



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CAMPUS FLORIANÓPOLIS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE AUTOMAÇÃO E
SISTEMAS

Renan da Silva Tchilian

Plataforma de Simulação de Interação Humano-*Swarm* Robótico: Uma
abordagem centrada no humano

Florianópolis
2023

Renan da Silva Tchilian

**Plataforma de Simulação de Interação Humano-*Swarm* Robótico: Uma
abordagem centrada no humano**

Tese submetida ao Programa de Pós-Graduação
em Engenharia de Automação e Sistemas da Uni-
versidade Federal de Santa Catarina para a obten-
ção do título de doutor em Engenharia de Automa-
ção e Sistemas.

Orientador: Prof. Ubirajara Franco Moreno, Dr.

Coorientadora: Profa. Mariana Netto, Dra.

Florianópolis

2023

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Tchilian, Renan da Silva

Plataforma de simulação de interação humano-swarm robótico
: uma abordagem centrada no humano / Renan da Silva
Tchilian ; orientador, Ubirajara Franco Moreno,
coorientador, Mariana Netto, 2023.

114 p.

Tese (doutorado) - Universidade Federal de Santa
Catarina, Centro Tecnológico, Programa de Pós-Graduação em
Engenharia de Automação e Sistemas, Florianópolis, 2023.

Inclui referências.

1. Engenharia de Automação e Sistemas. 2. Interação
Humano-Swarm. 3. Senso de Agência. 4. Sistemas de
Controle em Rede. I. Franco Moreno, Ubirajara. II. Netto,
Mariana. III. Universidade Federal de Santa Catarina.
Programa de Pós-Graduação em Engenharia de Automação e
Sistemas. IV. Título.

Renan da Silva Tchilian

Plataforma de Simulação de Interação Humano-Swarm Robótico: Uma abordagem centrada no humano

O presente trabalho em nível de doutorado foi avaliado e aprovado por banca examinadora composta pelos seguintes membros:

Prof. Jês de Jesus Fiais Cerqueira, Dr.
Universidade Federal da Bahia

Prof. André Schneider de Oliveira, Dr.
Universidade Tecnológica Federal do Paraná

Prof. Marcelo Ricardo Stemmer, Dr.
Universidade Federal de Santa Catarina

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do título de doutor em Engenharia de Automação e Sistemas.

Prof. Julio Elias Normey Rico, Dr.
Coordenador do Programa

Prof. Ubirajara Franco Moreno, Dr.
Orientador

Florianópolis, 4 de Julho de 2023.

Dedico este trabalho aos meus pais Vartan e Neusa e à
minha esposa Mariangela, em especial pela dedicação
e apoio em todos os momentos difíceis.

AGRADECIMENTOS

Ao Programa de Pós-Graduação em Engenharia de Automação e Sistemas, pela oportunidade de realização de trabalhos em minha área de pesquisa.

Ao orientador Prof. Dr. Ubirajara Franco Moreno pelo acompanhamento pontual e competente sempre se mostrando muito solícito.

Aos professores do curso de Pós-Graduação e aos colegas do programa pelo seu auxílio nas tarefas desenvolvidas durante o curso e apoio na revisão deste trabalho.

À Universidade Federal de Santa Catarina.

À CAPES e o CNPq, pela provisão da bolsa de doutorado. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001 e pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico - Brasil (CNPq) - Proc. 142353/2020-5.

E à Profa. Dra. Mariana Netto, ao departamento PICS-L (Le Laboratoire Perceptions, Interactions, Comportements & Simulations des usagers de la route et de la rue) e à Université Gustave Eiffel por me receberem durante meu estágio doutoral.

*“Existem três classes de pessoas que são infelizes:
a que não sabe e não pergunta,
a que sabe e não ensina
e a que ensina e não faz.”
(Siddhartha Gautama)*

RESUMO

A automação completa pode ser alcançada em ambientes que podem ser previstos com alta precisão e onde as consequências de falhas são aceitáveis. Porém, em ambientes mais complexos e imprevisíveis, é necessária alguma forma de controle humano para obter desempenho adequado na tarefa geral para a qual os robôs foram projetados. A tendência nos sistemas robóticos controlados por humanos é afastar-se do atual paradigma muitos-para-um, onde vários operadores são obrigados a controlar um único sistema, para um modo de operação um-para-muitos no qual um único operador pode controlar um grande número de veículos autônomos. O recente interesse pela experiência do operador como o senso de agência e a notável atividade recente de investigação na interação deste operador com *swarms* de robôs, designado por sistemas de Interação Humano-*Swarm* (IHS), trazem novos desafios e abrem novas perspectivas para interpretar e contrabalançar as dificuldades que surgem em sistemas altamente automatizados, principalmente em sistemas que requerem cooperação homem-máquina. Sabe-se que a automação pode modificar o senso de agência e essas mudanças podem impactar no desempenho do operador e na adequação do sistema. O conceito de agência, portanto, nos fornece novas ferramentas conceituais e medidas para melhorar e otimizar o design, controle e interação desses sistemas. Nesta tese é proposto o desenvolvimento de uma plataforma de simulação para aplicar o framework de agência ao campo de IHS e, além disso, são propostos três tipos de sistemas de teleoperação assistida. Como prova de conceito, a plataforma é empregada para avaliar como o nível de automação influencia o reconhecimento e gerenciamento de tal sistema pelo operador.

Palavras-chave: Interação Humano-*Swarm*. Sistemas de Controle em Rede. Controle Compartilhado. Problema de Desempenho Fora da Malha. Senso de Agência.

ABSTRACT

Complete automation can be achieved in environments that can be predicted with high precision and where the consequences of failure are acceptable. However, in more complex and unpredictable environments, some form of human control is necessary to obtain adequate performance in the general task for which the robots were designed. The trend in human-controlled robotic systems is to move away from the current many-to-one paradigm, where multiple operators are forced to control a single system to a one-to-many mode of operation in which a single operator can control a large number of autonomous vehicles. The recent interest in the experience of the operator as the sense of agency and the notable recent research activity in the interaction of this operator with robot swarms, referred as human-swarm interaction systems (HSI), brings new challenges and opens novel perspectives to interpret and counterbalance the difficulties that arise in highly automated systems, mainly in systems that require human-machine cooperation. It is known that the automation can modify the agentive experience and these changes can impact on the operator performance and on the system suitability. The concept of agency, thus, provides us with new conceptual tools and measures to improve and optimize the design, control and interaction of these systems. In this thesis it is proposed the development of a simulation platform to apply the framework of agency to the HSI field and, in addition, three types of assisted teleoperation systems are proposed. As a proof of concept, the platform is employed to assess how the level of automation influences an operator acknowledgement and management of such system.

Keywords: Human-Swarm Interaction. Networked Control Systems. Shared Control. Out-Of-The-Loop Performance Problem. Sense of Agency.

LISTA DE FIGURAS

Figura 1 – Matriz de Sistemas & Controle: Cinco desafios críticos da sociedade por sete desafios principais de pesquisa e inovação.	17
Figura 2 – Possíveis funções humanas na arquitetura de controle da equipe de robôs.	27
Figura 3 – Escala Níveis de Autonomia da interação humano-robô.	32
Figura 4 – Ilustração de teleoperação do <i>swarm</i> em um cenário compartilhado com pedestres (Link para o vídeo ilustrativo: https://t.ly/kaXi).	37
Figura 5 – Exemplo de interface para o Sistema de Suporte à Teleoperação (SST) preditivo. As linhas azuis representam a conexão do robô teleoperado com os vizinhos e a linha branca a trajetória sugerida para aquele instante de tempo.	47
Figura 6 – Arquitetura de simulação.	51
Figura 7 – <i>Joystick</i> utilizado na tarefa de teleoperação.	52
Figura 8 – Cenário da praça da cidade.	52
Figura 9 – Tela do operador	53
Figura 10 – Trecho da interface para os tipos de ação.	54
Figura 11 – Ilustração das opções de comportamento.	54
Figura 12 – Trecho da interface para ajuste de parâmetros.	55
Figura 13 – Trecho da interface para a seleção do robô e do nível de automação.	55
Figura 14 – Trecho da interface para as configurações.	56
Figura 15 – (a) Exemplo de conexão de quatro robôs com topologia fixa. Os robôs R2, R3 e R4 se comunicam com o robô R1 teleoperado durante toda missão, independentemente da distância entre os mesmos. (b) Exemplo de conexão de quatro robôs com topologia dinâmica. Os robôs R3 e R4 se comunicam com o robô R1 teleoperado, mas o robô R2 perdeu conexão com o robô R1 devido à distância ser maior do que o raio de comunicação.	56
Figura 16 – (a) Exemplo de interface com as conexões de topologia de todos os robôs. (b) Exemplo de interface com as conexões de topologia do robô teleoperado R1. (c) Exemplo de interface sem nenhuma conexão de topologia.	56
Figura 17 – Trecho da interface para: (a) o nível de automação de tarefas, (b) o sistema de alerta sem detecção de conflito e (c) o sistema de alerta com detecção de conflito.	57

Figura 18 – Sequência de operações teleoperadas ou autônomas para diferentes Níveis de Automação: FOC - superior esquerdo; POC - superior direito; PAC - inferior esquerdo; FAC - inferior direito. Os números de processo destacados em azul são autônomos e os destacados em vermelho são teleoperados.	58
Figura 19 – Cenário de exemplo para aplicação do método de força social.	60
Figura 20 – Resultado da aplicação do método de força social para um pedestre.	61
Figura 21 – Geração de dez trajetórias através do algoritmo de frente de onda com dez pontos objetivos diferentes.	61
Figura 22 – Trajetórias percorridas pelos pedestres. Links para vídeos de exemplo: https://youtu.be/nJDly2BazHA e https://youtu.be/pWq6MpOn9wo	62
Figura 23 – Simulação do consenso em um sistema com grafo completo.	63
Figura 24 – (a) Consenso da posição x de <i>rendezvous</i> . (b) Consenso da posição y de <i>rendezvous</i>	63
Figura 25 – (a) velocidade linear. (b) velocidade angular.	64
Figura 26 – Grafo completo.	64
Figura 27 – (a) Grafo cíclico não-direcionado (b) Grafo cíclico direcionado (c) Grafo linha não-direcionado (d) Grafo aleatório não-direcionado	65
Figura 28 – Simulação do consenso em um sistema com perda de conectividade.	65
Figura 29 – (a) Consenso da posição x de <i>rendezvous</i> . (b) Consenso da posição y de <i>rendezvous</i>	66
Figura 30 – (a) velocidade linear. (b) velocidade angular.	66
Figura 31 – Controle Total do Operador.	69
Figura 32 – Controle Parcial do Operador.	70
Figura 33 – A detecção de conflito com o pedestre e o tempo de reação do operador para dar o comando para assumir o controle do robô.	71
Figura 34 – A trajetória executada pelos robôs e pelo pedestre. O círculo vermelho indica o momento da detecção do conflito quando o operador realiza o comando para assumir o robô e interfere na trajetória do robô.	71
Figura 35 – Simulação do consenso em um sistema com um agente controlado por inteligência artificial (Robô10) e 9 agentes autônomos.	74
Figura 36 – (a) Consenso da posição x de <i>rendezvous</i> . (b) Consenso da posição y de <i>rendezvous</i>	75
Figura 37 – (a) velocidade linear. (b) velocidade angular.	75
Figura 38 – Grafo completo com presença do operador, respectivo líder de controle (nó 9 corresponde ao robô10).	76
Figura 39 – Grafo estrela com presença do operador, respectivos líderes de informação.	76

Figura 40 – Interface gráfica do operador que apresenta a posição e orientação dos agentes.	77
Figura 41 – Interface do Sistema Interação Humano- <i>Swarm</i> (IHS) com suporte à teleoperação	78
Figura 42 – Interface do simulador com os 10 robôs móveis diferenciais (pioneer3AT).	79
Figura 43 – Gráfico de barras com o valor médio de cada métrica.	79
Figura 44 – Interface do simulador com 10 robôs móveis diferenciais (Pioneer-3AT), pedestres e obstáculos.	80
Figura 45 – Simulação de consenso em um sistema com um agente teleoperado (Robot10) e nove agentes autônomos (Robot[1-9]) com obstáculos no ambiente. Link do vídeo da simulação: https://bit.ly/2W8XSKD	80
Figura 46 – Gráfico de barras com o valor médio de cada métrica.	81
Figura 47 – Todas as escolhas possíveis de líder em uma rede com quatro agentes.	83
Figura 48 – Interface para seleção de líder com grafo conexo.	84
Figura 49 – (a) Consenso da posição x de <i>rendezvous</i> para o robô teleoperado: (a) Robô-1 (b) Robô-2 (c) Robô-3 e (d) Robô-4.	84
Figura 50 – (a) Consenso da posição y de <i>rendezvous</i> para o robô teleoperado: (a) Robô-1 (b) Robô-2 (c) Robô-3 e (d) Robô-4.	85
Figura 51 – Interface para seleção de líder com grafo não conexo.	86
Figura 52 – Exemplo de grafo em que o nó com maior valor do autovetor de centralidade não possui uma árvore de extensão.	86
Figura 53 – Interface para seleção de líder com um nó sem árvore de extensão.	87
Figura 54 – (a) Consenso da posição x de <i>rendezvous</i> para o robô teleoperado: (a) Robô-1 (b) Robô-2 (c) Robô-3 e (d) Robô-4.	87
Figura 55 – (a) Consenso da posição y de <i>rendezvous</i> para o robô teleoperado: (a) Robô-1 (b) Robô-2 (c) Robô-3 e (d) Robô-4.	88
Figura 56 – Estrutura das Redes Neurais Recorrentes (Recurrent Neural Networks) (RNN) com duas camadas de Memória de Curto e Longo Prazo (Long Short-Term Memory) (LSTM).	110
Figura 57 – Configurações de hiperparâmetros de seis tipos para a estrutura do LSTM para validação da acurácia.	111
Figura 58 – Principais componentes estruturais da arquitetura do Sistema Operacional de Robô (Robot Operating System) (ROS).	115

LISTA DE QUADROS

Quadro 1 – 10 níveis de autonomia de (SHERIDAN; VERPLANK, 1978)	28
---	----

LISTA DE TABELAS

Tabela 2 – Parâmetros para o Modelo de Força Social	59
Tabela 3 – Tempo médio de reação e tempo de resolução para cada experimento no modo de controle total do operador.	72
Tabela 4 – Tempo médio de reação e tempo de resolução para cada experimento no modo de controle parcial do operador.	72

LISTA DE ABREVIATURAS E SIGLAS

3P	Objetivo, processo e desempenho (Purpose, Process and Performance)
CPHS	Sistemas Ciber-Físicos e Humanos (Cyber-Physical and Human Systems)
CPS	Sistemas Ciber-Físicos (Cyber-Physical Systems)
CPSoS	Sistemas Ciber-Físicos de Sistemas (Cyber-Physical Systems of Systems)
CS	Consciência Situacional (Situational Awareness)
DL	Aprendizagem Profunda (Deep Learning)
FAC	Controle Automático Completo (Full Automatic Control)
FOC	Controle Total do Operador (Full Operator Control)
GRU	Unidades Recorrentes Fechadas (Gated Recurrent Unit)
IA	Inteligência Artificial
IAD	Inteligência Artificial Distribuída
IHS	Interação Humano- <i>Swarm</i>
LoA	Níveis de Autonomia (Levels of Autonomy)
LSTM	Memória de Curto e Longo Prazo (Long Short-Term Memory)
ML	Aprendizado de Máquina (Machine Learning)
MLP	Perceptron Multicamadas (Multilayer Perceptron)
MPC	Controle Preditivo Baseado em Modelo (Model Predictive Control)
OOTL	Fora da Malha (Out-Of-The-Loop)
PAC	Controle Automático Parcial (Partial Automatic Control)
POC	Controle Parcial do Operador (Partial Operator Control)
RNA	Redes Neurais Artificiais (Artificial Neural Networks)
RNN	Redes Neurais Recorrentes (Recurrent Neural Networks)
ROS	Sistema Operacional de Robô (Robot Operating System)
SAGAT	Técnica de Avaliação Global da Consciência Situacional (Situation Awareness Global Assessment Technique)
SMA	Sistemas Multi-Agentes
SMR	Sistemas Multi-Robôs
SoS	Sistemas de Sistemas (System of Systems)
SST	Sistema de Suporte à Teleoperação
UAV	Veículo Aéreo Não Tripulado (Unmanned aerial vehicle)
UAVs	Veículos Aéreos Não Tripulados (Unmanned aerial vehicles)
UGVs	Veículos Terrestres Não Tripulados (Unmanned Ground Vehicles)
UUVs	Veículos Subaquáticos Não Tripulados (Unmanned Underwater Vehicles)

LISTA DE SÍMBOLOS

\mathcal{D}	Grafo direcionado
\mathcal{V}	Conjunto de vértices
\mathcal{E}	Conjunto de arestas
$\mathcal{A}(\mathcal{D})$	Matriz de adjacência do grafo direcionado \mathcal{D}
\mathbb{R}	Espaço Euclidiano de dimensão 1

SUMÁRIO

1	INTRODUÇÃO	17
1.1	TELEOPERAÇÃO DE SISTEMAS MULTI-ROBÔS	19
1.2	OBJETIVOS	24
1.2.1	Objetivos Específicos	25
2	INTERAÇÃO HUMANO-MÁQUINA	26
2.1	AGÊNCIA	33
2.2	O PROBLEMA DE DESEMPENHO FORA DA MALHA	35
3	PLATAFORMA DE SIMULAÇÃO IHS	37
3.1	SWARM ROBÓTICO	38
3.2	PEDESTRE	39
3.3	TELEOPERADOR E O SENSO DE AGÊNCIA	41
3.4	SISTEMAS DE SUPORTE À TELEOPERAÇÃO (SST)	42
3.4.1	Sistema de Suporte à Teleoperação <i>Long-Short Term Memory</i>	44
3.4.2	Sistema de Suporte à Teleoperação Preditivo	45
3.4.3	Sistema de Suporte à Seleção de Líderes	47
3.5	PLATAFORMA DE SIMULAÇÃO	50
4	AVALIAÇÃO DO SISTEMA IHS - SIMULAÇÕES E RESULTADOS	59
4.1	AVALIAÇÃO DO MODELO DE PEDESTRE	59
4.2	AVALIAÇÃO DO TELEOPERADOR	62
4.2.1	Cenários e a Tarefa de <i>Rendezvous</i>	62
4.2.2	Nível de Agência do Teleoperador	67
4.3	SISTEMAS DE SUPORTE À TELEOPERAÇÃO (SST)	73
4.3.1	Sistema de Suporte à Teleoperação <i>Long-Short Term Memory</i>	74
4.3.2	Sistema de Suporte à Seleção de Líderes	82
5	CONSIDERAÇÕES FINAIS	89
5.1	OBJETIVOS ALCANÇADOS	89
5.2	CONCLUSÃO	89
5.3	TRABALHOS FUTUROS	90
	REFERÊNCIAS	92
	APÊNDICE A – TREINAMENTO E VALIDAÇÃO DA LSTM	107
	APÊNDICE B – ARQUITETURA DO ROBOT OPERATING SYSTEM (ROS)	114

1 INTRODUÇÃO

Os papéis humanos em sistemas ciber-físicos estão se tornando mais complexos. Além de atuarem como usuários e consumidores, também assumem funções como agentes ativos, operadores, tomadores de decisão e facilitadores de infraestruturas eficientes e resilientes. Assim, além das ciências da engenharia, física e computacionais, as ciências sociais, comportamentais e econômicas acrescentam novas dimensões ao paradigma de convergência, como exemplificado pelos Sistemas Ciber-Físicos e Humanos (Cyber-Physical and Human Systems) (CPHS) (NETTO; SPURGEON, 2017) que integra em Lamnabhi-Lagarrigue, Annaswamy, Engell, Isaksson, Khargonekar, Murray, Nijmeijer, Samad, Tilbury e Van den Hof (2017) um dos desafios futuros referentes ao campo de pesquisa de Sistemas & Controle e que são apresentados a seguir.

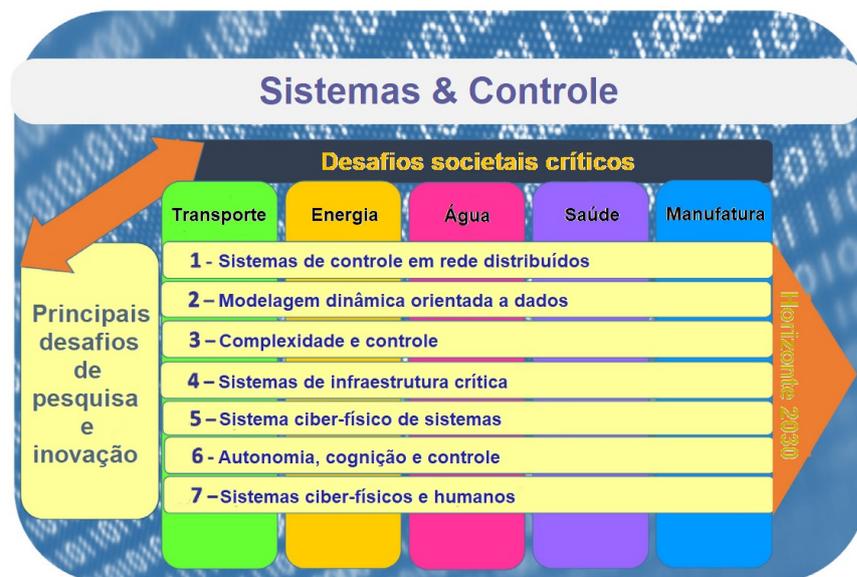


Figura 1 – Matriz de Sistemas & Controle: Cinco desafios críticos da sociedade por sete desafios principais de pesquisa e inovação.

Fonte – Adaptado de (LAMNABHI-LAGARRIGUE; ANNASWAMY; ENGELL; ISAKSSON; KHARGONEKAR; MURRAY; NIJMEIJER; SAMAD; TILBURY; VAN DEN HOF, 2017).

A alta complexidade desses sistemas implica que muitas questões relevantes não podem ser tratadas considerando um componente isolado do sistema ou mesmo usando o conhecimento disponível em uma única disciplina. Em vez disso, essas questões são inerentemente multidisciplinares, exigindo a compreensão da interação entre diferentes disciplinas. As questões que envolvem essas redes interdependentes e acopladas agora estão se tornando objetos de pesquisa, mas, devido à sua interdisciplinaridade, essa pesquisa ainda está sendo estabelecida.

O papel mais integrado da interação humana em robótica, saúde e outros campos em que os sistemas de controle interagem diretamente com indivíduos e grupos continua sendo uma área aberta de pesquisa. Uma grande oportunidade para o progresso em Sistemas & Controle deriva de desenvolvimentos empolgantes no campo de aprendizado de máquina, uma vez que, historicamente, existem conexões estreitas entre inteligência artificial e sistemas de controle.

Esses avanços estão criando um terreno fértil para colaborações mais profundas entre os pesquisadores de Sistemas & Controle e a comunidade de Inteligência Artificial (IA). É provável que os requisitos fundamentais do ponto de vista de controle levem novas questões no aprendizado de máquina e na IA. Por outro lado, os avanços metodológicos no aprendizado de máquina e na IA potencialmente oferecem novas ferramentas poderosas para identificação e controle. Tais colaborações poderiam ser inspiradas pelas principais necessidades de aplicações, como o projeto e verificação de sistemas autônomos inteligentes.

O papel humano se torna significativamente mais complexo em Sistemas Ciber-Físicos de Sistemas (Cyber-Physical Systems of Systems) (CPSoS), já que não está mais limitado ao de usuário ou operador, mas ao de agente habilitado. Intervenções humanas na tomada de decisões introduzem uma não linearidade e incerteza adicionais no sistema. Questões importantes de pesquisa incluem capacidade humana de atenção e como fornecer motivação para atenção suficiente e tomada de decisão consistente. Deve-se investigar como as capacidades de humanos e máquinas em monitoramento e tomada de decisão em tempo real podem ser combinadas de maneira ideal (LAMNABHI-LAGARRIGUE; ANNASWAMY; ENGELL; ISAKSSON; KHARGONEKAR; MURRAY; NIJMEIJER; SAMAD; TILBURY; VAN DEN HOF, 2017) e avanços na criação de plataformas experimentais de sistemas de controle em rede de baixo-custo, para incentivar esta área de pesquisa, é um fator essencial que é refletido no aumento significativo de artigos na área nos últimos quinze anos (CAVALCANTI; FIGUEREDO; ISHIHARA; BERNARDES; SANTANA; VARGAS; BORGES, 2018). Portanto, pesquisas futuras sobre o monitoramento das ações dos usuários e antecipação de seus comportamentos e modelagem de sua percepção da situação são necessárias para os desafios futuros como apresentado na Figura 1.

Portanto, os Sistemas de Sistemas (System of Systems) (SoS) precisam ser resilientes aos efeitos do comportamento imprevisível natural dos seres humanos. Os veículos operados autonomamente e os veículos operados pelo homem interagirão entre si. Os sistemas de controle futuros devem, portanto, alcançar um novo nível de robustez com relação ao não determinismo do comportamento humano. As técnicas de controle devem ser capazes de responder oportunamente a novas situações e eventos imprevisíveis decorrentes do comportamento humano. Conseqüentemente, os seres humanos devem ser considerados um elemento integrante dos sistemas sociotécnicos.

1.1 TELEOPERAÇÃO DE SISTEMAS MULTI-ROBÔS

Os tópicos apresentados a seguir servem para demonstrar a grande abrangência do tema e ao mesmo tempo delimitar o escopo desta tese em sistemas de Interação Humano-*Swarm* (IHS), portanto serão apresentadas identificações e classificações possíveis para sistemas multi-robôs presentes na literatura e a relação com estes sistemas.

Os avanços recentes na miniaturização da computação, comunicação, detecção e atuação tornaram viável o ideário de um grande número de veículos autônomos (ar: Veículos Aéreos Não Tripulados (Unmanned aerial vehicles) (UAVs), solo: Veículos Terrestres Não Tripulados (Unmanned Ground Vehicles) (UGVs) e água: Veículos Subaquáticos Não Tripulados (Unmanned Underwater Vehicles) (UUVs)) trabalhando cooperativamente para atingir um objetivo. No entanto, a largura de banda de comunicação e as restrições de energia apresentam empecilhos para o comando e o controle centralizados (REN; BEARD, 2008).

A fim de compreender este campo de estudo, primeiramente temos que entender dois conceitos principais: o que é um agente e o que é coordenação. Agente pode ser definido como uma entidade computável, com a capacidade de comunicação, colaboração e capacidade de adaptação, capaz de executar ações de forma flexível e independente a fim de realizar tarefas em um determinado ambiente. Atualmente, Sistemas Multi-Agentes (SMA) tornou-se um dos conceitos fundamentais da área de IA, e tem sido aplicado à pesquisa de Inteligência Artificial Distribuída (IAD). SMA podem ser vistos como um complexo sistema de informação inteligente distribuída combinado com agentes independentes fracamente-acoplados, que tenta simular os comportamentos racionais. As características de um SMA são: (1) Cada agente tem recursos de informação limitados e capacidade de resolução de problemas; (2) O controle global é inexistente no SMA; (3) O conhecimento e os dados são discretos; (4) E a computação é executada de modo assíncrono (YAN; ZHENMIN, 2009). E coordenação é o ato de regulação e combinação de forma a produzir resultados harmoniosos.

A robótica cooperativa consiste do uso coordenado de um grupo de robôs na realização de diferentes tarefas. Coordenação e interações de múltiplos agentes inteligentes têm sido estudadas de forma ativa no campo da IAD desde o início da década de 1970 (CAO, Y.U.; FUKUNAGA; KAHNG; MENG, 1995; BOND; GASSER, 2014), mas o campo da IAD se preocupa principalmente com os problemas que envolvem agentes de software. No final dos anos 1980, a comunidade de pesquisa robótica tornou-se muito ativa em robótica cooperativa, começando com projetos como o ACTRESS (ASAMA; MATSUMOTO; ISHIDA, 1989), CEBOT (FUKUDA; NAKAGAWA, 1987), GOFER (CALOUD; CHOI; LATOMBE; LE PAPE; YIM, 1990), SWARM (BENI, 1988) e o trabalho da IROS 1990 (STEELS, 1990). Por isso, é um campo emergente, e ainda é um campo ativo com muitos desafios e aplicabilidade em diversas áreas,

tais como mapeamento cooperativo, coleta de dados em redes de sensores, controle cooperativo, manipulação cooperativa, transporte e assim por diante (CAO, Y.U.; FUKUNAGA; KAHNG; MENG, 1995; LI, W., 2016).

