisionado (<i>Unsupervised Learning - UL</i>)
UTI	Unidade de Terapia Intensiva

SUMÁRIO

1	INTRODUÇÃO	18
1.1	OBJETIVOS	21
1.1.1	Objetivo Geral.....	21
1.1.2	Objetivos específicos.....	21
1.2	METODOLOGIA.....	21
1.3	ESCOPO	22
1.4	ESTRUTURA.....	23
2	JOGOS DIGITAIS	24
2.1	<i>EXERGAMES</i>	24
2.2	JOGOS SÉRIOS	25
2.3	<i>EXERGAMES</i> SÉRIOS E MULTIMODAL	26
2.4	O JSA “I BLUE IT”	31
2.5	AJUSTE DE DIFICULDADE	32
2.6	TEORIA DO <i>FLOW</i>	33
2.6.1	Condições do Flow.....	33
2.6.2	Dimensões do Flow.....	34
2.6.3	Canal do Flow	35
2.7	CONSIDERAÇÕES FINAIS DO CAPÍTULO	36
3	INTELIGÊNCIA ARTIFICIAL	37
3.1	REDES NEURAS ARTIFICIAIS.....	38
3.2	APRENDIZADO DE MÁQUINA.....	41
3.3	APRENDIZADO PROFUNDO	48
3.4	APRENDIZADO POR REFORÇO PROFUNDO.....	51
3.5	CONSIDERAÇÕES FINAIS DO CAPÍTULO	52
4	REABILITAÇÃO RESPIRATÓRIA	53
4.1	FISIOLOGIA RESPIRATÓRIA.....	54
4.2	DOENÇAS RESPIRATÓRIAS.....	56
4.3	FISIOTERAPIA RESPIRATÓRIA	57
4.4	MODALIDADES E TÉCNICAS EM FISIOTERAPIA RESPIRATÓRIA	58
4.5	DESCONFORTOS RESPIRATÓRIOS.....	60
4.6	CONSIDERAÇÕES FINAIS DO CAPÍTULO	61
5	ESTADO DA ARTE.....	63

5.1	MAPEAMENTO SISTEMÁTICO DA LITERATURA.....	63
5.1.1	Pesquisa.....	63
5.1.2	Análise.....	64
5.2	REVISÃO SISTEMÁTICA DA LITERATURA	65
5.2.1	Artigos Relevantes	65
5.2.2	Análise.....	69
5.2.2.1	<i>Doenças respiratórias.....</i>	69
5.2.2.2	<i>Exercícios.....</i>	70
5.2.2.3	<i>Dispositivos e Sensores</i>	72
5.2.2.4	<i>Biofeedback.....</i>	74
5.2.2.5	<i>Elementos do Jogo.....</i>	75
5.3	PESQUISA SOBRE DDA EM JS.....	76
5.3.1	Pesquisa complementar	76
5.3.2	Análise.....	77
5.4	TENDÊNCIAS E OPORTUNIDADES.....	81
5.4.1	Dispositivos e Sensores	82
5.4.2	Biofeedback.....	83
5.4.3	Flow	84
5.4.4	Inteligência Artificial	85
5.5	CONSIDERAÇÕES FINAIS DO CAPÍTULO	87
6	TESE	88
6.1	METODOLOGIA FLOW PSICOFISIOLÓGICO EM <i>EXERGAMES</i>	88
6.2	DDA MULTIMODAL MULTIDADOS INTELIGENTE.....	90
6.3	CONSIDERAÇÕES FINAIS DO CAPÍTULO	94
7	PROVA DE CONCEITO	95
7.1	CONTEXTUALIZAÇÃO	95
7.2	COLETA DE REQUISITOS	97
7.2.1	Principais resultados das entrevistas	97
7.2.2	Especificação dos Requisitos	102
7.3	PREDIÇÃO DE <i>SETUP</i> DO <i>EXERGAME</i>	102
7.4	DDA NO JSA “I BLUE IT”	105
7.5	AJUSTE DINÂMICO DE DIFICULDADE	107
7.5.1	Projeto Integração do Módulo DeepDDA com I Blue It	107
7.5.2	Função de Desempenho do Jogador.....	111

7.5.3	Modelo de Decisão no I Blue It.....	113
7.5.4	Monitoramento da SpO₂.....	119
7.5.5	Estratégia de Treinamento do DeepDDA com PPO.....	120
7.6	CONSIDERAÇÕES FINAIS DO CAPÍTULO	124
8	TESTAGEM DO FLOW PSICOFISIOLÓGICO	125
8.1	APRENDIZADO DE MÁQUINA DO MODELO DEEPDDA.....	125
8.2	TESTES DE SOFTWARE	132
8.2.1	Testes de Unidade.....	134
8.2.2	Testes de Integração.....	134
8.2.3	Testes Funcionais	135
8.2.4	Testes de Sistema	135
8.3	VALIDAÇÃO DE REQUISITOS PELOS UFE	135
8.4	CONSIDERAÇÕES FINAIS DO CAPÍTULO	137
9	DISCUSSÃO	138
9.1	SOBRE A REVISÃO DA LITERATURA	138
9.2	SOBRE O FLOW PSICOFISIOLÓGICO	140
9.3	SOBRE A ARQUITETURA MULTIMODAL	141
9.4	SOBRE A IMPLEMENTAÇÃO	142
9.5	SOBRE A TESTAGEM DO FLOW PSICOFISIOLÓGICO.....	143
9.6	SOBRE AS CONTRIBUIÇÕES DO FLOW PSICOFISIOLÓGICO	145
10	CONCLUSÃO	147
10.1	TRABALHOS FUTUROS	149
10.1.1	Melhoramentos.....	149
10.1.2	Desdobramentos	150
	REFERÊNCIAS.....	152
	APÊNDICE A - PROTOCOLO DE CONDUÇÃO DO MSL	163
	APÊNDICE B - ENTREVISTA SEMIESTRUTURADA.....	178
	APÊNDICE C - LEVANTAMENTO DE REQUISITOS	182
	APÊNDICE D - ESPECIFICAÇÃO DOS REQUISITOS	194
	APÊNDICE E - IMPLEMENTAÇÃO DO FLOW PSICOFISIOLÓGICO	204

1 INTRODUÇÃO

As modalidades terapêuticas são exercícios e recursos terapêuticos que permitem promover a melhora da saúde e bem-estar dos pacientes. Neste contexto, os Jogos Digitais (JD) são recursos que podem auxiliar, motivando os exercícios físicos por meio de entretenimento e induzindo demandas fisiológicas, como a frequência cardíaca, semelhantes às intensidades requeridas durante exercícios físicos tradicionais de fisioterapia (Carbonera, 2016). Os JD têm potencial para serem incluídos nos programas de exercícios fisioterapêuticos, atuando como adjuvantes na Reabilitação Respiratória (RR), fortalecendo as características tradicionais com entretenimento e tornando as sessões de fisioterapia mais agradáveis (Wang *et al.*, 2020), (Simmich; Deacon; Russell, 2019).

Os JD com propósitos específicos são qualificados como Jogos Sérios (JS) (Hounsell, 2024, p. 67) e podem ser um recurso complementar ao tratamento fisioterapêutico, agregando também elementos que promovem diversão, prazer, desafio, entretenimento e maior adesão ao tratamento fisioterapêutico com exercícios para RR motivados por JD (Butler *et al.*, 2019) (Grimes; Santos; Hounsell, 2018).

Os JS classificados em *exergames* combinam exercícios físicos com elementos de videogame, sendo relevante para reabilitação, onde a combinação de exercício e estímulos lúdicos pode aumentar a motivação e a adesão ao tratamento (Rafiei Milajerdi *et al.*, 2021). A combinação de elementos de JS com jogos de exercícios, Jogos Sérios Ativos (JSA) na RR, aliada a dispositivos específicos multimodais que utilizam dois ou mais dispositivos com sensores para controlar e monitorar os exercícios realizados nas sessões de terapia, promove resultados melhores na recuperação do paciente (Nery *et al.*, 2020). Esses dispositivos promovem flexibilidade na escolha de dispositivo específico dedicado ao tipo de exercício, promovem complementariedade na combinação de dois ou mais e promovem segurança com o monitoramento dos biosinais. Entretanto, observa-se na literatura que há poucos estudos com projetos de JS aplicado à RR que realizem o ajuste de dificuldade dos exercícios em função da capacidade de saúde do paciente (Dias *et al.*, 2020).

Na literatura (Chen, 2007), discute-se a necessidade de equilibrar os aspectos educacionais com a diversão em JS. No entanto, pouco se menciona sobre essa questão em Jogos Sérios Ativos voltados para a saúde. Observa-se a ausência de um

modelo conceitual que oriente essa reflexão de forma estruturada. É necessária uma metodologia que considere as especificidades dos jogos aplicados à saúde.

A Teoria do *Flow* (Chen, 2007), que apresenta elementos que promovem o equilíbrio entre o nível de desafio de uma atividade e capacidade do indivíduo em realizá-la, pode ser utilizada associada a técnicas de Inteligência Artificial (IA) (Cruz; Uresti, 2017). Mas, para promover desafios gerenciáveis e adequados a cada caso clínico, tem-se que considerar não somente os aspectos psíquicos, mas também os fisiológicos do paciente. Esta nova dimensão do Flow é, então, relevante e inerente ao contexto dos *exergames*. Entretanto, pouco explorada na literatura.

Em reabilitação motora, a IA têm sido uma solução frequentemente utilizada para auxiliar na condução dos exercícios, por intermédio de técnicas como algoritmos evolucionário (Andrade *et al.*, 2016), sistema de inferência *fuzzy* (Valencia; Majin, 2018), (Pezzeri; Borghese, 2020) e aprendizado por reforço (Sekhavat; Iran, 2017). Existem oportunidades em que a IA pode ser aplicada (Dias *et al.*, 2020) para melhorar o desempenho do uso de JS na RR, promovendo ações inteligentes.

As técnicas de IA podem ser utilizadas para monitorar e controlar os sinais fisiológicos por intermédio de *feedback* contínuo e podem controlar as ações de ajuste de dificuldade, de modo que haja fluidez durante os exercícios fisioterapêuticos. Para isso, os desenvolvedores devem incorporar elementos da Teoria do *Flow* no desenvolvimento do jogo, que pode ser implementado com uma abordagem de aprendizado por reforço integrado com a técnica de Ajuste Dinâmico de Dificuldade (DDA) (Sekhavat; Iran, 2017).

Essa abordagem é relevante diante da gravidade de Doenças Respiratórias Crônicas (DRC) e da necessidade de RR. Segundo relatório da Organização Mundial de Saúde, ocorrem cerca de 4 milhões de óbitos por ano ao redor do mundo causados por DRC (Levine *et al.*, 2021). Estas doenças representam um dos maiores problemas de saúde e afetam uma parcela considerável da população mundial, sendo responsável por cerca de 7% da mortalidade global (Soriano *et al.*, 2020). O Ministério da Saúde do Brasil (MSB) relatou no boletim epidemiológico o perfil da morbimortalidade por DRC, constatando que, em relação a mortes por DRC, o Brasil apresenta uma média de taxas de mortalidade de 29,3/100 mil habitantes por ano. Considerando a probabilidade de morrer de DRC no Brasil, entre 30 e 70 anos de idade, estima-se um risco de cerca de 15,2% (MSB, 2023).

O MSB também gerou um relatório das taxas de internações hospitalares por DRC, por faixa etária e sexo, com base nos dados do sistema de informação hospitalar obtidos a partir da utilização dos códigos J30 a J98 da Classificação Internacional de Doenças (CID-10). As maiores taxas observadas são provocadas pelas Doenças Pulmonares Obstrutivas Crônicas (DPOC), Bronquite e Enfisema (MSB, 2023), que representaram 93,4% dos óbitos por DRC no período apontado pelas pesquisas (Levine *et al.*, 2021). Cerca de 17% dos pacientes que buscam atendimento de emergência necessitam de hospitalizações, e 50% dos pacientes que recebem alta hospitalar precisam ser readmitidos durante o ano subsequente (MSB, 2023). A infecção aguda do trato respiratório inferior que são infecções que ocorrem nas vias aéreas inferiores, como a pneumonia, também é uma das principais causas de morte. (Nápolis; Chiavegato; Nascimento, 2011).

Estas doenças respiratórias causam complicações no sistema respiratório, levando à diminuição da função pulmonar, restrições de fluxo respiratório, fadiga, redução da qualidade de vida e são os maiores responsáveis por morbidades e mortalidades no mundo (Levine *et al.*, 2021). O tratamento exige intervenção multiprofissional e integrativa, ou seja, integração de interesses entre profissionais, pacientes e recursos terapêuticos para atingir objetivos da RR. As DRC ou a fraqueza respiratória adquirida na Unidade de Terapia Intensiva (UTI) podem provocar anormalidades psíquicas e fisiológicas (Machado, 2018). Um dos tratamentos prescritos é a RR, que é guiada por sessões de fisioterapia com procedimentos direcionados para cada doença respiratória, visando promover melhorias na função pulmonar e na qualidade de vida, incluindo técnicas como higiene brônquica, expansão pulmonar, fortalecimento muscular. A modalidade de exercícios fisioterapêuticos guiados por diretrizes clínicas associadas aos exercícios físicos é uma das componentes chaves para RR (Simmich; Deacon; Russell, 2019).

Com base no contexto apresentado, levanta-se uma questão:

“Como desenvolver um Jogo Sérioso Ativo (*Serious Exergames*) que equilibre os benefícios de ser jogo (diversão, engajamento) e as características terapêuticas inerentes (estimulação física, repetição) de forma personalizada e dinâmica?”

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Desenvolver um modelo conceitual para jogos sérios ativos (*exergames*) para adaptar o desempenho psíquico e fisiológico do paciente, permitindo o ajuste inteligente da dificuldade de acordo com as necessidades do jogador/paciente.

1.1.2 Objetivos específicos

- a) Estender a Teoria do *Flow* em jogos sérios ativos multimodais para reabilitação, considerando as dimensões psíquicas e fisiológicas do paciente;
- b) Desenvolver uma solução de software para promover ajuste dinâmico de dificuldade do jogo sério ativo;
- c) Aplicar e testar uma Prova de Conceito do *Flow Psicofisiológico* em um jogo sério ativo para reabilitação respiratória.

1.2 METODOLOGIA

Nesta seção é apresentada uma visão geral do processo metodológico utilizado para o desenvolvimento.

Revisão da Literatura (Petersen *et al.*, 2007): foi realizado um Mapeamento Sistemático de Literatura (MSL) (Petersen; Vakkalanka; Kuzniarz, 2015) sobre JS Inteligentes para RR, com o objetivo de obter informações sobre o problema apresentado, investigando em um arcabouço de informações científicas e comparando-as com os objetivos desta pesquisa, a fim de encontrar motivação para continuar a investigação científica, realizando os devidos ajustes, se necessário. Posteriormente, foi feita uma Revisão Sistemática de Literatura (RSL) (Kitchenham *et al.*, 2009), metodologia aplicada para interpretar, analisar e sistematizar as evidências relevantes disponíveis nos artigos selecionados no MSL. Também foi realizada uma pesquisa complementar não sistemática, porém específica, sobre DDA em jogos digitais para reabilitação.

Levantamento de campo (Barbosa; Silva, 2010): foram realizadas entrevistas com Usuários Finais Entendidos no domínio (UFE) (Hounsell, 2024, p. 67), conduzidas de forma semiestruturada para a elucidação e levantamento de requisitos de inteligência artificial para o JSA I Blue It. Utilizou-se o paradigma científico/naturalista, fazendo deduções (conhecimento a priori) e validações empíricas (a posteriori) para explicar, entender ou prever o comportamento dos Jogos Sérios Inteligentes na Reabilitação Respiratória, interpretando os resultados a fim de corroborar para a especificação dos requisitos;

Desenvolvimento tecnológico (Sekhavat; Iran, 2017), (Aggarwal, 2018): foi projetado e implementado um *Dynamic Difficulty Adjustment* (DDA) inteligente com aprendizado por reforço profundo como prova de conceito e realizada a validação da solução, executando-se demonstrações em uma entrevista semiestruturada com UFEs, e em seguida realizados testes funcionais para verificar o funcionamento do JSA I Blue It, seguidos de correções e ajustes.

1.3 ESCOPO

A seguir, são listados os principais elementos que definem o escopo desta pesquisa:

1. A investigação foi conduzida no contexto de *exergames* para RR pois o grupo já vem trabalhando nesta área desde 2016 (Grimes; Santos; Hounsell, 2018);
2. Foi utilizado o JSA I Blue It (Nery et al., 2020) por ser um jogo voltado para RR e se ter acesso direto ao código fonte;
3. Foi adotada a arquitetura 123-SGR (Dias, et al., 2023) por ser multimodal e aplicada para RR;
4. Foi utilizada a Teoria do Flow (Chen, 2007) por tratar de elementos para o equilíbrio entre níveis de desafios e habilidade que podem ser estendidos para atender a área de RR;
5. Foi utilizado o método de Aprendizado por Reforço (Aggarwal, 2018) por não necessitar de dados históricos para o treinamento da IA. Pelo fato de o jogo I Blue It ser uma solução acadêmica ainda pouco utilizada na prática clínica não se dispõe de uma massa de dados extensa o

suficiente para utilizar técnicas de IA que se baseiam em dados históricos.

1.4 ESTRUTURA

Esta tese está dividida em 10 capítulos. Capítulo 1, “Introdução”, apresenta os Jogos Digitais como recursos para reabilitação, descrevendo a lacuna e a questão de pesquisa. Introduz os conceitos fundamentais que envolvem esta pesquisa. O Capítulo 2, “Jogos Digitais”, explora o conceito de jogos digitais, categorias *exergames*, jogos sérios e multimodais, suas definições e características fundamentais, discute a técnica DDA e a Teoria do Flow. O Capítulo 3, “Inteligência Artificial”, apresenta as definições da área IA detalhando métodos e técnicas da área. O Capítulo 4, “Reabilitação Respiratória”, aborda os conceitos fundamentais sobre Reabilitação Respiratória, doenças e modalidades terapêuticas. O Capítulo 5, “Estado da Arte”, apresenta o uso de jogos digitais inteligentes na área da reabilitação e os trabalhos relacionados a esta tese, abrange uma revisão das tendências e oportunidades na área. Capítulo 6, “Tese”, apresenta o conceito *Flow Psicofisiológico em Jogos Digitais*. No Capítulo 7, “Prova de Conceito”, traz a prova de conceito com a aplicação do DeepDDA no JSA I Blue It. Capítulo 8, “Testagem do Flow Psicofisiológico”, descreve a abordagem estruturada para testar a prova de conceito. Capítulo 9 “Discussão”, discute o conceito de Flow Psicofisiológico em Jogos Sérios Ativos para Reabilitação, suas contribuições e impactos. Por fim, o Capítulo 10 apresenta a conclusão e descreve os trabalhos futuros.

2 JOGOS DIGITAIS

Segundo Salen e Zimmerman (2012), “um jogo é um sistema no qual os jogadores se envolvem em um conflito artificial, definido por regras, que implica em um resultado quantificável”. No entanto, o termo ‘jogo’ é usado para inúmeras atividades diferentes, resultando em várias definições (Salen; Zimmerman, 2012). Considerando o universo dos Jogos Digitais (JD), estes podem ser definidos como um sistema que possui hardware e software como componentes, podendo ser executados em computadores pessoais, consoles de jogo, dispositivos portáteis ou *arcades* (Miranda; Stadzisz, 2017). As tecnologias digitais são importantes, mas não deve ser enfatizada como artefato fim. São as características inerentes dos elementos do jogo, como interatividade, comunicação, manipulação, automatização, jogabilidade, mecânicas, dinâmicas, regras, objetivos, desafios, entre outros elementos, integrados às tecnologias digitais, que os definem (Salen; Zimmerman, 2012).

2.1 EXERGAMES

Os *exergames* são uma categoria de jogos digitais que combinam atividades físicas com elementos de *videogame*, promovendo tanto a atividade física quanto a mental. Esses jogos utilizam tecnologias como o *Kinect*, que captura movimentos em três dimensões e rastreia o esqueleto do jogador, permitindo uma interação mais natural e sem a necessidade de dispositivos adicionais. O conceito de *exergame* é particularmente relevante para intervenções em saúde, incluindo reabilitação física e mental, onde a combinação de exercício físico com estímulos lúdicos pode aumentar a motivação e a adesão ao tratamento (Milajerdi *et al.*, 2021).

A utilização de *exergames* em contextos terapêuticos tem mostrado benefícios significativos, especialmente em populações com necessidades especiais, como indivíduos com RR. Participar de treinamentos em *exergames* pode ajudar esses indivíduos a praticar habilidades motoras e funções executivas, oferecendo uma plataforma viável para o desenvolvimento dessas competências sem a necessidade de interações complexas ou a utilização de equipamentos difíceis de manejar (Milajerdi *et al.*, 2021).

Além dos benefícios físicos, os *exergames* também contribuem para o desenvolvimento cognitivo e emocional dos jogadores. A interatividade e o *feedback*

imediatos fornecidos pelos *exergames* criam um ambiente envolvente que pode promover o *flow*, um estado mental em que o jogador está completamente absorvido na atividade, resultando em uma experiência de aprendizagem mais eficaz e prazerosa (Csikszentmihalyi, 1990, p. 74).

No contexto dos jogos digitais, os *exergames* representam uma interseção entre tecnologia, saúde e entretenimento. Eles exemplificam como os avanços tecnológicos podem ser aplicados para criar experiências que são tanto divertidas quanto benéficas para a saúde. Ao integrar movimento físico com os desafios e recompensas dos jogos digitais, os *exergames* oferecem uma forma para promover a saúde e o bem-estar, adaptável a diversas faixas etárias e condições de saúde (Miranda; Stadzisz, 2017).

A seguir, são apresentados os Jogos Sérios (JS), outra categoria de jogos digitais que, embora compartilhem algumas características com os *exergames*, possuem finalidades específicas que vão além do entretenimento, como educação, treinamento e reabilitação.

2.2 JOGOS SÉRIOS

O conceito de Jogos Sérios (JS) foi criado em 1970 por Clark C. Abt, que definiu esta categoria como sendo jogos com finalidade educacional explícita e cuidadosamente pensada, onde o propósito primário é específico e com objetivos que vão além do puro entretenimento. Ou seja, não se destinam a serem jogados principalmente para diversão, mas isso não significa que o jogo sério não seja, ou não deva ser, divertido (Wilkinson, 2016). Esta área de estudo de JS tornou-se estável e popular a partir de 2002 com Ben Sawyer, ganhando dimensões multidisciplinares. Segundo Djaouti e colegas (Djaouti *et al.*, 2011), antes mesmo do ano de 2002, o ponto inicial do atual ecossistema de jogos classificados como JS, os projetos de jogos com propósitos primários além do entretenimento já estavam sendo desenvolvidos para a área como segurança, educação, governo, política, cultura e saúde.

De acordo com Troyer (2017), criar JS que efetivamente alcancem o propósito sério não é trivial. É necessário ter conhecimentos sobre a área de aplicação desejada, conhecimentos sobre jogos digitais e, dependendo do propósito do JS, também conhecimentos em pedagogia, psicologia, sociologia, medicina, engenharia, entre outras áreas. Segundo Buchinger e Hounsell (2015) e Noveletto *et al.* (2017), JS

são caracterizados como jogos digitais desenvolvidos com o objetivo de educação, treinamento, reabilitação ou outros objetivos governamentais ou corporativos. JS misturam as técnicas de interatividade, diversão e imersão com a prática de exercícios, visando aspectos específicos, combinados com aspectos lúdicos do entretenimento. Na área da reabilitação, os JS são tipicamente multidisciplinares, podendo envolver áreas da saúde, da computação e da engenharia. O design de jogos para programas de reabilitação deve seguir uma taxonomia dedicada e incluir exercícios direcionados para a reabilitação específica (Rego; Moreira; Reis, 2010) e com metodologia aderente ao propósito sério (Farias *et al.*, 2014).

Uma subcategoria importante dos JS é a dos Jogos Sérios Ativos (JSA) que combinam elementos de *Exergames* e JS. Esses jogos não apenas promovem a atividade física, mas também possuem objetivos educacionais, terapêuticos ou de treinamento. Os JSA são particularmente eficazes em contextos de saúde e reabilitação, onde a combinação de exercício físico com desafios cognitivos pode levar a melhorias significativas na saúde física e mental dos jogadores (Milajerdi *et al.*, 2021).

Ao explorar o potencial dos JSA, os profissionais de saúde e desenvolvedores de jogos podem criar experiências que não só entretêm, mas também educam e promovem a saúde e o bem-estar. A combinação de atividade física, desafio cognitivo e *feedback* imediato torna os JSA uma ferramenta valiosa na reabilitação e no treinamento, proporcionando benefícios que vão além do entretenimento e impactam positivamente a qualidade de vida dos jogadores.

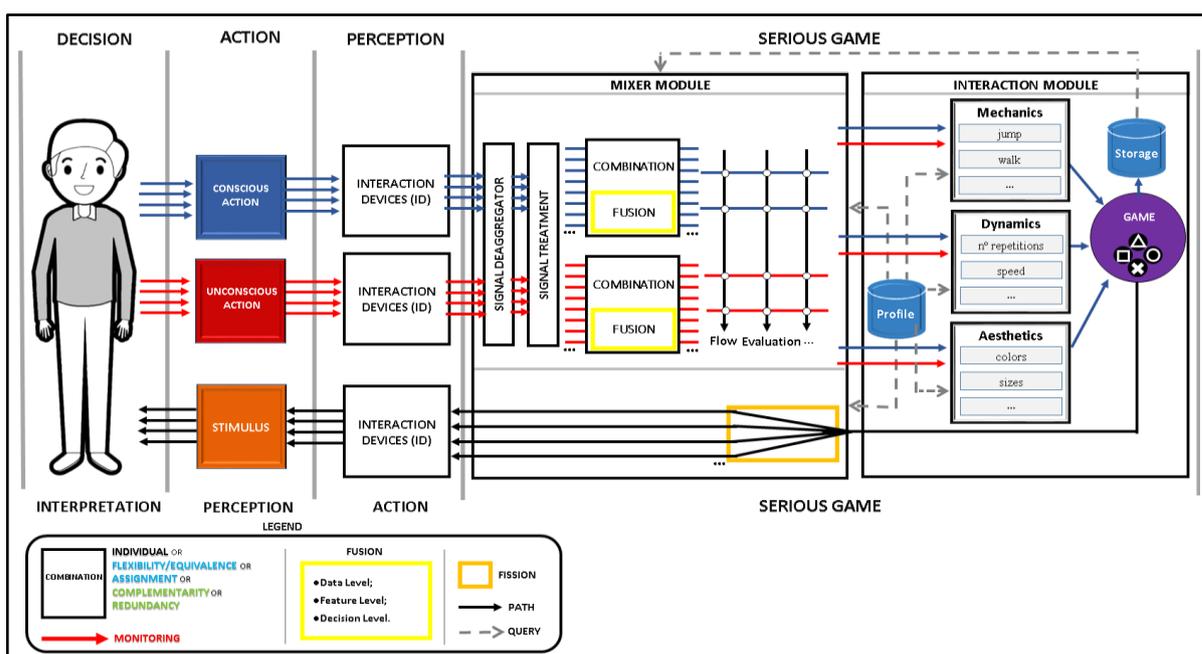
2.3 EXERGAMES SÉRIOS E MULTIMODAL

Serious Exergames Multimodais são sistemas que utilizam ao menos duas modalidades diferentes de dispositivos de entrada e/ou saída, suprimindo os aspectos de flexibilidade, complementariedade e segurança. A multimodalidade necessita de mecanismos para gerenciamento de interações, fusão de sinais advindos dos dispositivos e fissão de sinais para levar *feedback* ao usuário. Os autores propuseram uma arquitetura multimodal para JSA, intitulada 123-SGR, que contempla os três aspectos citados, com um determinado nível de abstração abrangente para permitir sua utilização em diversas áreas e em diversos propósitos (Dias *et al.*, 2023).

A arquitetura 123-SGR, integrada à versão 4.0 do JSA *I Blue It* (Nery *et al.*, 2020), é uma estrutura projetada para JSA com foco em reabilitação. Esta arquitetura abrange uma ampla gama de funcionalidades e efetua uma abstração dos fluxos de entrada e saída, além das comunicações entre os módulos e núcleos que compõem o sistema, como ilustrado na Figura 1.

A arquitetura 123-SGR é guiada por dois módulos: o *Mixer* e o Interação. Estes interpretam os sinais advindos da percepção de ações conscientes ou inconscientes e realizam o gerenciamento dos sinais e a interação com o JS. O módulo *Mixer* é composto por cinco núcleos (desagregador de sinais, tratamento de sinais, combinação, grade de adaptação e fissão) e o módulo Interação é composto por seis núcleos (mecânica, dinâmica, estética, jogo, armazenamento, perfil). Os fluxos dos estímulos são definidos pelos *feedbacks* promovidos pelas ações no JS.

Figura 1 - Arquitetura 123-SGR



Fonte: Dias *et al.*, (2023).

O fluxo consciente são ações que caracterizam a manipulação intencional das modalidades, realizada pelo jogador para gerar um resultado no *exergame*. O fluxo consciente passa pelos seguintes estados:

- Decisão: O jogador cria conscientemente uma mensagem.
- Ação: O jogador executa a ação que representa a mensagem pensada.

- Percepção: As mensagens são percebidas por um ou vários dispositivos.
- Módulo Mixer: Responsável pela gestão de sinais consiste e divide-se em cinco núcleos:
 - i. Desagregador de Sinais: separa informações para que possam ser utilizadas no jogo.
 - ii. Tratamento de Sinais: determina como o sinal é coletado (amostragem de dados, filtragem, etc.), se há necessidade de amplificação de sinal via software, como os dados válidos são extraídos e como esses dados válidos são usados no jogo.
 - iii. Combinação: Recebe os sinais dos dispositivos e determina como cada um deles procederá: (i) se flexível (um sinal OU outro); (ii) com atribuições diferentes (um faz A, o outro faz B); (iii) como fusão de modalidades redundantes (um e um); (iv) como fusão de modalidades complementares (um e outro); (v) ou diretamente (quando há apenas um sinal).
 - iv. Grade de Adaptação: responsável por realizar os testes, parametrizados por um terapeuta, para gerar adaptações que podem afetar a mecânica, dinâmica e estética do JSA. Trata apenas de adaptações para fins de fluxo (manutenção do interesse do jogador) e avaliação física (monitoramento), mas este núcleo permite a adição de tantos testes e adaptações quanto necessários, considerando possíveis conflitos entre gatilhos (valores definidos pelos terapeutas que requerem mudanças).
 - v. Fissão: analisa a mensagem de feedback do núcleo do jogo e a entrega ao jogador por meio dos dispositivos disponíveis, por exemplo, um monitor e uma caixa de som.
- Módulo Interação: Responsável por aplicar as adaptações e a interação no JSA. Este módulo possui 6 núcleos distintos:
 - i. Mecânica: responsável pelas ações a serem executadas, como pular ou andar, com base nas informações recebidas da Grade de Adaptação.
 - ii. Dinâmica: responsável pela dificuldade do jogo; controla parâmetros como velocidade, número de repetições, tamanho

- das áreas de colisão de obstáculos, altura das áreas de colisão de alvos, fórmula de pontuação, etc.
- iii. Estética: determina os aspectos visuais do jogo, como cores, formas e tamanhos dos objetos.
 - iv. Jogo: onde os aspectos mecânicos, dinâmicos e estéticos são aplicados.
 - v. Armazenamento: onde os dados do jogo, bem como os sinais dos dispositivos, são gravados, separados por jogador e linha do tempo.
 - vi. Perfil: núcleo que serve à Grade de Adaptação e aos núcleos de mecânica, dinâmica e estética, de modo que as adaptações sejam feitas de acordo com as capacidades e patologias dos usuários.

O fluxo inconsciente capta as características fisiológicas inconscientes ou não intencionais do paciente (às vezes além do limite desejável). Por exemplo, alterações na frequência cardíaca e na saturação de oxigênio. Esse fluxo de interação permite que a funcionalidade seja monitorada e é descrito através dos estados abaixo.

- Decisão: no fluxo inconsciente, não há uma decisão sendo tomada intencionalmente, mas sim uma reação provocada pelas ações conscientes do primeiro fluxo; por essa razão, o estado "Decisão" não é evidenciado neste fluxo.
- Ação: o estado fisiológico do jogador é capturado pelo sistema, independentemente das interações do jogador.
- Percepção: comporta-se da mesma maneira que o fluxo consciente; no entanto, os sinais (mensagens) são capturados por outros dispositivos específicos, ou outros sinais de dispositivos existentes são interpretados.
- Jogo Sérió: neste estado, o fluxo inconsciente passa pelos mesmos módulos com as mesmas funcionalidades que o fluxo consciente, mas eles estão preocupados com sinais não intencionais para objetivos de monitoramento de segurança.

Após receber sinais dos fluxos consciente e inconsciente, as modificações necessárias são aplicadas ao jogo e, para completar o ciclo de interação, o jogo

retorna uma resposta, mostrando ao paciente o que mudou no jogo. O fluxo de feedback é descrito abaixo:

- Jogo S3rio: Este 3 respons3vel por analisar as ocorr3ncias do jogo e produzir feedback para o jogador:
- Jogo: este n3cleo envia uma mensagem de resposta ao m3dulo Mixer.
- Perfil: este 3 um n3cleo que ajuda o m3dulo Mixer a enviar mensagens consistentes com o perfil do jogador. Por exemplo, se o jogador tem uma condi33o de defici3ncia auditiva, o m3dulo Mixer n3o deve enviar uma resposta em um canal de 3udio ou envi3-la em uma frequ3ncia aud3vel espec3fica.
- M3dulo Mixer: agora aciona o quinto n3cleo, fiss3o, que analisa as possibilidades e seleciona os dispositivos para entregar a resposta do jogo.
- A33o: a resposta fissurada 3 ent3o passada para os dispositivos dispon3veis.
- Percep33o: os sentidos do jogador capturam a resposta.
- Interpreta33o: o jogador interpreta o significado da resposta dada pelo jogo e o ciclo de intera33o multimodal se repete at3 o final da execu33o do jogo.

As defini33es dos m3dulos Mixer e Intera33o assumem um papel importante dentro da arquitetura 123-SGR. O m3dulo Mixer consiste em cinco n3cleos e 3 respons3vel pelo gerenciamento de sinais, combina33o e processos de adapta33o, garantindo uma integra33o eficiente de modalidades diversas para melhorar a jogabilidade. Por outro lado, o m3dulo Intera33o, com seus seis n3cleos distintos, gerencia a mec3nica do jogo, din3mica, est3tica e intera33es, resultando em uma experi3ncia de jogo personalizada. Esses m3dulos colaboram para permitir uma intera33o cont3nua entre os jogadores e o JSA.

A arquitetura 123-SGR pode ser utilizada em diversas 3reas de reabilita33o f3sica, especialmente na reabilita33o respirat3ria. O processamento de entradas multimodais pode ser realizado em v3rios n3veis de informa33o:

- No n3vel do sinal, onde a voltagem e a corrente em formas anal3gicas ou digitais s3o manipuladas.

- No nível dos dados, onde o nível do sinal é disponibilizado como uma sequência de valores no computador.
- No nível dos recursos, onde elementos do design do jogo que se referem a parâmetros como altura do alvo, tamanho dos obstáculos, espaço entre objetos e velocidade do jogo, por exemplo, são manipulados.
- No nível da decisão, onde os sinais provenientes da interação do paciente são aplicados a modificações no jogo.

2.4 O JSA “I BLUE IT”

O JSA de treinamento respiratório I Blue It Multimodal versão 4.0 (Nery *et al.*, 2020) e versão 4.5 (Dias *et al.*, 2023) foi projetado para auxiliar indivíduos com doenças respiratórias ao longo de seu processo de reabilitação. No jogo, os jogadores controlam um personagem golfinho chamado *Blue*, navegando por diferentes níveis e fases do jogo ao longo de sua jornada de reabilitação, manipulando seus movimentos por meio de técnicas específicas de respiração: ao exalar, o Blue submerge; ao inalar, o Blue salta. Os jogadores percorrem diferentes o jogo, coletando alvos e evitando obstáculos. Essa mecânica promove a prática de controle respiratório de maneira divertida e envolvente, incorporando elementos de jogabilidade que estimulam a atenção e a coordenação. Outras características incluem:

1. Projeto de código aberto, disponível gratuitamente em C# e implementado usando o motor de jogo Unity;
2. A montagem dos dispositivos também está disponível;
3. Benefícios da flexibilidade multimodal, pois nem todas as disfunções respiratórias lidam apenas com o fluxo de ar, mas também com a pressão do ar e outros aspectos;
4. Benefícios da complementariedade multimodal, pois alguns exercícios visam mudar a respiração dos pacientes, incluindo a quantidade de fluxo de ar que se pode produzir, músculos, posturas e outras medidas;
5. Benefícios do monitoramento multimodal, pois os exercícios respiratórios podem provocar vertigem em alguns pacientes, algo que pode ser identificado, por exemplo, através da saturação periférica de oxigênio ou da frequência cardíaca.

A versão mais recente de I Blue It está em conformidade com a arquitetura 123-SGR, incorporando diversos dispositivos de interação, como o Dispositivo Pneumotacógrafo (PITACO), Dispositivo Manovacuômetro (MANO-BD), Cinto Extensor e Dispositivo de Oxímetro de Pulso. Esses dispositivos medem e monitoram parâmetros respiratórios, incentivando ações respiratórias específicas, incluindo fluxo expiratório, fluxo inspiratório e manutenção de um fluxo constante.

2.5 AJUSTE DE DIFICULDADE

Os JS devem ser projetados para que possam ser personalizados e adaptados às necessidades e habilidades dos jogadores, fornecendo um nível adequado de dificuldade para aumentar o desempenho e manter o engajamento e entretenimento. O design de um JD deve considerar o adequado balanço entre os desafios do jogo e as habilidades do jogador para mantê-lo dentro do *flow* (Chen, 2007). Os profissionais envolvidos no design devem promover uma experiência divertida e interativa para uma grande variedade de perfis de usuários. Para isso, devem adotar no desenvolvimento do jogo os elementos contidos na teoria *flow* (condições, dimensões e canais) para implementar um método de adaptatividade que permita alcançar a experiência ótima do usuário perante as ações, as atividades e a interatividade no jogo, inclusive para diferentes perfis de jogadores.

A literatura apresenta alguns termos para o método de adaptatividade como, escala de dificuldade dinâmica, ajuste de dificuldade dinâmica, balanço de dificuldade dinâmica, adaptação em tempo real, ajuste procedural, geração de conteúdo e personalização (Cruz; Uresti, 2017). Entretanto, o termo mais frequentemente identificado na literatura é Ajuste Dinâmico de Dificuldade (*Dynamic Difficulty Adjustment - DDA*), e tem sido implementado em função das variáveis do jogo, como posição, velocidade e/ou pontuação (Andrade *et al.*, 2016), (Huygelier *et al.*, 2017), (Sekhavat; Iran, 2017). O ajuste também pode ser baseado em variáveis emocionais do jogador para alterar o nível de dificuldade (Pezzera; Borghese, 2020).

O sistema de adaptação age conforme interpretação das variáveis de entrada do jogo ou das variáveis de desempenho mantidas pelo jogo e pode ser dividida nas seguintes categorias (Novak; Mihelj; Munih, 2012) (Pezzera; Borghese, 2020):

- Automação adaptativa: ativa um agente autômato para prestar assistência automatizada, tornando a tarefa mais fácil ao usuário quando necessário. Por exemplo, piloto automático;
- Ajuste de dificuldade *off-line* do jogo: ajustes de parâmetros do jogo baseados no perfil do jogador ou no histórico do jogador;
- Ajuste de dificuldade *on-line* do jogo (ou, DDA): realiza ajustes em tempo real no jogo para torná-lo mais fácil ou mais difícil para o usuário, com desafios apropriados. Os ajustes podem ser providos em diversas subcategorias, como ajuste da mecânica, dinâmica, estética, audiovisual.

2.6 TEORIA DO *FLOW*

Flow é o estado mental ideal e de experiência ótima em que corpo e mente de um indivíduo atuam conectados, sendo as ações executadas congruentes aos objetivos pretendidos e percebidas pela consciência de modo que a energia psíquica flua sem esforços e com elevado nível de prazer (Csikszentmihalyi, 1990, p. 39). A Teoria do *Flow* define a fluidez da energia psíquica, o estado oposto da condição de entropia psíquica, que é a experiência subjetiva de envolver desafios gerenciáveis em uma série de objetivos, com *feedback* contínuo sobre o progresso e com ações de ajustes com base nos *feedbacks* (Csikszentmihalyi, 1990, p. 54) (Cruz; Uresti, 2017).

2.6.1 Condições do Flow

O estado mental de experiência ótima (*flow*) de concentração e imersão nas atividades é associado a três condições elementares: o equilíbrio entre níveis de desafios e habilidades; a existência de metas claras; e *feedback* imediato. O *flow* pode ser alcançado espontaneamente, por uma atividade estruturada ou pela capacidade do indivíduo de obter o *flow* (Csikszentmihalyi, 1990, p. 71).

O equilíbrio entre níveis de desafios e habilidades é a condição principal para ocorrência do *flow*. O termo desafio pode ser entendido como qualquer oportunidade de ação em uma atividade que proporcione oportunidade de melhorar o desempenho para que a ação não seja muito difícil e cause ansiedade, ou muito fácil e cause tédio. Na perspectiva da *Teoria do Flow* aplicada em jogos digitais (Chen, 2007), a área

definida como “*flow zone*” fornece ao jogador a experiência ótima em um fluxo agradável.

A condição de definir metas claras busca enfatizar que, para um indivíduo se envolver plenamente em uma atividade e assim manter o *flow*, é necessário que os objetivos parciais para alcançar o objetivo final estejam claros. As metas devem ser focadas na atividade a ser realizada para auxiliar o indivíduo a alcançar ou a manter o *flow*. A condição de *feedback* imediato busca emitir respostas automaticamente às ações realizadas pelo indivíduo e deve ser clara e precisa.

2.6.2 Dimensões do Flow

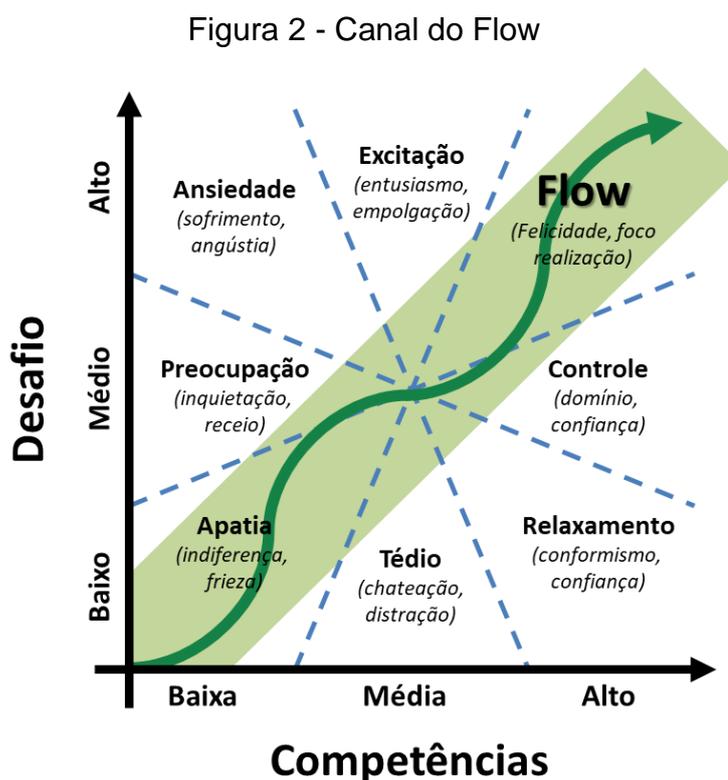
As três condições do *flow* apresentadas na seção anterior (equilíbrio entre desafios e habilidades, metas claras e *feedback*) são necessárias para manter o estado mental ideal e se manifestam em seis dimensões: concentração intensa, fusão de ação e consciência, perda de autoconsciência, sensação de controle, distorção da experiência temporal e experiência autotélica (Csikszentmihalyi, 1990, p. 71).

- Concentração intensa: ocorre quando a atividade é intensa e altamente envolvente. Somente os estímulos referentes as ações da atividade e que promovam o equilíbrio entre desafio e habilidade terão espaço para na consciência do indivíduo. Estímulos externos que não condizem com as metas, objetivos e ações da atividade não terão espaço na consciência de um indivíduo em estado de *flow*;
- Fusão de ação e consciência: Não há espaço para distrações, a atenção deve permanecer concentrada em um estímulo e o esforço para realizar a atividade não é percebido, levando o indivíduo a uma sensação de fluidez automatizada das ações;
- Perda da autoconsciência: À medida que ocorre a fusão entre as ações e consciência, ocorre a perda da autoconsciência, ou seja, as preocupações desaparecem;
- Sensação de controle: Potencializa o sentimento de segurança e confiança perante as ações;
- Distorção da experiência temporal: A percepção de tempo parece alterada, podendo ser mais rápida, mais lenta ou parada;

- Experiência autotélica: Refere-se a uma atividade envolvente, essencialmente motivadora e gratificante.

2.6.3 Canal do Flow

A Teoria do *Flow* representa a fluidez da energia psíquica relacionada diretamente com a interação com o meio em que o indivíduo está imerso. A clareza da comunicação entre o indivíduo e o mundo perante as ações realizadas na atividade deve ser eficiente e objetiva. Os efeitos psíquicos podem ser representados pela relação competências *versus* desafio por intermédio dos canais apatia, tédio, relaxamento, controle, preocupação, ansiedade, excitação e do canal *flow* (Csikszentmihalyi, 1990, p. 74), (Massimini; Carli, 1988), conforme exibido na Figura 2.



Fonte: Traduzido de Massimini e Carli (1988)

As variáveis psíquicas que promovem o estado mental ideal e de experiência ótima devem ser almejadas durante as atividades realizadas, promovendo bem-estar e felicidade.

2.7 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Os conceitos abordados neste capítulo destacam a relevância dos JSA no contexto da reabilitação. Isso pode ser constatado com a possibilidade de combinar os elementos de JD (JS e *Exergames*) com elementos da Teoria do Flow, resultando em técnicas de interatividade, diversão e imersão com a prática de exercícios, visando aspectos específicos combinados com aspectos lúdicos do entretenimento, mantendo o jogador engajado com um fluxo (*flow*) equilibrado e com desafios progressivos (Cruz; Uresti, 2017). Na área da reabilitação, esses jogos são importantes devido à possibilidade de personalização conforme as necessidades dos pacientes.

Os JSA podem ser usados para auxiliar os terapeutas e pacientes durante a reabilitação, tornando os exercícios mais atrativos ao paciente durante as sessões de fisioterapia. Isso é fundamental para estimular o paciente e auxiliar o terapeuta a observar o desenvolvimento do paciente. Por exemplo, se o jogo estimula uma sequência moderada de fluxo respiratório, mas, em resposta, o paciente faz uma sequência muito rápida, exalando mais do que inalando, isso pode ser avaliado e refletir na pontuação do jogo e na recuperação do paciente.

Neste contexto, a arquitetura multimodal 123-SGR, utilizada no JSA I Blue It, pode ser integrada com o método de DDA para ser um instrumento tecnológico de apoio à reabilitação.

3 INTELIGÊNCIA ARTIFICIAL

A Inteligência Artificial (IA) é uma área da computação que visa à concepção de sistemas inteligentes capazes de realizar tarefas que normalmente requerem inteligência humana. Esses sistemas são projetados para automatizar atividades que envolvem o pensamento e o comportamento humano, bem como o instinto e o comportamento animal, de modo geral, desenvolvendo e investigando sistemas que operam ou agem de maneira inteligente. A IA é um campo de pesquisa interdisciplinar que pode ser aplicado na resolução de uma ampla gama de problemas, desde os mais simples até os mais complexos (Russell; Norvig, 2010, p. 34). Na área da saúde, por exemplo, a IA pode ser usada para diagnosticar doenças, recomendar tratamentos e monitorar pacientes.

Em uma perspectiva, a IA pode ser definida em quatro categorias (Russell; Norvig, 2010, p. 2): Sistemas que pensam como humanos, Sistemas que agem como humanos, Sistemas que pensam racionalmente, Sistemas que agem racionalmente. Pensar como um humano sugere sistemas que modelam as propriedades de processamento cognitivo dos humanos, como um solucionador geral de problemas e sistemas que constroem modelos internos de seu mundo. Agir como um humano sugere que um sistema pode realizar algumas coisas específicas que os humanos conseguem fazer, o que inclui áreas como processamento de linguagem natural, raciocínio automatizado, representação do conhecimento, aprendizado de máquina, visão computacional e robótica. Pensar racionalmente sugere leis do racionalismo e pensamento estruturado, como silogismos e lógica formal. Finalmente, agir racionalmente sugere sistemas que fazem coisas racionais, como maximização da utilidade esperada e agentes racionais.

A IA permite a automação da inteligência e a concepção de sistemas inteligentes baseados na capacidade de analisar grandes volumes de dados, reconhecer padrões, tomar decisões autônomas e aprender com a experiência. Esses sistemas são utilizados em diversas aplicações, incluindo análise de dados, reconhecimento de padrões, automação de processos industriais, interação com usuários humanos. A IA permite a criação de agentes inteligentes que podem perceber seu ambiente, tomar decisões e agir de forma independente para atingir objetivos específicos (Luger, 2013, p. 18).

Nas subseções seguintes, são explorados os conceitos de IA que são essenciais para a implementação da prova de conceito proposta nesta tese. Serão abordadas técnicas específicas como redes neurais artificiais, aprendizado de máquina, aprendizado profundo e aprendizado por reforço profundo. Essas técnicas serão detalhadas, com o objetivo de fornecer uma compreensão clara e completa dos métodos utilizados e de como eles se inter-relacionam para alcançar os objetivos da pesquisa.

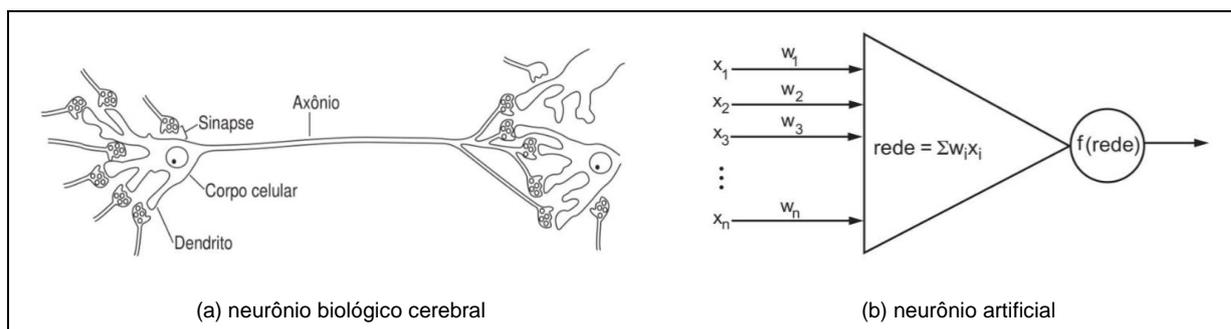
3.1 REDES NEURAIIS ARTIFICIAIS

As Redes Neurais Artificiais (*Artificial Neural Network - ANN*) são um dos modelos computacionais mais disseminados no campo da IA. São modelos inspirados pelo sistema nervoso central dos seres humanos e funcionam de maneira semelhante aos neurônios do cérebro, que possuem várias ramificações chamadas de dendritos e um único ramo chamado de axônio (Figura 3-a). Os dendritos recebem sinais de outros neurônios que são combinados e, quando excedem um limiar, disparam um impulso que é propagado ao longo do axônio. A base da ANN é o neurônio artificial, apresentado na Figura 3(b) (Luger, 2013, p. 29), que consiste em:

- Sinais de entrada x_i advindos do ambiente ou da ativação de outros neurônios;
- Um conjunto de pesos com valor real w_i que descrevem as forças de conexão;
- Um nível de ativação $\sum x_i w_i$ do neurônio determinado pela força cumulativa de seus sinais de entrada;
- Uma função de limiar f que calcula o estado final, ou de saída, do neurônio.

Os neurônios artificiais são os blocos fundamentais das redes neurais. Cada neurônio recebe múltiplos sinais de entrada, que são multiplicados por pesos associados a cada conexão. A soma ponderada dessas entradas é então passada por uma função de ativação, que determina a saída do neurônio. Esse processo permite que os neurônios processem informações de maneira não linear, o que é essencial para a capacidade de aprendizado das redes neurais (Luger, 2013, p. 29).

Figura 3 - Neurônio do cérebro e Neurônio Artificial

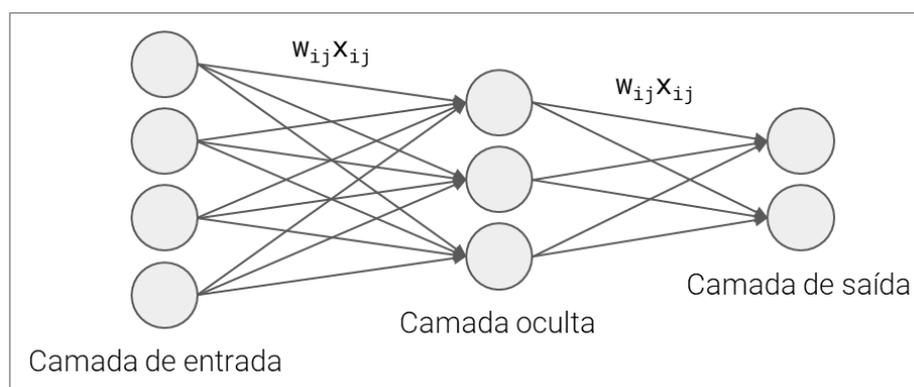


Fonte: adaptado de Luger (2013, p. 29)

A arquitetura das ANN consiste em um padrão de conexões entre os neurônios individuais, refere-se à estrutura e organização das conexões entre os neurônios. As ANNs são tipicamente organizadas em camadas (Figura 4) (Luger, 2013, p. 453):

- Camada de Entrada: Onde os dados brutos são recebidos pelo sistema;
- Camadas Ocultas: Onde o processamento e a transformação dos dados ocorrem através de múltiplas camadas de neurônios. O número de camadas e neurônios em cada camada pode variar dependendo da complexidade da tarefa;
- Camada de Saída: Onde a decisão final ou predição é feita.

Figura 4 - Camadas em uma ANN



Fonte: Adaptado de Luger (2013, p. 453)

As ANNs são divididas em diferentes tipos, sendo os dois principais (Skansi, 2018):

- *Redes Feedforward*: Onde a entrada é fornecida em um lado da rede e os sinais são propagados para frente (em uma direção) através da estrutura

da rede até o outro lado, onde os sinais de saída são lidos. Exemplos incluem o *Perceptron* e redes *Perceptron* Multicamadas (MLP);

- Redes Recorrentes: Onde ciclos na rede são permitidos e a estrutura pode ser totalmente interconectada. Exemplos incluem a Rede de Hopfield e Memória Associativa Bidirecional.

O *Perceptron* é um algoritmo de rede neural de camada única (rede de célula única) que motivou novas extensões e variantes de arquiteturas de redes. O *Perceptron* é inspirado pelo processamento de informações de uma única célula neural (chamada de neurônio). A rede neural é treinada de modo que o erro entre a saída da rede e uma saída esperada conhecida é apresentado ao algoritmo e usado para modificar seu estado interno. No caso do *Perceptron*, é composto por uma estrutura de dados (pesos) e procedimentos separados para treinar e aplicar a estrutura. A estrutura é um vetor de pesos (um para cada entrada esperada) e um elemento de entrada de viés (*bias*). Um peso é inicializado para cada entrada, além de um peso adicional para um viés constante e fixo que geralmente é configurado como 1.0 (Skansi, 2018). A ativação da rede para um padrão de entrada de dados é calculada pela equação (3.1):

$$\text{ativação} \leftarrow \sum_{k=1}^n (w_k \times x_{ki}) + (w_{bias} \times 1.0) \quad (3.1)$$

Onde:

- n é o número de pesos e entradas.
- x_{ki} é o k -ésimo atributo no i -ésimo padrão de entrada.
- w_{bias} é o peso de viés.

Os pesos são atualizados conforme a equação (3.2):

$$w_i(t+1) = w_i(t) + \alpha \times (e(t) - a(t)) \times x_i(t) \quad (3.2)$$

Onde:

- w_i é o i -ésimo peso no tempo t e $t + 1$.
- α é a taxa de aprendizado.
- $e(t)$ e $a(t)$ são a saída esperada e real no tempo t .

- x_i é a i -ésima entrada.

Esse processo de atualização é aplicado a cada peso por vez, bem como ao peso de viés. As ANNs são amplamente utilizadas em diversas aplicações devido à sua capacidade de aprender e generalizar a partir de dados. Algumas das aplicações comuns incluem:

- Reconhecimento de Imagens: Utilização de ANNs para identificar e classificar objetos em imagens;
- Processamento de Linguagem Natural: Aplicação de ANNs para entender e gerar linguagem humana;
- Diagnóstico Médico: Utilização de ANNs para prever doenças com base em dados de pacientes;
- Sistemas de Recomendação: Aplicação de ANNs para sugerir produtos ou serviços com base no comportamento do usuário.

As ANNs são sistemas adaptativos capazes de modificar sua estrutura interna, tipicamente os pesos entre os nós na rede, permitindo que sejam usadas para uma variedade de problemas de aproximação de função, como classificação, regressão, extração de características e memória de endereçamento de conteúdo. As ANNs são geralmente difíceis de configurar e lentas para treinar, mas, uma vez treinadas, são muito rápidas na aplicação. Elas são altamente valorizadas por suas capacidades de generalização e tolerância ao ruído. No entanto, possuem a limitação de serem opacas, ou seja, oferecem pouca explicação ao especialista sobre porque as decisões foram tomadas, apenas como foram feitas (Skansi, 2018).

Nesta seção, exploramos os conceitos fundamentais das redes neurais artificiais e suas principais características. As subseções a seguir aprofundarão esses conceitos e mostrarão como eles são aplicados no contexto da tese para resolver problemas específicos.

3.2 APRENDIZADO DE MÁQUINA

O aprendizado de máquina (*Machine Learning - ML*) é uma subárea da IA que se concentra no desenvolvimento de algoritmos que permitem que os sistemas computacionais adquiram conhecimento a partir de dados. Esses algoritmos treinam os sistemas a identificar padrões, fazer previsões ou tomar decisões. O aprendizado

de máquina pode ser utilizado para a criação de sistemas inteligentes que podem adaptar seu comportamento com base na experiência adquirida (Luger, 2013, p. 453). O ML pode ser definido como a capacidade de um sistema computacional de melhorar seu desempenho em uma tarefa específica ao longo do tempo, à medida que é exposto a mais dados. O ML é categorizado em três métodos principais: aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço (Skansi, 2018).

O Aprendizado Supervisionado (*Supervised Learning - SL*) é um método de ML onde o algoritmo é treinado com um conjunto de dados rotulados. Cada exemplo de treinamento é composto por entrada e saída desejada. O objetivo do algoritmo é aprender a mapear entradas para saídas com base nesses exemplos. Esse modelo aprendido pode então ser usado para prever saídas para novas entradas. Esse método é utilizado em tarefas de classificação e regressão. Aplicações comuns incluem classificação de padrões em imagens, reconhecimento de padrões em sinais e previsão com base em séries históricas de dados (Kuncheva, 2004).

O Aprendizado não Supervisionado (*Unsupervised Learning - UL*) é um método de ML em que o algoritmo é treinado com um conjunto de dados que não possui rótulos. O objetivo é descobrir estruturas ocultas ou padrões nos dados. O sistema tenta aprender a estrutura subjacente dos dados sem informações explícitas sobre a saída desejada. Esse método inclui tarefas de clusterização, onde os dados são agrupados em clusters baseados em similaridade, de associação, onde o objetivo é encontrar regras de associação entre variáveis nos dados e de sumarização de dados. Aplicações comuns incluem segmentação de dados, identificação de padrões e detecção de anomalias (Kuncheva, 2004).

O processo de treinamento de modelos de ML envolve um conjunto de etapas que garantem a eficácia dos algoritmos em aprender padrões e fazer previsões a partir de dados (Luger, 2013). A seguir são apresentadas as etapas de treinamento de modelos de ML, tanto o SL quanto o UL compartilham algumas dessas etapas, embora existam diferenças devido à natureza distinta dos dois paradigmas.

A primeira etapa no treinamento é a coleta de um conjunto de dados e extração de características (*features*) relevantes da base de dados, que sejam representativos do problema a ser resolvido. Os dados devem ser limpos para remover ruídos, lidar com valores ausentes e normalizar ou padronizar os atributos para garantir consistência. Em ambos os métodos, a qualidade dos dados é importante, pois

determina a capacidade do modelo de aprender padrões (Kuncheva, 2004), (Luger, 2013). É uma fase implementada para obter as entradas do algoritmo. Frequentemente, são utilizados descritores para tratamento dos dados, que consistem em algoritmos de leitura e extração de características da base de dados, onde os resultados são entradas de dados representadas por vetores de característica os quais podem ser qualitativos ou quantitativos (Kuncheva, 2004).

A segunda etapa é a divisão dos dados, no SL, o conjunto de dados é tipicamente dividido em três subconjuntos: treino, validação e teste. O conjunto de treino é usado para ajustar os parâmetros do modelo, o conjunto de validação é utilizado para ajustar hiperparâmetros e prevenir *overfitting*, e o conjunto de teste é empregado para avaliar a performance final do modelo. No UL, embora a divisão em conjuntos de treino, validação e teste não seja sempre necessária, pode ser útil reservar um subconjunto dos dados para avaliar a eficácia dos modelos gerados (Kuncheva, 2004), (Luger, 2013).

A seleção de um algoritmo de aprendizado adequado é a terceira etapa fundamental em ambos os tipos de aprendizado. No SL, algoritmos comuns incluem k vizinhos mais próximos, regressão linear, máquinas de vetores de suporte, árvores de decisão e redes neurais artificiais. No UL, algoritmos comuns incluem K-means, análise de componentes principais, algoritmos de agrupamento hierárquico e ANNs. A escolha do algoritmo depende da natureza do problema e das características dos dados.