Com relação ao controle cooperativo de sistemas de múltiplos veículos, o grau e a forma do acoplamento entre os veículos que compõem o sistema são de suma importância para a natureza e o nível da cooperação que pode ser alcançada. De um modo geral, quanto maior o grau do acoplamento, mais desafiador é formular soluções cooperativas eficazes (REN; BEARD, 2008).

As tarefas a serem executadas por vários agentes podem ser divididas em duas categorias: sistemas fortemente acoplados ou fracamente acoplados. As tarefas fortemente acopladas requerem o uso de múltiplos agentes para a sua execução e, geralmente, não podem ser realizadas por um único robô. Exige, portanto, que esses agentes tenham informações sobre o estado dos outros e sincronizem suas ações precisamente, além disso, cada agente é fundamental para o sucesso da tarefa. A outra categoria chamada de fracamente acoplada pode ser realizada por um único robô, mas com importantes ganhos relacionados com desempenho e tolerância a falhas quando realizada por múltiplos robôs. Estas tarefas não necessitam de coordenação de alto nível, permitindo, assim, um papel mais independente dos seus agentes. E a falha de um agente não é crucial para o sucesso da missão (CHAIMOWICZ; PEREIRA; CAMPOS, 2014).

No contexto de Sistemas Multi-Robôs (SMR), a coordenação envolve a regulação espaço-temporal adequada das ações dos robôs, de modo que a probabilidade de uma determinada tarefa ou meta seja maximizada e alcançada com sucesso (JONES, C. V., 2005). Os SMR podem aproximadamente ser tratados como um SMA, no qual cada robô pode ser tratado como um agente inteligente e autônomo com capacidade de lidar com tarefas locais e de coordenação com os parceiros (YAN; ZHENMIN, 2009).

A arquitetura dos SMR pode ser dividida em: arquitetura de grupo ou arquitetura individual (LI, S.-Q.; YUAN; TANG; YANG; YANG, 2007). A primeira foca as questões do sistema global, incluindo conhecimento, informação, estratégias de controle e atribuição de funções ao robô, enquanto a segunda se concentra na responsabilidade individual de cada robô e a divisão de seus módulos.

A decisão do tipo de arquitetura a ser utilizada tem que considerar os tipos de agentes disponíveis. Assim, um SMR pode ser dividido como homogêneo ou heterogêneo. Equipes homogêneas são compostas de membros que têm exatamente o mesmo hardware e programa de controle, enquanto que equipes heterogêneas os robôs diferem tanto no hardware ou no programa de controle (KANJANAWANISHKUL, 2014), em outras palavras, define-se um grupo de robôs como homogêneo se as capacidades dos robôs individualmente são idênticas e heterogêneo caso o contrário. Em geral, a heterogeneidade introduz complexidade uma vez que a alocação de tarefas se

torna mais difícil, e os agentes têm uma maior necessidade de modelar outros agentes do grupo. A literatura é atualmente dominada pelas obras que assumem grupos homogêneos de robôs. No entanto, algumas arquiteturas notáveis podem lidar com a heterogeneidade, por exemplo, ACTRESS e ALLIANCE (CAO, Y.U.; FUKUNAGA; KAHNG; MENG, 1995; ASAMA; MATSUMOTO; ISHIDA, 1989). Em grupos heterogêneos a alocação de tarefas pode ser determinada pelas capacidades individuais, mas em sistemas homogêneos, os agentes precisam ser capazes de assumir diferentes papéis que podem ser conhecidos a priori ou surgir dinamicamente durante a execução da missão (CAO, Y.U.; FUKUNAGA; KAHNG; MENG, 1995).

Os tipos de estruturas de comunicação é outro tema de grande relevância para SMR e a característica fundamental dos sistemas em rede, distinguindo-os dos sistemas tradicionalmente considerados na teoria dos sistemas, é a presença da rede e sua influência no comportamento do sistema geral. A estrutura de comunicação de um grupo determina os possíveis modos de interação entre agentes. Pode-se caracterizar três tipos de interações: interação via ambiente, interação via detecção e interação através de comunicações (CAO, Y.U.; FUKUNAGA; KAHNG; MENG, 1995).

Como resultado, um problema crítico para o controle cooperativo é projetar algoritmos distribuídos apropriados, de modo que o grupo de agentes possa chegar a um consenso sobre as informações compartilhadas na presença de troca de informações limitada e não confiável e com mudanças dinâmicas de topologias de interação (REN; BEARD, 2008). Aqui, cooperativa se refere à estreita relação entre todos os agentes da equipe, com o compartilhamento de informações desempenhando um papel importante (REN; CAO, Yongcan, 2010).

A utilização de múltiplos robôs de forma cooperativa pode trazer assim muitas vantagens quando comparado com o desempenho de um único robô. Dependendo da missão a ser realizada há um ganho significativo de desempenho, uma vez que a tarefa é realizada por diversos agentes, e também uma tolerância maior a falhas devido as capacidades redundantes desses agentes. Além de permitir o uso de robôs simples, uma vez que a ação conjunta reduz a necessidade de robôs altamente especializados (CHAIMOWICZ; PEREIRA; CAMPOS, 2014).

Sendo assim, SMR podem ser aplicados em diversos domínios tais como: industrial; de construção; agricultura e silvicultura; robótica de serviços; busca e salvamento; manipulação aérea cooperativa; tarefas complexas em ambientes não estruturados; e interação humano-robô (ERHART; HIRCHE, S., 2016).

Portanto a coordenação distribuída de vários agentes autônomos tem sido um tópico de pesquisa muito ativo na sociedade de Sistemas & Controle. Os resultados recentes da pesquisa em coordenação de múltiplos agentes distribuídos são categorizados como consenso, controle de formação distribuído, otimização distribuída, atribuição de tarefas distribuídas, estimativa e controle distribuídos e coordenação in-

teligente (REN; CAO, Yongcan, 2010). O principal objetivo do controle é fazer com que os agentes trabalhem juntos de forma cooperativa.

Sendo assim, o controle de *swarms*¹ de robôs geralmente depende apenas de interações locais para atingir o comportamento global desejado pela equipe. Existem muitos paradigmas que podem atender a essas necessidades e oferecer controle adequado do *swarm*, enquanto a outra perspectiva, a interação humano-*swarm*, que depende de métricas de fatores humanos, é menos explorada. Atualmente, não existe um método geral ou esquema validado para controle humano escalável, flexível e adaptável de *swarms* (WANG, L.; DAI; CHENG; GUAN, 2018).

Existem muitos casos em que o operador/supervisor humano² ainda é necessário, especialmente aqueles em que é necessário um controle mais preciso sobre a operação de um *swarm* ou quando um comportamento emergente desejado não pode ser gerado de forma autônoma e sem influência humana significativa. Nesses casos, as entradas podem ser fornecidas por um operador humano e essas contribuições contínuas terão uma influência persistente nos líderes selecionados e indiretamente no *swarm*, e tais situações requerem muito mais treinamento e atenção do operador. Ou seja, é necessário a reconciliação da natureza distribuída dos *swarms* com a capacidade de controle por um operador.

Atualmente, tem havido uma tendência de sistemas multi-robôs mudarem do paradigma de operação muitos-para-um para o modo de operação um-para-muitos, no qual um único operador é capaz de controlar um grande número de veículos autônomos (SILVA TCHILIAN; MORENO; NETTO, 2020). Esta transição está ocorrendo devido ao aumento da autonomia dos veículos não tripulados (UV's), em conjunto com uma mudança de responsabilidade do operador. Apesar disso, é crítico e continua sendo um desafio determinar as funções que serão executadas por sistemas autônomos e humanos (CUMMINGS; BERTUCELLI; MACBETH; SURANA, 2014).

O termo “mito da substituição” é usado na literatura de fatores humanos para indicar a suposição ingênua de que o impacto da automação é apenas a transferência de alguns deveres humanos para uma máquina capaz de realizar essas funções. No entanto, o impacto da automação é mais amplo, transformando o papel humano e trazendo uma profunda reorganização e ajuste das capacidades e competências dos trabalhadores (DEKKER; WOODS, 2002).

Recentemente, o conceito de “senso de agência” foi aplicado ao estudo das interações homem-máquina e refere-se a: “a experiência de controlar as próprias ações e, através delas, eventos no mundo exterior” (CHAMBON; HAGGARD, 2012). De acordo com a literatura, o senso de agência pode ser subdividido em três categorias: senso de intencionalidade, senso de iniciação e senso de controle (PACHERIE, 2008). No pre-

¹ Decidiu-se utilizar o estrangeirismo de *swarm* como substantivo coletivo de robôs, uma vez que não há um consenso de nomenclatura, com esta variando de acordo com a aplicação do sistema.

² doravante referido apenas como operador.

sente trabalho, considera-se o senso de controle, pois conforme indicado por Le Goff, Rey, Haggard, Oullier e Berberian (2018), é o aspecto mais relevante nas interações homem-máquina.

Particularmente, Wegner e Wheatley (2010) afirmou que: “uma ação é percebida como desejada: (1) quando o pensamento precede a ação em um intervalo apropriado (chamado princípio da prioridade), (2) quando o pensamento é compatível com a ação (princípio da consistência), e (3) quando o pensamento é a única causa aparente da ação (princípio da exclusividade)”.

Assim, a diminuição do senso de agência está relacionada ao problema de desempenho Fora da Malha (Out-Of-The-Loop) (OOTL), quando um operador é incapaz de compreender as intenções e prever o resultado das ações do sistema, causando uma diminuição de controle (BERBERIAN, 2019). A este respeito, o principal problema com a automação, de acordo com Norman (1990): “não é a automação em si, nem o próprio operador humano, mas sim como projetar uma interação entre o humano e a automação eficiente”.

E um dos fatores que desempenha um papel importante para ajustar o nível do senso de agência (UEDA; NAKASHIMA; KUMADA, 2021) são os Níveis de Autonomia (Levels of Autonomy) (LoA). O LoA é um dos principais fatores para determinar como o controle, autoridade, habilidade e responsabilidade são modificados entre as funções a serem desempenhadas pelo operador (FLEMISCH; HEESSEN; HESSE; KELSCH; SCHIEBEN; BELLER, 2012), como as tarefas ativas de: planejamento de processos, tomada de decisão, seleção de respostas, implementação de estratégias; e as tarefas passivas de: monitorar, entender e observar desvios e falhas de ações autônomas, bem como a capacidade de assumir o controle quando necessário (MORAY, 1986; SHERIDAN; VERPLANK, 1978).

No entanto, o desenvolvimento e análise destes sistemas são extremamente complexos, especialmente quando dependentes de comportamentos humanos. E como sabemos, as plataformas de simulação têm uma função fundamental para o design centrado no ser humano. As primeiras aplicações foram os simuladores de voo (PAUSCH; CREA; CONWAY, 1992) para projetos de cockpit (WEI; ZHUANG; WANYAN; WANG, 2013), para modelar o comportamento do piloto humano (MCRUER; KRENDEL, 1974; XU; TAN; EFREMOV; SUN; QU, 2017) e para avaliar o senso de agência do piloto (LE GOFF; REY; HAGGARD; OULLIER; BERBERIAN, 2018). Recentemente, plataformas de simulação têm sido usadas para outras aplicações como sistemas avançados de assistência ao motorista (MARS; CHEVREL, 2017; SALEH; CHEVREL; CLAVEAU; LAFAY; MARS, 2013) e interação humano-robô (LEWIS; WANG, J.; HUGHES, 2007; DEHAIS; CAUSSE; VACHON; TREMBLAY, 2012; WAMPLER; LI; MOSCIKI; ELLENRIEDER, 2017).

Além disso, o conceito de cidade inteligente traz consigo a crescente neces-

sidade de inserção destes sistemas em meios cohabitados por humanos, como em ambientes urbanos com pedestres, e isto reflete em um desafio adicional para a operação destes sistemas e a interação com humanos de forma segura. E, se sabe que, a automação pode modificar a experiência do agente e essas mudanças podem impactar no desempenho do operador e na adequação do sistema. Portanto, o recente interesse pela experiência do operador como agente (“agência”) (BERBERIAN, 2019) e a notável atividade de pesquisa recente na interação deste operador com *swarms*, denominado IHS, traz novos desafios e abre novas perspectivas para se interpretar e contrabalançar as dificuldades que surgem em sistemas altamente automatizados, principalmente em sistemas que requerem cooperação homem-máquina.

Visto que os usuários desejam fortemente a sensação de que estão no comando do sistema e que o sistema responde às suas ações, a agência serve como um indicador da percepção do usuário em relação a estes fatores. O conceito de agência, assim, nos fornece novas ferramentas conceituais e medidas para melhorar e otimizar o projeto, controle e interação desses sistemas.

Diante disso, a contribuição deste trabalho é o desenvolvimento de uma nova plataforma de simulação de interação humano-*swarm* para aplicar o framework de agência em sistemas de interação humano-*swarm*. Como prova de conceito, um caso de teste é apresentado para analisar como o LoA impacta o senso de agência. A avaliação é realizada com o estudo de caso proposto de supervisão e controle de *swarms* robóticos autônomos para cidades inteligentes e interação segura com humanos. O objetivo é avaliar e implementar um sistema de supervisão e controle para a teleoperação de *swarms* robóticos urbanos, considerando os diferentes aspectos da perspectiva de modelagem desses sistemas sociotécnicos para capturar a dinâmica e as interações entre operadores, usuários, artefatos técnicos e o ambiente. Além disso, outras contribuições realizadas foram as propostas de três tipos de sistemas para teleoperação assistida, a fim de auxiliar o operador na realização de determinadas tarefas.

A seguir são apresentados os objetivos no desenvolvimento desta tese, considerando-se o contexto e o âmbito de estudo aqui apresentados.

1.2 OBJETIVOS

O objetivo geral desta tese é propor uma plataforma de simulação para aplicar o framework de agência ao campo de IHS e avaliar como as diferentes características destes sistemas, como por exemplo o nível de automação, influenciam o reconhecimento e gerenciamento de um operador desse sistema no contexto de ambientes urbanos com pedestres. A avaliação deste sistema é realizada através de simulações desenvolvidas com as ferramentas ROS e Gazebo para refletir cenários de operação.

Além disso são propostos sistemas de auxílio ao operador humano na tarefa de teleoperação, a fim de maximizar seu desempenho e melhorar sua compreensão do

comportamento atual e do estado do *swarm* em geral. Esta tese desenvolve - por meio de estudos com usuários - novos métodos para exibir o estado de um *swarm* e fornecer assistência à teleoperação através de RNN e Controle Preditivo Baseado em Modelo (Model Predictive Control) (MPC) de forma a aprimorar a capacidade do usuário de reconhecer, prever e controlar comportamentos emergentes. Também é considerada a seleção de líderes para realizar a visualização e previsão, pois os líderes são os pontos intermediários do *swarm* ao operador. Os líderes podem ser usados para reunir informações agregadas sobre o *swarm* para retornar à interface, enquanto também propaga entradas de controle do usuário para o resto do *swarm*.

1.2.1 Objetivos Específicos

Os objetivos específicos consistem em obter uma plataforma que seja consistente com o que se sabe sobre controle sensorial, motor e cognitivo em humanos; precisa (preditiva) o suficiente para apoiar o desenvolvimento de um sistema eficiente de assistência à teleoperação e simples de ser usada no contexto de sistemas híbridos de times robô-humano distribuídos, fracamente acoplados com comunicação explícita.

Sendo assim, pode-se resumir os objetivos específicos desta tese em:

1. Propor uma plataforma de simulação para aplicar o framework de agência para sistemas IHS.
2. Propor métodos de auxílio e suporte à tarefa de teleoperação.
3. Identificar e propor ferramentas de validação de desempenho do *swarm*.

A estrutura desta tese é composta por esta introdução e mais quatro capítulos: no capítulo 2 são explorados os fatores humanos decorrentes da interação entre os agentes que compõe o sistema; no capítulo 3 são apresentadas as ferramentas de simulação utilizadas com as justificativas para a escolha das mesmas, assim como, todos os detalhes da plataforma de IHS desenvolvida nesta tese ; no capítulo 4 avalia-se o uso da plataforma com três propostas de sistemas de suporte a teleoperação e seus respectivos resultados ; por fim, no capítulo 5 as considerações finais são expostas com propostas de trabalhos futuros para a continuidade do tema de pesquisa.

2 INTERAÇÃO HUMANO-MÁQUINA

A seguir é realizada uma breve revisão de literatura com os principais conceitos da área de interação humano-máquina e, nas subseções seguintes, são apresentados os conceitos abordados nesta tese.

O estudo da interação humano-máquina tem como motivação e origem dos seus principais resultados o campo de estudos aeronáuticos, uma vez que, o movimento controlado de uma aeronave obviamente depende de uma combinação das características da aeronave e do piloto humano. O projeto eficaz da aeronave depende, portanto, da apreciação do projetista da maneira pela qual o humano (o piloto) interage com a máquina (a aeronave). As técnicas de modelagem de pilotos desempenharam um papel crucial na aviação e, como consequência, geraram grandes avanços na pesquisa do comportamento do controle humano (XU; TAN; EFREMOV; SUN; QU, 2017); e estas contribuições estão bem resumidas no excelente relatório de (MCRUER, 1965).

Porém com a crescente complexidade dos sistemas, mais recentemente, problemas na modelagem de pilotos têm atraído cada vez mais atenção nas técnicas de IA (ZAYCHIK; CARDULLO; GEORGE, 2006).

Na pesquisa dedicada ao controle humano de sistemas dinâmicos os objetivos são resumir dados comportamentais, fornecer uma base para a compreensão do comportamento de controle do operador e, acima de tudo, ser usado em conjunto com a dinâmica da máquina na formação de previsões do comportamento do sistema operador/máquina. Tais situações não são apenas relevantes na aviação, mas também no contexto do controle de teleoperação e supervisão humana de veículos não tripulados, em que um projeto que não considerar as características de ambos os agentes pode ter como consequência a degradação do desempenho do operador humano, levando a comportamentos inadequados e conflitos entre os agentes. Pode-se considerar conflito aqui como a impossibilidade de um agente ou um grupo de agentes de atingir uma meta que importa (DEHAIS; CAUSSE; VACHON; TREMBLAY, 2012).

E os sistemas multiagentes, assim como os campos de pesquisa citados anteriormente, são outro exemplo de sistema de interação humano-máquina em que a ocorrência de conflito é um precursor notável da ruptura do sistema. A impossibilidade de atingir uma meta pode ter origem em diversos fatores tais como: inconsistências na interface do usuário, modelos mentais insuficientes, recursos físicos ou cognitivos limitados, ações de outros agentes ou restrições ambientais (DEHAIS; CAUSSE; VACHON; TREMBLAY, 2012).

A Figura 2 resume os tipos de funções e papéis que o humano pode assumir. O termo humano aqui é usado para se referir ao operador, motorista, piloto ou companheiro de equipe do sistema robótico.

Os resultados de Goodrich, Quigley e Cosenzo (2005) sugerem que o número

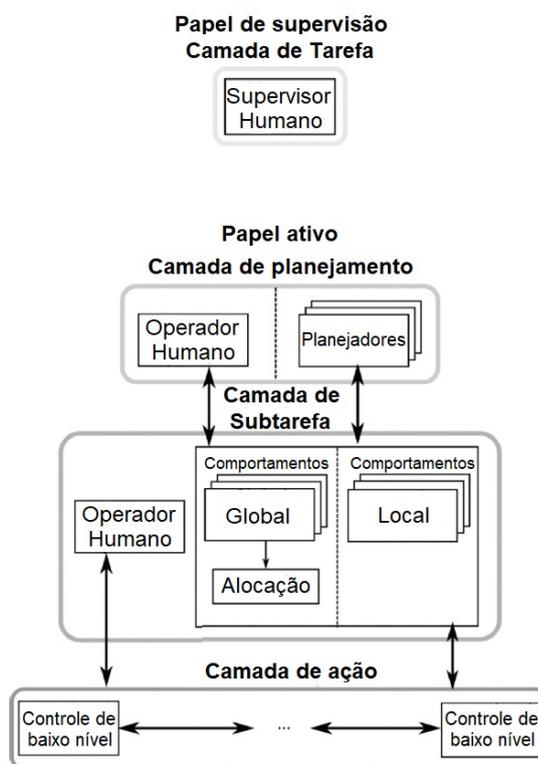


Figura 2 – Possíveis funções humanas na arquitetura de controle da equipe de robôs.

Fonte – Adaptado de (MUSICÍ; HIRCHE, Sandra, 2017).

máximo de robôs homogêneos e desacoplados que um único humano pode gerenciar é determinado pela expressão de *fan-out*, ou seja, postulou-se que o número ideal de robôs era aproximadamente o tempo autônomo dividido pelo tempo de interação exigido por cada robô. Ou seja, o modelo de *fan-out* assume a tolerância à negligência, a saber, que o desempenho de um robô será prejudicado se ele for deixado sem vigilância pelo operador por algum tempo (tempo de negligência) e que algum tempo de interação deve ser periodicamente dedicado ao robô pelo operador (KOLLING; WALKER; CHAKRABORTY; SYCARA; LEWIS, 2015).

Como alguns algoritmos de *swarm* requerem tempo para convergir e estabilizar após a emissão de um comando do operador, é possível que os mesmos tipos de comandos tenham efeitos diferentes, às vezes adversos, dependendo do estado do *swarm*. Para capturar a idéia de que os humanos podem precisar observar a evolução do estado do *swarm* e esperar algum tempo antes de agir, originou um novo conceito chamado benevolência negligenciada que foi investigado em Nagavalli, Luo, Chakraborty e Sycara (2014). Este conceito é, em certo sentido, o inverso da tolerância negligenciada utilizada na interação de robôs independentes e não coordenados, onde se supõe que o desempenho de um robô individual degrada com o tempo e, portanto, a atenção do operador precisa ser planejada para que o tempo de ausência de interação

com os robôs (o tempo de negligência) seja minimizado.

A complexidade cognitiva que classifica a dificuldade das tarefas do operador é introduzida por Lewis (2013). O conceito é descrever o relacionamento entre tipos de tarefas e complexidade de comandos. Se a complexidade cognitiva é “da ordem n ”, escrita $O(n)$, isso indica que o esforço necessário da parte do operador dedicado ao controle do *swarm* varia linearmente com o número de robôs. Se um *swarm* puder ser encarregado de um único comando, a complexidade cognitiva do operador será independente do número de robôs e, assim, a complexidade cognitiva é $O(1)$. O controle $O(1)$ descreve, assim, situações nas quais há um grande número de robôs que podem ser coordenados usando objetivos relativamente simples.

Há diferentes paradigmas de interação entre uma equipe humana e uma equipe robótica em termos de níveis de autonomia e fatores humanos. Segundo Jessie YC Chen e Barnes (2014), a interface precisa garantir que o ser humano entenda as intenções e comportamentos dos robôs e do meio ambiente. Além disso, este precisa alocar adequadamente a atenção humana a eventos importantes e garantir a autoridade de decisão do ser humano. No geral, a interface para a interação humano-automação precisa ser determinada por: objetivo (grau em que a automação é usada em relação à intenção do projetista), processo (se o nível de autonomia for adequado para uma determinada situação) e desempenho (confiabilidade, previsibilidade e capacidade).

Quadro 1 – 10 níveis de autonomia de (SHERIDAN; VERPLANK, 1978)

1	O humano executa todas as ações.
2	O computador oferece um conjunto completo de alternativas de ação.
3	O computador oferece uma seleção de alternativas de ação.
4	O computador sugere uma alternativa.
5	O computador executa uma ação autonomamente se o ser humano aprovar.
6	O computador permite que o ser humano tenha um tempo restrito para vetar antes da execução automática.
7	O computador executa uma ação e informa o humano.
8	O computador executa uma ação e informa o humano, se solicitado.
9	O computador executa uma ação e informa o ser humano, se assim o decidir.
10	O computador executa todas as ações de forma autônoma.

Fonte – Adaptado de (MUSICÍ; HIRCHE, Sandra, 2017).

Por exemplo, em Franchi, Secchi, Ryll, Bulthoff e Giordano (2012) o ser humano seleciona o modo de interação enquanto a equipe de UAVs autonomamente controla sua topologia variável. A escolha pode ser feita entre intervenção global (direcionando o centróide da formação até a meta) ou intervenção local (direcionando um único Veículo Aéreo Não Tripulado (Unmanned aerial vehicle) (UAV). Em Atman, Hatanaka,

Qu, Chopra, Yamauchi e Fujita (2018) o humano alterna manualmente entre dois controladores: o controle da posição da equipe do robô e o controle da velocidade da equipe do robô e fornece os comandos de entrada para o controlador escolhido.

Assim, apesar de os operadores humanos estarem sistematicamente “na malha de controle”, os pesquisadores adotam uma abordagem centrada na tecnologia, favorecendo a definição e alocação de tarefas para sistemas automatizados, levando em consideração apenas os operadores humanos no final do processo de projeto, uma vez definido o sistema de controle. Além disso, é geralmente considerado que os operadores humanos estarão lá para lidar com qualquer situação inesperada com eficiência. Conseqüentemente, para lidar com um processo complexo que falha ou se comporta de maneira perigosa ou mesmo imprevisível, os seres humanos precisam ser simultaneamente coordenados, eficientes e rápidos, ou seja, precisam ser “seres humanos mágicos” (PACAUX-LEMOINE; TRENTESAUX; REY; MILLOT, 2017).

O humano pode ser o vilão e, infelizmente, alguns projetos consideram que ele é apenas isso: sua racionalidade é limitada, ele/ela pode esquecer, cometer erros, reagir exageradamente, estar ausente ou até ser a causa raiz de um desastre. O humano pode ser o herói, e muitas vezes acreditamos que: ele/ela pode salvar vidas através de um comportamento inesperado e inovador. O humano pode ser a testemunha impotente: ele/ela pode ser incapaz de agir, apesar de ter certeza de que está certo e de que o sistema automatizado está errado (PACAUX-LEMOINE; TRENTESAUX; REY; MILLOT, 2017).

Portanto foram desenvolvidos diversos fatores humanos para que se pudesse considerar o humano como parte das características de projeto. A seguir apresentam-se alguns dos fatores considerados em missões com múltiplos robôs.

Segundo Endsley (1995), Consciência Situacional (Situational Awareness) (CS) é “a percepção dos elementos no ambiente em um volume de tempo e espaço, a compreensão de seu significado e a projeção de seu status em um futuro próximo”. Muitos estudos mostraram que a CS tem um impacto significativo na tomada de decisão humana e, finalmente, no desempenho da tarefa (HUSSEIN; ABBASS, 2018).

O ser humano deve sempre estar ciente da situação: de acordo com Endsley (1995), a CS é composta por três níveis: CS1 (percepção dos elementos), CS2 (compreensão da situação) e CS3 (projeção dos futuros estados). Cada nível de CS deve, portanto, ser considerado para garantir que os humanos possam tomar decisões e desenvolver continuamente seus modelos mentais do sistema. Portanto, a carga de trabalho mental humana deve ser cuidadosamente regulada: uma “carga de trabalho ideal” pode ser encontrada entre “nada a fazer”, induzindo uma potencial falta de interesse e “muitas coisas para fazer”, induzindo estresse e fadiga. No qual o primeiro nível descreve o conhecimento humano do estado de elementos relevantes no ambiente, o segundo nível reflete o grau em que ele/ela integra esses dados para entender

a situação atual geral e o terceiro nível descreve sua capacidade de fazer previsões relevantes em um futuro próximo (ENDSLEY, 1988; HUSSEIN; ABBASS, 2018).

A Técnica de Avaliação Global da Consciência Situacional (Situation Awareness Global Assessment Technique) (SAGAT) (ENDSLEY, 1988) é um método amplamente utilizado, no qual o ser humano participa de uma missão simulada. A simulação é congelada em momentos aleatórios, para que o operador possa responder a algumas perguntas que medem diferentes níveis de CS.

Uma taxonomia de fatores que afetam a CS na IHS é fornecida em (RILEY; STRATER; CHAPPELL; CONNORS; ENDSLEY, 2010). Esses fatores podem pertencer à tarefa (por exemplo, seu nível de autonomia), ao sistema (por exemplo, características de comunicação), ao ambiente (por exemplo, complexidade), habilidades pessoais (por exemplo, experiência e habilidades cognitivas) ou à interface (por exemplo, nível de fusão de informações).

Outro fator importante que influencia o desempenho humano em uma missão é o nível de carga de trabalho imposta ao ser humano. Em primeiro lugar, a capacidade humana de desenvolver e manter o nível desejado de CS é afetada pelo nível de carga de trabalho. As conclusões sugerem que níveis muito baixos e altos de carga de trabalho podem causar degradação do desempenho humano.

Os primeiros estudos consideravam a carga de trabalho humana composta por componentes objetivos e subjetivos (CAMPBELL, 1988). Enquanto o componente objetivo consiste em fatores decorrentes da estrutura da tarefa, da interface ou do ambiente; o componente subjetivo é composto de fatores pertencentes ao executor humano da tarefa, incluindo experiência, habilidades cognitivas, habilidades e autoconfiança.

Em seu artigo seminal John D Lee e See (2004) definiu a confiança humana em um agente como “a atitude de que um agente ajudará a alcançar os objetivos de um indivíduo em uma situação caracterizada por incerteza e vulnerabilidade”. No entanto, tanto excesso de confiança quanto desconfiança são prejudiciais ao desempenho da missão. No entanto, uma meta-análise quantitativa sobre fatores que afetam a confiança revelou que o desempenho do robô é o principal contribuinte para a confiança (HANCOCK; BILLINGS; SCHAEFER; CHEN; DE VISSER; PARASURAMAN, 2011).

Os problemas de confiança são particularmente relevantes para nosso foco no controle de vários sistemas por um agente inteligente, porque a desconfiança ou a confiança excessiva se propagam para os sistemas componentes. Existem inúmeras definições de confiança na literatura de psicologia organizacional, relacionamentos interpessoais e interações homem-máquina, entre outros campos. No contexto da interação homem-máquina, uma das definições mais amplamente citadas é a do artigo de John D Lee e See (2004), que parece mais relevante, pois captura a “adequação da confiança, a influência do contexto, as características relacionadas ao objetivo do agente e os processos cognitivos que governam o desenvolvimento e a erosão da

confiança” (CHEN, J. Y.; BARNES, 2014).

Deve-se ressaltar que o excesso de confiança é tão prejudicial quanto a falta de confiança. Em outras palavras, a calibração é um elemento importante da confiança; a confiança apropriada implica que os seres humanos entendam os limites de um agente, bem como seus benefícios (CHEN, J. Y.; BARNES, 2014).

Verificou-se que as pessoas tendem a perceber a automação como sendo mais capaz e confiável do que as ajudas humanas (quando, de fato, a mesma informação foi fornecida aos participantes). No entanto, a ressalva é que as pessoas são mais sensíveis aos erros de automação do que aos erros de outro ser humano; essa sensibilidade relativa leva a uma queda mais rápida da confiança nos auxílios automatizados quando erros são detectados (CHEN, J. Y.; BARNES, 2014).

Como a previsibilidade é um aspecto crítico do desenvolvimento e manutenção da confiança, os comportamentos dos agentes que mudam ao longo do tempo podem impedir que os operadores calibrem adequadamente a confiança apropriada (DE VISSER; PEETERS; JUNG; KOHN; SHAW; PAK; NEERINGX, 2020).

Para erros de avaliação, o operador interpreta mal a solução ideal e comete um erro de calibração. Para erros de intenção, o operador está ciente da superioridade do auxílio, mas ainda escolhe não utilizar a automação para manter o controle sobre o ambiente de decisão.

Finalmente, as atitudes dos operadores humanos em relação à confiança nos sistemas automatizados também podem ser influenciadas por suas personalidades (por exemplo, introversão versus extroversão), fatores afetivos (por exemplo, humores e emoções) e estados de estresse como fadiga. De fato, com base em dados empíricos, Jessie YC Chen e Barnes (2014) observou que os efeitos devido a diferenças individuais nas habilidades cognitivas às vezes podem ser ainda maiores do que os efeitos causados pelas manipulações do projeto da interface.

A fim de aumentar a transparência da automação para o operador JD Lee (2012) propôs que os projetistas de sistemas tornassem os Objetivo, processo e desempenho (Purpose, Process and Performance) (3P) do sistema, bem como o histórico dos 3P visíveis ao operador. O objetivo lida com o grau em que a automação acionada por agente está sendo usada de acordo com a intenção do projetista. O processo lida com a questão de saber se o algoritmo do sistema automatizado é apropriado para uma determinada tarefa. O desempenho lida com a confiabilidade, previsibilidade e capacidade do sistema. Portanto para aumentar a transparência do sistema para o membro da equipe humana, os 3Ps do sistema, bem como o histórico dos 3Ps, deveriam estar visíveis para o operador. No entanto, a apresentação deve ser de forma simplificada (por exemplo, telas gráficas integradas) para que o operador não fique sobrecarregado com as informações adicionais que ele/ela precisa processar (CHEN, J. Y.; BARNES, 2014).

Na psicologia organizacional na área de planejamento e tomada de decisão, Herbert A Simon (1956) propôs o “Princípio da Satisfação” (SCHMITT; ROTH; SCHULTE, 2017), que descreve o comportamento dos tomadores de decisão. O princípio sublinha que o ser humano em geral não tenta encontrar uma solução ótima para um determinado problema. Em vez disso, ele para de trabalhar no problema assim que a solução é suficiente para o seu nível pessoal de aspiração. E o nível de aspiração do ser humano depende da situação atual. Isso significa que, em situações críticas, é suficiente uma solução de baixa qualidade. Por outro lado, em situações não críticas, o nível de aspiração pessoal do operador humano pode ser muito maior.

Por fim, um importante aspecto humano diz respeito à vontade de cooperar. A disposição de cooperar está relacionada às relações entre os seres humanos, bem como entre os seres humanos e os sistemas de assistência no que diz respeito à autoconfiança e à confiança. A disposição de cooperar pode ser vista como uma função crescente da confiança no sistema e uma função decrescente da autoconfiança. Portanto, quanto mais o homem confia no sistema de assistência, mais ele estará disposto a cooperar. Quanto mais o ser humano é autoconfiante, menos ele quer cooperar (PACAUX-LEMOINE; TRENTESAUX; REY; MILLOT, 2017).

Existem inúmeros casos de falha em sistemas autônomos, estes podem ser identificados em quatro tipos de erros humanos: nenhuma ação, ação apropriada mas tardia, ação agravante e ação ineficiente. E um estudo recente destaca que os pesquisadores geralmente negligenciam os pontos fortes e fracos dos operadores humanos (TRENTESAUX; MILLOT, 2016).

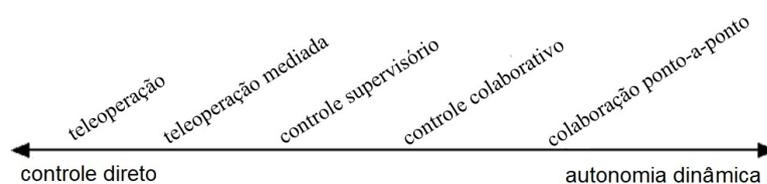


Figura 3 – Escala Níveis de Autonomia da interação humano-robô.

Fonte – (GOODRICH; SCHULTZ, 2008).

Em Goodrich e Schultz (2008), uma escala de LoA é usada para definir os tipos de interação homem-robô, variando do controle humano direto do robô (teleoperação) ao nível de pares (iniciativa mista), como representado na Figura 3. A interação de iniciativa mista é realizada por meio de autonomia dinâmica, que incorpora interações que variam do controle direto à total autonomia, com base no tipo de interação mais eficaz. Para abordar a autonomia dinâmica, Desai e Yanco (2005) exaltam a necessidade de deslizar nessa escala de autonomia, onde o modo de interação muda suavemente entre humanos e robôs à medida que a tarefa cooperativa evolui, não apenas em níveis discretos de autonomia, como é comumente implementado.

Dessa forma, as tarefas cooperativas entre humanos e máquinas tendem a progredir à medida que as máquinas tornam as tarefas onerosas para o operador humano e resultam em aumento de produtividade (KABER; ONAL; ENDSLEY, 2000; SAHAI; PACHERIE; GRZYNSZPAN; BERBERIAN, 2017). Além disso, vários trabalhos propuseram automação adaptativa para manter o envolvimento do operador no controle de sistemas complexos e aumentar a percepção da situação (KABER; ENDSLEY, 2004).

E conforme declarado por Harriott, Seiffert, Hayes e Adams (2014), as métricas de interação humano-robô são inadequadas para descrever as interações humano-*swarm* sozinhas devido aos desafios de interação impostos pelo *swarm*. Métricas tão comuns como eficácia da tarefa, tolerância à negligência, tempo livre, fan-out, esforço de interação, tempo de resposta à intervenção, entre outras, não são diretamente aplicáveis e precisam ser reformuladas para serem usadas (STEINFELD; FONG; KABER; LEWIS; SCHOLTZ; SCHULTZ; GOODRICH, 2006; OLSEN; GOODRICH, 2003).

Considerando-se este contexto de análise da interação humano-máquina através de conceitos provenientes do campo de fatores humanos, na próxima seção explora-se o conceito de agência como indicador para o projeto de sistemas IHS.

2.1 AGÊNCIA

A automação pode modificar a experiência do agente e essas mudanças podem impactar no desempenho do operador e na adequação do sistema. Posto isso, o conceito de agência fornece interpretações e evidências para uma melhor compreensão do impacto da inserção da automação.

O termo 'senso de agência' refere-se a: "a experiência de controlar as próprias ações e, por meio delas, os eventos do mundo exterior" (CHAMBON; HAGGARD, 2012). De acordo com a literatura, o senso de agência pode ser subdividido em três categorias: senso de intencionalidade, senso de iniciação e senso de controle (PACHERIE, 2008). Nesta tese considera-se o sentido de controle, pois conforme indicado por Le Goff, Rey, Haggard, Oullier e Berberian (2018), é o aspecto mais relevante nas interações homem-máquina. A definição e análise das três categorias de senso de agência são exploradas em Pacherie (2007) com mais detalhes.

Particularmente, Wegner e Wheatley (2010) afirmou que: "uma ação é percebida como desejada: (1) quando o pensamento precede a ação em um intervalo adequado (chamado princípio de prioridade), (2) quando o pensamento é compatível com a ação (princípio de consistência), e (3) quando o pensamento é a única causa aparente da ação (princípio de exclusividade)".

O sistema de processamento da agência pode ser distinguido por dois tipos distintos de medidas (Explícita vs Implícita) (MOORE; MIDDLETON; HAGGARD; FLETCHER, 2012; GALLAGHER, 2000). A primeira refere-se à capacidade de atribuir agên-

cia a si mesmo ou a outro. A avaliação do nível explícito pode ser feita por meio de métodos declarativos clássicos, como pesquisas e autorrelatos. O segundo tipo são as medidas implícitas, para evitar vieses de conformidade, como atenuação sensorial (WEISS; HERWIG; SCHÜTZ-BOSBACH, 2011) ou ligação intencional (IB) (HAGGARD; CLARK, S.; KALOGERAS, 2002); para uma revisão veja (MOORE; OBHI, 2012).

Além disso, Pacherie (2011) argumentou que as ações individuais são semelhantes às ações conjuntas com base no princípio da congruência entre os resultados previstos e reais. Sebanz, Bekkering e Knoblich (2006) definiu uma ação conjunta como “qualquer forma de interação social pela qual dois ou mais indivíduos coordenam suas ações no espaço e no tempo para provocar mudanças no ambiente”. Conseqüentemente, a capacidade de previsão é crucial para alcançar uma coordenação eficiente em uma ação conjunta.

Por outro lado, diferentemente das ações individuais, nas ações conjuntas é necessário considerar a intenção do outro. No entanto, é difícil para o operador criar um modelo mental dos agentes automatizados e, conseqüentemente, compreender suas ações. Isso é causado pelo aumento da automação e sistemas cada vez mais complexos (BERBERIAN, Bruno; SOMON; SAHAI; GOURAUD, 2017). A conseqüência, conforme descrito por Wiener (1989) é que: “Isso pode resultar em situações em que o operador fica surpreso com o comportamento da automação, e como conseqüência, ele faz perguntas como: “o que ele está fazendo agora?”, “por que fez isso?” ou “o que vai fazer a seguir?””.

Conforme indicado por Shneiderman e Plaisant (2010), os usuários desejam fortemente a sensação de que estão no comando do sistema e que o sistema responde às suas ações. E o senso de agência é relevante quando se trata de sistemas altamente automatizados, uma vez que uma diminuição na agência pode gerar preocupações críticas em relação a: aceitabilidade do sistema, comportamento do operador (BERBERIAN, 2019), degradação do monitoramento (CASPAR; CHRISTENSEN; CLEEREMANS; HAGGARD, 2016), que impactam diretamente na atuação de operadores humanos na supervisão do sistema associada a uma “difusão de responsabilidade” (CASPAR; VUILLAUME; MAGALHÃES DE SALDANHA DA GAMA; CLEEREMANS, 2017; MORETTO; WALSH; HAGGARD, 2011; FRITH, 2014).

Berberian (2019) testou se fornecer informações sobre o que o sistema está prestes a fazer leva a um aumento no nível de aceitabilidade do usuário, concomitante com um aumento no controle e desempenho e foi capaz de mostrar um aumento na eficiência do operador assumir o controle e um aumento no desempenho do time humano-máquina. Silva Tchilian, Moreno e Netto (2020) propôs um sistema de apoio com recomendações de ações a serem realizadas a cada instante e conseguiu mostrar um aumento no desempenho da tarefa. Le Goff, Rey, Haggard, Oullier e Berberian (2018) investigou como a previsibilidade do sistema impacta o desenvolvimento

da experiência da agência durante a interação homem-máquina, Bruno Berberian, Le Blaye, Schulte, Kinani e Sim (2013) forneceu evidências de que os princípios de prioridade, consistência e exclusividade podem ser usados para projetar interfaces homem-máquina capazes de compensar os efeitos negativos da latência no controle de ação.

Assim, um grande desafio no campo IHS com as próximas gerações de sistemas altamente automatizados é precisamente determinar como compensar essa diminuição no sentido de controle. Uma melhor compreensão do sentido da função de agência pode, portanto, contribuir para a reflexão sobre as interações com a tecnologia automatizada e, principalmente, para otimizar a interação humano-automação. Portanto, os recentes desenvolvimentos e aplicações do conceito de agência validam e fornecem ferramentas conceituais e medidas para analisar as interações agente-sistema.

Na próxima seção é apresentado um dos principais problemas decorrentes da diminuição da agência do operador.

2.2 O PROBLEMA DE DESEMPENHO FORA DA MALHA

Uma das consequências do projeto de um sistema automatizado que resulta em um baixo nível de agência é conhecido como o problema de desempenho OOTL. Este fenômeno ocorre quando um operador não consegue compreender as intenções e prever o resultado das ações do sistema, causando uma diminuição do controle. Em outras palavras, o fenômeno OOTL corresponde a uma falta de envolvimento na malha de controle do operador humano (LE GOFF; REY; BERBERIAN, Bruno, 2015). Os termos “confusão total”, “efeito surpresa” ou “nenhuma consciência do modo atual do sistema” indicam processos semelhantes (BERBERIAN, Bruno; SOMON; SAHAI; GOURAUD, 2017).

A dissociação entre o operador humano e a malha de controle, gerada pela inserção da automação, resulta em um declínio na competência do operador humano para interferir nas malhas de controle do sistema e assumir o controle manual quando necessário (BERBERIAN, Bruno; SOMON; SAHAI; GOURAUD, 2017).

As causas e soluções para o fenômeno OOTL, respectivamente, envolvem, mas não se limitam aos seguintes aspectos: diminuição na percepção de sinais importantes (BILLINGS, 1991; WIENER, 1988), confiança desequilibrada na capacidade do sistema (PARASURAMAN; MOLLOY; SINGH, 1993), diminuição na consciência situacional (ENDSLEY, 2018) ; oferecer informações de estado e sugerir ações de entrada para aumentar a eficiência e confiabilidade do trabalho em equipe, alterar o nível de automação do sistema ou preparar o supervisor/operador para situações críticas.

O problema de desempenho OOTL é delineado por três aspectos principais: falha em detectar e reconhecer o problema e por dificuldades para identificar soluções adequadas. Como consequências, podem ser citados maiores tempos de recuperação

do sistema, menor precisão de resposta e atrasos que podem dificultar a realização de todas as tarefas por parte dos operadores ou reduzir a eficácia das ações executadas. Entre outros problemas, pode-se citar a total incapacidade de detectar uma falha de automação, incapaz de decidir se uma intervenção é necessária, além do desconhecimento do curso de ação adequado para estabilizar o sistema e trazê-lo de volta ao controle. Assim, a automação mostrou impactar a aquisição de informações pelos operadores, análise de informações, tomada de decisão e ação (PARASURAMAN; SHERIDAN; WICKENS, 2008; BERBERIAN, Bruno; SOMON; SAHAI; GOURAUD, 2017). Inúmeros exemplos de incidentes e acidentes resultantes desses mal-entendidos do sistema foram relatados na literatura (SARTER; WOODS, 1995).

Conforme apontado por Le Goff, Rey e Bruno Berberian (2015) os três seguintes incidentes dos domínios de: aviação (Voo 447 da Air France, (B.E.A, 2012)), usina nuclear (incidente da usina nuclear de Three Miles Island, (NORMAN, 1988)) e finanças (negociação de alta frequência Knight Capital, (JONES, C. M., 2013)) ilustram tais dificuldades. Embora esses casos anteriores sejam de domínios diferentes, eles destacam que quando o equipamento autônomo falha, os operadores parecem drasticamente incapazes de analisar a situação e decidir a solução adequada porque desconhecem o estado do sistema precedente à falha.

Considerando a seguinte avaliação: “na maioria dos casos, os erros ocorreram em caso de mal-entendidos entre os operadores humanos e as máquinas, especialmente em ambientes altamente automatizados” destaca a mudança de perspectiva do problema de desempenho OOTL, de erro humano para falha de interação (BERBERIAN, 2019).

Portanto, na atual situação de crescente automação, a conscientização das dificuldades de interação humano-sistema é imperativa. Após décadas de pesquisa, os trabalhos da comunidade de fatores humanos trouxeram diferentes princípios de fatores humanos/ergonomia (HF/E) (ROUNDTREE; GOODRICH; ADAMS, 2019) como soluções para um melhor desempenho em equipe. Apesar disso, o problema de desempenho OOTL continua sendo um desafio (BERBERIAN, Bruno; SOMON; SAHAI; GOURAUD, 2017). Desta forma, uma plataforma para avaliar e analisar esses sistemas complexos é uma necessidade para avançar no projeto e implementação de sistemas IHS e possibilitar a retirada desses sistemas do laboratório.

No próximo capítulo é apresentada a plataforma de simulação desenvolvida nesta tese e suas características que visam contribuir no estudo da agência em sistemas de IHS com o objetivo de mitigar os problemas de interação humano-máquina que surgem em sistemas altamente automatizados e complexos, como os apresentados anteriormente.

3 PLATAFORMA DE SIMULAÇÃO IHS

Experimentos com equipes de robôs móveis no mundo físico geralmente representam uma tarefa desafiadora devido à complexidade envolvida. É preciso garantir que a configuração do hardware do robô, a integração do software e a interação com o ambiente sejam exaustivamente testadas para que a implantação das equipes de robôs funcione sem problemas. Isso geralmente requer muito tempo de preparação para as experiências e afasta o que é essencial, ou seja, a tarefa cooperativa executada pelos robôs.

Esta tese aborda o problema de controle por um único operador da navegação de um *swarm* em espaços urbanos não estruturados e compartilhados com pedestres. Na Figura 4, pode-se ver uma ilustração do sistema a ser considerado com os três tipos de agentes e as interações entre os mesmos.

A plataforma de simulação aqui desenvolvida implementa estes três tipos de agentes: teleoperador, robôs móveis (*swarm*) e pedestres e simula suas interações, como contextualizado no capítulo 2, através das ferramentas de simulação ROS e Gazebo, a fim de se avaliar o impacto que a automação possui na agência (seção 2.1) para mitigar os problemas apresentados pelo declínio do senso de agência (seção 2.2).

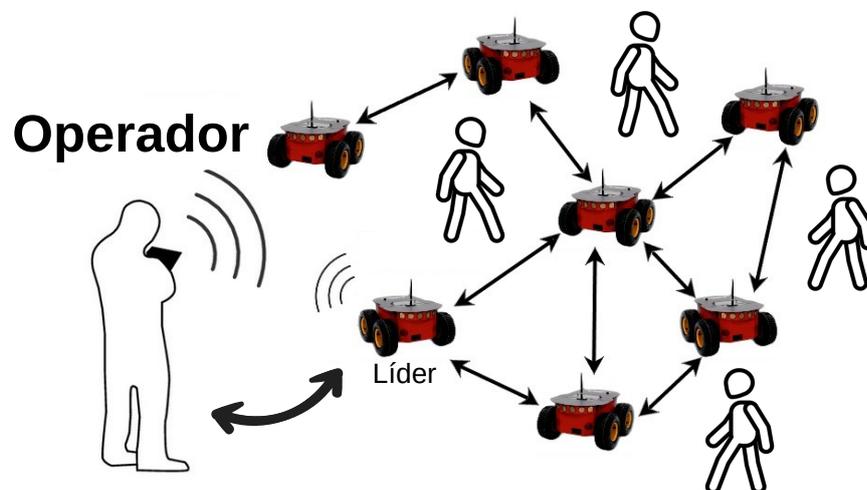


Figura 4 – Ilustração de teleoperação do *swarm* em um cenário compartilhado com pedestres (Link para o vídeo ilustrativo: <https://t.ly/kaXi>).

A seguir são definidos os modelos utilizados para implementação dos agentes que compoem o sistema na plataforma de simulação desenvolvida.

3.1 SWARM ROBÓTICO

Na simulação foram utilizados robôs móveis diferenciais com restrições não-holonômicas, embora os resultados nesta tese tenham validade geral e possam ser estendidos para outros tipos de veículos autônomos.

A coordenação entre o *swarm* robótico é realizado através de algoritmos de consenso por se tratarem de algoritmos distribuídos que não dependem de um agente central para sua execução. Suponha que haja n veículos na equipe. A topologia de comunicação da equipe pode ser representada pelo grafo direcionado $\mathcal{D} \triangleq (\mathcal{V}, \mathcal{E})$, onde $\mathcal{V} = \{1, \dots, n\}$ é o conjunto de nós e $\mathcal{E} \subseteq \mathcal{V} \times \mathcal{V}$ é o conjunto de arestas. O algoritmo de consenso de tempo contínuo é dado por:

$$\dot{x}_i(t) = - \sum_{j=1}^n a_{ij}(t) [x_i(t) - x_j(t)], \quad i = 1, \dots, n \quad (1)$$

onde $a_{ij}(t)$ é a entrada $\{i, j\}$ da matriz de adjacência $\mathcal{A}(\mathcal{D}) \in \mathbb{R}^{n \times n}$ associada a \mathcal{D} no tempo t e x_i é o estado de informação do i -ésimo veículo. Definir $a_{ij} = 0$ indica o fato de que o veículo i não pode receber informações do veículo j . Uma consequência da equação (1) é que o estado de informação $x_i(t)$ do veículo i é direcionado para os estados de informação de seus vizinhos.

A equação de consenso (1) é escrita em forma de matriz como:

$$\dot{x}(t) = -\mathcal{L}_n(t)x(t) \quad (2)$$

onde $x = [x_1, \dots, x_n]^T$ é o estado da informação e $\mathcal{L}_n(t) = [l_{ij}(t)] \in \mathbb{R}^{n \times n}$ é a matriz Laplaciana não-simétrica associada a \mathcal{D} . Um consenso é alcançado por uma equipe de veículos se, para todos os $x_i(0)$ e todos os $i, j = 1, \dots, n$, $|x_i(t) - x_j(t)| \rightarrow 0$, com $t \rightarrow \infty$.

Quando a comunicação entre veículos ocorre em instantes discretos, o estado das informações é atualizado usando uma equação de diferença. O algoritmo de consenso em tempo discreto tem a forma:

$$x_i[k+1] = \sum_{j=1}^n d_{ij}[k] x_j[k], \quad i = 1, \dots, n \quad (3)$$

Onde k denota um evento de comunicação; $d_{ij}[k]$ é a entrada (i, j) de uma matriz estocástica de linhas $\mathcal{A}(\mathcal{D}) = [d_{ij}] \in \mathbb{R}^{n \times n}$ no índice de tempo discreto k com a suposição adicional de que $d_{ij}[k] > 0$ para todos $i = 1, \dots, n$ e $d_{ij}[k] > 0$ para todos $i \neq j$ se a informação for do veículo j para o veículo i e $d_{ij}[k] = 0$, caso contrário.

Intuitivamente, o estado das informações de cada veículo é atualizado como a média ponderada de seu estado atual e dos estados atuais de seus vizinhos. Observe que um veículo mantém seu estado atual de informações se não trocar informações

com outros veículos naquele instante. A equação de consenso em tempo discreto (3) é escrita em forma de matriz como:

$$x[k+1] = D[k]x[k] \quad (4)$$

Semelhante ao caso de tempo contínuo, o consenso é alcançado se para todos os $x_i[0]$ e para todos os $i, j = 1, \dots, n$, $|x_i[k] - x_j[k]| \rightarrow 0$, com $k \rightarrow \infty$, sendo D uma matriz de Perron.

3.2 PEDESTRE

Os modelos baseados em força são uma das ferramentas mais importantes usadas para simular o movimento de multidões. Dentre estes, o Modelo de Força Social desenvolvido por (HELBING, 1991, 2010) é provavelmente o mais conhecido. Nesta tese o modelo de força social para o modelo de pedestre foi utilizado através de uma especificação de parâmetro para permitir que o modelo diferencie pedestres de robôs. Explorou-se a aplicabilidade do modelo de força social para a dinâmica de pedestres para simular o movimento de pedestres e a interação entre pedestres e robôs.

Neste modelo microscópico contínuo, três hipóteses baseadas na física newtoniana definem o comportamento do pedestre (KABALAN, 2016):

- Seja procurando para chegar a um destino ou apenas andando, cada pedestre tem uma direção desejada.
- Cada pedestre tenta andar na velocidade desejada.
- Os indivíduos tentam manter uma certa distância dos outros que não conhecem.

Contudo, a força social não satisfaz a terceira lei de Newton (ação=reação) por causa de sua natureza anisotrópica, isso significa que para dois pedestres i e j , $f_j^{SOC} \neq -f_i^{SOC}$ (KABALAN, 2016).

O modelo de força social¹ é usado como ponto de partida baseado no trabalho desenvolvido em (VALERO; ANTONELLI; CHRISTOFOROU; FARHI; KABALAN; GIOLDASIS; FOISSAUD, 2020). Neste modelo, o movimento de uma partícula i é determinado com base na relação:

$$\frac{d\vec{v}_i}{dt} = \vec{F}_i^a + \sum_{\text{outras partículas } j} \vec{F}_{j \rightarrow i} + \sum_{\text{obstáculos } k} \vec{F}_{k \rightarrow i} + \vec{\xi} \quad (5)$$

onde:

¹ Para situações gerais, sabe-se que o modelo de força social pode produzir comportamentos não naturais em comparação com pedestres reais.

- \vec{F}_i^a : a força propulsora para conduzir o objeto em direção ao seu objetivo.
- $\vec{F}_{j \rightarrow i}$: a força repulsiva do objeto j .
- $\vec{F}_{k \rightarrow i}$: a força repulsiva do objeto k .
- ξ : o erro do modelo.
- v_i é a velocidade.

A força propulsora pode ser expressa da seguinte forma:

$$\vec{F}_i^a = \frac{\vec{v}_{ides} - \vec{v}_i}{\tau_i} \quad (6)$$

$$\vec{v}_{ides} = -V_{0,j} \cdot \frac{\vec{\nabla}_x d(\vec{x}, \vec{s})}{\|\vec{\nabla}_x d(\vec{x}, \vec{s})\|} \quad (7)$$

onde:

- \vec{v}_{ides} é a velocidade desejada.
- τ_i é o tempo de relaxação que determina a capacidade do pedestre de seguir sua trajetória desejada em caso de perturbação.
- $V_{0,j}$ é a velocidade livre de obstáculos.
- $\frac{\vec{\nabla}_x d(\vec{x}, \vec{s})}{\|\vec{\nabla}_x d(\vec{x}, \vec{s})\|}$ nos fornece a direção e sentido desejado.