Durante o treinamento, o algoritmo ajusta seus parâmetros internos para minimizar a diferença entre as previsões do modelo e as saídas reais no SL, ou para descobrir padrões ou estruturas ocultas nos dados no UL. Em ambas os métodos, o objetivo é melhorar continuamente o desempenho do modelo através de iterações sobre os dados de treino (Luger, 2013).

No SL, o algoritmo é treinado com um conjunto de dados rotulados, onde cada exemplo de treinamento é composto por uma entrada e a saída desejada. O modelo aprende a mapear entradas para saídas com base nesses exemplos. No UL, o algoritmo é treinado com um conjunto de dados não rotulados e tenta aprender a estrutura subjacente dos dados sem informações explícitas sobre a saída desejada.

Em uma quarta etapa, a avaliação no método de SL envolve o uso do conjunto de validação para ajustar hiperparâmetros e tomar decisões sobre o refinamento do modelo. Métricas comuns de avaliação incluem precisão, recall, F1-score e erro

quadrático médio (MSE). No UL, a avaliação pode ser mais desafiadora devido à ausência de rótulos. Métodos de avaliação incluem métricas de coesão e separação para clusterização, e medidas de entropia e pureza para validação de agrupamentos (Kuncheva, 2004).

Os hiperparâmetros são parâmetros do algoritmo de aprendizado que não são aprendidos diretamente a partir dos dados, como a taxa de aprendizado ou o número de camadas em uma rede neural. No SL, esses parâmetros são ajustados usando os resultados da validação para melhorar o desempenho do modelo. No UL, o ajuste de hiperparâmetros baseia-se nos resultados da avaliação das estruturas ou padrões descobertos (Skansi, 2018). O processo de treinamento de modelos de ML, em ambos os métodos, envolve uma série de etapas que garantem a eficácia dos algoritmos em aprender e aplicar padrões significativos a partir de dados.

O Aprendizado por Reforço (*Reinforcement Learning - RL*) é um método onde um agente aprende a tomar decisões ao interagir com um ambiente. O agente recebe recompensas ou punições com base em suas ações e ajusta seu comportamento para maximizar as recompensas ao longo do tempo. Nesse método não se faz necessário base de dados para o ML, o treinamento utiliza das observações do ambiente, onde os agentes inteligentes podem perceber seu ambiente por meio de sensores e agir sobre ele por meio de atuadores, utilizando técnicas de IA (Ertel, 2017).

Por definição, agentes inteligentes são qualquer entidade capaz de perceber seu ambiente por intermédio de sensores e agir por intermédio de atuadores utilizando técnicas de IA (Russell; Norvig, 2010, p. 64). Por exemplo, um agente humano tem olhos, ouvidos, tato e outros órgãos sensoriais que permitem a percepção dos estímulos, além de pernas, braços e mãos que permitem a atuação. Exemplos de agentes inteligentes incluem agentes robóticos, agentes de softwares e agentes de jogos. Um ambiente de tarefas é caracterizado pelo acrônimo PEAS (*Performance, Environment, Actuators, Sensors*), onde a performance é a medida de desempenho atrelada aos objetivos das ações que se deseja obter, o ambiente é o espaço que permite obter percepções e atuar sobre ele, os atuadores são os controles possíveis sobre o ambiente e os sensores permitem obter os possíveis estímulos do ambiente (Russell; Norvig, 2010, p. 40).

Em RL, os Processos de Decisão Markoviano (*Markov Decision Process - MDP*) são um formalismo matemático utilizado para modelar o ambiente de decisão. Um MDP é definido por um conjunto de estados, ações, transições de estado e

recompensas, permitindo ao agente aprender políticas de ação que maximizam as recompensas esperadas. Os sistemas são capazes de aprender sobre opções táticas e estratégicas possíveis em seu ambiente para obter *insights* que levam melhores decisões (Millington; Funge, 2009).

O MDP é um framework fundamental na teoria de controle e aprendizado por reforço, que consiste em estados, ações, uma matriz de transição, recompensas e um fator de desconto. As equações de *Bellman* são utilizadas para encontrar políticas ótimas que maximizam as recompensas acumuladas. Métodos clássicos para resolver MDP incluem Iteração de Política, Iteração de Valor, Métodos de Monte Carlo e TD-Learning (Kumar *et al.*, 2019). Entretanto, quando as probabilidades de transição de estados e as recompensas são desconhecidas, é necessário aprender esses parâmetros utilizando RL. Algoritmos como Q-Learning e suas extensões, como o Deep Q-Learning, são desenvolvidos para abordar esses problemas, permitindo o aprendizado eficiente em ambientes complexos e desconhecidos (Mnih *et al.*, 2015).

Uma das grandes dificuldades do aprendizado por reforço tradicional é a necessidade de armazenar tabelas gigantescas que mapeiam todos os pares de estado e ação, conhecidos como tabelas $Q(state, action)$. À medida que o número de estados e ações aumenta, essas tabelas se tornam impraticáveis de armazenar e gerenciar devido ao seu tamanho exorbitante. Em contraste, o uso de ANN em aprendizado por reforço, como no Deep Q-Learning, resolve esse problema ao prever os valores Q diretamente a partir dos pares $(state, action)$ (Mnih *et al.*, 2015). Isso permite uma representação mais compacta e eficiente, capaz de generalizar entre estados e ações, e reduz significativamente a necessidade de armazenamento, facilitando o aprendizado em ambientes complexos e de grande escala.

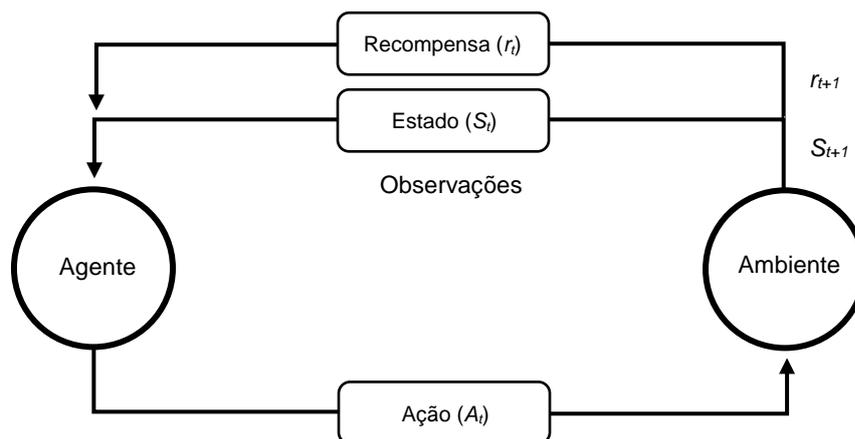
O RL é um método de ML que permite a tomada de decisão baseada na interação de um agente com um ambiente. RL estuda técnicas de como os agentes devem realizar ações em um ambiente para maximizar as recompensas recebidas, orientando o processo de aprendizagem e melhorando gradativamente seu desempenho. Um agente de RL pode ser descrito como um agente que busca um objetivo orientado pela experiência de tomadas de decisões que possam aprender por um processo contínuo, de modo a maximizar as recompensas (Aggarwal, 2018, p. 373).

A base do RL é a relação entre ação de um agente e a recompensa de um ambiente, por um MDP, apresentada na Figura 5, onde não se conhece as

probabilidades de transição de estados nem as recompensas (Aggarwal, 2018, p. 378), que consiste em:

- Agente: tudo o que é capaz de perceber seu ambiente e agir sobre ele, adotando a melhor ação possível diante de uma situação;
- Ambiente: o espaço em que o agente atua e realiza ações;
- Ação (A_t): uma saída especificada por um mapeamento que altera o ambiente e conduz o agente a um estado novo em um instante t ;
- Estado (S_t): representa todas as variáveis descritas no estado atual em um instante de tempo t ;
- Recompensa (r_t): o ambiente dá recompensa para retribuir por uma boa ação, com base no quão boa foi a aprendizagem do agente em um instante de tempo t . Um algoritmo gerador de recompensas deve ser implementado para gerar, por exemplo, recompensas positivas ou negativas. As recompensas podem ser atribuídas ao final de cada passo ou ao final de uma sequência de passos (episódio);
- Regras: mapeia as percepções dos estados do agente para um conjunto de ações.

Figura 5 - Markov Decision Processes (MDP)



Fonte: adaptado de Aggarwal (2018, p. 378).

O processo de treinamento no RL, inicia-se com a definição do problema e modelagem do ambiente onde o agente operará. Isso envolve definir os estados possíveis, ações, recompensas e a dinâmica do ambiente (transições entre estados). Em seguida, ocorre a inicialização do agente, onde se deve inicializar os parâmetros

do agente, incluindo a política inicial (estratégia de ação) e a função de valor (que estima o valor das ações ou estados). A interação e exploração do ambiente ocorre com o agente executando uma ação com base na política atual. O ambiente responde com uma nova observação (estado) e uma recompensa. E, o agente atualiza suas estimativas de valor e ajusta sua política com base no feedback recebido (Aggarwal, 2018, p. 373) e (Schulman *et al.*, 2017).

Função de Valor e Política: O agente usa funções de valor para estimar a qualidade de um estado ou ação. Isso pode ser feito através de duas abordagens principais: Métodos baseados em valor: Como o *Q-learning*, que aprendem uma função de valor que estima o valor esperado das ações. Métodos baseados em política: Como a Otimização de Política Proximal (*Proximal Policy Optimization - PPO*), que aprendem diretamente a política que mapeia estados para ações (Schulman *et al.*, 2017).

O agente deve equilibrar a exploração (tentar novas ações para descobrir mais sobre o ambiente) e a aproveitamento (usar ações conhecidas para maximizar a recompensa). Estratégias como *epsilon-greedy*, onde o agente escolhe uma ação aleatória com probabilidade ϵ , são frequentemente utilizadas. Atualização de políticas e parâmetros pode ocorrer por duas técnicas: Atualização da função de política, que consiste em uma técnica com base em política, a política é atualizada para maximizar a recompensa esperada. Atualização da função de valor, que consiste em uma técnica com base em valor, a função de valor é ajustada para minimizar a diferença entre a previsão de valor e a recompensa real observada (Aggarwal, 2018, p. 373).

O desempenho do agente é periodicamente avaliado em um ambiente de teste. As políticas e funções de valor são ajustadas com base na avaliação para melhorar o desempenho. Hiperparâmetros, como taxa de aprendizado e fatores de desconto, são ajustados para melhorar a eficácia do treinamento. A seguir são apresentados os principais algoritmos de RL:

- *Q-learning*: Um algoritmo de aprendizado baseado em valor que aprende a função de valor $Q(s, a)$ que dá a recompensa esperada de tomar ação a no estado s ;
- *SARSA (State-Action-Reward-State-Action)*: Semelhante ao *Q-learning*, mas a atualização depende da ação escolhida pela política atual;
- *DQN (Deep Q-Network)*: Combina *Q-learning* com ANN para lidar com grandes espaços de estado;

- PPO (*Proximal Policy Optimization*): Um algoritmo de aprendizado baseado em política que otimiza diretamente a política de ação, mantendo a estabilidade do treinamento através de uma função de perda com regularização. Faz uso de duas ANNs profundas, uma para função de política e uma para função de valor.

O treinamento no RL é distinto dos treinamentos dos métodos SL e UL, devido à sua natureza interativa e baseada em recompensas. Enquanto os outros métodos se concentram na análise de dados estáticos, o RL envolve uma dinâmica contínua de interação e adaptação, onde o agente aprende a melhorar seu comportamento através da experiência direta com o ambiente.

3.3 APRENDIZADO PROFUNDO

O aprendizado profundo (*Deep Learning - DL*) é uma área do ML que também abrange os três métodos principais de aprendizagem: supervisionada, não supervisionada e por reforço. Entretanto, o DL estende esses métodos para tratar problemas de IA em vários domínios que geralmente não são atendidos de forma abrangente no ML tradicional, como representação do conhecimento, raciocínio, planejamento, imagens e linguagem natural (Skansi, 2018). O DL oferece várias vantagens sobre as técnicas tradicionais de ML, incluindo (Aggarwal, 2018, p. 373):

- Automatização da Extração de Características: O DL elimina a necessidade de engenharia manual de características, aprendendo automaticamente as representações mais relevantes a partir dos dados brutos. pode realizar o processamento de extração de características com uma ANN profunda;
- Acurácia: Para problemas com volume muito grande de dados, apresenta melhor acurácia quando comparado com ML tradicional e pode ser útil para aprender representações de recursos de entradas sensoriais;
- Escalabilidade: As arquiteturas de DL podem ser escaladas para lidar com grandes volumes de dados e modelos complexos, melhorando a performance com o aumento dos dados;

- Generalização: Redes profundas são capazes de generalizar bem a partir de grandes quantidades de dados, capturando padrões complexos e sutis que métodos mais superficiais podem não detectar;
- Versatilidade: O DL pode ser aplicado em uma ampla gama de domínios e tarefas, desde reconhecimento de fala e processamento de linguagem natural até diagnósticos médicos e sistemas autônomos.

A área de ML obteve maior aderência da comunidade quando novos modelos, como rede neurais recorrentes e rede neurais convolucionais, começaram a ser aplicadas em grandes volumes de dados, com melhor acurácia e com melhor performance computacional. Neste contexto, o ML renasceu com o nome *Deep Learning* (Skansi, 2018).

O poder do DL decorre da possibilidade da decomposição repetida de múltiplas funções simples para obter uma função complexa. Isso aumenta a representação da rede e reduz o espaço de parâmetros necessário para o aprendizado. Redes mais profundas (com mais camadas ocultas), como a arquitetura da ANN podem aprender funções mais complexas, sendo capazes de lidar com grandes volumes de dados multissensoriais e de alta dimensão (Lecun; Bengio; Hinton, 2015).

No contexto do aprendizado por reforço, o termo "Deep" refere-se ao uso de múltiplas camadas ocultas em redes neurais para lidar melhor com problemas mais complexos. Ao considerar mais camadas ocultas, as redes neurais profundas (*Deep Neural Networks*) conseguem modelar e aproximar funções de alta complexidade, permitindo que o sistema aprenda representações mais abstratas e detalhadas dos dados de entrada. Isso é particularmente útil em ambientes onde as relações entre estados e ações são altamente não lineares e difíceis de capturar com abordagens tradicionais. Portanto, a profundidade adicional das redes neurais melhora a capacidade de lidar com desafios mais difíceis, proporcionando uma solução mais robusta e eficaz para problemas de aprendizado por reforço (Lecun; Bengio; Hinton, 2015).

Enquanto o ML tradicional muitas vezes depende de engenharia de características para transformar dados brutos em representações utilizáveis, o DL tem a capacidade de aprender essas representações diretamente dos dados brutos. Essa capacidade de aprendizado hierárquico torna o DL uma ferramenta para muitas

aplicações complexas. A seguir são apresentadas as principais arquiteturas de ANN (Aggarwal, 2018, p. 35) (Lecun; Bengio; Hinton, 2015).

- As Redes Neurais *Feedforward* (*Feedforward Neural Networks* - FNN) são o tipo mais básico de redes neurais, onde a informação propaga em apenas em uma direção: das camadas de entrada, através das camadas ocultas, até a camada de saída. Um exemplo clássico de FNN é o Perceptron Multicamadas (MLP), que consiste em múltiplas camadas de neurônios, com cada camada totalmente conectada à camada seguinte;
- As Redes Neurais Recorrentes (*Recurrent Neural Networks* - RNN) são um tipo de rede neural onde as conexões entre os neurônios formam um grafo dirigido ao longo de uma sequência temporal. Isso permite que as RNNs exibam comportamento temporal dinâmico, sendo ideais para tarefas onde a ordem dos dados é importante, como processamento de linguagem natural e séries temporais. As RNNs têm a capacidade de manter um estado interno (memória) que captura informações sobre entradas anteriores, permitindo que a rede modele dependências temporais complexas;
- As Redes Neurais Convolucionais (*Convolutional Neural Networks* - CNN) são especialmente projetadas para processar dados que possuem uma grade topológica, como imagens. As CNNs utilizam operações de convolução e *pooling* para extrair características hierárquicas dos dados de entrada, reduzindo a dimensionalidade e capturando padrões espaciais. As CNNs são amplamente utilizadas em tarefas de visão computacional, como reconhecimento de objetos, detecção de faces e segmentação de imagens.

Nesta seção, os fundamentos do aprendizado profundo, destacando suas principais técnicas e vantagens. As subseções a seguir detalharão como essas técnicas são aplicadas no contexto da tese para resolver problemas específicos e alcançar os objetivos de pesquisa.

3.4 APRENDIZADO POR REFORÇO PROFUNDO

O Aprendizado por Reforço Profundo (*Deep Reinforcement Learning* - DRL) é uma subárea emergente que combina técnicas de aprendizado por reforço com aprendizado profundo para lidar com problemas complexos que envolvem grandes espaços de estado e ação. O DRL utiliza ANN para aproximar funções de valor e políticas, permitindo que agentes inteligentes aprendam comportamentos ótimos através da interação com um ambiente (Aggarwal, 2018, p. 373).

O DRL estende o aprendizado por reforço tradicional, que se baseia na interação de um agente com um ambiente para maximizar recompensas cumulativas. A principal limitação do aprendizado por reforço tradicional é sua dificuldade em lidar com grandes espaços de estado e ação, devido à complexidade computacional envolvida na representação e atualização das funções de valor e políticas. O DRL supera essa limitação utilizando ANN para aproximar essas funções, permitindo que agentes aprendam comportamentos em ambientes complexos e dinâmicos (Aggarwal, 2018, p. 373).

As arquiteturas de ANN do método DL, como as FNN e as RNN, são exemplos de componentes do DRL. As FNN são usadas para aproximar funções de valor e políticas em problemas de decisão estática, onde a dependência temporal das ações é limitada. Já as RNN são utilizadas em cenários onde a dependência temporal é crítica, como em tarefas de controle sequencial e tomada de decisão ao longo do tempo (Aggarwal, 2018, p. 35). As FNN processam entradas e produzem saídas em uma única passagem, sem considerar o histórico das ações passadas. Isso as torna adequadas para problemas onde as ações são independentes no tempo. Por outro lado, as RNN mantêm um estado interno que captura informações sobre ações e estados passados, permitindo que a rede modele dependências temporais e tome decisões informadas com base no histórico de interações do agente com o ambiente (Aggarwal, 2018, p. 377).

O *Proximal Policy Optimization* (PPO) é um algoritmo de aprendizado por reforço profundo que se destaca pela sua eficiência e estabilidade. O PPO otimiza políticas diretamente, utilizando um mecanismo de *clipping* para evitar atualizações de grande escala que podem desestabilizar o treinamento. Esse método garante que as políticas sejam atualizadas de maneira controlada, mantendo um equilíbrio entre exploração e aproveitamento. O PPO combina as vantagens de métodos baseados

em gradiente de política com técnicas de controle de variância para melhorar a estabilidade e a eficiência do treinamento. Ele utiliza uma função de recompensa substituta que penaliza mudanças significativas na política, incentivando atualizações incrementais que preservam a robustez do modelo (Schulman *et al.*, 2017).

As aplicações de DRL são vastas e abrangem diversos domínios, incluindo:

- Jogos: Agentes de DRL têm alcançado desempenho super-humano em jogos complexos como Go, xadrez e videogames;
- Robótica: DRL é utilizado para ensinar robôs a realizar tarefas complexas, como manipulação de objetos, navegação autônoma e interação com o ambiente;
- Finanças: Aplicações de DRL em finanças incluem negociação algorítmica, gestão de portfólios e previsão de mercado;
- Saúde: DRL é utilizado para otimizar planos de tratamento, personalizar terapias e melhorar a eficiência de diagnósticos médicos.

Nesta seção, os fundamentos do aprendizado por reforço profundo, destacando suas principais técnicas e vantagens. As subseções a seguir detalharão como essas técnicas são aplicadas no contexto da tese para resolver problemas específicos e alcançar os objetivos de pesquisa.

3.5 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo, foram apresentados os métodos e técnicas de IA destacando sua utilização em diversas áreas, como saúde, onde é utilizada para diagnóstico, recomendação de tratamentos e monitoramento de pacientes. O método RL com a técnica de otimização PPO representa uma solução de aprendizado que máquina em problemas complexos e sem dados históricos. Esse método é aplicado em áreas como jogos, robótica e finanças, onde decisões sequenciais e otimização são necessárias.

As ANN desempenham um papel importante como o treinamento dos algoritmos de Aprendizado por Reforço, como o PPO, potencializando o desenvolvimento de agentes inteligentes mais robustos, capazes de enfrentar desafios complexos em diversos domínios. A combinação de RL, PPO e ANN destaca-se como uma abordagem capaz de aprender com a experiência e adaptar-se a diferentes cenários.

4 REABILITAÇÃO RESPIRATÓRIA

Segundo a *American Thoracic Society* e a *European Respiratory Society*, a Reabilitação Respiratória (RR) é definida como um programa de tratamento multidisciplinar implementado por uma equipe de especialistas da área da saúde. A RR é uma intervenção que incluem treinamento físico, educação e mudanças de comportamento, com o objetivo de melhorar a condição física e psicológica de indivíduos com doença respiratória (Machado, 2018). A RR é baseada na avaliação do paciente, seguida por terapias individualizadas com atividades e comportamentos que promovam a saúde (Nápolis; Chiavegato; Nascimento, 2011). O programa de RR deve combinar exercícios físicos, suporte nutricional, apoio psicológico e orientações educacionais, tudo de acordo com a fisiopatologia, a fim de promover mudança no estilo de vida do paciente (Nápolis; Chiavegato; Nascimento, 2011).

O exercício físico em pacientes com doenças respiratórias exige acompanhamento de profissional especializado, pois une as ciências da fisiologia do exercício com a fisiopatologia do paciente e da monitoração intensiva. Assim, para cada caso clínico, a terapia deve ser planejada e gradual conforme propostas e objetivos terapêuticos específicos, seguindo princípios que regem a adaptação e resposta muscular a estímulos graduais. Devem ser considerados a frequência, intensidade, tempo (duração), especificidade (tipo) e reversibilidade (Nápolis; Chiavegato; Nascimento, 2011).

Na prescrição de treinamento físico-respiratório, a frequência, a intensidade e o tempo são bases fundamentais dentro do protocolo de treinamento, que proverão as adaptações necessárias para a evolução do condicionamento físico-respiratório desejado. No entanto, é necessário respeitar outros fatores, como a individualidade biológica, a especificidade do treinamento, a característica da modalidade empregada, a sobrecarga do treinamento, a progressão e continuidade do treinamento. Não existe uma concordância sobre as melhores modalidades de treinamentos e parâmetros e a serem utilizados na prescrição de exercícios, devido à ampla variação dos protocolos de treinamento existentes. De forma geral, o treinamento deve objetivar o aumento da capacidade aeróbia e o aumento da força e resistência muscular periférica (Nápolis; Chiavegato; Nascimento, 2011).

A avaliação da capacidade física no acompanhamento de pacientes pneumopatas traz informações importantes sobre a doença respiratória, úteis para

determinar a gravidade da doença. Além disso, auxilia na determinação do programa de treinamento, prognóstico, respostas a intervenções, e na determinação de sua efetividade (Nápolis; Chiavegato; Nascimento, 2011).

A fraqueza muscular esquelética na UTI é observada em cerca de 25% dos pacientes que estiveram sob ventilação mecânica por mais de sete dias (Machado, 2018). Entretanto, com o progresso da medicina, com o avanço tecnológico e as terapias respiratórias, há uma redução na mortalidade nas UTI e maior sobrevida dos pacientes.

Contudo, é importante atentar para aspectos decorrentes do aumento das comorbidades relacionadas à sobrevida dos doentes, como a limitação funcional decorrente da fraqueza adquirida na UTI, déficit de força muscular, dispneia, ansiedade, estresse e depressão. Nesses casos, é necessário submeter os pacientes a programas de RR para promover melhor qualidade de vida (Nápolis; Chiavegato; Nascimento, 2011).

4.1 FISILOGIA RESPIRATÓRIA

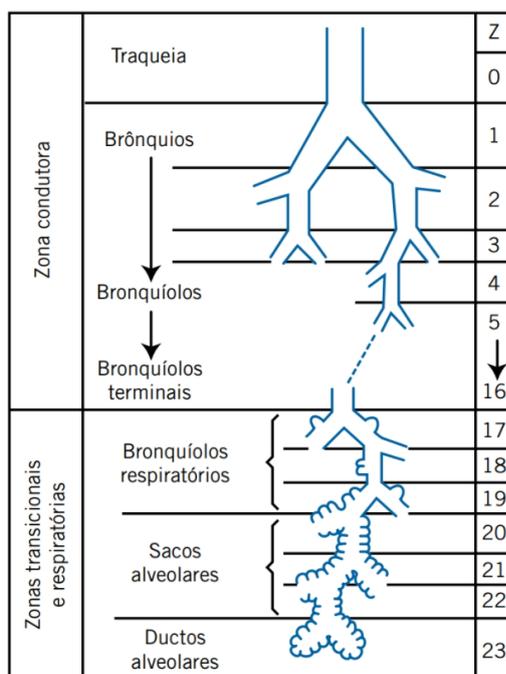
O sistema respiratório é composto por um conjunto de órgãos responsáveis por realizar a troca gasosa entre a atmosfera ambiente e as células do organismo. Sua função principal é permitir que o oxigênio se mova do ar para o sangue venoso e que o dióxido de carbono se mova do sangue venoso para o ar. Em humanos, o sistema respiratório é formado por: pulmões, fossas nasais, boca, faringe, laringe, traqueia, brônquios, bronquíolos e os alvéolos pulmonares (West, 2013). Além da troca gasosa, o pulmão realiza outras funções, como metabolizar alguns compostos, filtrar materiais indesejados e agir como reservatório de ar para o sangue.

As vias aéreas e fluxo aéreo, zona condutora exibida na Figura 6 (z0-z16), se dividem em uma série de tubos ramificados. A traqueia se divide em brônquio principal direito e esquerdo, que se dividem em brônquios lobares e, por conseguintes, brônquios segmentares. Este processo segue até os bronquíolos terminais, que são as menores vias aéreas sem alvéolos. Durante a inspiração, o volume da cavidade torácica aumenta e o ar é puxado para dentro dos pulmões por ações de fluxo-volume (West, 2013).

O oxigênio e o dióxido de carbono se movem entre o ar e o sangue por difusão, de uma área de pressão parcial alta para outra área de pressão parcial baixa. Na

membrana alvéolo-capilar, nas zonas transicionais e respiratórias exibidas na Figura 6 (z17-z23), é responsável pela difusão, que é realizada por um número enorme de pequenos sacos aéreos, denominados alvéolos, envolvidos pelos vasos sanguíneos, denominados capilares (West, 2013).

Figura 6 - Fisiologia Respiratória



Fonte: West (2013).

A mecânica do sistema respiratório depende da interação entre pulmão, tórax, diafragma e abdome. A parede do tórax é dividida em caixa torácica pulmonar e caixa torácica abdominal. Os músculos respiratórios torácico são considerados músculos esqueléticos e têm como função deslocar a parede do tórax de maneira rítmica para possibilitar a ventilação pulmonar e manter os gases sanguíneos arteriais dentro dos limites normais (Machado, 2018).

O músculo diafragmático é mais ativo que os músculos esqueléticos. Quando o diafragma se contrai, ocorre queda da pressão intrapleural e um aumento do volume pulmonar. Os músculos abdominais também desempenham um papel importante na atividade respiratória, predominantemente em ações expiratórias, descolando o diafragma dentro do tórax como geradores de pressão (Machado, 2018).

4.2 DOENÇAS RESPIRATÓRIAS

Doenças Respiratórias são distúrbios das vias aéreas e dos pulmões que podem afetar qualquer parte da fisiologia respiratória ou da mecânica dos músculos do sistema respiratório (Flaschen; Bates, 2019). O trato respiratório superior e o trato respiratório inferior podem apresentar uma gama de distúrbios devido à exposição ao meio ambiente (poeiras, gases, microrganismos) ou à densa rede de capilares por onde passa todo débito cardíaco, no qual doenças que afetam os vasos sanguíneos podem também afetar o pulmão. Além disso, o sistema respiratório é sensível a fenômenos alérgicos que podem afetar suas funções (Flaschen; Bates, 2019) (West, 2013).

Segundo um estudo de Wang *et al.* (2016) publicado pelo jornal médico *The Lancet*, existem cinco grandes doenças respiratórias que afetam milhões de pessoas: Doença Pulmonar Obstrutiva Crônica (DPOC), Asma, Infecção Aguda do Trato Respiratório Inferior, Tuberculose e Câncer de Pulmão. Essas doenças estão entre as causas mais comuns de morte em todo o mundo. Entretanto, além dessas cinco doenças respiratórias, há várias outras cuja incidência é grande, porém menos quantificada, que também podem comprometer a saúde do sistema respiratório, tais como (Levine *et al.*, 2021) rinite, sinusite crônica, faringite, bronquite aguda, entre outras morbidades advindas de doenças neuromusculares, genéticas, pós-cirúrgicas, cardíacas ou abdominais.

As principais divisões da fisiologia respiratória podem ser consideradas como base para a descrição das principais doenças do sistema respiratório. No caso dos brônquios, brônquios menores e bronquíolos, estes estão sujeitos à inalação de poeiras e partículas que podem levar a doenças causadas por inflamações crônicas ou processos infecciosos virais. Por exemplo, a bronquiectasia ocorre nos brônquios e pode ser resultado de fibrose cística, uma doença genética, ou de pneumonia, que pode ser provocada por vírus, fungo ou bactéria. Nos brônquios menores e bronquíolos, a asma é uma doença crônica muito comum que causa inflamações nas vias aéreas, uma condição em que as vias aéreas ficam estreitas e inchadas, provocando dificuldade para respirar (Flaschen; Bates, 2019).

Outra doença que também afeta os brônquios e que geralmente é provocada por infecção viral é a bronquite crônica, categorizada como uma DPOC. Doença respiratória que causa uma obstrução não reversível ao fluxo aéreo e, por

consequência, a perda progressiva das funções pulmonares. A DPOC tornou-se a quarta maior causa de morte mais comum no mundo (Fernandes, 2009).

Os dutos alveolares e alvéolos estão sujeitos, por exemplo, a pneumonia ou enfisema, ocorrendo a destruição alveolar e a perda de tecido. O enfisema pulmonar compõe o grupo de DPOC. As doenças da pleura podem estar envolvidas em processos inflamatórios, sendo a doença mais comum a tuberculose pulmonar, que pode acompanhar qualquer tipo de pneumonia, sendo a mais comum a tuberculose bacteriana infecciosa. O diafragma pode ser comprometido quando o pulmão apresenta inflamação crônica, como ocorre no enfisema, que causa a fadiga diafragmática, limitando a capacidade e a tolerância na realização de exercícios (Flaschen; Bates, 2019).

4.3 FISIOTERAPIA RESPIRATÓRIA

Por definição, fisioterapia é uma área da saúde que estuda, previne e trata os distúrbios físicos intercorrentes em órgãos e sistemas do corpo humano, que podem ser gerados por doenças adquiridas, traumas ou por mutações genéticas (Fernandes *et al.*, 2015).

Nas últimas décadas, a fisioterapia respiratória tem-se destacado como parte essencial da equipe multidisciplinar que compõe a UTI para prover a reabilitação do paciente, respaldada pela portaria nº 3.432 do Ministério da Saúde, que regulamenta a assistência fisioterapêutica em período integral, devido à sua eficácia em diminuir complicações, reduzir o período de hospitalização e aumentar o bem-estar (Nápolis; Chiavegato; Nascimento, 2011).

A fase aguda da doença pulmonar prolongada em paciente acamados ou imobilizados pode causar perda da contratilidade muscular, resultando na atrofia muscular (Nápolis; Chiavegato; Nascimento, 2011). A fisioterapia respiratória incorpora um conjunto de técnicas, exercícios e manobras que podem promover atividades otimizadas pelo treinamento de força e resistência, melhorando a contração muscular. A atuação fisioterapêutica precoce, com a contração muscular ativa, a retirada do paciente do leito e com os protocolos de mobilização progressiva, de acordo com a fisiologia e fisiopatologia do paciente, reduzem os fatores que levam à gênese da miopatia e à perda da força muscular (Nápolis; Chiavegato; Nascimento, 2011). O exercício físico é o pilar central de um programa de RR, e os benefícios

obtidos incluem: aumento da capacidade de tolerância ao exercício, melhoria da capacidade funcional, redução dos sintomas da dispneia e fadiga e melhoria do estado de saúde relacionado à qualidade de vida.

4.4 MODALIDADES E TÉCNICAS EM FISIOTERAPIA RESPIRATÓRIA

A fisioterapia respiratória reúne um conjunto de técnicas baseadas na aplicação terapêutica e deve ser adaptada a cada paciente de acordo com o acometimento do sistema respiratório, doenças associadas, condições clínicas, evolução do quadro, idade, fatores fisiológicos e capacidade de cooperação e adesão do tratamento (Sarmiento, 2016). Com foco em objetivos, a fisioterapia respiratória consiste em técnicas fisioterapêuticas para melhorar a mecânica ventilatória (pulmão, caixa torácica e músculos respiratórios) ou para a facilitação do *clearance* mucociliar com manobras de desobstrução brônquica (higiene das vias aéreas) (Sarmiento, 2016) (Modesto *et al.*, 2015). As modalidades de fisioterapia respiratória dividem-se em três principais áreas: higiene das vias aéreas, expansão pulmonar e treinamento dos músculos respiratórios.

Na modalidade de higiene das vias aéreas, também conhecida como remoção de secreções brônquicas, as secreções aumentam a resistência ao fluxo, dificultam as trocas gasosas e exaurem os músculos respiratórios. Esta modalidade pode ser realizada com objetivos de deslocamento da secreção brônquica para segmentos de maior calibre, remoção de secreções, favorecimento da drenagem torácica, aumento do fluxo respiratório, melhora da ausculta pulmonar e melhora das trocas gasosas. As seguintes técnicas podem ser utilizadas (Sarmiento, 2016) (Modesto *et al.*, 2015):

- Aspiração traqueal;
- Compressão torácica;
- Pressão expiratória positiva;
- Aceleração do fluxo expiratório;
- Tosse dirigida;
- Expiração forçada (*Huffing*);
- Ciclo ativo da respiração;
- Hiperinsuflação manual com ambu (*Bag-squeezing*).

A modalidade de expansão ou reexpansão pulmonar consiste em técnicas respiratórias indicadas em situações de redução dos volumes pulmonares. Estas técnicas têm como objetivo promover a redução da pressão pleural, aumento da pressão intrapulmonar, recuperação de volumes e capacidades pulmonares, prevenção ou reexpansão de áreas colapsadas, aumento da permeabilidade das vias aéreas e fortalecimento dos músculos respiratórios. As seguintes técnicas podem ser utilizadas (Sarmiento, 2016) (Modesto *et al.*, 2015):

- Exercícios respiratórios aeróbicos (esteira e cicloergômetro);
- Exercício diafragmático;
- Exercícios de inspiração profunda;
- Inspiração em tempos com ou sem pausa;
- Exercícios de expansão torácica localizada;
- Técnicas manuais de reexpansão pulmonar;
- Hiperinsuflação manual com ambu (*Bag-squeezing*);
- Respiração por pressão positiva ao final da expiração;
- Respiração por pressão positiva intermitente;
- Respiração por pressão positiva expiratória nas vias aéreas;
- Respiração por pressão positiva contínua nas vias aéreas;
- Respiração por pressão positiva nas vias aéreas em dois níveis (*Bi-level*).

Na modalidade de treinamento dos músculos respiratórios, as técnicas visam melhorar duas propriedades do músculo: força (*strength*) e resistência (*endurance*). A força corresponde à capacidade de realizar um esforço de contração máxima de curta duração (velocidade e explosão), enquanto a resistência corresponde à capacidade de sustentar um esforço durante um período de tempo (Machado, 2018). As seguintes técnicas podem ser realizadas visando ao ganho de força ou resistência, entre outras (Sarmiento, 2016) (Modesto *et al.*, 2015):

- Treinamento dos músculos inspiratórios com carga linear pressórica ou carga alinear pressórica;
- Treinamento dos músculos inspiratórios com hiperventilação isocápnica;
- Respiração diafragmática com peso sobre o abdome;

A escolha da modalidade fisioterapêutica depende dos objetivos prescritos para cada paciente e compõe o programa de reabilitação respiratória, com aplicações

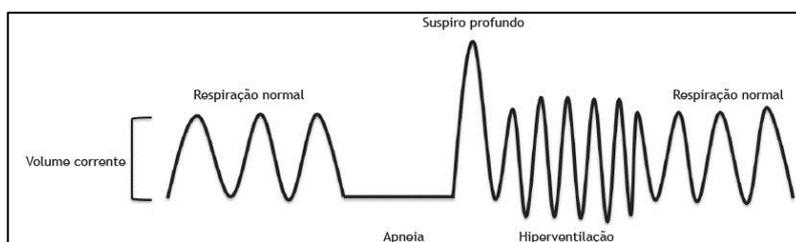
através de instrumentos e dispositivos clínicos. A seguir, é apresentada uma lista de instrumentos e dispositivos, não com o foco de definir suas aplicações e características, mas para ilustrar alguns exemplos:

- Pletismógrafo;
- Espirômetro;
- Manovacuumêtro;
- Pneumotacógrafo;
- Oxímetro;
- PEP;
- Flutter;
- Shaker;
- Acapella;
- Voldyne;
- Respirom;
- Power Breath.

4.5 DESCONFORTOS RESPIRATÓRIOS

Desconfortos respiratórios são quadros caracterizados por padrões de respiração irregulares, sendo os mais frequentes a dispneia, taquicardia e vertigem (Vidotto *et al.*, 2019). A Figura 7 mostra um exemplo de uma representação de padrões respiratórios, que podem surgir com o maior recrutamento dos músculos acessórios da respiração.

Figura 7 - Padrões respiratórios



Fonte: Adaptado de Vidotto *et al.* (2019)

Em várias doenças respiratórias, como DPOC e asma, o grau de recrutamento dos músculos acessórios indica a gravidade da doença e pode levar a desconfortos respiratórios (Vidotto *et al.*, 2019). A capacidade de realização de exercícios é um parâmetro comumente afetado pelas doenças respiratórias. Durante repetidas incursões respiratórias em exercícios de moderada à vigorosa, por exemplo, o paciente pode começar a respirar muito rápido, provocando descompasso da respiração e do batimento cardíaco, levando a desconfortos respiratórios. Três fatores podem influenciar o comportamento da respiração (aspectos bioquímicos, aspectos biomecânicos e sintomas respiratórios), resultando em diversas sensações (Vidotto *et al.*, 2019) (West, 2013) (Machado, 2018), tais como:

- Fadiga;
- Tontura;
- Dispnéia;
- Vertigem;
- Ritmo respiratório acelerado ou baixo;
- Ritmo cardíaco acelerado ou baixo;
- Taquicardia;
- Hiperventilação;
- Hipoventilação;
- Dessaturação;
- Parestesia;
- Entre outros desconfortos.

4.6 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo, foi abordado a importância da RR como um programa de tratamento multidisciplinar essencial para pacientes com doenças respiratórias. A RR combina treinamento físico, educação e mudanças comportamentais para melhorar a condição física e psicológica dos pacientes. A prescrição de exercícios deve ser individualizada, levando em consideração a fisiopatologia do paciente e monitorada por profissionais especializados.

A fisioterapia respiratória, como parte da RR, envolve técnicas que melhoram a mecânica ventilatória e a higiene das vias aéreas. A modalidade de treinamento dos

músculos respiratórios foca em melhorar a força e a resistência muscular, utilizando métodos adaptados às necessidades específicas de cada paciente.

Observa-se que a personalização do tratamento e a supervisão contínua são elementos-chave para alcançar os melhores resultados, proporcionando uma melhora significativa na qualidade de vida dos pacientes.

5 ESTADO DA ARTE

Neste capítulo, são apresentados um mapeamento sistemático da literatura e uma revisão sistemática da literatura sobre a utilização de inteligência artificial em jogos sérios aplicados à reabilitação respiratória. Também é realizada uma pesquisa complementar não estruturada com trabalhos relacionados a esta tese, além de serem discutidas as tendências e as oportunidades identificadas na literatura.

5.1 MAPEAMENTO SISTEMÁTICO DA LITERATURA

Para pesquisar o tema “Uso da Inteligência Artificial em Jogos Digitais aplicados à Reabilitação Respiratória”, aplica-se um Mapeamento Sistemático da Literatura (MSL) no período de janeiro de 2011 até maio de 2020, o qual forneceu uma visão geral da área de pesquisa estruturada na forma de relatórios e gráficos. Este mapeamento apresenta um resumo visual com a identificação de locais de publicação, extração e classificação das características relevantes ao tema, resultados gerais e contribuições. Trata-se de uma pesquisa mais abrangente e compreensível, ou seja, uma pesquisa em largura que categoriza os trabalhos relacionados e indica tendências (Petersen *et al.*, 2007) e (Petersen; Vakkalanka; Kuzniarz, 2015), em cinco fases:

- 1) Questões de pesquisa;
- 2) Definições e realização da busca;
- 3) Critérios de seleção (objetivos e subjetivos);
- 4) Classes de dados;
- 5) Extração de dados.

Cada fase do protocolo resulta em uma estratégia *top-down*, seguindo as diretrizes para condução do MSL, detalhadas no Apêndice A.

5.1.1 Pesquisa

Na fase do protocolo denominada “Definir as Questões de Pesquisa”, o foco é delimitar o escopo do MSL. Neste contexto, este estudo apresenta um levantamento sistemático da literatura para responder à seguinte Pergunta Primária (PP) de

pesquisa: Como a inteligência artificial tem sido usada nos jogos digitais aplicados à reabilitação respiratória? Para auxiliar na resposta à PP, as seguintes Perguntas Secundárias (PS_i) devem ser respondidas:

PS₁: Quais são as técnicas de IA mais usadas em relação aos JD?

PS₂: Para quais finalidades a IA tem sido usada em relação aos JD?

PS₃: Quais doenças respiratórias têm mais emprego de IA em JD?

5.1.2 Análise

Os resultados do mapeamento apresentam evidências de que esta área de estudo está em crescimento no número de publicações, com um incremento médio anual de 8% (Gráfico 1, Apêndice A). Para a obtenção desta taxa de crescimento, o ano de 2020 (ano que foi feito o mapeamento) foi desconsiderado, uma vez que os artigos não são cadastrados nas bases de dados imediatamente, podendo ainda surgirem novos artigos. A aplicação do Critério de Exclusão 3 (CE3) resultou na eliminação de seis artigos de revisão, mas nenhum relacionado ao tema deste estudo, o que indica claramente a necessidade do presente mapeamento da literatura.

Na relação entre os gêneros da narrativa do JD, suas origens e sinais utilizados, observa-se uma maior frequência do emprego de jogos comerciais dos gêneros ação e esporte (Gráfico 3, Apêndice A), controlados por captura de movimentos. Exemplos incluem as suítes de JD *Adventures*, *Wii Fit* e *EA Sports Active*, que promovem exercícios aeróbicos com dispositivos *Kinect*, *Wiimote*, entre outros. Isso ocorre, possivelmente, devido à popularidade e facilidade de adesão a consoles de *videogames* e dispositivos já disponíveis no mercado, com proeminência para as suítes de jogos comerciais desenvolvidas especialmente para esses equipamentos.

Tais artefatos têm sido utilizados por terapeutas como complemento à reabilitação respiratória por apresentarem exercícios aeróbicos que estimulam o treinamento cardiorrespiratório, similares ou equivalentes aos exercícios das intervenções fisioterapêuticas tradicionais. Nos JD autorais, observam-se os Jogos Sérios com expectativa de bons resultados por terem propósitos específicos. Nota-se que há uma maior frequência do emprego do gênero ação, controlados por captura de sinais da respiração.

Em apenas três artigos foi descrito o uso explícito de inteligência artificial, sendo que apenas um (TU et al., 2020) apresentou experimentos com jogos, enquanto

os outros dois (Kotova; Korvas, 2016) (Aguilar *et al.*, 2011) apresentaram, respectivamente, experimentos com dispositivos *Kinect* e *Wiimote*. Foram identificados artigos do uso de JD com maior frequência nas doenças respiratórias de Fibrose Cística e DPOC. Observa-se na relação entre técnicas de IA, tratamentos e doenças respiratórias que poucos artigos têm explorado o emprego de IA.

5.2 REVISÃO SISTEMÁTICA DA LITERATURA

Esta seção apresenta uma Revisão Sistemática de Literatura (RSL). A RSL é uma metodologia para identificar, selecionar, avaliar, analisar, interpretar e sistematizar as evidências relevantes disponíveis. Em outras palavras, trata-se de uma pesquisa aprofundada que produz resultados detalhados por meio de análise de conteúdo do material pesquisado (Kitchenham *et al.*, 2009).

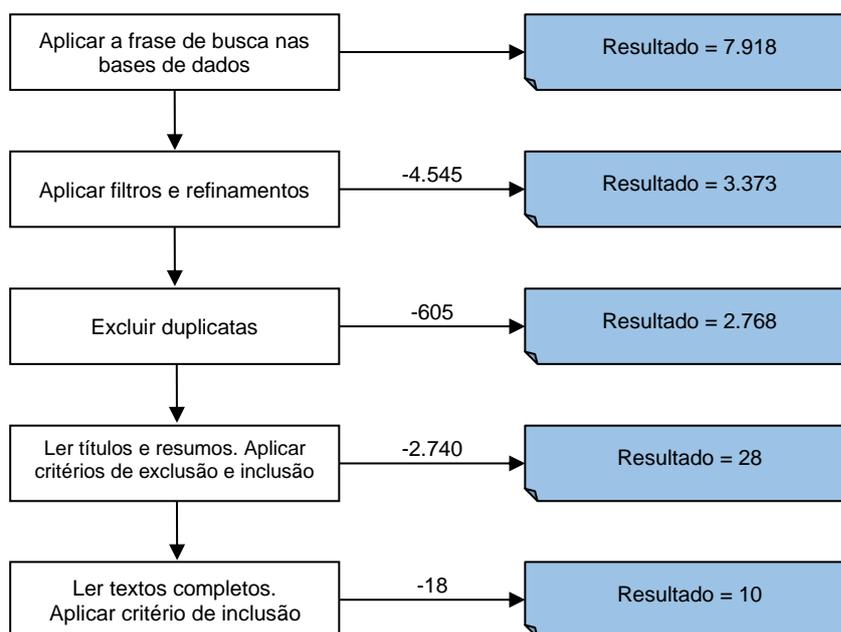
5.2.1 Artigos Relevantes

Esta revisão incluiu os artigos relevantes de um período de dez anos (de janeiro de 2011 até maio de 2020) sobre o “Uso da Inteligência Artificial em Jogos Digitais aplicados à Reabilitação Respiratória”, identificados a partir do Mapeamento Sistemático da Literatura realizado anteriormente, conforme Apêndice A (Dias *et al.*, 2020), que identificou e permitiu a seleção dos principais artigos que serão analisados nesta RSL.

Foram incluídos nesta análise apenas artigos que apresentaram mais de um dispositivo de controle e/ou monitoramento do JD (abordagem multimodal) e que utilizaram IA, seja de forma implícita ou explícita. A Figura 8 ilustra o processo de triagem e seleção de artigos em função do MSL e da RSL, que acrescenta um segundo Critério de Inclusão (Cl₂): “o artigo deve apresentar dois ou mais dispositivos de controle e/ou monitoramento que são utilizados durante o uso do JD”.

A pesquisa conduzida pelo MSL apresentou 7.918 artigos. Após a aplicação do protocolo de triagem, 28 resultados permaneceram para avaliação. Posteriormente, após a leitura completa dos textos e a aplicação do Cl₂, 10 estudos relevantes foram selecionados para RSL.

Figura 8 - Fluxograma de triagem e seleção de artigos



Fonte: Elaborado pelo autor (2020).

Observando a quantidade de artigos relevantes por região, dos dez artigos selecionados para RSL (Tabela 1), nota-se que 30% foram realizados por pesquisadores brasileiros, constituindo de pesquisas de estudo de caso, que representam 40% do total dos artigos. Quanto aos estudos clínicos randomizados e controlados, que são experimentos da área da saúde com melhor evidência científica e determinação da eficácia (West, 2013), foram identificados 3 artigos (Espanha, Itália e Estados Unidos).

O artigo que apresentou a maior amostra demográfica foi de Mazzoleni *et al.* (2014), com 40 pessoas, conduzido por ensaio clínico randomizado e controlado. Já o estudo com menor amostra demográfica foi conduzido por Pereira *et al.* (2013), com apenas 1 pessoa. Nota-se que 20% dos artigos não realizaram testes em humanos, sendo conduzido como estudos de caso com foco apenas de implementação tecnológica.

Em relação às doenças respiratórias consideradas pelos artigos, 40% são de população com DPOC, envolvendo adultos ou idosos, oriundos de diferentes países. Para doença respiratória FC, com 30% do total dos artigos, observa-se que 2/3 desses estudos foram conduzidos com crianças, provenientes de diferentes países.

Tabela 1 - Características dos estudos

ID	Referência	Doença	País origem	Tipo de pesquisa	População
1	Aguilar <i>et al.</i> (2011)	DPOC	Espanha, Noruega	Teste piloto	7 Homens e Mulheres (>18 anos)
2	Oikonomou e Day (2012)	FC	Reino Unido	Estudo de caso	30 Crianças (<15 anos)
3	Pereira <i>et al.</i> (2013)	-	Brasil	Estudo de caso	1 Criança (8 anos)
4	Wardini <i>et al.</i> (2013)	DPOC	Canadá	Teste piloto	32 Homens e Mulheres (50-80 anos)
5	Del Corral <i>et al.</i> (2014)	FC	Espanha	Estudo clínico randomizado e controlado	16 Crianças e adolescentes (7-18 anos)
6	Mazzoleni <i>et al.</i> (2014)	DPOC	Itália	Estudo clínico randomizado e controlado	40 Homens e Mulheres (50-80 anos)
7	Chacon <i>et al.</i> (2016)	-	Brasil	Estudo de caso	-
8	Henrique, Néry e Hounsell (2019)	-	Brasil	Estudo de caso	-
9	Yuen <i>et al.</i> (2019)	FC	Estados Unidos	Estudo clínico randomizado e controlado	20 Mulheres (50-80 anos)
10	Tu <i>et al.</i> (2020)	DPOC, Asma	Estados Unidos e China	Teste piloto	10 Homens e Mulheres (>18 anos)

Legenda. DPOC: Doença Pulmonar Obstrutiva Crônica; FC: Fibrose Cística.

Fonte: Elaborada pelo autor (2020).

As propostas dos estudos realizados pelos artigos selecionados nesta RSL (Tabela 2) foram divididas em duas linhas de pesquisas: 50% estão direcionadas à usabilidade de suítes de JD aplicados à RR, enquanto os outros 50% estão voltados para projetos de sistemas computacionais que envolvem JD. Destes, 4/5 são projetos de Jogos Sérios com exercícios respiratórios utilizando dispositivos de espirometria de incentivo.

Dos instrumentos de avaliação utilizados pelos estudos, 60% empregaram treino aeróbico, enquanto 40% utilizaram o teste de caminhada de seis minutos (*6MWD - Six-Minute Walk Distance*) e a Escala de *Borg* para classificação do esforço percebido. Em relação às modalidades de dispositivos utilizados, observa-se o uso de produtos do Nintendo Wii™ e de dispositivos desenvolvidos especialmente para JS, com o propósito de controlar/monitorar os exercícios respiratórios. As principais medidas fisiológicas realizadas pelos estudos foram FR, FC, SatO2 e os parâmetros da espirometria.

Tabela 2 - Principais instrumentos e resultados

ID	Proposta	Avaliação	Multimodalidade	Medida	Principais resultados
1	Projeto de sistema de controle usando Nintendo Wii™	- Treino Aeróbico	- Wiimote's câmera - Cinto abdominal com marcadores - Painele de array LEDs com 30 fotosensores infravermelho	FR	- FR (rpm) foi abaixo de 15% de erros em comparações aferidas visualmente pelo especialista - Monitora respiração - Dispositivo não-invasivo - Confortável
2	Projeto de Jogos Sérios para fisioterapia da Fibrose Cística	- Jogos Sérios com Exercícios respiratórios - Espirometria de incentivo	- PEP Mask - Teclado - Mouse	PEP	- Uso para pesquisas acadêmicas - Uso como referência para novos projetos - Monitorar o paciente durante a fisioterapia - Recurso para otimizar a fisioterapia - Motivar e engajar as crianças a fazer a fisioterapia
3	Avaliação de viabilidade do uso de jogos de Nintendo Wii™	- Treino Aeróbico	- Wiimote - Wii Balance Board	FR FC SatO ₂	- FR média 28rpm (aferida visualmente pelo especialista) - FC máxima 164bpm - SatO ₂ médio 95%±3% - O ambiente virtual promoveu efetividade, diversão, tarefas estimulantes e motivação
4	Avaliação de viabilidade do uso de jogos de Nintendo Wii™	- 6MWD - Treino Aeróbico - Escala de Borg	- Wii Balance Board - Wiimote	FC SatO ₂ FEV ¹ DBS	- FC média 102±18bpm - SatO ₂ médio 91%±5% - Encoraja o paciente a manter as atividades - Divertido
5	Avaliação de viabilidade do uso de jogos de Nintendo Wii™	- 6MWD - Treino Aeróbico - Escala de Borg	- Wiimote - Wii Balance Board - Mat controller	FR FC SatO ₂ VO ₂ FEV ¹ FVC DBS	- FC média usando Active Platform (Wii-Acti) 159.5 ± 14.1bpm - SatO ₂ médio 94%±3.3% - Videogames ativos são bem tolerados pelos pacientes - Obtém resposta fisiológica efetiva
6	Avaliação de viabilidade do uso de jogos de Nintendo Wii™	- 6MWD - Treino Aeróbico - Escala de Borg	- Wiimote - Wii Balance Board	FEV ¹ FVC MIP MEP FR SatO ₂ FC	- MIP médio 9.8±8.5 cm H ₂ O - MEP médio 9.8±6.7 cm H ₂ O - Melhor condições psicológicas - Potencial interativo do videogame
7	Projeto de Jogos Sérios para fisioterapia respiratória	- Jogos Sérios com Exercícios respiratórios - Espirometria de incentivo	- Espirômetro de incentivo - Sensor infrared para identificar o nível MIC e PIC	MIC PIC	- MIC mínimo 600 ml/min - A combinação de técnicas de fisioterapia em jogos estimula e incentiva o paciente
8	Projeto de Jogos Sérios para fisioterapia respiratória	- Jogos Sérios com Exercícios respiratórios - Espirometria de incentivo	- PITACO: Pneumotacógrafo - MANO: Manovacuômetro	FR Fluxo Volume	- Incentiva e complementa o processo de reabilitação respiratória - Maior participação profissional na evolução do paciente
9	Avaliação de viabilidade do uso de jogos de Nintendo Wii™	- 6MWD - SGRQ - Treino Aeróbico - Escala de Borg	- Wiimote - Wii Balance Board	FEV ¹ FVC DLCO	- Os resultados do estudo não apoiam intervenções em <i>home-based</i> (em casa), os resultados não foram eficazes.
10	Projeto de Jogos Sérios para treinamento da respiração	- Jogos Sérios com Exercícios respiratórios	- RV usando Tracker - Smart Watch - Smartphone	FR FC	- Acurácia efetiva das medidas fisiológicas da respiração - Prove capacidade de treinamento e experiência do usuário

Legenda. DE: medidas obtidas por Dispositivo Especial de JS; DF: medida obtida de Dispositivo Fisioterapêutico ou manual; PEP: Positive Expiratory Pressure FR: Frequência Respiratória (rpm-respirações por minuto); FC: Frequência Cardíaca (bpm-batimentos por minuto); SatO₂: Saturação de Oxigênio; MIC: Medida da Capacidade Inspiratória; PIC: Predição da Capacidade Inspiratória; MIP: Pressão de inspiração máxima; MEP: Pressão de expiração máxima; SGRQ: Saint George's Respiratory Questionnaire; 6MWD: Six-minute walk distance.

Fonte: Elaborada pelo autor (2020).

5.2.2 Análise

Esta seção apresenta uma síntese narrativa da análise dos principais aspectos evidenciados nos artigos relevantes exibidos na seção anterior. Dessa forma, para apresentar as principais semelhanças e principais diferenças encontradas, esta análise foi subdividida em doenças respiratórias, exercícios, sensores, *biofeedback* e *flow*.

5.2.2.1 Doenças respiratórias

Os estudos apresentados pelos artigos destacaram a RR como componente essencial para o tratamento de pacientes com doenças respiratórias, sendo a reabilitação um elemento essencial pelo aumento da capacidade e da tolerância na realização de atividades cotidianas, além de proporcionar melhor qualidade de vida em função do progresso da saúde do paciente.

Constata-se que quatro artigos incluem pesquisas sobre DPOC (Aguilar *et al.*, 2011), (Wardini *et al.*, 2013), (Mazzoleni *et al.*, 2014) e (tu *et al.*, 2020), um grupo de doenças respiratórias que causam lesões que obstruem o fluxo de ar, sendo bronquite e enfisema as mais comuns. Três artigos incluem pesquisas sobre FC (Oikonomou; Day, 2012), (Del Corral *et al.*, 2014) e (Yuen *et al.*, 2019). Durante o tratamento destas doenças, os pacientes enfrentam muitos desafios em dia a dia, incluindo a frequência regular de sessões de reabilitação em clínicas de fisioterapia, além dos desafios e esforços exigidos na realização de atividades prescritas no programa de reabilitação (Mazzoleni *et al.*, 2014).

No caso de pacientes com DPOC, treinos com exercícios fisioterapêuticos comumente fazem parte do programa de reabilitação respiratória. Existem casos de pacientes com Fibrose Cística (FC) em que são necessárias quatro sessões de fisioterapia por dia para remoção de secreções, a fim de reduzir a infecção e prevenir lesões no pulmão (Del Corral *et al.*, 2014) e (Yuen *et al.*, 2019).

Além das sessões de fisioterapia e avaliações quantitativas para medir e acompanhar a saúde dos pacientes, há casos de estudos (Mazzoleni *et al.*, 2014) que avaliam também a saúde dos pacientes por meio de medidas funcionais, tais como qualidade de vida pelo Questionário de Respiração de São George (*St. George's Respiratory Questionnaire – SGRQ*), composto por 76 itens divididos em três domínios

(sintomas, atividades e impacto). A ansiedade foi medida usando o Inventário de Depressão de Beck (*Beck Depression Inventory - BDI*) que contém 21 grupos de questões que avaliam a gravidade da depressão. No final da sessão, os pacientes responderam a um questionário sobre o grau percebido de aceitabilidade do programa de reabilitação, abordando aspectos como conforto, ausência de dor, fadiga, diversão, vantagens e desejo de continuar.

Neste contexto, considerando que a adesão a programas de reabilitação respiratória é essencial para garantir melhor qualidade de vida aos pacientes, esses programas podem se beneficiar dos recursos tecnológicos promovidos pelos JS para auxiliar nos problemas e/ou objetivos fisioterapêuticos. Um conjunto de abordagens para reabilitação, consistindo na combinação de programas de atividade física e técnicas fisioterapêuticas para o fortalecimento, expansão, resistência ou readaptação, pode contribuir com as condições de saúde do sistema respiratório. Além disso, os aspectos de entretenimento que os JS podem promover podem contribuir para um maior engajamento nas sessões de fisioterapia.

5.2.2.2 Exercícios

As atividades físicas identificadas nesta RSL para avaliação da saúde dos pacientes incluem treinos aeróbicos e exercícios respiratórios com espirometria de incentivo. Esses exercícios são guiados pelas propriedades de força e *endurance* (Machado, 2018) e estão contemplados em atividades como respiração diafragmática, inspiração máxima, expiração máxima, manutenção respiratória, técnica de relaxamento respiratório, expansão muscular torácica e abdominal, caminhadas, bicicleta ergométrica e exercícios com membros superiores e inferiores. Segundo Machado (2018), exercícios que contemplam as propriedades força e *endurance* em programas de RR têm como objetivo diminuir o esforço necessário para respirar e fortalecer a musculatura respiratória.

Observa-se nos estudos (Wardini *et al.*, 2013), (Del Corral *et al.*, 2014), (Mazzoleni *et al.*, 2014) e (Yuen *et al.*, 2019) o uso de dois mecanismos de avaliação da saúde do paciente, o teste 6MWD e a escala de *Borg*, respectivamente, para avaliar a capacidade e a percepção de esforço exigido. Esses mecanismos podem ser aplicados antes e depois dos exercícios fisioterapêuticos para avaliar o progresso do paciente. Essas medidas podem demonstrar se os efeitos fisiológicos do uso de jogos

digitais podem ser considerados similares aos da fisioterapia tradicional (Mazzoleni *et al.*, 2014).

Por conseguinte, as atividades de treino aeróbico, como caminhada, esteira ergométrica e/ou bicicleta ergométrica durante o uso de JD (Aguilar *et al.*, 2011), (Pereira *et al.*, 2013), (Wardini *et al.*, 2013), (Del Corral *et al.*, 2014), (Mazzoleni *et al.*, 2014) e (Yuen *et al.*, 2019), promovem movimentos repetitivos que contribuem com o progresso da saúde respiratória do paciente, refletindo na diminuição da frequência respiratória, na redução da dispneia e no aumento da tolerância às atividades. Nesse cenário, é necessário selecionar jogos adequadamente conforme a capacidade e as preferências de cada paciente (Del Corral *et al.*, 2014). Sugere-se que exercícios aeróbicos com *videogames* (*Wii Fit*, *Wii Sports*, *Wii Exerbeat*, *Wii Action*, *Wii Train*) proporcionam movimentação repetida e controlada dos membros superiores e inferiores (Pereira *et al.*, 2013) e podem induzir altas demandas fisiológicas capazes de produzir efeitos significantes se usado regularmente. Por exemplo, paciente jovens e com as funções pulmonares preservadas podem suportar a realização de exercícios de alta intensidades usando videogames (Del Corral *et al.*, 2014).