Uma expressão simples de força repulsiva é:

$$\vec{F}_{i \rightarrow j} = g(\theta_{ij}) \cdot A_{ij} e^{\left(-\frac{d(i,j)}{B_{ij}}\right)} \cdot \vec{n}_{ij} \quad (8)$$

$$g(\theta_{ij}) = \lambda_j + (1 - \lambda_j) \cdot \left(\frac{1 + \cos(\theta_{ij})}{2}\right) \quad (9)$$

Onde:

- $d(i,j)$ é a distância entre o objeto i e j ;
- \vec{n}_{ij} é o vetor unitário, orientado de i a j ;
- A_{ij} e B_{ij} são parâmetros que ajustam respectivamente a amplitude da força e a amplitude da distância;
- θ_{ij} é o ângulo entre a direção do objeto j e o objeto i .
- λ_j é um parâmetro, de modo que $\lambda_j = 1$ implica que a percepção do objeto/pedestre é totalmente isotrópica e, ao contrário, $\lambda_j = 0$, que a percepção é particularmente anisotrópica.

Os parâmetros A_{ij} e B_{ij} dependem tanto das características do objeto i quanto das características do objeto j . Isso nos permite distinguir interações entre:

1. pedestre \leftrightarrow pedestre.
2. pedestre \rightarrow robô.

$g(\theta_{ij})$ é uma função para representar a anisotropia da percepção dos objetos, pois os humanos geralmente estão mais atentos ao ambiente que se aproxima à frente do que ao ambiente que está atrás. Utilizou-se aqui uma expressão comum na literatura (HELBING; MOLNAR, 1995; DIAS; IRYO-ASANO; NISHIUCHI; TODOROKI, 2018; KABALAN, 2016).

3.3 TELEOPERADOR E O SENSO DE AGÊNCIA

Os seres humanos, interagindo com os Sistemas Ciber-Físicos (Cyber-Physical Systems) (CPS), formulam crenças sobre a dinâmica do sistema. É natural esperar que operadores humanos, encarregados de teleoperação, usem essas crenças para controlarem robôs remotos.

Nos casos em que é necessário um controle mais preciso sobre a operação de um *swarm*, ou quando um comportamento emergente desejado não pode ser gerado autonomamente e sem influência humana significativa, entradas contínuas podem ser fornecidas por um operador humano. Essas contribuições contínuas terão uma influência persistente sobre os líderes selecionados e indiretamente sobre o *swarm*, e tais situações requerem significativamente mais treinamento e atenção por parte do operador.

Em sua forma básica, a influência persistente é semelhante à teleoperação. Geralmente envolve alguma noção do estado do sistema que é retornado ao operador, que pode modificar as entradas de acordo. Esse controle geralmente requer uma malha de realimentação com baixa latência, garantindo que as entradas de controle sejam recebidas e processadas nos momentos necessários, e uma representação do estado do sistema que é interpretável pelo operador. Mas as interações próximas também são propícias ao controle contínuo, uma vez que o humano pode ser detectado pelos robôs continuamente e pode direcioná-los como um robô líder, e, portanto, qualquer movimento do operador é potencialmente uma entrada para o *swarm*.

Embora ainda não existam padrões definidos pela comunidade, normalmente avalia-se sistemas de IHS com relação a algum tipo de métrica de desempenho da tarefa. Isso geralmente resulta em métricas tradicionais de robótica móvel, como tempo de conclusão de tarefas, distância percorrida, consumo de energia e etc. Assim como, o número de comandos entregues e o número de comandos bloqueados pelo controlador por motivos de segurança. Pode-se dividir as métricas existentes em cinco tipos de

classes de indicadores que podem ser usados para avaliar o estado do sistema no IHS: indicadores de desempenho, indicadores de interação, indicadores de complexidade, indicadores de automação do *swarm* e indicadores de estado humano.

Portanto o senso de agência representa um indicador com uma abrangência ampla e que parte do paradigma de projeto centrado no humano, ou seja, focado em fatores humanos para determinar como o sistema deve ser implementado e quais as possíveis vantagens e desvantagens que determinada funcionalidade pode acarretar na execução da tarefa.

Esta tese não sugere que este deve ser o único indicador a ser utilizado, mas que o senso de agência nos fornece novas ferramentas conceituais e medidas para melhorar e otimizar o projeto, controle e interação dos sistemas IHS. De fato, é provável que, para alcançarmos o nível de sistemas operacionais, seja necessária alguma combinação híbrida, com outras abordagens de avaliação.

Claramente, uma área em que o senso de agência é importante, mas pode ser difícil de alcançar, são as interações com sistemas complexos. Particularmente, nenhum estudo, até onde sabemos, investigou o senso de agência em sistemas IHS.

A capacidade de medir a sensação de controle é importante para avaliar diferentes dispositivos automatizados, pois é relevante para avaliar o desempenho do operador. Assim, uma melhor medição e compreensão do fenômeno psicológico do senso humano de controle pode contribuir para melhorar o projeto de sistemas automáticos. Consequentemente, central para o senso de agência é a contiguidade temporal entre a ação de alguém e os efeitos resultantes, bem como o inverso, as ações intencionais humanas produzem mudanças sistemáticas na percepção do tempo (BERBERIAN, Bruno; SARRAZIN; LE BLAYE; HAGGARD, 2012).

3.4 SISTEMAS DE SUPORTE À TELEOPERAÇÃO (SST)

Um dos principais problemas para o projeto de sistemas avançados de assistência é prever o comportamento do operador. Utiliza-se uma abordagem interdisciplinar que consiste no projeto de sistemas IHS com base em um modelo que representa implicitamente os processos perceptivos, motores e cognitivos humanos envolvidos na tarefa.

Esse modelo e sua aplicação se concentram especificamente na teleoperação, embora a mesma abordagem possa ser adaptada para outros tipos de interação dinâmica humano-*swarm*. Portanto, a inspiração para o modelo foi a dificuldade em se modelar todas as características referentes a psicologia da percepção e da neurofisiologia dos sistemas motores.

A lógica por trás dessa abordagem foi primeiro construir um modelo baseado em dados do sistema IHS, que pode ser relevante tanto para a teoria do controle quanto para a ciência do comportamento humano. Do ponto de vista mais prático, era também

uma maneira de orientar as escolhas de projeto em função de hipóteses específicas sobre a natureza dos sistemas perceptivos e motores.

Por outro lado, uma abordagem cibernética visa representar os processos psicológicos e fisiológicos subjacentes, de acordo com o conhecimento atual sobre controle e cognição sensorial e motora em humanos. Porém o modelo baseado em dados é poderoso para fazer inferências e identificar parâmetros do sistema.

A tarefa básica do operador humano é controlar, de alguma maneira prescrita, um sistema dinâmico. Várias saídas do sistema podem ser motivo de preocupação e o operador possui duas entradas, através da qual ele pode controlar o sistema teleoperado, velocidade linear e velocidade angular.

O modelo proposto baseia-se na hipótese de que o operador utiliza informações visuais para identificar a localização futura, bem como a posição, velocidade e direção dos agentes no sistema em relação ao agente teleoperado.

Também são realizados experimentos abrangentes em simuladores, usando a identificação e o modelo proposto para melhor entender a estratégia de operação humana e capturar várias características e estados do operador.

O desempenho da equipe de agentes humanos não é limitado pelo poder de computação, mas pela capacidade dos agentes autônomos de entender os seres humanos. Isso é evidenciado pela maioria dos sistemas atuais que assumem dados de entradas humanas fixas e estereotipadas, voltadas para um ser humano “médio”.

Esses sistemas pressupõem que a qualidade da ação de entrada humana, que geralmente é considerado de baixo ruído e alta precisão, seja estática ao longo do tempo e entre indivíduos. Consideramos que essa é uma suposição fundamentalmente falha por causa das diferenças inter e intraindividuais em seres humanos e agentes. Para levar em conta a variabilidade humana durante a IHS, as tecnologias de avaliação humana contínua combinam as tecnologias de detecção humana e ambiental, fornecendo os elementos fundamentais para que os sistemas gerem previsões, momento a momento, da dinâmica comportamental e de desempenho interna e externa do indivíduo em ambientes operacionais e de treinamento. Fundamentalmente, essa capacidade permite que os sistemas passem de uma abordagem de mitigação dos efeitos da variabilidade humana para uma que incorpore preditivamente essa variabilidade.

Conforme Figura 6 pode-se observar que o operador será responsável por teleoperar um líder de controle através de comandos de velocidade para que tenha uma influência persistente e contínua nos outros agentes do *swarm*, ou seja, a ação de controle no líder de controle irá se propagar através dos agentes adjacentes para todo o *swarm*. E, por outro lado, todos os agentes desempenham o papel de líderes de informação, retornando informações ao operador, através da comunicação, para composição do SST.

3.4.1 Sistema de Suporte à Teleoperação *Long-Short Term Memory*

Há uma ampla gama de métodos de Aprendizado de Máquina (Machine Learning) (ML), incluindo Redes Neurais Artificiais (Artificial Neural Networks) (RNA), máquinas de vetores de suporte, sistemas de inferência nebulosa, etc. Embora cada um desses métodos possa ser adaptado para resolver o problema em questão, as RNA são escolhidas para este trabalho pelas razões que serão explicitadas a seguir.

Primeiramente, as RNA são aproximadores de funções universais, o que significa que, para cada função limitada contínua, existe uma RNA que pode aproximar essa função a qualquer nível de precisão desejado (HORNİK; STINCHCOMBE; WHITE *et al.*, 1989). Máquinas de vetores de suporte (ANDRAS, 2002; HAMMER; GERSMANN, 2003) e sistemas de inferência nebulosa (KOSKO, 1994) compartilham a mesma propriedade. De fato, RNA, sistemas de inferência nebulosa e máquinas de vetores de suporte são funcionalmente equivalentes (LI, H.-X.; CHEN, C. P., 2000). No entanto, cada um deles foi projetado para tarefas específicas. Máquinas de vetores de suporte são adequadas para problemas de classificação. Embora um problema de classificação possa ser considerado um problema de aproximação de função, o inverso nem sempre é verdadeiro porque a saída de uma função pode ser com valor real, enquanto em um problema de classificação a saída da função (classificador) é um conjunto de valores discretos, cada um representando uma classe. Não existe uma fronteira tão clara entre os sistemas de inferências nebulosas e as RNA, pois ambos são capazes de representar sistemas semelhantes com precisão. Porém a inferência nebulosa depende de conhecimento especializado para representar o sistema e, portanto, tende a ser empregada apenas em situações em que esse conhecimento está disponível.

As RNN são uma classe de RNA e, portanto, também possuem a propriedade de aproximação universal (SCHÄFER; ZIMMERMANN, 2006) e, em teoria, podem reconstruir trajetórias no espaço de estados de sistemas dinâmicos tanto contínuos (FUNAHASHI; NAKAMURA, 1993) quanto discretos (JIN; NIKIFORUK; GUPTA, 1995).

As RNN possuem dinâmica e são aproximadores universais para reconstruir trajetórias no espaço de estados de sistemas dinâmicos (SCHÄFER; ZIMMERMANN, 2006), que os tornam modelos candidatos adequados para o problemas de previsão. Em (FUNAHASHI; NAKAMURA, 1993), é mostrado que qualquer trajetória de tempo finito de um sistema dinâmico pode ser aproximada por alguma RNN a qualquer nível de precisão desejado, dado um estado inicial adequado. Este resultado é estendido para RNN discretas em (JIN; NIKIFORUK; GUPTA, 1995).

Então por conta das propriedades atendidas pelas RNN como exposto anteriormente e sua inerente capacidade de representar sistemas dinâmicos, escolheu-se as RNNs como o método a ser implementado para identificação do comportamento humano.

Um estudo abrangente sobre arquiteturas das RNN podem ser encontrados

em (KOLEN; KREMER, 2001; MANDIC; CHAMBERS, 2001). E em (OGUNMOLU; GU; JIANG; GANS, 2016), algumas arquiteturas de redes neurais, como Perceptron Multicamadas (Multilayer Perceptron) (MLP), RNN simples, assim como LSTM e Unidades Recorrentes Fechadas (Gated Recurrent Unit) (GRU) são comparadas entre si na modelagem de sistemas dinâmicos robóticos com comportamentos complexos.

As LSTMs são o estado da arte das RNNs e diversas variantes da arquitetura foram propostas desde o seu início em 1995. Porém de acordo com uma análise em larga escala de oito variantes de LSTM em três tarefas representativas desenvolvida por (GREFF; SRIVASTAVA; KOUTNIK; STEUNEBRINK; SCHMIDHUBER, 2016), os resultados demonstraram que nenhuma das variantes foi capaz de melhorar significativamente a arquitetura padrão da LSTM.

As definições, provas e demais propriedades podem ser encontradas em livros com tratamentos modernos e abrangentes em RNA tais como (SIMON, H., 1999; KOLEN; KREMER, 2001; BISHOP, 2006; LECUN; BENGIO; HINTON, 2015).

3.4.2 Sistema de Suporte à Teleoperação Preditivo

Nesta seção é desenvolvido um SST preditivo, baseado em (ORDOÑEZ; MORENO; CERQUEIRA; ALMEIDA, 2014), cujo desenvolvimento é explanado a seguir. A predição fornece uma sugestão de trajetória baseada na minimização de um funcional sujeito à restrições. A função objetivo busca minimizar a diferença do estado da informação do robô teleoperado para os demais robôs adjacentes considerando as restrições da dinâmica dos estados da informação e do sinal de controle.

A cada instante, mediante o uso do modelo do sistema, os estados futuros são preditos para o horizonte de predição N_p . A predição dos estados $\xi[k + k_j|k]$ para $k_j = 1, \dots, N_p$ depende dos valores no instante t (estados e controles passados) e dos sinais de controle futuros $u[k + k_j|k]$ para $k_j = 1, \dots, N_p - 1$, os quais serão calculados.

O sinal de controle $u[k]$ é aplicado no processo e todos os outros sinais de controle da sequência de controles futuros são rejeitados, dado que no próximo instante amostral, o algoritmo é repetido para calcular o novo controle $u[k + 1|k + 1]$, ou seja, a cada iteração uma janela deslizante com horizonte N_p é utilizada para predição dos estados.

A estratégia de controle cooperativo descentralizado e individual, é utilizada de forma que cada veículo integrante da equipe possa calcular a própria trajetória de consenso para solucionar o problema de *rendezvous*, no qual um grupo de agentes deve se encontrar em um ponto em comum, baseado apenas na comunicação local. Para tal, a troca de informação está limitada à uma relação entre veículos vizinhos. É importante ressaltar que as trajetórias de consenso relacionadas ao estado da informação estão sempre associadas às posições dos veículos nos eixos x e y , em que denota-se por $\xi_i^{(x,y)}$ para $i = 1, \dots, n$.

Seja a equação:

$$u_i = - \sum_{j=1}^n a_{ij} (\xi_i^{(x,y)} - \xi_j^{(x,y)}) - a_{i(n+1)} (\xi_i^{(x,y)} - \xi_r^{(x,y)}) \quad (10)$$

para $i = 1, \dots, n$. Na qual $\xi_i^{(x,y)} \in \mathbb{R}^m$ é o estado da informação do veículo i , $\xi_j^{(x,y)} \in \mathbb{R}^m$ são os estados da informação dos veículos vizinhos $j \in N$, $\xi_r^{(x,y)} \in \mathbb{R}^m$ é o estado de referência e a_{ij} com $i = 1, \dots, n$ e $j = 1, \dots, n+1$ é a entrada (i, j) da matriz de adjacência $\mathcal{A}_{n+1} \in \mathbb{R}^{n \times (n+1)}$.

Assim, define-se um J_i :

$$\begin{aligned} J_i[k] = & \sum_{j=1}^n \sum_{k_j=1}^{N_p} \|\hat{\xi}_i[k+k_j|k] - \hat{\xi}_j[k+k_j|k]\|_{\Delta\xi}^2 \\ & + \sum_{k_j=1}^{N_p} \|\hat{\xi}_i[k+k_j|k] - \hat{\xi}_r[k+k_j|k]\|_{\Delta e}^2 \\ & + \sum_{k_j=1}^{N_u} \|\Delta u_i[k+k_j|k]\|_{\lambda_{u_i}}^2 \end{aligned} \quad (11)$$

em que n é o número de veículos, N_p é o horizonte de predição e conseqüentemente, o tamanho da janela deslizante. As notações $\hat{\xi}_i[k+k_i|k]$ e $\hat{\xi}_j[k+k_i|k]$ são as predições dos estados i e j , respectivamente, para $k_i = 1, \dots, N_p$ a partir do instante atual k . Em relação ao esforço de controle, tem-se que N_u é o horizonte de controle, $\Delta u_i[k]$ é o incremento de controle e λ_{u_i} é uma função no tempo que permite quantificar a penalização no sinal de controle de acordo com o comportamento desejado do sistema.

As matrizes $\Delta\xi$ e Δe estão compostas pelos valores da matriz de adjacência correspondentes. Desta forma, quando não há canal de comunicação habilitado entre os veículos i e j (i.e., i e j não são vizinhos), os respectivos parâmetros de entrada da matriz $\Delta\xi$ são nulos. De forma similar, quando o veículo i não recebe informação acerca da referência, já que o conhecimento é limitado, o respectivo parâmetro de entrada da matriz Δe é nulo.

Desta forma, pode-se propor o seguinte problema de otimização:

$$\begin{aligned} \min_{u_i[k]} \quad & J_i = L(\hat{\xi}[k+1|k], \hat{\xi}_j[k+1|k], \Delta U_i) \\ \text{s.t.} \quad & \dot{\xi} = f(\xi[k+1|k], \xi_j[k+1|k], u_i[k+1|k]) \end{aligned} \quad (12)$$

com $u_i[k+1|k] \in U$ e $k_i = 0, \dots, N_p - 1$, em que a minimização do funcional J_i associado a uma função L está sujeita a restrições da dinâmica dos estados da informação $\xi_i[k+k_i+1|k]$ e do sinal de controle $u_i[k+k_i|k] \in U$.

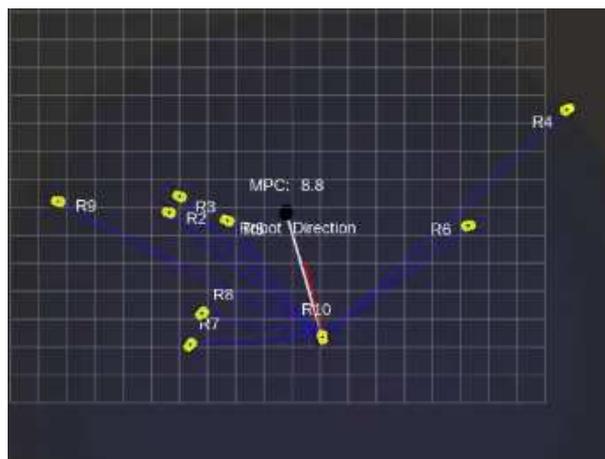


Figura 5 – Exemplo de interface para o SST preditivo. As linhas azuis representam a conexão do robô teleoperado com os vizinhos e a linha branca a trajetória sugerida para aquele instante de tempo.

Realizando as devidas manipulações algébricas podemos reescrever J_j que pode ser expresso como um problema de formulação quadrática dado por:

$$\begin{aligned} \min_{u_j} \quad & J_j = \frac{1}{2} U_j^T H_j(\xi_i, \xi_j) U_j + f_j^T(\xi_i, \xi_j) U_j \\ \text{s.t.} \quad & \dot{\xi} = u_j \\ & u_j \in U \end{aligned} \quad (13)$$

Na Figura 5 pode-se observar na interface do operador a implementação do SST preditivo com indicações visuais da trajetória sugerida pelo sistema.

3.4.3 Sistema de Suporte à Seleção de Líderes

Um método para lidar com a complexidade de controlar um *swarm* é permitir que um operador selecione e controle um agente ou subconjunto do *swarm*, reduzindo assim o número de robôs que devem ser considerados simultaneamente. Indivíduos ou grupos de robôs selecionados por um operador são frequentemente indicados como líderes, pois espera-se que eles influenciem e liderem o *swarm* restante.

A seleção de um pequeno conjunto de robôs individuais como líderes abre a possibilidade de formas de controle mais envolventes que também são usadas para sistemas de um e vários robôs, como teleoperação. A principal diferença entre *swarms* controlados por líderes e outros sistemas é que os líderes têm uma influência que se propaga através do *swarm*, e um operador deve tentar controlar todo o *swarm* através dessa influência propagada. As principais questões que surgem no controle baseado em líderes são (KOLLING; WALKER; CHAKRABORTY; SYCARA; LEWIS, 2015):

1. a melhor maneira de selecionar o líder;

2. se um líder selecionado continua sendo um líder em um cenário ou se a liderança é transitória;
3. como controlar os efeitos de propagação no *swarm* restante;
4. como os líderes devem interagir com os membros do *swarm* próximos.

Apesar disso, a seleção de líderes de *swarm* pode permitir esse controle. E nesse caso, o controle de um único líder ou de um grupo de líderes é semelhante à teleoperação simples ou multi-robô. A seleção de líderes únicos ou pequenos grupos de líderes tem sido a escolha padrão para grande parte do trabalho em IHS que envolvem influência persistente e contínua.

O argumento aqui é que nem sempre são necessárias informações completas para o melhor desempenho. De fato, pode-se pensar em situações nas quais isso pode realmente ser prejudicial ao desempenho. Por exemplo, ao lidar com um número maior de robôs, o operador pode rapidamente ficar sobrecarregado com informações completas e incapaz de entender o comportamento global que ocorre.

Sendo assim, nos casos em que é necessário um controle mais preciso sobre a operação de um *swarm*, ou quando um comportamento emergente desejado não pode ser gerado de forma autônoma e sem influência humana significativa, as entradas podem ser fornecidas por um operador humano. Essas contribuições contínuas terão uma influência persistente nos líderes selecionados e indiretamente no *swarm*, e tais situações exigem muito mais treinamento e atenção do operador. Em sua forma básica, a influência persistente é semelhante à teleoperação, com a principal diferença de que a influência do movimento do líder sobre o *swarm* deve ser levada em consideração.

As contribuições recentes abordam o problema de seleção de líderes online, onde o líder pode ser constantemente selecionado em função do estado atual do sistema para otimizar algum critério adequado (FRANCHI; BÜLTHOFF; GIORDANO, 2011). Uma estratégia de seleção de líder online baseada em confiança é proposta em (SAEIDI; MIKULSKI; WANG, Y., 2017) que reduz a carga de trabalho física do operador usando a confiança de humano para robô como um critério dinâmico para selecionar o líder e a confiança de robô para humano é usada para dinamicamente dimensionar o feedback de força háptica. A maioria dos trabalhos considera o ser humano o tomador de decisão de nível superior para influenciar e controlar o comportamento da equipe de robôs (LEE, D.; SPONG, 2005; EGERSTEDT, M.; CROIX; KAWASHIMA; KINGSTON, 2014).

As estratégias baseadas no líder podem ser divididas em dois métodos designados como liderança tácita via consenso (sem distinção explícita líder/seguidor) e liderança explícita via inundação (a propagação da influência do líder tem precedência) (AMRAII; WALKER; LEWIS; CHAKRABORTY; SYCARA, 2014).

Inúmeros trabalhos compararam uma estratégia de agente fixo a uma tática de seleção dinâmica de agentes, demonstrando a melhora no desempenho geral do grupo de robôs. Por exemplo, alternar os líderes dinamicamente pode otimizar a taxa de sincronização de velocidade para a equipe de robôs (FRANCHI; BÜLTHOFF; GIORDANO, 2011), melhorar o rastreamento coletivo e a manutenção da formação (FRANCHI; GIORDANO, 2016), a proporção de velocidades dos seguidores para o líder é maximizada pela seleção dinâmica de líder (KAWASHIMA; EGERSTEDT, M., 2012) e também pode atenuar o efeito de ataques cibernéticos (CLARK, A.; BUSHNELL; POOVENDRAN, 2013, 2012).

As restrições de comunicação impõem que em sistemas IHS pode ser mais eficiente para o operador interagir com o *swarm* através de um único agente ou um subconjunto de agentes ao invés de se comunicar diretamente com todos os membros do *swarm* (NUNNALLY; WALKER; KOLLING; CHAKRABORTY; LEWIS; SYCARA; GOODRICH, 2012). A sobrecarga de comunicação pode ser minimizada através do uso de agentes posicionados de forma otimizada dentro do *swarm* para disseminação de informações pela rede robótica (LEWKOWICZ; AGARWAL; CHAKRABORTY, 2019).

O sistema de suporte proposto tem por objetivo apresentar um sistema de apoio à decisão para facilitar o controle efetivo do *swarm*. Considere o problema de seleção do agente ótimo no sistema à partir de uma rede de agentes executando um algoritmo de consenso de informações, ou seja, uma abordagem para o problema de seleção dinâmica de robôs. O agente ótimo é definido por uma estrutura para a seleção de agentes com base na consideração conjunta da conectividade e no desempenho da pontuação do autovetor de centralidade.

Considere um conjunto conectado de robôs, modelado como um grafo $\mathcal{D} = (\mathcal{V}, \mathcal{E})$, onde \mathcal{V} denota o conjunto de robôs e \mathcal{E} denota o conjunto de arestas de comunicação entre os robôs. Portanto, existe uma aresta e_i entre dois vértices $v_i \rightarrow v_j$ se o robô j correspondente estiver na faixa de comunicação ρ do do outro robô i . Seja $\mathcal{T} \subset \mathcal{V}$ o robô teleoperado do *swarm*. O robô teleoperado é o robô que atua como canal de comunicação entre o *swarm* e o operador humano.

O valor do autovetor de centralidade é uma métrica que quantifica a influência de um nó sobre a rede, ou seja, mede quantas conexões um nó possui e o quanto seus vizinhos valorizam seu estado de informação. Essa medida foi proposta pela primeira vez por (BONACICH, 1972) e, desde então, é amplamente adotada para definir a importância relativa de um agente em uma rede.

Existem muitas medidas de centralidade, como por exemplo, a centralidade de Katz (KATZ, 1953) e a centralidade Page Rank (GLEICH, 2015). Nesta tese é considerado o autovetor de centralidade devido à sua relação com algumas propriedades algébricas da rede, que serão mostradas em simulações e experimentos.

Para uma matriz $\mathbf{W} \in \mathbb{R}^{n \times n}$, um autovetor esquerdo correspondente ao autovalor

λ_i é um vetor $\mathbf{v}_i \in \mathbb{C}^n$ satisfazendo $\mathbf{v}_i^\top W = \lambda_i \mathbf{v}_i^\top$.

Os valores do autovetor de centralidade são calculadas como

$$\sigma = \mathbf{v}_{max} / \|\mathbf{v}_{max}\|_1 \quad (14)$$

onde $\mathbf{v}_{max} \in \mathbb{R}^n$ é o autovetor esquerdo dominante, ou seja, associado ao autovalor máximo (para uma matriz estocástica de linhas, $|\lambda_n| = 1$). O i -ésimo elemento de $\sigma = [\sigma_1 \dots \sigma_n]^\top$ é chamado de valor de centralidade do agente i .

Essa medida de desempenho garante que selecionemos o robô que minimize o número de iterações ou o tempo para convergir para o consenso de informações desejado. Dessa forma, líderes ótimos são aqueles que estão bem conectados dentro da rede, especificamente, um líder é considerado ótimo se leva a uma rede conexa e minimiza o tempo para chegar a um consenso.

Uma vez definidos os modelos utilizados para implementação dos agentes que compõe o sistema, a seguir apresenta-se a plataforma de simulação desenvolvida.

3.5 PLATAFORMA DE SIMULAÇÃO

Neste trabalho, apresenta-se uma estrutura baseada em ROS para simulação do sistema de IHS. Utilizando o simulador Gazebo, tem-se ferramentas para executar, comparar, analisar e integrar novos algoritmos para execução de tarefas com vários robôs. Com essa estrutura, pode-se concentrar principalmente nos desafios específicos das tarefas, executar testes exaustivos em diferentes cenários e com diferentes tamanhos de equipes em um ambiente bastante realista e, por fim, executar experimentos mais rápidos no mundo real, imitando a configuração dos experimentos simulados.

Sendo assim, escolheu-se o ROS como o *framework* do sistema por possuir integração com uma coleção de ferramentas, bibliotecas e convenções que simplificam a tarefa de criar algoritmos em uma ampla variedade de plataformas robóticas e o Gazebo para simulação 3D do ambiente e os robôs devido seu suporte nativo neste framework e por facilitar a transição de uma plataforma de simulação para uma plataforma experimental.

O hardware utilizado para as simulações computacionais possui placa gráfica NVidia GeForce GTX 1050, 8 GB de RAM e processador Intel Core i7-7700HQ. O sistema operacional utilizado foi o Linux Ubuntu 18.04 LTS e o middleware de integração foi a distribuição ROS Melodic.

Considere um sistema IHS no qual um operador é responsável por teleoperar/supervisionar um grupo de n robôs e garantir a realização da tarefa. O operador pode selecionar e controlar um dos robôs para operar simultaneamente, através do qual o *swarm* será controlado. Os robôs possuem comunicação com agentes adjacentes e o operador é capaz de perceber os vizinhos do robô que está sendo comandado e exibido na interface do operador.

Então, a missão do operador é orientar o *swarm* para garantir o cumprimento da tarefa e, quando necessário, assumir o controle de algum robô. O consenso de informações garante que os agentes que compartilham informações na topologia da rede tenham uma visão consistente das informações críticas para a tarefa de coordenação. O sistema de supervisão e controle da teleoperação do *swarm* robótico é realizado em um cenário urbano simulado com pedestres para capturar a dinâmica e as interações entre operadores, usuários, artefatos técnicos e o ambiente durante a realização das tarefas.

Daqui em diante é proposta uma plataforma de simulação para obter percepções para um projeto centrado no ser humano de sistemas IHS, permitindo compreender como diferentes aspectos impactam a capacidade do operador de transmitir sua intenção ao *swarm* para cumprir uma determinada missão, por exemplo: diferentes LoA, métodos de controle, configurações e informações de estado exibidas. A ilustração da arquitetura proposta do sistema *IHS* é mostrada na Figura 6.

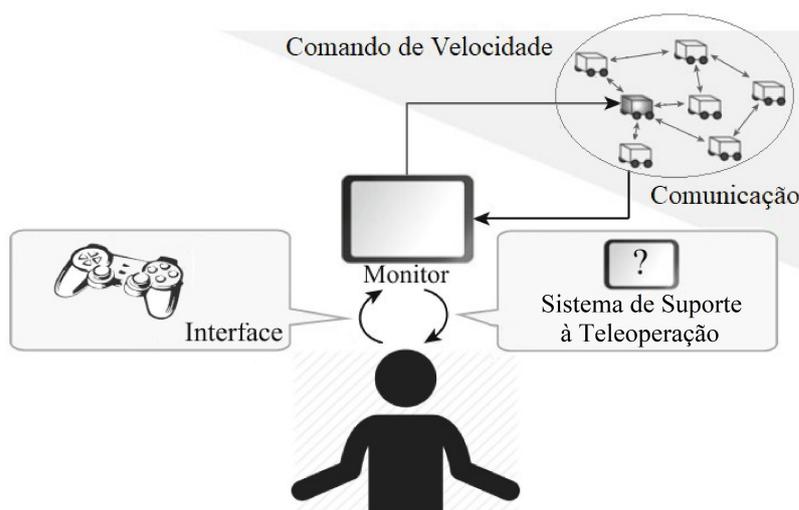


Figura 6 – Arquitetura de simulação.

Os métodos de controle para transmitir a intenção do operador a um *swarm* podem ser divididos em quatro tipos: (1) selecionar comportamentos de *swarm* desejados, (2) alterar parâmetros nos algoritmos de controle do *swarm*, (3) controle indireto por alteração do ambiente e (4) controle através de diferentes estratégias de liderança de *swarm* (KOLLING; WALKER; CHAKRABORTY; SYCARA; LEWIS, 2015). Algumas dessas estratégias de liderança de *swarm* são exploradas em inúmeros artigos como (WALKER; AMRAII; CHAKRABORTY; LEWIS; SYCARA, 2014; GOODRICH; KERMAN; JUN, 2012; WALKER; AMRAII; LEWIS; CHAKRABORTY; SYCARA, 2013, 2014; TIWARI; JAIN; BUTAIL; BALIYARASIMHUNI; GOODRICH, 2017;

CROIX; EGERSTEDT, M. B., 2012; MA; XIE, 2018).

A entrada de controle do operador no robô teleoperado se propagará pelos agentes vizinhos do *swarm*, conforme declarado pelo algoritmo de consenso. O papel do operador é, portanto, supervisionar e, quando necessário, interferir no *swarm* assumindo o controle e teleoperando um dos robôs através de um joystick (Figura 7).



Figura 7 – Joystick utilizado na tarefa de teleoperação.

Os agentes autônomos possuem um algoritmo de desvio de obstáculos implementado através do planejador de trajetória global *A** (HART; NILSSON; RAPHAEL, 1968) e do planejador de trajetória baseado em *rollout* (GERKEY; KONOLIGE, 2008), disponível no framework ROS, para que os robôs sejam capazes de alcançar o ponto de consenso de forma autônoma.

A seguir, é apresentada a plataforma proposta para a operação de um sistema IHS. Primeiramente, foi construído um cenário de praça central de uma cidade para realizar as simulações (veja a Figura 8).



Figura 8 – Cenário da praça da cidade.

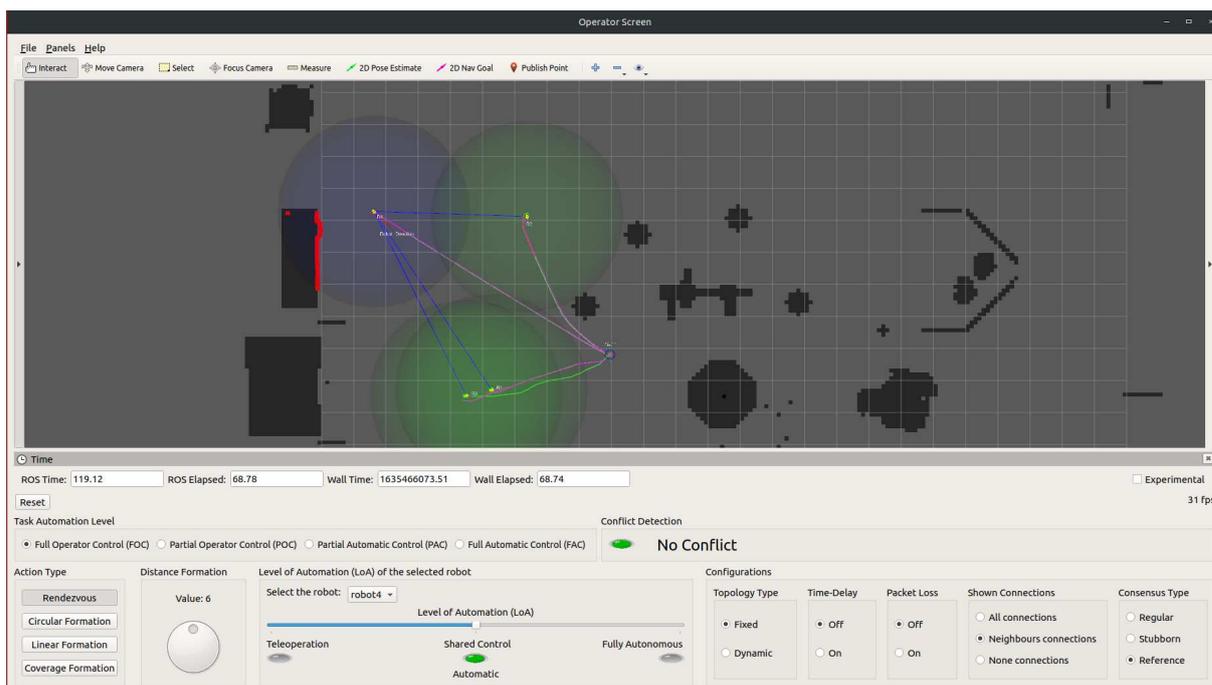


Figura 9 – Tela do operador

A tela do operador desenvolvida pode ser vista na Figura 9. Essa interface pode ser subdividida em cinco segmentos principais que serão designados a seguir:

1) O primeiro segmento é o “Tipo de Ação” que corresponde ao método de controle de seleção de comportamentos de *swarm* desejados. Neste módulo o operador pode escolher entre quatro opções: *rendezvous*, formação circular, formação linear, formação de cobertura. O primeiro comportamento corresponde a um processo frequentemente encontrado em sistemas de *swarms* naturais e muitas vezes foi adaptado a *swarms* artificiais, o objetivo básico é mover todo o *swarm* para um local comum. O segundo comportamento corresponde ao *swarm* adotar uma formação circular ao redor do robô selecionado e manter essa formação durante a locomoção. O terceiro comportamento designa a opção, na qual o *swarm* se move em formação de linha, com um robô atrás do outro. Por fim, a formação de cobertura denota o comportamento em que os robôs assumem um movimento lado a lado. Esses componentes da interface podem ser vistos na Figura 10 e a ilustração do comportamento é apresentada na Figura 11.

2) O próximo módulo é o método de controle para alteração de parâmetros no algoritmo de *swarm* (Figura 12). O parâmetro escolhido para ser modificado é a distância a ser mantida entre os robôs ou do valor de consenso da informação, dependendo do comportamento a ser realizado.

3) No terceiro módulo é possível alterar os Níveis de Autonomia (Levels of Autonomy) (LoA) do robô selecionado (Figura 13). De acordo com (GOODRICH; OLSEN; CRANDALL; PALMER, 2001) a autonomia ajustável qualifica-se como um sistema



Figura 10 – Trecho da interface para os tipos de ação.

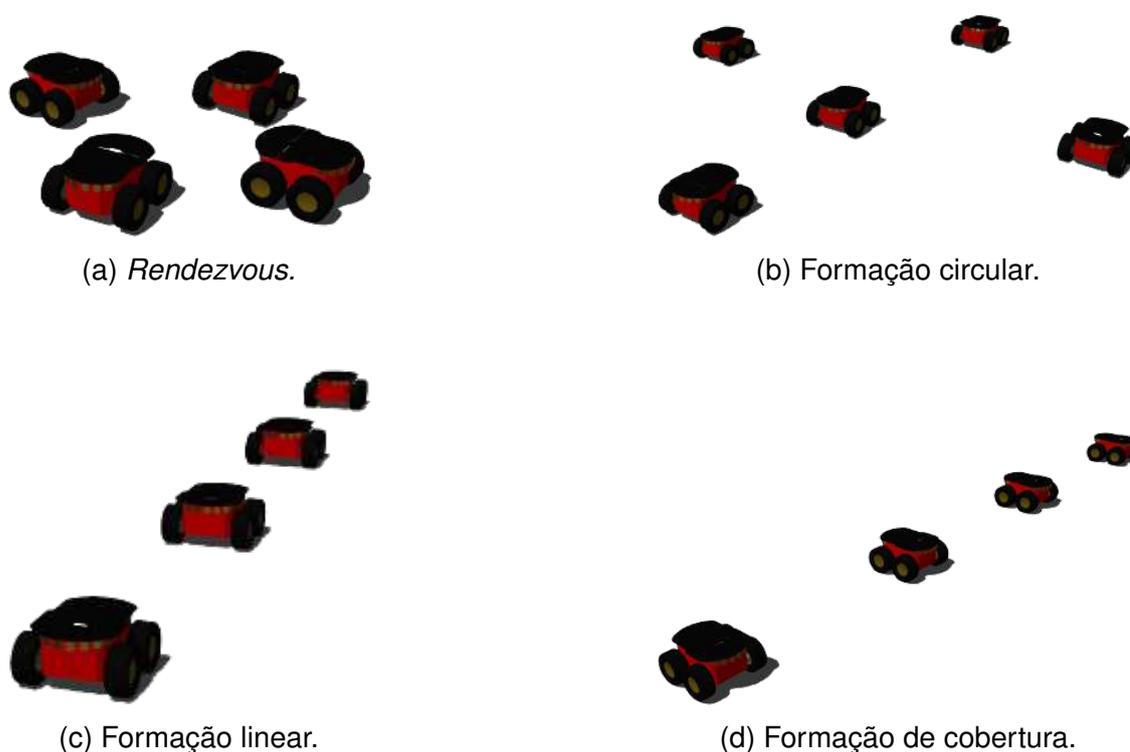


Figura 11 – Ilustração das opções de comportamento.

com vários níveis de autonomia e em cada modo, o robô tem alguma autoridade sobre o seu comportamento de acordo com o modo de autonomia selecionado e o operador humano só pode influenciar o comportamento do robô através da interface homem-máquina. E de acordo com (CHIOU; HAWES; STOLKIN; SHAPIRO; KERLIN; CLOUTER, 2015) o LoA mais amplamente aplicado em robótica é o controle compartilhado, a fusão de teleoperação e controle autônomo durante a execução de tarefas. No controle compartilhado, a entrada do operador é combinada com o movimento calculado do robô para produzir uma saída melhorada (DRAGAN; SRINIVASA, 2013).

Indicamos três níveis de automação em nossa plataforma de simulação. Totalmente autônomo define o nível operacional no qual o *swarm* está executando tarefas predefinidas conforme atribuídas pelo planejador de missão sem a assistência de um operador. Para controle humano compartilhado, o *swarm* está regularmente em modo



Figura 12 – Trecho da interface para ajuste de parâmetros.

totalmente autônomo com um humano intervindo periodicamente no sistema. O controle manual é o nível em que o operador humano tem total controle sobre o robô líder por meio de um joystick, ou seja, está continuamente intervindo e influenciando o *swarm* durante a missão.

O módulo possui acima um menu *pop-up* para selecionar o robô desejado e abaixo um controle deslizante para o LoA com três níveis: teleoperação, controle compartilhado (o operador pode alternar entre o modo automático e manual) e totalmente autônomo. Existem três sinais visuais (como LEDs) para indicar o modo selecionado - se selecionado o LED fica verde, senão fica cinza, apenas para a opção de controle compartilhado e quando o operador assume o comando, mudando para o modo manual, o LED fica vermelho.

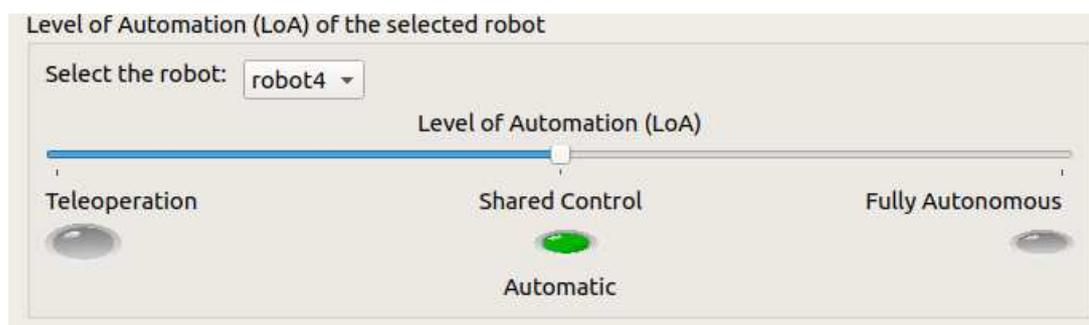


Figura 13 – Trecho da interface para a seleção do robô e do nível de automação.

4) O próximo módulo possui opções de configuração para alterar algumas especificações da simulação (Figura 14). São cinco menus: no primeiro o operador pode configurar o tipo de topologia de comunicação de fixa (a topologia não muda durante a simulação, Figura 15a) para dinâmica (a topologia muda com base na distância entre os robôs, Figura 15b); na segunda opção é possível ativar e desativar um atraso de tempo na troca de pacotes de informação; o terceiro menu tem a função de ativar ou desativar as perdas de pacotes; a próxima tem três opções, apresentar na interface todas as conexões da topologia de todos os robôs (Figura 16a), ou todas as conexões

do robô selecionado (Figura 16b), ou seja, os vizinhos dele, ou simplesmente não mostrar nenhuma das conexões (Figura 16c).



Figura 14 – Trecho da interface para as configurações.

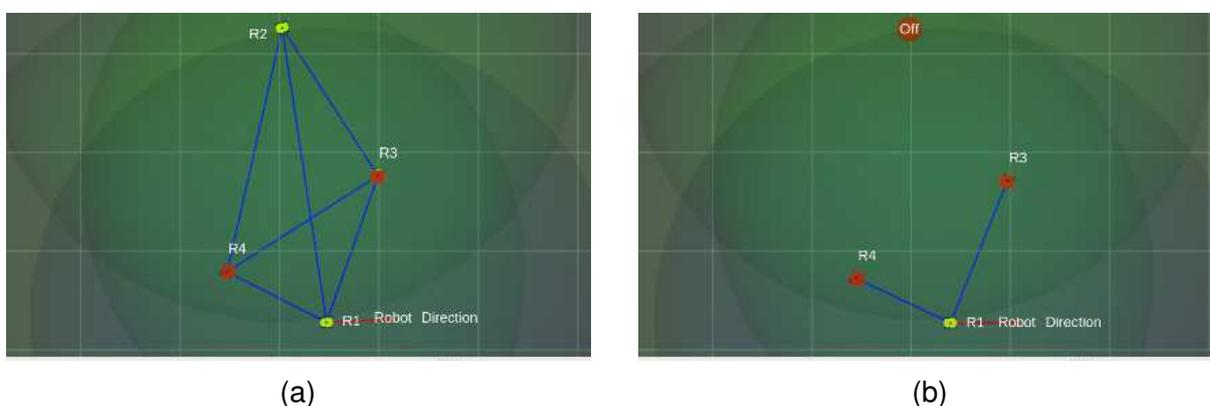


Figura 15 – (a) Exemplo de conexão de quatro robôs com topologia fixa. Os robôs R2, R3 e R4 se comunicam com o robô R1 teleoperado durante toda a missão, independentemente da distância entre os mesmos. (b) Exemplo de conexão de quatro robôs com topologia dinâmica. Os robôs R3 e R4 se comunicam com o robô R1 teleoperado, mas o robô R2 perdeu conexão com o robô R1 devido à distância ser maior do que o raio de comunicação.

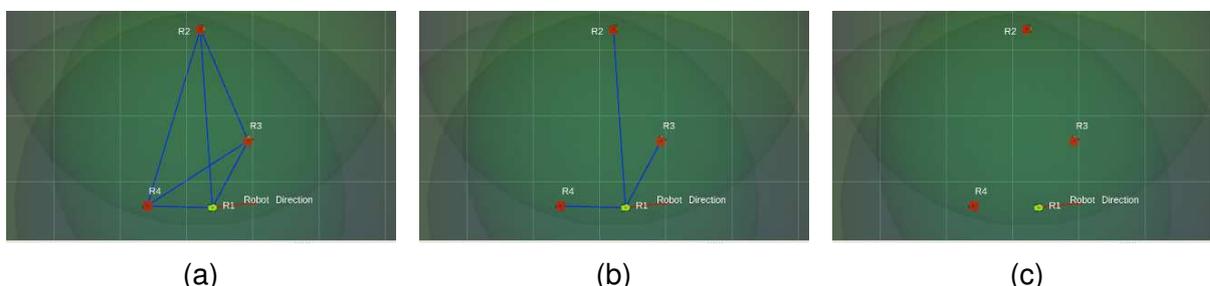


Figura 16 – (a) Exemplo de interface com as conexões de topologia de todos os robôs. (b) Exemplo de interface com as conexões de topologia do robô teleoperado R1. (c) Exemplo de interface sem nenhuma conexão de topologia.

5) Por fim, é possível escolher entre três tipos de consenso: regular (todos os robôs têm a mesma conduta em relação a informação de consenso), teimoso (o robô

selecionado não é influenciado pelas informações de seus vizinhos, tornando-se uma raiz do grafo) e a referência (um marcador interativo é adicionado ao mapa e se torna a raiz do grafo).

As simulações são realizadas selecionando um nível de automação da tarefa a ser implementada e a variação do senso de agência pode ser analisada pela comparação entre esses diferentes modos de operação. Na Figura 17 a interface é apresentada com as quatro opções para o LoA da tarefa e a interface de alerta.

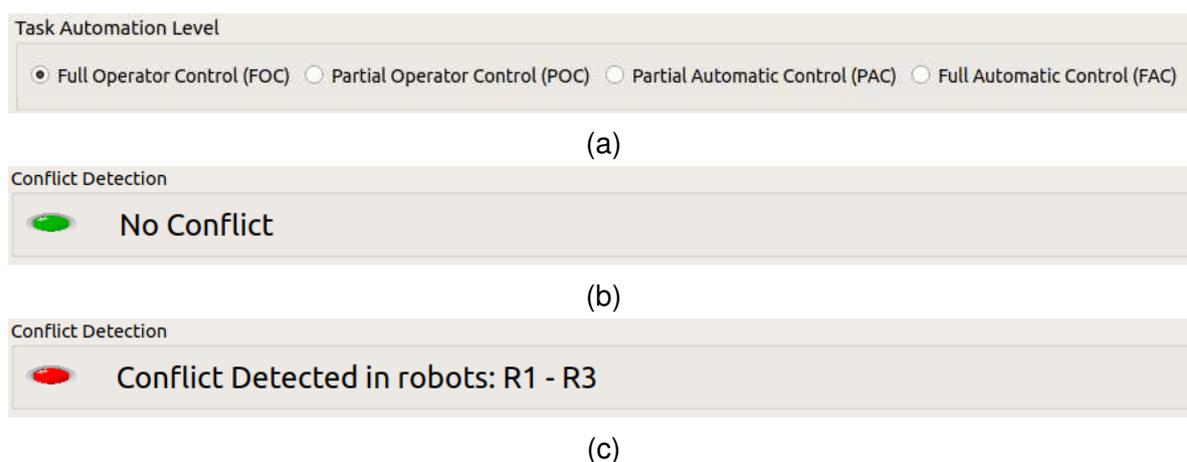


Figura 17 – Trecho da interface para: (a) o nível de automação de tarefas, (b) o sistema de alerta sem detecção de conflito e (c) o sistema de alerta com detecção de conflito.

Afim de atender ao requisito da tarefa, os participantes contam com ferramentas de automação em diferentes graus para as seguintes tarefas: detecção de conflitos, seleção de robôs, comando de tomada de controle, resolução de conflitos e liberação do comando de tomada de controle. Para estudar como o nível de automação afeta o senso de agência, o nível de automação pode ser variado entre os blocos de experimentos. Quatro diferentes níveis de automação são propostos, baseados em (SHERIDAN; VERPLANK, 1978), desde a condição menos automatizada até a condição mais automatizada:

- A condição Controle Total do Operador (Full Operator Control) (FOC): a detecção de conflitos é automática; seleção do robô, comando de tomada de controle, resolução de conflitos e liberação do comando de tomada de controle são realizados pelo participante;
- A condição Controle Parcial do Operador (Partial Operator Control) (POC): detecção de conflito e seleção do robô são automáticas; A execução do comando de tomada de controle, resolução de conflitos e comando de controle de entrega são realizados pelo participante;

- A condição Controle Automático Parcial (Partial Automatic Control) (PAC): detecção de conflito, seleção de robô, comando de tomada e devolução do controle são automáticos, resolução de conflito é realizada pelo participante;
- A condição Controle Automático Completo (Full Automatic Control) (FAC): Ferramentas de automação detectam o conflito, selecionam o robô, implementam o comando e conduzem para a resolução do conflito, o operador apenas observa.

Todas os LoA das tarefas descritas anteriormente estão ilustradas na Figura 18. Durante a simulação todas essas variáveis apresentadas são armazenadas e então apresentadas para analisar o processo de tomada de decisão pelo participante e em quais momentos essas decisões foram tomadas.

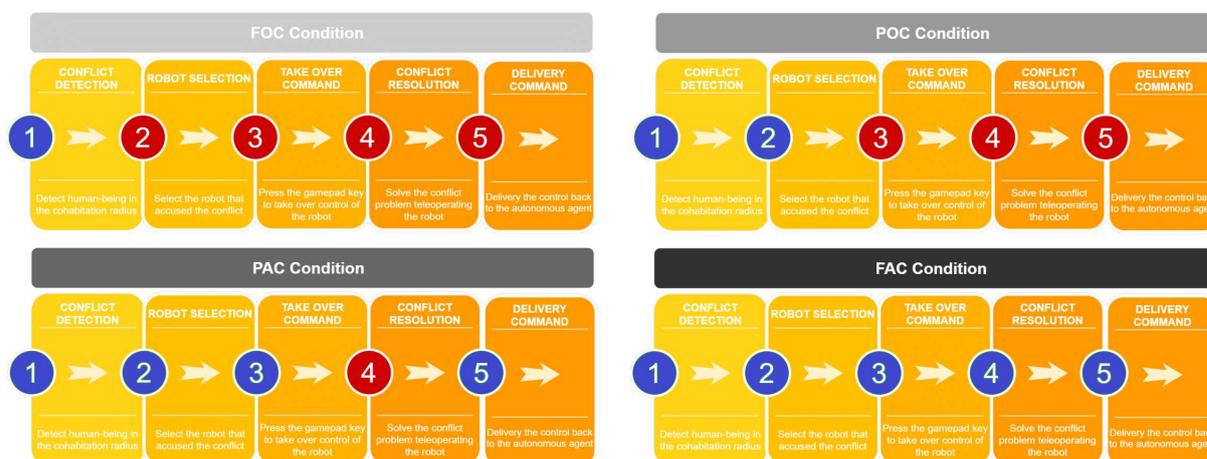


Figura 18 – Sequência de operações teleoperadas ou autônomas para diferentes Níveis de Automação: FOC - superior esquerdo; POC - superior direito; PAC - inferior esquerdo; FAC - inferior direito. Os números de processo destacados em azul são autônomos e os destacados em vermelho são teleoperados.

No próximo capítulo o uso destas ferramentas será detalhado e explicado, juntamente com os resultados obtidos das simulações.

4 AVALIAÇÃO DO SISTEMA IHS - SIMULAÇÕES E RESULTADOS

Neste capítulo são retomados os agentes que compõem o sistema, a interação entre os mesmos e simulações e resultados do uso da plataforma para avaliação dos agentes e o desempenho e impacto de diferentes níveis de configuração da plataforma proposta.

4.1 AVALIAÇÃO DO MODELO DE PEDESTRE

O modelo de força social aqui implementado contribui para futura integração do movimento de *swarms* e suas interações com pedestres em simulações de larga escala. Portanto, estas simulações podem trazer informações à respeito da segurança dos pedestres e dos demais agentes em coabitação com o *swarm* e podem ser ferramentas avançadas e eficazes para um melhor planejamento do espaço público.

As perspectivas da aplicação deste modelo incluem o aprimoramento do próprio modelo, estudando diferentes configurações urbanas e testando parâmetros adicionais, que permitam modelar com mais precisão o comportamento do movimento dos pedestres.

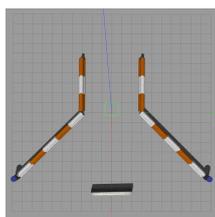
A velocidade livre foi estimada pela velocidade usual para pedestres que tem um alcance entre $1,1\text{ m/s}$ e $1,4\text{ m/s}$ (VALERO; ANTONELLI; CHRISTOFOROU; FARHI; KABALAN; GIOLDASIS; FOISSAUD, 2020). Os parâmetros A e B foram estimados à partir de dados da literatura em torno de i) para o caso de pedestre evitando um pedestre como $350\text{ kg}\cdot\text{m/s}^2$ e $0,50\text{ m}$, respectivamente; e, ii) para o caso de pedestres evitando robôs partiu-se da hipótese que o pedestre reagiria da mesma forma e assumiu-se os mesmos parâmetros para fins de simulação. Porém, é importante ressaltar que dados empíricos que corroborem estas estimativas do uso de parâmetros na mesma ordem de grandeza seriam necessários para confirmar que a interação pedestre-pedestre se assemelha à interação pedestre-robô. Da mesma forma, o tempo de relaxamento foi estimado igual a $0,20\text{ s}$ e o parâmetro $\lambda = 0,5$.

Na Tabela 2 estão apresentados os parâmetros e os respectivos valores utilizados para a simulação dos pedestres.