No artigo de Wardini *et al.* (2013), foram registrados e avaliados a segurança, viabilidade, diversão, presença e adesão aos programas de treinamento com exercícios usando *videogames* para comparações com programas tradicionais de reabilitação. Como resultado, obteve-se que exercícios moderados com JD foram considerados seguros e viáveis. No artigo de Del Corral *et al.* (2014), constatou-se que os *videogames* constituem em uma modalidade de treino com respostas fisiológicas efetivas, além de serem divertidos, mantendo-se estáveis a partir do terceiro minuto e possibilitando comparar as respostas fisiológicas durante o quinto minuto de treinamento no teste dos 6MWT, gerando altas demandas fisiológicas durante todas as atividades propostas nos videogames.

Exercícios que combinam JS com dispositivos especiais por espirometria de incentivo (Oikonomou; Day, 2012), (Chacon *et al.*, 2016), (Henrique; Néry; Hounsell, 2019) e (TU *et al.*, 2020) podem ser utilizados para fortalecimento da musculatura respiratória ou expansão pulmonar. Normalmente, envolvem pico de fluxo inspiratório, pico de fluxo expiratório, manutenção do fluxo inspiratório e manutenção do fluxo expiratório. A combinação de atividades de treinamento da respiração com monitoramento base em *biofeedback*, utilizando realidade virtual (Tu *et al.*, 2020),

pode ser prescrita como recurso complementar ao tratamento de doenças respiratórias, além de ajudar a controlar a ansiedade e o estresse.

Nesta circunstância, o monitoramento das valências fisiológicas durante os exercícios de reabilitação promove segurança aos pacientes (Tu *et al.*, 2020). Observa-se que todos os estudos apresentaram, ao menos, uma medida fisiológica utilizada na avaliação de doenças respiratórias, tais como SpO₂, FR, FC, fluxo respiratório, volume respiratório, duração respiratória, picos respiratórios, capacidade vital, entre outras medidas que permitem identificar sinais que influenciam a saúde respiratória. Por exemplo, Tu *et al.* (2020) realizaram experimentos em realidade virtual que supervisionaram e calcularam continuamente as medições fisiológicas, fornecendo experiência intuitiva e orientação contínua da respiração, promovendo o desempenho e experiência do treinamento com base em medições atuais e históricas.

Portanto, constata-se que o uso de *videogames*, por representarem um caminho inovador e facilitador de atividades físicas, tem sido incorporado como um recurso terapêutico em programas de reabilitação para ajudar a promover exercícios que podem contribuir para potencializar a melhora da saúde e bem-estar dos pacientes com doenças respiratórias.

5.2.2.3 Dispositivos e Sensores

Identifica-se que alguns estudos (Aguilar *et al.*, 2011), (Pereira *et al.*, 2013), (Wardini *et al.*, 2013), (Del Corral *et al.*, 2014), (Mazzoleni *et al.*, 2014) e (Yuen *et al.*, 2019) fazem uso de sensoriamento com dispositivos comerciais (*Wiimote, Wii Balance Board, Wii Mat Controller*) associados aos jogos digitais comerciais (*Wii Fit, Wii Sports, Wii Exerbeat, Wii Action, Wii Train*), pelo fato de suas propostas de estudos serem aplicadas na avaliação de viabilidade do uso de JD em reabilitação. Todavia, existem estudos com foco em projetar sistemas que podem também se beneficiar dos dispositivos comerciais citados anteriormente, com adaptações para propósitos específicos (Aguilar *et al.*, 2011). Além disso, há estudos que utilizam sensoriamento em novos dispositivos projetados especificamente para os propósitos da reabilitação respiratória (Oikonomou; Day, 2012), (Chacon *et al.*, 2016), (Henrique; Néry; Hounsell, 2019) e (Tu *et al.*, 2020).

No artigo de Wardini *et al.* (2013), as medidas fisiológicas da dispneia, SatO₂ e FC foram obtidas antes, durante e depois das sessões de treinamentos com jogos

digitais *Wii Fitness* e *Wii Sports* utilizando *Wii Balance Board* e *Wiimote*. Entretanto, Guirao *et al.* (2011) não fizeram uso de jogos, mas criaram uma arquitetura integrada de baixo custo com câmera *Wiimote*, cinto abdominal com marcadores e fotosensores infravermelho, aplicando técnica de aprendizado de máquina para reconhecimento dos padrões da respiração.

Foram identificados também sensores dedicados às medições de estímulos da respiração. No artigo de Oikonomou e Day (2012), foi desenvolvido um jogo que é controlado através da respiração utilizando um dispositivo de Pressão Expiratória Positiva (PEP), que usa um sensor de pressão que converte a pressão do ar exercido pelo paciente em sinal digital que é enviado para o PC pela interface USB. A combinação de JS com dispositivo que promove exercícios respiratórios que induzem a limpeza de secreções são recursos que encorajam crianças, adolescente e adultos na realização de fisioterapia, tendo potencial para ser adaptado a outros dispositivos de respiração para limpeza de secreções.

Chacon *et al.* (2016) utilizaram espirometria de incentivo usando um sensor acoplado na parte superior, composto por uma luz infravermelha que é emitida quando é detectado o fluxo da respiração, conforme a interação com os exercícios para expansão pulmonar usando JS. Henrique, Néry e Hounsell (2019) propuseram um dispositivo incentivador manovacuômetro que usa um sensor de pressão, e um dispositivo híbrido pneumotacógrafo e manovacuômetro, para ser usado como controle de um JS, incentivando a realização de exercícios respiratórios. Tu *et al.* (2020) utilizaram RV com sensores de acelerômetro e sensor PPG do *smartwatch* e *smartphone*, que medem continuamente os sinais biológicos, incluindo padrão de respiração, intervalo entre passos, amplitude da arritmia sinusal respiratória e calculam os padrões da respiração conforme dados atuais e históricos do paciente.

Estudos de reabilitação com JD focados na avaliação e viabilidade se alicerçam exclusivamente em controles de videogames populares com sensores de interação com *Kinect* e *Wiimote*, que são usados com mais frequência devido à sua facilidade de aquisição no mercado de jogos. Entretanto, projetos que se alicerçam em desenvolver novos controles apresentam-se como mais vantajosos (Tu *et al.*, 2020) no processo de reabilitação, pois possuem sensores dedicado aos biosinais, especialmente os sinais da respiração, permitindo a utilização de diversos dispositivos para controle e monitoramento integrados com JS (Oikonomou; Day, 2012), (Chacon *et al.*, 2016), (Henrique; Néry; Hounsell, 2019) e (Tu *et al.*, 2020).

Os métodos tradicionais de fisioterapia utilizam dispositivos médicos para medir e monitorar os sinais fisiológicos do paciente durante a reabilitação. Com a inclusão de JS na reabilitação, o tratamento ganha novos recursos, possibilitando a combinação de dispositivos eletrônicos com dispositivos e sensores que podem auxiliar tanto o paciente quanto o fisioterapeuta com informações sobre medidas fisiológicas e do monitoramento dos biosinais.

5.2.2.4 Biofeedback

Em reabilitação respiratória, é fundamental que os exercícios incentivados pelos JD sejam monitorados por um sistema biomédico para promover segurança ao paciente. Os sensores em JS multimodais com propósitos de reabilitação, combinados com o *feedback* contínuo, podem fornecer ao paciente segurança e informações sobre o progresso de seu tratamento (Nery *et al.*, 2020).

No trabalho de Aguilar *et al.* (2011), os autores descreveram que dar *feedback* em tempo real do padrão de respiração desempenhado pelo paciente em reabilitação promove efeitos positivos, aumentando a motivação e ajudando a melhorar suas habilidades respiratórias. Neste caso, são gravados os sinais da respiração, aplicadas técnicas de reconhecimento de padrões e, em seguida, fornecido *feedback* ao paciente sobre a velocidade de seu ritmo respiratório.

No artigo de Oikonomou e Day (2012), os JS propostos fornecem *feedback* sobre a quantidade de tempo gasto em cada jogo, a frequência de uso do jogo, a quantidade de litros de ar exalados, a pontuação e o ranque. Também exibem, em tempo real, em uma barra lateral, a medida da pressão exercida pelo paciente no sensor através da respiração.

Mazzoleni *et al.* (2014) realizaram monitoramento e *feedback* antes das sessões de fisioterapia baseados em jogos, consistindo em cinco minutos de atividade de respiração profunda em pé sobre a prancha de equilíbrio *Wii Balance Board*, com *feedback* fornecido na tela. Durante o jogo, foi realizado monitoramento contínuo da FR, FC e SatO₂, com *feedback* auxiliado por instrumentos fisioterapêuticos, onde a FC não podia ser superior a 80% do máximo previsto e SatO₂ não podendo ser inferior a 95%.

Chacon *et al.* (2016) propuseram um sistema que emite *feedback* visual por intermédio de um sensor de luz infravermelha, ativado quando é detectado o fluxo da

respiração. Este exibe na tela do JS uma barra com uma esfera que desloca conforme o fluxo respiratório, possibilitando observar a medição da capacidade inspiratória e a predição da capacidade inspiratória. Após as sessões, o JS permite uma série de visualizações sobre o desempenho do paciente.

Henrique, Néry e Hounsell (2019) propuseram um JS que fornece *feedback* visual e sonoro, incluindo cores e formas dos objetos de jogo e informações como pontuação, fase e nível. Tu *et al.* (2020) realizam experimentos similares aos padrões de protocolo de treinamento, utilizando um sistema inteligente intitulado *BreathCoach*, que realiza a sessão de treino com uso de RV, supervisionando e calculando continuamente as medições fisiológicas necessárias, como a detecção dinâmica da FR, seguido de *biofeedback* em tempo real.

5.2.2.5 Elementos do Jogo

Os elementos do jogo combinados com os sensores e os *biofeedbacks* provêm um ambiente de interação que beneficiam a reabilitação, possibilitando o monitoramento dos biosinais e o controle das ações durante os exercícios fisioterapêuticos.

Nos artigos de Oikonomou e Day (2012), Henrique, Néry e Hounsell (2019) e Chacon *et al.* (2016) foram desenvolvidos JS baseados em diretrizes de fisioterapia, com uma variedade de jogabilidades contendo níveis de dificuldade direcionados para cada faixa etária em com interface que acompanham o progresso do usuário na forma de pontuação e ranque. Outros elementos adicionais, como obstáculos, alvos, bônus, recompensas e energias, aumentam o desafio ao longo do jogo, proporcionando diversão extra e aumentando o engajamento e a motivação.

Observa-se que os JS projetados exclusivamente para reabilitação (Oikonomou; Day, 2012), (Chacon *et al.*, 2016), (Henrique; Néry; Hounsell, 2019) e (Tu *et al.*, 2020) apresentam elementos de jogo planejados de acordo com os objetivos terapêuticos dos exercícios, focando no progresso do jogador (paciente).

No estudo realizado no artigo de Wardini *et al.* (2013), as sessões de treinamentos com jogos digitais *Wii Fitness* e *Wii Sports*, utilizando *Wii Balance Board* e *Wiimote*, apresentaram elementos de jogos que incentivaram movimentos similares aos realizados em sessões de fisioterapias regulares. Isso reflete nas avaliações realizadas pelos estudos (Aguilar *et al.*, 2011) (Pereira *et al.*, 2013) (Mazzoleni *et al.*,

2014) (Yuen *et al.*, 2019), que também fazem uso de dispositivos associados aos jogos digitais comerciais. No artigo de Pereira *et al.* (2013), o ambiente virtual com treinamento aeróbico promoveu maior interesse e motivação pela terapia, criando um ambiente divertido e com tarefas estimulantes que influenciaram as respostas fisiológicas, como os valores da frequência cardíaca atingida durante o jogo.

Entretanto, somente um estudo (Tu *et al.*, 2020) apresenta explicitamente o uso das técnicas de IA para ajustar os elementos do jogo com o objetivo de treinar a respiração.

5.3 PESQUISA SOBRE DDA EM JS

Nesta seção, são apresentados os trabalhos identificados por uma pesquisa não estruturada, realizada como pesquisa complementar de estudos relacionados à tese. Esses trabalhos estão listados em ordem cronológica de publicação, seguidos por uma análise das contribuições e evidências identificadas.

5.3.1 Pesquisa complementar

Com base nos resultados e nas análises realizadas no MSL e na RSL, constatou-se que não foram identificados artigos abordando métodos de Ajuste Dinâmico de Dificuldade (DDA) durante o uso do jogo. Neste caso, decidiu-se realizar uma pesquisa complementar.

Para isto, foi feita a busca de trabalhos publicados no período entre janeiro de 2016 até julho de 2024, com a *string* de busca:

*("virtual reality" OR *game*) AND (difficulty) AND (flow OR adapt* OR adjustment OR scal*) AND (physio* OR rehabilitat* OR therap*)*

A busca foi realizada no banco de dados do MBA *Scopus*, por ter sido uma das bases que trouxe resultados consideráveis perante a busca realizada no MSL e por ser classificada com o uma das maiores bases de dados da literatura (Buchinger; Andriolli; Hounsell, 2014). A busca resultou nos artigos listados na Tabela 3.

Tabela 3 - Características dos artigos relevantes sobre o método DDA

Referência	Reabilitação	Modalidade	Dados	Técnica	Comportamento inteligente
Andrade <i>et al.</i> (2016)	Motora para AVC	Dispositivo háptico	Distância, Largura e Altura	IA com Algoritmo Evolucionário	Geração automatizada de exercícios com níveis adequados
Huygelier <i>et al.</i> (2017)	Motora para AVC	Óculos de RV	Tamanho, Posição	Estatística com Distribuição de <i>Gaussian</i>	Realiza o cálculo das posições e tamanho dos próximos alvos
Sekhavat e Iran (2017)	Motora para membros	<i>Kinect</i>	Velocidade, Tamanho e Distância	IA com Aprendizado por Reforço	Um agente realiza o ajuste das variáveis com base em recompensas
Garcia, Crocomo e Andrade (2018)	Motora para mão	Dispositivo háptico	Largura, Altura e Velocidade	IA com Algoritmos Evolucionários	As características dominantes são transmitidas (cruzamento e mutações)
Valencia <i>et al.</i> (2018)	Motora para Membros superiores	<i>Leap Motion</i>	Score do jogo e tempo	IA com Sistema de Inferência <i>Fuzzy</i>	Com base nas regras de inferências
Lopes, Magalhães e Cavaco (2019)	Motora para Disfonia	Som	Tempo de fonação e Intensidade vocal	Estatística com equações e parâmetros vocais	Com base nos modelos de sinais vocais
Pezzer <i>et al.</i> (2019)	Motora para equilíbrio	Sensores de Câmeras e <i>Balance Board</i>	Score do jogo, Metas diárias e Ranque	Analítica com equações e parâmetros	Com base nos modelos matemáticos
Pezzer e Borghese (2020)	Motora para equilíbrio	Sensores de Câmeras e <i>Balance Board</i>	Score do jogo e Estado emocional	IA com Sistema de Inferência <i>Fuzzy</i>	Com base nas regras de inferências ocorre ajuste da dificuldade
Aziz Hutama, Sihwi e Salamah, (2021)	Motora para Disgrafia	<i>Kinect</i>	Score do jogo	IA com Sistema de Inferência <i>Fuzzy</i>	Com base nas regras de inferências ocorre ajuste da dificuldade
Aguilar <i>et al.</i> (2022)	Atividade Física	Sensor de Movimento e FC	Score do jogo e FC	IA com Redes Neurais Artificiais	Ajuste dinâmico da dificuldade baseado em sinais fisiológicos e desempenho
Kostkova <i>et al.</i> (2023)	Visual Cerebral	Mouse e teclado	Score do jogo	IA com Aprendizado por Reforço e QLearning	Ajuste da dificuldade baseado no desempenho do jogador

Fonte: Elaborada pelo autor (2021).

5.3.2 Análise

Andrade *et al.* (2016) propuseram o método de Ajuste Dinâmico de Dificuldade (*Dynamic Difficulty Adjustment - DDA*) com base em Algoritmos Evolucionários (AE), aplicado em dois JS de reabilitação (*The Catcher e Happy Fish*) controlados por um dispositivo háptico de reabilitação motora para interação com pacientes com quadro clínico de AVC. O dispositivo emula um *joystick* convencional e promove resistência nos movimentos, resultando em treinamento muscular dos membros superiores. O algoritmo de IA proposto para o DDA avalia periodicamente os objetivos para realizar o ajuste do nível de dificuldade conforme capacidade do paciente. Cada cromossomo

de uma população do AE é caracterizado pelas variáveis distância $[0.01w \ 0.5w]$ e velocidade $[0.1h \ 0.5h]$, onde w é a largura da tela e h é a altura, em pixel. O algoritmo evolucionário inicializa uma população com valores randômicos e, em seguida, ocorre uma partida do jogo, na qual para cada cromossomo é calculado o *fitness*, gerando uma nova população pelos operadores de seleção e mutação. As variáveis distância e velocidade são ajustadas com base no sucesso ou fracasso do jogador em coletar alvos, sendo uma sequência de exercício do jogo (uma geração) definido pelo intervalo de tempo entre dois alvos, e entre sequências de exercícios podem ser gerados níveis de dificuldades diferentes.

Huygelier *et al.* (2017) apresentaram o *design* de um jogo de realidade virtual para reabilitação de pacientes com hemiparesia resultante de um AVC. O *design* do jogo associou os elementos de intervenção terapêutica (dispositivos incentivadores) da área da saúde com os elementos de mecânica da área de jogos, resultando em estímulos de atividades de movimentos interativos por intermédio da coleta de dois tipos de alvos. Conforme o desempenho do jogador, o algoritmo de DDA adapta a posição dos próximos alvos, tomando como base os valores das posições dos alvos (acertos e erros) de rodadas anteriores, que são usados como entrada para o algoritmo de DDA com distribuição gaussiana, determinando a localização futura dos próximos alvos em posições onde ocorrem erros, estimulando novas tentativas.

Sekhvat e Iran (2017) propuseram o uso do método DDA com base na técnica de Aprendizagem por Reforço para ajuste de dificuldade em tempo real com múltiplos objetivos avaliados em períodos diferentes. O jogo de reabilitação proposto utiliza o dispositivo *Kinect* para capturar os movimentos dos braços incentivados pelas rebatidas com as mãos nas bolas que surgem no cenário, sendo que os acertos acumulam pontos e os erros os diminuem. O nível de dificuldade é definido de acordo com as seguintes propriedades do jogo: velocidade em mover o personagem, tamanho das bolas e distância entre os arcos de bolas. O método DDA é baseado em aprendizado por reforço com múltiplos períodos, com ações que agregam recompensas para avaliar múltiplos objetivos, onde cada um é associado a um estado. Três indicadores (velocidade, tamanho e distância) avaliam a satisfação/desempenho do jogador, medindo o progresso ou regresso do paciente após cada rodada. Sendo uma rodada do jogo suficiente para medir se o objetivo 'um' foi satisfeito, ou a pontuação de duas rodadas consecutivas para medir se o objetivo 'dois' foi satisfeito ou um histórico de cinco ou mais rodadas para medir o objetivo 'três'.

Garcia, Crocomo e Andrade (2018) desenvolveram uma nova versão do algoritmo de DDA com base em Algoritmos Evolucionários, apresentado por Andrade *et al.* (2016). A estrutura do cromossomo de uma população foi caracterizada com três variáveis: largura, altura e velocidade. Os resultados apresentados sugerem que as técnicas de IA usadas para obter DDA podem ser adaptadas para diferentes jogos e elementos do jogo. Isto foi comprovado com a aplicação do algoritmo evolucionário ajustado para um novo jogo com novas jogabilidades.

Valencia *et al.* (2018) realizaram uma análise comparativa entre ajustes de dificuldade manual e DDA usando lógica *Fuzzy* em um jogo denominado *Bug Catcher*, controlado por captura de movimentos (*Leap Motion Device*) para reabilitação dos membros superiores de pacientes com hemiparesia resultante de um AVC. O exercício do jogo consiste em pegar insetos e separá-los em determinadas caixas. O sistema *fuzzy* proposto utiliza múltiplas entradas (pontos, porcentagem de sucesso, tempo) na função de associação de acordo com as regras de associação *fuzzy* de desempenho, obtendo 49 combinações que resultam em uma probabilidade de acesso a um nível de dificuldade do jogo entre sete níveis predefinidos.

Lopes, Magalhães e Cavaco (2019) propuseram um JS para reabilitação de paciente com disfonia, que consiste em usar o tempo de fonação máximo e intensidade vocal para mover (caminhar, voar, nadar, etc.) o personagem até um alvo. O DDA usa equações parametrizadas para avaliar o desempenho do jogador com base nos limiares das variáveis tempo de fonação máximo e intensidade vocal, possibilitando o ajuste da fase do jogo em quinze diferentes níveis de dificuldade.

Pezzerá *et al.* (2019) propuseram o uso de um *exergame* chamado *Farm Game* para reabilitação domiciliar com DDA, com geração de conteúdo procedural (PCG) e módulo de ajuste de parâmetros dos limiares (mínimo e máximo) de dificuldades compatíveis com a capacidade do paciente. O DDA é realizado por equações parametrizadas e associadas ao score e aos seguintes elementos do jogo: cumprimento de metas diárias, que são os movimentos exigidos pelos exercícios durante o uso do jogo, bônus por participar de eventos, por exemplo, jogar por vários dias consecutivos e estar com pontuação ranqueada entre os dez melhores jogadores.

Pezzerá e Borghese (2020) apresentaram uma proposta para reabilitação domiciliar com um sistema DDA que combina três fontes de dados: desempenho histórico e de exercícios recentemente realizados; desempenho atual durante o exercício do jogo e; estado emocional do paciente. O método DDA proposto faz uso

de Lógica *Fuzzy* para mapear as entradas e um conjunto e inferências *Fuzzy* é usado para inferir os níveis de dificuldade.

Aziz Hutama, Sihwi e Salamah (2021) propuseram o uso de um *exergame* baseado no *Kinect* para terapia em crianças com disgrafia, utilizando DDA com o modelo Sugeno *Fuzzy* de ordem zero, ajustando automaticamente o nível de dificuldade conforme a habilidade de grafia do jogador. O DDA é realizado através de variáveis de vida e pontuação, adaptando-se dinamicamente para tornar o jogo mais envolvente. O jogo foi testado por terapeutas e crianças, mostrando-se uma alternativa eficaz e divertida para a terapia.

Aguilar *et al.* (2022) propuseram o método DDA com base em Redes Neurais Artificiais, aplicado em um *exergame* desenvolvido para promover a atividade física. O *exergame*, denominado 'Pathologys', foi projetado para ajustar a dificuldade do jogo em tempo real com base na frequência cardíaca (FC) e no desempenho do usuário. O algoritmo de IA avalia periodicamente as variáveis para ajustar a dificuldade do jogo, proporcionando uma experiência personalizada. Durante o estudo, dois grupos de participantes interagiram com versões do jogo baseadas em heurística e rede neural artificial.

Kostkova *et al.* (2023) propuseram o método de DDA utilizando um algoritmo de Aprendizado por Reforço com Q-Learning, aplicado em jogos sérios para reabilitação de habilidades em crianças com Deficiência Visual Cerebral. O jogo inclui tarefas como reconhecimento de objetos, percepção figura-fundo, e percepção de movimento. O algoritmo de DDA ajusta automaticamente os parâmetros do jogo com base no desempenho em tempo real das crianças, promovendo uma experiência de jogo personalizada e adaptativa. O objetivo do estudo é avaliar a eficácia de uma abordagem terapêutica adaptativa para crianças, utilizando jogos sérios como ferramenta de reabilitação.

Um dos principais aspectos evidenciados nos trabalhos relacionados (Tabela 3) é a possibilidade de implementações do método DDA com diferentes técnicas de IA e o uso de DDA em diferentes propósitos de reabilitação e tipos de jogos.

Observa-se nos trabalhos que utilizam de técnicas de IA para implementar o DDA que apenas a proposta apresentada por Aguilar (2022) utiliza sinal fisiológico, com a FC, mas não de forma integrada para ajustar a dificuldade do jogo e a abordagem utiliza a técnica de Rede Neural Artificial que requer uma quantidade significativa de dados históricos para o treinamento.

Quanto ao uso de técnica de Aprendizado por Reforço, o trabalho proposto por Sekhvat (2017) avalia os objetivos em diferentes períodos. Essa abordagem pode não ser responsiva o suficiente para mudanças rápidas nas condições do paciente, como em casos de necessidade de reduzir o nível de dificuldade caso haja variações em biosinais monitorados. Consequência do fato de não abordar sinais fisiológicos e de não ser multimodal. O trabalho descrito por Kostkova (2023), não aborda sinais fisiológicos e usa apenas os dispositivos teclado e mouse. Caso haja necessidade de integrar outros sinais e dados (fisiológicos e psíquicos), a técnica de Aprendizado por Reforço com Q-Learning não é a melhor solução, pois pode ser instável e lenta para convergir em ambientes com número grande de variáveis.

Quanto a técnica utilizando Sistema de Inferência Fuzzy, descrito por Valencia et al. (2018), Pezzera e Borghese (2020) e Hutama (2021), esta demonstra ser limitada na captura de variáveis fisiológicas, e a dependência de regras pré-definidas pode restringir a flexibilidade e a capacidade de adaptação dinâmica. Já os algoritmos evolucionários, conforme descrito por Andrade (2016) e Garcia, Crocomo e Andrade (2018) podem ser computacionalmente intensivos e não se adaptar rapidamente às mudanças das variáveis. Além disso, focam principalmente em parâmetros de desempenho, sem integração com sinais fisiológicos.

Observa-se na literatura trabalhos que utilizam equações analíticas ou estatísticas (Huygelier *et al.*, 2017), (Lopes; Magalhães; Cavaco, 2019), (Pezzer *et al.*, 2019) para realizar o ajuste de dificuldade, geralmente com o emprego de variáveis com limiares definidos previamente com base na capacidade do paciente. Essas abordagens, têm limitações quanto à sua capacidade de adaptação dinâmica perante as condições dos pacientes, uma vez que dependem de parâmetros fixos e previamente estabelecidos.

5.4 TENDÊNCIAS E OPORTUNIDADES

A partir da análise dos estudos selecionados, identificaram-se oportunidades que impulsionaram em novas pesquisas, tanto nas referências em torno dos artigos selecionados quanto em referências complementares que corroboram com as evidências identificadas.

5.4.1 Dispositivos e Sensores

Em relação aos sensores utilizados nos estudos apresentados, observa-se uma grande heterogeneidade quanto à aplicação e à quantidade de sensores utilizados simultaneamente ou complementarmente em um mesmo JD. Os sensores são componentes essenciais para as medições e avaliações das características fisiológicas dos pacientes durante as atividades físicas aplicadas na fisioterapia. Constatou-se que a multimodalidade, com o uso de dois ou mais dispositivos, proporciona complementariedade, flexibilidade e monitoramento (Henrique; Néry; Hounsell, 2019) (Nery *et al.*, 2020) dos sinais vitais ou de outros biosinais importantes para a reabilitação do paciente.

Foi possível observar ao menos três comportamentos inteligentes promovidos pelos sensores: análise de amostras de sinais do fluxo respiratório; identificação de estímulos e; isolamento do padrão de respiração do paciente (Kotova; Korvas, 2016) (Aguilar *et al.*, 2011) (Tu *et al.*, 2020). Com base nesses comportamentos inteligentes, outras evidências e oportunidade do uso da IA foram constatadas. Por exemplo, nos primeiros instantes de uso do JS, nas medições dos dispositivos, podem ser utilizadas técnicas de aprendizado de máquina (*machine learning*) usando abordagens de reconhecimento de padrões dos biosinais a fim de aferir o estado fisiológico do paciente para conduzi-lo ao programa de atividade com maior segurança e assertividade. Clerico *et al.* (Clerico *et al.*, 2016) relataram que a captura de amostras de sinais fisiológicos e a respectiva inclusão de suas características em algoritmos de aprendizado de máquina com o classificador *Support Vector Machine* (SVM) podem contribuir para monitoramento em tempo real de possíveis anormalidades e refletir na efetividade para atingir os objetivos do usuário durante a fisioterapia usando o JS.

Outro exemplo, durante o uso do JS, é a análise das entradas de biosinais, perante inúmeras repetições de exercícios respiratórios podem gerar desconfortos respiratórios (seção 4.5). Neste caso, a IA pode ser aplicada para realizar a análise e o monitoramento dos sinais da frequência respiratória, frequência cardíaca, saturação de oxigênio (Martinez *et al.*, 2013), proporcionando segurança com base em medições atuais e históricas do paciente. Tartarisco *et al.* (2015) apresentaram um modelo de aprendizado de máquina, a combinação de redes neurais com sistemas fuzzy, denominado *neuro-fuzzy*, capaz de reconhecer padrões de sinais fisiológicos (frequência cardíaca, frequência respiratória e tremores) durante o tratamento.

Constatou-se também que as combinações de vários sensores associados a diferentes sinais fisiológicos com métodos de processamento de sinais e a técnicas de aprendizado de máquina com algoritmos de reconhecimento de padrões resultam em dispositivos inteligentes (*smart devices, wearable sensors ou gadgets*) que promovem a detecção automática de padrões fisiológicos, capazes de realizar o monitoramento em tempo real das condições de saúde dos pacientes (Costa *et al.*, 2019) (Kumar, S. *et al.*, 2019).

Portanto, verifica-se a tendência do uso de sensores de oximetria, espirometria, sensores de pletismografia, sensores de resposta galvânica da pele, termistores, sensores de eletroencefalografia, entre outros.

5.4.2 Biofeedback

Em relação ao *biofeedback* constatou-se que é um componente necessário para fornecer ao paciente informações sobre os programas de atividade física. Foi possível observar ao menos três comportamentos inteligentes predominantes gerados pelo *feedback*: a exibição da relação entre a medição e a predição da capacidade inspiratória; a geração de *feedback* conforme a variação de sinais da respiração e; os *feedbacks* gerados pela geração de conteúdo e/ou alterações da estética dos elementos de jogo.

Neste contexto, a literatura evidencia o monitoramento de sinais fisiológicos com *biofeedback* multimodal contínuo associado a técnicas de IA. Os dispositivos podem monitorar a fisiologia do paciente durante o uso do JS e acionar funções de alarme usando um *loop de feedback*, que gera recompensas quando os exercícios são realizados corretamente e penaliza os estados de excitação. O *feedback* pode ser visual e auditivo, aumentando a clareza e objetividade dos exercícios fisioterapêuticos (Parnandi *et al.*, 2014) (Parnandi; Gutierrez-Osuna, 2017) (Liang *et al.*, 2018).

Segundo Moret-Bonille *et al.* (Moret-Bonillo *et al.*, 2014), a lógica *fuzzy* é uma opção para abordagens que precisam lidar com um conjunto de dados contínuos, podendo refletir inúmeras condições diversas, para tomada de decisão a partir da análise de sinais fisiológicos. Exemplos incluem: *feedback* respiratório, que mede a frequência e os padrões da respiração, bem como os níveis de oxigênio e de dióxido de carbono no sangue; *feedback* cardiovascular, que mede a variabilidade da frequência cardíaca e a arritmia sinusal respiratória; *feedback* neuromuscular, que

mede a tensão muscular com a eletromiografia de superfície e; *feedback* do sistema nervoso central, que mede os sinais cerebrais.

Portanto, observa-se o uso de sensores para coleta de sinais, tratados em tempo real ou para armazenamento em um banco de dados específico, associados a *feedback*, pode possibilitar o uso de técnicas de IA e de análise de dados para geração de relatórios para o terapeuta. Isso contribui com *feedbacks* que podem ajudar em um plano de tratamento baseado em evidências, além de prover *feedback* sobre a evolução dos pacientes ao longo da reabilitação.

5.4.3 Flow

Constatou-se na literatura que o uso da Teoria do *Flow* é aderente ao desenvolvimento de JD (Chen, 2007) (Cruz; Uresti, 2017) (Andrade *et al.*, 2016) (Sekhavat; Iran, 2017) (Lopes; Magalhães; Cavaco, 2019) (Pezzera; Borghese, 2020), de modo a prover desafios equilibrados à capacidade do jogador.

A combinação da Teoria do *Flow* com IA pode potencializar o fluxo adequado dos exercícios fisioterapêuticos guiados por JS. Por exemplo, observa-se o emprego dos seguintes comportamentos inteligentes que ajudam a promover o *Flow*: condução do ciclo da respiração (Joo; Lee; Song, 2018) (Tu *et al.*, 2020); condução das atividades cardiorrespiratórias (Rutkowski *et al.*, 2019) (Pereira *et al.*, 2013); condução de atividades para treino da musculatura (Grimes; Santos; Hounsell, 2018) (Sutanto *et al.*, 2019); indução na melhoria da força e resistência dos músculos respiratórios, cardiopulmonares, agilidade e equilíbrio (Mazzoleni *et al.*, 2014) (Del Corral *et al.*, 2014) (Wardini *et al.*, 2013) e; indução e/ou ajuste de nível de dificuldade gradual (Andrade *et al.*, 2016) (Sekhavat; Iran, 2017) (Valencia; Majin, 2018).

Usando como exemplo o comportamento inteligente que realiza o ajuste de dificuldade dos exercícios com base na *Teoria do Flow*, observa-se que os artigos de Hagelbäck e Johansson (2009), Pirovano *et al.* (2012), Correa *et al.* (2014), Clerico *et al.* (2016), e Cruz e Uresti (2017) apresentaram métodos de geração de conteúdo procedural ou de ajuste de dificuldade que consiste em rastrear o desempenho do jogador. O ajuste dinâmico de dificuldade (Andrade *et al.*, 2016) (Sekhavat; Iran, 2017) (Valencia; Majin, 2018) permite que os exercícios se adaptem ao estado atual do jogador/paciente, podendo tornar o JS mais adequado, equilibrado e seguro, além de tornar o jogo mais engajador e divertido, evitando o tédio ou frustração.

5.4.4 Inteligência Artificial

Os JD apresentados, geralmente, não possuem recursos de análise e monitoramento dos biosinais e não têm monitoramento para evitar desconfortos respiratórios (seção 4.5). Em reabilitação respiratória, os exercícios incentivados pelo JS devem ser monitorados por um sistema biomédico para promover a segurança do paciente. A IA pode contribuir para este propósito. Observa-se que a prevalência de exercícios é voltada para treinamento muscular respiratório e/ou expansão pulmonar.

Considerando os trabalhos identificados na literatura, observa-se que as técnicas de IA podem ser associadas ao JS e à RR para serem usadas antes, durante (dentro) e/ou depois do JS, oferecendo várias funções (Tabela 4).

Antes de usar o JS, a IA pode ser implementada para ajudar a selecionar o JS adequado, sua parametrização (nível de dificuldade, fase do JS) de acordo com o problema e os objetivos almejados com a reabilitação, a doença e/ou o perfil do paciente, bem como a dosimetria inicial (determinação da quantidade, frequência e duração do tratamento).

Tabela 4 - Funções da IA em JS

Momento de uso	Funções
Antes de usar	<ul style="list-style-type: none"> ▪ Customização do tratamento ▪ Dosimetria
Durante o uso (dentro)	<ul style="list-style-type: none"> ▪ Segurança (análise de sinais) ▪ Conforto físico ▪ Conforto motivacional (Flow) ▪ Diversão
Depois de usar	<ul style="list-style-type: none"> ▪ Ajuste de Dosimetria ▪ Diagnóstico de alta

Fonte: Dias *et al.* (2020).

Durante o uso do JS, nas entradas de biosinais, perante inúmeras repetições de exercícios respiratórios, podem causar desconfortos respiratórios ao paciente (seção 4.5). Neste caso, a IA pode ser aplicada para monitorar sinais como batimento cardíaco e da saturação de oxigênio, proporcionando segurança com base em medições atuais e históricas do paciente.

Ainda durante o uso do JS, na condução dos exercícios fisioterapêuticos, situações desagradáveis (seção 4.5) podem surgir e só ser percebida em casos extremos. A IA pode proporcionar mais conforto ajustando, por exemplo, escala de dificuldade, desafios, comportamentos e objetos do jogo. Assim, a IA mantém a segurança do paciente durante a reabilitação respiratória, emitindo alertas ou até interrompendo o exercício caso seja detectada alguma anormalidade, evitando que o paciente sinta desconfortos respiratórios (fisiológicos) (seção 4.5) ou motivacionais (psicológicos) associados ao *Flow* (Cruz; Uresti, 2017).

A IA também pode ser usada nos JS para ajustar dinamicamente a dificuldade através do método DDA. Essa adaptação pode abranger conteúdo, mecânica, dinâmica e estética, tornando-o mais alinhado com as necessidades e capacidades do paciente. A IA ajusta os desafios, refletindo o progresso e as limitações do paciente. Isso torna o jogo menos repetitivo e mais envolvente, aumentando a eficácia terapêutica. Observa-se, pelo menos, dois grupos de funções que podem ser utilizados no DDA: um relacionado ao fisiológico e outro ao psicológico do paciente.

Depois do uso do JS, na geração de relatórios e laudos, a IA pode contribuir analisando dados do jogo e fornecendo feedback de desempenho, permitindo ao terapeuta monitorar e analisar o progresso do paciente. É comum ter variações no estado de saúde do paciente entre as sessões, portanto, ajustes para a próxima sessão devem ser feitos com cautela e baseados também na medição do dia da sessão. Isso possibilita ajustar o treino para as próximas sessões de fisioterapia conforme os objetivos do tratamento, sugerindo alterações no número, duração ou intervalo de sessões de terapia (dosimetria) e na indicação de possível alta.

A utilização da IA antes, durante e depois do JS proverá a adequação da resposta ao estímulo gerado pelo JS, para que o fluxo do jogo, imediato ou a longo prazo, não fique muito exigente nem muito relaxado para o paciente, evitando frustração ou tédio, e levando a uma maior aderência ao tratamento. O acompanhamento suportado por técnicas de IA pode ainda auxiliar na otimização do tratamento, economizando recursos (duração da sessão e números de sessões) e abreviando o tratamento.

5.5 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Os resultados obtidos na pesquisa da literatura mostram tendências e lacunas em relação às publicações sobre a questão de pesquisa. Na revisão de literatura, constatou-se que há poucos artigos propondo explicitamente o uso de inteligência artificial em jogos digitais aplicados à reabilitação respiratória. As técnicas mais frequentes são *Decision Making* e *Intelligent Movement*, sendo esses grupos constituídos de uma coleção de algoritmos que são frequentemente utilizados em diversos gêneros de jogos digitais.

Na pesquisa complementar por trabalhos relacionados à questão específica de pesquisa, foram encontrados artigos que utilizam a IA para realizar o ajuste de dificuldade dos exercícios em JS para reabilitação, com base no desempenho do jogador (paciente) e com o objetivo de evitar que o desafio do jogo seja muito difícil, provocando frustração, ou muito fácil, provocando tédio. Ou seja, o ajuste dinâmico contribui para manutenção do *Flow*. Porém, não foram identificados trabalhos que proponham o ajuste da dificuldade aplicado à reabilitação respiratória.

Por fim, conclui-se que existem inúmeras oportunidades para o uso da IA no desenvolvimento de JS para auxiliar profissionais e pacientes da área de Reabilitação Respiratória.

6 TESE

As evidências identificadas no capítulo sobre o estado da arte mostram que existem oportunidades para o ajuste dinâmico de dificuldade em *exergames* para treinamento respiratório com o emprego de inteligência artificial. Assim, neste capítulo, é descrito o conceito da proposta desta tese, intitulada “Flow Psicofisiológico em Jogos Digitais”.

6.1 METODOLOGIA FLOW PSICOFISIOLOGICO EM EXERGAMES

A proposta desta tese de doutorado é promover o *Flow Psicofisiológico em Jogos Digitais Multimodais para Reabilitação Respiratória*, fundamentando-se na *Teoria do Flow* de Csikszentmihaly (1990), adaptada para jogos digitais (Chen, 2007), que descreve um estado de engajamento pleno e imersão profunda, característico de experiências de jogo.

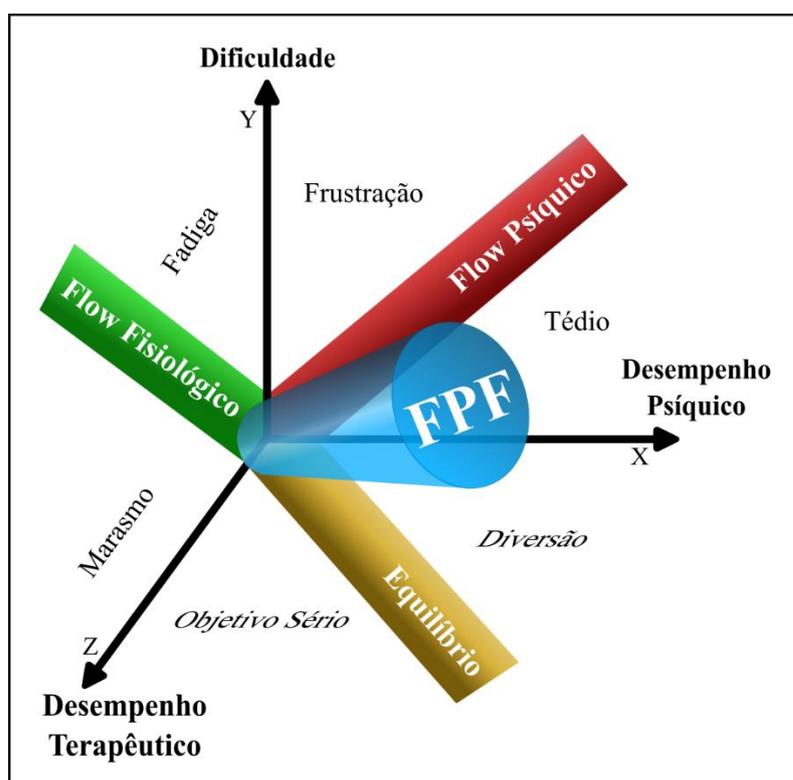
Esta tese visa adaptar e expandir esses conceitos para o contexto da fisioterapia. O conceito de *Flow Psicofisiológico em Jogos Digitais* propõe a fusão dos elementos de *Teoria do Flow* com as variáveis psíquicas e fisiológicas dos pacientes, especialmente em relação aos elementos do exercício terapêutico.

O Flow Psicofisiológico integra de forma dinâmica os fluxos psíquicos e fisiológicos do paciente dentro de um contexto terapêutico específico. Essa metodologia visa criar um estado de equilíbrio, onde as variáveis mentais e corporais do paciente são harmonizadas de maneira contínua e adaptativa. No contexto dos Jogos Sérios Ativos Multimodais, essa metodologia busca equilibrar cuidadosamente a saúde mental e física do paciente, utilizando o conceito de Flow como catalisador para maximizar o desempenho terapêutico. Através da sincronização entre os desafios apresentados pelos *exergames* e as capacidades psico-fisiológicas do paciente, o Flow Psicofisiológico promove uma experiência de fisioterapia que mantém o paciente motivado, otimizando os resultados tanto no âmbito psicológico quanto fisiológico. Esta fusão entre a teoria do Flow e os parâmetros clínicos específicos assegura que o tratamento seja ajustado de forma precisa às necessidades individuais, proporcionando um caminho equilibrado entre o desafio e a recuperação, resultando em uma experiência terapêutica eficaz e gratificante.

Na Figura 9, o Flow Psicofisiológico é um cilindro tridimensional que se projeta no plano para balancear frustração e tédio (faixa de projeção vermelha), em outro plano para balancear fadiga e marasmo (faixa de projeção verde) mas, que também se projeta noutro plano para equilibrar a diversão e o objetivo sério do jogo (faixa de projeção amarela).

Os efeitos psíquicos relacionam-se com a percepção emocional do jogador, mapeados no plano 'Desempenho Psíquico' versus 'Dificuldade' (Figura 9, plano XY) em canais como tédio, frustração e *flow* psíquico. Por exemplo, se um paciente com condição de saúde debilitada enfrenta um desafio de alta exigência psíquica, pode entrar em uma zona de frustração (área fora do *flow*), o que pode provocar entropia psíquica e agravar a saúde física. Alternativamente, um indivíduo em boa condição de saúde pode experimentar tédio se o desafio do exercício for insuficientemente estimulante (área fora do *flow*), resultando em relaxamento demasiado (marasmo) e potencialmente comprometendo o regime terapêutico. As variáveis psíquicas consideradas incluem as medidas do jogo que resultam no Desempenho do Jogador (DJ). Em que uma baixa pontuação no jogo é um indicativo de que o fluxo psíquico não está ajustado à capacidade do paciente.

Figura 9 - Representação do Flow Psicofisiológico (FPF)



Fonte: Elaborado pelo autor (2024).

Os efeitos fisiológicos são caracterizados pela integração entre a condição de saúde do paciente e o esforço exigido pelo *exergame*, mapeados no plano 'Desempenho Terapêutico' *versus* 'Dificuldade' (Figura 9, plano YZ) em canais como fadiga, marasmo e *flow* fisiológico. As variáveis fisiológicas consideradas nesta dimensão incluem, para o estudo de caso que será detalhado adiante para terapia respiratória, Pressão Inspiratória máxima (PI_{max}), Pressão Expiratória máxima (PE_{max}), Tempo de Inspiração máximo (TI_{max}), Tempo de Expiração máximo (TE_{max}), Fluxo Inspiratório (FL_i), Fluxo Expiratório (FL_e), Frequência Respiratória (FR), Saturação de Oxigênio (SpO₂) (ver Tabela 25), dentre outras que são ajustadas conforme a especificidade de cada caso clínico.

O equilíbrio entre o objetivo sério e a diversão mapeados no plano 'Desempenho Terapêutico' *versus* 'Desempenho Psíquico' (Figura 9, plano XZ) conduz a relação entretenimento *versus* saúde, buscando uma sinergia entre a condição de saúde do paciente e o esforço exigido pelo *exergame*, ajustando essas variáveis para mantê-lo e guiá-lo em um estado contínuo de *flow*. Essa metodologia é diferenciada do *Flow* tradicional encontrado em jogos digitais (Chen, 2007), onde o desempenho é geralmente medido somente pela pontuação obtida e a dificuldade é ajustada diretamente com base nisso. No *Flow* Psicofisiológico, a dificuldade é ajustada considerando não apenas a pontuação, mas também um espectro mais amplo de medidas de desempenho e saúde.

O Ajuste Dinâmico de Dificuldade (*Dynamic Difficulty Adjustment - DDA*) é um método que pode ser aplicado para conduzir ao equilíbrio entre o estado de saúde do paciente e o esforço exigido durante o programa de reabilitação, guiando os exercícios terapêuticos (Sekhavat; Iran, 2017).

6.2 DDA MULTIMODAL MULTIDADOS INTELIGENTE

Para compreender a aplicação das diversas dimensões do *Flow* Psicofisiológico em Jogos Digitais Ativos, é fundamental definir os componentes que permitem a adaptação dinâmica e personalizada dos exercícios terapêuticos. A seguir, são apresentados os três componentes chave para abordagem DDA do *Flow* Psicofisiológico:

- 1) Multimodal: A abordagem multimodal permite integrar e gerenciar sinais provenientes de diversas fontes, como dispositivos de controle e biosinais (conscientes e inconscientes). A arquitetura 123-SGR é um exemplo dessa integração, pois permite capturar e processar diferentes tipos de sinais durante a interação do paciente com o *exergame*. Esta abordagem garante que todos os aspectos relevantes da reabilitação, como sinais de movimento e sinais fisiológicos, sejam considerados;
- 2) Multidados: Dados atuais ou históricos, Dados medidos ou perguntados. Dados como saturação de oxigênio, pressão inspiratória e expiratória, frequência respiratória e *feedback* psíquico com opiniões emitidas pelo jogador (cansaço, esforço, estado de humor, dentre outras) são coletados e analisados para entender completamente o estado do paciente. Esses dados permitem ajustes precisos e personalizados no *exergame*, promovendo um equilíbrio entre desafio e capacidade;
- 3) Inteligente: O uso de IA ajuda a gerenciar a adaptação dinâmica dos níveis de dificuldade em *exergames*. A IA, permite ajustar os desafios com base nas respostas fisiológicas e psíquicas dos pacientes, promovendo com maior assertividade o equilíbrio do jogo entre diversão, objetivo sério e desempenho.

O objetivo é alinhar as dimensões do Flow Psicofisiológico dos exercícios realizados em um jogo digital aos objetivos terapêuticos, assegurando uma experiência integrada que abranja:

- Conforto Motivacional (*Flow* Psíquico): Do ponto de vista psicológico, o módulo manterá o usuário engajado e motivado. Através da manipulação inteligente de elementos do jogo, com níveis progressivos de desafio, o DDA otimizará o *flow* psíquico, garantindo que o exercício seja percebido como divertido, recompensador e psicologicamente gratificante;
- Conforto Físico (*Flow* Fisiológico): A dimensão fisiológica envolve o conforto físico do jogador, essencial para a adesão a longo prazo e efetividade do tratamento. O DDA ajustará os desafios do jogo para manter o usuário dentro de um estado de *flow* fisiológico, onde a atividade não é nem demasiadamente exigente nem insuficientemente estimulante,

ajudando a maximizar a eficácia dos exercícios sem causar desconforto ou exaustão;

- Segurança (Análise de Biosinais): O DDA realizará o monitoramento para garantir a segurança durante o uso do jogo. Através da análise dos biosinais, como saturação de oxigênio, será possível verificar se o exercício está sendo realizado dentro dos limites seguros para o paciente. Este monitoramento protege o paciente contra riscos potenciais;
- Diversão (Jogo Sérioso Ativo): Além de seus aspectos terapêuticos, um jogo digital é projetado para ser divertido e envolvente. A integração do conceito Flow Psicofisiológico visa reforçar a natureza lúdica do jogo, tornando-o uma ferramenta eficaz para reabilitação que simultaneamente entretém e auxilia na recuperação física. A diversão é um componente que pode transformar a percepção da terapia de uma tarefa árdua para uma atividade agradável;
- Instrumento terapêutico tecnológico (Inteligência Artificial): O módulo DDA contribui como um instrumento de reabilitação (respiratória). Ao incorporar tecnologias de IA, o jogo oferece uma plataforma que adapta os exercícios às necessidades específicas de cada paciente, proporcionando uma abordagem terapêutica personalizada.

Observa-se na Tabela 3, que o método DDA pode ser implementado por diferentes técnicas de software, como Analítica, Estatística, Sistema de Inferência Fuzzy, Algoritmo Evolucionário, Aprendizado por Reforço, Redes Neurais Artificiais ou técnicas mistas.

O DDA inteligente pode ser operacionalizado por meio do método de Aprendizado por Reforço Profundo (do inglês, *Deep Reinforcement Learning*) (Aggarwal, 2018, p. 373). Este módulo de DDA é nomeado nesta tese de DeepDDA, que permite ajustar dinamicamente os desafios para que flua adequadamente às necessidades e capacidades individuais de cada paciente.

Dentre as técnicas identificadas na literatura (ver Tabela 3), as técnicas combinadas para conceber o DeepDDA incorpora *deep learning* dentro de aprendizado por reforço (*Deep Reinforcement Learning* - DRL) resultando na técnica de DRL. Com o DeepDDA, a adaptação dos níveis de dificuldade com base nos dados de desempenho do paciente é contínua, algo que técnicas tradicionais ou estáticas

podem não conseguir com a mesma eficiência. O aprendizado baseado em recompensa, diferentemente de outros métodos de IA, utiliza um sistema que se ajusta conforme o agente aprende com as interações do paciente. Este modelo é particularmente adequado para ambientes dinâmicos, como os *exergames* para reabilitação, onde as necessidades dos pacientes podem mudar constantemente. A integração multimodal e multidados permite analisar uma variedade de informações, permitindo ajustes mais precisos e personalizados, promovendo o equilíbrio entre as várias dimensões do *exergame*.

O agente DeepDDA, resolve também um problema de otimização, no qual, para manter o *Flow Psicofisiológico*, o paciente precisa realizar o aproveitamento (*exploitation*) do desafio já conhecidos, intensificando a realização dos exercícios fisioterapêuticos propostos no jogo para estimular o refinamento dos exercícios. Além disso, o DeepDDA também induz a diversificação, pois o paciente precisa também explorar (*exploration*) novos desafios, aumentando a diversidade dos exercícios para evitar a convergência que pode manter o paciente por muito tempo em uma zona de relaxamento.

Neste contexto, o DeepDDA pode ser composto por um agente DRL implementado com o algoritmo *Proximal Policy Optimization* (PPO) (Schulman *et al.*, 2017), que utiliza duas Redes Neurais Artificiais (*Artificial Neural Network* - ANN), a rede neural da política que é responsável por mapear os estados do ambiente para uma distribuição de probabilidades sobre as ações possíveis, e a rede neural do valor que estima a função de valor, que é o valor esperado das recompensas futuras acumuladas a partir de um dado estado.

O algoritmo PPO é conhecido por sua eficiência, estabilidade e desempenho (Schulman *et al.*, 2017), sendo adequado para ajustar dinamicamente os desafios com base nas respostas do paciente. O PPO é eficaz porque combina a estabilidade do aprendizado com a capacidade de adaptação contínua em ambientes dinâmicos. Ele evita grandes atualizações nos parâmetros das redes neurais, o que melhora a convergência e a performance do agente ao longo do tempo. Além disso, sua estrutura permite que o agente aprenda a partir das interações, ajustando rapidamente as políticas. Ao utilizar redes neurais para estimar políticas e valores, o algoritmo pode prever as respostas do paciente e adaptar os desafios de maneira personalizada.

6.3 CONSIDERAÇÕES FINAIS DO CAPÍTULO

A Figura 10 ilustra a combinação de componentes importante para promover a adaptação dinâmica conforme previsto na metodologia do conceito Flow Psicofisiológico em *exergames*. A interseção das abordagens multimodal, multitudes e inteligente somam-se para implementar um sistema personalizado de DDA. A inteligência artificial, representada pelo DeepDDA, permite um ajuste contínuo dos desafios com base nas respostas fisiológicas e psíquicas dos pacientes.

Figura 10 - Combinação para DDA do Flow Psicofisiológico (FPF)



Fonte: Elaborado pelo autor (2024).

A abordagem multimodal integra diversas fontes de sinais, como dispositivos de controle e biosinais, através da arquitetura 123-SGR. Esta integração é fundamental para capturar uma gama completa de informações durante a interação do paciente com o *exergame*, garantindo que todos os aspectos relevantes da reabilitação sejam considerados.

Os multitudes são as interações de jogo que são uma das modalidades no modelo 123-SGR.

7 PROVA DE CONCEITO

Propõe-se como prova de conceito o desenvolvimento do módulo DeepDDA aplicado no JSA *I Blue It* Multimodal (NERY *et al.*, 2020). Este módulo visa atualizar o JSA *I Blue It* para a versão 5.0, tornando-o aderente ao conceito do *Flow Psicofisiológico*, fundamentado em exercícios terapêuticos especificamente voltados ao Treinamento da Musculatura Respiratória (TMR). O JSA *I Blue It* tem potencial para receber o módulo DeepDDA, pois representa um sistema biomédico com um ecossistema de recursos de hardware e software de maturidade e abrangência aplicável em ambientes clínicos. A seguir, é apresentada a linha do tempo das contribuições que fazem parte do ecossistema do JSA *I Blue It*, sendo a versão 5.0 o resultando da prova de conceito desta tese:

- **Versão 1.0: I Blue It – Pitaco (Grimes, 2018)**
 - Concepção do Dispositivo Pitaco;
 - Jogo Sêrio Blue.
- **Versão 2.0: I Blue It – ManoBD (Henrique, 2019)**
 - Concepção do Dispositivo ManoBD;
 - Minigame Copo D'água e Bolo de Aniversário;
- **Versão 3.0: I Blue It – Health InfoCharts (Santos, 2020)**
 - Concepção de Service Design com gráficos e estatísticas.
- **Versão 4.0: I Blue It – Multimodal (Nery, 2020)**
 - Concepção de Arquitetura 123-SGR Multimodal;
 - Dispositivo Cinta Extensora e Oxímetro;
 - Redesign para Versão 4.5: I Blue It - Multimodal (2023).
- **Versão 5.0: I Blue It – Flow Psicofisiológico (2024)**
 - Concepção do Conceito Flow Psicofisiológico;
 - Inteligência Artificial.

7.1 CONTEXTUALIZAÇÃO

Uma entrevista semiestruturada realizada com UFEs destacou o potencial da versão 4.0 do JSA *I Blue It* para realizar exercícios dentro da modalidade de fisioterapia de TMR, aproveitando a imersão digital que o JSA oferece. Esta versão do *I Blue It* contempla a arquitetura de sistema interativo multimodal 123-SGR (Dias *et al.*, 2023), que dispõe de três funcionalidades: flexibilidade, complementariedade e segurança. No entanto, observou-se a existência de limitações listadas a seguir:

- 1) A falta de um conceito integrado que aborde simultaneamente as condições psíquicas e fisiológicas do jogador (paciente). Isso é importante, pois a reabilitação respiratória não se trata apenas da melhoria da capacidade pulmonar, mas também do bem-estar mental e emocional do paciente, que são interdependentes e críticos para uma recuperação holística;
- 2) A ausência de um método para ajustar automaticamente o nível de dificuldade em termos de interação mecânica, dinâmica e estética dentro da arquitetura do jogo. Um paciente pode não saber qual dificuldade escolher ou optar por uma dificuldade inadequada. Além disso, a dificuldade pode não se ajustar à medida que o paciente melhora, levando ao tédio. A habilidade de adaptar o jogo dinamicamente, não apenas em resposta às capacidades físicas do paciente, mas também em resposta a seu estado emocional e mental, poderia aumentar significativamente a eficácia do tratamento;
- 3) A ausência do emprego de técnicas de IA nos biosinais gerados pelo fluxo consciente e inconsciente. A capacidade de prever e ajustar a terapia com base nesses sinais pode permitir intervenções mais precisas e personalizadas, além de fornecer *feedbacks* contínuo, essencial para monitoramento dos procedimentos fisioterapêuticos;
- 4) A aplicação insuficiente de modelos matemáticos e estratégias de avaliação que alinhem as dificuldades do jogo com as variáveis psicofisiológicas do paciente. Esta integração é necessária para garantir que os desafios propostos pelo jogo sejam apropriados e benéficos para o estado clínico do jogador (paciente), estimulando a progressão terapêutica de forma segura;
- 5) A ausência de um protocolo de exercício terapêutico com parâmetros e valores padrão específicos para a modalidade de fisioterapia voltada ao TMR.

As limitações identificadas destacam a necessidade de desenvolver uma abordagem mais integrada para mitigar efeitos adversos no processo de reabilitação e evitar impactos negativos no progresso do programa de RR. Um exemplo é o risco de exaustão respiratória, que pode expor o paciente a perigos ao utilizar o jogo, prejudicando seu desempenho e engajamento durante as sessões terapêuticas.

A arquitetura 123-SGR, apesar de robusta em termos de interação mecânica, dinâmica e estética, carece de um conceito para promover o ajuste dinâmico de

dificuldade, conforme observado nas limitações (1) e (2). Além disso, embora a segurança seja um pilar dessa arquitetura, ela não inclui uma abordagem de análise de sinais por meio de IA para adaptar às necessidades do paciente, conforme evidenciado na limitação (3). Também há uma falta de modelos matemáticos para avaliação do desempenho do paciente (limitação 4). A ausência de um protocolo para uma modalidade terapêutica, que permita a realização de um estudo clínico aplicado a uma população de específica, é uma lacuna destacada na limitação (5).

Diante dessas lacunas, uma prova de conceito com a proposta desta tese pode ser incorporada no JSA I Blue It, visando a resolução destas limitações.

7.2 COLETA DE REQUISITOS

Com o propósito de coletar dados e obter opiniões ou fatos relacionados, realizou-se uma entrevista semiestruturada (Apêndice B e Apêndice C) com Usuário Final Entendido (UFE) no domínio (Hounsell, 2024, p. 67) no domínio da reabilitação. Esta abordagem permitiu uma interação mais flexível e profunda, possibilitando que os entrevistados expressassem suas visões detalhadamente sobre o uso de inteligência artificial em *exergames*.

7.2.1 Principais resultados das entrevistas

A análise sistemática interparticipantes (Barbosa; Silva, 2010, p. 145) das respostas coletadas durante a entrevista semiestruturada com os UFEs revelou informações que contribuem diretamente para a prova de conceito desta tese.

No primeiro tópico da entrevista, uma das principais descobertas foi a compreensão de que a fisioterapia mais recentemente está orientada para objetivos específicos e solução de problemas através de modalidades terapêuticas, ao invés de focar exclusivamente no tratamento de doenças. Esta abordagem permite a aplicação de estudos e técnicas desenvolvidas para uma doença respiratória específica a um espectro mais amplo de condições respiratórias, adaptando-se ao estado clínico individual de cada paciente. Modalidades como higiene das vias aéreas, expansão pulmonar e treinamento dos músculos respiratórios foram identificadas como importantes para RR.

Foi também observado que, embora os benefícios proporcionados pelo jogo *I Blue It* sejam ainda hipotéticos, este possui o potencial de servir como um instrumento eficaz para ensinar métodos de inspirar e expirar. A análise recomendou o monitoramento das valências respiratórias para assegurar que os exercícios propostos não exacerbem as condições de saúde do paciente. O *I Blue It* foi reconhecido por seu potencial no treinamento da musculatura respiratória, especialmente quando combinado com tecnologias de sensoriamento, transdução e inteligência artificial, promovendo um ambiente controlado e seguro para a reabilitação, com exercícios que permitam a progressão no jogo e por conseguinte a progressão da saúde do paciente.

No segundo tópico, emergiu a necessidade de realizar estudos clínicos para avaliar se os alvos e obstáculos do JSA *I Blue It* efetivamente aumentam a valência respiratória e cardíaca dos pacientes. Foi sugerida a utilização da Escala de *Borg* para classificação do esforço percebido, que poderia ajudar a equilibrar adequadamente os níveis e fases do jogo. Apurou-se que o obstáculo no jogo se assemelha com a espirometria de incentivo do volume pulmonar, e que o alvo pode ser relacionado com o incentivo à fluxo. No entanto, é necessário tomar cuidado para que os desafios com alvos e obstáculos não sobrecarreguem a musculatura respiratória.