Tabela 2 – Parâmetros para o Modelo de Força Social

Parâmetros	Valores
$V_0(\text{m/s})$	$1,2(\pm 0,2)$
$A(\text{kg}\cdot\text{m/s}^2)$	$350(\pm 30)$
$B(\text{m})$	$0.5(\pm 0.1)$
$\tau(\text{s})$	$0.2(\pm 0.05)$

Como visto anteriormente na interação entre pedestres um fator essencial é



(a) Teste em um ambiente simples.



(b) Mapa de um ambiente simples.



(c) Mapa dilatado do ambiente simples.

Figura 19 – Cenário de exemplo para aplicação do método de força social.

a proximidade que é a distância que caracteriza a proximidade entre os indivíduos. Essa distância de interação entre dois indivíduos depende de diversos fatores. Assim, cada indivíduo mantém, dependendo do contexto, certa distância de outros indivíduos, inclusive ao caminhar. Assim, estas distâncias são obtidas através da variação dos parâmetros do modelo de força social. Sendo que o parâmetro A impacta de forma diretamente proporcional na magnitude da força de repulsão, o parâmetro B no decaimento da força de repulsão com relação à distância entre os agentes, V_0 afeta de forma diretamente proporcional na magnitude da velocidade desejada e τ de forma inversamente proporcional na magnitude da força de atração.

Na Figura 19 é apresentado um exemplo de cenário para a implementação do modelo de força social para um único pedestre em um ambiente simples. Na Figura 20 são apresentados os resultados obtidos para aplicação do modelo de força social.

Neste modelo os pedestres usam o caminho mais curto para chegar ao objetivo. Para tanto, considera-se o algoritmo de frente de onda que se inicia no objetivo de um ambiente 2D onde as áreas ocupadas por obstáculos são representadas em preto. À medida que a frente de onda se propaga no ambiente, seus tempos de chegada podem ser encontrados para cada nó do espaço discretizado e assim, se gera um mapa de distância geodésica ao objetivo. Uma vez que o mapeamento da distância $d(\vec{x}, \vec{s})$ para o objetivo s é calculado, a velocidade desejada é deduzida.

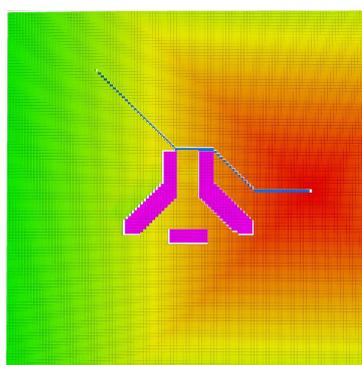
Dessa forma, obtém-se os valores necessários para o cálculo da força de atração, com cada pedestre gerando um mapa de frente de onda, dependente do objetivo designado a cada pedestre simulado. A força de repulsão é dependente da locomoção dos pedestres no ambiente e suas distâncias relativas a outros agentes e objetos presentes no ambiente.

Na Figura 21 é possível verificar as trajetórias geradas para a simulação de dez pedestres diferentes. As trajetórias foram geradas através do algoritmo de frente de onda com dez pontos objetivos diferentes, sendo um objetivo atribuído a cada pedestre.

Na Figura 22 é possível observar a trajetória percorrida pelos pedestres durante uma simulação com os parâmetros indicados anteriormente e as velocidades desejadas determinadas pela aplicação do algoritmo de frente de onda apresentados na



(a) Algoritmo de frente de onda representado em escala de cinza no mapa de grade do ambiente simples. (b) Distância geodésica da posição inicial nas coordenadas $x=15, y=10$ até a meta representada em verde.



(c) Distâncias geodésicas para o objetivo em um ambiente simples (os obstáculos estão em rosa): o objetivo é colocado aqui nas coordenadas $x=50, y=30$ em vermelho com o caminho em azul com posição inicial $x=15, y=10$ na região verde.

Figura 20 – Resultado da aplicação do método de força social para um pedestre.

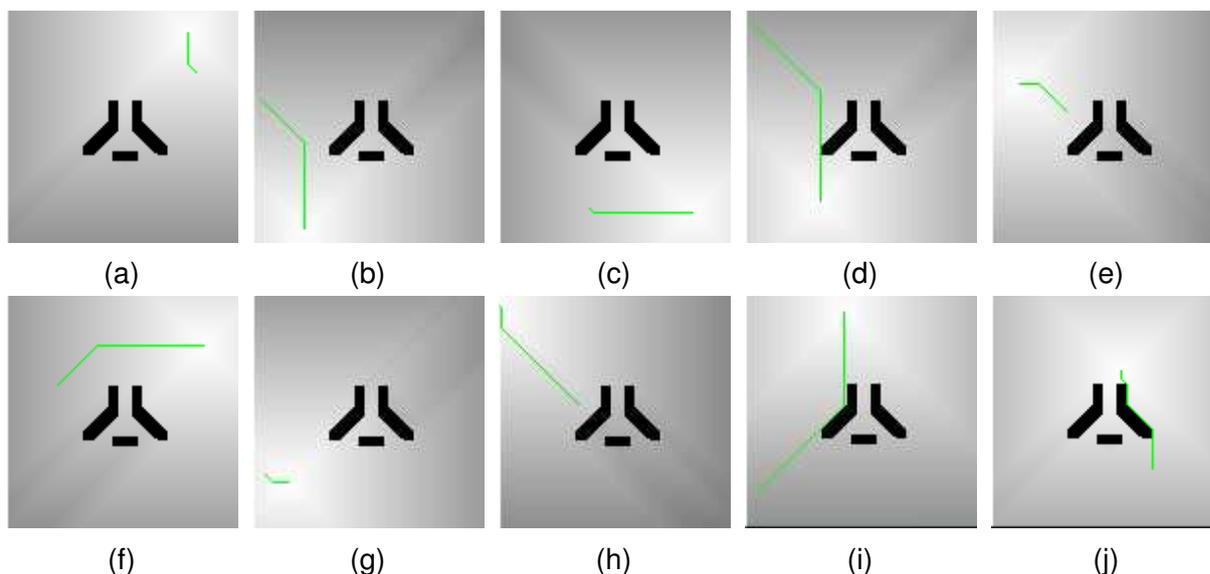


Figura 21 – Geração de dez trajetórias através do algoritmo de frente de onda com dez pontos objetivos diferentes.

Figura 21.

Portanto pela Figura 22 e pelos vídeos pode-se observar as trajetórias percor-

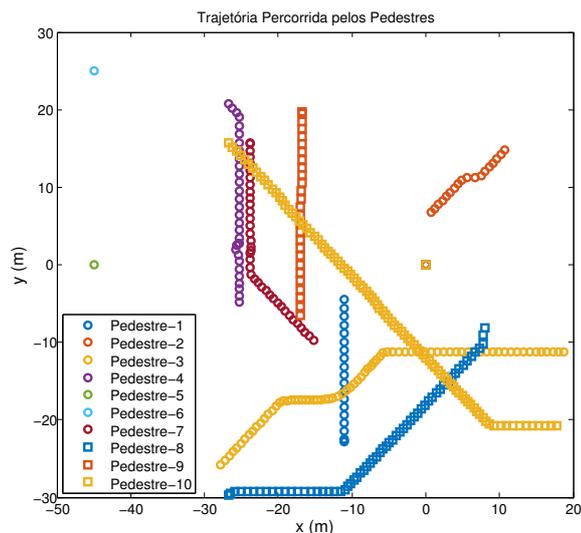


Figura 22 – Trajetórias percorridas pelos pedestres. Links para vídeos de exemplo: <https://youtu.be/nJDly2BazHA> e <https://youtu.be/pWq6MpOn9wo>

ridas pelos pedestres, a força de atração aplicada para cada agente, as forças de repulsão quando estes se aproximam de obstáculos ou outros pedestres e, por fim, a força resultante da aplicação da força de atração e repulsão que determina de fato o caminho a ser percorrido pelo pedestre.

Na próxima seção o teleoperador e a respectiva avaliação deste agente no sistema IHS é explorado.

4.2 AVALIAÇÃO DO TELEOPERADOR

Os cenários apresentados a seguir motivam a necessidade de inserção de um teleoperador no sistema, a tarefa de *rendezvous* é apresentada juntamente com dois cenários ilustrativos. Em seguida são realizadas simulações para medir o nível de agência do teleoperador ao realizar a tarefa de *rendezvous* e, por fim, os sistemas de suporte à teleoperação e o sistema de suporte à seleção de líderes são apresentados.

4.2.1 Cenários e a Tarefa de *Rendezvous*

Os cenários apresentados a seguir motivam a necessidade de inserção de um teleoperador no sistema. Inicialmente o algoritmo de consenso clássico em uma topologia fixa com uma árvore de extensão é simulado para apresentar o problema de *rendezvous*, no qual um grupo de agentes deve se encontrar em um ponto em comum, baseado apenas na comunicação local. Ou seja, os agentes só tem acesso as informações sobre os agentes adjacentes, também chamados de vizinhos.

Na Figura 23 pode-se observar que foram simulados 10 agentes autônomos executando o algoritmo de consenso. E todos agentes se encaminham para o ponto

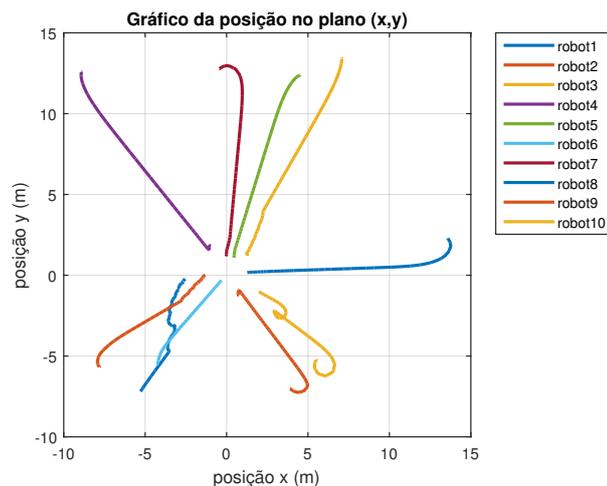


Figura 23 – Simulação do consenso em um sistema com grafo completo.

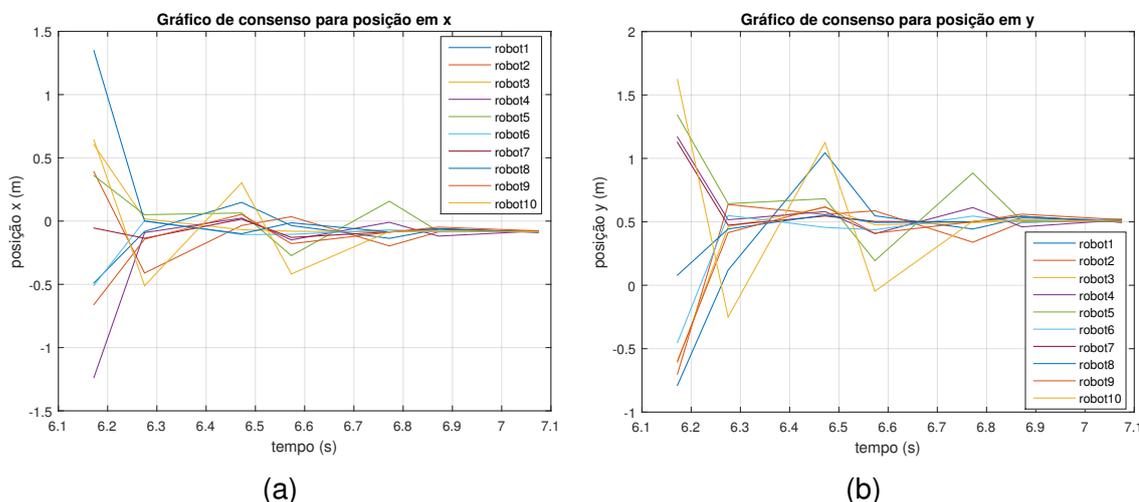


Figura 24 – (a) Consenso da posição x de *rendezvous*. (b) Consenso da posição y de *rendezvous*.

de encontro em aproximadamente $(0,0)$ no plano (x,y) . Na Figura 24 pode-se ver com mais detalhes a evolução do consenso da informação no tempo.

Portanto ao executar o algoritmo de consenso para se obter um ponto de *rendezvous* é possível aplicar uma lei de controle local para que cada robô se locomova para o ponto de interesse. As entradas de controle, velocidade linear e velocidade angular, de cada robô são apresentados na Figura 25. As oscilações à partir de aproximadamente 15s começam a ocorrer devido ao comportamento de desvio de obstáculo que é ativado quando os robôs estão aglomerados próximos ao ponto de consenso.

A topologia para este cenário é considerada de grafo completo, mas para que ocorra o consenso neste caso basta que o grafo possua uma árvore de extensão, ou de forma mais restrita que o grafo seja conexo. Ou seja, para que ocorra o consenso basta que a Laplaciana correspondente ao grafo em análise tenha autovalor zero simples e os demais autovalores sejam positivos. Na Figura 26 são apresentadas as conexões

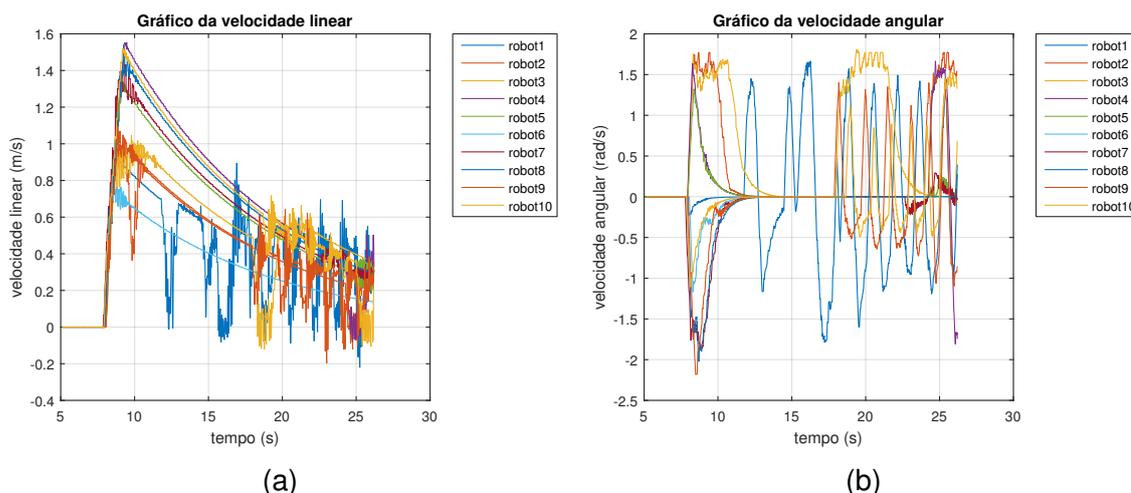


Figura 25 – (a) velocidade linear. (b) velocidade angular.

neste tipo de grafo.

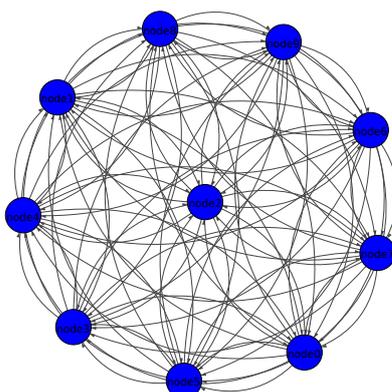


Figura 26 – Grafo completo.

Apenas para enfatizar que não é necessário a conexão entre todos os nós para que ocorra consenso, outros exemplos de grafos são apresentados na Figura 27, pois possuem as propriedades apontadas anteriormente e, sendo assim, também atingiriam o consenso.

Porém, observe que um modelo de comunicação geralmente é baseado em distância, ou seja, dois agentes podem se comunicar apenas se a distância for menor que um determinado limite. Para garantir que o consenso ou o controle da formação possa ser alcançado, o mecanismo de manutenção da conectividade tem que ser garantido, de modo que, se dois agentes forem vizinhos em um determinado instante, eles sempre serão vizinhos depois. Porém dificuldades de ordem prática como perdas de pacote, atrasos na comunicação, perda de conexões e outros fatores não previsíveis, impedem que se possa garantir a convergência para um valor de consenso de forma adequada em ambientes não estruturados e dinâmicos.

Como pode-se ver no exemplo simulado na Figura 28, com topologia dinâmica

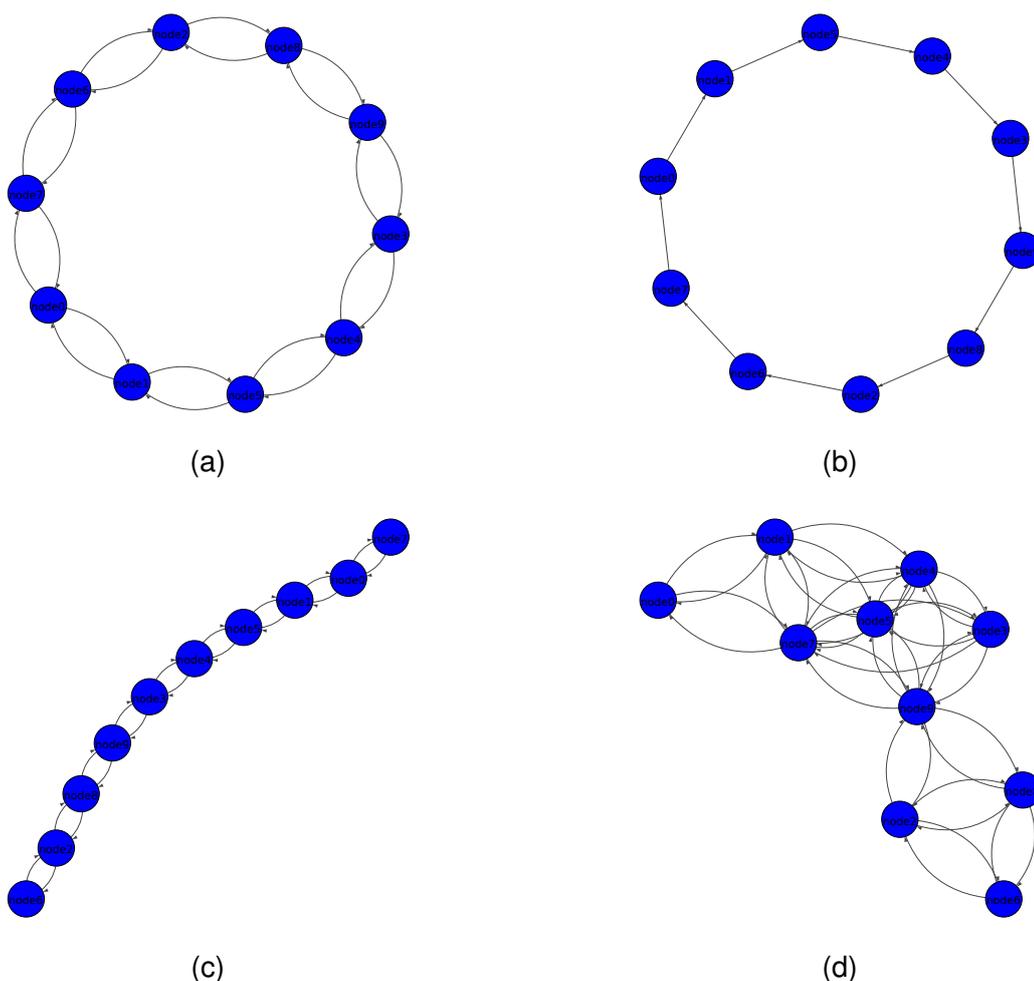


Figura 27 – (a) Grafo cíclico não-direcionado (b) Grafo cíclico direcionado (c) Grafo linha não-direcionado (d) Grafo aleatório não-direcionado

dependente da distância entre os agentes, o sistema autônomo executa o algoritmo de consenso (3), no qual logo no início da simulação ocorre a perda de conexão de agentes que garantiam a conectividade da rede.

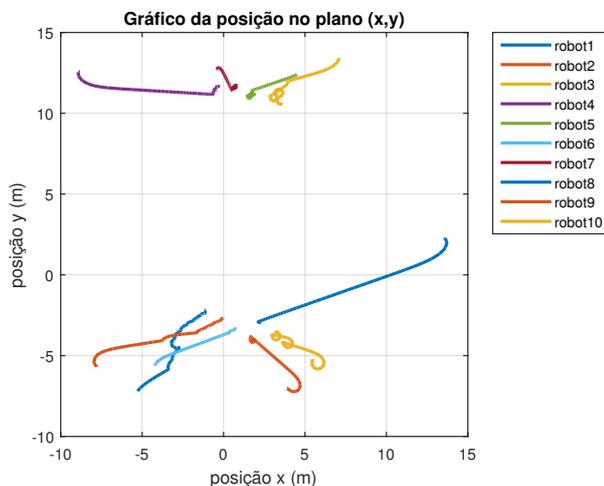


Figura 28 – Simulação do consenso em um sistema com perda de conectividade.

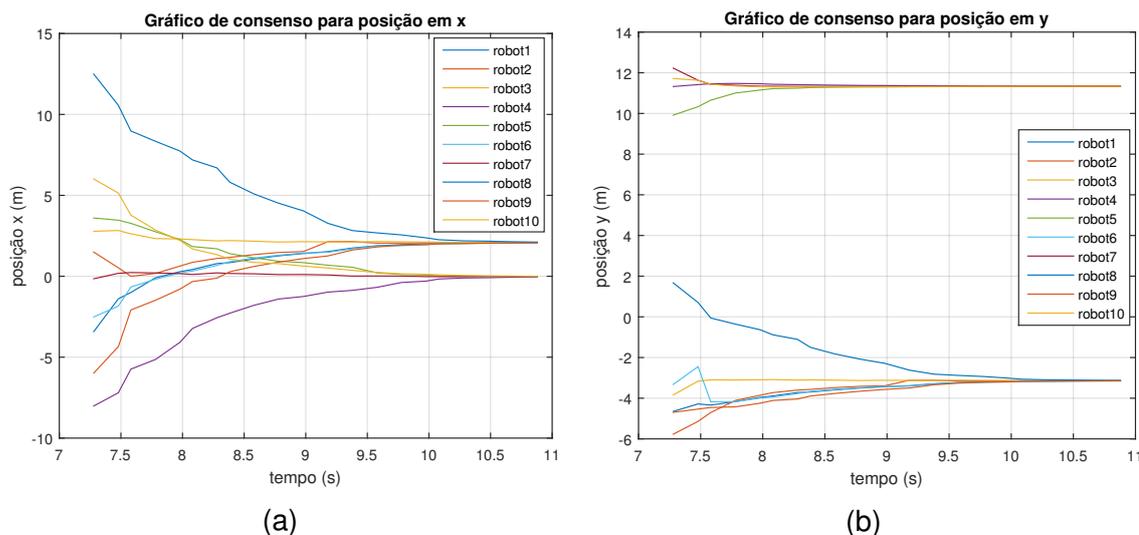


Figura 29 – (a) Consenso da posição x de *rendezvous*. (b) Consenso da posição y de *rendezvous*.

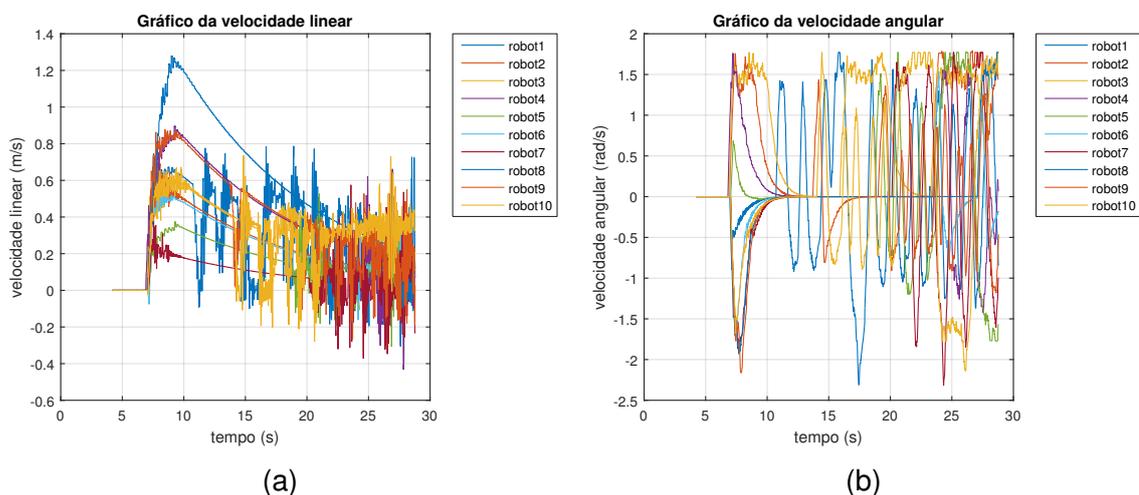


Figura 30 – (a) velocidade linear. (b) velocidade angular.

Como pode-se observar na Figura 28 devido a perda de conexão o grupo de robôs autônomos convergiu para duas posições distintas no plano (x,y) . A seguir, na Figura 29 pode ser observada a evolução da informação de consenso no tempo, para as posições x e y , respectivamente. E abaixo pode-se ver o resultado da velocidade linear e velocidade angular, ou seja, das entradas de controle, para o sistema apresentado anteriormente.

Na Figura 30 pode-se observar que inicialmente as velocidades convergiram para zero, mas por volta de 15s começam a oscilar tanto a velocidade linear quanto a velocidade angular. Isso ocorre, novamente, pois ao se aproximarem do ponto de consenso, os agentes autônomos estão há uma distância de segurança menor que a permitida. Sendo assim, uma vez ativado o sensor de proximidade, os robôs ativam o comportamento de desvio de obstáculos. Como estão todos aglomerados, os agentes oscilam em torno dos pontos de consenso, e, portanto, ocorrem as oscilações na

velocidade linear e angular.

Sendo assim, fica claro que até mesmo em problemas básicos, quando tratados em ambientes não estruturados e dinâmicos, não é uma tarefa trivial projetar um sistema de agentes autônomos que garantam a manutenção de conectividade durante toda missão. Somado a isso tem-se os desafios impostos pela estrutura de comunicação como largura de banda, limite de alcance, dentre outros fatores.

Então, uma vez determinadas as alternativas para avaliação do sistema IHS e definidas as métricas para guiarem o projeto do sistema, pode-se prosseguir para o desenvolvimento de sistemas que auxiliem o operador na tarefa a ser executada, através de sistemas de suporte na tomada de decisão. Esses sistemas de suporte em conjunto com as ferramentas de avaliação do teleoperador formam uma combinação valiosa para indicar quais tipos de sistemas e configurações melhoram o desempenho do teleoperador e, por consequência, do restante do sistema. Nas próximas subseções são apresentados estes pontos.

4.2.2 Nível de Agência do Teleoperador

No desenvolvimento da plataforma, a principal preocupação foi a relação entre o nível de automação e as duas medidas de senso de agência: a duração percebida dos intervalos entre ações e efeitos e o julgamento explícito de controle causal.

Para a avaliação da plataforma foram escolhidos dois casos de teste, variando o nível de automação da tarefa, como prova de conceito da plataforma aqui proposta. Para estes dois casos de teste, foi escolhida a tarefa de *rendezvous* a ser executada, sendo o controle compartilhado o nível de automação do robô selecionado. Para a configuração foi escolhida a topologia dinâmica, sem atrasos ou perdas de pacotes, mostrando apenas as conexões dos vizinhos e o consenso baseado na referência.

O primeiro caso de teste é o controle total do operador em que a única tarefa que é automática é a detecção de conflito e o operador é responsável por selecionar o robô indicado na tela de conflito, assumir o comando do robô pressionando o botão do joystick e resolver o problema de conflito para finalmente entregar o comando de volta ao modo autônomo. Para o segundo caso de teste foi escolhido o controle parcial do operador que é semelhante ao primeiro caso de teste com a exceção de que a tarefa de seleção do robô também é automática para este modo de operação.

Os casos de teste foram realizados com 4 voluntários com idade média de 35 anos, que passaram por treinamento pré-operação para familiarização com a interface humano-*swarm*. As instruções que foram enviadas aos operadores voluntários foram de que eles deveriam realizar a tarefa de *rendezvous* garantindo que todos os agentes se encontrassem em um ponto comum. E a tarefa seria considerada cumprida assim que todos os agentes estivessem dentro de um determinado raio do ponto de encontro. Assim, cada voluntário gerou dados de três tentativas bem-sucedidas, ou seja, cumpriu-

se a tarefa de *rendezvous* com todos os agentes na linha ou dentro da região de interesse, sem colisões e dentro de um período de tempo.

É importante notar, entretanto, que o problema de navegação consciente do humano não é considerado aqui. Ou seja, o estudo da forma como um robô deve navegar na presença de pessoas considerando aspectos como o conforto humano, respeitando as regras sociais e imitando o comportamento humano de baixo nível, não foram preocupações nos cenários apresentados.

A sequência de eventos que os voluntários experimentariam em cada tentativa da simulação é a seguinte: No início de cada tentativa, os participantes supervisionariam a navegação do *swarm* de robôs no ambiente (o ambiente, conforme mostrado na Figura 8, é uma praça de cidade com pedestres e robôs). (1) Após um curto intervalo aleatório de tempo, surge um conflito devido à presença de um pedestre em seu raio de coabitação, ou seja, em uma distância inferior à distância proxêmica mínima (outro agente ou obstáculo adentrou ao espaço pessoal de operação). O participante percebe a detecção do conflito por um círculo vermelho ao redor do robô e um sinal luminoso com um display de texto indicando quais robôs apresentaram conflito, conforme exemplo da Figura 17c. (2) No caso do controle compartilhado, por exemplo, o participante decide ou não assumir e alterar o modo de operação de automático para manual, (3) após a execução do comando, pressionando um botão no controle, um sinal luminoso na interface indica a mudança no modo de operação com um texto indicando o modo de operação atual do robô, e (4) após a resolução do conflito o operador solta o botão para voltar ao modo automático de operação. É importante ressaltar que o controle é efetivo somente após um atraso temporal controlado no engajamento do operador por meio do comando de ativação. Esse engajamento é marcado pelo surgimento de uma luz verde na interface juntamente com um efeito sonoro curto. (5) Para a medida implícita, uma possibilidade, após cada tentativa, e qualquer que seja o sucesso do comando de controle, os participantes teriam que estimar o atraso temporal percebido entre a ativação do botão até o comando de controle e o aparecimento do feedback visual (“luz verde”, “efeito sonoro curto” e “texto indicando controle manual”).

O total de doze simulações são apresentados na Figura 31 para o controle total do operador com cada par de gráficos indicando qual robô foi selecionado ao longo do tempo e o segundo gráfico indicando todos os conflitos ocorridos para cada robô e o momento da entrada gerada pelo operador. As outras doze simulações foram realizadas para o segundo caso de teste e são apresentadas na Figura 32. Assim, um total de vinte e quatro simulações foram utilizadas para a análise entre esses dois modos de operação.

O tempo de reação e a vinculação intencional para medir o senso de agência do operador, podem ser observados na Figura 33, na qual aparece um conflito devido à presença de um pedestre no raio de coabitação do robô, como pode ser observado

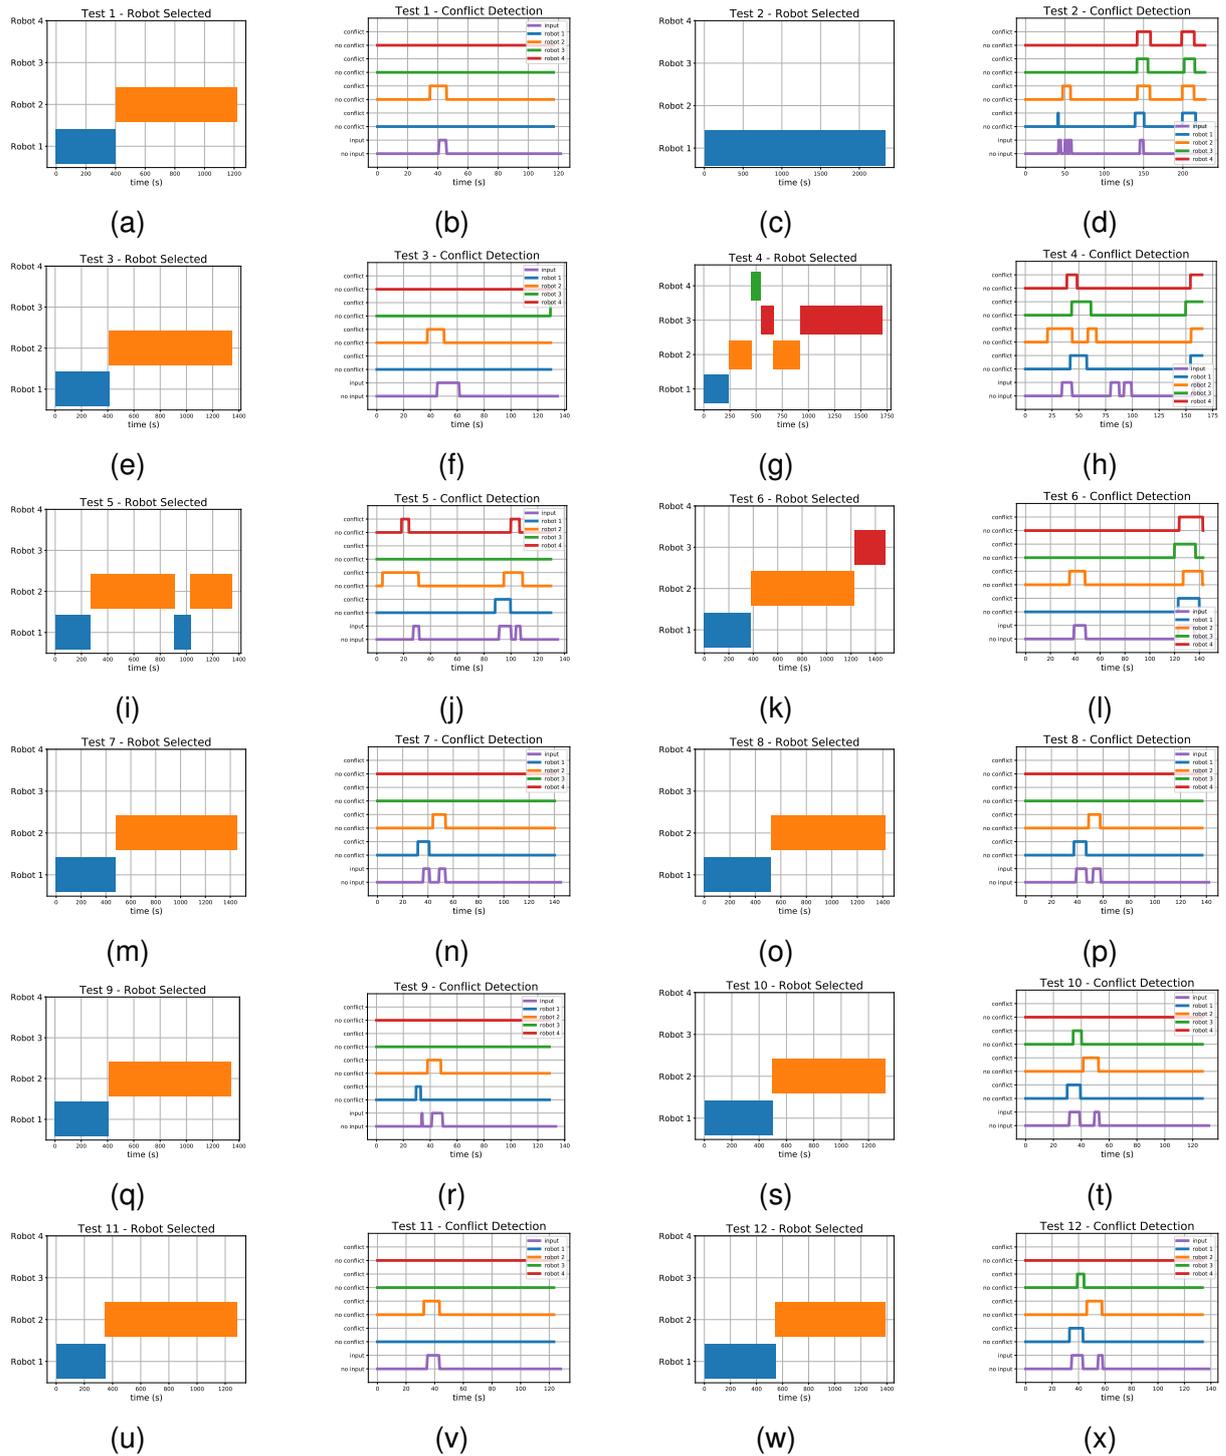


Figura 31 – Controle Total do Operador.

na Figura 34, que mostra todas as trajetórias dos robôs e o caminho do pedestre. Os resultados de tal evento são os sinais na interface que acusam o conflito e o número do robô que o operador deve interferir. Uma vez percebido pelo operador, este executa um comando para assumir o controle do robô. E na Figura 33 está a diferença de tempo entre o conflito e o comando de entrada do operador.

As tabelas a seguir resumem os resultados obtidos para os dois casos de

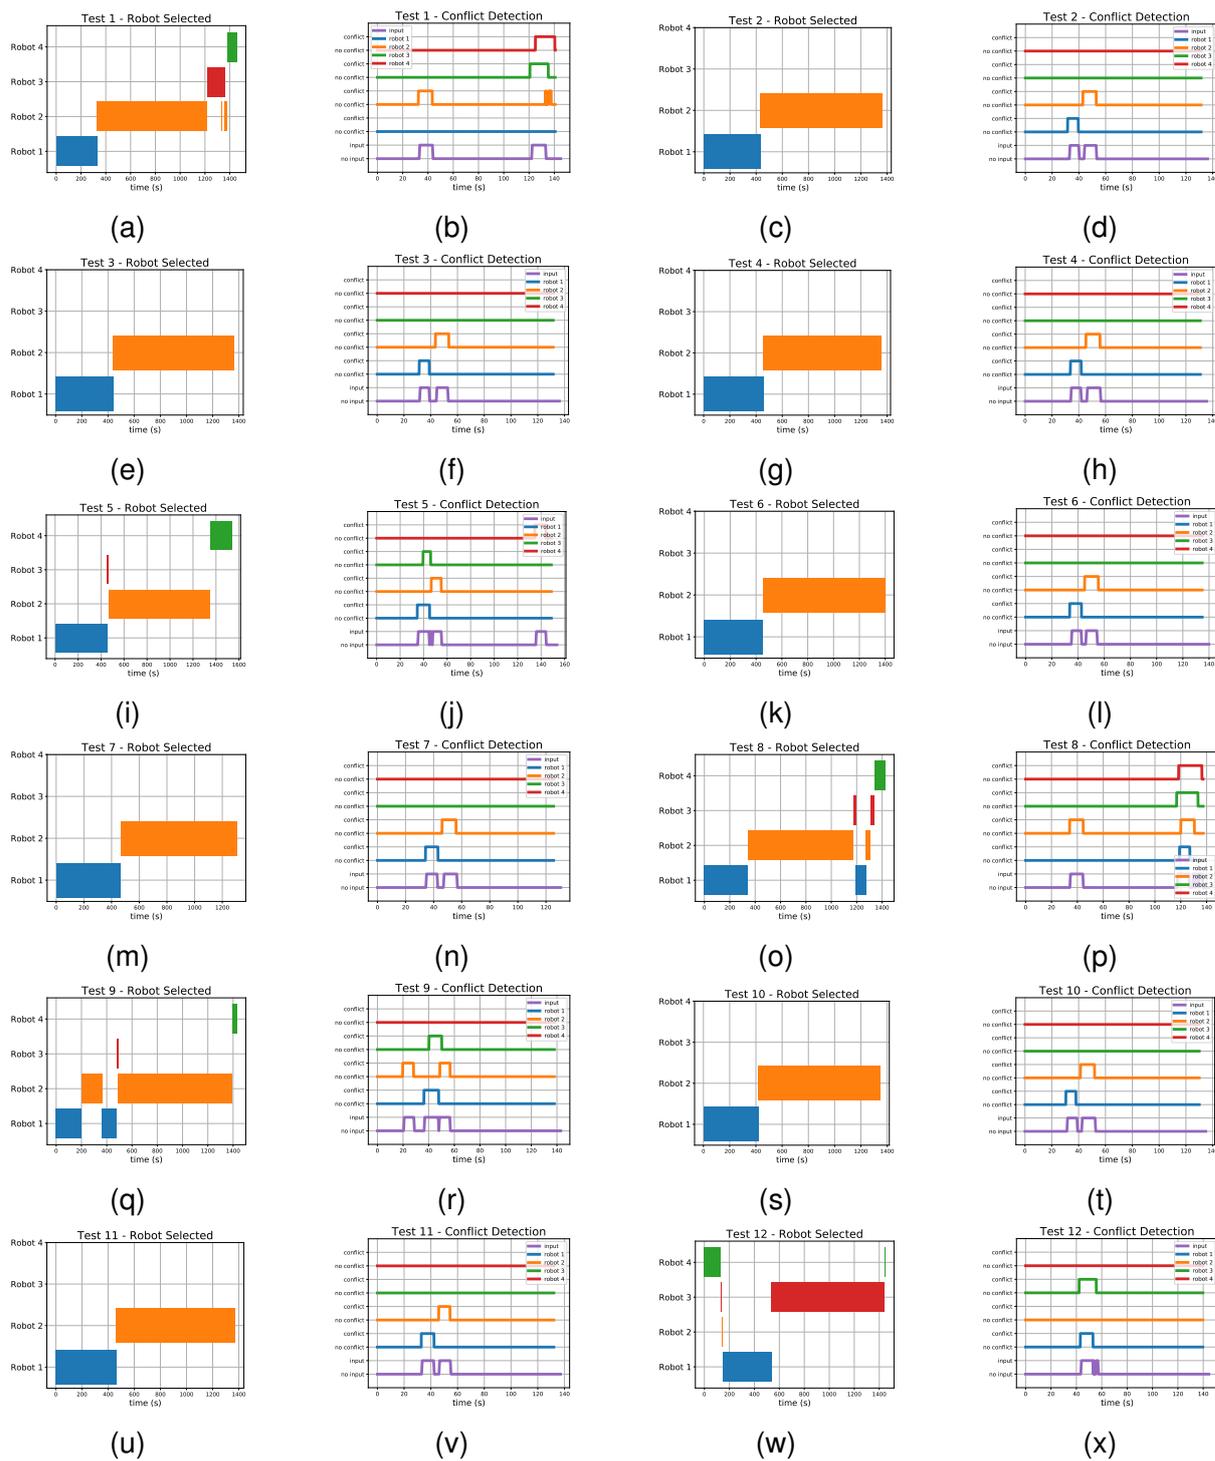


Figura 32 – Controle Parcial do Operador.

teste com doze experimentos cada que foram apresentados nas Figuras 31 e 32, respectivamente.

As Tabelas 3 e 4 resumem os resultados obtidos durante os experimentos. O modo de controle total do operador apresentou tempo de reação médio de 5,5s e tempo de resolução médio de 11,4s. Por outro lado, o modo de controle parcial do operador apresentou tempo de reação médio de 0,7s e tempo de resolução médio de

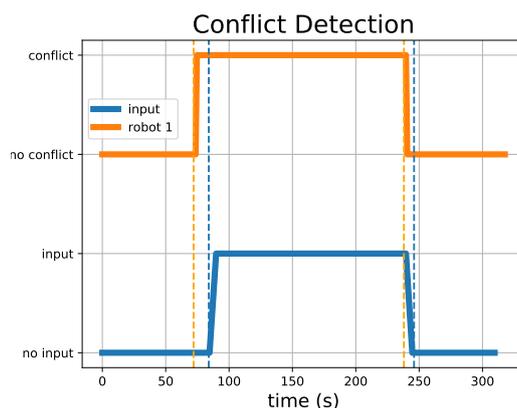


Figura 33 – A detecção de conflito com o pedestre e o tempo de reação do operador para dar o comando para assumir o controle do robô.

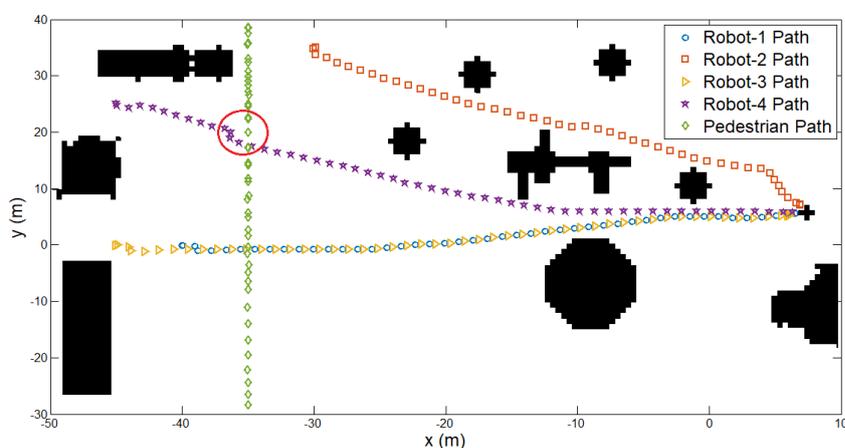


Figura 34 – A trajetória executada pelos robôs e pelo pedestre. O círculo vermelho indica o momento da detecção do conflito quando o operador realiza o comando para assumir o robô e interfere na trajetória do robô.

9,8s. Assim, o aumento da automação de tarefas tem como consequência uma menor carga de trabalho do operador, que resultou em tempos de reação mais rápidos, o que é um indicativo de uma melhor consciência situacional. O tempo de resolução porém, não tem uma diferença expressiva como apresentado no tempo de reação, mas no geral o controle parcial teve um tempo de resolução mais rápida também.

Apesar da melhora no tempo de reação, esses resultados não se refletiram no tempo de resolução de conflitos. Assim, apesar da carga de trabalho maior, em ambos os cenários os operadores conseguiram atender os conflitos no mesmo tempo, porém com o efeito colateral de gerar mais conflitos devido à demora para realizar uma ação para o primeiro cenário de caso de teste.

Ao final de cada tentativa, os participantes foram solicitados a avaliar seu senso de controle sobre o sistema automatizado (ou seja, o sistema automatizado com controle total do operador e aquele com controle parcial do operador). O senso de controle

Tabela 3 – Tempo médio de reação e tempo de resolução para cada experimento no modo de controle total do operador.

FOC	Tempo de Reação (s)	Tempo de Resolução (s)
Teste 1	5.7	11.2
Teste 2	1.5	5.8
Teste 3	7.1	12.6
Teste 4	12	15
Teste 5	10.4	16.4
Teste 6	3.2	12.5
Teste 7	4.4	10.0
Teste 8	2.8	10.8
Teste 9	3	10.1
Teste 10	4.6	10.9
Teste 11	2.1	11.1
Teste 12	9.7	10.7
Média	5.5	11.4

Tabela 4 – Tempo médio de reação e tempo de resolução para cada experimento no modo de controle parcial do operador.

POC	Tempo de Reação (s)	Tempo de Resolução (s)
Teste 1	1.0	12.8
Teste 2	1.1	9.6
Teste 3	0.5	8.8
Teste 4	0.5	9.4
Teste 5	0.8	9.6
Teste 6	1.1	9.9
Teste 7	0.6	8.5
Teste 8	0.3	10.6
Teste 9	0.9	9.8
Teste 10	0.8	9.7
Teste 11	0.3	9.2
Teste 12	0.4	10.0
Média	0.7	9.8

foi medido por uma pergunta clássica na literatura de agência (eu me senti no controle da manobra de evitar conflitos) (LE GOFF; REY; HAGGARD; OULLIER; BERBERIAN, 2018) em uma escala do tipo Likert de 7 pontos (1 = discordo totalmente, 7 = concordo totalmente). A média para o primeiro caso de controle total do operador foi uma pontuação de 6 e para o controle parcial do operador uma pontuação de 5.

De forma semelhante, Gold, Damböck, Lorenz e Bengler (2013) investigaram o comportamento dos motoristas quando uma aquisição era necessária devido a um conflito de automação. A gestão das operações principais de direção era realizada de forma autônoma, enquanto os motoristas realizavam uma tarefa auxiliar. Quando a automação detectava um conflito (ou seja, um carro parado na estrada), um alarme

avisava o motorista de que uma ação era necessária. Verificou-se que os motoristas que receberam pedidos de aquisição mais curtos reagiram mais rapidamente. Nossos resultados estão de acordo com os de Gold, Damböck, Lorenz e Bengler (2013) em relação aos tempos de reação, no sentido de que uma solicitação de controle mais curta, sem a necessidade de decidir sobre a seleção do robô, melhorou o tempo de reação, e a maior automação levou a uma diminuição no senso de controle.

Novos estudos e mais resultados precisam ser realizados para verificar se esses resultados estão de acordo com os achados de Adler e Benbunan-Fich (2012), que mostraram que a alta frequência na troca de tarefas tende a degradar o desempenho geral e pode levar a um menor esforço cognitivo ao decidir se uma intervenção é necessária.

Um estudo mais extenso é necessário para investigar a aceitabilidade do usuário de tal plataforma por meio de perguntas adaptadas de Verberne, Ham e Midden (2012) por Le Goff, Rey, Haggard, Oullier e Berberian (2018). Este questionário contém itens relacionados à 'dimensão da confiança' (achei este sistema confiável; confio neste sistema), 'dimensão da segurança' (este sistema aumenta meu desempenho durante a tarefa de supervisão; usar este sistema aumenta o nível de segurança) e facilidade de uso percebida (é difícil para mim entender o comportamento do sistema; usar este sistema não requer muitos recursos de atenção; usar este sistema é estressante). Essas dimensões são conhecidas por serem fundamentais para a aceitabilidade do usuário (GHAZIZADEH; LEE, John D; BOYLE, 2012). As respostas a essas perguntas podem ser calculadas para formar uma medida confiável de aceitabilidade. Pontuações mais altas refletem mais aceitabilidade do sistema automatizado.

Portanto, estudos extensos para diferentes tipos de cenários e avaliações podem ser realizados com a plataforma proposta para investigar diferentes aspectos da interação humano-*swarm* considerando os quatro modos de operação possíveis. Além disso, diferentes sistemas de suporte podem ser implementados para avaliar a eficácia de dar opções de ação como qual rota seguir, qual líder selecionar ou qual ação executar no momento, que podem melhorar o desempenho geral e o senso de agência do operador.

4.3 SISTEMAS DE SUPORTE À TELEOPERAÇÃO (SST)

Considerando os dois cenários apresentados anteriormente: primeiro o consenso em um problema de *rendezvous* com topologia fixa; segundo, o mesmo exemplo, mas considerando agora a topologia dinâmica e dependente da distância dos agentes e seus respectivos vizinhos; explora-se a seguir o mesmo cenário só que desta vez com um dos agentes substituídos por Redes Neurais Recorrentes (Recurrent Neural Networks) (RNN), para ilustrar que a presença do teleoperador pode solucionar o problema de não atingir consenso visto no cenário 2. No apêndice A é apresentado

como foram obtidos os dados dos teleoperadores e como estes dados foram utilizados no treinamento da RNN e os resultados de comparação do desempenho do sistema, com teleoperação com *feedback* visual e o sistema com suporte à teleoperação, são apresentados na próxima subseção.

4.3.1 Sistema de Suporte à Teleoperação *Long-Short Term Memory*

O cenário a ser considerado preliminarmente é um sistema IHS com 10 robôs, como os casos anteriormente apresentados. Só que desta vez um dos agentes é um robô “teleoperado”. A topologia aqui considerada é dinâmica para o controle e do tipo estrela para exibição. Foram realizados testes, que serão abordados nas próximas seções, para obtenção de dados, que por sua vez foram utilizados para o treinamento de uma RNN, mais especificamente uma LSTM, afim de desenvolver um sistema de suporte à teleoperação. À seguir são apresentados os resultados obtidos para este sistema, no qual o operador foi substituído pela RNN durante toda a simulação, como forma de ilustração do funcionamento do sistema com redes neurais. Na Figura 35 é apresentada a locomoção dos agentes no plano (x,y).

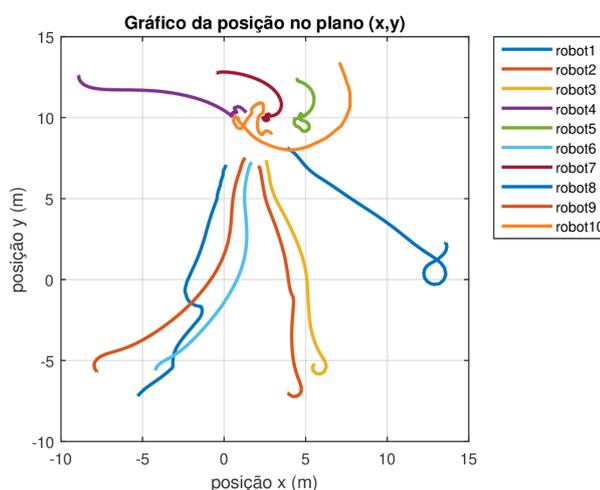


Figura 35 – Simulação do consenso em um sistema com um agente controlado por inteligência artificial (Robô10) e 9 agentes autônomos.

Como pode-se observar a RNN responsável pela teleoperação do “robô10” apresentou um comportamento bem atípico ao ser comparado com os resultados de agentes autônomos apresentados anteriormente. Mas como veremos nas próximas seções, a RNN aproximou com boa acurácia os valores de teste da teleoperação humana. Além disso foi capaz de remediar a desconexão entre os agentes como pode-se observar pelo comportamento do “robô-1” que inicialmente ía no sentido negativo do eixo y e à partir de certo momento retoma a conexão e realiza um contorno indo em direção ao consenso do grupo inteiro. Na Figura 36 são apresentados os gráficos para evolução do consenso no tempo, na qual consegue-se observar de forma mais clara o

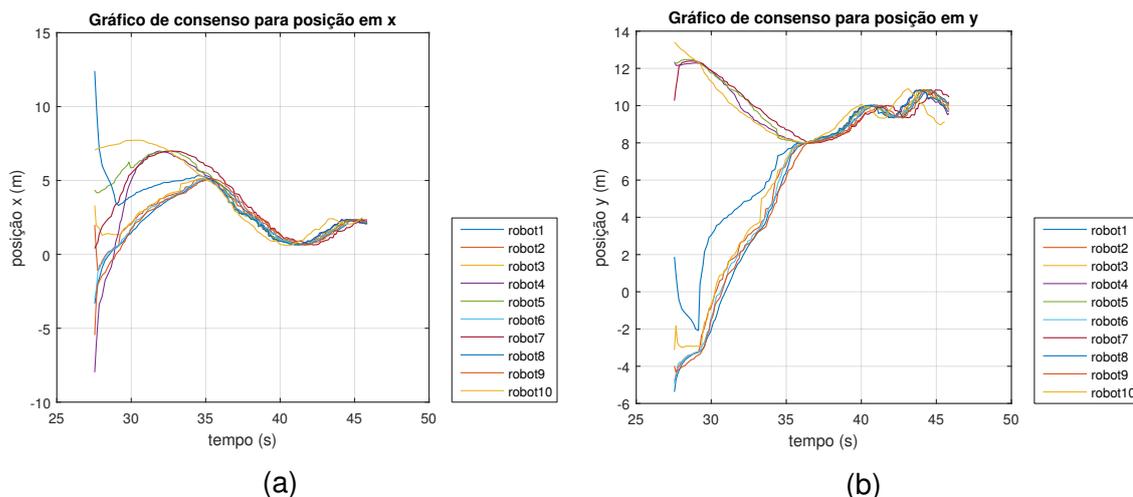


Figura 36 – (a) Consenso da posição x de *rendezvous*. (b) Consenso da posição y de *rendezvous*.