No terceiro tópico, destacou-se a importância de monitorar, avaliar e controlar continuamente as variáveis fisiológicas do paciente para garantir que estejam alinhadas com suas condições clínicas. Isso inclui ajustar os estímulos no JSA de acordo com um protocolo de treinamento da musculatura respiratória e que leve em conta a progressão dos treinamentos.

A análise desses dados aponta para a necessidade de um *design* de jogo adaptável que possa atender a variáveis individuais e ajustar-se dinamicamente às mudanças nos estados dos pacientes. Isso não apenas melhora a experiência do usuário, mas também contribui para os objetivos terapêuticos, promovendo uma reabilitação que se estende além do físico para abraçar uma abordagem holística da saúde. A Tabela 5 apresenta um resumo dos *Insights* resultantes da entrevista adotados no JSA *I Blue It* 5.0.

O JSA *I Blue It* incluirá exercícios que combinam inspiração e expiração. Essa abordagem assegura que os exercícios respiratórios sejam mais completos e eficazes. Ao incorporar tanto a inspiração quanto a expiração nos exercícios, o

exergame proporcionará um treinamento mais equilibrado e eficaz para os pacientes, promovendo melhorias significativas na capacidade respiratória.

Tabela 5 - Resumo dos *Insights* adotados no JSA I Blue It 5.0

Questões das Unidades de Análise	Categoria	Código	UFEs (%)	Descrição	Principais Feedbacks UFEs
Quais protocolos de treinamento e/ou quais parâmetros de prescrição de treinamento podem ser realizados com os recursos presentes no Jogo Digital I Blue It para o Treinamento Muscular Respiratório (TMR)?	Prescrição	Inspiração com Expiração	90,0	Combinação de exercícios de inspiração e expiração.	I Blue It tem potencial para exercícios de TMR
Quais as situações de progressão e regressão devem ser reconhecidas pelo I Blue It?	Variáveis DDA	Carga	70,0	Ajuste de resistência respiratória.	1ª Sessão: ($CG_{min} = 30\%$);
		Velocidade	60,0	Ajuste da velocidade dos objetos.	Fixo em 60 objetos por sessão;
		Repetição	50,0	Número de fluxos respiratórios.	
	Decisões DDA	Falhas durante sessão	30,0	Mecanismos para detectar falhas durante a sessão.	Diminuir a Carga e a Velocidade se ocorrer 3 falhas consecutivas no nível;
		Falhas entre sessão	50,0	Mecanismos para detectar falhas entre sessões.	Diminuir a Carga e a Velocidade se ocorrer ($\Delta DJ < -\alpha$) ou ($\Delta EB > \beta$) na sessão;
		Sucesso	40,0	Mecanismos para detectar sucessos em objetos e sessão.	
	Ações DDA	Ajustar Carga e velocidade	90,0	Ajuste da carga para equilibrar os desafios adequadamente.	Aumentar CG a cada nível, se ocorrer ($\Delta DJ > \alpha$) ou a cada sessão, se ocorrer ($\Delta EB < \beta$); Aumentar velocidade, se ocorrer sucesso em 3 níveis consecutivos;
Qual a ordem de ajuste das variáveis? (carga, tempo/repetição, velocidade)	Ordem de Ajuste	Primeiro Carga	70,0	Prioridade de ajuste de exercícios.	Mais comum trabalhar com repetições.
		Segundo Velocidade	50,0	Ajuste secundário dos exercícios.	
Os dados (picos e tempos) de Inspiração e Expiração devem ser tratados iguais durante o TMR?	Picos e tempos de ins-exp	Diferentes	60,0	Ajustes separados de carga para os picos de fluxo e tempos.	Devem ser ajustados separadamente.
Para o TMR deve-se estimular picos e duração conjuntamente? (ou um por vez, qual o primeiro, qual o mais fácil?)	Incentivos respiratórios	Picos	60,0	Foco inicial nos picos respiratórios.	Estimular separadamente, depois pode ser conjuntamente.
		Duração	50,0	Foco secundário tempo do fluxo.	
Existem avaliações que vão além dos dados fisiológicos e que são/devem ser regularmente analisadas	Avaliação	Escala de Borg	70,0	Utilização da Escala de Borg para quantificar o esforço percebido pelo paciente.	Ajustar a carga se EB variar > 2 medias de esforço entre 2 sessões consecutivas. ($\Delta EB \leq \beta$)
Quais as condições dos sinais de monitoramento (SpO2, FC, FR) do paciente para eventual "ajuste do jogo digital I Blue It"?	Sinais de monitoramento	FR	60,0	Monitoramento constante da Frequência Respiratória.	Emitir alertas se SpO2 menor que 89%
		SpO2	60,0	Monitoramento constante da Saturação de Oxigênio Periférica.	

Fonte: Elaborada pelo autor (2022).

A adaptação da dificuldade do jogo será baseada em três principais variáveis de DDA: velocidade, repetição e carga. A velocidade dos exercícios será modulada para assegurar que os pacientes possam acompanhar os exercícios de maneira eficiente e segura. A carga será ajustada para alinhar com a capacidade respiratória do paciente, garantindo que o nível de esforço esteja de acordo com sua condição de saúde. Além disso, a frequência dos exercícios será ajustada conforme a necessidade terapêutica, permitindo uma adaptação contínua e personalizada.

Decisões de DDA serão implementadas para detectar falhas e sucessos durante e entre as sessões. Isso permitirá ajustes na dificuldade do jogo com base no desempenho do paciente, assegurando que o nível de desafio seja sempre apropriado. A principal ação de ajuste dinâmico de dificuldade será a modificação da velocidade, garantindo que os desafios estejam ajustados adequadamente para o nível de habilidade e progresso do paciente.

O jogo será configurado para tratar os picos de fluxo e os tempos de inspiração e expiração de forma diferenciada. Essa abordagem permitirá um ajuste mais preciso e eficaz dos exercícios respiratórios, atendendo às necessidades específicas de cada tipo de respiração. O foco inicial será dado aos picos respiratórios, seguido pelos tempos de fluxo. Isso alinha com a necessidade de aumentar a resistência e fortalecer a capacidade respiratória, promovendo um desenvolvimento progressivo e sustentável das capacidades respiratórias dos pacientes.

Para a avaliação do esforço percebido pelo paciente, a Escala de Borg modificadas será utilizada (Jensen; Karoly; Braver, 1986). Essa ferramenta permitirá uma avaliação contínua e subjetiva do nível de dificuldade e esforço dos exercícios, garantindo que os ajustes necessários possam ser feitos de maneira precisa.

A Frequência Respiratória (FR) e a Saturação de Oxigênio Periférica (SpO₂) serão monitoradas constantemente durante as sessões de exercício. Esse monitoramento contínuo garantirá que os exercícios sejam realizados dentro dos limites seguros e apropriados para a condição fisiológica do paciente, proporcionando um ambiente de reabilitação seguro e controlado.

Em conclusão, a implementação desses *insights* no Flow Psicofisiológico assegurará que o *exergame* esteja bem alinhado com as práticas clínicas recomendadas e as necessidades dos pacientes. Essa abordagem personalizada e baseada em dados proporcionará uma reabilitação respiratória mais eficaz, segura e

motivadora, contribuindo significativamente para a melhoria da saúde e do bem-estar dos pacientes.

Os elementos e variáveis da caracterização do problema de ajuste dinâmico de dificuldade são apresentados a seguir:

1) *Problema de Otimização*

- a. Funções-objetivo psíquicas (indicadores para medir o desempenho do jogador)
 - i. Maximizar o número de alvos coletados;
 - ii. Maximizar o número de obstáculos vencidos;
 - iii. Minimizar o número de falhas e perdas;
 - iv. Maximizar o bem-estar, felicidade, satisfação;
 - v. Minimizar o desconforto, frustração, tédio, irritação.
- b. Funções-objetivo fisiológicas (indicadores para medir a saúde física do jogador)
 - i. Melhorar ou manter a SpO₂;
 - ii. Melhorar ou manter a FR;
 - iii. Melhorar ou manter a FC;
 - iv. Aumentar a duração dos fluxos respiratórios;
 - v. Aumentar os picos inspiratórios e expiratórios.
- a. Funções-objetivo terapêuticos (indicadores para medir a saúde e bem-estar do jogador)
 - vi. Melhorar a força muscular respiratória;
 - vii. Melhorar a resistência muscular respiratória;
 - viii. Melhorar o controle da musculatura respiratória.

2) *Reinforcement Learning*

- a. Dado um estado atual s_t o agente realiza uma ação a_t que modifica o ambiente (JSA);
- b. O ambiente dá uma recompensa $r_t(s_t, a_t)$ que pode ser a cada passo ou a cada período;
- c. O estado do agente é alterado para S_{t+1} com base nas variáveis psicofisiológicas;
- d. A sinapse do agente é atualizada com base no peso sobre a ação.

3) *DeepDDA*

- a. Agente: Agregado ao Módulo *Mixer* do JSMM / *Blue It*;
- b. Desempenho: Promover ajuste dinâmico de dificuldade usando IA;
- c. Ambiente: Reabilitação Respiratória composto por terapeuta, paciente e recursos fisioterapêuticos (JSA e Dispositivos Multimodais);
- d. Sensores: Pneumotacógrafo, Manovacuometro, Cinta elástica, Oxímetro.

4) *Ambiente*

- a. Parcialmente observável;
- b. Não determinístico;
- c. Episódico;
- d. Discreto e contínuo;
- e. Baseado em objetivos.

5) *Entradas*

- a. Fisiológicas

- i. Saturação de Oxigênio (SpO₂);
 - ii. Frequência Respiratória (FR);
 - iii. Picos inspiratórios e expiratórios (PI_{max} e PE_{max});
 - iv. Fluxos inspiratórios e expiratórios.
 - b. Psíquicas
 - i. Número de alvos alcançados;
 - ii. Número de obstáculos vencidos;
 - iii. Altura dos alvos;
 - iv. Tamanho dos obstáculos;
 - v. Velocidade.
- 6) *Deep Reinforcement Learning*
- a. *API ML-Agents*.
 - b. *Proximal Policy Optimization*
- 7) *Gerador de recompensas*:
- a. Recompensa positiva;
 - b. Recompensa negativa;
 - c. Função de recompensa;
 - i. Ao final de cada passo;
 - ii. Ao final de cada episódio;

7.2.2 Especificação dos Requisitos

Com base nas informações obtidas na coleta de requisitos durante as entrevistas com os UFEs, é apresentada no Apêndice D a Especificação de Requisitos de Software (*Software Requirement Specification - SRS*) para o JSA I Blue It, fundamentada na Norma 29148-2018-ISO/IEC/IEEE. Esta norma cobre os processos do ciclo de vida de engenharia de sistemas e software, com especial atenção à engenharia de requisitos. A documentação detalha a especificação dos Requisitos Funcionais (RF) e dos Atributos de Qualidade necessários para integrar os conceitos desta tese, especialmente o aprendizado por reforço profundo, ao JSA I Blue It.

7.3 PREDIÇÃO DE *SETUP* DO *EXERGAME*

Os recursos de predição de *setup* têm como objetivo prever e recomendar os parâmetros do *exergame* para uma primeira sessão de novos pacientes ou caso o terapeuta queira redefinir o plano de treinamento de uma sessão qualquer. Este módulo de predição passa a ser uma extensão aos recursos do JSA I Blue It: *Health InfoCharts* (Santos *et al.*, 2020) responsável por exibir as métricas do paciente obtidas

durante a fisioterapia. Esse módulo permite que o terapeuta tenha controle e acompanhamento do plano de treinamento e é um recurso destinado a ajustar os parâmetros para o início do tratamento, permite configurar os parâmetros do jogo com base nos dados demográficos do novo paciente e nos dados históricos de pacientes anteriores.

Os dados utilizados são representados por X , que inclui o perfil do paciente atual e de um conjunto de perfis de pacientes similares. Cada vetor $x_i \in X$ é composto pelas características físicas (ex. altura, peso), históricos de sessões de fisioterapia e dados de desempenho em *exergames* de tratamento anteriores. Ao coletar e analisar esses dados, é possível usá-los para auxiliar na personalização do tratamento.

O uso de IA para o *setup* contribui para gerar recomendações dos parâmetros iniciais do jogo. O tipo de parâmetro 'terapeuta' exibido na Tabela 25 são gerados manualmente pelo terapeuta ou automaticamente pela IA de recomendação antes do início de uma sessão, por exemplo, para definir o nível de dificuldade da primeira sessão ou modificar uma sessão futura caso sejam identificadas situações adversas (seção 4.5).

O modelo de predição para prever os parâmetros P , pode ser implementado por um algoritmo de aprendizado de máquina, como o *K-Nearest Neighbors* (KNN) que é definido pela equação de similaridade entre k -vizinhos. O projeto do KNN deve ser implementado nas seguintes etapas: transformação dos dados; cálculo da similaridade; identificação dos k -vizinhos mais próximos; recomendação dos parâmetros.

Na etapa de transformação dos dados, realiza-se um pré-processamento dos dados de pacientes de modo que são transformados para um formato numérico apropriado para o cálculo de distâncias. Isso inclui a conversão de campos categóricos (como sexo e condição de saúde) em valores numéricos e a normalização de características fisiológicas para garantir comparabilidade.

Para o cálculo de similaridade, comumente, é calculada pela equação da distância euclidiana apresentado na equação (7.1), para identificar perfis de pacientes similares entre os vetores de características x_i e x_j . A distância euclidiana é utilizada para medir a similaridade entre pacientes. Essa métrica calcula a raiz quadrada da soma das diferenças ao quadrado entre os valores correspondentes das características dos pacientes.

$$d(x_i, x_j) = \sqrt{\sum_{k=1}^m (x_{i,k} - x_{j,k})^2} \quad (7.1)$$

Onde m é o número total de características.

Na identificação dos vizinhos mais próximos, o algoritmo calcula a distância euclidiana entre as características do novo paciente e todos os pacientes do banco de dados. As distâncias são então ordenadas, e os k pacientes mais próximos são selecionados como vizinhos. Onde, para um novo paciente x_{new} , identifica-se os k -vizinhos mais próximos no conjunto de dados histórico X equação (7.2).

$$V(x_{new}) = \{x_i \in X \mid \text{dentre os } k \text{ menores valores de } d(x_{new}, x_i)\} \quad (7.2)$$

Para gerar as recomendações de parâmetros iniciais equação (7.3), baseando-se nos perfis dos vizinhos mais próximos, o algoritmo recomenda um *setup* inicial para o *exergame*. Os parâmetros são calculados como a média ponderada entre os parâmetros dos k -vizinhos mais próximos:

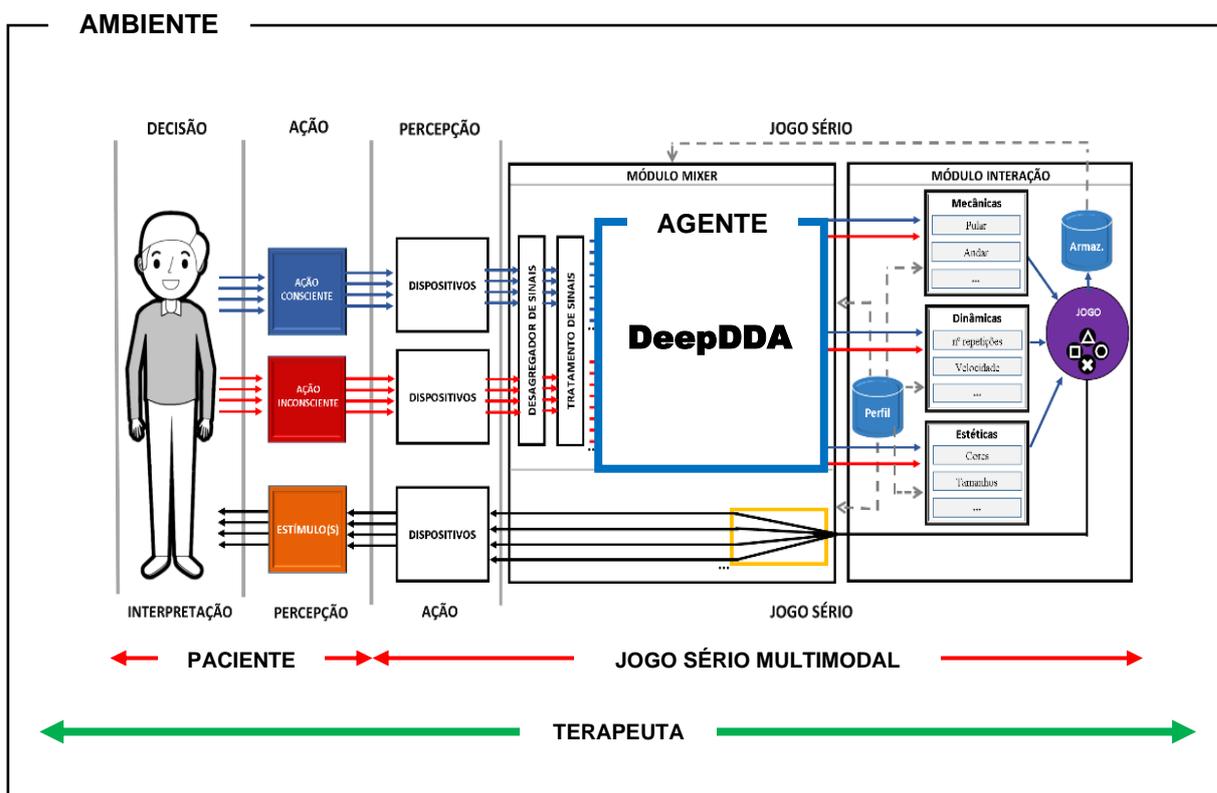
$$P_{new} = \frac{1}{k} \sum_{x_i \in V(x_{new})} parameters[x_i] \quad (7.3)$$

A utilização de método de aprendizado de máquina para a predição de *setup* do JSA I Blue It permite a personalização dos tratamentos de reabilitação respiratória. O modelo matemático baseado em KNN possibilita a recomendação de parâmetros com base no histórico de perfis de pacientes similares, de modo a gerar uma sugestão ao especialista. A integração desse módulo de predição ao *I Blue It: Health InfoCharts* fornece ao terapeuta uma ferramenta para monitorar e ajustar o plano de treinamento em tempo real, proporcionando uma abordagem dinâmica ao tratamento. Com a capacidade de prever e ajustar os parâmetros do *exergame*. A implementação pode ser analisada no Apêndice E.

7.4 DDA NO JSA “I BLUE IT”

Para implementar DeepDDA conforme a Arquitetura 123-SGR, são destacados os conjuntos de componente: ambiente, agente, paciente e terapeuta (Figura 11). Cada um desses elementos desempenha um papel no ciclo de adaptação e feedback.

Figura 11 - DeepDDA para Arquitetura 123-SGR



Fonte: Dias *et al.* (2023).

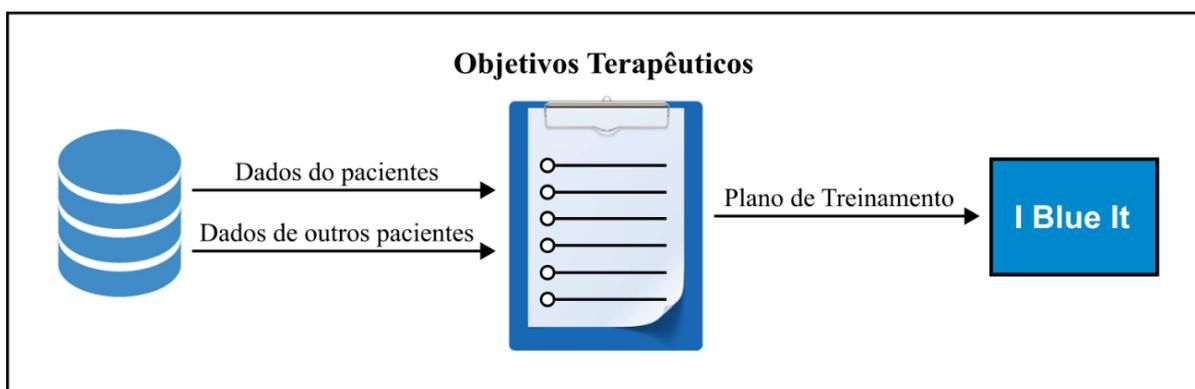
Neste contexto, o ambiente do jogo fornece os estímulos e desafios aos quais o paciente responde. O agente DeepDDA processa as entradas psicofisiológicas e ajusta os desafios com base no comportamento e no estado do jogador. O paciente interage com o *exergame*, cujas respostas fisiológicas e psíquicas ao jogo são utilizadas para a adaptação dos exercícios. O terapeuta supervisiona o processo, garantindo que os ajustes feitos pelo sistema estejam alinhados com os objetivos terapêuticos e promovam o bem-estar do paciente.

O DeepDDA mapeia as percepções psicofisiológicas proveniente dos dispositivos, das opiniões dos pacientes (*Escala de Borg*) e do jogo aos estados do agente para um conjunto de ações, determinando e executando, a cada etapa, a

melhor ação no ambiente que maximiza as recompensas a médio e longo prazo. No contexto da otimização do problema de ajuste de dificuldade, as valências psicofisiológicas do paciente definem o estado do jogador, enquanto as ações de ajuste dinâmico de dificuldade que o agente DeepDDA pode realizar determinam os ajustes nos elementos do módulo interação do JS (mecânicas, dinâmicas e estéticas).

Para iniciar a primeira sessão de terapia de um novo paciente, o terapeuta prescreve um plano de treinamento às necessidades do paciente e objetivos terapêuticos. A prescrição faz uso dos dados clínicos, fisiológicos, antropométricos e demográficos do paciente, podendo também incorporar dados de outros pacientes que possuam perfis semelhantes que serão recomendados pela IA do Módulo Preditivo de *Setup* do *Exergame* com base nas valências psicofisiológicas provenientes do banco de dados do I Blue It (Figura 12). Assim que a primeira sessão começar, e durante as sessões subsequentes de terapia, os mecanismos do DeepDDA serão ajustados dinamicamente com base nos dados históricos e nas variáveis (biosinais) advindas dos dispositivos (fluxo consciente e fluxo inconsciente) de monitoramento e/ou controle, em função da condição de saúde do paciente e do seu desempenho no JS.

Figura 12 - Plano de Treinamento



Fonte: Elaborado pelo autor (2024).

O objetivo é otimizar a evolução do paciente nas fases, níveis e pontuação, garantindo complementariedade, flexibilidade e segurança (multimodalidade), motivação (JSA) e atendimento aos objetivos terapêuticos (incentivos adequados).

O DeepDDA também proverá o monitoramento dos biosinais gerados pelo fluxo consciente e inconsciente (Dias et al. 2023), com análise que permita gerar *feedbacks*

contínuos durante a realização do programa de RR, tanto para o terapeuta como para o paciente.

Em resumo, esta proposta incorpora a utilização da arquitetura multimodal 123-SGR (Nery *et al.* 2020) (Dias *et al.* 2023), de jogos sérios destinados à reabilitação, caracterizada por sua flexibilidade, complementariedade e segurança. Para o desenvolvido do agente DeepDDA, é empregada a técnica de aprendizado por reforço (Sekhavat e Iran, 2017) em combinação com aprendizado de máquina profundo (Aggarwal, 2018). Essa abordagem permite a integração de diversas variáveis de entradas (biosinais) e facilita a tomada de decisões baseada nas interações do agente com o ambiente para maximizar as recompensas, ou seja, as ações realizadas pelo paciente durante os exercícios terapêuticos geram recompensas que incentivam o progresso do paciente.

7.5 AJUSTE DINÂMICO DE DIFICULDADE

O Ajuste Dinâmico de Dificuldade (*Dynamic Difficulty Adjustment - DDA*), aplicado em Aprendizado por Reforço Profundo (*Deep Reinforcement Learning*), constitui o agente inteligente DeepDDA. Esse agente aprende e se adapta às repostas do jogador, para ajustar a dificuldade de forma a manter o engajamento do jogador e assegurar que os exercícios realizados no JSA I Blue It proporcionem benefícios terapêuticos efetivos durante a reabilitação.

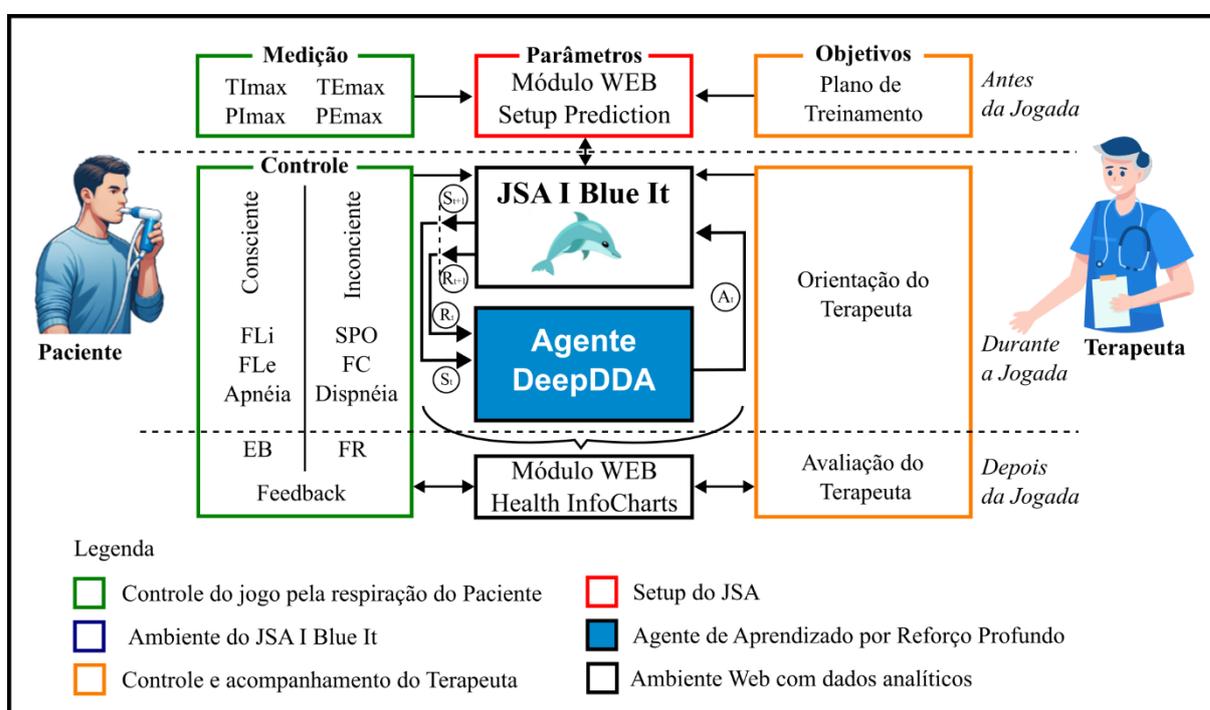
O mecanismo de ajuste de dificuldade funciona mediante a análise contínua da função de Desempenho do Jogador (*DJ*), com variáveis psicofisiológicas configurado para detectar variações significativas no desempenho - tanto melhorias quanto piores. O modelo matemático, expresso por um conjunto de equações detalhadas nas próximas subseções, foram desenvolvidos para que os ajustes de dificuldade sejam respostas dinâmicas e adaptativas ao estado atual do jogador, promovendo o *Flow Psicofisiológico*, a implementação pode ser analisada no Apêndice E.

7.5.1 Projeto Integração do Módulo DeepDDA com I Blue It

A Figura 13 apresenta o projeto de integração do módulo DeepDDA com o JSA I Blue It. O diagrama demonstra três camadas de iterações: Antes da jogada (na parte superior), durante a jogada (no meio) e depois da jogada (na parte inferior).

Na camada antes da jogada, ocorre o *setup* do *exergame*, recebendo os parâmetros da medição dos dispositivos e os parâmetros dos objetivos do plano de treinamento. Na camada durante a jogada, o DeepDDA coordena o ciclo contínuo de observação, decisão, ação, estado e recompensa nas interações entre os três elementos principais: o paciente, o JSA I Blue It e o terapeuta. Na camada depois da jogada, são exibidas informações que permitem analisar e avaliar o desempenho do paciente no módulo Web do I Blue It.

Figura 13 - Projeto de Integração do Módulo DeepDDA com I Blue It



Fonte: Elaborado pelo autor (2024).

No *setup* do *exergame*, ocorre a medição dos limites máximos de $P_{I_{max}}$, $P_{E_{max}}$, $T_{I_{max}}$ e $T_{E_{max}}$. Essas medidas são utilizadas para determinar os limiares da respiração para controlar o personagem 'Blue', definidos pelas variáveis fluxo de inspiração (FL_i) e fluxo de expiração (FL_e). O Plano de Treinamento definido pelo terapeuta fundamenta-se nos parâmetros do paciente e nos parâmetros definidos pelo Terapeuta (ver Tabela 25, Tabela 26 e Tabela 27). Esses parâmetros são informados ao agente DeepDDA, que aprende e se adapta conforme o desempenho do paciente, ajustando o exercício do Jogo (JSA I Blue It). Durante a jogada, o terapeuta orienta o paciente e, após a jogada, avalia o desempenho.

O fluxo das variáveis no DeepDDA começa com as capacidades máximas de inspiração e expiração, tanto em termos de pressão quanto de tempo, que servem como parâmetros para ajustar os exercícios. Esses fluxos respiratórios são utilizados para controlar o personagem *Blue* e alcançar os objetivos do treinamento, o que resulta no desempenho do paciente, indicando como ele está respondendo aos exercícios propostos. O sistema monitora o número de falhas consecutivas, como a falha em coletar alvos ou desviar de obstáculos, e as pontuações de sucesso, refletidas pelos níveis completados com sucesso pelo paciente, indicando sua capacidade de progredir nos exercícios.

O agente DeepDDA processa esses dados de entrada para ajustar dinamicamente os parâmetros dos exercícios, como a velocidade e a carga, com base no desempenho do paciente. A saída desse processamento é o ajuste do nível de dificuldade dos exercícios, com o objetivo de guiar o paciente ao '*Estado de Flow*', onde a dificuldade dos exercícios está adequadamente ajustada às suas capacidades, promovendo uma experiência terapêutica eficaz e segura.

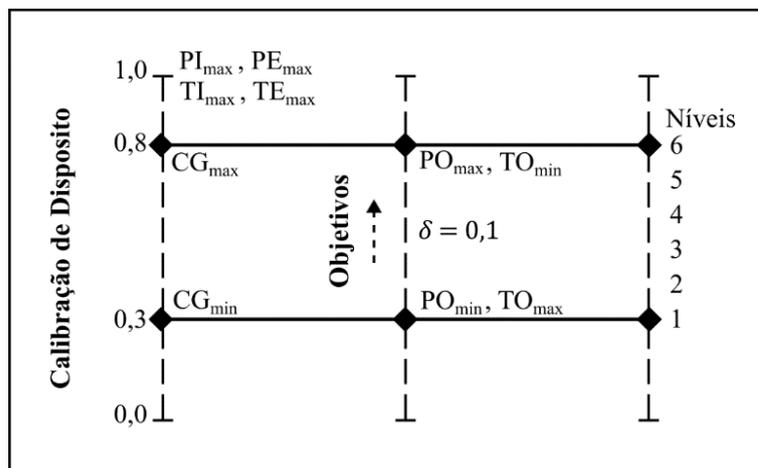
A equação (7.4) define os limiares da velocidade dos objetos na cena. Representa a dificuldade correspondente a um treino de resistência (*Endurance Training*), o que pode resultar em uma regressão ou permitir a progressão com base no Desempenho do Jogador (*DJ*).

$$VL_{t+1} = \min(\max(VL \pm VL_{\delta}, VL_{min}), VL_{max}) \mid VL_{min} = 1 \text{ e } VL_{max} = 3 \quad (7.4)$$

A Figura 14 apresenta os limiares da *CG* obtidos da medição dos dispositivos e a normalização da *PO*, que define a *CG* com base na proporcionalidade entre a Altura do Objeto (distância na vertical) e a força requerida para alcançar os 'Alvos'. Representa a dificuldade correspondente a um treino de força (*Strength Training*). Esta configuração é importante para ajustar a carga CC_t através da posição dos objetos (*PO*) no ambiente do *exergame*. A posição dos alvos é normalizada com base nas capacidades respiratórias máximas do paciente (PI_{max}, PE_{max}). O intervalo de carga segura varia entre [0.3, 0.8]. Conforme o Desempenho do Jogador (*DJ*), o DeepDDA ajusta a posição dos alvos, refletindo diretamente na intensidade da carga. Assim, a carga pode ser ajustada em incrementos ou decrementos, por exemplo, o valor do fator de ajuste $\gamma = 0.1$ para objetos do tipo alvo e $\delta = 0.1$ para objetos do tipo

obstáculo, promovendo ajustes gradativos. Esses ajustes são realizados dentro dos limites seguros. Pode-se utilizar como valores referência para [Baixo, Médio, Alto], respectivamente, [0.1, 0.5, 0.8].

Figura 14 - Limiares e Normalização da Posição e Tamanho dos Objetos



Fonte: Elaborado pelo autor (2024).

Os objetos do tipo 'Obstáculos' seguem a mesma lógica aplicada em alvos, neste caso, a normalização ocorre com base no tamanho do objeto (TO). O tamanho dos obstáculos é normalizado com base nas capacidades respiratórias máximas (TI_{max}, TE_{max}), que define a CG com base na proporcionalidade entre o tamanho do obstáculo e a força requerida para desviar do obstáculo. O objetivo é garantir que o paciente vença os obstáculos sem colidir.

O modelo matemático do agente DeepDDA que é integrado com o JSA I Blue It, demonstra uma abordagem para TMR por meio de *exergames*. Através da medição inicial, monitoramento contínuo e ajustes adaptativos em tempo real, o sistema é capaz de ajudar o terapeuta a construir um plano de treinamento personalizado. A implementação das camadas antes, durante e depois da jogada garante que cada interação do paciente com o *exergame* seja cuidadosamente ajustada para promover o estado de *flow*, onde os exercícios estão alinhados às capacidades individuais do paciente. A combinação de dados fisiológicos, psíquicos, desempenho do paciente e ajustes dinâmicos do DeepDDA pode representar uma ferramenta de apoio à reabilitação respiratória.

7.5.2 Função de Desempenho do Jogador

A implementação do DDA requer uma avaliação contínua do desempenho do paciente para assegurar que os desafios propostos no jogo estejam alinhados com as capacidades atuais do paciente. Esse processo envolve a definição de uma função que determina o desempenho atual do paciente, representada pela função Desempenho do Jogador (DJ), pela variação de Desempenho do Jogador (ΔDJ) e o Limiar de Tolerância (α).

A função $DJ(t)$ é responsável pela avaliação contínua durante o jogo e representa a combinação dos elementos psicofisiológicos que determinam o desempenho do paciente. O cálculo para a função DJ , exibida na equação (7.5), é definido pela soma ponderada entre o grau do *Flow Psíquico* (P^{FLOW}) e o grau do *Flow Fisiológico* (F^{FLOW}).

$$DJ(t) = w_1 \cdot P^{FLOW}(t) + w_2 \cdot F^{FLOW}(t) \quad \text{com} \quad w_1 = w_2 = 0.5 \quad (7.5)$$

Onde:

- $DJ(t)$ é a função de desempenho do jogador no instante t .
- $P^{FLOW}(t)$ é a medida do *flow* psíquico no instante t , normalizado $[0, 1]$.
- $F^{FLOW}(t)$ é a medida do *flow* fisiológico no instante t , normalizado $[0, 1]$.
- w_1 e w_2 são os pesos de ponderação, ambos iguais a 0.5.

Esses componentes são fundamentais para avaliar o equilíbrio entre os desafios e as capacidades psicofisiológica do jogador, orientando os exercícios de acordo com o progresso gradual da saúde do paciente e alinhando-os com os objetivos terapêuticos específicos. Dessa forma, evitam-se esforços que excedam os limites do paciente.

O uso da pontuação do jogador para definir o *Flow Psíquico* (P^{FLOW}), dado pela equação (7.6), é fundamentado nos conceitos apresentados por Csikszentmihaly (1990), que descreve que o *flow* é alcançado quando um indivíduo está imerso em uma atividade. No contexto dos *exergames*, a pontuação serve como uma métrica objetiva do desempenho do jogador, refletindo seu progresso e sucesso na superação dos desafios propostos. Assim, o modelo matemático para obter o P^{FLOW} é determinado pelo resultado da razão entre a pontuação jogador PJ_t no instante t pela

pontuação máxima PJ_{max} possível na jogada. Isso estabelece o equilíbrio entre o nível de dificuldade e o desempenho psíquico do paciente, eixo X,Y da

Figura 9 (sua percepção subjetiva de engajamento e capacidade). Essa abordagem garante que os desafios do jogo sejam ajustados para manter o paciente na zona de *flow* psicológico.

$$P^{FLOW}(t) = \begin{cases} 0, & se < LD_{min} \\ \frac{PJ_t}{PJ_{max}}, & se < LD_{max} \\ 1, & caso contrário \end{cases} \quad (7.6)$$

Onde:

- $P^{FLOW}(t)$ é o *flow* psíquico no instante t .
- LD_{min} representa o mínimo de desempenho para manter o nível de dificuldade do *exergame*.
- LD_{max} representa o objetivo do plano terapêutico que define o sucesso no exercício.

Já a medida do F^{FLOW} é determinado pela normalização *min – max* das medidas do fluxo de inspiração FL_i e fluxo da expiração FL_e durante as jogadas e das medidas obtidas na medição ($PI_{max}, PE_{max}, TI_{max}, TE_{max}$). A normalização é realizada dentro do intervalo definido no plano de treinamento, conforme a expressão da equação (7.7). A normalização garante que diferentes métricas fisiológicas sejam ajustadas para uma escala comum, permitindo uma avaliação consistente do esforço respiratório. Isso assegura que variações nas capacidades individuais dos pacientes sejam consideradas, ajustando os desafios de maneira a promover um equilíbrio entre o nível de dificuldade e o desempenho terapêutico, eixo Y,Z da

Figura 9 (seu esforço objetivo de engajamento e capacidade física). Dessa forma, é possível manter o paciente em um estado de *flow* fisiológico, onde a carga de trabalho da respiração é suficiente para estimular o progresso sem causar fadiga excessiva ou desmotivação.

$$F^{FLOW}(t) = \begin{cases} 0, & se \overline{|FL|}_i < 0.3 \cdot PI_{max} \text{ ou } \overline{FL}_e < 0.3 \cdot PE_{max} \\ 1, & se \overline{|FL|}_i > 0.8 \cdot PI_{max} \text{ ou } \overline{FL}_e > 0.8 \cdot PE_{max} \\ w_1 \cdot \overline{FL}_i + w_2 \cdot \overline{FL}_e, & caso contrário, com } w_1 = w_2 = 0.5 \end{cases} \quad (7.7)$$

$$\widetilde{FL}_i = \frac{\overline{FL}_i - \min(FL_i)}{\max(FL_i) - \min(FL_i)} \quad \widetilde{FL}_e = \frac{\overline{FL}_e - \min(FL_e)}{\max(FL_e) - \min(FL_e)}$$

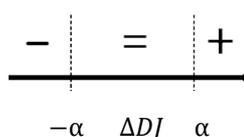
Onde:

- F^{FLOW} é o *flow* fisiológico no instante t .
- \overline{FL}_i e \overline{FL}_e são, respectivamente, os valores médios de FL_i e FL_e no período.
- \widetilde{FL}_i e \widetilde{FL}_e são, respectivamente, FL_i e FL_e , normalizados em $[0, 1]$.

A função da Variação de Desempenho do Jogador (ΔDJ) é calculada pela diferença entre o desempenho do episódio atual (S_t) e o desempenho do episódio anterior (S_{t-1}), servindo como um indicador para o DDA, por exemplo: para a progressão de carga, S_t corresponde à sessão atual e S_{t-1} corresponde à sessão anterior. Essa função reflete as variações de desempenho ao longo do jogo e é utilizada para determinar se ajustes de dificuldade são necessários, com base no valor absoluto de α , que define o limiar de tolerância simétrica $[-|\alpha|, |\alpha|]$, conforme ilustra a Figura 15, que estabelece o limiar para ajuste de dificuldade.

Os ajustes são realizados apenas quando a diferença entre os desempenhos (ΔDJ) estiver fora do intervalo $[-|\alpha|, |\alpha|]$, garantindo que mudanças intermitentes sejam evitadas e que o equilíbrio do jogo seja mantido. Ou seja, se $\Delta DJ < -|\alpha|$ ou $\Delta DJ > |\alpha|$, significa que existe uma discrepância significativa entre o desempenho do jogador e o *Flow* Psicofisiológico, indicando a necessidade de ajuste.

Figura 15 - Flow da Função de ΔDJ



Fonte: Elaborado pelo autor (2024).

7.5.3 Modelo de Decisão no I Blue It

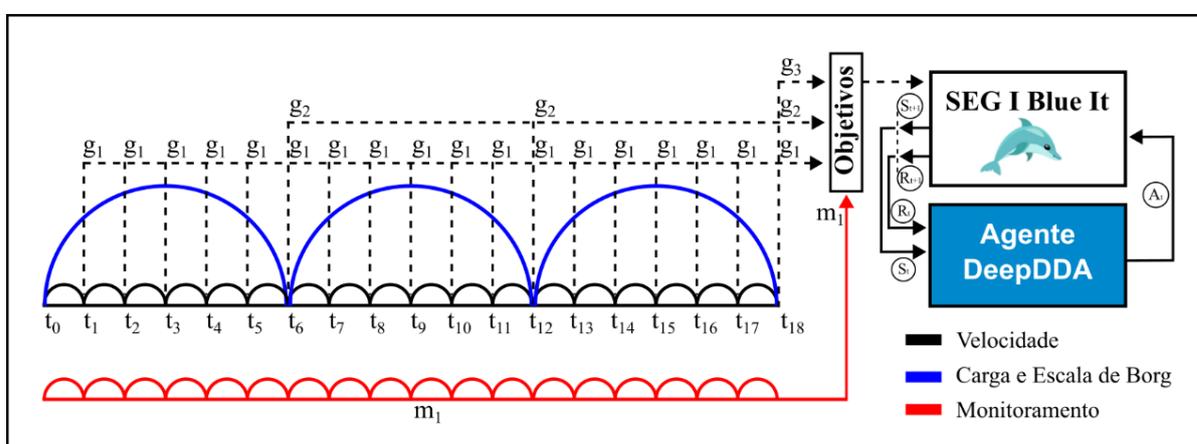
O modelo de Decisão de Markov (MDP, do inglês *Markov Decision Processes*) é uma abordagem matemática usada para modelar decisões sequenciais em ambientes incertos (Kumar *et al.*, 2019). No aprendizado por reforço, o MDP facilita o desenvolvimento de agentes inteligentes capazes de aprender e otimizar suas ações com base em recompensas recebidas. No contexto do DeepDDA, o MDP é utilizado

para modelar como o agente interage com o ambiente do jogo. Este modelo permite que o agente observe o estado atual (S_t) do jogo, tome decisões informadas para ação (A_t) e, após a ação, receba uma recompensa (R_t) que reflete o sucesso da ação em relação aos objetivos do plano de treinamento do paciente no *exergame*. Em seguida, o estado do agente é alterado para S_{t+1} .

A Figura 16 apresenta a arquitetura do ciclo de progressão do paciente em termos de objetivos do plano de treinamento. No eixo X, o final de cada nível do jogo é definido por t_i e a distância entre dois níveis é chamado de período. Por exemplo, uma sessão de fisioterapia pode possuir 6 níveis (séries) com 10 objetos cada, totalizando 60 objetos. Os objetivos definidos para medir o desempenho do paciente, são:

- g_1 : O Objetivo 1 (nível) é aumentar a velocidade quando a ΔDJ atingir o limiar definido por α em um nível (FR-02.01).
- g_2 : O Objetivo 2 (sessão) é aumentar a carga quando a $\Delta DJ > \alpha$ e a $\Delta EB \leq \beta$ em FS_L sessões consecutivas (FR-02.02, FR-02.03 e FR-02.04). É aplicado conforme apresentado na Figura 14, em vários intervalos de carga. Mas, em uma única frequência de avaliação (entre sessões).
- g_3 : O Objetivo 3 (fase) e avançar de fase do jogo.
- m_1 : O Monitoramento 1 (Biosinal) consiste em observar, por exemplo, a oximetria de pulso para identificar anomalias e agir conforme FR-03.01.

Figura 16 - Ciclo de Progressão



Fonte: Elaborado pelo autor (2024).

Onde:

- t_i representa o período correspondente a 10 objetos.
- g_1 representa o período correspondente a 1 nível.
- g_2 representa o período correspondente a 1 sessão.
- g_3 representa o período correspondente a 1 fase.
- S_t e S_{t+1} define, respectivamente, o estado atual e o próximo estado.
- R_t e R_{t+1} definem, respectivamente, a recompensa atual e a próxima recompensa.
- A_t define a ação que deve ser executada.

A seguir estão listadas as regras dos objetivos referentes ao progresso do paciente:

- **Sessão tutorial:** O agente DeepDDA é desativado e o tutorial segue ativado no tipo de comportamento “*Cérebro Heurístico*”, onde não há tomada de decisão e ação pelo agente inteligente. O objetivo é oportunizar ao paciente um momento de familiarização com o jogo com um breve tutorial. Nesta sessão usa-se carga mínima (CC_{min}) e velocidade mínima (VL_{min}).
- **Sessões com interação com Alvos:** O módulo DeepDDA é ativado no tipo de comportamento “*Cérebro de Inferência*”, responsável por tomar decisões com base em um modelo previamente treinado, onde os recursos de inteligência artificial correspondentes ao ajuste dinâmico de dificuldade estão em operação. Durante a sessão, o objetivo g_1 é avaliado com maior frequência (DDA para progressão de velocidade durante a sessão) e requer um histórico de desempenho mais curto, enquanto o g_2 é avaliado a cada sessão (DDA para progressão de carga entre sessão e pela avaliação de desempenho e da Escala de Borg) e com um histórico de desempenho mais longo. O Monitoramento da SpO2 (m_1) é avaliado do início ao final da sessão a cada período t_i .
- **Sessões com interação com Obstáculos:** O módulo DeepDDA segue ativado no tipo de comportamento “*Cérebro de Inferência*”, com um histórico de desempenho ainda mais longo. No objetivo g_3 , ocorre a mudança para uma fase com somente obstáculos. Segue o mesmo ciclo de progressão exibido na Figura 16. No entanto as restrições referentes

ao objetivo g_1 seguem a seguinte lógica: é avaliado a cada nível (DDA para progressão de velocidade), mas a VL é inversamente proporcional ao $T0$, inicia com velocidade máxima (nível de dificuldade menor) e para aumentar o desafio a velocidade é decrementada.

A primeira etapa do ciclo do aprendizado por reforço é a observação (Tabela 6). Durante esta fase, o agente coleta dados sobre o estado atual do ambiente. No DeepDDA, essas observações incluem métricas de desempenho do jogador, tais como a pontuação e sinais fisiológicos. O agente também pode receber informações sobre a configuração atual do jogo, como níveis de dificuldade, tipos de objetos e o estado de saúde do jogador. Essas observações são para que o agente conheça o contexto dentro do qual está operando, permitindo-lhe tomar decisões.

Quando não existir objetos na cena do jogo, as observações serão preenchidas com x e y relativos de -1 e velocidade em 0 . O propósito é gerar observações “nulas” nos vetores de observação.

Tabela 6 - Observações do Agente

Observação	Variável
Velocidade dos Objetos	VL
Alvos coletados com sucesso	SA
Alvos com falas	FA
Obstáculos superados com sucesso	SO
Obstáculos com falhas	FO
Desempenho do Jogador	DJ
Variação de Desempenho do Jogador	ΔDJ
Grau de Escala de Borg	EB
Saturação periférica	SpO_2
Fluxo inspiratório	FL_i
Fluxo expiratório	FL_e

Fonte: Elaborada pelo autor (2022).

A cada passo, o agente processa as observações para determinar o nível de dificuldade que está sendo aplicado pelo *exergame* ao paciente em relação ao seu DJ . Dependendo da ΔDJ , o valor absoluto de α é verificado e um sinal de nível de dificuldade do *exergame* $\{0, 1, 2\}$ é atribuído ao estado atual (S_t), e que significa, respectivamente, *exergame* {fácil, *flow*, difícil}, conforme exibido na equação (7.8). O

modelo matemático e a estrutura do código são fundamentais para a aplicação eficaz do ajuste de dificuldade, assegurando que os desafios estejam apropriados para o nível de habilidade do jogador, proporcionando uma experiência equilibrada e engajante. O estado de *Flow* é sustentado com o DDA mantendo a função ΔDJ nos limites do conforto psíquico e físico do paciente.

$$S_t = \begin{cases} 0, & \text{se } \Delta DJ > \alpha \\ 1, & -\alpha < \Delta DJ < \alpha \\ 2, & \text{se } \Delta DJ < -\alpha \end{cases} \quad (7.8)$$

Após tomar uma decisão, o agente executa uma ação no ambiente. No contexto do I Blue It, isso pode significar modificar a dinâmica do jogo de acordo com a decisão tomada, por exemplo, alterar a velocidade ou a altura dos alvos. Outros ajustes de dificuldade do jogo seguem conforme as especificações dos RF descritos neste capítulo. O Agente DeepDDA é responsável por tomar a decisão da escolha de uma ação dentre as três possíveis {manter, diminuir, aumentar} a dificuldade para cada um dos RF de DDA. A equação (7.9) apresenta a ação em um dado instante, ilustrando como o agente ajusta dinamicamente a dificuldade do jogo.

$$A_t = \begin{cases} 0, & \text{Ação para manter nível de dificuldade} \\ 1, & \text{Ação para diminuir o nível de dificuldade} \\ 2, & \text{Ação para aumentar o nível de dificuldade} \end{cases} \quad (7.9)$$

Finalmente, após a ação ser implementada, o agente recebe uma recompensa baseada no resultado de suas ações. A função de recompensa, exibida na equação (7.10), é um reforço, ou seja, um sinal representado por r_{t+1} que é devolvido pelo ambiente ao agente a cada A_t efetuada, e uma transição de estado S_{t+1} tenha ocorrido. Essa recompensa é calculada com base na eficácia com que a ação contribuiu para alcançar o objetivo desejado.

$$R_{t+1} = R_t + \begin{cases} -0.1/NR, & \text{se mantiver nível de dificuldade} \\ -2.0, & \text{se } A_t \text{ e } S_{t+1} \text{ forem a decisão errada} \\ 1.0, & \text{se } A_t \text{ e } S_{t+1} \text{ forem a decisão correta} \end{cases} \quad (7.10)$$

As recompensas atribuídas são usadas para recompensar ou penalizar o agente pelas decisões que tomou, são definidas em três tipos de episódios que promovem o reforço do DDA.

Episódio Neutro: Quando o desempenho do paciente permanece sem melhora ou declínio significativo, o agente pode receber uma recompensa negativa, mas em uma escala menor do que em um episódio de falha. Isso mantém o agente consciente de que deve buscar melhorar o estado do paciente continuamente, mas sem ser excessivamente penalizado em situações de estabilidade. Objetivo é encorajar a explorar ajustes que possam melhorar o desempenho.

Episódio de Falha: Se o paciente não consegue alcançar os objetivos terapêuticos ou se há um declínio no desempenho, o agente recebe uma penalidade. Isso ajuda a orientar o agente a evitar ações que não são benéficas para o paciente.

Episódio de Sucesso: Quando o paciente alcança ou supera os objetivos terapêuticos estabelecidos, o agente recebe uma recompensa positiva. Isso incentiva o agente a continuar promovendo ações que ajudam o paciente a progredir em seu tratamento.

Este processo contínuo de observação, decisão, ação, estado e recompensa é fundamental para a eficácia do DeepDDA, garantindo que o *exergame* se adapte continuamente às necessidades e capacidades do paciente. Ao manter o jogador engajado em um nível adequado de desafio, o DeepDDA promove um progresso terapêutico mais eficiente e uma experiência de reabilitação mais satisfatória.

Ao longo do aprendizado de máquina durante toda a sessão de jogo, o agente está constantemente aprendendo e ajustando suas políticas para melhor atender ao objetivo de manter um equilíbrio ideal entre desafio e habilidade. Cada episódio de jogo fornece novas informações que são utilizadas para refinar o modelo de decisão, garantindo uma adaptação contínua e sensível às necessidades do jogador.

Nos próximos passos, o DeepDDA explora alternativas próximas à decisão tomada, eventualmente movendo-se por um gradiente em direção a uma solução ótima. O *Proximal Policy Optimization* (PPO) é um algoritmo de otimização dentro do método de aprendizado por reforço que funciona bem quando os espaços de ação e estado tornam complexos (Schulman *et al.* 2017). O PPO aborda parte desse problema adicionando restrições adicionais como uma penalidade no algoritmo.

Os parâmetros de entrada que são passados para o DeepDDA como observações são processados em características definidoras que são então ativadas

ou desativadas com base nas entradas iniciais. Após misturar as informações, o DeepDDA é capaz de produzir uma das decisões disponíveis. Os valores de recompensa que a IA recebe são então usados para adicionar pesos à importância das camadas ocultas, eventualmente resultando em uma política que processa as entradas iniciais em um resultado. O objetivo do DeepDDA é determinar as ações que resultarão nas maiores recompensas possíveis, o que reforça os pesos usados na rede neural e define o comportamento do DeepDDA.

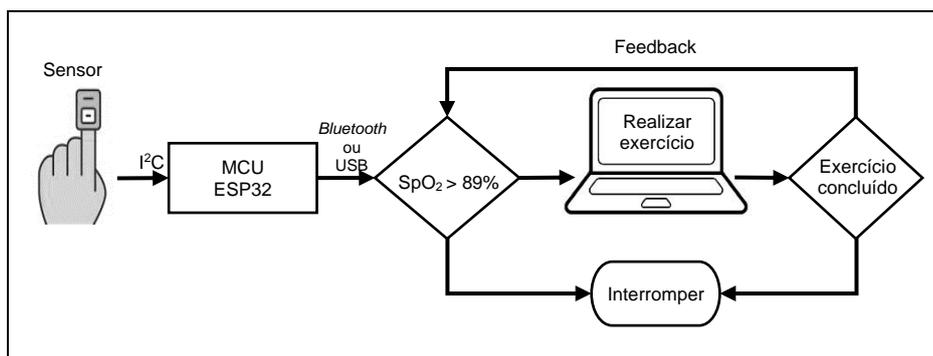
Ao implementar este ciclo de aprendizado e otimização, o DeepDDA assegura que os desafios do *exergame* sejam continuamente ajustados para proporcionar uma experiência de reabilitação motivadora. Em resumo, o DeepDDA funciona através de um ciclo contínuo que envolve a coleta de dados sobre o estado atual do jogador, a tomada de decisões com base nessas observações, a execução de ações no jogo, e a recepção de recompensas que ajudam a ajustar as decisões futuras.

Este ciclo de aprendizado permite que o *exergame* se ajuste dinamicamente às necessidades dos pacientes, garantindo que os desafios sejam apropriados para suas habilidades e promovam um estado de *flow* que é essencial para a eficácia terapêutica.

7.5.4 Monitoramento da SpO₂

O projeto do DeepDDA inclui um sistema de monitoramento da Saturação de Oxigênio (SpO₂) para garantir a segurança dos pacientes durante a fisioterapia (RF.03.01). A medição da SpO₂ é fundamental para acompanhar a resposta fisiológica do paciente durante o *exergame*, evitando esforço excessivo e desconforto (Chen *et al.*, 2010). Durante a sequência de exercício fisioterapêutico, um dispositivo de oximetria de pulso fornece sinais constantemente, que podem ser implementados e tratados dentro do *exergame*.

A SpO₂ é monitorada e os dados enviados para processamento do DeepDDA. As seguintes restrições são aplicadas (Figura 17): se a SpO₂ caia abaixo de 95%, a velocidade do jogo é reduzida; se cair abaixo de 89%, o jogo é interrompido e um alerta é emitido.

Figura 17 - Ciclo de Monitoramento da SpO₂

Fonte: Elaborado pelo autor (2024).

Esse monitoramento contínuo previne desordens respiratórias e aumenta a segurança dos exercícios, garantindo que os pacientes realizem as atividades dentro de parâmetros seguros e adequados às suas condições fisiológicas. A Tabela 7 exhibe as recompensas aplicadas pelo monitoramento de biosinais.

Tabela 7 - Recompensa do Monitor de Sinais

Tipo	Valor	Descrição
Normal	0.5	Recompensa por manter o sinal em nível de normalidade.
Regular	-0.5	Perda de recompensa por manter o sinal em faixa aceitável (regular) de risco.
Irregular	-1.0	Perda de recompensa por atingir faixa de risco em que deve suspender o uso do jogo.

Fonte: Elaborada pelo autor (2022).

7.5.5 Estratégia de Treinamento do DeepDDA com PPO

Para o processo de treinamento da função de decisão do agente DeepDDA, foi escolhido o ML-Agents¹ e as bibliotecas TensorFlow² e PyTorch² com a linguagem de programação Python, o que fornece um ecossistema de ferramentas, bibliotecas e recursos. O kit de ferramentas Unity ML-Agents é um pacote de código aberto que permite que o jogo se conecte às bibliotecas e aproveite seus algoritmos para treinar modelos.

No ML-Agents, os agentes são anexados nos objetos do jogo e passam observações e recompensas de volta para o cérebro do agente, que então executa a ação resultante. Existem três tipos diferentes de cérebros:

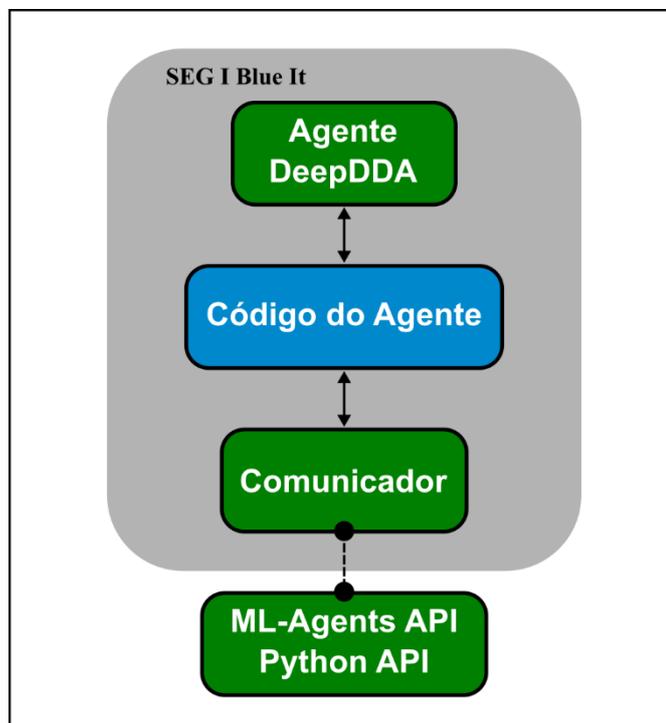
¹ ML-Agents (*Machine Learning Agents*), biblioteca *open source* desenvolvida pela Unity.

² TensorFlow e PyTorch, bibliotecas *open source* para ML e ANN

- Cérebro Interno de Inferência: Arquivos `.byte`, gerado a partir do TensorFlow após o treinamento do agente. Responsável por tomar decisões.
- Cérebro Heurístico: Utiliza scripts C# pré-programados para determinar suas ações. O cérebro heurístico recebe os mesmos dados que o cérebro interno ou externos e podem ser usados para testes e depuração.
- Cérebro Externo: São controlados pelo TensorFlow. Esses cérebros são ativamente treinados pelos algoritmos de aprendizado de máquina para gerar um arquivo `.byte`, que é a política resultante.

O componente *academy* do ML-Agents é responsável por coordenar todos os diferentes cérebros do DeepDDA que podem estar agindo sobre objetos em um ambiente de jogo. A *academy* gerencia a sincronização e a comunicação entre os agentes e os cérebros, facilitando o treinamento e a implementação das políticas de aprendizado.

Figura 18 - Ciclo de Comunicação com a API ML-Agents



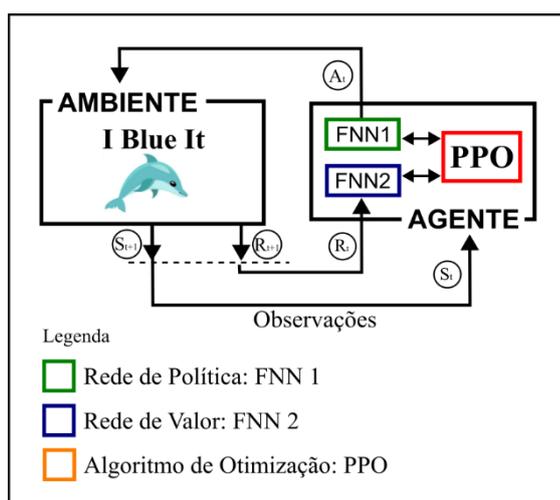
Fonte: Elaborado pelo autor (2024).

Para o treinamento do DeepDDA selecionou-se para o gradiente de política o algoritmo *Proximal Policy Optimization* (PPO), que é uma técnica de otimização de

políticas pertencente à classe de métodos de Aprendizado por Reforço baseados em política desenvolvido por Schulman *et al.* (2017). Para o agente DeepDDA utiliza-se duas Redes Neurais Artificiais (*Artificial Neural Network - ANN*) de arquitetura Redes Neurais *Feedforward (Feedforward Neural Network - FNN)*. A política consiste em uma função que mapeia estados do ambiente em ações para aproximar a função ideal que mapeia as observações ao melhor estado-ação dentre as decisões possíveis que o agente pode tomar, conforme ilustrado na Figura 19. A combinação das ferramentas oferecidas pela Unity e ML-Agents facilita a implementação de um agente adaptativo ao ambiente do jogo.

O PPO requer a configuração de hiperparâmetros, que são configurações externas definidas antes do treinamento do modelo. Os hiperparâmetros do PPO e das FNNs influenciam como o algoritmo aprende e toma decisões dentro do jogo. Por exemplo, o parâmetro “*lambda*” é usado para o cálculo da Estimativa de Vantagem Generalizada (GAE), regulando o peso dado à estimativa de valor atual na determinação de uma nova estimativa de valor. Este parâmetro equilibra a dependência entre as recompensas observadas e a estimativa de valor atual, garantindo que a política e a função de valor sejam atualizadas de maneira controlada, evitando mudanças instáveis.

Figura 19 - Ciclo de Treinamento e Otimização PPO



Fonte: Elaborado pelo autor (2024).

Onde:

- S_t e S_{t+1} define, respectivamente, o estado atual e o próximo estado.

- R_t e R_{t+1} define, respectivamente, a recompensa atual e a próxima recompensa.
- A_t define a ação que deve ser executada.

Além disso, outros hiperparâmetros, como “*buffer_size*”, “*num_epoch*”, “*batch_size*”, “*learning_rate*” e “*num_layers*” são parametrizados para otimizar a eficiência do processo de treinamento. O uso adequado dessas configurações permite que o agente DeepDDA aprenda melhor as variações psicofisiológicas, resultando em ajustes precisos da dificuldade no JSA I Blue It.

- O parâmetro “*buffer_size*” corresponde ao número experiências que devem ser coletas (observações, ações e recompensas) antes de uma atualização de aprendizagem ou do modelo;
- O parâmetro “*num_epoch*” define o número de passagens pelo buffer de experiência durante a descida do gradiente; o “*learning_rate*” determina a intensidade de cada etapa de atualização da descida do gradiente e deve ser ajustado se o treinamento estiver instável e;
- O parâmetro “*num_layers*” especifica o número de camadas ocultas após a entrada de observações, outros hiperparâmetros necessários para o treinamento estão descritos na seção 5.

O PPO otimiza uma função objetivo “*surrogate*” (substituta), que é uma função de aproximação em redes neurais. Os métodos de gradiente de política calculam uma estimativa do gradiente da política e aplicam-na em um algoritmo de ascensão de gradiente. O PPO propõe um objetivo principal com razões de probabilidade recortadas (*Clipped Surrogate Objective*) para penalizar mudanças excessivas na política (Schulman *et al.* 2017). A função objetivo substituta é otimizada durante o processo de treinamento. O PPO maximiza um objetivo substituto para garantir a estabilidade das atualizações da política.

O PPO alterna entre a coleta de dados da política e a otimização de perda “*surrogate*” usando várias épocas de *Stochastic Gradient Descent* (SGD) (Schulman *et al.* 2017). Utilizando técnicas como estimadores de função de vantagem com redução de variância e bonificações de entropia, o algoritmo atinge uma performance estável e confiável.

Por fim, a estrutura de estatísticas de treinamento fornecida pelo *TensorBoard* auxilia na avaliação contínua do progresso do agente. Métricas como “*Cumulative*

Reward” e *Entropy*” possibilitaram *insights* sobre o aprendizado, garantindo que o agente estivesse explorando adequadamente o espaço de ação sem comprometer a eficácia do processo.

7.6 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Em síntese, este capítulo apresentou a definição do conceito *Flow Psicofisiológico* aplicado no JSA I Blue It, com objetivo de conceber uma solução para promover uma reabilitação respiratória mais adaptativa e personalizada. Foi apresentado o projeto do módulo DeepDDA fundamentado no conceito *Flow Psicofisiológico do Jogos Digitais*. Através das diversas subseções, delineou-se um quadro de integração de um sistema de Ajuste Dinâmico de Dificuldade (*Dynamic Difficulty Adjustment - DDA*), baseado em aprendizado por reforço profundo, a implementação pode ser analisada no Apêndice E.

A entrevista semiestruturada com Usuários Finais Especialistas (UFEs) trouxe perspectivas que influenciaram diretamente o design e as especificações do jogo. Esses *insights* levaram a concepção de um modelo de IA, onde as recomendações dos UFEs permitiram conceber um sistema que considere variáveis fisiológicas e psíquicas, permitindo que o DeepDDA adapte dinamicamente a dificuldade dos exercícios. As sugestões dos especialistas sobre a prescrição de exercícios combinando inspiração e expiração, o ajuste da velocidade, carga e repetição dos exercícios, bem como a avaliação contínua utilizando a Escala de Borg, foram incorporadas ao projeto do jogo, garantindo que os desafios estejam sempre alinhados com as capacidades dos pacientes.

8 TESTAGEM DO FLOW PSICOFISIOLÓGICO

A testagem da prova de conceito desta tese foi realizada através de uma abordagem estruturada que inclui a validação e testes do DDA inteligente, testes de funcionalidade do I Blue It e validação dos requisitos pelos UFE. Esta abordagem assegura que o “*I Blue It 5.0: Flow Psicofisiológico*” atenda às necessidades terapêuticas. A seguir, são detalhadas as etapas do processo de validação.

8.1 APRENDIZADO DE MÁQUINA DO MODELO DEEPDDA

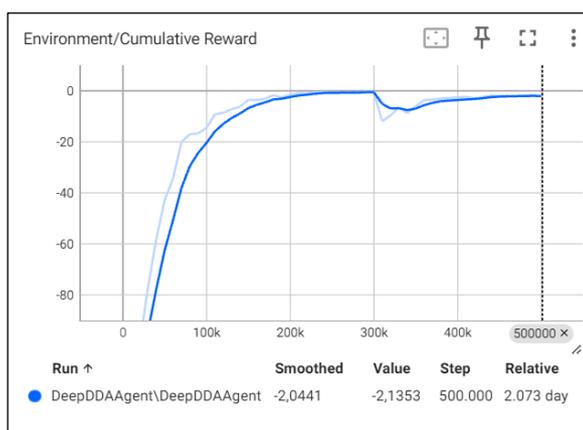
Para testar o modelo de aprendizado de máquina do DDA inteligente (DeepDDA), foram planejadas duas simulações de treinamento utilizando dados sintetizados com base na respiração de um indivíduo hígido. Optou-se, por dividir o treinamento em duas partes devido às limitações de processamento do microcomputador utilizado (GPU RTX3050 e CPU i5-12500H) e, principalmente, para explorar hiperparâmetros e encontrar os melhores ajustes por experimentação empírica, podendo testar diferentes ajustes e observar o impacto no comportamento do agente. Logo, o objetivo da primeira rodada de treinamento foi de definir os hiperparâmetros e a estratégia de recompensas para, se necessário, realizar ajustes para que otimizem o aprendizado de máquina.

Foi definida para a primeira rodada de treinamento de 500.000 *steps* com *checkpoints* a cada 100.000 *steps* para monitorar o progresso global do agente e verificar se o agente está aprendendo ao longo do tempo. A seguir, são apresentadas as principais métricas intrínsecas de validação do aprendizado de máquina do agente DeepDDA, que consistem em métricas internas ao próprio processo de aprendizado e refletem a eficácia do algoritmo de aprendizado em alcançar seus objetivos durante o treinamento, começando com a Recompensa Cumulativa Média (*Cumulative Reward*), que consiste em recompensa média cumulativa do agente. A curva de recompensa deve aumentar durante um treinamento bem-sucedido, sendo este o indicador chave do desempenho do agente ao longo do tempo.

Durante o primeiro treinamento do agente DeepDDA, observou-se no gráfico de recompensas acumuladas (Figura 20) uma tendência crescente até cerca de 250.000 *step*, onde a curva estabiliza em um platô com recompensas cumulativas negativas próximo de 0. É comum obter recompensas cumulativas médias negativas

no início do treinamento, especialmente em problemas complexos, nos quais a estratégia de recompensas atribuída ao agente aplica penalidades quando o desempenho permanece neutro (ver equação 7.10). Observa-se que entre 250.000 a 300.000 *steps*, o platô segue indicando que o agente está convergindo para uma política estável ao longo dos episódios.

Figura 20 - Recompensa Cumulativa Média (Treinamento 1)



Fonte: Elaborado pelo autor (2024).

Para melhorar o desempenho do agente, o treinamento foi interrompido no *checkpoint* de 300.000 *steps* para realizar a primeira intervenção de ajustes dos hiperparâmetros, conforme exibidos na Tabela 8. O treinamento 1 então foi reiniciado, continuando o monitoramento até 500.000 *steps*.

O impacto dos ajustes mostrou uma tendência de melhoria entre 300.000 e 400.000, mas não foi suficiente para sair da faixa de recompensa negativa. Em 500.000 *steps*, observa-se que o agente ainda não atingiu um desempenho ótimo, com recompensa cumulativa média em um platô próximo de -2,1 que sugere ser necessário mais ajustes adicionais.

Foi realizada uma segunda intervenção de ajustes, agora no *checkpoint* de 500.000 *steps*, que corresponde ao máximo de etapas (hiperparâmetro *max_steps*) planejado para o treinamento 1. Neste ponto do treinamento, foi decidido revisar também a estratégia de recompensas, de modo a reduzir a penalidade aplicada em estados neutros (Tabela 9), que corresponde a ação manter o nível de dificuldade. A primeira rodada de treinamento demandou cerca de 48 horas de processamento.

Tabela 8 - Ajustes de Hiperparâmetros

Parâmetro	Treinamento 1 Valores planejados	Treinamento 1 Ajustes em 300k	Treinamento 2 Valores atualizados	Objetivo do ajuste
batch_size	512	1024	2048	Batches maiores podem fornecer estimativas de gradiente mais estáveis.
buffer_size	10240	20480	20480	Capturar mais experiências antes de uma atualização.
learning_rate	3.0e-4	1.0e-3	1.0e-4	Taxas de aprendizado menores podem ajudar a evitar oscilação e instabilidade.
beta	1.0e-4	1.0e-4	5.0e-3	Foi aumentado para incentivar a exploração do espaço de ação.
epsilon	0.2	0.1	0.2	Parâmetro de clipagem de PPO que define o quão agressivamente a nova política diverge da antiga.
num_epoch	3	5	5	Número maior para acelerar a aprendizagem.
time_horizon	64	128	256	Reduzir o viés.

Fonte: Elaborada pelo autor (2024).

Tabela 9 - Ajuste da Estratégia de Recompensa do Agente

Tipo	Treinamento 1	Treinamento 2	Objetivo do ajuste
Neutro	-0.1	-0.1 / NR	Reduzir a penalidade por manter o nível de dificuldade.
Sucesso	1.0	1.0	-
Falha	-2.0	-2.0	-

Fonte: Elaborada pelo autor (2024).

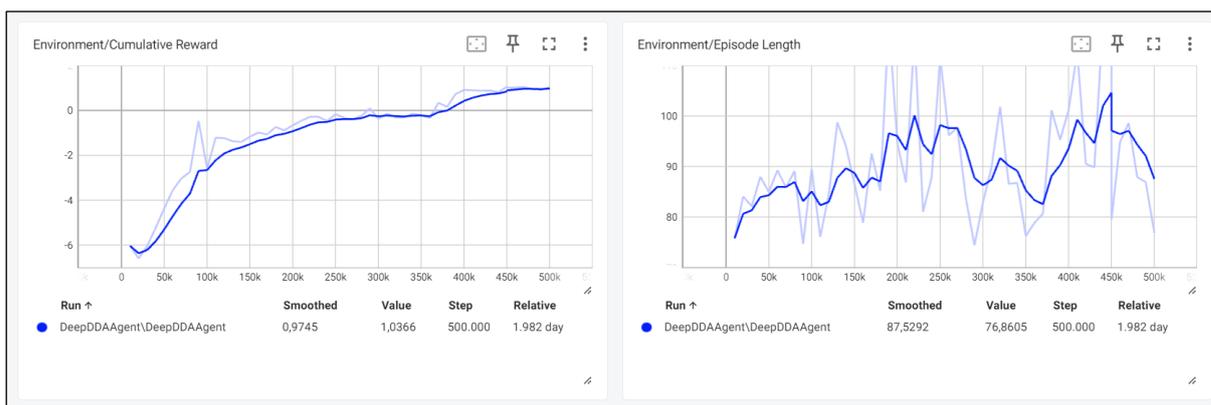
As próximas análises serão direcionadas somente aos resultados do Treinamento 2, dividindo em três grupos de gráficos de métricas: ambiente, perda e política. Na análise das curvas de métricas de ambiente, observa-se que a curva de Recompensa Cumulativa Média (*Cumulative Reward*), seguindo os ajustes indicados na Tabela 8 e Tabela 9, apresentou uma melhora nas recompensas acumuladas nas primeiras 100.000 steps (Figura 21), subindo de aproximadamente -6 para -2. Esse intervalo exhibe o impacto da mudança da estratégia de recompensas comparadas ao do treinamento 1, as recompensas estavam entre -80 a -20 nas primeiras 100.000 steps. A linha de tendência, no treinamento 2 é ascendente, indicando que o agente está aprendendo e adaptando suas ações para melhorar o desempenho.

A recompensa chega a valores positivos entre 350.000 e 400.000 steps, mostrando que o agente está alcançando um nível de desempenho onde as ações

corretas são recompensadas com mais frequência. A recompensa acumulada oscila um pouco, mas a tendência geral é ascendente. O valor suavizado (*smoothed*) da recompensa acumulada se estabiliza em valor positivo em torno de 1.0 a 500k *steps*, sugerindo que o agente alcançou um nível de aprendizado aceitável.

Observa-se que o tamanho do Episódio (*Episode Length*) exibido na Figura 21 apresenta algumas flutuações no comprimento do episódio ao longo do tempo. Isso sugere que o agente está aprendendo a manter-se ativo por mais tempo antes de falhar em suas tarefas. Essas variações podem ser devidas às diferentes nas políticas que o agente explora enquanto testa diferentes estratégias. Assim como no gráfico de recompensa cumulativa, as flutuações são esperadas e fazem parte do processo de exploração do agente.

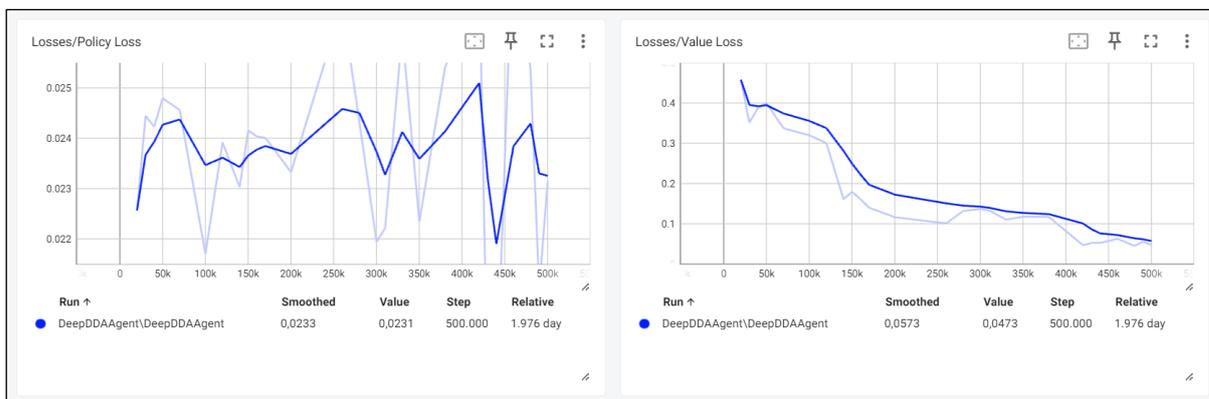
Figura 21 - Métricas de Ambiente



Fonte: Elaborado pelo autor (2024).

As curvas de métricas de perda, apresentadas na Figura 22, são importantes para observar como o modelo está se ajustando. A curva a Perda de Política (*Policy Loss*) representa a perda média da atualização da função de política que o agente está tentando aprender. Ela correlaciona como a política (processo para decidir ações) está mudando. A curva deve diminuir durante um treinamento bem-sucedido. Já a Perda de Valor (*Value Loss*) é a perda média da atualização da função de valor. Ela correlaciona como o modelo é capaz de prever o valor de cada estado e deve diminuir durante um treinamento bem-sucedido.

Figura 22 - Métricas de Perda



Fonte: Elaborado pelo autor (2024).

A curva Perda de Política (*Policy Loss*) mostra flutuações ao longo dos 500.000 *steps*, com a média geral estabilizada em torno de 0.023. As flutuações podem ser vistas em intervalos regulares, o que sugere que o agente está explorando diferentes ações e ajustando sua política para melhor se alinhar com as recompensas recebidas, refletindo o equilíbrio entre exploração e aproveitamento. A linha suavizada mostra uma leve tendência decrescente, um sinal positivo de que o agente está melhorando sua política.

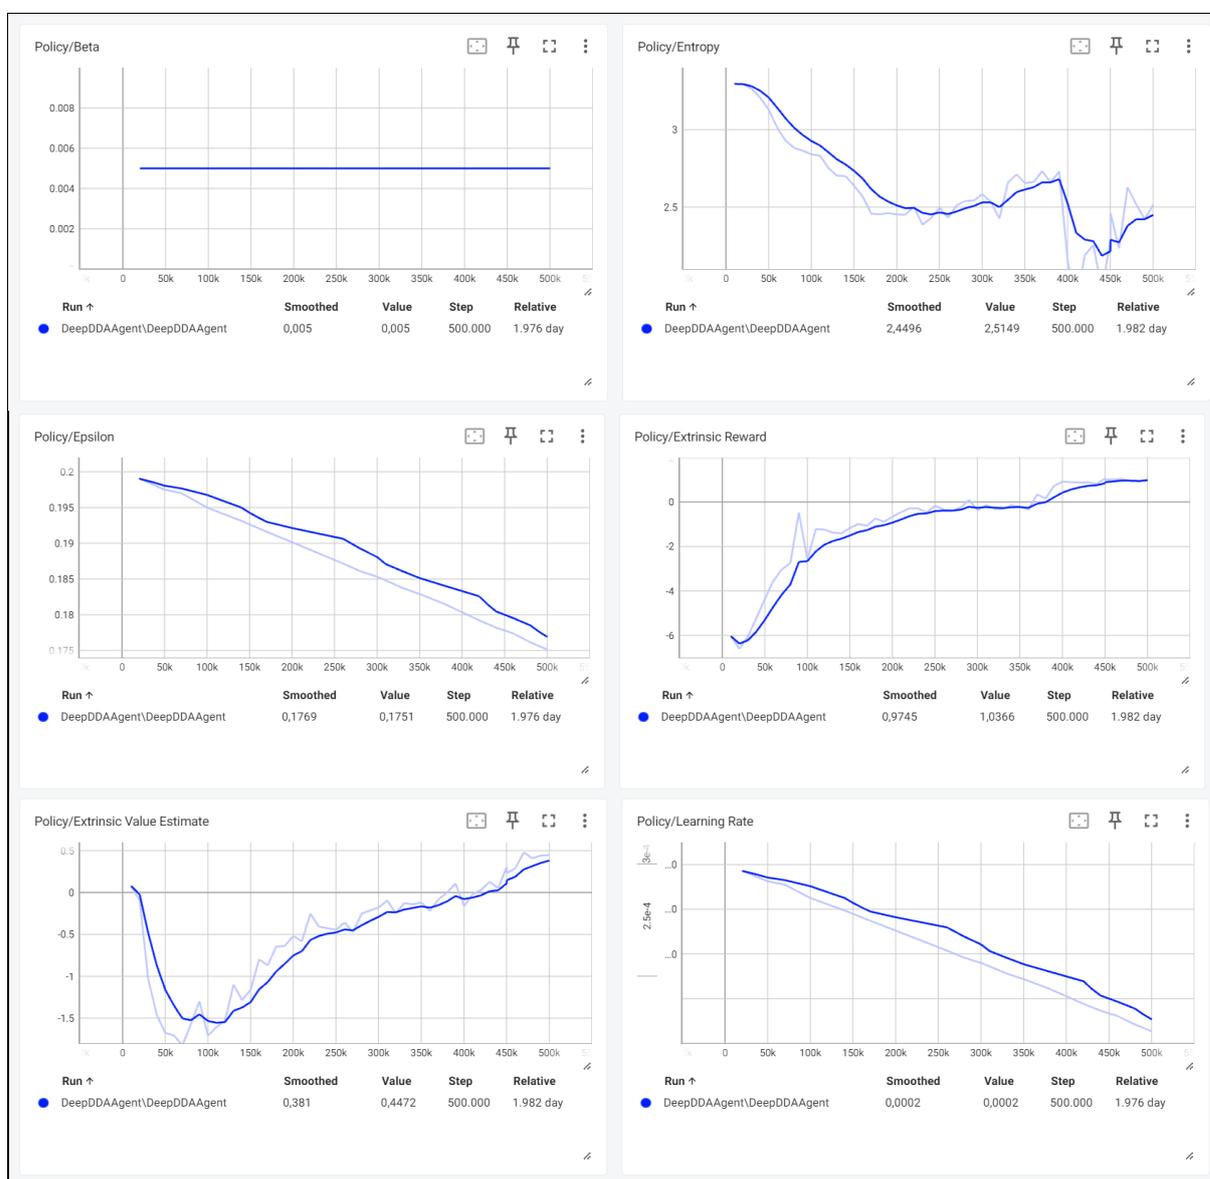
A curva Perda de Valor (*Value Loss*) mostra uma tendência de queda ao longo do tempo, começando alta e diminuindo constantemente até se aproximar de zero. Isso indica que o modelo está ficando cada vez melhor em prever os valores das ações tomadas pelo agente, representando um sinal positivo de convergência, mostrando que o agente está aprendendo a avaliar corretamente as recompensas futuras, o que é importante para a tomada de decisões eficiente. É importante considerar a perda de valor em conjunto com a perda de política. Uma perda de valor estável e baixa, juntamente com uma perda de política controlada, sugere que o agente está aprendendo de maneira eficaz.

As curvas de métricas de política, apresentadas na Figura 23, estão relacionadas aos parâmetros e sinais de recompensas usadas pela política do agente. A curva *Beta* está definida como constante, pois é um parâmetro de regularização que controla a entropia da política para manter a exploração equilibrada.

A curva de Entropia (*Entropy*) reflete as decisões aleatórias do agente DeepDDA e deve diminuir lentamente durante um processo de treinamento bem-sucedido. À medida que o agente aprende uma política mais definida, a entropia tende

a diminuir. A flutuação observada entre 400.000 e 450.000 *steps* pode ser explicada por fatores relacionados com a Exploração versus Aproveitamento, que consiste no aumento da entropia quando o agente está explorando novas ações e quando o agente está aproveitando mais ações diferentes, a entropia aumenta. Posteriormente, à medida que o agente identifica as melhores ações, a entropia pode diminuir novamente. Os valores de entropia começam em torno de 3.5 e diminuem para cerca de 2.0 ao longo dos 500.000 *steps*. A linha suavizada mostra uma diminuição contínua, indicando que o agente está explorando menos e aproveitando mais em ações específicas já aprendidas.

Figura 23 - Métricas de Política



Fonte: Elaborado pelo autor (2024).

A curva de *Epsilon* mostra uma tendência decrescente ao longo do tempo. Isso é esperado, pois a política *epsilon-greedy* diminui gradualmente para reduzir a exploração e aumentar a aproveitamento de ações aprendidas. O valor de *Epsilon* começa em cerca de 0.20 e diminui para aproximadamente 0.17 ao longo de 500.000 steps. A linha suavizada mostra uma diminuição contínua, indicando uma redução na exploração.

A curva de Recompensa Extrínseca (*Extrinsic Reward*) mostra uma tendência crescente ao longo do tempo com algumas flutuações. Isso indica que o agente está aprendendo a maximizar as recompensas extrínsecas dadas pelo ambiente, o que é um bom sinal de que o agente está melhorando seu desempenho. A recompensa extrínseca estabiliza em torno de 1,0 a partir de 450.000 *steps*, sugerindo que o agente está se aproximando de uma política estável que maximiza a recompensa extrínseca, indicando uma melhoria na performance do agente em relação aos objetivos definidos.

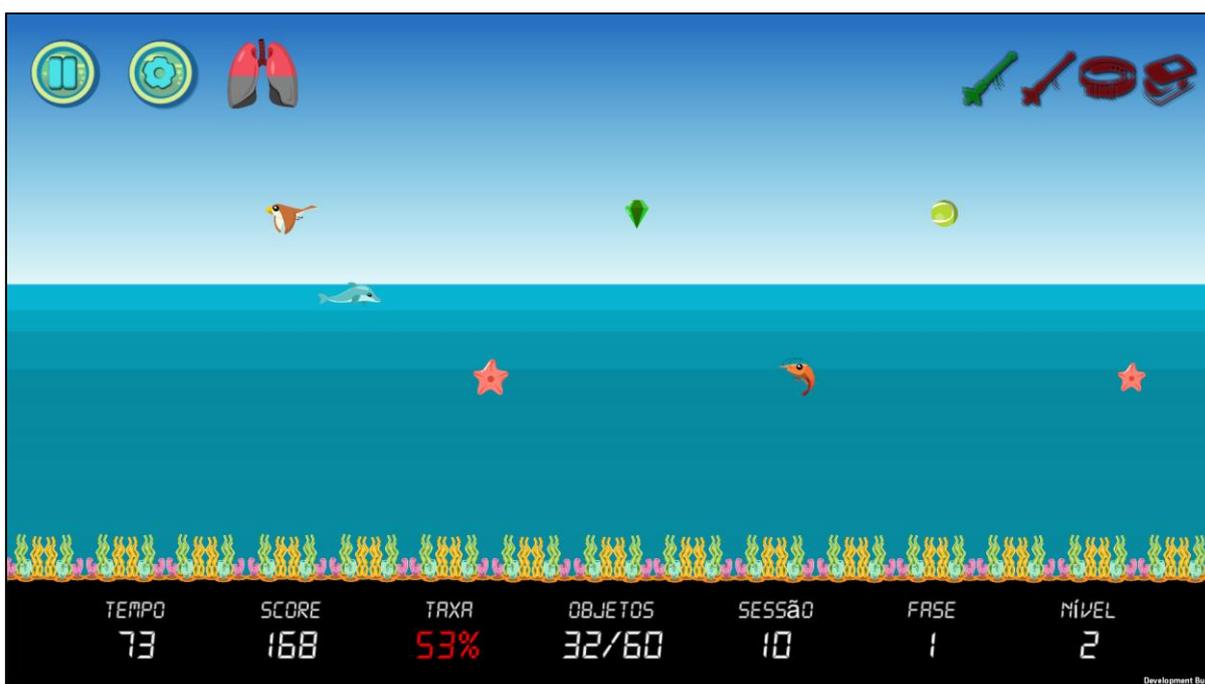
A curva de Estimativa de Valor Extrínseco (*Extrinsic Value Estimate*) consiste na estimativa média de valor para todos os estados visitados pelo agente. A curva deve aumentar durante um treinamento bem-sucedido. A estimativa de valor extrínseco mostra uma tendência inicial decrescente até cerca de 100.000 *steps*, seguida por uma recuperação gradual até 500.000 *steps*. A estimativa de valor extrínseco começa em torno de 0, diminui para cerca de -1,5 e, em seguida, aumenta novamente para cerca de -0,44 no final de 500.000 *steps*. A recuperação sugere que o agente está melhorando na avaliação de suas ações e recompensas futuras ao longo do tempo.

A Taxa de Aprendizagem (*Learning Rate*) consiste no passo que o algoritmo de treinamento leva à medida que pesquisa a política ideal. A curva deve diminuir ao longo do tempo refletindo uma tendência decrescente. A taxa de aprendizado está definida como linear e é reduzida gradualmente para permitir uma convergência mais estável e refinada. A taxa de aprendizado começa em $1.0e-4$ e diminui para 0.0002 ao longo de 500k *steps*. A linha suavizada mostra uma diminuição contínua, o que indica que o treinamento está ajustando a taxa de aprendizado conforme o agente se aproxima de uma política ótima.

A segunda rodada de treinamento demandou cerca de 47 horas de processamento. Uma vez definidos os parâmetros do aprendizado da IA, os algoritmos estão operacionais para começar a serem testados.

Na Figura 24, é exposto uma cena da fase 1 do *exergame*, com o modelo do agente DeepDDA ativado no tipo de comportamento “*Cérebro de Inferência*”, onde diversos elementos interativos são apresentados. A parte inferior da tela exibe informações, como tempo decorrido, pontuação (*score*), taxa de sucesso em porcentagem, número de objetos coletados do total existente no *exergame*, essas pontuações são observações psíquicas do jogador e são representados nas observações das variáveis que resultam no *DJ*. O jogo também possui dados que são observados pelo agente durante a interação com os objetos do tipo alvo, que aparecem em posições que incentivam o paciente a exercer um fluxo de inspiração ou expiração para coletá-los que correspondem as observações fisiológicas do jogador.

Figura 24 - Ambiente do I Blue It



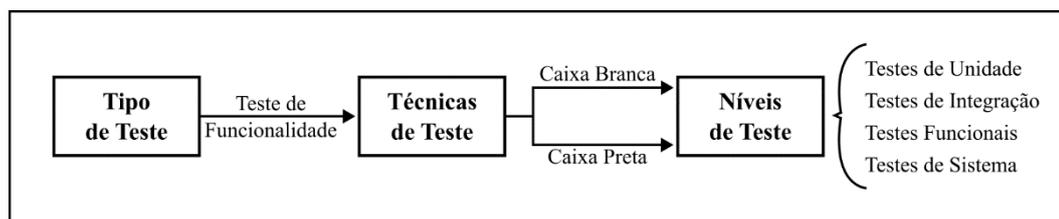
Fonte: Elaborado pelo autor (2024).

8.2 TESTES DE SOFTWARE

Para assegurar a robustez do módulo DeepDDA e dos módulos preditivos de IA desenvolvidos para prova de conceito, foi realizado um conjunto de testes de funcionalidades, organizados em quatro níveis distintos (Figura 25). Esses níveis de testes foram aplicados ao “*I Blue It 5.0: Flow Psicofisiológico*”, foram selecionados

para avaliar a funcionalidade através das técnicas de caixa branca e caixa preta (Sommerville, 2018). Cada nível de teste foi escolhido com um propósito específico para garantir a validação das IA implementadas. Os testes foram conduzidos com a colaboração de dois estudantes de iniciação científica do curso de Bacharelado em Ciência da Computação e um estudante de iniciação científica do curso de Bacharelado em Engenharia Elétrica.

Figura 25 - Testes aplicados no I Blue It



Fonte: Elaborado pelo autor (2024).

O teste de funcionalidade tem como objetivo assegurar que todos os requisitos implementados funcionem conforme o especificado. Este tipo de teste verifica se o agente DeepDDA ajusta corretamente os níveis de dificuldade do *exergame*, se a IA prevê e recomenda os parâmetros do *exergame* com base nos dados atuais e históricos de pacientes, e se a IA realiza o monitoramento e detecção de anomalias dos biosinais com base nas respostas dos usuários e nos dados coletados. Além de assegurar que todas as funcionalidades do sistema I Blue It estejam em pleno funcionamento.

A técnica de caixa branca foi adotada para realizar uma verificação das condições e comandos internos do software, proporcionando uma análise detalhada do código-fonte. Essa abordagem permite garantir que todas as operações internas estejam corretas e que o fluxo de execução atenda aos requisitos estabelecidos. Esse tipo de teste é especialmente útil nos níveis de testes de unidade e de integração, onde a validação da lógica interna é fundamental. Durante o teste de caixa branca, foram verificados os métodos específicos e a lógica do código, buscando identificar e corrigir possíveis falhas ou inconsistências.

Por sua vez, a técnica de caixa preta foi empregada para validar as funcionalidades do sistema a partir da perspectiva do usuário final, sem a necessidade de considerar a estrutura interna do código. Nessa abordagem, o foco está na verificação dos requisitos funcionais e da usabilidade do *exergame* I Blue It,

garantindo que ele atenda às expectativas dos usuários e funcione conforme o esperado em diversos cenários de uso. Durante os testes de caixa preta, foram detalhados os casos de uso testados, os requisitos funcionais validados e a perspectiva do usuário final, buscando garantir uma experiência consistente e satisfatória para os usuários.

Os níveis de testes apresentados na Figura 25 foi planejado e executado para abordar aspectos específicos da funcionalidade e da integração do sistema. Os testes de unidade focaram em garantir que todos os métodos das classes implementadas recebam as entradas esperadas e produzam as saídas corretas, verificando o comportamento de cada função de maneira isolada. Em seguida, os testes de integração foram conduzidos para verificar se os módulos, APIs e demais classes de *gameplay* funcionam conforme especificado, assegurando a comunicação eficiente entre as partes do sistema. Os testes funcionais centraram-se nos requisitos de negócios dos UFE, avaliando a funcionalidade do software em cenários reais de uso. Finalmente, os testes de sistema envolveram uma abordagem ponta a ponta para garantir que a interação do usuário com o I Blue It ocorra conforme esperado, verificando a usabilidade e a experiência do usuário em todas as etapas do *exergame*. A seguir estão descritos cada um dos níveis de testes aplicados.

8.2.1 Testes de Unidade

Garantir que todos os métodos das classes implementadas recebam as entradas esperadas e produzam as saídas correspondentes. Verificar o comportamento de cada método e função individualmente, assegurando que as operações internas de cada classe estejam corretas. Testes realizados em cada componente para garantir que as entradas produzam as saídas esperadas. Estes testes incluem a verificação de métodos e da lógica do código, utilizando técnica de caixa branca para analisar as operações internas.

8.2.2 Testes de Integração

Verificar se os módulos, APIs e demais classes de *gameplay* do I Blue It funcionam conforme especificado. Garantir que a comunicação entre diferentes partes do sistema ocorra sem falhas, focando na interação entre componentes individuais.

Testes realizados para assegurar que os módulos, APIs e classes de *gameplay* funcionem de maneira integrada e sem falhas. Durante os testes de integração, foram identificadas e corrigidas falhas na comunicação entre módulos.

8.2.3 Testes Funcionais

Os testes funcionais possuem foco nos requisitos de negócios dos usuários, assegurando que o sistema atenda suas especificações e expectativas. Testar as funcionalidades do software em casos de teste reais de uso, contemplando as funcionalidades principais e secundárias do *exergame*, são realizados para validar que o sistema atenda aos requisitos. Esses testes envolveram a execução de casos de uso das interações dos usuários, onde os requisitos foram tabulados para facilitar a validação. Relatórios de execução dos testes funcionais, com foco nos requisitos de negócios e na validação das funcionalidades principais e secundárias.

8.2.4 Testes de Sistema

Consistem em testes ponta a ponta para garantir que o comportamento do usuário (paciente) ao interagir com o I Blue It seja conforme o esperado. Verificar os diversos fluxos de uso, incluindo a usabilidade e a experiência do usuário, desde a inicialização do *exergame* até o encerramento da sessão terapêutica. Estes testes se destacaram sob a avaliação do comportamento do sistema sob diferentes condições de uso. Relatórios de execução dos testes de sistema, incluindo a usabilidade, experiência do usuário e *feedback* dos pacientes.

8.3 VALIDAÇÃO DE REQUISITOS PELOS UFE

A validação dos requisitos foi realizada através de reuniões estruturadas com os UFE, onde foram apresentadas demonstrações do I Blue It 5.0: Flow Psicofisiológico, que contempla a concepção do Conceito Flow Psicofisiológico e Inteligência Artificial com a implementação do DeepDDA. O objetivo dessas reuniões foi coletar *feedbacks* e *insights* para confirmar que os requisitos refletem adequadamente as necessidades dos usuários e que a solução proposta é consistente. As etapas da demonstração envolveram:

- Demonstração da inteligência artificial do I Blue It com o DeepDDA, explicando como os ajustes dinâmicos de dificuldade são realizados para melhorar a experiência terapêutica;
- Avaliação do *exergame*, incluindo perguntas direcionadas aos UFEs sobre funcionalidades e inteligência do sistema.

Feedbacks e Melhorias sobre Ajustes de Dificuldade: Os ajustes de dificuldade no *exergame* foram aprimorados com base em *feedbacks* recebidos. Primeiramente, a velocidade dos objetos, agora é definida como o objetivo primário, progride entre “Nível” (g1), relacionado com treinamento de resistência, podendo o NR ser 30, 60 ou mais. A carga dos objetos, definida como o objetivo secundário, progride entre “Sessões” (g2), relacionado com treinamento de força. Na primeira fase, o treino de carga inclui poucos objetos, com a possibilidade de o terapeuta elaborar manualmente o plano de treinamento ou usar a recomendação da IA. Além disso, houve uma revisão nos ajustes das estrelas para manter a linha da água durante o fluxo de respiração de relaxamento, evitando que o paciente seja incentivado a jogar enquanto descansa.

Feedbacks e Melhorias sobre Funcionalidades: No que diz respeito às funcionalidades, o controle de tempo de inspiração/expiração, um recurso já existente entre os tipos de fases do jogo, foi ratificado pelo UFE. O escore absoluto do paciente foi incorporado ao HUD do jogo, proporcionando uma visão clara do desempenho do paciente. A Escala de Borg foi simplificada para atender a solicitação do terapeuta, facilitando o uso e a interpretação. A ficha de cadastro do paciente agora inclui a classificação de distúrbio misto (leve, moderado ou grave) e a opção de fármaco. A exportação de dados para uma versão em Excel está sendo analisada e será implementada posteriormente. Correções nos gráficos, com o ajuste do eixo x do gráfico da plataforma para o número de sessão, e correções adicionais no *I Blue It: Health InfoCharts* serão feitas posteriormente. Não foi aplicado um protocolo específico de terapia, como o Ciclo Ativo da Respiração, permitindo que o terapeuta tenha liberdade para criar um plano de treinamento customizado no I Blue It, independentemente de protocolo.

Recursos Inteligentes Aprovados

- *Setup* de Parâmetros: Foi aprovado pelos UFE os novos recursos da área do sistema web do I Blue It criados para permitir definir um plano de treinamento manualmente ou feita pela IA de recomendação;
- DDA de Velocidade dos Objetos: A IA de ajuste de dificuldade da velocidade em cada nível (série) de exercício foi aprovada e comparada com um treinamento de resistência que promove desafio e engajamento;
- DDA de Ajuste da Altura e Tamanho dos Objetos: A IA de ajuste de dificuldade da altura e do tamanho dos objetos foi aprovada e reflete no ajuste da carga (treino de carga) entre sessões de fisioterapia, sendo a progressão baseada no desempenho do paciente e na avaliação da Escala de Borg.

As melhorias e *feedbacks* coletados durante essas reuniões foram incorporados ao sistema, garantindo uma solução mais eficaz e alinhada com os objetivos de reabilitação respiratória.

8.4 CONSIDERAÇÕES FINAIS DO CAPÍTULO

A testagem do conceito de Flow Psicofisiológico com a implementação do DeepDDA no I Blue It foi robusta para atender às necessidades terapêuticas dos usuários. As rodadas de treinamento do modelo de aprendizado de máquina mostraram progressos significativos, apesar das flutuações nas recompensas acumuladas. Ajustes nos hiperparâmetros e na estratégia de recompensas melhoraram o desempenho do agente, evidenciando a importância de uma abordagem iterativa no treinamento de agentes de IA.

Os testes de software, aplicando técnicas de caixa branca e caixa preta, garantiram a funcionalidade do sistema. A integração das funcionalidades foi aprovada em diversos níveis, desde testes unitários até testes de sistema, assegurando que todas as operações internas e interações com os usuários finais estavam em conformidade com os requisitos especificados.

As reuniões de testagem com os UFE forneceram *insights* que foram incorporados ao I Blue It. Os *feedbacks* resultaram em melhorias nas funcionalidades. A aprovação dos recursos inteligentes, como o *setup* de parâmetros e o DDA, reforça a eficácia da prova de conceito.

9 DISCUSSÃO

O conceito *Flow* Psicofisiológico em Jogos Sérios Ativos para Reabilitação (em especial Respiratória) representa uma metodologia inovadora. Ao integrar os conceitos de *Flow* aos de fisioterapia, promove nos *exergames* dos programas de reabilitação um estado de fluxo psíquico e fisiológico. Esse estado de *Flow* Psicofisiológico envolve os pacientes em uma experiência na qual dificuldade, desempenho terapêutico e desempenho psíquico estão em equilíbrio. A seguir, discute-se o *Flow* Psicofisiológico como uma ferramenta para programas de reabilitação (respiratória), oferecendo um recurso adicional para compor o plano de treinamento dos profissionais da área de fisioterapia.

9.1 SOBRE A REVISÃO DA LITERATURA

A revisão da literatura sobre o uso de IA em jogos digitais aplicados à reabilitação foi estruturada em duas partes principais. Na primeira parte, o Mapeamento Sistemático da Literatura (MSL) e a Revisão Sistemática da Literatura (RSL), e ofereceu uma visão abrangente e detalhada das tendências, aplicações e lacunas na área. Além da pesquisa sistemática com ênfase no campo da IA. Na segunda parte da revisão da literatura foi realizada uma pesquisa complementar não estruturada de trabalhos sobre o uso da técnica DDA. A revisão da literatura permitiu uma análise detalhada dos locais de publicação, características dos estudos, contribuições gerais, tendências e lacunas.

Na revisão sistemática (Seções 3.1 e 3.2), o número de publicações sobre a utilização de IA em jogos digitais para reabilitação respiratória cresceu a uma taxa média anual de 8%. O MSL, de um total 7.918 destacou 28 artigos relevantes (Tabela 14). Os estudos foram categorizados em *Intelligent Movement*, *Path Finding*, *Decision Making*, *Tactical and Strategic* e *Machine Learning*. A principal contribuição da MSL foi a identificação dos métodos de IA mais comuns utilizados em JD para RR. Esses métodos incluem *Intelligent Movement* e *Decision Making*, que permitem a navegação otimizada e adapta os elementos do jogo, respectivamente (Gráfico 9, Gráfico 13, Apêndice A).

Em seguida dos 28 artigos do MSL, 10 foram classificados para RSL. Observou-se que os jogos digitais têm sido utilizados por terapeutas como

complemento à reabilitação respiratória por apresentarem exercícios que estimulam o treinamento cardiorrespiratório, similares ou equivalentes aos exercícios das intervenções fisioterapêuticas tradicionais. Jogos digitais promovem exercícios que incentivam e auxiliam o paciente com *biofeedback* em tempo real. Esse *feedback* é conduzido por variáveis de desempenho no jogo, combinado com elementos de jogos como alvos, obstáculos e recompensas, proporciona diversão e aumenta o engajamento do paciente. A literatura revisada mostrou que há um número limitado de estudos explorando o uso explícito de IA (Gráfico 5, Apêndice A) em jogos digitais para reabilitação (respiratória). Os trabalhos analisados no RSL concentram-se em técnicas que não fazem uso de redes neurais artificiais dentro do método de aprendizado por reforço.

A revisão não estruturada (complementar) sobre a utilização da técnica de DDA, destacou 11 artigos relevantes (Tabela 3). Os trabalhos analisados destacaram a aplicação de diferentes técnicas do campo da IA para aplicar o DDA, como *Algoritmos Evolucionários*, *Sistemas de Inferência Fuzzy*, *Aprendizado por Reforço* ou *Redes Neurais Artificiais*, que foram utilizados para adaptar o jogo. Esses ajustes foram baseados em variáveis de desempenho no jogo, resultando em comportamentos inteligentes como a geração automatizada de conteúdo e a modificação em tempo real de elementos do jogo como a posição, o tamanho e a altura (Seção 3.3). Tais técnicas permitem a criação de níveis de dificuldade dinâmicos que se adaptam às necessidades individuais.

A análise da literatura revelou que o uso de IA em jogos digitais aplicados à reabilitação é um campo emergente, com crescente reconhecimento acadêmico e terapêutico. Apesar dos avanços e do potencial crescente dos jogos digitais apoiados por IA na reabilitação, não se encontrou na literatura uma abordagem, com ou sem IA, que focasse na articulação entre as dimensões psíquicas e fisiológicas. Isso demonstrou que existem oportunidades para o emprego do Flow Psicofisiológico com a técnica DDA no campo da IA em *exergames* voltados para reabilitação. A exploração de métodos de aprendizado por reforço e técnicas de redes neurais artificiais é uma área promissora. Não foram encontrados estudos que implementaram o DDA com uso do método de aprendizado por reforço com a técnica de ANN.

9.2 SOBRE O FLOW PSICOFISIOLÓGICO

O conceito Flow Psicofisiológico, proposto nesta tese, representa uma metodologia para a implementação de Jogos Sérios Ativos (JSA) na área da reabilitação, integrando elementos do desempenho psíquico (jogo) com elementos do desempenho físico (terapêutica). Esse conceito fundamenta-se na Teoria do *Flow*, que descreve um estado de alta concentração e engajamento. O *Flow* Psicofisiológico visa equilibrar as variáveis da dimensão do Flow Psíquico, para evitar tanto o tédio quanto a frustração, com as da dimensão do Flow Fisiológico, para evitar tanto a fadiga excessiva quanto o marasmo inadequado, com a dimensão da Dificuldade que define a intensidade do esforço exigido durante os exercícios no *exergame*.

A necessidade do Flow na dimensão fisiológica auxilia no uso de *exergames* em programas de reabilitação. O estado de Flow é essencial para manter os pacientes engajados e motivados durante as sessões de terapia. Isso significa ajustar dinamicamente a dificuldade dos exercícios para ajudar a prevenir tanto a fadiga quanto o marasmo, ambos prejudiciais ao processo terapêutico. Cansaço excessivo pode levar à exaustão e até a lesões, enquanto o marasmo pode resultar em desinteresse e baixa adesão ao tratamento.

O conceito de Flow Psicofisiológico é particularmente eficaz em contextos multimodais e multidados, onde múltiplos tipos de informações são integrados para fornecer uma experiência terapêutica mais completa e adaptativa. No entanto, o conceito pode ser implementado em sistemas não multimodais, embora com eficácia potencialmente reduzida, uma vez que a riqueza de dados provenientes de múltiplos modos oferece uma melhor personalização do tratamento.

A utilização de IA é um componente central para a implementação eficaz do Flow Psicofisiológico, especialmente para o DDA com base em sinais fisiológicos e psíquicos. No entanto, em situações em que a IA não está disponível, podem-se usar métodos heurísticos ou baseados em regras para tentar replicar parte dos benefícios, embora com menor precisão e adaptabilidade.

A prova de conceito realizada focou na Reabilitação Respiratória, mas os princípios do conceito Flow Psicofisiológico alcançado com o agente DeepDDA podem ser adaptados e aplicados a outras áreas de reabilitação, desde que envolvam uma combinação de desafios psíquicos e fisiológicos. Fundamentalmente, o que o Flow Psicofisiológico enfatiza em termos de *Game Design* é que o projeto de um *exergame*

deve se preocupar com o conforto psicológico, mas também físico do jogador, em especial se o jogo for um jogo sério.

9.3 SOBRE A ARQUITETURA MULTIMODAL

A implementação do Flow Psicofisiológico se beneficia de uma arquitetura multimodal para capturar e integrar diversos sinais fisiológicos e psíquicos do paciente. A arquitetura 123-SGR, utilizada no desenvolvimento do I Blue It, demonstra ser eficaz para este propósito. Contudo, embora a multimodalidade aumente a eficácia do Flow Psicofisiológico, o conceito pode ser adaptado para arquiteturas menos complexas.

A arquitetura 123-SGR oferece flexibilidade, complementariedade e segurança, sendo composta por dois módulos principais: o Mixer e o Interação. O módulo Mixer é responsável pelo processamento dos sinais provenientes de diversos dispositivos, como de respiração e saturação sanguínea, enquanto o módulo Interação cuida do *gameplay*. Esses módulos permitem a captura e análise de fluxos conscientes e inconscientes do paciente.

O fluxo consciente envolve ações intencionais do jogador, como controlar a respiração para manipular o personagem no jogo. O fluxo inconsciente captura características fisiológicas não intencionais, como variações na frequência respiratória e saturação de oxigênio, que podem ser monitoradas para garantir a segurança do tratamento. O fluxo de *feedback* fecha o ciclo de interação, fornecendo respostas ao paciente sobre o desempenho.

A escolha do I Blue It para incorporar o conceito de Flow Psicofisiológico destaca-se por ser um JSA que já utilizava a arquitetura 123-SGR, permitindo a integração de diversos dispositivos de controle e monitoramento. No desenvolvimento do DDA inteligente, foi incluído na prova de conceito os dispositivos Pitaco e Oxímetro. O I Blue It 5.0 é, portanto, considerado uma plataforma multimodal, pois integra diversas fontes de dados fisiológicos e psíquicos.

9.4 SOBRE A IMPLEMENTAÇÃO

A especificação de requisitos de software foi necessária para integrar o conceito de Flow Psicofisiológico ao JSA I Blue It. Os requisitos e os atributos de qualidade foram elucidados na entrevista semiestruturada com UFEs, sendo necessários para incorporar as técnicas de aprendizado de máquina ao I Blue It. Isso assegura que o *exergame* possa se ajustar dinamicamente às necessidades dos pacientes durante o TMR.

Os requisitos derivaram um dicionário de parâmetros e variáveis para a definição dos modelos matemáticos necessários para conceber a prova de conceito do Flow Psicofisiológico. Para cada conjunto de parâmetros interdependentes, foi proposto um modelo matemático para assegurar que os ajustes de dificuldade sejam realizados adequadamente. Há parâmetros e variáveis que são definidos pelo terapeuta, outros que são definidos internamente no *gameplay* e outros que são biosinais de entrada do paciente.

Os requisitos proporcionam uma estrutura detalhada para a implementação do Flow Psicofisiológico, assegurando que todos os aspectos técnicos e terapêuticos sejam contemplados. Os requisitos asseguram que o JSA I Blue It seja eficaz no TMR, promovendo uma abordagem personalizada e segura para cada paciente. Em resumo, os requisitos delineiam os elementos essenciais para a implementação do conceito de Flow Psicofisiológico no I Blue It, através da integração de biosinais, ajuste dinâmico da dificuldade e *feedback*.

O conceito de Flow Psicofisiológico foi integrado no JSA I Blue It, utilizando a arquitetura Multimodal 123-SGR, o método *Dynamic Difficulty Adjustment* (DDA) e implementado com o aprendizado por reforço com a técnica *Proximal Policy Optimization* (PPO) e Redes Neurais Artificiais (*Artificial Neural Network* - ANN). Sendo assim, o DDA foi potencializado com Aprendizado por Reforço Profundo (*Deep Reinforcement Learning*). Esta implementação resultou em um agente inteligente denominado DeepDDA, que ajusta o nível de dificuldade do *exergame*, com base nos sinais fisiológicos e psíquicos do paciente. O DeepDDA é um mecanismo de ajuste de dificuldade que funciona mediante a análise contínua da função de Desempenho do Jogador (DJ) com variáveis psicofisiológicas, configurado para detectar variações significativas no desempenho.

O diferencial do DeepDDA, além de não requerer treinamento com extensa quantidade de dados de usuário, é o fato de lidar tanto com dados de interação quanto dados de percepção de usuário (Escala de Borg) sendo que não se conhece na literatura relato de JS que tenha lidado com ambos os tipos de dados.

O módulo preditivo de *setup* do *exergame* auxilia os terapeutas com recomendação de parâmetros de um *setup* inicial com base na capacidade do paciente. Esses ajustes são baseados nos desempenhos históricos dos pacientes com perfis similares, visando que o tratamento seja adequado às necessidades específicas do novo paciente.

O impacto do Flow Psicofisiológico está na viabilidade de integrar tecnologias de inteligência artificial em um contexto terapêutico, oferecendo uma abordagem personalizada e adaptativa para a reabilitação. Além disso, a implementação do Flow Psicofisiológico propõe que o equilíbrio entre as três dimensões. No contexto do I Blue It, atua como um sistema cognitivo que aprende com cada interação do paciente. A capacidade de ajustar dinamicamente a dificuldade do jogo garante que os pacientes estejam constantemente desafiados de maneira apropriada, evitando tanto a frustração quanto o tédio, tanto fadiga quanto marasmo e também equilibrando objetivo sério e diversão (ver Figura 9). O DeepDDA foi implementado de maneira a garantir que a experiência de jogo seja personalizada e evolua conforme o progresso do paciente (Apêndice E).

9.5 SOBRE A TESTAGEM DO FLOW PSICOFISIOLOGICO

Dez profissionais UFEs foram entrevistados para definir os requisitos e três verificaram as implementações dos requisitos, contribuindo com observações e sugestões para aprimorar o sistema. A principal ressalva apresentada envolveu a ordem do ajuste de dificuldade durante uma sessão. Foi sugerido que o ajuste de velocidade poderia ser utilizado para promover o engajamento do paciente, uma vez que a cadência da velocidade do fluxo respiratório pode induzir um treinamento de resistência. A cadência e a velocidade dos movimentos em exercícios de terapias sem uso de *exergames* são impostas pelo próprio paciente, não se aplica um protocolo específico para este caso, pois depende diretamente do ritmo que o paciente consegue executar. Logo, o algoritmo DDA foi ajustado para tratar a velocidade

primeiro e dentro da sessão para promover um desafio onde o DDA conduz ao equilíbrio psicofisiológico com base na capacidade do paciente.

Foi destacado que o objetivo principal da TMR é o treinamento de força, onde a carga é a principal variável. A orientação neste contexto é que não se deve ajustar a carga dentro de uma sessão, considerando o ajuste deve ser feito entre sessões, com a avaliação de Escala de Borg pelo paciente e a validação pelo terapeuta. Isso garante que o treinamento de força seja conduzido de maneira mais controlada. Essas contribuições foram importantes para refinar a abordagem do DDA e assegurar que a ferramenta atendesse aos objetivos terapêuticos específicos da reabilitação respiratória.

Além das sugestões sobre o ajuste de dificuldade de velocidade e carga, os especialistas verificaram os requisitos do agente DeepDDA na adaptação do nível de dificuldade do *exergame* em tempo real, com base nos sinais fisiológicos e psíquicos dos pacientes. A capacidade do sistema de monitorar e responder às condições individuais dos pacientes foi reconhecida como um avanço significativo na personalização dos tratamentos de reabilitação com apoio de tecnologias.

Após os ajustes sugeridos, para assegurar a robustez do DeepDDA, foi realizado um conjunto de testes organizados em quatro níveis distintos. Esses níveis de testes aplicados na versão Flow Psicofisiológico do I Blue It foram selecionados para avaliar a funcionalidade através das técnicas de caixa branca e caixa preta. Cada nível de teste foi escolhido com um propósito específico para garantir a adequação do agente DeepDDA.

A técnica de caixa branca foi adotada para realizar uma verificação dos códigos das funções e comandos internos do *exergame*, proporcionando uma análise detalhada do código-fonte do DeepDDA. Aqui foram executados Testes de Unidade e Testes de Integração. O objetivo desses testes foi de avaliar o aprendizado por reforço do agente DeepDDA, assegurando que todas as funcionalidades implementadas funcionassem conforme o especificado. Estes tipos de testes verificam se o agente DeepDDA ajusta corretamente os níveis de dificuldade no JSA I Blue It com base nas respostas dos usuários e nos dados coletados.

Nos testes de caixa preta, foram detalhados os casos de testes, os requisitos funcionais validados e a perspectiva do usuário final, buscando garantir uma experiência consistente e satisfatória para os usuários. Aqui foram executados os Testes Funcionais e Testes de Sistema. Essa abordagem garantiu que todas as

operações internas estejam corretas e que o fluxo de execução atenda aos requisitos estabelecidos.

A testagem do Flow Psicofisiológico no I Blue It foi, portanto, um processo detalhado, assegurando que todas as funcionalidades do agente DeepDDA e a experiência do usuário fossem adequadamente testadas e refinadas. Através da colaboração dos especialistas e da aplicação de uma metodologia de testes, foi possível garantir que o I Blue It atenda aos objetivos terapêuticos e tenha capacidade de oferecer uma experiência de TMR segura e eficaz.

9.6 SOBRE AS CONTRIBUIÇÕES DO FLOW PSICOFISIOLOGICO

O desenvolvimento e a implementação do conceito de Flow Psicofisiológico no JSA I Blue It proporcionaram contribuições do ponto de vista científico, técnico e terapêutico.

Do ponto de vista científico, o conceito de Flow Psicofisiológico proposto nesta tese representa uma inovação na implementação de JSA para reabilitação. A principal contribuição científica é o conceito Flow Psicofisiológico e a filosofia de Game Design na busca do equilíbrio das dimensões do Flow Psíquico, com o Flow Fisiológico e com o Nível de Dificuldade, potencializando que os pacientes se mantenham engajados, motivados e entretidos, tanto mental quanto fisicamente.

Do ponto de vista técnico, a implementação de uma solução de IA para realizar a definição e recomendação de parâmetros de *setup* de jogo baseado em perfis similares ao do paciente e a solução de IA do projeto do DeepDDA com os modelos matemático para a implementação do Flow Psicofisiológico são contribuições tecnológicas que foram aplicadas em uma prova de conceito em um contexto terapêutico. A arquitetura multimodal 123-SGR mostrou-se eficaz na captura e análise de sinais fisiológicos e psíquicos, permitindo que os sinais fossem utilizados pelo módulo DeepDDA. Outra contribuição foi a demonstração da viabilidade de utilizar técnicas de aprendizado por reforço profundo com o PPO para o desenvolvimento do módulo DeepDDA. Isso garantiu um treinamento do agente de modo que os exercícios fossem seguros e adaptados às necessidades do paciente.

Do ponto de vista terapêutico, a personalização e a adaptação contínua do *exergame* às necessidades individuais dos pacientes, potencializada que cada paciente receba uma terapia adaptada às suas condições específicas de saúde,

contribuindo para o engajamento nos exercícios. A capacidade do sistema de ajustar dinamicamente a dificuldade do jogo, como a variação de velocidade dos objetos desempenha mais um papel lúdico psíquico do que terapêutico, e junto com a mecânica e cenário do jogo, contribuem para alcançar aspectos de diversão e a motivação dos pacientes ao longo do tratamento. A progressão ou regressão de carga entre sessões conduzida pelo desempenho psicofisiológico e por indicação do paciente de intensidade de esforço pela Escala de Borg em um JSA, são contribuições inovadoras para área da fisioterapia.

10 CONCLUSÃO

O equilíbrio do jogo entre diversão, fisioterapia e desempenho é um desafio pois, manter os pacientes engajados, motivados e aderentes às sessões de fisioterapia enquanto se atingem os objetivos terapêuticos é decisivo para o sucesso dos tratamentos. Este estudo propôs o conceito Flow Psicofisiológico em jogos digitais aplicados à reabilitação, uma metodologia capaz de promover o equilíbrio entre os estados psíquicos e fisiológicos dos pacientes. Este conceito visa harmonizar a percepção de esforço (nível de dificuldade) com o equilíbrio entre desempenho terapêutico e desempenho psíquico do paciente, criando um estado de motivação com elementos lúdicos em jogos sérios ativos, proporcionando uma experiência terapêutica mais eficaz e envolvente. A Tabela 10 resume a solução utilizada para alcançar o equilíbrio do jogo, combinando a metodologia, os métodos, as técnicas e as tecnologias, delineando uma solução com conceito Flow Psicofisiológico em Jogos Sérios Ativos (*Serious Exergames*).

Tabela 10 - Abordagem do Flow Psicofisiológico

Metodologia	Flow Psicofisiológico	
Método	<i>Exergame</i>	RL DDA
Técnica	<i>Exergame</i> Multimodal	PPO ANN
Tecnologia	Unity C# Python	ML-Agents TensorFlow Pytorch

Fonte: Elaborada pelo autor (2024).

Na revisão da literatura, identificou-se, no MSL seguido de RSL, 10 artigos relevantes sobre IA aplicada em jogos digitais para reabilitação. Observou-se que poucos trabalhos ajustam o nível de dificuldade dos exercícios terapêuticos com base nas condições de saúde do paciente (física e psíquica), com foco principalmente no uso de IA. O que é comum são ajustes parametrizados, analíticos e apenas de variáveis de desempenho no jogo, como pontuação. Constatou-se uma lacuna no uso da IA antes do jogo para recomendação de parâmetros iniciais do *exergame*,

utilizando da base de dados de pacientes similares aos dados de um novo paciente. Ainda, uma lacuna durante o jogo, com o ajuste dinâmico de dificuldade dos exercícios terapêuticos para promover desafios compatíveis ao quadro clínico do paciente. Para confirmar os resultados do MSL e RSL, foi realizada uma revisão da literatura não estruturada sobre o uso de DDA. Identificou-se 11 artigos relevantes, a maioria dos trabalhos com DDA enfatizam o ajuste de dificuldade para reabilitação motora, mas não trataram de forma integrada as condições psíquicas e fisiológicas do paciente.

O Flow Psicofisiológico foi alcançado com a prova de conceito de um agente inteligente intitulado DeepDDA, que utiliza Aprendizado por Reforço e PPO com duas ANNs, uma rede de política e uma rede de valor, para implementar o DDA. Foram utilizadas tecnologias como ML-Agents, TensorFlow e Unity. O DeepDDA foi implementado com base nos sinais fisiológicos e psíquicos do paciente, permitindo ajuste dinâmico de dificuldade dos exercícios terapêuticos.

A prova de conceito foi aplicada no *Serious Exergame* I Blue It Multimodal, tornando-o aderente ao conceito de Flow Psicofisiológico. Nas avaliações com UFEs, o agente DeepDDA ajustou dinamicamente a dificuldade dos exercícios, garantindo um equilíbrio entre diversão e eficácia terapêutica. A verificação da prova de conceito sugere que a aplicação do Flow Psicofisiológico pode ser uma estratégia eficaz para melhorar a aderência e os resultados dos programas de reabilitação, oferecendo uma alternativa inovadora e personalizada para a terapia.

Resumo dos Principais Resultados:

R1. Foi publicado um Artigo de Revisão da Literatura sobre uso da Inteligência Artificial em Jogos Digitais aplicados à Reabilitação (Dias *et al.*, 2020);

R2. Foi publicado um Artigo sobre Arquitetura Multimodal para *Serious Exergames* aplicados à Reabilitação (Dias *et al.*, 2023);

R3. Foi efetuado um levantamento de Requisitos para Desenvolvimento de *Serious Exergames* para TMR (seção 5.4);

R4. Foi desenvolvido um *Serious Exergames* para TMR adaptável por dados fisiológicos, desempenho no jogo e percepção do esforço do jogador (Capítulo 5 e Apêndice E).

Principais Contribuições:

C1. Foi concebido um modelo estendido de *Flow* contemplando aspectos psíquicos e fisiológicos para *Serious Exergames* (

Figura 9);

C2. Foi desenvolvida uma solução de Inteligência Artificial para personalização do *setup* de uso do *exergame* (seção 5.5);

C3. Foi desenvolvida uma solução de Inteligência Artificial para gerenciar, decidir e agir sobre Flow Psicofisiológico com os modelos matemáticos para DDA (seção 5.6).

Os *exergames* estão ficando cada vez mais presente na reabilitação motora, em especial a reabilitação respiratória, devido à necessidade de adaptar o Flow para esta nova realidade. Com base nos resultados desta tese, que demonstraram a integração do conceito Flow Psicofisiológico com Inteligência Artificial no JSA I Blue It para reabilitação respiratória, espera-se maior suporte para desenvolvimento de *exergames* para reabilitação que proporcionem terapias personalizadas divertidas, adaptativas e engajadoras.

Uma das principais limitações deste estudo foi a utilização de dados simulados, baseados na respiração de um único indivíduo hígido, para o treinamento desta primeira versão do modelo DeepDDA. Esta abordagem, embora válida para uma prova de conceito, não captura a variabilidade e a complexidade dos dados respiratórios de diferentes pacientes, especialmente aqueles com distúrbios respiratórios. A falta de dados reais e variados limita a generalização e a aplicabilidade do modelo em cenários clínicos diversificados.

10.1 TRABALHOS FUTUROS

Na seção, são discutidas as possibilidades de melhoramentos e desdobramentos do conceito de Flow Psicofisiológico.

10.1.1 Melhoramentos

A seguir, são apresentadas algumas melhorias pontuais, mas relevantes:

“*Desenvolvimento de uma nova versão do I Blue It com análise de dados longitudinal.*” Um estudo que utilize a análise de dados ao longo de um significativo

período ajudaria a personalizar o *exergame* de acordo com o histórico de desempenho e progresso dos pacientes com uso de técnicas de *Big Data* e análise preditiva para otimizar os resultados terapêuticos.

“Desenvolvimento de uma nova versão do I Blue It com tele fisioterapia.” A necessidade de fornecer reabilitação respiratória acessível, especialmente para pacientes com dificuldades de locomoção ou em tempos de pandemia. A reabilitação remota pode aumentar significativamente o alcance e a adesão dos pacientes aos programas de reabilitação.

“Expansão da aplicação do conceito do Flow Psicofisiológico para outras áreas da saúde.” O Flow Psicofisiológico tem potencial de uso em reabilitação respiratória, mas outras áreas da saúde, como reabilitação neurológica, cardiovascular e ortopédica, também enfrentam desafios significativos relacionados à adesão e eficácia dos tratamentos.

“Investigar o comportamento da IA com o conceito do Flow Psicofisiológico para outras áreas da saúde.” Investigar quais adaptações são necessárias para cada área específica e como técnicas de inteligência artificial podem ser integradas para personalizar ainda mais os tratamentos baseados nas necessidades individuais dos pacientes.

“Avaliar a interface de configuração terapêutica para identificar a clareza e utilidade efetiva dos parâmetros definidos.” Existe uma significativa quantidade de parâmetros que governam o funcionamento do jogo e do DeepDDA e estes devem ser refinados num processo usualmente denominado de balanceamento do jogo. Para isto ser feito é necessário que vários indivíduos usem o jogo sob supervisão de um *game designer*.

10.1.2 Desdobramentos

A seguir, são apresentados alguns desdobramentos de novas pesquisas:

“Realização de Treinamentos do agente DeepDDA com abordagem Data-driven Deep Reinforcement Learning com dados de pacientes com distúrbios restritivos, obstrutivos e mistos.” A necessidade de interagir continuamente com o ambiente para coletar dados suficientes para treinar o modelo resulta em um processo intensivo de tempo e recursos, limitando a escalabilidade e a aplicação prática em muitos cenários. No entanto, a abordagem *Data-driven Deep Reinforcement Learning*

pode mitigar alguns desses desafios ao utilizar grandes volumes de dados históricos e simulados, especialmente no contexto de pacientes com distúrbios restritivos, obstrutivos e mistos. Ao treinar modelos com esses dados pré-coletados, é possível desenvolver políticas e estratégias mais robustas sem a necessidade de interação contínua com o ambiente, buscando maneiras de coletar e utilizar dados e reaproveitar *big datasets* de interações passadas, histórico de pacientes (*offline*). Essa técnica permite uma melhor generalização e aplicação prática em cenários clínicos, otimizando o uso de recursos e tempo.

“Análise do impacto do Flow Psicofisiológico no engajamento e na motivação dos pacientes durante a terapia.” A implementação do conceito de Flow Psicofisiológico no I Blue It necessita de uma avaliação detalhada para verificar quais os benefícios terapêuticos comparados aos métodos tradicionais. O principal questionamento é como o uso do DDA afeta o engajamento, diversão e motivação dos pacientes durante a terapia. Sugere-se realizar um estudo clínico para correlacionar as medidas obtidas pelo I Blue It com instrumentos convencionais de avaliação da função respiratória e do progresso terapêutico.

“Estudo para a realização de avaliações efetivas de uso envolvendo pacientes pneumopatas e/ou cardíacos.” Essas avaliações podem fornecer a perspectiva dos terapeutas e dos pacientes, mas é necessário obter a aprovação do Comitê de Ética em Pesquisa com Seres Humanos (CEPSH). É importante definir um protocolo de estudo e fazer um desenho da pesquisa em conjunto com os terapeutas, avaliando qual população se beneficiaria mais do tratamento, qual tipo de estudo seria mais adequado, quais instrumentos, critérios, riscos, benefícios, entre outros elementos relevantes.

REFERÊNCIAS

- AGGARWAL, Charu C. **Neural Networks and Deep Learning**. Cham: Springer International Publishing, 2018. DOI 10.1007/978-3-319-94463-0. Disponível em: <http://link.springer.com/10.1007/978-3-319-94463-0>. Acesso em: 20 jun. 2022
- AGUILAR, J. Guirao; BELLIKA, J. G.; FERNANDEZ LUQUE, L.; TRAVER SALCEDO, V. Respiration tracking using the Wii remote game controller. **Studies in Health Technology and Informatics**, vol. 169, p. 455–459, 2011. DOI. <https://doi.org/10.3233/978-1-60750-806-9-455>.
- AGUILAR, Jonathan David; GUZMÁN, Diego Enrique; RENGIFO, Carlos Felipe; CHALAPUD, Luz Marina; GUZMÁN, Juan David. Proposal of a Game with Dynamic Difficulty Adjustment from Physiological Signals in the Context of an Exergame. 2022. **Proceedings of the 2022 IEEE 40th Central America and Panama Convention, CONCAPAN 2022** [...]. [S. l.]: Institute of Electrical and Electronics Engineers Inc., 2022. DOI. <https://doi.org/10.1109/CONCAPAN48024.2022.9997775>.
- ANDRADE, Kleber De O.; PASQUAL, Thales B.; CAURIN, Glauco A.P.; CROCOMO, Marcio K. Dynamic difficulty adjustment with Evolutionary Algorithm in games for rehabilitation robotics. **IEEE International Conference on Serious Games and Applications for Health, SeGAH**, 2016. DOI. doi.org/10.1109/SeGAH.2016.7586277
- AZIZ HUTAMA, Bukhori Abdul; SIHWI, Sari Widya; SALAMAH, Umi. Kinect Based Therapy Games to Overcome Misperception in People with Dysgraphia Using Dynamic Difficulty Adjustment. 2021. **2021 IEEE International Conference on Computing, ICOCO 2021** [...]. [S. l.]: Institute of Electrical and Electronics Engineers Inc., 2021. p. 230–235. DOI. <https://doi.org/10.1109/ICOCO53166.2021.9673556>.
- BALLI, Fabio. Developing Digital Games to Address Airway Clearance Therapy in Children With Cystic Fibrosis: Participatory Design Process. **JMIR Serious Games**, vol. 6, nº 4, p. e18, 2018. DOI. <https://doi.org/10.2196/games.8964>.
- BARBOSA, Simone Diniz Junqueira; SILVA, Bruno Santana. **Interação Humano-Computador**. Rio de Janeiro, Elsevier, 2010.
- BINGHAM, Peter M.; LAHIRI, Thomas; ASHIKAGA, Taka. Pilot trial of spirometer games for airway clearance practice in cystic fibrosis. **Respiratory Care**, vol. 57, nº 8, p. 1278–1284, 2012. DOI. <https://doi.org/10.4187/respcare.01263>.
- BUCHINGER, Diego; ANDRIOLLI, Gustavo de Siqueira Cavalcanti; HOUNSELL, Marcelo da Silva. Mecanismos de busca acadêmica: uma análise quantitativa. **Revista Brasileira de Computação Aplicada**, Passo Fundo, p. 108–120, abr. 2014. DOI. <https://doi.org/https://doi.org/10.5335/rbca.2014.3452>.
- BUTLER, Stacey J.; LEE, Annemarie L.; GOLDSTEIN, Roger S.; BROOKS, Dina. Active Video Games as a Training Tool for Individuals With Chronic Respiratory Diseases: A SYSTEMATIC REVIEW. **Journal of Cardiopulmonary Rehabilitation**

and Prevention, vol. 39, n° 2, p. 85–90, 2019. DOI.
<https://doi.org/10.1097/HCR.0000000000000320>.

CAMPOS, Natália Evangelista; HEINZMANN-FILHO, João Paulo; BECKER, Nicolas Acosta; SCHIWE, Daniele; GHELLER, Mailise Fatima; DE ALMEIDA, Ingrid Silveira; DONADIO, Márcio Vinícius Fagundes. Evaluation of the exercise intensity generated by active video gaming in patients with cystic fibrosis and healthy individuals. **Journal of Cystic Fibrosis**, p. 1–8, 2020. DOI.
<https://doi.org/10.1016/j.jcf.2020.01.001>.

CARBONERA, Raquel Pinto; VENDRUSCULO, Fernanda Maria; DONADIO, Márcio Vinícius Fagundes. Physiological responses during exercise with video games in patients with cystic fibrosis: A systematic review. **Respiratory Medicine**, vol. 119, p. 63–69, 2016. DOI. <https://doi.org/10.1016/j.rmed.2016.08.011>.

CHACON, P. F.S.; SCHON, C. F.; FURTADO, V. H.L.A.V.; SIGNORETTI, G. L.A.M.; OLIVEIRA, J. P.P.; RIBEIRO, A. G.; WANDERLEY, C. D.V.; DINIZ, A. A.R.; SOARES, H. B.V. Support and rehabilitation of patients with pulmonary expansion deficit by using game therapy. **Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS**, vol. 2016-October, p. 5632–5635, 2016. DOI.
<https://doi.org/10.1109/EMBC.2016.7592004>.

CHEN, Ching-Yi; LIU, Che-Chun; CHANG, Ya-Ling; WANG, Chih-Yuan. A Biofeedback Portable System for Panic Disorder. **International Conference on Electronics and Information Engineering**, 2010.

CHEN, Jenova. Flow in Games - CACM. **Viewpoint**, vol. 50, n° 4, p. 31–34, 2007.

CLERICO, Andrea; CHAMBERLAND, Cindy; PARENT, Mark; MICHON, Pierre Emmanuel; TREMBLAY, Sebastien; FALK, Tiago H.; GAGNON, Jean Christophe; JACKSON, Philip. Biometrics and classifier fusion to predict the fun-factor in video gaming. **IEEE Conference on Computational Intelligence and Games, CIG**, vol. 0, 2016. DOI. <https://doi.org/10.1109/CIG.2016.7860418>.

CORREA, Omar; CUERVO, Celso; PEREZ, Pedro C.; ARIAS, Alejandro. A new approach for self adaptive video game for rehabilitation. Experiences in the Amblyopia treatment. **SeGAH 2014 - IEEE 3rd International Conference on Serious Games and Applications for Health, Books of Proceedings**, 2014. DOI.
<https://doi.org/10.1109/SeGAH.2014.7067102>.

COSTA, Taisa Daiana da; DE FATIMA FERNANDES VARA, Maria; SANTOS CRISTINO, Camila; ZORASKI ZANELLA, Tyene; NUNES NOGUEIRA NETO, Guilherme; NOHAMA, Percy. Breathing Monitoring and Pattern Recognition with Wearable Sensors. **Wearable Devices - the Big Wave of Innovation**. IntechOpen, 2019. vol. i, p. 13. DOI. <https://doi.org/10.5772/intechopen.85460>.

CRUZ, Christian Arzate; URESTI, Jorge Adolfo Ramirez. Player-centered game AI from a flow perspective: Towards a better understanding of past trends and future

directions. **Entertainment Computing**, vol. 20, p. 11–24, 2017. DOI. <https://doi.org/10.1016/j.entcom.2017.02.003>.

CSIKSZENTMIHALYI, Mihaly. **Flow: The Psychology of Optimal Experience**. 1990. vol. 16. DOI. <https://doi.org/10.5465/amr.1991.4279513>.

DEL CORRAL, Tamara; CEBRIÀ IRANZO, Maria Àngels; LÓPEZ-DE-URALDE-VILLANUEVA, Ibai; MARTÍNEZ-ALEJOS, Roberto; BLANCO, Isabel; VILARÓ, Jordi. Effectiveness of a home-based active video game programme in young cystic fibrosis patients. **Respiration**, vol. 95, nº 2, p. 87–97, 2018. DOI. <https://doi.org/10.1159/000481264>.

DEL CORRAL, Tamara; PERCEGONA, Janaína; SEBORGA, Melisa; RABINOVICH, Roberto A.; VILARÓ, Jordi. Physiological response during activity programs using Wii-based video games in patients with cystic fibrosis (CF). **Journal of Cystic Fibrosis**, vol. 13, nº 6, p. 706–711, 2014. DOI. <https://doi.org/10.1016/j.jcf.2014.05.004>.

DIAS, Claudinei; NERY, Jhonatan Thallisson Cabral; HOUNSELL, Marcelo da Silva; LEAL, André Bittencourt. A Multimodal Software Architecture for Serious Exergames and Its Use in Respiratory Rehabilitation. **Sensors**, vol. 23, nº 21, p. 8870, 31 out. 2023. DOI. <https://doi.org/10.3390/s23218870>.

DIAS, Claudinei; HOUNSELL, M. da Silva; LEAL, André Bittencourt; ROMAGNO, Amilto; SOMA, SETO, Rodrigo Yuji; ENGLEITNER, Matheus; TONDORF, Diego Fellipe. Uso da Inteligência Artificial em Jogos Digitais aplicados à Reabilitação Respiratória: um mapeamento sistemático da literatura. **SBC Proceedings of SBGames**. Recife, PE. Brazil: SBC Proceedings of SBGames, Games and Health, 2020. p. 10.

DJAOUTI, Damien; ALVAREZ, Julian; JESSEL, Jean-Pierre; RAMPNOUX, Olivier. Origins of Serious Games. **Serious Games and Edutainment Applications**, p. 25–43, 2011. DOI. https://doi.org/10.1007/978-1-4471-2161-9_3.

ERTEL, Wolfgang. **Introduction to Artificial Intelligence**. Cham: Springer International Publishing, 2017 (Undergraduate Topics in Computer Science). DOI. <https://doi.org/10.1007/978-3-319-58487-4>.

FARIAS, Emanuel Henrique; OLIVEIRA, Helder Cognaco de; HOUNSELL, Marcelo da Silva; ROSSITO, Gabriel Mesquita. MOLDE – a Methodology for Serious Games Measure-Oriented Level DEsign. **XIII Simpósio Brasileiro de Jogos e Entretenimento Digital**, p. 29–38, 2014.

FERNANDES, Alba Barros Souza. Reabilitação respiratória em DPOC – a importância da abordagem fisioterapêutica. **Pulmão RJ - Atualizações Temáticas**, vol. 1, nº 1, p. 71–78, 2009.

FERNANDES, Antonio Carlos; RAMOS, Alice Conceição Rosa; MORAIS FILHO, Mauro César; ARES, Marcelo de Jesus Justino. **Reabilitação**. 2º ed. Barueri, SP, 2015.

FLASCHEN, John Hansen; BATES, David V. Respiratory disease. 2019. **Encyclopedia Britannica**. Disponível em: <https://www.britannica.com/science/respiratory-disease>. Acessado em: 1 abr. 2021.

GOMES, Evelim L.F.D.; CARVALHO, Celso R.F.; PEIXOTO-SOUZA, Fabiana Sobral; TEIXEIRA-CARVALHO, Etienne Farah; MENDONÇA, Juliana Fernandes Barreto; STIRBULOV, Roberto; SAMPAIO, Luciana Maria Malosá; COSTA, Dirceu. Active video game exercise training improves the clinical control of asthma in children: Randomized controlled trial. **PLoS ONE**, vol. 10, nº 8, p. 1–11, 2015. DOI. <https://doi.org/10.1371/journal.pone.0135433>.

GRIMES, Renato Hartmann; SANTOS, Adam Mews dos; HOUNSELL, Marcelo da Silva. O Processo de Design de um Sistema Biomédico com Jogo Sério e Dispositivo Especial para Reabilitação Respiratória. **XVII SBGames, Simpósio Brasileiro de Games e Entretenimento Digital**, p. 215–224, 2018.

HAGELBÄCK, Johan; JOHANSSON, Stefan J. Measuring player experience on runtime dynamic difficulty scaling in an RTS game. **CIG2009 - 2009 IEEE Symposium on Computational Intelligence and Games**, p. 46–52, 2009. DOI. <https://doi.org/10.1109/CIG.2009.5286494>.

HENRIQUE, Yuri Andreas May; NÉRY, Jhonatan Thallisson Cabral; HOUNSELL, Marcelo Silva. Desenvolvimento de Dispositivo Híbrido para Jogo Sério Aplicado a Saúde. **XVIII SBGames, Simpósio Brasileiro de Games e Entretenimento Digital**, p. 102–110, 2019.

HOLMES, Hayley; WOOD, Jamie; JENKINS, Sue; WINSHIP, Peta; LUNT, Dianne; BOSTOCK, Susan; HILL, Kylie. Xbox Kinect™ represents high intensity exercise for adults with cystic fibrosis. **Journal of Cystic Fibrosis**, vol. 12, nº 6, p. 604–608, 2013. DOI. <https://doi.org/10.1016/j.jcf.2013.05.005>.

HOUNSELL, M. da S. **Abordagens da ludificação digital no ensino**. In: MANOEL OSMAR SEABRA JUNIOR; MARIA LUIZA SALZANI FIORINI; GISELE SILVA ARAÚJO; JANIELE DE SOUZA SANTOS UCHELLI; ANA PAULA DONATAN RIBERIRO (orgs.). **Jogos Digitais e Analógicos como Tecnologia Assistiva na Educação Especial: modelos didático-metodológicos**. 1º ed. Goiania: SOBAMA, 2024. vol. 1, p. 62–82.

HUYGELIER, Hanne; GILBERT, Céline R.; VAN EE, Raymond; VANDEN ABEELE, Vero. The design of a virtual reality game for stroke-induced attention deficits. **CHI PLAY 2017 Extended Abstracts - Extended Abstracts Publication of the Annual Symposium on Computer-Human Interaction in Play**, p. 223–230, 2017. DOI. <https://doi.org/10.1145/3130859.3131308>.

JENSEN, Mark P.; KAROLY, Paul; BRAVER, Sanford. The measurement of clinical pain intensity: a comparison of six methods. **Pain**, vol. 27, nº 1, p. 117–126, out. 1986. DOI. [https://doi.org/10.1016/0304-3959\(86\)90228-9](https://doi.org/10.1016/0304-3959(86)90228-9).

JOO, Sunghee; LEE, Kyeongjin; SONG, Changho. A comparative study of smartphone game with spirometry for pulmonary function assessment in stroke patients. **BioMed Research International**, vol. 2018, 2018. DOI. <https://doi.org/10.1155/2018/2439312>.

JOO, Sunghee; SHIN, Doochul; SONG, Changho. The effects of game-based breathing exercise on pulmonary function in stroke patients: A preliminary study. **Medical Science Monitor**, vol. 21, p. 1806–1811, 2015. DOI. <https://doi.org/10.12659/MSM.893420>.

KITCHENHAM, Barbara; PEARL BRERETON, O.; BUDGEN, David; TURNER, Mark; BAILEY, John; LINKMAN, Stephen. Systematic literature reviews in software engineering - A systematic literature review. **Information and Software Technology**, vol. 51, n° 1, p. 7–15, 2009. DOI. <https://doi.org/10.1016/j.infsof.2008.09.009>.

KOSTKOVA, Katarina; BEN ITZHAK, Nofar; STIJNEN, Lieselot; ORTIBUS, Els; JANSEN, Bart. Dynamic Difficulty Adjustment in Serious Games for Cerebral Visual Impairment. 2023. **2023 IEEE 11th International Conference on Serious Games and Applications for Health, SeGAH 2023**: Institute of Electrical and Electronics Engineers Inc., 2023. DOI. <https://doi.org/10.1109/SeGAH57547.2023.10253769>.

KOTOVA, Marketa; KORVAS, Pavel. Playing computer games for isolated breathing therapy. **IECBES 2016 - IEEE-EMBS Conference on Biomedical Engineering and Sciences**, p. 175–180, 2016. DOI. <https://doi.org/10.1109/IECBES.2016.7843438>.

KUMAR, Aviral; FU, Justin; TUCKER, George; LEVINE, Sergey. **Stabilizing Off-Policy Q-Learning via Bootstrapping Error Reduction**. **Conference on Neural Information Processing Systems**, p. 1–19, 2019. Disponível em: <http://arxiv.org/abs/1906.00949>.

KUMAR, S.; KUMAR, Saket; TIWARI, P. M.; VIRAL, Rajkumar. Smart Safety Monitoring System for Sewage Workers with Two Way Communication. **2019 6th International Conference on Signal Processing and Integrated Networks, SPIN 2019**, vol. 70, p. 617–622, 2019. DOI. <https://doi.org/10.1109/SPIN.2019.8711628>.

KUNCHEVA, Ludmila I. **Combining Pattern Classifiers: methods and algorithms**. John Wiley & Sons, Inc., Hoboken, New Jersey: John Wiley & Sons, 2004. DOI. <https://doi.org/10.1002/9781118111111.ch1>.

KUYS, Suzanne S.; HALL, Kathleen; PEASEY, Maureen; WOOD, Michelle; COBB, Robyn; BELL, Scott C. Gaming console exercise and cycle or treadmill exercise provide similar cardiovascular demand in adults with cystic fibrosis: a randomised cross-over trial. **Journal of Physiotherapy**, vol. 57, n° 1, p. 35–40, 2011. DOI. [https://doi.org/10.1016/S1836-9553\(11\)70005-4](https://doi.org/10.1016/S1836-9553(11)70005-4).

LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning. **Nature**, vol. 521, n° 7553, p. 436–444, 27 maio 2015. DOI. <https://doi.org/10.1038/nature14539>.

LEGEAR, Tyler; LEGEAR, Mark; PRERADOVIC, Dejan; WILSON, Geoffrey; KIRKHAM, Ashley; CAMP, Pat G. Does a Nintendo Wii exercise program provide similar exercise demands as a traditional pulmonary rehabilitation program in adults with COPD? **Clinical Respiratory Journal**, vol. 10, nº 3, p. 303–310, 2016. DOI. <https://doi.org/10.1111/crj.12216>.

LEVINE, Stephanie; MARCINIUK, Darcy; AGLAN, Amro; CELEDÓN, Juan C; FONG, Kwun; HORSBURGH, Robert; MALHOTRA, Atul; MASEKELA, Refiloe; MORTIMER, Kevin; REDDE, Hellen; RICE, Mary; SIMONDS, Anita. **The Global Impact of Respiratory Disease**. Third Edition. 22 jul. 2021.

LIANG, Rong Hao; YU, Bin; XUE, Mengru; HU, Jun; FEIJS, Loe M.G. Biofidget demo: Biofeedback for respiration training using an augmented fidget spinner. **Conference on Human Factors in Computing Systems - Proceedings**, vol. 2018-April, p. 1–12, 2018. DOI. <https://doi.org/10.1145/3170427.3186523>.

LOPES, Vanessa; MAGALHÃES, João; CAVACO, Sofia. A dynamic difficulty adjustment model for dysphonia therapy games. **VISIGRAPP 2019 - Proceedings of the 14th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications**, vol. 2, nº Visigrapp, p. 137–144, 2019. DOI. <https://doi.org/10.5220/0007402901370144>.

LUGER, George F. **Inteligência Artificial**. 6. ed. São Paulo, Pearson Education do Brasil. 2013.

MACHADO, Maria da Glória Rodrigues. **Bases da Fisioterapia Respiratória: terapia intensiva**. 2º ed. Rio de Janeiro: Guanabara Koogan, 2018.

MARTINEZ, Martin D.; CASASECA DE LA HIGUERA, P.; MARTIN FERNANDEZ, M.; ALBEROLA LOPEZ, C. Probabilistic modeling of the oxygen saturation pattern for the detection of anomalies during clinical interventions. **Computing in Cardiology**, vol. 40, nº 1, p. 213–216, 2013.

MASSIMINI, Fausto; CARLI, Massimo. The systematic assessment of flow in daily experience. **Optimal Experience**. Cambridge University Press, 1988. p. 266–287. DOI. <https://doi.org/10.1017/CBO9780511621956.016>.

MAZZOLENI, Stefano; MONTAGNANI, Giulia; VAGHEGGINI, Guido; BUONO, Lorenzo; MORETTI, Francesca; DARIO, Paolo; AMBROSINO, Nicolino. Interactive videogame as rehabilitation tool of patients with chronic respiratory diseases: Preliminary results of a feasibility study. **Respiratory Medicine**, vol. 108, nº 10, p. 1516–1524, out. 2014. DOI. <https://doi.org/10.1016/j.rmed.2014.07.004>.

MILLINGTON, Ian; FUNGE, John. **Artificial Intelligence For Games**. 2nd ed., 2009. <https://doi.org/10.1017/S0263574700004070>.

MIRANDA, Frederico S; STADZISZ, Paulo C. Jogo Digital: definição do termo. **SBGames**, nº May, p. 296–299, 2017. Disponível em: <https://www.sbgames.org/sbgames2017/papers/ArtesDesignShort/173500.pdf>.

MNIH, Volodymyr; KAVUKCUOGLU, Koray; SILVER, David; RUSU, Andrei A.; VENESS, Joel; BELLEMARE, Marc G.; GRAVES, Alex; RIEDMILLER, Martin; FIDJELAND, Andreas K.; OSTROVSKI, Georg; PETERSEN, Stig; BEATTIE, Charles; SADIK, Amir; ANTONOGLU, Ioannis; KING, Helen; KUMARAN, Dharshan; WIERSTRA, Daan; LEGG, Shane; HASSABIS, Demis. Human-level control through deep reinforcement learning. **Nature**, vol. 518, nº 7540, p. 529–533, 26 fev. 2015. DOI. <https://doi.org/10.1038/nature14236>.

MODESTO, Danielle Ferreira; RODRIGUES, Flávia Contini; SANTANA, Taciane Cristina; BATISTA, Renata de Melo. Procedimento Operacional Padrão Procedimento Operacional: técnica de fisioterapia respiratória em pacientes adultos. **Hospital de Clínicas da Universidade Federal do Triângulo Mineiro - Uberaba: EBSEH – Empresa Brasileira de Serviços Hospitalares**, 2015.

MORET-BONILLO, Vicente; ALVAREZ-ESTÉVEZ, Diego; FERNÁNDEZ-LEAL, Angel; HERNÁNDEZ-PEREIRA, Elena. Intelligent Approach for Analysis of Respiratory Signals and Oxygen Saturation in the Sleep Apnea/Hypopnea Syndrome. **The Open Medical Informatics Journal**, vol. 8, nº 1, p. 1–19, 2014. DOI. <https://doi.org/10.2174/1874431101408010001>.

MSB. Perfil epidemiológico dos óbitos de pessoas não identificadas no Brasil, 2015 a 2021. **Boletim Epidemiológico**, vol. 54, p. 1–20, 2023.

NÁPOLIS, Lara Maris; CHIAVEGATO, Luciana Dias; NASCIMENTO, Oliver. **Série Atualização e Reciclagem em Pneumologia: Fisioterapia Respiratória**. São Paulo, Volume 3: Editora Atheneu, 2011.

NERY, Jhonatan Thallisson Cabral; ANDREAS, Yuri; HENRIQUE, May; HOUNSELL, Silva. 123-SGR: Uma Arquitetura para Jogos Sérios Multimodais para Reabilitação. **SBC Proceedings of SBGames**. Recife, PE. Brazil: SBC Proceedings of SBGames, Games and Health, p. 900–909, 2020.

NOVAK, Domen; MIHELJ, Matjaž; MUNIH, Marko. A survey of methods for data fusion and system adaptation using autonomic nervous system responses in physiological computing. **Interacting with Computers**, vol. 24, nº 3, p. 154–172, maio 2012. DOI. <https://doi.org/10.1016/j.intcom.2012.04.003>.

O'DONOVAN, Cuisle; GREALLY, Peter; CANNY, Gerard; MCNALLY, Paul; HUSSEY, Juliette. Active video games as an exercise tool for children with cystic fibrosis. **Journal of Cystic Fibrosis**, vol. 13, nº 3, p. 341–346, maio 2014. DOI. <https://doi.org/10.1016/j.jcf.2013.10.008>.

OIKONOMOU, Andreas; DAY, David. Using serious games to motivate children with cystic fibrosis to engage with mucus clearance physiotherapy. **Proceedings - 2012 6th International Conference on Complex, Intelligent, and Software Intensive Systems, CISIS 2012**, p. 34–39, 2012. DOI. <https://doi.org/10.1109/CISIS.2012.108>.

PARENT, Andrée Anne; GOSSELIN-BOUCHER, Vincent; HOULE-PELOQUIN, Marilyn; POIRIER, Claude; COMTOIS, Alain Steve. Pilot project: Physiologic responses to a high-intensity active video game with COPD patients—Tools for home

rehabilitation. **Clinical Respiratory Journal**, vol. 12, nº 5, p. 1927–1936, 2018. DOI. <https://doi.org/10.1111/crj.12760>.

PARNANDI, Avinash; AHMED, Beena; SHIPP, Eva; GUTIERREZ-OSUNA, Ricardo. Chill-out: Relaxation training through respiratory biofeedback in a mobile casual game. **Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering, LNICST**, vol. 130, p. 252–260, 2014. DOI. https://doi.org/10.1007/978-3-319-05452-0_18.

PARNANDI, Avinash; GUTIERREZ-OSUNA, Ricardo. Physiological Modalities for Relaxation Skill Transfer in Biofeedback Games. **IEEE Journal of Biomedical and Health Informatics**, vol. 21, nº 2, p. 361–371, 2017. DOI. <https://doi.org/10.1109/JBHI.2015.2511665>.

PEREIRA, Silvana Alves; LAGO, Flavia; MELO, Leana da Silva; MORAN, Cristiane Aparecida; BARONI, Marina Pegoraro. Uso do Nintendo Wii e adaptações cardiorrespiratórias agudas em uma criança com Síndrome de Down: relato de caso. **Simpósio Internacional de Fisioterapia Cardiorrespiratória e Fisioterapia em Terapia Intensiva**, p. 45–50, 2013.

PETERSEN, Kai; FELDT, Robert; MUJTABA, Shahid; MATTSSON, Michael. Systematic Mapping Studies in Software Engineering. p. 1–10, 2007.

PETERSEN, Kai; VAKKALANKA, Sairam; KUZNIARZ, Ludwik. Guidelines for conducting systematic mapping studies in software engineering: An update. **INFORMATION AND SOFTWARE TECHNOLOGY**, vol. 64, p. 1–18, 2015. DOI. <https://doi.org/10.1016/j.infsof.2015.03.007>.

PEZZERA, Manuel; BORGHESE, N. Alberto. Dynamic difficulty adjustment in exer-games for rehabilitation: a mixed approach. **2020 IEEE 8th International Conference on Serious Games and Applications for Health, SeGAH 2020**, 2020. DOI. <https://doi.org/10.1109/SeGAH49190.2020.9201871>.

PEZZERA, Manuel; TIRONI, Alessandro; ESSENZIALE, Jacopo; MAINETTI, Renato; BORGHESE, N. Alberto. Approaches for increasing patient's engagement and motivation in exer-games-based autonomous telerehabilitation. **2019 IEEE 7th International Conference on Serious Games and Applications for Health, SeGAH 2019**, 2019. DOI. <https://doi.org/10.1109/SeGAH.2019.8882468>.

PIROVANO, Michele; MAINETTI, Renato; BAUD-BOVY, Gabriel; LANZI, Pier Luca; BORGHESE, Nunzio Alberto. Self-adaptive games for rehabilitation at home. **2012 IEEE Conference on Computational Intelligence and Games, CIG 2012**, p. 179–186, 2012. DOI. <https://doi.org/10.1109/CIG.2012.6374154>.

RAFIEI MILAJERDI, Homa; SHEIKH, Mahmoud; NAJAFABADI, Mahboubeh Ghayour; SAGHAEI, Behnaz; NAGHDI, Naser; DEWEY, Deborah. The Effects of Physical Activity and Exergaming on Motor Skills and Executive Functions in Children with Autism Spectrum Disorder. **Games for Health Journal**, vol. 10, nº 1, p. 33–42, 1 fev. 2021. DOI. <https://doi.org/10.1089/g4h.2019.0180>.

REGO, Paula; MOREIRA, Pedro Miguel; REIS, Luís Paulo. Serious Games for Rehabilitation: A survey and a classification towards a taxonomy. **Proceedings of the 5th Iberian Conference on Information Systems and Technologies, CISTI 2010**, 2010.

RUSSELL, Stuart J.; NORVIG, Peter. **Artificial Intelligence A Modern Approach**. Third Edit. 2010.

RUTKOWSKI, Sebastian; RUTKOWSKA, Anna; JASTRZĘBSKI, Dariusz; RACHENIUK, Henryk; PAWEŁCZYK, Witold; SZCZEGIELNIAK, Jan. Effect of Virtual Reality-Based Rehabilitation on Physical Fitness in Patients with Chronic Obstructive Pulmonary Disease. **Journal of Human Kinetics**, vol. 69, n° 1, p. 149–157, 18 out. 2019. DOI. <https://doi.org/10.2478/hukin-2019-0022>.

RUTKOWSKI, Sebastian; RUTKOWSKA, Anna; KIPER, Paweł; JASTRZEBSKI, Dariusz; RACHENIUK, Henryk; TUROLLA, Andrea; SZCZEGIELNIAK, Jan; CASABURI, Richard. Virtual reality rehabilitation in patients with chronic obstructive pulmonary disease: A randomized controlled trial. **International Journal of COPD**, vol. 15, p. 117–124, 2020. DOI. <https://doi.org/10.2147/COPD.S223592>.

SALEN, Katie; ZIMMERMAN, Eric. **Regras do jogo: fundamentos do design de jogos**. São Paulo: Blucher. 2012.

SANTOS, Adam Mews dos; HOUNSELL, Marcelo da Silva; NOVELETTO, Fabrício; CATARINA, De Santa; CATARINA, Santa; CATARINA, Santa; CATARINA, Santa. I Blue It: Um Jogo Sério para auxiliar na Reabilitação Respiratória. **XVII SBGames, Simpósio Brasileiro de Games e Entretenimento Digital**, p. 179–188, 2018.

SANTOS, Adam Mews dos; MEZZALIRA, Diogo; CONEJO, Gabriel Guebarra; GASPARI, Isabela; HOUNSELL, Marcelo da Silva. Estendendo Jogos Sérios com a perspectiva de Serviço. p. 1088–1091, 2020.

SARMENTO, George Jerre Vieira. **Fisioterapia respiratória de A a Z**. Barueri, SP: Manole, 2016.

SCHULMAN, John; WOLSKI, Filip; DHARIWAL, Prafulla; RADFORD, Alec; KLIMOV, Oleg. Proximal Policy Optimization Algorithms. **OpenAI Gym**, 19 jul. 2017. Disponível em: <http://arxiv.org/abs/1707.06347>.

SEKHAVAT, Yoonas A.; IRAN, Tabriz. MPRL: Multiple-Periodic Reinforcement Learning for difficulty adjustment in rehabilitation games. **2017 IEEE 5th International Conference on Serious Games and Applications for Health, SeGAH 2017**, 2017. DOI. <https://doi.org/10.1109/SeGAH.2017.7939260>.

SIMMICH, Joshua; DEACON, Anthony J.; RUSSELL, Trevor G. Active video games for rehabilitation in respiratory conditions: Systematic review and meta-analysis. **Journal of Medical Internet Research**, vol. 21, n° 2, 2019. DOI. <https://doi.org/10.2196/10116>.

SKANSI, Sandro. **Introduction to Deep Learning**. Cham: Springer International Publishing, 2018(Undergraduate Topics in Computer Science). DOI 10.1007/978-3-319-73004-2.

SOMMERVILLE, Ian. **Engenharia de software**. 10^o ed. São Paulo, SP: Pearson, 2018.

SORIANO, Joan B.; KENDRICK, Parkes J.; PAULSON, Katherine R.; GUPTA, Vinay; ABRAMS, Elissa M.; ADEDOYIN, Rufus Adesoji; ADHIKARI, Tara Ballav; ADVANI, Shailesh M.; AGRAWAL, Anurag; AHMADIAN, Elham; ALAHDAB, Fares; ALJUNID, Syed Mohamed; ALTIRKAWI, Khalid A.; ALVIS-GUZMAN, Nelson; ANBER, Nahla Hamed; ANDREI, Catalina Liliana; ANJOMSHOA, Mina; ANSARI, Fereshteh; ANTÓ, Josep M.; VOS, Theo. Prevalence and attributable health burden of chronic respiratory diseases, 1990–2017: a systematic analysis for the Global Burden of Disease Study 2017. **The Lancet Respiratory Medicine**, vol. 8, n^o 6, p. 585–596, 2020. DOI. [https://doi.org/10.1016/S2213-2600\(20\)30105-3](https://doi.org/10.1016/S2213-2600(20)30105-3).

SUTANTO, Y. S.; MAKHABAH, D. N.; APHRIDASARI, J.; DOEWES, M.; SURADI; AMBROSINO, N. Videogame assisted exercise training in patients with chronic obstructive pulmonary disease: A preliminary study. **Pulmonology**, vol. 25, n^o 5, p. 275–282, 2019. DOI. <https://doi.org/10.1016/j.pulmoe.2019.03.007>.

TARTARISCO, G.; CARBONARO, N.; TONACCI, A.; BERNAVA, G. M.; ARNAO, A.; CRIFACI, G.; CIPRESSO, P.; RIVA, G.; GAGGIOLI, A.; DE ROSSI, D.; TOGNETTI, A.; PIOGGIA, G. Neuro-fuzzy physiological computing to assess stress levels in virtual reality therapy. **Interacting with Computers**, vol. 27, n^o 5, p. 521–533, 2015. DOI. <https://doi.org/10.1093/iwc/iwv010>.

TU, Linlin; HAO, Tian; BI, Chongguang; XING, Guoliang. BreathCoach: A smart in-home breathing training system with bio-feedback via VR game. **Smart Health**, vol. 16, n^o November 2019, p. 100090, 2020. DOI. <https://doi.org/10.1016/j.smhl.2019.100090>.

UNITY TECHNOLOGIES. ML-Agents. 29 jul. 2024. Disponível em: <https://github.com/Unity-Technologies/ml-agents>. Acessado em: 28 jul. 2024.

VAGG, Tamara; TAN, You Yuan; SHORTT, Cathy; HICKEY, Claire; PLANT, Barry J.; TABIRCA, Sabin. MHealth and Serious Game Analytics for Cystic Fibrosis Adults. **Proceedings - IEEE Symposium on Computer-Based Medical Systems**, vol. 2018-June, p. 100–105, 2018. DOI. <https://doi.org/10.1109/CBMS.2018.00025>.

VALENCIA, Yessica; MAJIN, Jhon. Applications for Upper Limb Rehabilitation. 2018.

VIDOTTO, Laís Silva; DE CARVALHO, Celso Ricardo Fernandes; HARVEY, Alex; JONES, Mandy. Dysfunctional breathing: What do we know? **Jornal Brasileiro de Pneumologia**, vol. 45, n^o 1, p. 1–9, 2019. DOI. <https://doi.org/10.1590/1806-3713/e20170347>.

WANG, H.; NAGHAVI, M.; ALLEN, C.; BARBER, R. M.; CARTER, A.; CASEY, D. C.; CHARLSON, F. J.; CHEN, A. Z.; COATES, M. M.; COGGESHALL, M.; DANDONA,

L.; DICKER, D. J.; ERSKINE, H. E.; HAAGSMA, J. A.; FITZMAURICE, C.; FOREMAN, K.; FOROUZANFAR, M. H.; FRASER, M. S.; FULLMAN, N.; ... ZUHLKE, L. J. Global, regional, and national life expectancy, all-cause mortality, and cause-specific mortality for 249 causes of death, 1980–2015: a systematic analysis for the Global Burden of Disease Study 2015. **The Lancet**, vol. 388, n° 10053, p. 1459–1544, 2016. DOI. [https://doi.org/10.1016/S0140-6736\(16\)31012-1](https://doi.org/10.1016/S0140-6736(16)31012-1).

WANG, Ya Qing; LIU, Xin; MA, Rui Chen; YIN, Ying Ying; YANG, Zhuo; CAO, Hui Ping; XIE, Jiao. Active Video Games as an Adjunct to Pulmonary Rehabilitation of Patients With Chronic Obstructive Pulmonary Disease: A Systematic Review and Meta-Analysis. **American journal of physical medicine & rehabilitation**, vol. 99, n° 5, p. 372–380, 2020. DOI. <https://doi.org/10.1097/PHM.0000000000001341>.

WARDINI, Rima; DAJCZMAN, Esther; YANG, Nathan; BALTZAN, Marcel; PRÉFONTAINE, David; STATHATOS, Maria; MARCIANO, Haguit; WATSON, Shawn; WOLKOVE, Norman. Using a virtual game system to innovate pulmonary rehabilitation: Safety, adherence and enjoyment in severe chronic obstructive pulmonary disease. **Canadian Respiratory Journal**, vol. 20, n° 5, p. 357–361, 2013. DOI. <https://doi.org/10.1155/2013/563861>.

WEST, John B. **Fisiologia Respiratória: princípios básico**. Porto Alegre: Artmed: 2013.

WILKINSON, Phil. Brief history of serious games. **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**, vol. 9970 LNCS, p. 17–41, 2016. DOI. https://doi.org/10.1007/978-3-319-46152-6_2.

YUEN, Hon K.; LOWMAN, John D.; OSTER, Robert A.; DE ANDRADE, Joao A. Home-Based Pulmonary Rehabilitation for Patients With Idiopathic Pulmonary Fibrosis: A PILOT STUDY. **Journal of Cardiopulmonary Rehabilitation and Prevention**, vol. 39, n° 4, p. 281–284, 2019. DOI. <https://doi.org/10.1097/HCR.0000000000000418>.

APÊNDICE A - PROTOCOLO DE CONDUÇÃO DO MSL

1. Definições de busca

Para a fase “Realizar as Definições de Busca”, os artigos relevantes foram identificados a partir dos seguintes Mecanismos de Busca Acadêmica (MBA): *IEEE Xplore, Scopus, Engineering Village, Web of Science, PubMed, Science Direct*. Estes MBAs representam os principais fornecedores de informação nesta área de estudo (Buchinger et al. 2014). A busca também foi realizada nos *Anais do Simpósio Brasileiro de Games e Entretenimento Digital (SBGames)* e *Simpósio Internacional de Fisioterapia Cardiorrespiratória e Fisioterapia em Terapia Intensiva (SIFR)*.

A busca foi executada entre os meses de fevereiro a maio de 2020 por intermédio de cadastro acadêmico válido no portal da CAPES e a base de dados do mapeamento, extraída no mês de junho de 2020, foi sistematizada através de planilhas eletrônica do MS Excel por ser uma ferramenta flexível para a tabulação do dicionário de dados listado na seção “Classe de Dados”. Foi definida a seguinte frase de busca:

*("virtual reality" OR *game*) AND (respirat* OR breath* OR expirat* OR inspirat* OR pulmonar*) AND (rehabilitat* OR therap*)*.

Para a construção da frase de busca, executaram-se ensaios preliminares de busca com o refinamento aplicado durante as iterações iniciais que foi planejada utilizando respectivamente grupos de palavras-chave relacionados a (técnica ou método) AND (conceito ou ideia) AND (área de aplicação). O termo “virtual reality” foi empregado porque algumas publicações na área da saúde podem utilizá-lo como referência a jogos digitais (Grimes, Santos e Hounsell 2018).

Nesta fase, o resultado da busca feita a partir da frase ajustada para manter a semântica da busca em cada um dos MBAs escolhidos, conforme exibido na Tabela 11, permitiu identificar todos os artigos científicos em potencial.

Tabela 11 - Frases de Busca em MBAs

MBA	Frase de Busca
IEEE Xplore	1- (((“All Metadata”: "virtual reality" OR *game*) AND “All Metadata”: reabilitat* OR therap*) AND “All Metadata”: respirat*) 2 - (((“All Metadata”: "virtual reality" OR *game*) AND “All Metadata”: reabilitat* OR therap*) AND “All Metadata”: breath*) 3 - (((“All Metadata”: "virtual reality" OR *game*) AND “All Metadata”: reabilitat* OR therap*) AND “All Metadata”: expirat*) 4 - (((“All Metadata”: "virtual reality" OR *game*) AND “All Metadata”: reabilitat* OR therap*) AND “All Metadata”: inspirat*) 5 - (((“All Metadata”: "virtual reality" OR *game*) AND “All Metadata”: reabilitat* OR therap*) AND “All Metadata”: pulmonar*)
Scopus	TITLE-ABS-KEY(("virtual reality" OR *game*) AND (respirat* OR breath* OR expirat* OR inspirat* OR pulmonar*) AND (reabilitat* OR therap*))
Engineering Village	((("virtual reality" OR game* OR *game) AND (respirat* OR breath* OR expirat* OR inspirat* OR pulmonar*) AND (reabilitat* OR therap*)) WN KY) AND (English WN LA) + ({ca} OR {ja} OR {cp}) WN DT
Web of Science	((("virtual reality" OR *game*) AND (respirat* OR breath* OR expirat* OR inspirat* OR pulmonar*) AND (reabilitat* OR therap*))
PubMed	((("virtual reality"[Title/Abstract] OR *game*)[Title/Abstract]) AND ((respirat*[Title/Abstract] OR breath*[Title/Abstract] OR expirat*[Title/Abstract] OR inspirat*[Title/Abstract] OR pulmonar*)[Title/Abstract])) AND ((reabilitat*[Title/Abstract] OR therap*)[Title/Abstract])
Science Direct	1 - Title OR abstract:((game) AND (respiratory OR breathing OR expiration OR inspiration OR pulmonar) AND (rehabilitation OR therapy)) 2 - Title OR abstract:(("virtual reality") AND (respiratory OR breathing OR expiration OR inspiration OR pulmonar) AND (rehabilitation OR therapy))

Fonte: Elaborada pelo autor (2020).

No MBA *IEEE Xplore*, devido ao limite de cinco *wildcards* (caracteres coringa: "*") em uma frase de busca, houve a necessidade de dividir os termos *respirat**, *breath**, *expirat**, *inspirat** e *pulmonar** em cinco buscas diferentes. Para o MBA *Engineering Village*, por não permitir dois *wildcards* no mesmo termo, foi necessário dividir **game OR game**. Já no MBA *Science Direct*, a restrição de até oito conectores lógicos levou a divisão da frase de busca em duas partes, Tabela 11. Exclusivamente para os eventos SBGames e SIFR, por não possuírem um mecanismo de busca, foi realizado download dos Anais dos últimos dez anos e realizada a busca utilizando o

Software Agent Ransack com as seguintes frases de busca: para SBGames (*respirat* OR breath* OR expirat* OR inspirat* OR pulmonar* OR rehabilita* OR reabilita* OR therap* OR terap**) e para SIFR (*jogo* OR *game* OR “realidade virtual” OR “virtual reality”*).

Durante as leituras de triagens, cinco pesquisadores membros do grupo de pesquisa avaliaram independentemente os títulos e resumos dos artigos, realizando a análise conforme critérios subjetivos (exclusão e inclusão) apresentados na próxima subseção. Outros dois pesquisadores avaliaram e decidiram sobre discrepâncias, discordâncias ou dúvidas na exclusão e inclusão dos artigos, as quais foram discutidas e resolvidas por consenso. Posteriormente, uma análise de texto completo foi realizada seguindo a mesma abordagem quanto às discordâncias e sendo resolvidas por consenso.

2. Critérios de seleção (objetivos e subjetivos)

Na terceira fase do protocolo, deve-se definir Critérios Objetivos (CO_i) e Critérios subjetivos de Exclusão e Inclusão (CE_i) e (CI) que são considerados para classificar somente os artigos relevantes à questão de pesquisa deste estudo.

Nesta fase foram definidos os seguintes CO_i:

CO₁: Publicação no período de janeiro de 2011 até maio de 2020;

CO₂: Artigos escritos em Inglês. Exceção aos Anais do SBGames e SIFR;

CO₃: Artigos de acesso na íntegra pelo Portal de Periódicos da CAPES;

CO₄: Artigos publicados em periódicos ou eventos científicos (revisados pelos pares);

CO₅: Artigos não duplicados;

CO₆: Artigos que são textos completos (maior ou igual a 4 páginas);

Os CO₁₋₄ são aplicados pelos recursos de filtros e refinamentos disponíveis diretamente em cada um dos MBAs. Os CO₅₋₆ são aplicados pelos pesquisadores.

Os CE_i foram definidos considerando a não identificação de estudos primários completos sobre jogos digitais aplicados à reabilitação respiratória. O CI foi definido considerando a presença de indícios de inteligência artificial, seja explicitamente ou implicitamente observado pelos pesquisadores.

Foram definidos os seguintes CE_i e CI:

CE₁: Artigos que não propõem o uso de jogos digitais;

CE₂: Artigos que não se relacionam com reabilitação na área de doenças respiratórias;

CE₃: Artigos que não são primários (artigos de revisão, por exemplo);

CI: Independente da autodenominação, deve apresentar indícios (explícito ou implícito) de Inteligência Artificial na arquitetura do software do jogo ou do dispositivo de controle.

Foi definida uma estratégia para a uniformização e aplicação dos critérios subjetivos. Adotou-se primeiro a triagem do MBA que apresentou menor número de resultados, *Engineering Village*, na qual cinco pesquisadores aplicaram independentemente os CE₁₋₂ e realizaram em seguida a união dos resultados para validar o entendimento do protocolo e estabelecer um nivelamento na aplicação dos critérios subjetivos. Logo após chegarem ao consenso quanto aplicação dos critérios subjetivos, as triagens dos demais MBAs foram divididas entre os cinco pesquisadores, tomando o cuidado de levar para deliberação quaisquer discrepâncias, dúvidas quanto a exclusão e inclusão para ser decidido em consenso.

A metodologia utilizada para seleção dos artigos relevantes foi dividida em duas etapas: Seleção com a aplicação dos CO_i e CE_i com base em títulos e resumos somente; Seleção por leitura de texto completo com aplicação do CI.

3. Classes de dados

Na quarta fase do protocolo, “Criar Classes de Dados”, identificam-se as características e depois se classificam os artigos conforme afinidade, com objetivo de formar grupos de conceitos com respectivas variáveis investigadas. Nesta fase, foram definidas classes de dados primários de informações relevantes para este mapeamento, conforme o seguinte dicionário de dados:

- i. Dados sobre a publicação: ano de publicação, primeiro autor, veículo de publicação, tipo de publicação;
- ii. Dados sobre os jogos digitais: nome do jogo, gênero, dispositivo, sinais, origem;
- iii. Dados sobre inteligência artificial: uso, local, comportamento, ênfase do esforço do usuário, técnica de IA, inteligência artificial;
- iv. Dados sobre reabilitação respiratória: fase clínica, doenças, medidas, tratamento;

- v. Dados sobre a pesquisa: design de pesquisa, objetivo, medida, instrumento, dados demográficos, resultado.

4. Extração de dados

Os artigos relevantes são mapeados na fase “Extração de dados e mapeamento”. Os dados extraídos nesta fase contribuem para obter as respostas das PS_i para posteriormente responder a PP desta pesquisa.

As questões de Extração de Dados (ED_i) a seguir guiaram o processo de classificação e análise:

ED₀₁: Qual a curva de crescimento de publicações e respectiva tendência da área de estudo?

ED₀₂: Qual a constância dos tipos de publicações?

ED₀₃: Quais os gêneros da narrativa que mais se destacaram e quais suas origens?

ED₀₄: Quais os sinais utilizados para controlar, conduzir e/ou monitorar o jogo?

ED₀₅: Quantos artigos usaram explicitamente Inteligência Artificial?

ED₀₆: Em qual local do sistema pode ser percebido e/ou identificado o uso de Inteligência Artificial?

ED₀₇: Qual a ênfase do esforço do usuário?

ED₀₈: Quais técnicas de Inteligência Artificial utilizadas?

ED₀₉: Qual comportamento percebido e/ou identificado que mais se destacou?

ED₁₀: Usa Inteligência Artificial explicitamente para qual objetivo e quais algoritmos?

ED₁₁: Quais doenças respiratórias foram abordadas?

ED₁₂: Quais tipos de tratamentos foram aplicados?

ED₁₃: Quais medidas (biosinais) foram avaliadas?

5. Resultados

Apresenta-se nesta seção os resultados dos dados coletados dos artigos relevantes selecionados neste mapeamento. Vinte e oito artigos foram selecionados. A Tabela 12 contém o número de artigos que foram identificados e mantidos em cada

etapa, a ordem de aplicação dos CO_i, CE_i e CI que aparecem foi adotada para otimizar o processo de seleção.

Tabela 12 - Número de Artigos Identificados

Base de Dados	Frase Busca	CO 1-4	CO 5	CE 1	CE 2	CO 6	CE 3	CI
IEEE Xplore	1.245	743	566	17	5	4	4	4
Scopus	983	438	401	55	17	15	12	12
Engineering Village	125	80	26	6	3	1	1	1
Web of Science	318	195	84	24	8	2	2	2
PubMed	457	214	137	12	3	3	3	3
Science Direct	4.644	1.557	1.408	64	4	3	2	2
SBGames	124	124	124	104	4	4	3	3
SIFR	22	22	22	22	2	2	1	1
Total	7.918	3.373	2.768	304	46	34	28	28

Fonte: Elaborada pelo autor (2020).

Das 8 bases de dados consideradas neste mapeamento, a que apresentou mais publicações foi o *Scopus*, com 12 artigos, 43% dos resultados. Após a busca preliminar (frase de busca com filtros/refinamentos CO₁₋₄), todos os artigos duplicados foram excluídos pelo CO₅ utilizando recurso condicional automatizado em planilha do MS Excel, gerada pela união dos resultados dos MBAs. Após a triagem de leitura dos títulos e resumos, 28 resultados permaneceram para avaliação do texto completo pelo CI e posteriormente, os 28 artigos, foram classificados como relevantes e selecionados no MSL. Os artigos relevantes selecionados em cada MBA através deste mapeamento sistemático da literatura estão listados na Tabela 13 e Tabela 14.

Tabela 13 - Artigos Relevantes em cada MBA

Base de Dados	ID
IEEE Xplore	[1, 2, 3, 4]
Scopus	[5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16]
Engineering Village	[17]
Web of Science	[18, 19]
PubMed	[20, 21, 22]
Science Direct	[23, 24]
SBGames	[25, 26, 27]
SIFR	[28]

Fonte: Elaborada pelo autor (2020).

Tabela 14 - Artigos Relevantes

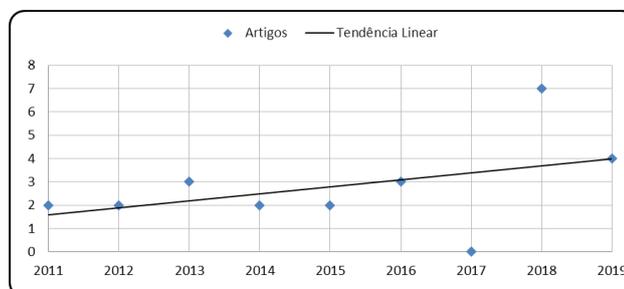
ID	Título	Autor/Ano
19	MHealth and Serious Game Analytics for Cystic Fibrosis Adults	(Vagg <i>et al.</i> , 2018)
20	Playing computer games for isolated breathing therapy	(Kotova e Korvas, 2016)
21	Support and rehabilitation of patients with pulmonary expansion deficit by using game therapy	(Chacon <i>et al.</i> , 2016)
22	Using serious games to motivate children with cystic fibrosis to engage with mucus clearance physiotherapy	(Oikonomou e Day, 2012)
23	Virtual reality rehabilitation in patients with chronic obstructive pulmonary disease: A randomized controlled trial	(Rutkowski <i>et al.</i> , 2020)
24	Effect of Virtual Reality-Based Rehabilitation on Physical Fitness in Patients with Chronic Obstructive Pulmonary Disease	(Rutkowski <i>et al.</i> , 2019)
25	Videogame assisted exercise training in patients with chronic obstructive pulmonary disease: A preliminary study," Pulmonology	(Sutanto <i>et al.</i> , 2019)
26	Pilot project: Physiologic responses to a high-intensity active video game with COPD patients–Tools for home rehabilitation	(Parent <i>et al.</i> , 2018)
27	Effectiveness of a home-based active video game programme in young cystic fibrosis patients	(Del Corral <i>et al.</i> , 2018)
28	Does a Nintendo Wii exercise program provide similar exercise demands as a traditional pulmonary rehabilitation program in adults with COPD?	(Legear <i>et al.</i> , 2016)
29	The effects of game-based breathing exercise on pulmonary function in stroke patients: A preliminary study	(Joo, Shin, e Song, 2015)
30	Interactive videogame as rehabilitation tool of patients with chronic respiratory diseases: Preliminary results of a feasibility study	(Mazzoleni <i>et al.</i> , 2014)
31	Physiological response during activity programs using Wii-based video games in patients with cystic fibrosis (CF)	(Del Corral <i>et al.</i> , 2014)
32	Xbox Kinect™ represents high intensity with cystic fibrosis	(Holmes <i>et al.</i> , 2013)
33	Using a virtual game system to innovate pulmonary rehabilitation: Safety, adherence and enjoyment in severe chronic obstructive pulmonary disease	(Wardini <i>et al.</i> , 2013)
34	Gaming console exercise and cycle or treadmill exercise provide similar cardiovascular demand in adults with cystic fibrosis: a randomised cross-over trial	(Kuys <i>et al.</i> , 2011)
35	Respiration tracking using the Wii remote game controller	(Aguilar <i>et al.</i> , 2011)
36	A comparative study of smartphone game with spirometry for pulmonary function assessment in stroke patients	(Joo <i>et al.</i> , 2018)
37	Pilot trial of spirometer games for airway clearance practice in cystic fibrosis	(Bingham, Lahiri, e Ashikaga, 2012)
38	Home-Based Pulmonary Rehabilitation for Patients With Idiopathic Pulmonary Fibrosis: a pilot study	(Yuen <i>et al.</i> , 2019)
39	Developing Digital Games to Address Airway Clearance Therapy in Children With Cystic Fibrosis: Participatory Design Process	(Balli, 2018)
40	Active video game exercise training improves the clinical control of asthma in children: Randomized controlled trial	(Gomes <i>et al.</i> , 2015)
41	BreathCoach: A smart in-home breathing training system with bio-feedback via VR game	(Tu <i>et al.</i> , 2020)
42	Evaluation of the exercise intensity generated by active video gaming in patients with cystic fibrosis and healthy individuals	(Campos <i>et al.</i> , 2020)
43	O Processo de Design de um Sistema Biomédico com Jogo Sério e Dispositivo Especial para Reabilitação Respiratória	(Grimes, Santos, e Hounsell, 2018)
44	I Blue It : Um Jogo Sério para auxiliar na Reabilitação Respiratória	(Santos <i>et al.</i> , 2018)
45	Desenvolvimento de Dispositivo Híbrido para Jogo Sério Aplicado a Saúde	(Henrique <i>et al.</i> , 2019)
46	Uso do Nintendo Wii e adaptações cardiorrespiratórias agudas em uma criança com Síndrome de Down: relato de caso	(Pereira <i>et al.</i> , 2013)

Fonte: Elaborado pelos autores (2020).

No Gráfico 1 apresentam-se a frequência das publicações dos artigos relevantes no período de 2011-2020 e a tendência de crescimento da área de

pesquisa (ED01). Observa-se, por exemplo, que dos 28 artigos selecionados, o ano de maior frequência foi em 2018, com sete publicações.

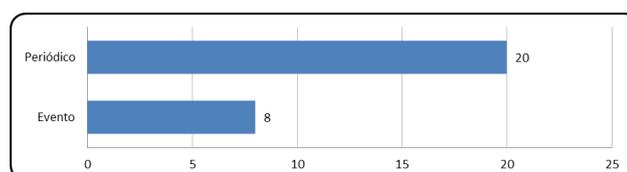
Gráfico 1 - Número de artigos publicados ao longo dos anos



Fonte: Elaborado pelos autores (2020).

Quanto a constância dos tipos de publicações (ED02), o Gráfico 2 mostra que os periódicos são mais frequentes nesta área de estudo, com 71% dos artigos selecionados. Os veículos de publicação mais frequentes identificados foram Journal of Cystic Fibrosis com 15% dos artigos de periódicos (Del Corral *et al.*, 2014) (Holmes *et al.*, 2013) (Campos *et al.*, 2020) e o SBGames com 38% dos artigos de eventos científicos (Grimes *et al.*, 2018) (Santos *et al.*, 2018) (Henrique *et al.*, 2019).

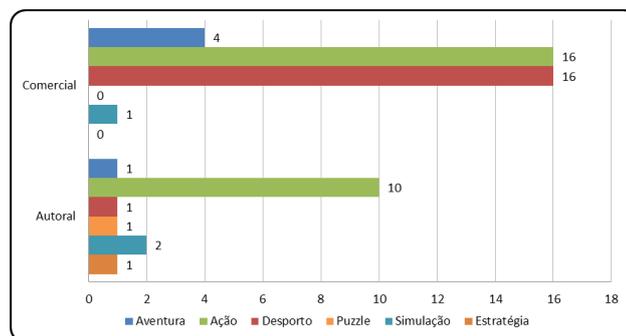
Gráfico 2 - Tipos de Publicação



Fonte: Elaborado pelos autores (2020).

Em relação aos gêneros da narrativa dos JD que mais se destacaram e suas origens (ED03), utilizados pelos artigos selecionados, pode ser visto no Gráfico 3 que o gênero ação e desporto é o mais utilizado em jogos de origem comercial. Para os jogos de origem autoral (Jogos Sérios desenvolvidos pelos autores do artigo com propósito específico) o gênero ação é o mais utilizado. Destaca-se que existem artigos que abordam jogos que se encaixam em mais de um gênero. Foi identificado que 2 (Kotova e Korvas, 2016) (Aguilar *et al.*, 2011) dos 28 artigos não descreveram qual jogo foi utilizado, descrevendo apenas o dispositivo e respectivos sinais usados para controlar um jogo qualquer.

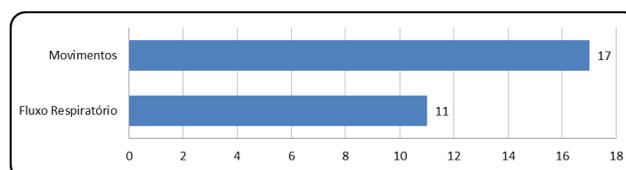
Gráfico 3 - Relação entre gêneros da narrativa e origens



Fonte: Elaborado pelos autores (2020).

Os sinais utilizados para controlar, conduzir e/ou monitorar o jogo (ED04) que foram identificados nos artigos são obtidos por intermédio dos movimentos dos jogadores e por intermédio do fluxo respiratório. Pode ser visto no Gráfico 4 que os controles que captam os sinais dos movimentos são mais frequentes, sendo que 16 dos 17 estudos usaram sensores Kinect ou Wii como controle padrão do jogo para realizar os exercícios com treinamentos em uma ou mais modalidades de jogos comerciais, tais como: Adventures (Rutkowski *et al.*, 2020), Wii Fit (Sutanto *et al.*, 2019), EA Sports Active (Del Corral *et al.*, 2018). Os artigos que não usaram Kinect ou Wii, propuseram o uso de dispositivos específicos para controlar o jogo, como por exemplo, dispositivos com sensores que utilizam o sinal da respiração.

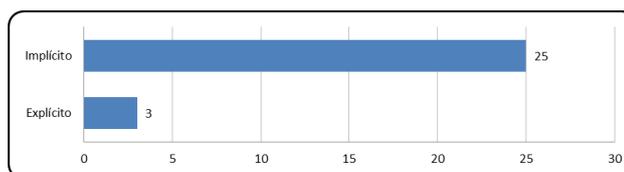
Gráfico 4 - Sinais utilizados



Fonte: Elaborado pelos autores (2020).

Foram poucos os artigos que usaram explicitamente inteligência artificial (ED05), apenas 11% dos artigos (Kotova; Korvas, 2016) (Aguilar *et al.*, 2011) (Tu *et al.*, 2020) descreveram explicitamente o uso de IA. Em maior frequência, foram identificados artigos que apresentaram indícios que permitiram inferir o uso de IA. Neste caso, foram classificados como “implícito” na variável “Uso de IA” (Gráfico 5).

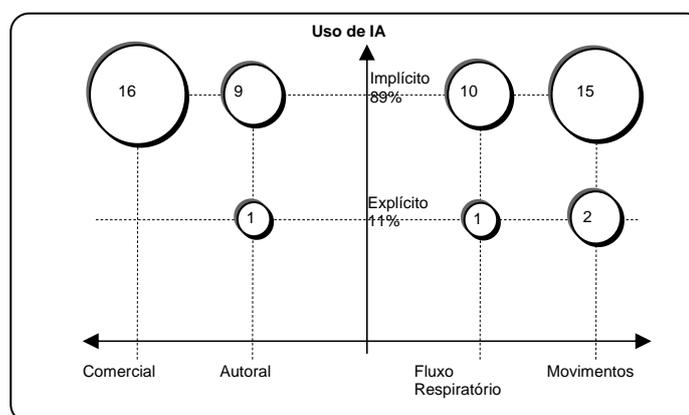
Gráfico 5 - Uso de IA



Fonte: Elaborado pelos autores (2020).

Pode ser observado no Gráfico 6, um gráfico de bolhas que permite relacionar as variáveis “Uso de IA” (implícito, explícito), “Origem” (comercial, autoral) e “Sinal” (fluxo respiratório, movimentos). Dezesesseis artigos utilizaram jogos de origem comercial, neste caso, o uso de IA pôde ser percebido implicitamente pela análise do *gameplay* e experiência dos pesquisadores. Observa-se uma maior frequência de artigos que se enquadram na percepção do uso de IA implícito: dentre os 28 artigos, 89% foram classificados por inferência, sendo 35% e 54%, respectivamente, controlados por sinais do fluxo respiratório e movimentos. Em 7% (Kotova; Korvas, 2016) (Aguilar, *et al.*, 2011) dos artigos não foi descrito qual jogo foi utilizado, portanto o lado esquerdo da Gráfico 6 o quantitativo é menor.

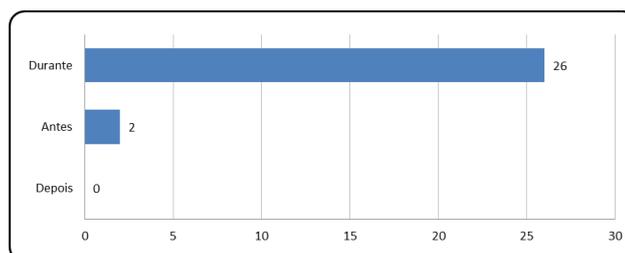
Gráfico 6 - Relação entre Uso de IA, Origem e Sinal



Fonte: Elaborado pelos autores (2020).

Quanto aos locais de aplicação da IA no que pode ser percebido e/ou identificado, classificou-se o uso de IA (ED06), em antes, durante ou depois do jogo (Gráfico 7). Percebe-se ações inteligentes durante o jogo em 93% dos artigos selecionados.

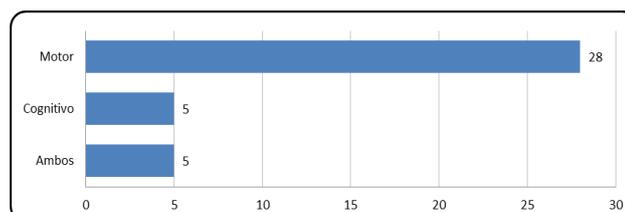
Gráfico 7 - Local de uso da IA



Fonte: Elaborado pelos autores (2020).

Para a ênfase do esforço do usuário (ED07), pode ser percebido, no Gráfico 8, que dentre os 28 artigos que dão ênfase ao esforço motor, existem também 18% (Oikonomou; Day, 2012) (Chacon *et al.*, 2016) (Joo *et al.*, 2015) (Joo *et al.*, 2018) (Tu *et al.*, 2020) que fazem uso simultâneo do esforço motor e cognitivo.

Gráfico 8 - Ênfase do esforço do usuário

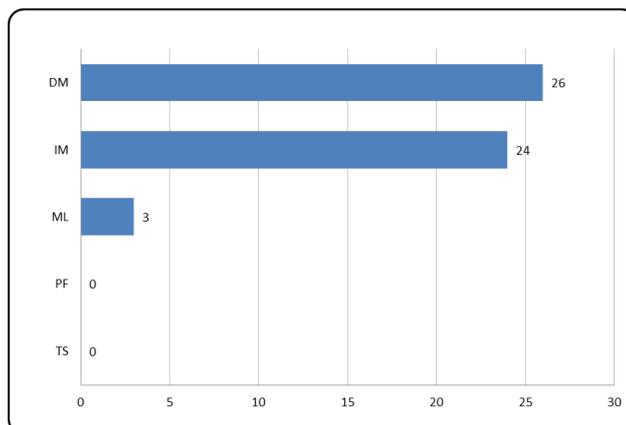


Fonte: Elaborado pelos autores (2020).

As técnicas de Inteligência Artificial utilizadas (ED08), são constituídas por classes de algoritmos agrupadas por características e objetivos similares (Millington e Funge 2009), tais como: *Intelligent Movement*; *Path Finding*; *Decision Making*; *Tactical and Strategic*; *Machine Learning*.

O Gráfico 9 exibe as frequências de uso das técnicas de IA. Reparar que em alguns artigos tem-se o uso de mais de uma técnica de IA. Observa-se que as maiores frequências aparecem para *Intelligent Movement* e *Decision Making*. Estes dois grupos de algoritmos são frequentemente utilizados na implementação de mecânicas e jogabilidades em diversos gêneros da narrativa de JD.

Gráfico 9 - Técnicas de IA



Legenda. IM: Intelligent Movement; PF: Path Finding; DM: Decision Making, TS: Tactical and Strategic; ML: Machine Learning.

Fonte: Elaborado pelos autores (2020).

O comportamento percebido e/ou identificado que mais se destacaram (ED09) foi a indução na melhora da resistência muscular, cardiopulmonar, agilidade e equilíbrio, sendo este comportamento percebido em 54% dos artigos (Tabela 15). Infere-se na relação entre comportamento percebido e técnicas de IA, que 86% e 93% dos artigos utilizam respectivamente *Intelligent Movement* e *Decision Making*. Foi possível realizar esta inferência por intermédio do *gameplay* e das mecânicas dos jogos descritos nos artigos selecionados.

Quanto ao emprego da técnica *Machine Learning*, os trabalhos de (Aguilar *et al.*, 2011), (Korvas, 2016) e (Tu *et al.*, 2020) descreveram explicitamente o emprego de algoritmos computacionais inteligentes que se enquadram nesta categoria. Estes 3 artigos fazem uso explicitamente de IA (ED10) com o objetivo de reconhecimento de padrões e visão computacional com algoritmos *Random forest classifier*, *Incremental-merge segmentation algorithm*, *Breathing pattern extraction*.

Muito embora os trabalhos de (Aguilar *et al.*, 2011) e (Korvas, 2016) tenham feito experimentos com dispositivos de controle utilizando respectivamente os sensores Kinect e Wiimote, eles não propuseram o uso de jogos. Em (Tu *et al.*, 2020) os autores propuseram uma arquitetura para representar o padrão de respiração em um jogo de realidade virtual que monitora os sinais da respiração e do batimento cardíaco. De tal modo que calcula de forma inteligente o padrão da respiração ideal com base em medições atuais e históricas. Esses 3 artigos têm em comum o uso de inteligência artificial para fornecer *biofeedback* em tempo real durante a reabilitação respiratória.

Tabela 15 - Comportamento inteligente percebido

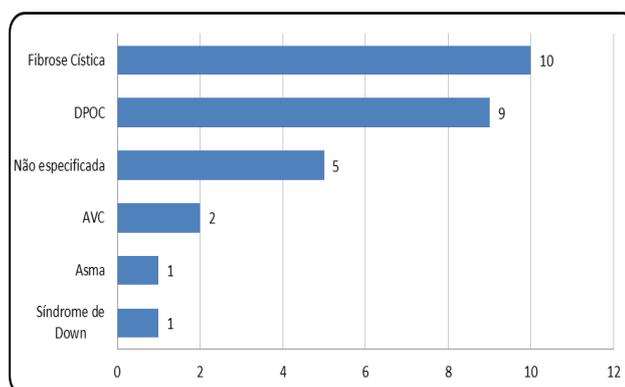
Comportamento	IM	DM	ML
Análise de amostras de sopro por segundo	1	1	
Conduz o ciclo da respiração, as atividades cardiopulmonares e resistência muscular	6	6	1
Conduz o jogador aos passos necessários	1	1	
Detecta e isola o padrão de respiração			1
Exibe relação entre medição e predição de capacidade inspiratória		1	
Induz na melhoria da resistência muscular, cardiopulmonar, agilidade e equilíbrio	15	15	
Promove o nível de dificuldade gradual (Flow)	1	1	
Promove feedback conforme variação de sinais da respiração		2	1
Total	24	27	3

Legenda. IM: Intelligent Movement; DM: Decision Making, ML: Machine Learning.

Fonte: Elaborado pelos autores (2020).

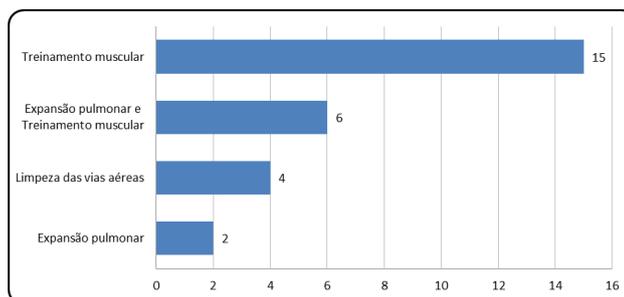
Quanto às doenças respiratórias (ED11) observa-se que a Fibrose Cística, com 36% dos artigos, representa a doença respiratória com maior frequência, seguida da DPOC, com 32%. Foi identificado apenas 4% para Asma e Síndrome de Down (Gomes *et al.*, 2015) (Pereira *et al.*, 2013), (Gráfico 10). Foi observado nos artigos três tipos de tratamentos (ED12), treinamento muscular, expansão pulmonar e limpeza das vias aéreas, conforme exibido no Gráfico 11. As medidas (biosinais) avaliadas durante a fisioterapia (ED13) podem ser observadas no Gráfico 12. As medidas mais usadas foram volume expiratório forçado no primeiro segundo capacidade vital forçada e a frequência cardíaca.

Gráfico 10 - Doenças associadas



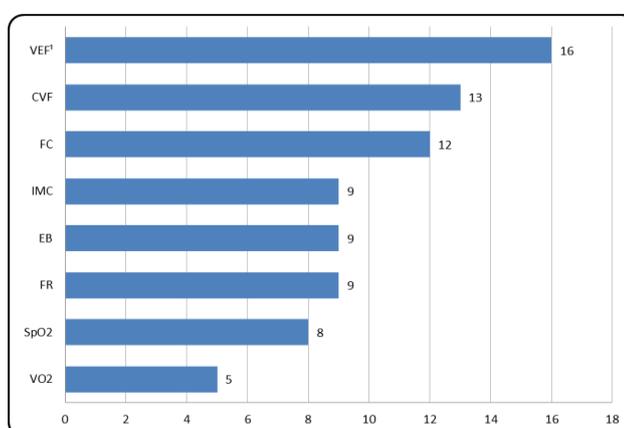
Fonte: Elaborado pelos autores (2020).

Gráfico 11 - Tratamentos mencionados



Fonte: Elaborado pelos autores (2020).

Gráfico 12 - Biosinais utilizados



Legenda. VEF1: Volume Expiratório Forçado no primeiro segundo; CVF: Capacidade Vital Forçada; FC: Frequência Cardíaca; IMC: Índice de Massa Corporal; EB: Escala Borg; FR: Frequência Respiratória; SpO2: Saturação de Oxigênio; VO2: Volume de Oxigênio.

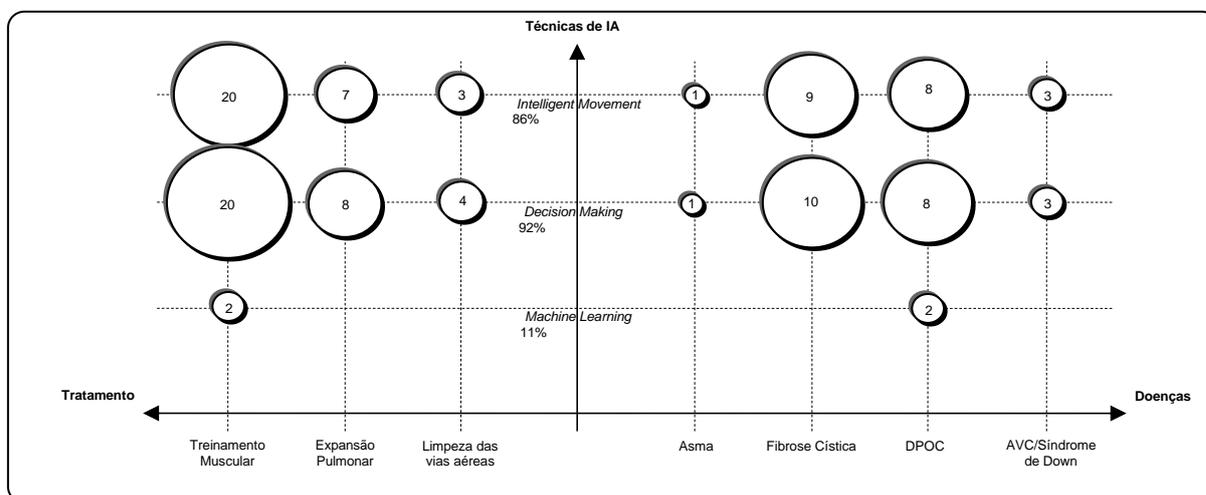
Fonte: Elaborado pelos autores (2020).

A relação entre as variáveis Técnicas de IA, Tratamento e Doença, exibida no Gráfico 13, permite observar por exemplo, que 92% dos artigos abordaram a técnica de Decision Making, sendo 71% para Treinamento Muscular. Ao menos 36% são aplicados na Fibrose Cística. Observa-se também que ao menos 11% dos artigos fizeram uso de Machine Learning para treinamento muscular e ao menos 7% aplicado em DPOC.

Na relação entre as variáveis Técnicas de IA e Tratamento, foi possível perceber um conjunto de artigos que fazem uso de uma, duas ou mais técnicas de IA e um, dois ou mais tipos de tratamento em um mesmo ambiente de reabilitação. Por exemplo, os artigos (Rutkowski *et al.*, 2020) (Rutkowski *et al.*, 2019) (Mazzoleni *et al.*, 2014) (Del Corral *et al.*, 2014) (Wardini *et al.*, 2013) (Pereira *et al.*, 2013) realizaram

experimentos de treinamento muscular e expansão pulmonar utilizando *Intelligent Movement e Decision Making*.

Gráfico 13 - Relação entre Técnicas de IA, Tratamentos e Doenças



Fonte: Elaborado pelos autores (2020).

6. Riscos

Há um risco de se ter deixado de fora artigos relevantes de MBAs que não foram escolhidas neste MSL. Para mitigar este risco, o artigo (Buchinger *et al.*, 2014) contribuiu na seleção de bases relevantes ao tema proposto por este mapeamento. Existe um risco da falta de algum termo chave na busca. Neste caso, foi realizada uma busca manual nas referências bibliográficas dos artigos identificados, para procurar publicações adicionais relevantes. Percebeu-se que o artigo (O'Donovan *et al.*, 2014), identificado nas referências de (Campos *et al.*, 2020), não foi listado nas buscas porque em seu título e resumo os termos não foram condizentes com a frase de busca deste mapeamento. Isto pode ter ocorrido porque não foram utilizados termos específicos como *exercice*, *wii* e *Kinect* por não serem diretamente associados a terapia e não serem indicação de técnica ou método. Outro risco é que podem ter ocorrido erros na aplicação dos critérios subjetivos, mesmo tendo os pesquisadores realizado reuniões frequentes para discutir as discordâncias ou dúvidas na exclusão e inclusão dos artigos.

APÊNDICE B - ENTREVISTA SEMIESTRUTURADA



Jogo SériO Inteligente para Reabilitação Respiratória

Doutorando: Claudinei Dias, MSc.
Orientador: André Bittencourt Leal, PhD.
Coorientador: Marcelo da Silva Hounsell, PhD.

Programa de Pós-graduação em Engenharia Elétrica - PPGEEEL
2020-2

UDESC
UNIVERSIDADE DO ESTADO DE SANTA CATARINA
CCT - Joinville

Convite

- Participar da fase de pesquisa da produção de um Sistema Biomédico Inteligentes para Reabilitação Respiratória
- Termo de Consentimento Livre e Esclarecido - TCLE
- Introdução
 - Objetivo
 - Jogos Sérios
 - I Blue It (softwares)
 - Dispositivos (hardwares)
- Entrevista semiestruturada



2

TCLE

- O(a) senhor(a) está sendo convidado(a) a participar de uma entrevista semiestruturada de uma pesquisa de doutorado intitulada "Jogo SériO Inteligente para Reabilitação Respiratória"
- Os riscos para os respondentes serão mínimos, por se tratar de uma entrevista
- Mesmo assim, caso você não se sinta confortável em ter suas informações coletadas, não goste do assunto abordado, da metodologia ou do material utilizado, ou ainda por quaisquer outros motivos, O(a) senhor(a) poderá se retirar da reunião a qualquer momento, sem qualquer tipo de constrangimento e sem precisar se justificar
- As únicas pessoas que terão acesso aos dados brutos serão os pesquisadores diretamente envolvidos no projeto: Claudinei Dias, Marcelo da Silva Hounsell e André Bittencourt Leal. Os resultados, sem identificações, poderão ser veiculados em artigos técnicos e científicos



3

Introdução

- Objetivos
 - Desenvolver recursos inteligentes para:
 - Auxiliar os fisioterapeutas na condução da reabilitação respiratória
 - Auxiliar os pacientes com disfunções respiratórias durante o tratamento



4

Introdução

- Jogos Sérios
 - Visa aspectos específicos
 - Prática de exercícios
 - Interatividade
 - Diversão
 - Imersão
 - Engajamento
 - Desafios progressivos



5

Introdução

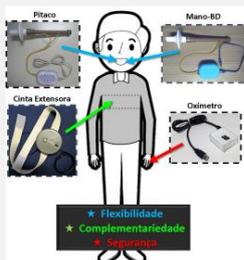
- Jogo SériO: **I Blue It**



6

Introdução

Dispositivos especiais para Controle do **I Blue It**



7

Introdução

- Dispositivo Pneumotacógrafo (PITACO)

Controle do Blue

- Espirometria de incentivo
- Fluxo da respiração
- Auxiliar o Treinamento Muscular Respiratório

Monitoramento

- Frequência Respiratória



8

Introdução

- Dispositivo Manovacuômetro (MANO)

Controle do Blue

- Força muscular
- Pressão expiratória e inspiratória máxima
- Capacidade pulmonar



9

Introdução

- Dispositivo Cinta Extensora

Controle do Blue

- Extensão de Circunferência
- Abdominal
- Torácica

Monitoramento

- Frequência Respiratória



10

Introdução

- Dispositivo de Oximetria de Pulso

Monitoramento

- Frequência Cardíaca
- Saturação de oxigênio



Introdução

- Incentivos respiratórios motivados pelo "I Blue It"
 - O fluxo expiratório
 - O fluxo inspiratório
 - Manutenção do fluxo expiratório
 - Manutenção do fluxo inspiratório
 - Frequência respiratória basal

Introdução

- Mecânica do Jogo Sério I Blue It

- Controle do jogo pelo fluxo respiratório
- Ato de expirar faz o Blue (Personagem Golfinho) submergir
- Ato de inspirar faz o Blue saltar
- Existem obstáculos que devem ser evitados
- Existem alvos e bônus que devem ser coletados

Introdução

- Transição de dificuldade "I Blue It" **fase 1**

Fase	Nível	Tempo[s]	Alvos	Obstáculos	Velocidade
1	1	30	Baixos	-	Lento
1	2	30	Médios	-	Lento
1	3	30	Altos	-	Lento
1	4	50	Baixos	-	Médio
1	5	50	Médios	-	Médio
1	6	50	Altos	-	Médio
1	7	70	Baixos	-	Rápido
1	8	70	Médios	-	Rápido
1	9	70	Altos	-	Rápido

Fonte: GRIMES (2018)

Introdução

- Transição de dificuldade "I Blue It" **fase 2**

Fase	Nível	Tempo[s]	Alvos	Obstáculos	Velocidade
2	1	30	Baixos	Pequenos	Lento
2	2	30	Baixos	Médios	Lento
2	3	30	Baixos	Grandes	Lento
2	4	60	Médios	Pequenos	Médio
2	5	60	Médios	Médios	Médio
2	6	60	Médios	Grandes	Médio
2	7	90	Altos	Pequenos	Rápido
2	8	90	Altos	Médios	Rápido
2	9	90	Altos	Grandes	Rápido

Fonte: GRIMES (2018)

Introdução

- Transição de dificuldade "I Blue It" **fase 3**

Fase	Nível	Tempo[s]	Alvos	Obstáculos	Velocidade
3	1	40	-	Pequenos	Lento
3	2	40	-	Médios	Lento
3	3	40	-	Grandes	Lento
3	4	80	-	Pequenos	Médio
3	5	80	-	Médios	Médio
3	6	80	-	Grandes	Médio
3	7	120	-	Pequenos	Rápido
3	8	120	-	Médios	Rápido
3	9	120	-	Grandes	Rápido

Fonte: GRIMES (2018)

Introdução

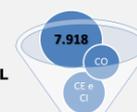
- Regra atual de transição

Pontuação	Decisão
$\geq 70\%$	Avança um nível
31-69%	Refaz o nível
$\leq 30\%$	Retrocede um nível

Introdução

- Mapeamento Sistemático da Literatura - MSL**
 - Como a Inteligência Artificial tem sido usada nos Jogos Digitais aplicados à Reabilitação Respiratória
- Revisão Sistemática da Literatura - RSL**
 - Uso da Inteligência Artificial em Jogos Sérios Multimodais para Reabilitação Respiratória

Momento de Uso	Funções
Antes de usar	<ul style="list-style-type: none"> Customização do tratamento Dosimetria Segurança (análise de sinais)
Durante o uso (dentro)	<ul style="list-style-type: none"> Conforto físico e motivacional (Flow) Diversão
Depois de usar	<ul style="list-style-type: none"> Ajuste de Dosimetria Diagnóstico de alta



artigos relevantes

10 artigos selecionados com IA durante o uso do JSMM

Entrevista semiestruturada

Tópico 1: Objetivo

Investigar em quais pneumopatologias os esforços promovidos pelo "I Blue It" são aplicáveis

1) Qual a sua especialidade (Patologia, Técnica e Procedimento)?

2) Os recursos presentes no **I Blue It** podem ser utilizados em quais pneumopatologias?

3) Quais técnicas terapêuticas podem ser realizadas com os recursos presentes no **I Blue It**?

4) Quais procedimentos terapêuticos podem ser realizados com os recursos presentes no **I Blue It**?

Tópico 2: Objetivo

Investigar se os esforços promovidos pelo "I Blue It" estão graduados

5) A sequência atual das fases e níveis do **I Blue It** estão em ordem progressiva de exigência de esforço para os pacientes (independente da patologia)?

6) A sequência das fases e níveis do **I Blue It** deve ser sempre a mesma independente da patologia/tratamento?

6.1) Se a resposta da questão 5 for não. Para qual situação a sequência seria diferente?

6.2) Se resposta da questão 5 for não. Qual deveria ser a sequência?

6.3) A sequência seria a mesma para qualquer dispositivo (Pitaco, ManoBD, Cinta)?

Tópico 3: Objetivo

Como realizar o DDA do "I Blue It"

O quê?

Quanto?

Quando?

Onde?



31

7) Qual adaptação (em tempo de jogo) deve ser realizada nos exercícios do "I Blue It" para atender as metas da fisioterapia? Depende de quê?



32

8) Como obter o equilíbrio entre o desafio (exercício) e a capacidade (saúde) do paciente?



33

9) Quais as condições dos sinais de monitoramento (SatO2, FR, FC, ...) do paciente para eventual ajuste do "I Blue It"? Depende de quê?



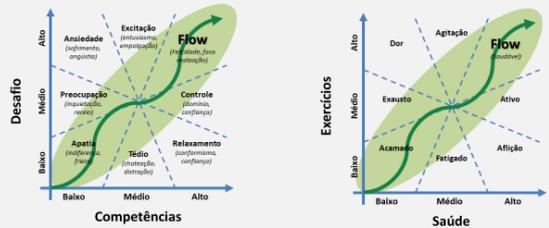
34

10) Quais informações cadastrais coletar para fazer comparações de progresso entre pacientes?



35

Flow



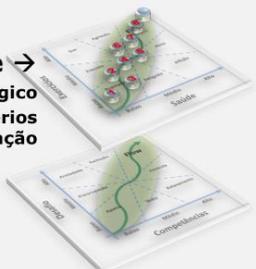
Fonte: Adaptado de: [CSIKSZENTMIHALYI, 1991 e MASSIMINI, 2012]



36

Tese →

Flow Psicofisiológico em Jogos Sérios Para Reabilitação



A IA pode ajudar a promover o Flow

1. DDA
2. ANN
3. SVM
4. GA
5. FSM
6. Fuzzy
7. DT
8. NB
9. etc.



Fonte: Adaptado de: [CSIKSZENTMIHALYI, 1991 e MASSIMINI, 2012]

37

Este espaço é destinado a quaisquer considerações entre pesquisadores e especialistas



38

Obrigado pela participação!



39

Jogo Sérioso Inteligente para Reabilitação Respiratória

Doutorando: Claudinei Dias, MSc.
Orientador: André Bittencourt Leal, PhD.
Coorientador: Marcelo da Silva Hounsell, PhD.

Programa de Pós-graduação em Engenharia Elétrica - PPGEEEL

2020-2



40

APÊNDICE C - LEVANTAMENTO DE REQUISITOS

1. Entrevista Semiestruturada com UFE

A entrevista foi realizada com dez UFE, dos quais nove eram da área da fisioterapia e um da engenharia, seguindo um roteiro de tópicos e perguntas previamente definidos. Esta metodologia de entrevista semiestruturada foi escolhida por permitir que o entrevistador tenha a flexibilidade de explorar mais profundamente as respostas dos entrevistados, além de permitir ajustar a sequência dos tópicos e perguntas conforme a necessidade, o que facilita a obtenção de *insights* detalhados e específicos (Barbosa; Silva, 2010).

O encontro foi realizado por videoconferência, começando com a apresentação dos pesquisadores e dos objetivos da pesquisa. Em seguida, foi realizada a leitura do Termo de Consentimento Livre e Esclarecido (TCLE), e com a anuência dos participantes, iniciou-se a gravação da entrevista. A discussão prosseguiu com a explanação dos principais conceitos do projeto, garantindo que todos os participantes tivessem um entendimento claro dos temas que seriam discutidos.

Os UFEs foram selecionados com base em critérios de formação acadêmica, sendo especialistas em fisioterapia atuantes em ambientes hospitalares, clínicas e como professores de curso de fisioterapia (ver Tabela 16). Essas características foram consideradas para obter uma visão abrangente e multidisciplinar sobre o uso de IA em *exergames*, assegurando que as opiniões coletadas fossem representativas e fundamentadas na experiência prática e acadêmica dos especialistas.

Tabela 16 - Frequências dos códigos sobre especialidade

Unidade de análise: Qual a sua especialidade?				
Categoria	Código	f. Códigos	Qtd. UFEs	% UFEs
Formação	Respiratória	8	8	80,0
	Cardíaca	3	3	30,0
	Engenharia Biomédica	1	1	10,0
	Neurológica	1	1	10,0
Atuação	Professor	6	6	60,0
	Hospitalar	5	5	50,0
	Clínica	1	1	10,0

Fonte: Elaborada pelo autor (2022).

2. Planejamento e Execução da Entrevista

O roteiro da entrevista foi estruturado em três tópicos principais, cada um desenhado para explorar aspectos distintos do uso da versão 4.0 do *I Blue It* na reabilitação respiratória.

- Primeiro Tópico: Abordou perguntas específicas para identificar as doenças respiratórias nas quais os exercícios propostos pelo *exergame* poderiam ser aplicáveis, além de explorar os tipos de modalidades fisioterapêuticas relevantes para esses exercícios. Esta parte da entrevista foi importante para compreender a abrangência e a aplicabilidade dos exercícios.
- Segundo Tópico: Focou em avaliar se os esforços requeridos pelos exercícios do *I Blue It* estavam adequadamente escalonados e se seguiam uma sequência fisioterapêutica adequada. Esta parte da entrevista foi projetada para verificar a progressão dos exercícios e sua adequação às práticas fisioterapêuticas.
- Terceiro Tópico: Investigou como o ajuste dinâmico de dificuldade no *I Blue It* poderia ser otimizado para manter um equilíbrio entre o desafio dos exercícios e as condições de saúde do paciente. Este tópico foi especialmente importante para entender como o jogo pode adaptar-se às necessidades e capacidades dos pacientes.

Além das perguntas estruturadas nos três tópicos, reservou-se um espaço ao final da entrevista para discussões abertas e considerações adicionais dos pesquisadores e especialistas. Este momento permitiu a troca de ideias e *insights* que poderiam não ter sido completamente abordados pelas questões estruturadas.

3. Análise de Dados

A análise de dados foi realizada com o apoio da ferramenta QDA Miner, que consiste em um método qualitativo importante na pesquisa científica, fornecendo métodos sistemáticos para inferir conhecimentos a partir de dados verbais ou escritos. Essa técnica descreve e quantifica fenômenos específicos e interpreta-os em termos de seus significados, intenções, consequências ou contextos.

Na metodologia empregada, a análise de dados coletados através de entrevistas semiestruturadas com UFE permitiu uma exploração dos *insights* e experiências dos entrevistados. Essa abordagem possibilitou uma compreensão das aplicações práticas do JSA *I Blue It* no contexto da fisioterapia respiratória. Ao analisar as respostas dos entrevistados, foi possível identificar não só as condições de doenças respiratórias mais beneficiadas pelo jogo, mas também avaliar as práticas fisioterapêuticas existentes e como o jogo pode ser integrado ou adaptado para melhor atender às necessidades clínicas dos pacientes.

O *exergame* foi discutido como uma ferramenta potencial para o treinamento da musculatura respiratória, considerando a importância do monitoramento das variáveis respiratórias para prevenir a exacerbação das condições de saúde do paciente. Os dados ajudaram a mapear o potencial de ajuste dinâmico de dificuldade do jogo, garantindo que as atividades sejam alinhadas com o equilíbrio físico e o bem-estar dos usuários.

A análise quantitativa foi realizada para complementar a análise qualitativa, oferecendo uma medida objetiva e categórica das respostas e interações com o *I Blue It*. Esta abordagem pode incluir a tabulação de frequências, médias e outras estatísticas descritivas que quantificam a pesquisa, as melhorias na capacidade respiratória dos pacientes e os padrões de uso.

No processo de coleta de dados, a diversidade das especialidades dos UFEs entrevistados é de fundamental importância, como evidenciado pela Tabela 16. Esta tabela apresenta a frequência das especialidades entre os UFEs, oferecendo uma visão da variedade de conhecimentos e perspectivas que contribuem para a pesquisa. A maioria dos UFEs, representando 80,0%, possui formação na área respiratória, destacando a relevância desta especialidade para o foco da tese. Especialistas cardíacos e de engenharia biomédica também estão representados, com 30,0% e 10,0%, respectivamente, sugerindo uma abordagem interdisciplinar no desenvolvimento do *exergame I Blue It*. A presença de um especialista neurológico enfatiza a importância de considerar uma variedade de condições de saúde que podem se beneficiar do uso do jogo.

Além da formação, a atuação dos UFEs varia entre contextos hospitalares, clínicos e acadêmicos, com a maior frequência, 60,0%, sendo profissionais que atuam como professores e 50,0% atuam em hospitais. Essa distribuição de atuação

profissional indica uma rica troca de conhecimento entre a teoria e a prática clínica, garantindo que as contribuições à tese sejam tanto práticas quanto acadêmicas.

A experiência combinada dos UFEs nas respectivas áreas de especialização e atuação contribui diretamente para o desenvolvimento da prova de conceito desta tese. A integração dessas diferentes perspectivas assegura que o *I Blue It* possa ser efetivamente adaptado para atender às necessidades diversas e complexas dos pacientes com doenças respiratórias.

A Tabela 17 apresenta dados sobre os protocolos e prescrições de exercício que podem ser realizados com o JSA *I Blue It*, direcionados ao Treinamento Muscular Respiratório (TMR).

Tabela 17 - Frequências dos códigos sobre protocolo e prescrição de exercício

Unidade de análise:				
Quais protocolos de treinamento e/ou quais parâmetros de prescrição de treinamento podem ser realizados com os recursos presentes no Jogo Digital <i>I Blue It</i> para o Treinamento Muscular Respiratório (TMR)?				
Categoria	Código	f. Códigos	Qtd. UFEs	% UFEs
Protocolos	Não explicitados	8	8	80,0
	Ciclo Ativo da Respiração	1	1	10,0
	Plazzi	1	1	10,0
Prescrição	Inspiração com Expiração	9	9	90,0
	Só inspiração	3	3	30,0
	Relaxamento	4	3	30,0
	Só expiração	2	1	10,0

Fonte: Elaborada pelo autor (2022).

A análise das frequências dos códigos Tabela 17 reflete as opiniões dos UFEs quanto à aplicabilidade do jogo na prática terapêutica. Observa-se que a maior parte dos UFEs não especificou um protocolo de treinamento particular, o que pode indicar uma preferência por abordagens individualizadas ou a necessidade de adaptar os protocolos existentes ao contexto do *exergame*. Contudo, a presença de referências a protocolos específicos como o “Ciclo Ativo da Respiração” e o “Plazzi” ressalta o potencial de integração do *I Blue It* em programas de TMR já estabelecidos.

No que diz respeito à prescrição de exercícios, a grande maioria dos UFEs indicou que a inspiração combinada com a expiração constitui um componente essencial da prescrição de treinamento, alinhando-se com as funções de exercícios respiratórios mais completos. Ainda, a prescrição de atividades focadas apenas na inspiração foi apontada por 30,0% dos UFEs, enquanto a expiração isolada foi mencionada por 10,0%. Estas prescrições específicas de respiração destacam a

necessidade de um ajuste preciso e personalizado das funcionalidades do jogo para corresponder às diversas técnicas de respiração exigidas em diferentes modalidades terapêuticas.

Além disso, o código de “Relaxamento” foi identificado como um elemento importante, reconhecendo a necessidade de integrar exercícios que promovam o relaxamento dos pacientes, evidenciando a importância do equilíbrio entre a atividade e o descanso na prática de TMR.

Essas informações auxiliam a estruturação e aperfeiçoamento do I Blue It, assegurando que o *exergame* possa ser adaptado para atender a uma variedade de necessidades terapêuticas e promover uma reabilitação respiratória efetiva e envolvente.

A Tabela 18 exibe dados relacionados às situações de progressão e regressão reconhecidas pelo *exergame* I Blue It e sua capacidade de adaptação à condição do usuário, uma funcionalidade conhecida como *Dynamic Difficulty Adjustment* (DDA). A Tabela 18 categoriza as respostas dos UFEs em termos de variáveis e decisões de DDA que devem ser reconhecidas pelo jogo para proporcionar uma experiência personalizada e terapeuticamente valiosa.

Dentre as variáveis de DDA, a “Carga” surge como a mais prevalente, mencionada em 70,0% das ocasiões pelos UFEs, destacando sua importância como um fator significativo na progressão terapêutica. O ajuste da carga é necessário para garantir que os exercícios se alinhem com a capacidade do paciente e evoluam de maneira apropriada à medida que sua condição respiratória melhora.

O “Pico de Fluxo” e a “Manutenção de Fluxo” também são considerados essenciais, embora em menor grau. Isso reflete a necessidade de reconhecer diferentes aspectos do desempenho respiratório no jogo, permitindo um treinamento que aborde tanto os picos quanto a consistência do fluxo respiratório do paciente.

A “Repetição” e a “Velocidade”, com uma duração indeterminada, foram destacadas por 50,0% e 60,0% dos UFEs, indicando que a duração e a rapidez com que os exercícios são realizados devem ser adaptáveis para manter o jogador engajado e para promover a progressão terapêutica. O ajuste do “Tempo”, com uma duração determinada, foi mencionado em 50,0% das respostas, reforçando a importância de exercícios temporizados dentro do protocolo de treinamento.

Tabela 18 - Frequência dos códigos sobre ajustes de progressão ou regressão

Unidade de análise:				
Quais as situações de progressão e regressão devem ser reconhecidas pelo I Blue It?				
Categoria	Código	f. Códigos	Qtd. UFEs	% UFEs
Variáveis DDA	Carga	14	7	70,0
	Velocidade (duração indeterminada)	7	6	60,0
	Repetição (duração indeterminada)	6	5	50,0
	Tempo (duração determinada)	7	5	50,0
	Pico de Fluxo	7	4	40,0
	Manutenção de Fluxo	7	2	20,0
Decisões DDA	Evento falha entre Sessão	9	5	50,0
	Evento de Sucesso	4	4	40,0
	Evento de falha	4	3	30,0
Ações DDA	Ajustar a Carga	10	9	90,0
	Ajustar o Tempo	5	3	30,0
	Ajustar a Altura do Alvo	5	3	20,0
	Ajustar o Tamanho do Obstáculo	3	3	20,0
	Ajustar a Frequência	1	1	10,0

Fonte: Elaborada pelo autor (2022).

As “Decisões DDA” relacionadas ao “Evento de Falha” e ao “Evento de Falha entre Sessão” foram consideradas frequentes. Isso pode sugerir uma oportunidade para explorar mais profundamente como esses eventos podem ser usados para ajustar a dificuldade e proporcionar um *feedback* significativo para os usuários.

Em relação as “Ações DDA”, destaque para “Ajustar a Intensidade/Carga” com 90,0% das menções. O ajuste de carga se destaca como sendo o mais importante elemento para promover a progressão do paciente.

Estes dados fornecem *insights* sobre como os UFEs percebem a funcionalidade de ajuste dinâmico de dificuldade do I Blue It. Eles reforçam a importância de um sistema de DDA bem definido que possa reconhecer e responder adequadamente a uma gama de variáveis fisiológicas e de desempenho, garantindo uma experiência de jogo que seja não apenas engajante, mas também terapeuticamente benéfica para os pacientes.

A Tabela 19 exibe informações sobre a ordem de ajuste das variáveis, no contexto do *exergame* I Blue It, para o treinamento muscular respiratório. A frequência dos códigos indica a importância no jogo, estabelecidas pelos UFEs para a progressão terapêutica dos pacientes.

Tabela 19 - Frequências dos códigos sobre ajustes das variáveis

Unidade de análise:				
Qual a ordem de ajuste das variáveis? (carga, tempo/repetição, velocidade)				
Categoria	Código	f. Códigos	Qtd. UFEs	% UFEs
Ordem de ajuste	Segundo (carga)	9	7	70,0
	Primeiro (velocidade)	5	5	50,0
	Setup do <i>exergame</i> (tempo/repetição)	5	5	50,0

Fonte: Elaborada pelo autor (2022).

Dos dados coletados, a “Carga” é considerada a variável mais importante e que deve ser ajustada entre as sessões de *exergame*, como indicado por 70,0% dos UFEs. Este dado sugere que o aumento ou a diminuição da resistência respiratória é o passo para priorizar a força e a capacidade dos músculos respiratórios antes de qualquer outro elemento do jogo.

A “Velocidade” das atividades é mencionada por 50,0% dos UFEs. Isso pode envolver a rapidez com que os objetivos devem ser alcançados ou a velocidade de apresentação dos estímulos, influenciando o ritmo do exercício e, conseqüentemente, a dinâmica da respiração durante o jogo. Logo, pode ser ajustada durante a sessão para desafiar o paciente e ser um elemento engajante similar ao treino de resistência.

O “Tempo” ou a duração dos exercícios é mencionada também por 50,0% dos UFEs enfatizando seu ajuste. Este aspecto ressalta a importância de modular a duração das atividades respiratórias para otimizar a resistência dos músculos respiratórios e adaptar a terapia às melhorias observadas nos pacientes. Esta variável deve ser ajustada antes do início do treinamento, sugere-se que a duração seja por número de repetições de fluxos de inspiração e expiração.

Esses dados sublinham a hierarquia nas estratégias de personalização do I Blue It, as quais devem ser cuidadosamente consideradas para assegurar uma progressão terapêutica eficaz. A importância dada a cada variável guiará os desenvolvedores e clínicos na configuração do jogo, permitindo que se adaptem às necessidades específicas de cada paciente e proporcionando um caminho claro para a evolução dentro do *exergame*.

Na Tabela 20, os dados coletados destacam a visão dos UFEs sobre como os picos e tempos de inspiração e expiração devem ser abordados no TMR dentro do contexto do *exergame* I Blue It. Os dados revelam uma inclinação significativa dos especialistas para tratar os picos e tempos de inspiração e expiração de forma

diferenciada durante as sessões de TMR, com 60,0% dos UFEs apoiando essa perspectiva.

Tabela 20 - Frequências dos códigos sobre picos e tempos respiratórios

Unidade de análise:				
Os dados (picos e tempos) de Inspiração e Expiração devem ser tratados iguais durante o TMR?				
Categoria	Código	f. Códigos	Qtd. UFEs	% UFEs
Picos e tempos de ins-ex	Diferentes	6	6	60,0
	Iguais	1	1	10,0

Fonte: Elaborada pelo autor (2022).

Este *insight* contribui para o projeto das mecânicas do jogo e para a elaboração de protocolos de TMR que considerem as distintas demandas dos exercícios de inspiração e expiração. Tal abordagem reconhece que a inspiração e expiração podem exigir diferentes níveis de esforço e técnica, refletindo a complexidade do sistema respiratório e as variadas necessidades terapêuticas dos pacientes.

Apenas 10,0% dos UFEs consideram que os picos e tempos devem ser tratados igualmente, o que sugere que, embora a abordagem unificada possa ser adequada para algumas aplicações, uma estratégia mais personalizada e ajustável é preferida. Esse reconhecimento das necessidades distintas dos dois tipos de exercício respiratório é importante para garantir que o I Blue It ofereça uma experiência de reabilitação que não só seja engajante e interativa, mas também clinicamente eficaz.

A Tabela 21 fornece informações significativas sobre como os incentivos respiratórios devem ser implementados no TMR dentro do *exergame* "I Blue It". De acordo com a análise, há uma distribuição quase equitativa entre os UFEs no que tange à estimulação de picos respiratórios e duração, e como esses dois elementos devem ser combinados durante o treinamento.

Tabela 21 - Frequências dos códigos sobre incentivos respiratórios

Unidade de análise:				
Para o TMR deve-se estimular picos e duração conjuntamente? (ou um por vez, qual o primeiro, qual o mais fácil?)				
Categoria	Código	f. Códigos	Qtd. UFEs	% UFEs
Incentivos respiratórios	Picos	6	6	60,0
	Duração	5	5	50,0
	Picos e Duração	4	4	40,0

Fonte: Elaborada pelo autor (2022).

Um pouco mais da metade dos UFEs, representando 60,0%, considera que os picos de respiração devem ser o foco principal do estímulo no TMR. Isso implica que o jogo deve ser projetado para enfatizar e reforçar a intensidade dos esforços respiratórios, possivelmente por meio de mecânicas de jogo que recompensem respirações profundas e controladas.

Por outro lado, 50,0% dos UFEs acreditam que a duração dos exercícios respiratórios é igualmente importante, sugerindo que o *exergame* também deveria incentivar os jogadores a manter uma respiração estável por um período prolongado. Isso pode ajudar a treinar a resistência dos músculos respiratórios e promover a eficiência na respiração.

Um percentual de UFEs indica que uma combinação de picos e duração deve ser estimulada, o que sugere uma abordagem multifacetada que balanceie entre os dois tipos de estímulo respiratório. Este dado reforça a necessidade de um *design* de jogo que possa alternar ou integrar diferentes tipos de estímulo de acordo com o plano de TMR personalizado para cada paciente.

Ao reconhecer a necessidade de estimular tanto os picos quanto a duração, e talvez a interação entre os dois, a experiência do jogo pode ser aprimorada para fornecer um treinamento respiratório mais holístico e eficaz.

A Tabela 22 exibe a amplitude das avaliações necessárias para complementar os dados fisiológicos coletados durante o TMR com o *exergame* I Blue It. A Tabela 22 aponta para a necessidade de uma abordagem abrangente na avaliação do progresso do paciente, que considera não só as medidas físicas, mas também o bem-estar geral.

Tabela 22 - Frequências dos códigos sobre avaliação

Unidade de análise: Existem avaliações que vão além dos dados fisiológicos e que são/devem ser regularmente analisadas?				
Categoria	Código	f. Códigos	Qtd. UFEs	% UFEs
Avaliação	Escala de Borg	10	7	70,0
	Emoções	3	3	30,0
	Psicossocial	4	2	20,0
	Balanço de Tronco	1	1	10,0

Fonte: Elaborada pelo autor (2022).

Os dados indicam que a maioria dos UFEs recomenda a utilização regular da Escala de Borg. Esta escala é um método validado para quantificar o esforço percebido do paciente, o que permite uma avaliação subjetiva do nível de dificuldade

e do esforço envolvido nas atividades respiratórias. O alto índice de recomendação desta ferramenta reflete sua importância e utilidade no contexto da reabilitação respiratória.

Embora menos frequente, a inclusão de avaliações do balanço do tronco, mencionada por 10,0% dos UFEs, sinaliza uma consciência sobre a importância da postura e do controle do corpo no sucesso do TMR. Esta avaliação pode proporcionar *insights* adicionais sobre a mecânica corporal do paciente durante os exercícios.

Avaliações que consideram as emoções e aspectos psicossociais foram apontadas por 30,0% e 20,0% dos UFEs, respectivamente. Estes dados sublinham a necessidade de abordar a experiência do paciente de maneira holística, onde o estado emocional e o contexto psicossocial desempenham um papel importante na eficácia do tratamento e na adesão ao programa de TMR.

Estas avaliações adicionais são essenciais para uma compreensão completa dos resultados do TMR, ajudando a identificar áreas que necessitam de mais atenção e permitindo ajustes personalizados no plano de tratamento.

A Tabela 23 destaca a relevância de vários sinais de monitoramento que podem influenciar o ajuste do *exergame* I Blue It, garantindo que o TMR seja seguro e eficaz para o paciente.

Tabela 23 - Frequências dos códigos sobre monitoramento

Unidade de análise:				
Quais as condições dos sinais de monitoramento (SpO2, FC, FR) do paciente para eventual “ajuste do jogo digital I Blue It”?				
Categoria	Código	f. Códigos	Qtd. UFEs	% UFEs
Sinais de monitoramento	FR	6	6	60,0
	SpO2	6	6	60,0
	FC	7	5	50,0
	Musculatura Acessória	2	2	20,0
	CO2	1	1	10,0

Fonte: Elaborada pelo autor (2022).

A Frequência Respiratória (FR) e a Saturação de Oxigênio Periférica (SpO2) seguem em importância, ambos referenciados por 60,0% dos UFEs. O monitoramento da FR e SpO2 permite que o jogo detecte sinais vitais de estresse ou desconforto durante a atividade, ajustando automaticamente o jogo para prevenir a fadiga ou o excesso de esforço, assegurando a segurança do paciente.

Os dados refletem que a Frequência Cardíaca (FC) é uma variável importante e citada pelos UFEs. Isto indica que a FC é um indicador com potencial para a adaptação da intensidade do exercício no jogo, fornecendo uma medida objetiva da resposta do paciente ao exercício e permitindo um ajuste fino do nível de dificuldade para atender às condições fisiológicas em tempo real.

A Musculatura Acessória foi mencionada por 20,0% dos UFEs, sublinhando que a observação do uso de músculos auxiliares na respiração pode indicar uma compensação por dificuldades respiratórias, o que pode ser um sinal para ajustar a dificuldade do jogo.

A menção ao CO₂ aponta para a necessidade de monitorar os níveis de dióxido de carbono, que podem ser críticos em pacientes com certas condições respiratórias, sugerindo que essa métrica pode ser útil em um cenário clínico mais controlado.

Esta análise oferece uma orientação clara sobre quais sinais de monitoramento são considerados prioritários e devem ser integrados no *design* do I Blue It para otimizar a personalização do TMR e a experiência geral do usuário. A inclusão dessas métricas no monitoramento em tempo real do jogo melhora a segurança e a eficácia do treinamento e enriquece a capacidade do sistema de ajustar dinamicamente a dificuldade para atender às necessidades individuais dos pacientes.

A Tabela 24 apresenta quais informações dos pacientes são consideradas as mais importantes pelos UFEs quando se trata de permitir comparações entre pacientes no contexto do *exergame* I Blue It. Esta análise de frequência dos códigos é essencial para compreender quais dados são prioritários no desenvolvimento de um perfil de paciente detalhado e personalizado.

Tabela 24 - Frequências dos códigos sobre paciente

Unidade de análise:				
Quais são as informações mais importantes para permitir comparação entre pacientes? (estado/região, patologias, etnias, idades, sexo, altura, peso, etc.)				
Categoria	Código	f. Códigos	Qtd. UFEs	% UFEs
Dados dos pacientes	Altura	10	7	70,0
	Patologia	8	6	60,0
	Sexo	3	3	30,0
	Peso	3	3	30,0
	Idade	2	2	20,0
	Etnia	1	1	10,0

Fonte: Elaborada pelo autor (2022).

A “Altura” é a variável mais frequentemente mencionada. Essa prevalência sublinha a relevância das características físicas na personalização dos exercícios de reabilitação respiratória, uma vez que a estatura do paciente pode influenciar diretamente a capacidade pulmonar e a mecânica respiratória.

A “Patologia” segue ressaltando que o conhecimento das condições médicas específicas do paciente é vital para adaptar o jogo às suas necessidades terapêuticas. O “Sexo” do paciente também foi destacado, sugerindo que diferenças entre gêneros podem desempenhar um papel na personalização do treinamento. Estas diferenças podem ser devido a variações na fisiologia respiratória ou na resposta ao exercício.

O “Peso” reflete uma visão de que, embora o peso seja um fator relevante quando relacionado com a “Altura”, ele pode não ser tão crítico quanto a altura ou a patologia para o ajuste do *exergame*. Finalmente, “Idade” e “Etnia” embora possam ser úteis para um entendimento mais amplo do perfil do paciente, elas podem não ser tão diretas no impacto da personalização do TMR quanto as outras variáveis.

As informações apresentadas fornecem uma compilação da entrevista realizada com os UFEs. Elas refletem o pensamento coletivo e as percepções dos UFEs, especialistas nos campos da fisioterapia e engenharia, cujas contribuições são vitais para garantir que o I Blue It seja uma ferramenta relevante, eficaz e segura para pacientes com doenças respiratórias.

Cada tabela apresentou *insights*, desde as especialidades e competências dos UFEs até as preferências sobre as métricas de monitoramento e as características dos pacientes. As frequências dos códigos destacam a importância de personalizar a experiência de reabilitação baseada em uma variedade de fatores, tais como o ajuste da carga, o equilíbrio entre os picos e tempos de inspiração e expiração, e a atenção a elementos além dos fisiológicos, como o bem-estar emocional e psicossocial dos pacientes.

APÊNDICE D - ESPECIFICAÇÃO DOS REQUISITOS

Para compreender a SRS, é essencial consultar o dicionário de parâmetros presente na Tabela 25, Tabela 26 e Tabela 27, que fornecem informações importantes sobre as diferentes etapas do *gameplay*, tornando-se uma referência para entender a estrutura e funcionamento do jogo. A coluna ‘Sigla’ refere-se à abreviação da variável utilizada; a coluna ‘Nome’ fornece o nome completo da variável; a ‘Descrição’ apresenta e uma breve definição de sua função; ‘Valores típicos’ apresenta os valores geralmente esperados ou utilizados para a variável, oferecendo uma referência para a configuração inicial e para ajustes durante as sessões de reabilitação; a coluna ‘Unid.’ consiste na unidade de medida utilizada para quantificar a variável. A Tabela 25 possui os parâmetros que devem ser definidos pelo terapeuta antes do início do *exergame*, são definições que devem ser planejadas com o plano de treinamento.

Tabela 25 - Dicionário de parâmetros definido pelo ‘Terapeuta’ antes do jogo

Sigla	Nome	Descrição	Valor padrão	Unid.
CG_{min}	Carga Mínima	Representa o menor trabalho ou esforço aplicado ao sistema respiratório, medido pelo PI_{max} (Pressão Inspiratória Máxima) ou PE_{max} (Pressão Expiratória Máxima), obtido durante a medição do dispositivo de incentivo respiratório. Utilizado para ajustar a intensidade mínima dos exercícios respiratórios.	0,3	cmH ₂ O
CG_{max}	Carga Máxima	Representa o maior trabalho ou esforço aplicado ao sistema respiratório. A carga máxima é influenciada tanto pela força exercida pelos músculos respiratórios quanto pela resistência ao fluxo de ar, medida pelo PI_{max} (Pressão Inspiratória Máxima) ou PE_{max} (Pressão Expiratória Máxima). Utilizado para limitar a intensidade máxima dos exercícios respiratórios.	0,8	cmH ₂ O
FA	Fase	Número da Fase do <i>exergame</i> , que define o tipo de objetos apresentados durante a sessão. As fases são categorizadas da seguinte forma: Fase 1: Somente Alvos. Fase 2: Somente Obstáculos. Fase 3: Alvos e Obstáculos.	1	n/a
FA_L	Falhas em Alvos	Representa o limiar máximo de falhas em interações consecutivas com alvos durante cada sessão, para que seja considerada falha no <i>exergame</i> e resulte na regressão da CG.	3	objetos
FO_L	Falhas em Obstáculos	Representa o limiar máximo de falhas em interações consecutivas com obstáculos durante cada sessão, para que seja considerada falha no <i>exergame</i> e resulte em regressão da CG.	3	objetos
FS_L	Limiar de Sessões	Representa o número limite em concluir sessões consecutivas com desempenho mínimo (LD_{min}), resultando em uma regressão ou progressão para o ajuste do plano de treinamento.	1	sessão
LD_{min}	Limiar Inferior de Desempenho	Representa o limiar mínimo de desempenho do objetivo terapêutico para manter o nível de dificuldade. Se o desempenho estiver abaixo deste valor, o nível de dificuldade deve diminuir. Este limiar garante que o paciente não enfrente desafios excessivos.	0,3	n/a
LD_{max}	Limiar Superior de Desempenho	Representa o limiar mínimo necessário para aumentar o nível de dificuldade. Se o desempenho do paciente estiver acima deste valor, o nível de dificuldade será aumentado para proporcionar desafios adequados e promover o progresso.	0,6	n/a
NI	Nível	Número do Nível dentro de uma Fase. Cada Nível é composto por 10 objetos, sendo 5 objetos para incentivar a inspiração e 5 para expiração.	1	n/a
NR	Número de Repetições	Define a quantidade de níveis em uma sessão (que corresponde ao número de séries) desejado para um determinado exercício. Representa o número objetos, refletindo na duração e intensidade do desafio.	6	objetos
OJ	Tipo de Objeto de Jogo	Especifica os tipos de objetos presentes no <i>exergame</i> , que são diretamente relacionados à fase do jogo. Os tipos de objetos podem ser alvos (1), obstáculos (2) ou uma combinação de ambos (3).	1	n/a
SA_L	Limiar de Sucesso em Alvos	Representa o limiar mínimo de desempenho em interações corretas consecutivas com alvos durante cada sessão para que seja considerado sucesso no <i>exergame</i> e permita a progressão da CG.	6	objetos
SO_L	Limiar de Sucesso em Obstáculos	Representa o limiar mínimo de desempenho em interações corretas consecutivas com obstáculos durante cada sessão para que seja considerado sucesso no <i>exergame</i> e permita a progressão da CG.	6	objetos
VL	Velocidade	Define a Velocidade dos objetos. Representa a dificuldade correspondente a um Treino de Resistência (<i>Endurance Training</i>).	1.0	u/s
γ	Constante Degrau Gama	Escalar que ajusta a altura dos alvos. Representa uma escala de ajuste de dificuldade correspondente a um Treino de Força. Define a CG com base na proporcionalidade entre a Altura do Objeto (distância na vertical) e a força requerida para alcançar o Alvo.	0,1	n/a
δ	Constante Degrau Delta	Escalar que ajusta o tamanho dos obstáculos. Representa uma escala de ajuste de dificuldade correspondente a um Treino de Força. Define a CG com base na proporção entre o tamanho do obstáculo e a força requerida para desviar do obstáculo.	0,1	n/a

Fonte: Elaborado pelo autor (2024).

A Tabela 26 possui os parâmetros que devem ser definidos pelo paciente, sendo neste caso definida antes, durante ou depois do uso do jogo. Esses parâmetros são definições que podem ser um sinal de entrada no jogo do tipo consciente ou inconsciente, com exceção da EB que é uma escala de esforço selecionada ao final de cada sessão.

Tabela 26 - Dicionário de parâmetros definido pelo 'Paciente'

Sigla	Tipo	Nome	Descrição	Valor padrão	Unid.
<i>FR</i>	Consciente	Frequência Respiratória	Número de respirações por minuto durante as atividades. Valores de referência para adolescentes e adultos.	[12 a 20]	rmp
<i>PE_{max}</i>	Consciente	Pressão Expiratória Máxima	Representa a força máxima gerada durante um esforço expiratório profundo do paciente até estabilização da medição.	[100 a 200]	cmH ₂ O
<i>PI_{max}</i>	Consciente	Pressão Inspiratória Máxima	Representa a força máxima gerada durante um esforço inspiratório máximo profundo do paciente até a estabilização da medição.	[100 a 300]	cmH ₂ O
<i>TE_{max}</i>	Consciente	Tempo de Expiração Máximo	É tempo máximo sustentado para uma expiração profunda e contínua.	[2 a 6]	s
<i>TI_{max}</i>	Consciente	Tempo de Inspiração Máximo	É o tempo máximo sustentado para uma inspiração profunda e contínua.	[1 a 3]	s
<i>FL_i</i>	Consciente	Fluxo de Inspiração	Fluxo de interação com o jogo através da inspiração.	n/a	n/a
<i>FL_e</i>	Consciente	Fluxo de Expiração	Fluxo de interação com o jogo através da expiração.	n/a	n/a
<i>SpO_{2min}</i>	Inconsciente	Saturação Periférica Mínima	Percentual de mínimo de oxigênio para continuar o exercício.	> 89	%
<i>EB</i>	Consciente	Escala de Borg	Sistema para avaliar percepção de esforço respiratório.	[0 a 10]	n/a

Legenda: Momento do jogo em que ocorre a definição do parâmetro ■ Antes ■ Durante ■ Depois

Fonte: Elaborado pelo autor (2024).

A Tabela 27 possui os parâmetros que são definidos internamente pelo *exergame*, são definições que foram implementadas no I Blue It para atender ao propósito da reabilitação respiratória, ao conceito Psicofisiológico e ao DDA.

Os parâmetros definidos no *gameplay* controlam a eficácia do DeepDDA. Eles são configurados para adaptar os desafios conforme a capacidade e as respostas do jogador durante a terapia. Esses parâmetros são necessários para a implementação efetiva do DDA, para manter o engajamento e maximizar os benefícios terapêuticos das sessões de jogo. Há um conjunto de parâmetros que são ajustados pelo terapeuta no *setup* do jogo, um conjunto que é advindo dos sinais dos dispositivos e outro que é ajustado com base na observação contínua de desempenho e nas interações do jogador. Para cada conjunto de parâmetros interdependentes é proposto um modelo matemático detalhado para assegurar que os ajustes de dificuldade sejam precisos e significativos. Os Requisitos Funcionais (RF) são apresentados com um ID no formato "RF-Número" para facilitar o controle e a consistência. Esses RF são estruturados conforme os campos definidos na Tabela 28.

Tabela 27 - Dicionário de parâmetros definido pelo 'Exergame' durante o jogo

Sigla	Nome	Descrição	Valor padrão	Unid.
CG_c	Carga Corrente	Representa o esforço durante a jogada e o progresso é avaliado entre cada sessão, decrementando ou incrementado a carga para adaptar a capacidade do paciente.	$[CG_{min}, CG_{max}]$	cmH ₂ O
DJ	Desempenho do Jogador	Índice de avaliação global definido pela relação entre o total de objetos pelo número de alvos capturados e/ou obstáculos evitados.	n/a	n/a
DO	Distância entre Obstáculos	Incrementa uma distância adicional entre obstáculos.	0,1	n/a
F^{FLOW}	Flow Fisiológico	Medida de desempenho da combinação dos elementos referentes aos biosinais do paciente.	[0 a 1]	n/a
p^{FLOW}	Flow Psíquico	Medida de desempenho da combinação dos elementos referente a pontuação no jogo.	[0 a 1]	n/a
PJ	Pontos da Jogada	Score obtido por realizar ações, como capturar alvos ou evitar obstáculos.	n/a	n/a
PO	Posição dos Objetos	Define a posição dos objetos no ambiente do jogo.	n/a	n/a
PJ_{max}	Pontuação máxima da Jogada	Pontuação máxima possível no jogo.	n/a	n/a
PJ_r	Razão da Pontuação	Índice da pontuação da jogada pela pontuação máxima possível no jogo.	n/a	n/a
TO	Posição dos Objetos	Define a tamanho dos objetos no ambiente do jogo.	n/a	n/a
VL_δ	Delta de Ajuste de Velocidade	Define o ajuste de velocidade dos objetos, influenciando no tempo de reação do jogador.	± 0.5	n/a
α	Constante Tolerância Alpha	Escalar que define um limiar de tolerância de ΔDJ , onde não ocorrem ajustes.	$[-0.1 a 0.1]$	n/a
β	Constante Tolerância Beta	Escalar que define um limiar de tolerância ΔEB , onde não ocorrem ajustes.	± 2	n/a
ΔDJ	Varição de Desempenho do Jogador	Diferença entre o desempenho do episódio atual e o do episódio anterior.	n/a	n/a
ΔEB	Varição da Escala de Borg	Diferença entre EB da sessão atual e o da sessão anterior.	n/a	n/a

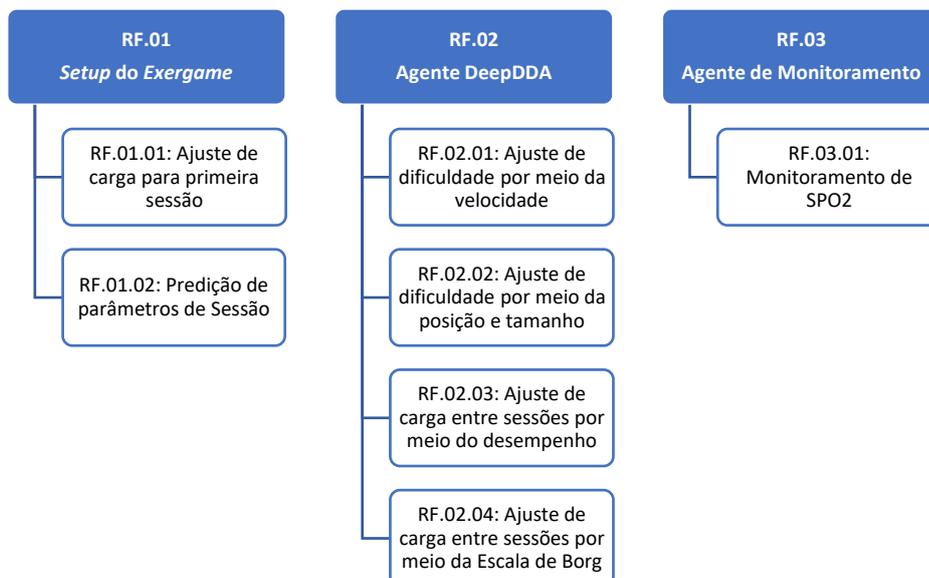
Fonte: Elaborado pelo autor (2024).

Tabela 28 - Modelo e definições padrões para os Requisitos Funcionais

ID DO RF	NOME DO REQUISITO FUNCIONAL
Descrição	Descrição do que o sistema deve fazer e o que se espera alcançar com a aplicação da IA.
Entrada	Representação atual do ambiente que a IA recebe.
Ação	Execução das ações que a IA deve tomar para satisfazer o requisito.
Saída	O resultado ou produto da ação da IA, que pode ser uma nova representação do estado ou qualquer outro resultado relevante.

O diagrama exibido na Figura 26 consolida e apresenta os RF do projeto. Este diagrama organiza os requisitos em uma estrutura categorizada, facilitando a visualização das dependências e inter-relações entre eles.

Figura 26 - Diagrama resumo dos Requisitos Funcionais



Fonte: Elaborado pelo autor (2024).

1. Predição de Setup do Exergame (RF.01)

RF.01.01	AJUSTE DE CARGA PARA PRIMEIRA SESSÃO
Descrição	Com base na medição dos dispositivos (Pitaco, ManoBD ou Cinta Estensora), deve ajustar para a primeira sessão os parâmetros das variáveis CG_{min} . O objetivo é que o esforço do paciente na primeira sessão seja o mínimo, facilitando o aprendizado cognitivo do jogo para maximizar o engajamento do paciente, garantindo uma experiência positiva e, minimizando o risco de sobrecarga e mantendo o paciente na zona do treino fisioterapêutico.
Entrada	$PI_{max}, PE_{max}, TI_{max}, TE_{max}$ (registrado na medição inicial)
Ação	Ajustar a carga $CG_t = CG_{min} * \begin{cases} PI_{max}, & \text{se Alvo e inspiração.} \\ PE_{max}, & \text{se Alvo e expiração.} \\ TI_{max}, & \text{se Obstáculo e inspiração.} \\ TE_{max}, & \text{se Obstáculo e expiração.} \end{cases}$
Saída	Carga ajustada CG_t

RF.01.02	PREDIÇÃO DE PARÂMETROS DE SESSÃO
Descrição	A IA deve recomendar os parâmetros de <i>setup</i> do jogo para personalizar o tratamento de novos pacientes. Deve usar dados do perfil do paciente, bem como dados históricos de perfil de pacientes anteriores, de modo que seja considerada a similaridade de perfil.
Entrada	Dados representados em vetores de características: X : [pacientId, patientName, condition, year, height, weight, sex, insPeakFlow, expPeakFlow, insFlowDuration, expFlowDuration, respiratoryRate, durationGame, phase, level, parameters[y']]
Ação	Execução de um Modelo de Inteligência Artificial usando o algoritmo <i>K-Nearest Neighbors</i> (KNN) para recomendação. $V(x_{new}) = \{x_i \in X \mid \text{dentre os } k \text{ menores valores de } d(x_{new}, x_i)\}$ Onde: X é a matriz de características de entrada (histórico de perfil de pacientes). d é o cálculo da distância euclidiana para. V são os perfis similares ao do novo paciente.
Saída	Recomendação do <i>setup</i> de sessão: [Fase, Nível, Número de Níveis, Velocidade, Degrau de Ajuste de Alvos, Limiar de Sucesso em Alvos, Limiar de Falhas em Alvos, Degrau de Ajuste de Obstáculos, Limiar de Sucesso em Obstáculos, Limiar de Falhas em Obstáculos]

2. Agente DeepDDA (RF.02)

RF.02.01	AJUSTE DE DIFICULDADE POR MEIO DA VELOCIDADE
Descrição	A IA deve ajustar a dificuldade do treino com base na velocidade dos objetos, proporcionando maior ou menor esforço ao paciente. O objetivo é oferecer um treino adaptativo que se ajusta em tempo real à velocidade, garantindo que o paciente experimente o nível adequado de esforço.
Entrada	Carga atual: CG_t Variação de Desempenho do Jogador: ΔDJ Número de Falhas consecutivas: F_i Número de Níveis com Sucessos: L_i
Ação	Ajustar a velocidade do exercício conforme condições a seguir: Se Alvos: $VL_{t+1} = VL_t \pm VL_\delta$ Se Obstáculos: $VL_{t+1} = \frac{VL_t}{VL_\delta}$ $VL_{t+1} = VL_t + \begin{cases} \text{Manter } VL_t, & \text{se } -\alpha \leq \Delta DJ \leq \alpha \\ -VL_\delta, & \text{se ocorrer } F_i \text{ falhas consecutivas em} \\ & \text{coletar alvos ou desviar de obstáculos.} \\ VL_\delta, & \text{se } \Delta DJ > \alpha \text{ por } L_i \text{ sucessos.} \end{cases}$ Limiars da Velocidade: $VL_{t+1} = \min(\max(VL \pm VL_\delta, VL_{min}), VL_{max})$
Saída	Velocidade ajustada VL_{t+1}

RF.02.02	AJUSTE DE DIFICULDADE POR MEIO DE POSIÇÃO E TAMANHO
Descrição	A IA deve ajustar a Carga por meio da Posição dos Objetos (PO) e do Tamanho dos Objetos (TO) do jogo. O objetivo é realizar ajustes de progressão ou regressão com base nas posições e tamanho dos objetos e capacidades respiratórias do paciente e do plano de treinamento, proporcionando o estado de Flow ao paciente.
Entrada	Carga atual: CG_t Variação de Desempenho do Jogador: ΔDJ Número de Falhas consecutivas: F_i Número de Níveis com Sucessos: L_i
Ação	<p>Ajustar os objetos na interface do jogo conforme condições a seguir: Se Alvos: $CG_t = PO_n$ Se Obstáculos: $CG_t = TO_n$</p> $CG_{t+1} = CG_t + \begin{cases} \text{Manter } CG_t, & \text{se } -\alpha \leq \Delta DJ \leq \alpha \\ -\delta * CG_t, & \text{se ocorrer } F_i \text{ falhas consecutivas em coletar} \\ & \text{alvos ou desviar de obstáculos.} \\ \delta * CG_t, & \text{se } \Delta DJ > \alpha \text{ por } L_i \text{ sucessos.} \end{cases}$ <p>Onde: PO é a posição normalizada dos Alvos com base na PI_{max} e PE_{max} do paciente; TO é o tamanho normalizado dos Obstáculos com base no TI_{max} e TI_{max} do paciente; $[CG_{min}, CG_{max}]$ são os limites de carga seguros.</p> <p>Limiares da Carga: $CG_{t+1} = \max(\min(CG_{t+1}, CG_{max}), CG_{min})$</p>
Saída	Carga ajustada CG_{t+1}

RF.02.03	AJUSTE DE CARGA ENTRE SESSÕES POR MEIO DO DESEMPENHO
Descrição	A IA deve ser capaz de ajustar a carga com base na Variação de Desempenho (ΔDJ) entre a sessão atual e a sessão anterior. O objetivo é realizar ajustes de progressão ou regressão com base plano de treinamento e nas capacidades respiratórias do paciente e condicionado ao grau de esforço da Escala de Borg selecionado pelo paciente (ver RF.02.04).
Entrada	Carga atual: CG_t Variação de Desempenho do Jogador: ΔDJ Número de Falhas consecutivas: F_i Número de Níveis com Sucessos: L_i
Ação	<p>Ajustar os objetos na interface do jogo conforme plano de treinamento e condições a seguir: Se Alvos: $CG_t = PO_n$ Se Obstáculos: $CG_t = TO_n$</p> $CG_{t+1} = CG_t + \begin{cases} \text{Manter } CG_t, & \text{se } -\alpha \leq \Delta DJ \leq \alpha \\ -\delta * CG_t, & \text{se } \Delta DJ < -\alpha \\ \delta * CG_t, & \text{se } \Delta DJ > \alpha \end{cases}$ <p>Onde: PO é a posição normalizada dos Alvos com base na PI_{max} e PE_{max} do paciente; TO é o tamanho normalizado dos Obstáculos com base no TI_{max} e TI_{max} do paciente; $[CG_{min}, CG_{max}]$ são os limites de carga seguros.</p> <p>Limiares da Carga: $CG_{t+1} = \max(\min(CG_{t+1}, CG_{max}), CG_{min})$</p>
Saída	Carga ajustada CG_{t+1}

RF.02.04	AJUSTE DE CARGA ENTRE SESSÕES POR MEIO DA ESCALA DE BORG
Descrição	A IA deve ser capaz de ajustar a carga com base na Variação da Escala de Borg (ΔEB) entre a sessão atual e a sessão anterior. O objetivo é adaptar o treinamento com base na percepção subjetiva do paciente sobre o esforço, garantindo uma experiência personalizada.
Entrada Ação	<p>Valor da Escala de Borg no final da sessão: EB</p> <p>Ajustar os objetos na interface do jogo conforme Escala de Borg (0-10) e condições a seguir: Se Alvos: $CG_t = PO_n$ Se Obstáculos: $CG_t = TO_n$</p> $CG_{t+1} = CG_t + \begin{cases} -\delta * CG_t, & \text{se } \Delta EB > \beta \\ \delta * CG_t, & \text{se } \Delta EB \leq \beta \end{cases}$ <p>Onde: PO é a posição normalizada dos Alvos com base na PI_{max} e PE_{max} do paciente; TO é o tamanho normalizado dos Obstáculos com base no TI_{max} e TI_{max} do paciente; $[CG_{min}, CG_{max}]$ são os limites de carga seguros.</p> <p>Limiares da Carga: $CG_{t+1} = \max(\min(CG_{t+1}, CG_{max}), CG_{min})$</p>
Saída	Carga ajustada CG_{t+1}

3. Agente de Monitoramento (RF.03)

RF.03.01	MONITORAMENTO DE SPO2
Descrição	A IA deve monitorar o $SpO2_t$ do paciente, identificar possíveis anomalias e emitir alerta se ultrapassar o limiar de no mínimo 89% $SpO2_t$. O objetivo é evitar que ocorra vertigem ou hiperventilação. Deve usar dados históricos do perfil do paciente.
Entrada Ação	<p>Valor da Saturação Sanguínea: $SpO2_t$</p> <p>Ajustar a velocidade do exercício conforme condições a seguir: Se Alvos: $CG_t = VL_t * VL_{fator}$ Se Obstáculos: $CG_t = \frac{VL_t}{VL_{fator}}$</p> $VL_{t+1} = VL_t + \begin{cases} \text{Manter } VL_t, & \text{se } SpO2_t \geq 95\% \\ -VL_t * VL_{fator}, & \text{se } SpO2_t < 95\% \\ \text{Suspender Sessão}, & \text{se } SpO2_t < 89\% \end{cases}$ <p>Limiares da Velocidade: $VL_{t+1} = \max(\min(VL_{t+1}, VL_{max}), VL_{min}) \mid VL_{min} = 1 \text{ e } VL_{max} = 3$</p>
Saída	<p>Para</p> <p>Pausa o <i>exergame</i> e exibe mensagem de segurança.</p> <p>Velocidade ajustada VL_{t+1}</p>

4. Atributos de Qualidade

Os requisitos descritos nos cenários de atributos de qualidade a seguir garantem a efetividade e adequação ao domínio da reabilitação.

AQ.01 CENÁRIO DE DISPONIBILIDADE	
Definição	O "I Blue It", baseado na "Arquitetura 123-SGR", deve garantir acesso contínuo e operacional no <i>exergame</i> de reabilitação.
Justificativa	A terapia é vital para a recuperação dos pacientes. Interrupções no sistema podem prejudicar o progresso.
Critérios de sucesso	<ol style="list-style-type: none"> 1. Uptime: Meta de no mínimo 95,0% de tempo de operação. 2. Recuperação Rápida: recuperação do sistema em minutos. 3. Notificações: usuários são alertados sobre possíveis interrupções. 4. Redundância: Dispositivos (como por exemplo Pitaco), e do banco de dados.
Estratégia	<ol style="list-style-type: none"> 1. Monitoramento contínuo da disponibilidade. 2. Uso da arquitetura "123-SGR" para resiliência e adaptabilidade. 3. Estabelecimento de protocolos claros de manutenção.
AQ.02 CENÁRIO DE PRECISÃO	
Definição	O "I Blue It" deve processar as entradas de dados do usuário com precisão.
Justificativa	Processamento efetivo para a satisfação do usuário.
Critérios de sucesso	<ol style="list-style-type: none"> 1. Processamento de Entrada: sistema interpreta entradas dos dispositivos com precisão. 2. Métricas: precisão do sistema. 3. Alinhamento: precisão do sistema alinha-se com as expectativas do usuário.
Estratégia	<ol style="list-style-type: none"> 1. Ênfase na precisão do algoritmo. 2. Ajuste baseado em feedback.
AQ.03 CENÁRIO DE ADAPTAÇÃO E FLEXIBILIDADE	
Definição	O "I Blue It" deve adaptar-se a diversas modalidades de interação.
Justificativa	A adaptação potencializa a reabilitação.
Critérios de sucesso	<ol style="list-style-type: none"> 1. Adaptabilidade Modal: o sistema transita entre modalidades de dispositivos. 2. Experiência do Usuário: interações sem interrupções. 3. Integração de Sinais: modalidades são integradas para dados abrangentes.
Estratégia	<ol style="list-style-type: none"> 1. Reconhecimento e adaptação a diferentes dispositivos. 2. Otimização da experiência do usuário em diferentes dispositivos.

AQ.04	CENÁRIO DE INTEROPERABILIDADE
Definição	O "I Blue It" deve monitorar os dados fisiológicos de forma precisa.
Justificativa	Monitoramento preciso, como da frequência respiratória e saturação sanguínea é para a segurança do paciente.
Critérios de sucesso	<ol style="list-style-type: none"> 1. Precisão dos Dados: Leituras das medidas fisiológicas realizadas com precisão. 2. Monitoramento em Tempo Real: características do jogo adaptam-se de acordo com dados fisiológicos. 3. Confiabilidade: aquisição e processamento de dados são consistentes. 4. Segurança do Paciente: bem-estar do paciente é priorizado.
Estratégia	<ol style="list-style-type: none"> 1. Validação dos dados para precisão. 2. Monitoramento e ajuste baseados na segurança.

A incorporação de cenários de atributos de qualidade garante a aplicabilidade do I Blue It em ambientes reais de reabilitação. Estes cenários validam a natureza centrada no paciente.

APÊNDICE E - IMPLEMENTAÇÃO DO FLOW PSICOFISIOLÓGICO

1. IMPLEMENTAÇÃO

A implementação do conceito *Flow Psicofisiológico em Jogos Digitais* é apresentada conforme o projeto definido no capítulo 4. Isso inclui a criação do módulo preditivo de *Setup do Exergame*, responsável por personalizar os parâmetros iniciais do jogo, a criação do módulo *Agente DeepDDA*, que ajusta dinamicamente a dificuldade do jogo para manter o paciente em um estado de *flow*, e do módulo de *Monitoramento de Biosinais*, que garante a segurança do paciente durante a sessão de jogo, ajustando parâmetros ou pausando o jogo conforme necessário.

1.1. MÓDULO PREDITIVO DE SETUP DO EXERGAME

O módulo preditivo de *setup do exergame* auxilia os terapeutas na criação de um exercício inicial. Este módulo usa os dados demográficos do paciente, os dados das sessões de fisioterapia de históricos de perfil de pacientes anteriores, bem como o perfil individual de cada paciente. A combinação de dados e análise preditiva facilita o início do tratamento e garante que o paciente esteja engajado de maneira apropriada desde o início. Após a IA recomendar o *setup do exergame*, o terapeuta pode realizar ajustes, se necessário, para confirmar o plano de treinamento e aplicar as configurações ao *exergame*.

1.1.1. Algoritmo Preditivo e de Recomendação

Para prever e recomendar um *setup* de jogo, é utilizado o algoritmo KNN (*K-Nearest Neighbors*) (Luger, 2013). O KNN é uma técnica de aprendizado de máquina que faz previsões com base na proximidade com outros dados no espaço de características. No contexto deste módulo preditivo, o KNN é utilizado para identificar pacientes anteriores cujos perfis são semelhantes aos do novo paciente. Analisando a similaridade com KNN, identifica-se os *k* vizinhos mais próximos (pacientes em tratamento com perfis mais próximos do novo paciente) com base em métricas de distância, que medem a proximidade entre os pontos de dados no espaço de

características e fazem a previsão com base nesses vizinhos. A partir dessa análise, é possível recomendar um *setup* inicial personalizado para o novo paciente.

A IA foi parametrizada para realizar uma busca dos 5 pacientes mais próximos do novo paciente. A implementação do KNN (Algoritmo 1) no módulo preditivo de *setup* do *exergame* segue as seguintes etapas: Transformação dos Dados; Cálculo da similaridade; Identificação dos *k*-vizinhos mais próximos; recomendação dos parâmetros.

Algoritmo 1: KNN, Predição de recomendação do setup do exergame.

```

1:  distâncias ← lista vazia
2:  para cada linha em treinamento faça
3:    valorLinhaTeste ← obterValoresLista(linhaTeste)
4:    valorLinhaTreinamento ← obterValoresLista(linha)
5:    dist ← distânciaEuclidiana(valorLinhaTeste, valorLinhaTreinamento)
6:    adicionar (linha, dist) em distâncias
7:  fim para
8:  ordenar distâncias por valor
9:  vizinhos ← lista vazia
10: para i = 1 até numVizinhos faça
11:   adicionar distâncias[i][0] em vizinhos
12: fim para
13: retornar vizinhos

```

Fonte: Elaborado pelo autor (2024).

Na linha 3 e 4 do algoritmo, são definidos a lista teste e treino que consiste nas listas de características da base de dados utilizadas pelo KNN. Na linha 6 ocorre o cálculo da distância entre as características analisadas para determinar quais são os *k*-vizinhos mais próximo às características do paciente.

Essa abordagem garante que os parâmetros iniciais recomendados sejam baseados em dados concretos e no desempenho de pacientes com perfis similares. Isso facilita o início do tratamento e garante que o paciente esteja engajado de maneira apropriada desde o início. A combinação de dados históricos e análise preditiva permite que o tratamento evolua de maneira dinâmica, adaptando-se continuamente ao progresso do paciente e proporcionando uma experiência de reabilitação mais eficiente.

As fichas exibidas na Figura 27 são recomendações dos parâmetros do jogo com base nos perfis dos pacientes similares. O terapeuta pode copiar um dos perfis ou aceitar a média ponderada dos 5 perfis similares ou, se preferir, ajustar o plano de treinamento manualmente.

Figura 27 - Recomendações de perfis de pacientes

Fase	1	Nível	1
Número de Níveis	6	Velocidade	1.00
Degrau de Ajuste de Alvos	0.10	Limiar de Sucesso em Alvos	6
Limiar de Falhas em Alvos	3	Degrau de Ajuste de Obstáculo	0
Limiar de Sucesso em Obstáculos	6	Limiar de Falhas em Obstáculos	3

COPIAR PERFIL

Fonte: Elaborado pelo autor (2024).

O resultado da predição e recomendação da IA é apresentada na Figura 28, que contém a interface de configuração dos parâmetros de *setup* do *exergame* I Blue It, permitindo que o terapeuta personalize as sessões de fisioterapia respiratória. Cada parâmetro exibido na interface tem um propósito específico, descrito conforme as tabelas de parâmetros (Tabela 25, Tabela 26 e Tabela 27).

- **Fase (FA):** determina o tipo de exercício apresentado durante a sessão do *exergame*, identificada pelos números, onde $FA = 1$ corresponde a um exercício apenas com alvos, $FA = 2$ apenas obstáculos, e $FA = 3$ com alvos e obstáculos.
- **Nível (NI):** determina o nível de dificuldade dentro de uma fase (Figura 14), cada nível é composto por 10 objetos, sendo 5 para inspiração e 5 para expiração. Valor típico para primeira sessão: 1.
- **Número de Níveis (NR):** determina o número de repetições (séries) desejado para um determinado exercício, refletindo na duração e

intensidade do desafio, corresponde a variável Número de Repetições (NR) da sessão. Range típico: 3 a 6.

- **Velocidade (VL):** determina a velocidade do fluxo de objetos no exercício. Range típico: 1 a 3.
- **Degrau de Ajuste de Alvos (γ):** é um parâmetro que ajusta a altura dos alvos, representando uma escala de ajuste de dificuldade correspondente a um treino de força, e define a carga (CG) com base na relação da altura do objeto. Range típico: 0.0 a 1.0.
- **Limiar de Sucesso em Alvos (SA_L):** define o limiar mínimo de desempenho em interações corretas consecutivas com objetos durante cada sessão para que seja considerado um sucesso no *exergame* e permita a progressão da carga. Range típico: 0 a 5.
- **Limiar de Falhas em Alvos (FA_L):** define o limiar máximo de falhas em interações consecutivas com objetos para que seja considerado uma falha, resultando em regressão da carga. Range típico: 0 a 3.
- **Degrau de Ajuste de Obstáculos (δ):** é um parâmetro que ajusta o tamanho dos obstáculos, também representando uma escala de ajuste de dificuldade correspondente a um treino de força. Range típico: 0.0 a 1.0.
- **Limiar de Sucesso em Obstáculos (SO_L):** define o limiar mínimo de desempenho em interações corretas consecutivas com obstáculos, permitindo a progressão da carga. Por fim, Range típico: 0 a 5.
- **Limiar de Falhas em Obstáculos (FO_L):** define o limiar máximo de falhas em interações consecutivas com obstáculos para que seja considerada uma falha, resultando em uma regressão da carga. Range típico: 0 a 3.

A Figura 28, exibe um exemplo de valores que resulta em uma sessão com 60 objetos. Esses parâmetros são configurados antes do início do *exergame* para definir o nível de dificuldade do plano de treinamento da sessão ou modificar a sessão caso ocorram situações adversas. A interface de configuração, como mostrada na figura, permite que o terapeuta insira os valores desejados para cada parâmetro e salve as configurações, garantindo que o setup inicial seja adequado às necessidades específicas do paciente e ajustado conforme o progresso durante a reabilitação.

Figura 28 - Parâmetros de *Setup* do *Exergame*

Fase*	1	Nível*	1
Número de Níveis (10 objetos por nível)*	6	Velocidade*	1,00
Degrau de Ajuste de Alvos*	0,10	Limiar de Sucesso em Alvos*	6
Limiar de Falhas em Alvos*	3	Degrau de Ajuste de Obstáculos*	0
Limiar de Sucesso em Obstáculos*	6	Limiar de Falhas em Obstáculos*	3

SALVAR

Fonte: Elaborado pelo autor (2024).

1.2. MÓDULO AGENTE DEEPDDA

A integração das tecnologias de aprendizado por reforço e a implementação do mecanismo do agente DeepDDA no JSA I Blue It foi realizada através de um processo em que os algoritmos de aprendizado por reforço foram gradualmente adaptados e integrados ao jogo. O uso da Unity e do pacote ML-Agents contribuiu para essa intergração, permitindo que a lógica de aprendizado por reforço e as mecânicas de jogo interagissem gradualmente com o avanço de cada etapa da implementação.

No contexto do I Blue It, o ML-Agents atua como um sistema cognitivo que aprende com cada interação do jogador. Essa aprendizagem é continuamente aplicada para ajustar a dificuldade do jogo, assegurando que os desafios propostos estejam sempre alinhados com a habilidade e a condição do jogador. A integração do aprendizado por reforço com o jogo também envolve o processamento de dados coletados pelos dispositivos, que são essenciais para avaliar a resposta fisiológica do jogador e adequar os estímulos de acordo com esses dados.

Este sistema de aprendizado por reforço é implementado de maneira a garantir que a experiência de jogo seja personalizada e evolua conforme o progresso do paciente. A capacidade do DeepDDA de adaptar os desafios do jogo com base nas

observações contínuas contribui para que o JSA I Blue It ganhe novas funcionalidades que melhore a experiência do paciente e do terapeuta.

1.2.1. Integração por Eventos de Gameplay

A Integração do DeepDDA com o I Blue It abrange desde o carregamento da cena inicial até a finalização de uma sessão de fisioterapia com *exergame*. A estrutura a seguir visa facilitar tal integração, assegurando que cada componente exerça um papel definido no fluxo do jogo.

Com o carregamento da cena principal, inicia-se a configuração do ambiente do jogo. Embora não necessária a integração direta com DeepDDA nessa etapa, ela estabelece o estado inicial do jogo, podendo influenciar a interação inicial do jogador com o sistema. Neste caso, ajustam-se os parâmetros do jogo (módulo de *setup* apresentado na seção anterior) com base na capacidade respiratória do jogador. O DeepDDA tem o papel de analisar esses dados para configurar a dificuldade inicial, assegurando que o jogo comesse em um nível dificuldade apropriado.

Os dados de medição e desempenho histórico são fundamentais para personalizar a experiência de jogo, definindo uma dificuldade inicial adequada para as fases subsequentes. Durante as fases, a dificuldade é ajustada dinamicamente com base em métricas como, DJ, NR, CG entre outras (Tabela 25, Tabela 26 e Tabela 27).

A implementação de eventos no JSA I Blue It é fundamental para ativar respostas específicas diante de condições pré-definidas durante o jogo. Esses eventos facilitam a comunicação entre o agente DeepDDA e os diversos componentes do jogo, sustentando uma arquitetura modular e responsiva. A seguir, estão expostos os eventos incorporados ao módulo do DeepDDA, cada um projetado para otimizar a interação e resposta do jogo às ações do usuário.

- *OnStageStart*: Representa o início de uma fase ou nível do jogo. Esse evento pode ser utilizado pelo DeepDDA para ajustar o nível de dificuldade no início das sessões usando as recomendações de parâmetros da IA de *setup* do *exergame* ou que foi definido pelo terapeuta manualmente.
- *OnObjectHit*: Este evento ocorre quando o jogador colide com um objeto. Ele é importante para que o DeepDDA observe a interação física entre objetos e o jogador.

- *OnDifficultyAdjustmentObjectSucceeded*: Acionado quando o jogador completa com sucesso um desafio. Esse evento ajuda o DeepDDA a adaptar a dificuldade do jogo com base nas conquistas do jogador.
- *OnDifficultyAdjustmentTargetMiss*: Disparado quando um alvo não é atingido pelo jogador. Este evento é utilizado pelo DeepDDA para ajustar dinamicamente a dificuldade do jogo, conforme os requisitos estabelecidos.
- *OnDifficultyAdjustmentObstacleHit*: Similar ao evento anterior, ocorre quando o jogador colide com um obstáculo. Esse evento permite que o DeepDDA ajuste a dificuldade com base na frequência de colisões do jogador com obstáculos.
- *OnDifficultyAdjustmentSpeed*: Utilizado pelo DeepDDA para ajustar dinamicamente a velocidade do jogo, conforme os requisitos estabelecidos e o desempenho do jogador.
- *OnTargetHitThreshold*: Evento recebido quando o limiar mínimo de desempenho em interações consecutivas com alvos é alcançado de modo que permite a progressão.
- *OnTargetMissThreshold*: Evento recebido quando o limiar mínimo de falhas em interações consecutivas com alvos ocorre de modo que resulte em uma regressão.
- *OnUpdatedPerformanceTarget*: Evento acionado quando o limiar para diminuir ou aumentar o nível de dificuldade em coletar alvos é invocado.
- *OnObstacleMissThreshold*: Evento recebido quando o limiar mínimo de desempenho em interações consecutivas com obstáculo é alcançado de modo que permite a progressão.
- *OnObstacleHitThreshold*: Evento recebido quando o limiar mínimo de falhas em interações consecutivas com obstáculo ocorre de modo que resulte em uma regressão.
- *OnUpdatedPerformanceObstacle*: Evento acionado quando o limiar para diminuir ou aumentar o nível de dificuldade em desviar de obstáculos é invocado.
- *OnUpdatedPerformanceLevel*: Evento acionado para indicar o sucesso em um nível.

- *OnStageEnd*: Representa o término de uma fase ou nível do jogo, acionado pela conclusão ou falha. Esse evento pode iniciar a transição para telas de pontuação, avaliação da Escala de Borg, reinício ou encerramento do jogo, sendo utilizado pelo DeepDDA para ajustar a carga entre sessões.

Os eventos implementados no JSA I Blue It permitem que o sistema DeepDDA responda às ações do jogador, influenciando diretamente os mecanismos de dificuldade e engajamento. Gerenciar o desempenho do jogador e disparar eventos quando certos limiares são atingidos. O sistema DeepDDA utiliza esses eventos para ajustar continuamente os parâmetros do jogo, garantindo que os desafios permaneçam adequados às habilidades do jogador. Os eventos de *gameplay* são entregues ao módulo DeepDDA para realizar as observações, para que o agente tome decisões baseadas nas observações. Dependendo da decisão, o agente então executa os ajustes de dificuldade, que podem incluir chamadas de métodos para realizar as modificações de parâmetros do jogo.

1.2.2. Algoritmos DeepDDA

O algoritmo do agente DeepDDA gerencia a lógica de aprendizado por reforço e tomada de decisão. Para isto, requer uma comunicação constante entre o jogo e os modelos de aprendizado por reforço. Para alcançar essa integração, os *scripts* do *gameplay* do I Blue It foram estendidos para incluir canais de comunicação dedicados, responsáveis pelo envio de informações do jogo para o módulo de aprendizado e pela recepção de comandos de ajuste de dificuldade.

A implementação começou com a definição das métricas de desempenho do jogador. Essas métricas foram selecionadas para serem representativas dos objetivos terapêuticos e do engajamento do jogador. Utilizando o *framework* do Unity, foram criados eventos específicos para monitorar essas métricas em tempo real e ajustar a dificuldade de acordo com os dados coletados. O sistema de DDA foi programado para interpretar essas métricas dentro de um modelo matemático, que inclui algoritmos para ponderar as mudanças de desempenho ao longo do tempo e determinar se as adaptações na dificuldade são necessárias.

O agente DeepDDA coleta uma variedade de observações que são relevantes para atender os RF descritos na seção 5.4. Isso inclui métricas de desempenho do

jogador, dados de entrada do dispositivo de controle, *feedback* do jogador, e outros indicadores-chave. Utilizando as observações coletadas, o agente decide sobre as ações que abordam os RF. Para cada ação tomada, uma recompensa correspondente é atribuída com base no impacto da ação no progresso e no desempenho do jogador. Isso incentiva o agente a aprender comportamentos que melhoram o engajamento e a eficácia do treinamento.

O Algoritmos 2, 3, 4 e 5 a seguir descrevem a função do agente *DeepDDA*, que é uma especialização da classe *Agent* da *API ML-Agents* do *Unity* no contexto de aprendizado por reforço para jogos. O papel deste agente é observar o desempenho do jogador e ajustar os parâmetros do jogo (como, velocidade e carga). O Algoritmo 2, *OnEpisodeBegin*, é chamado no início de cada episódio do agente referentes a cada um dos objetivos de progressão e às falhas que levam à regressão. Ele é responsável por reiniciar variáveis e estados do agente para configurações iniciais, como contadores e incrementos relacionados à altura e ao tamanho.

Algoritmo 2: OnEpisodeBegin()

- 1: **Início**
 - 2: Resetar o estado g1
 - 3: Resetar o estado g2
 - 4: Resetar o estado g3
 - 5: Resetar o estado de falhas alvos e obstáculos
 - 6: Resetar o estado de falhas em sessões
 - 7: **Fim**
-

Fonte: Elaborado pelo autor (2024).

O Algoritmo 3, *CollectObservations*, é chamado a cada passo do loop de execução do agente para observar e coletar dados do ambiente durante o jogo. A cada passo, ele coleta dados sobre o estado atual do jogo, como os fluxos da respiração, a pontuação do jogador, a taxa de sucesso ou falha em atingir os objetivos como coletar objetos ou desviar de objetos, entre outras variáveis relevantes. Esses dados são fundamentais para a tomada de decisões do agente.

O Algoritmo 4, *OnActionReceived*, é chamado a cada passo quando uma ação é recebida pelo agente. Dentro deste método, o agente determina o desempenho atual do paciente, identifica o estado atual do jogo e processa as ações que deve tomar. Uma estrutura de controle *switch* é usada pelo *actionBuffers* para ajustar o nível de dificuldade do jogo com base no desempenho do jogador. O *actionBuffers* dispara a decisão da política que foi treinada por aprendizado por reforço profundo. Existem

casos para manter o nível de dificuldade, diminuir o nível de dificuldade ou aumentar a dificuldade.

Algoritmo 3: CollectObservations(Sensor)

```

1: Início
2:   Sensor Observa VL
3:   Sensor Observa FA, FO, SA e SO
4:   Sensor Observa DJ e ΔDJ
5:   Sensor Observa EB
6:   Sensor Observa SpO2
7:   Sensor Observa FLi e FLe
8:   Fim

```

Fonte: Elaborado pelo autor (2024).

O algoritmo 4 exibe o padrão de ajuste de dificuldade aplicado para os elementos do *actionBuffers*: *speedAction*, *objectsAction*, *sessionAction*. O método *GetCurrentPerformance* é uma função auxiliar dentro da classe que determina o desempenho atual do jogador e o estado atual do jogo com base em critérios definidos na seção 5.6. Além dos métodos descritos, a classe pode conter métodos adicionais relacionados a eventos específicos do jogo.

Algoritmo 4: OnActionReceived(actionBuffers)

```

1: Início
2:   speedAction = vectorAction[0]
3:   objectsAction = vectorAction[1]
4:   sessionAction = vectorAction[2]
5:   Escolha speedAction
6:   Caso 0:
7:     manter nível de dificuldade
8:      $R_{t+1}^- = 0.1/NR$ 
9:     Fim do Episódio
10:  Caso 1:
11:    diminuir nível de dificuldade
12:    Se estado_atualflow == 1
13:       $R_{t+1}^+ = 1.0$ 
14:    Senão
15:       $R_{t+1}^- = 2.0$ 
16:    Fim do Episódio
17:  Caso 2:
18:    aumentar nível de dificuldade
19:    Se estado_atualflow == 2
20:       $R_{t+1}^+ = 1.0$ 
21:    Senão
22:       $R_{t+1}^- = 2.0$ 
23:    Fim do Episódio
24:  Escolha objectsAction
25:    Segue a mesma estratégia do algoritmo do objectsAction (linhas 5 a 23)
26:  Escolha sessionAction
27:    Segue a mesma estratégia do algoritmo do objectsAction (linhas 5 a 23)
28:  Fim

```

Fonte: Elaborado pelo autor (2024).

O método *GetCurrentFlowState* que é chamado a cada passo de tempo dentro do método *OnActionReceived*, é definido para obter o estado atual do desempenho do jogador e do estado do jogo. O Algoritmo 5 apresenta a lógica utilizada para avaliar o estado atual do *Flow*, determinado com base no desempenho atual do paciente em termos de variáveis do *flow* psicofisiológico e aplicando a variação do desempenho. Esse algoritmo, retorna '2' se em função *DJ* for menor que '0.3' indicando que a dificuldade do jogo está difícil (esforço exigido alto versus capacidade do paciente baixa), retorna '1' se $DJ \geq LD_{min}$ e $\Delta DJ \in [-\alpha, \alpha]$ indicando que a dificuldade do jogo está na zona do *flow*, retorna '0' se $DJ \geq LD_{min}$ indicando que a dificuldade do jogo é fácil (esforço exigido baixo versus capacidade do paciente alta) ver diagrama do *Flow* Psicofisiológico (Figura 9).

Algoritmo 5: estado_atual_flow()

```

1:  $w_1 = w_2 = 0.5$ ;
2:  $FP(t) = \text{equação 4.6}$ 
3:  $FF(t) = \text{equação 4.7}$ 
4:  $DJ(t) = w_1 \cdot FP(t) + w_2 \cdot FF(t)$ ;
5:  $\Delta DJ = DJ_t - DJ_{t-1}$ ;
6: Se  $DJ < 0.3$  então
7:   Retorne 2;
8: Senão Se  $DJ \geq LD_{min}$  E  $\Delta DJ \in [-\alpha, \alpha]$  então
9:   Retorne 1;
10: Senão Se  $DJ \geq LD_{max}$  E  $\Delta DJ > 0.1$  então
11:   Retorne 0;

```

Fonte: Elaborado pelo autor (2024).

Para a ação definida pelo *actionBuffers[speedAction]*, utilizam-se as especificações do modelo matemático do RF-02.02, onde se deve relacionar o esforço em um treino de resistência à velocidade do *exergame VL*, considerando que o desempenho do jogador *DJ* já está definido pela equação (7.5) e velocidade deve permanecer dentro do intervalo seguro com a inclusão de uma fator de ajuste VL_{fator} conforme A_t determinada pelo DeepDDA.

Para as ações definidas pelos *actionBuffers[objectsAction, sessionAction]*, utilizam-se as especificações do modelo matemático dos RF-02.01, RF-02.03 e RF-02.04, onde se deve relacionar a carga CG_t à posição do objeto *PO* e ao tamanho do objeto *TO*, considerando que o desempenho do jogador *DJ* já está definido pela equação (7.5) e que as variáveis *PO* e *TO* já foram normalizadas em termos de *CG*. A

carga CG_t deve permanecer dentro do intervalo seguro CG_{min} e CG_{max} , com a inclusão de um fator de ajuste δ conforme A_t determinada pelo DeepDDA.

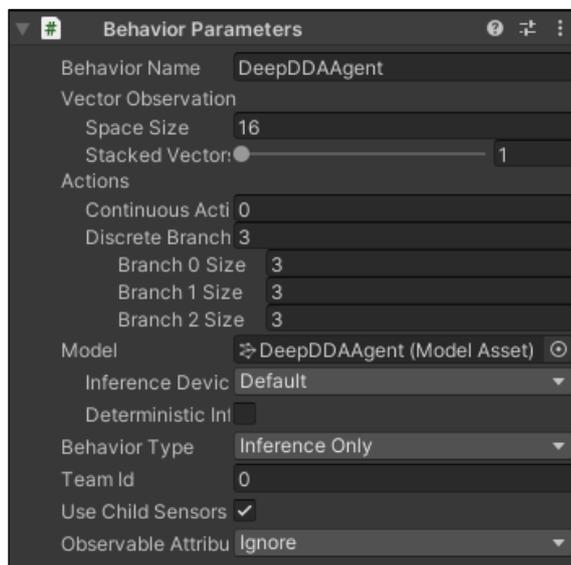
Foi implementada a classe *DeepDDAManager*, que estende a funcionalidade do *DeepDDAAgent* e adiciona eventos e métodos específicos para DDA. Esta classe é responsável por gerenciar os parâmetros que ajustam os níveis de dificuldade do jogo e responde aos eventos de desempenho do paciente disparados pelas classes de *gameplay* ou pelo próprio agente, garantindo que os níveis de dificuldade sejam adequados às necessidades terapêuticas.

DeepDDAManager define os seguintes métodos para executar as ações de manter o nível de dificuldade, diminuir o nível de dificuldade ou aumentar o nível de dificuldade, que são chamados no Algoritmo 4 com base no desempenho do paciente em um estado S_t e nos objetivos $\{g1, g2, g3\}$ determinados pelo terapeuta no plano de treinamento do paciente:

- *SpeedAdjustment*: Este método ajusta a velocidade dos objetos. Ele aumenta ou diminui a velocidade dentro de limites predefinidos.
- *AdjustObjects*: Este método ajusta a posição e o tamanho dos objetos com base no tipo de objeto e no limiar de falhas ou sucesso. Ele distingue entre alvos e obstáculos, ajustando os incrementos de altura e tamanho de acordo com o desempenho do paciente.
- *LevelSucceeded*: Este método é chamado quando um nível é completado com sucesso, incrementando os parâmetros de desempenho.
- *SessionSucceeded*: Este método é chamado quando uma sessão é completada com sucesso, incrementando os parâmetros de desempenho.
- *AdjustBorgScaleLoad*: Este método ajusta a carga com base na Escala de Borg, aumentando ou diminuindo a dificuldade com base na percepção de esforço do paciente.

O agente DeepDDA observa o desempenho do jogador para realizar ajustes de dificuldade do jogo. A análise de desempenho no término de cada fase ajusta a dificuldade das sessões futuras. O DeepDDA decide sobre ajustes necessários, promovendo o estado de *Flow* e evitando frustrações no jogador. A Figura 29 exibe a configuração dos parâmetros de comportamento do agente *DeepDDAAgent* do script *BehaviorParameters*.

Figura 29 - Parâmetros de Comportamento do Agente DeepDDA



Fonte: Elaborado pelo autor (2024).

A seguir, apresenta-se os principais parâmetros e suas funções no contexto do ajuste dinâmico de dificuldade para a reabilitação respiratória.

- *Vector Observation (Space Size: 16)*: Esta configuração determina o tamanho do espaço de observação vetorial. Neste caso, o agente observa dezesseis variáveis, que podem incluir métricas fisiológicas do paciente, como fluxo respiratório, saturação sanguínea, além de métricas psíquicas com parâmetros do ambiente do JSA I Blue It.
- *Stacked Vectors (1)*: Define o número de vetores de observação empilhados. Com um valor de 1, o agente trabalha com um único vetor de observação por decisão.
- *Actions*: As ações do agente são divididas em ramos discretos, com quatro ramos especificados. Cada ramo pode representar uma ação distinta que o agente pode tomar, como ajustar a carga ou a velocidade dos exercícios.
- *Branch 0, 1 e 2 Size (3)*: Estes ramos são configurados para três possíveis ações (manter, diminuir ou aumentar), respectivamente, a carga durante a sessão, a velocidade do exercício, a carga da próxima sessão e a carga da próxima sessão por meio da Escala de Borg.
- *Model*: É o modelo de aprendizado por reforço que foi gerado pelo ML-Agents com base nas implementações do projeto do DeepDDA.

- *Inference Device (Default)*: O dispositivo de inferência padrão será utilizado para realizar cálculos e tomar decisões. Pode ser configurado para usar CPU ou GPU, dependendo dos recursos disponíveis e da complexidade do modelo.
- *Deterministic Inference*: Quando habilitada, esta opção garante que o comportamento do agente seja determinístico, ou seja, as mesmas observações sempre resultarão nas mesmas ações, útil para testes e validações.
- *Behavior Type (Default)*: Define o tipo de comportamento do agente. O tipo padrão é utilizado aqui, mas pode ser configurado para comportamento específico conforme necessário.

1.2.3. Algoritmo de Monitoramento

O monitoramento da Saturação do Oxigênio (SpO2) garante a segurança dos pacientes durante o uso do *exergame* I Blue It. A SpO2 é monitorada continuamente para ajustar o nível de dificuldade do jogo conforme a condição fisiológica do paciente, evitando riscos à saúde. A implementação (Algoritmo 6) utiliza um sensor de oximetria de pulso que captura dados em tempo real. A resposta ao estímulo é ajustada dinamicamente: se a SpO2 cair abaixo de 95%, a velocidade do jogo é reduzida (linha 4 do Algoritmo 6); se cair abaixo de 89% (linha 9 do Algoritmo 6), o jogo é interrompido para evitar desconforto ou danos ao paciente. A integração dos dados de SpO2 no modelo matemático é realizada através de algoritmos que calculam recompensas ou penalidades baseadas nos níveis de oxigênio.

Algoritmo 6: Monitor e Feedback

```

1:  para cada quadro do jogo faça
2:    se oxímetro conectado então
3:      Monitor(SpO2)
4:      se  $(Regular_{min} \leq SpO2 \leq Normal_{min})$  então
5:        se  $countSPORegular \geq limiteRegular$  então
6:          Executa PaineAviso() e PauseJogo()
7:          Adicione recompensa  $R_{t+1} -= 0.5$ 
8:          Reduz Velocidade dos Objetos  $VL_{t+1} = VL_t * VL_{fator}$ 
9:        senão se  $SpO2 < Regular_{min}$  então
10:         Executa PaineAviso() e InterrompeJogo()
11:         Adicione recompensa  $R_{t+1} -= 1.0$ 
12:        senão
13:         Adicione recompensa  $R_{t+1} += 0.5$ 
14:      atualize SpO2

```

Fonte: Elaborado pelo autor (2024).

A implementação do código de monitoramento da SpO2 no projeto I Blue It é executada continuamente, garantindo uma resposta rápida e precisa a quaisquer alterações na condição do paciente, ao atingir um limite regular predefinido, o jogo exibe um painel de aviso e pausa, aplicando uma recompensa negativa e reduzindo a velocidade dos objetos. Se a SpO2 cair abaixo do mínimo regular, um segundo painel de aviso é exibido, aplicando uma penalidade maior e interrompendo o jogo.

A Escala de Borg (*EB*) de Percepção de Esforço (Figura 30) é uma ferramenta fundamental utilizada para medir a intensidade do esforço percebido pelo paciente durante os exercícios no *exergame*. A escala varia de 0 a 10, onde 0 representa "Nenhum esforço" e 10 "Muito intenso". Esta escala é especialmente útil para ajustar o nível de dificuldade dos exercícios de forma dinâmica, baseada no *feedback* direto do paciente. Após cada sessão, o paciente avalia o seu esforço utilizando a Escala de *Borg*, e essa informação é registrada no banco de dados junto ao histórico da sessão. A seguir, a definição de cada escala (Jensen; Karoly; Braver, 1986):

- 1) **Nenhum:** Sem esforço. Posso manter durante horas.
- 2) **Muito leve:** Esforço demasiadamente fácil manter.
- 3) **Leve:** Esforço fácil de manter.
- 4) **Leve-moderado:** Esforço mínimo.
- 5) **Moderado:** Esforço moderado e sem perder o fôlego.
- 6) **Moderado-forte:** Sinto um cansaço moderado.
- 7) **Forte:** Sinto um esforço desafiador.
- 8) **Muito Forte:** Esforço no limite do desconfortável.
- 9) **Intenso:** Sinto um esforço difícil de manter.
- 10) **Muito intenso:** Sinto cansaço grande.

Figura 30 - Escala de Borg



Fonte: Elaborado pelo autor (2024).

O grau de intensidade do esforço definido pelo paciente pela *EB* é armazenado no perfil do paciente e a ΔEB , que é a diferença entre as avaliações *EB* de duas sessões consecutivas, é utilizado pelo agente DeepDDA para ajustar o nível de dificuldade dos exercícios. Se a ΔEB indicar um aumento significativo no esforço percebido, o agente pode optar por reduzir a dificuldade na próxima sessão, garantindo que o paciente não se sinta sobrecarregado. Inversamente, se o esforço percebido for baixo, o agente pode aumentar a dificuldade para garantir que o paciente esteja desafiado de forma adequada. Este feedback contínuo e adaptativo ajuda a manter o paciente engajado e seguro durante o tratamento.

1.2.4. Treinamento do Agente DeepDDA

O treinamento do modelo DeepDDA foi executado com o toolkit do ML-Agents, que realiza a implementação de algoritmos de aprendizado por reforço em ambientes de jogos no Unity. O Algoritmo 7 exibe os parâmetros utilizado no aprendizado por reforço. A linha 3 exibe a escolha do algoritmo treinador PPO (*Proximal Policy Optimization*), que foi escolhido devido à sua eficácia em lidar com grandes espaços de estados e ações, garantindo estabilidade e desempenho eficiente durante o treinamento.

Algoritmo 7: hiperparâmetros de treinamento

```

1: behaviors:
2:   DeepDDAAgent:
3:     trainer_type: ppo
4:   hyperparameters:
5:     batch_size: 2048
6:     buffer_size: 20480
7:     learning_rate: 1.0e-4
8:     beta: 5.0e-3
9:     epsilon: 0.2
10:    lambda: 0.95
11:    num_epoch: 5
12:    learning_rate_schedule: linear
13:    beta_schedule: constant
14:    epsilon_schedule: linear
15:  network_settings:
16:    normalize: true
17:    hidden_units: 256
18:    num_layers: 2
19:  reward_signals:
20:    extrinsic:
21:      gamma: 0.99
22:      strength: 1.0
23:    max_steps: 5e5
24:    time_horizon: 256
25:    summary_freq: 10000
26:    keep_checkpoints: 5
27:    checkpoint_interval: 100000

```

Fonte: Elaborado pelo autor (2024).

O ML-Agents utiliza um arquivo “trainer_config.yaml” que controla os hiperparâmetros usados pelo algoritmo de treinamento PPO (Tabela 29), que são definidos antes do início do treinamento e determinam o comportamento de aprendizado.

A Tabela 29 apresenta as descrições dos hiperparâmetros utilizados pelo cérebro da IA de DDA.

Tabela 29 - Hiperparâmetros de Treinamento com PPO

Parâmetro	Valor	Descrição
trainer_type	PPO	Especifica qual tipo de algoritmo de treinamento será utilizado.
summary_freq	10000	Número de experiências a serem coletadas antes de gerar e exibir estatísticas de treinamento. Define a granularidade dos gráficos no <i>TensorBoard</i> , controlando a frequência de atualização das métricas.
time_horizon	256	Define o número de etapas de experiência a serem coletadas antes de transferi-las para o buffer. Se atingido antes do episódio terminar, uma estimativa de valor prevê a recompensa total esperada. Horizontes longos têm menos viés, mas maior variância; horizontes curtos têm mais viés, mas menor variância. Range típico: 32 a 2048
max_steps	5e5	Número total de etapas (observações e ações) a serem coletadas no ambiente antes de encerrar o treinamento. Range típico: 5e5 a 1e7
keep_checkpoints	5	Número máximo de pontos de verificação (<i>checkpoints</i>) do modelo a serem mantidos.
checkpoint_interval	1e5	Intervalo de etapas entre a criação de pontos de verificação do modelo. Ajuda a preservar o estado do treinamento em diferentes estágios para possível recuperação e análise.
learning_rate	1.0e-4	Taxa de aprendizado inicial para atualização via descida de gradiente. Define a magnitude de cada ajuste. Pode ser reduzida se o treinamento for instável ou as recompensas não aumentarem consistentemente. Range típico: 1e-5 a 1e-3
batch_size	2048	Número de experiências processadas em cada iteração de descida de gradiente. Deve ser menor que <i>buffer_size</i> . Para ações contínuas, valores maiores são recomendados, entre 512 e 5120 para PPO. Para ações discretas, valores menores são preferíveis, entre 32 e 512. Range típico: 512 a 5120
buffer_size	20480	Número de experiências a serem coletadas antes de atualizar a política. Deve ser várias vezes maior que o <i>batch_size</i> para garantir atualizações mais estáveis. Range típico: 2048 a 409600
learning_rate_schedule	linear	Define como a taxa de aprendizado deve mudar ao longo do tempo, reduzindo-a linearmente até chegar a zero em <i>max_steps</i> para garantir uma convergência mais estável.
hidden_units	256	Número de neurônios nas camadas ocultas da rede neural. Problemas simples podem usar menos unidades, enquanto problemas complexos exigem mais para capturar interações intrincadas entre variáveis. Range típico: 32 a 512
num_layers	2	Número de camadas ocultas na rede neural. Menos camadas são adequadas para problemas simples, enquanto problemas mais complexos podem exigir mais camadas para capturar interações detalhadas entre variáveis. Range típico: 1 a 3
beta	5.0e-3	Força da regularização da entropia que controla a aleatoriedade da política, incentivando a exploração do espaço de ação. Valores mais altos promovem mais exploração, enquanto valores mais baixos reduzem a aleatoriedade. Deve ser ajustado para que a entropia diminua gradualmente à medida que a recompensa aumenta, monitorável no <i>TensorBoard</i> . Range típico: 1e-4 a 1e-2
epsilon	0.2	Define o limite aceitável de divergência entre políticas antigas e novas durante a atualização por gradiente. Valores menores proporcionam atualizações mais estáveis, enquanto valores maiores permitem mudanças rápidas, mas podem resultar em comportamento errático. Range típico: 0.1 a 0.3
Gamma	0.99	O hiperparâmetro gamma determina o valor das recompensas futuras no cálculo de políticas. Valores altos de gamma fazem com que as recompensas futuras sejam mais consideradas na decisão das ações, enquanto valores baixos favorecem recompensas imediatas. Range típico: 0.90 a 0.99
Strength	1.0	Define a influência do sinal de recompensa extrínseca durante o treinamento. Valores mais altos aumentam o impacto das recompensas externas na atualização da política do agente, enquanto valores mais baixos reduzem essa influência. Range típico: 0.0 a 1.0
beta_schedule	constant	Determina como o beta muda ao longo do tempo. Linear, decai beta linearmente, atingindo 0 em <i>max_steps</i> , enquanto constant mantém a constante beta durante todo o treino. Se não for definido explicitamente, a programação beta padrão será definida como <i>hyperparameters -> learning_rate_schedule</i> .
epsilon_schedule	linear	Define a variação do epsilon ao longo do tempo (para PPO). Linear reduz gradualmente o valor até zero em <i>max_steps</i> . Constant mantém o valor fixo durante todo o treinamento. Se não especificado, segue o <i>learning_rate_schedule</i> .
lambd	0.95	Regulariza a Estimativa de Vantagem Generalizada (GAE), equilibrando a confiança entre a estimativa de valor atual e recompensas reais do ambiente. Valores menores confiam mais na estimativa atual, enquanto valores maiores se baseiam nas recompensas recebidas. Range típico: 0.9 a 0.95
num_epoch	5	Número de passagens pelo buffer de experiência ao otimizar por descida de gradiente. Lotes maiores permitem mais passagens, enquanto menos passagens proporcionam atualizações mais estáveis, embora desacelerem o aprendizado. Range típico: 3 a 10

Fonte: Unity Technologies (2024).

O DeepDDA integra uma abordagem ator-crítico (Schulman *et al.*, 2017), onde o ator é responsável por decidir as ações com base no estado atual do ambiente, enquanto o crítico estima o valor esperado das recompensas futuras. Esse arranjo permite que o modelo ajuste a dificuldade dos exercícios de forma precisa, promovendo um equilíbrio ideal entre desafio e capacidade do paciente. Durante o treinamento, o agente coleta dados sobre o desempenho do paciente e utiliza essas informações para refinar continuamente sua política, visando otimizar a experiência de reabilitação.

No algoritmo PPO para treinamento (Algoritmo 10), a ‘função ator’ é responsável por selecionar as ações que o agente deve tomar com base no estado atual do ambiente. A ‘função crítico’ avalia a política do ator, estimando o valor esperado das recompensas futuras a partir de um determinado estado ou par estado-ação. No algoritmo PPO, o estilo ator-crítico é implementado da seguinte forma:

- Ator (Função de Política $\pi\theta$): A política é atualizada usando um objetivo substituto com *clipping* para garantir que as atualizações não sejam muito grandes.
- Crítico (Função de Valor $V\phi$): A função de valor é atualizada para fornecer melhores estimativas das recompensas futuras, ajudando a calcular a vantagem necessária para a atualização da política.

Algoritmo 8: PPO, estilo Ator-Crítico

```

1:  para iteração = 1, 2, ... faça
2:    para ator = 1, 2, ..., N faça
3:      Execute a política  $\pi_{\theta_{old}}$  no ambiente por T passos de tempo
4:      Calcule as estimativas de vantagem  $\hat{A}_1, \dots, \hat{A}_T$ 
5:    fim para
6:    Otimize o surrogate L em relação a  $\theta$ , com K épocas e tamanho de minibatch  $M \leq NT$ 
7:     $\theta_{old} \leftarrow \theta$ 
8:  fim para

```

Fonte: Elaborado pelo autor (2024).

No *loop* de Iteração principal, o algoritmo PPO itera várias vezes, onde cada iteração corresponde a uma atualização da política do agente. No *loop* de ator, a cada ator, a Política atual ($\pi\theta_{old}$) é executada no ambiente por T passos de tempo, aqui está implícita a ANN de Política (linha 3 do Algoritmo 8). Durante esses T passos de tempo, o ator coleta dados sobre os estados, ações e recompensas, e calcula as estimativas de vantagem ($\hat{A}_1, \dots, \hat{A}_T$), aqui está implícita a ANN de Valor (linha 4 do Algoritmo 8).

Após coletar os dados dos N atores, a função objetivo "surrogate" (L) é otimizada em relação aos parâmetros da política (θ) usando K épocas de gradiente estocástico em *minibatches* (\cdot) de tamanho M , onde M é menor ou igual a NT (número total de amostras coletadas). Após a otimização, os parâmetros antigos da política ($\pi_{\theta_{old}}$) são atualizados com os novos parâmetros (θ).

Quando o processo de treinamento é concluído, o modelo DeepDDA é salvo e pode ser inserido no projeto do Unity para gerar a versão final do jogável com DDA.

1.3. CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo, foram detalhadas as etapas de implementação de prova de conceito do módulo DeepDDA no sistema JSA I Blue It. A implementação incluiu a definição de modelos matemáticos para o DDA advindos das especificações dos requisitos que demonstraram como as variáveis de posição do objeto (PO), tamanho do objeto (TO) e velocidade (VL) influenciam a carga. Os algoritmos desenvolvidos foram fundamentados em aprendizado por reforço profundo, permitindo ajuste do nível de dificuldade dos exercícios.

A integração do módulo DeepDDA com o sistema JSA I Blue It foi realizada de forma a garantir a interoperabilidade dos ajustes dinâmicos de dificuldade. Foram implementadas interfaces de comunicação entre os módulos, permitindo a transferência de dados em tempo real e a aplicação dos ajustes necessários com base no desempenho do paciente. O próximo passo envolve a validação desses modelos e a avaliação.