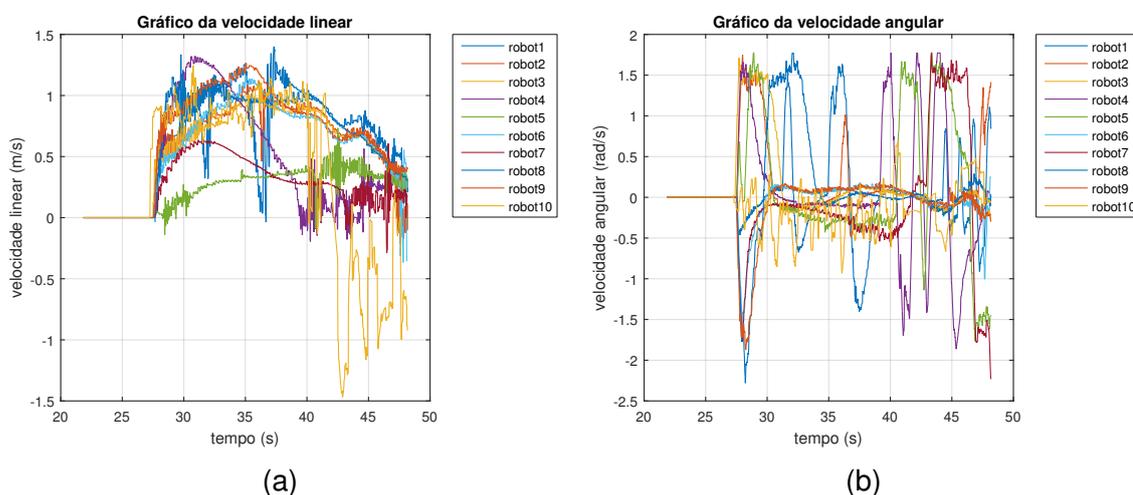


Figura 37 – (a) velocidade linear. (b) velocidade angular.

comportamento inicial semelhante ao cenário anterior, mas em cerca de 30s os robôs começam a formar consenso em um único ponto e na Figura 37 são apresentadas as velocidades lineares e angulares novamente.

Como pode-se observar, o fato de existir o líder no sistema faz com que a variável de consenso convirja para o valor do líder, uma vez que este é uma raiz no grafo e seu valor não é alterado explicitamente pela informação dos vizinhos, apenas implicitamente devido a reação do operador ao comportamento dos outros agentes. Na Figura 38 é apresentado o grafo completo, mas com a presença do teleoperador para ilustrar a topologia dinâmica quando os robôs estão todos próximos do operador e na Figura 39 são apresentados os líderes de informação.

E por fim, apresenta-se as entradas de controle para este sistema. Como pode-se observar a presença de um agente diferente no sistema, tornando o sistema híbrido, fez com que a resposta das entradas de controle não tivessem um comportamento bem

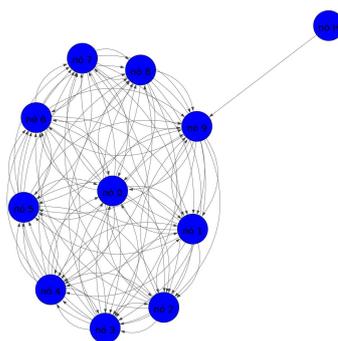


Figura 38 – Grafo completo com presença do operador, respectivo líder de controle (nó 9 corresponde ao robô10).

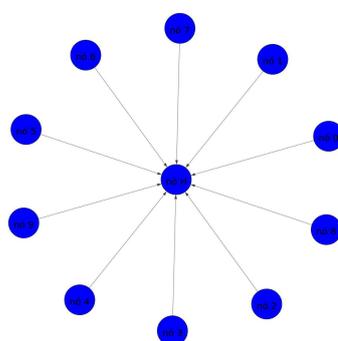


Figura 39 – Grafo estrela com presença do operador, respectivos líderes de informação.

definido como nos primeiros 15s de simulação dos casos apresentados anteriormente. Portanto demonstrando a influência do agente “teleoperado” que se propaga pela rede alterando o comportamento do *swarm*.

O treinamento e validação da RNN é apresentado no Apêndice A. Na Figura 40 é apresentada a interface do operador de forma pictórica, para uma melhor visualização, na qual as tartarugas em marrom representam os agentes autônomos e a tartaruga branca representa o agente teleoperado e o raio para definir o fim da tarefa.

Os dados para o treinamento da LSTM foram obtidos de testes com voluntários que geraram dados de cinco tentativas bem sucedidas, que se entende por cumprir a tarefa de *rendezvous* com todos os agentes na linha ou dentro da região de interesse, sem ocorrer colisões e dentro de um período não maior que um minuto e trinta segundos. Sendo assim, todas as tentativas bem sucedidas geraram dados que foram utilizados para o treinamento e validação da rede neural. Ao total foram trinta simulações, sendo vinte e cinco para treinamento, dos quais trinta por cento dos dados foram separados para validação (um total de 772 dados) e os outros setenta por cento foram utilizados para treinamento (um total de 1542 dados). As cinco simulações restantes foram utilizadas para teste e para avaliar o desempenho da rede.

O *joystick* utilizado na simulação é apresentado na Figura 7. As instruções que

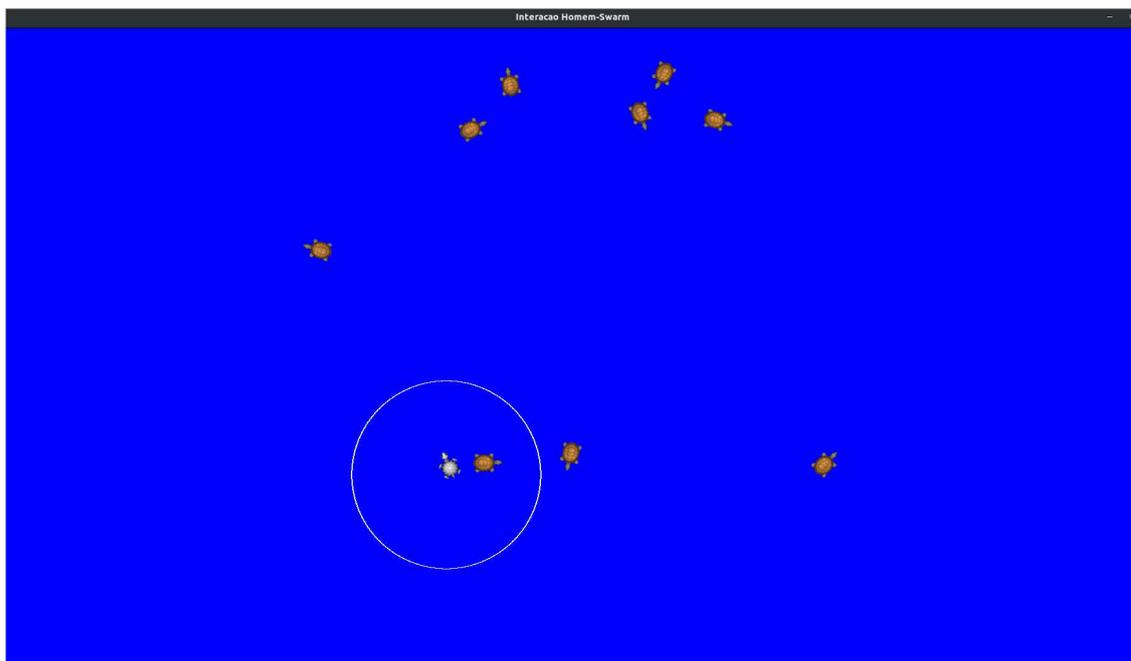


Figura 40 – Interface gráfica do operador que apresenta a posição e orientação dos agentes.

foram encaminhadas aos operadores voluntários é que deveriam realizar a tarefa de *rendezvous* garantindo que todos os agentes se encontrem em um ponto em comum. E a tarefa seria considerada cumprida assim que todos os agentes se encontrassem dentro de um determinado raio do agente teleoperado.

Os dados gerados correspondem a posição no eixo x , posição no eixo y e orientação θ de todos os dez robôs que compõem o sistema. Esses fatores representam o vetor de entrada da RNN. E o vetor de saída é representado pelas entradas de controle, ou seja, velocidade linear e velocidade angular imposta pelo operador ao agente teleoperado através do dispositivo de entrada (*joystick*).

Uma vez obtida a RNN treinada foi desenvolvido um assistente de teleoperação, representado por uma flecha na interface do usuário que busca auxiliar o operador na tarefa de teleoperação. Na Figura 41 pode-se observar a interface com o suporte integrado e na Figura 42 a interface no Gazebo.

O próximo passo é repetir as simulações de teleoperação pura, mas desta vez com suporte à teleoperação. E, por fim, verificar o tempo necessário para completar a tarefa, assim como as medidas de norma-1 das entradas de velocidade linear e velocidade angular.

De modo geral as simulações com o suporte à teleoperação apresentaram resultados melhores quando comparados com a teleoperação pura. O valor médio normalizado de cada métrica analisada é apresentado no gráfico de barras Figura 43.

Como pode ser visto na Figura 43 o SST tem melhor desempenho no tempo de realização da tarefa e a norma L_1 para a velocidade linear, porém o SST tem pior

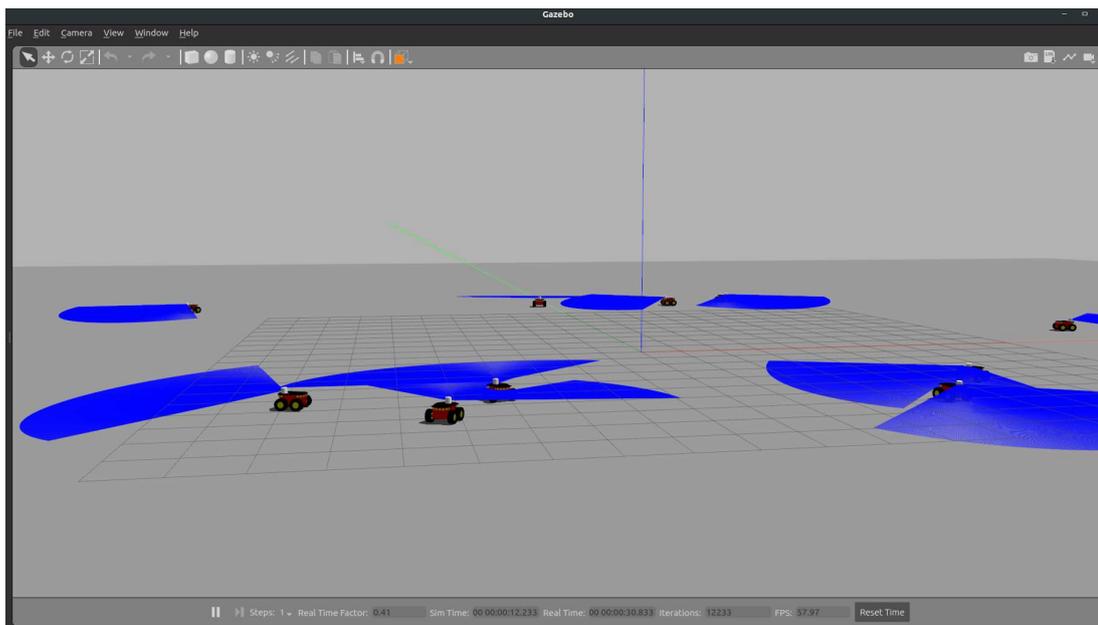


Figura 42 – Interface do simulador com os 10 robôs móveis diferenciais (pioneer3AT).

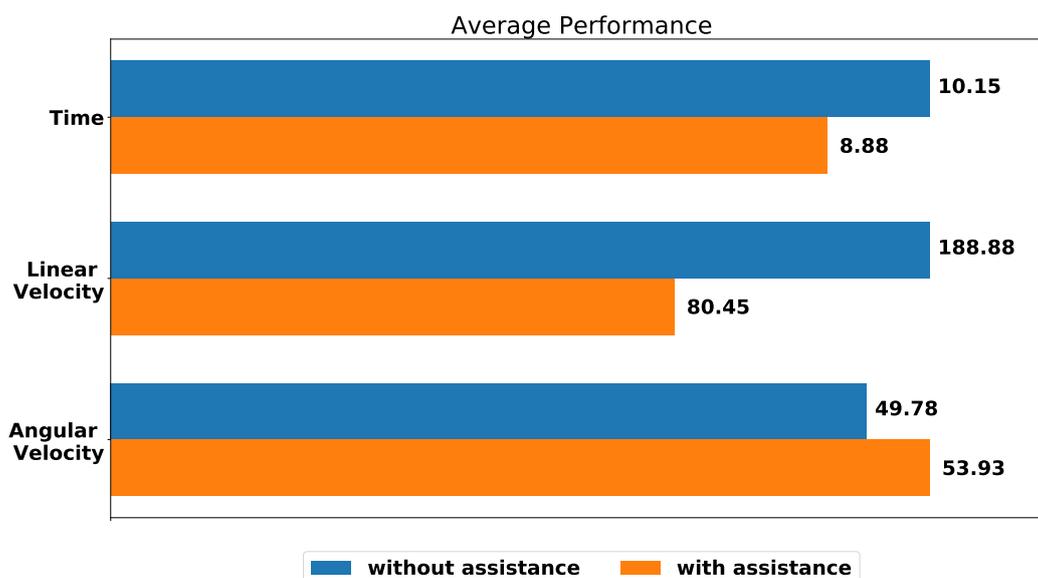


Figura 43 – Gráfico de barras com o valor médio de cada métrica.

operador humano foi capaz de cumprir a missão com o SST.

O valor médio normalizado de cada métrica é apresentado, como no cenário anterior, no gráfico de barras Figura 46.

Para o segundo cenário novamente, como pode ser visto na Figura 46, o tempo para realizar a tarefa e a norma L_1 para a velocidade linear têm melhor desempenho com SST do que o caso sem o suporte. Porém o SST tem pior desempenho para a norma L_1 da velocidade angular.

Assim, tanto para o primeiro como para o segundo cenário, o sistema de IHS

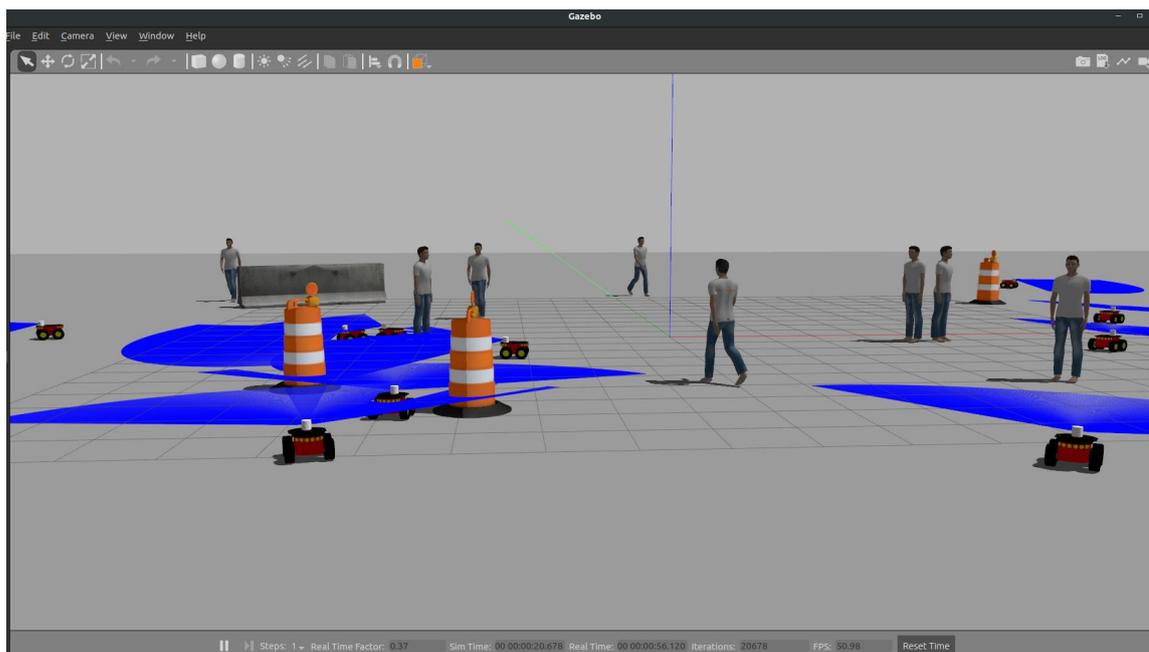


Figura 44 – Interface do simulador com 10 robôs móveis diferenciais (Pioneer-3AT), pedestres e obstáculos.

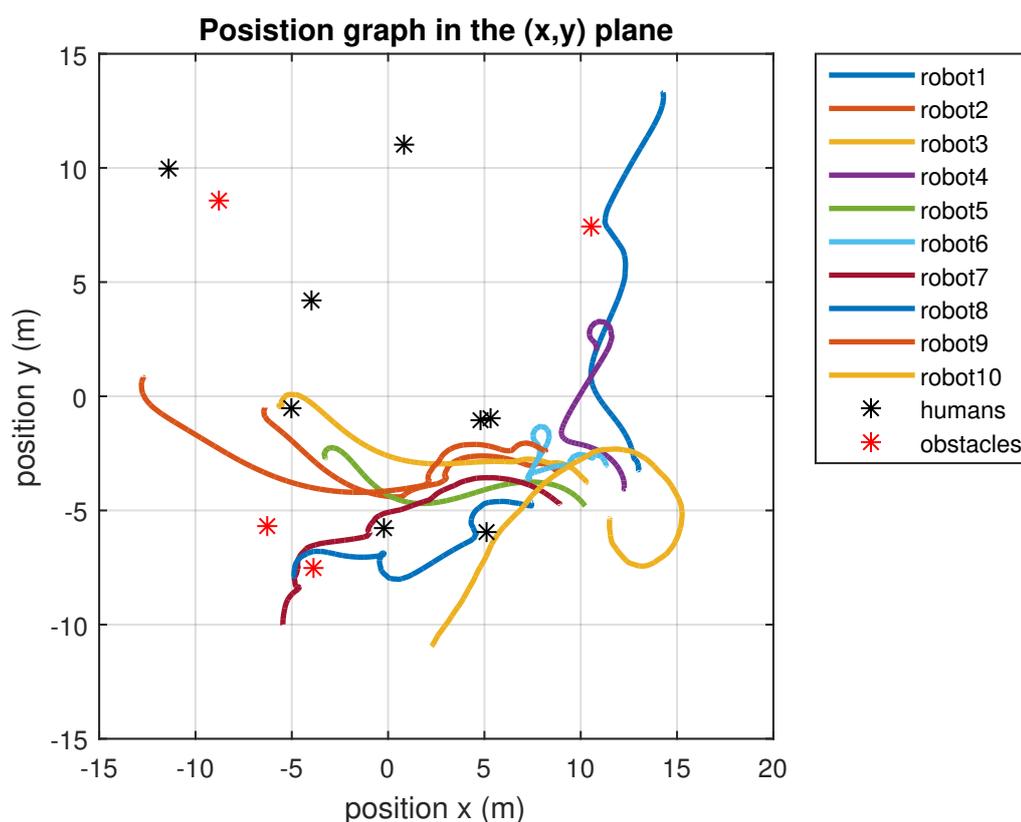


Figura 45 – Simulação de consenso em um sistema com um agente teleoperado (Robot10) e nove agentes autônomos (Robot[1-9]) com obstáculos no ambiente. Link do vídeo da simulação: <https://bit.ly/2W8XSKD>.

proposto com nove robôs autônomos e um agente teleoperado com um sistema de suporte à teleoperação, desenvolvido com uma rede neural recorrente LSTM, foi capaz

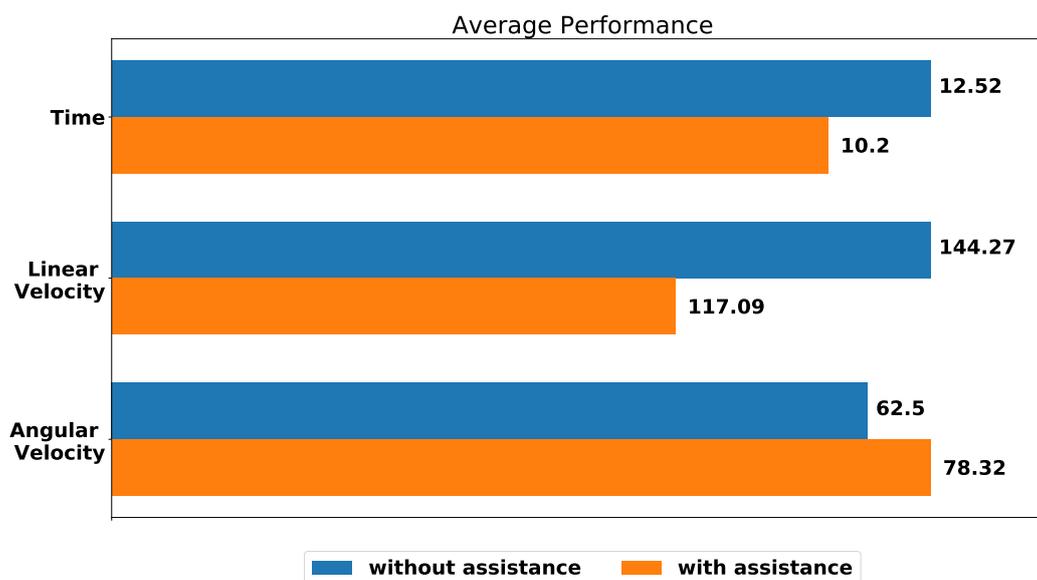


Figura 46 – Gráfico de barras com o valor médio de cada métrica.

de suprir as necessidades para realizar a tarefa de *rendezvous* mesmo na presença de obstáculos, perda de pacotes e conectividade.

Visualizações de *swarms* podem servir a muitos propósitos. O principal, conforme explorado nos estudos anteriores, é melhorar a compreensão, previsão e controle do operador dos comportamentos emergentes que o *swarm* realiza. Um objetivo secundário é garantir que o usuário tenha confiança adequada no *swarm*. Embora o desempenho e a confiança nem sempre estejam correlacionados, a falta de confiança ou excesso de confiança - onde os operadores confiam demais ou muito pouco no sistema automatizado - geralmente é indesejável. A transparência tende a aumentar a confiança na automação e, portanto, é importante verificar se as visualizações dos *swarms* tem o mesmo efeito que a transparência em outros tipos de automação.

Portanto buscou-se investigar a aplicabilidade dos métodos de RNN e Aprendizagem Profunda (Deep Learning) (DL) para a previsão de comportamentos de operadores humanos em sistemas híbridos humano-*swarm*. A dificuldade de modelagem do comportamento humano, assim como dinâmicas não modeladas e as suposições simplificadoras nos métodos de modelagem clássicos resultam em modelos que produzem previsões rapidamente divergentes quando o modelo é usado de maneira iterativa. No entanto, o efeito da dinâmica não modelada pode ser capturado coletando conjuntos de dados do sistema. Estes métodos fornecem um conjunto forte de ferramentas para extrair padrões dos dados; no entanto, grandes conjuntos de dados são geralmente necessários para que os métodos funcionem bem. É importante ressaltar que a coleta de uma grande quantidade de dados de um sistema robótico pode ser uma abordagem complicada e cara e, por isso, se torna essencial o uso de simuladores. Demonstrou-se assim a viabilidade de uso de informações de previsão para a melhora de desempenho

de sistemas IHS.

4.3.2 Sistema de Suporte à Seleção de Líderes

O sistema de apoio à decisão é validado através de simulações computacionais comparando os resultados da missão dos cenários com e sem o auxílio de apoio à decisão.

A principal contribuição aqui reside no sistema de apoio à decisão que auxilia o operador no método de seleção do melhor agente do *swarm*. Durante a operação do sistema, o operador pode reconfigurar a topologia selecionando um agente teleoperado diferente. Quando o sistema está com o sistema de apoio à decisão ativado, uma seleção ideal do agente desejado é fornecida ao operador. Essa seleção é determinada considerando o agente que resulta em um sistema conexo com a pontuação máxima do autovetor de centralidade que avalia os méritos relativos de diferentes seleções de agentes para a execução da missão.

O módulo de seleção de líderes é a base da arquitetura. Este módulo aceita como entrada um conjunto de robôs distribuídos arbitrariamente no plano e seleciona o líder ótimo, ao contrário de algumas abordagens ingênuas presentes na literatura que assumem a existência de um líder específico a priori conhecido por todos os robôs da rede ou dependentes de identificadores de robô estabelecidos a priori (TAVARES; MADRUGA; BRITO; NASCIMENTO, 2020; WALKER; AMRAI; LEWIS; CHAKRABORTY; SYCARA, 2013). Em nossa abordagem os robôs são heterogêneos, iniciam em uma configuração arbitrária e o líder do grupo é selecionado por meio de ferramentas algorítmicas em um ambiente de topologia dinâmica.

O sistema de apoio à decisão implementado é desenhado numa abordagem centrada no ser humano, ou seja, a ajuda e o apoio são fornecidos, mas não impostos. A missão a ser cumprida para validar o sistema de apoio à decisão do operador é a tarefa de rendezvous e o operador assume o controle de um dos robôs do *swarm*. Isso é esperado, pois o operador pode optar por investigar uma área de interesse ou evitar certas ameaças.

O componente central do sistema é a Plataforma IHS desenvolvida. Todos os dados e informações são fornecidos na plataforma e também fornecem o meio de interação entre o operador e os robôs. O operador seleciona e controla o robô líder interagindo com a plataforma. Além disso, a plataforma exibe os dados da rede graficamente para que as informações possam ser facilmente compreendidas pelo operador.

Para maior clareza da apresentação, considera-se uma equipe de quatro robôs. Um dos robôs é selecionado como veículo líder e os demais agentes atuam de forma autônoma. A decisão de seguir a política de seleção de líderes fornecida pelo auxílio à decisão é exclusivamente do operador. Para a estrutura de suporte à decisão, a rede é reconfigurada constantemente durante o tempo de execução do sistema, e o algoritmo

de seleção precisa ser constantemente recalculado online e atualizado.

Assim, nesta rede de robôs, é possível ao operador alternar entre quatro subsistemas distintos, cada um definido pela designação de um agente diferente como líder. A missão do *swarm* é definida como a tarefa de *rendezvous*, e o objetivo da missão é convergir todos os robôs para a mesma área.

O procedimento distribuído para seleção de líder único deve ser feito para que o algoritmo inicie em um dado grafo, $\mathcal{D} = (\mathcal{V}, \mathcal{E})$. Considere o exemplo a seguir, apresentado na Figura 47.

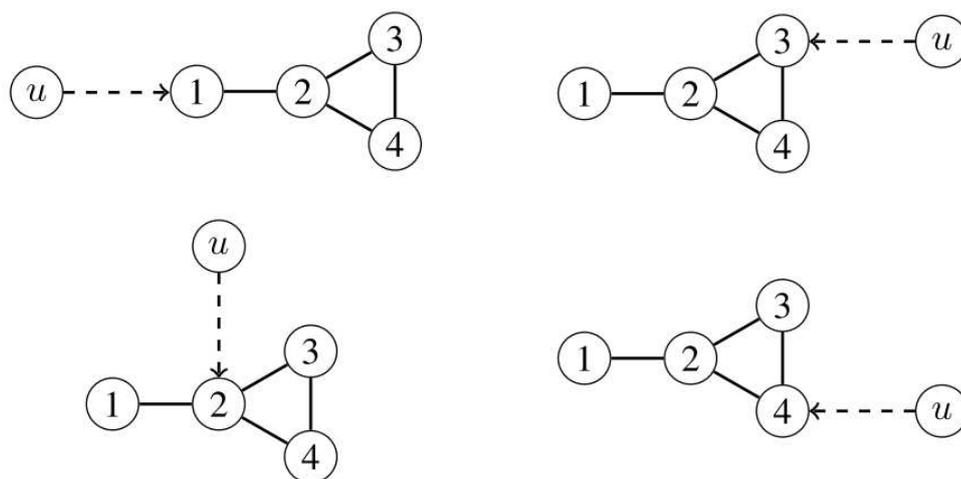


Figura 47 – Todas as escolhas possíveis de líder em uma rede com quatro agentes.

O sistema é composto pelas seguintes etapas:

1. Verificar se há uma árvore de extensão à partir de cada nó.
2. Calcular o valor do autovetor de centralidade
3. Selecionar o nó que possua uma árvore de extensão e tenha o maior valor do autovetor de centralidade

Na Figura 48 pode-se observar a interface para seleção do líder. O botão verde indica o robô recomendado que para o grafo conexo apresentado é o robô-2. E o botão vermelho indica o robô selecionado no atual momento. Uma vez que todos os robôs neste caso possuem uma árvore de extensão (indicado pelo LED verde), a recomendação é dada pelo nó com maior valor do autovetor de centralidade (maior barra horizontal). Pode-se verificar que o nó 1 possui o menor valor de 0,46, o nó 2 possui o maior valor de 1,0 e os nós 3 e 4 empatam com valor de 0,85. O robô-1 é apresentado em vermelho no grafo por ser o robô selecionado para teleoperação naquele instante.

Sendo assim, caso o operador selecione a recomendação do sistema, a informação de consenso irá convergir mais rápido, diminuindo o tempo de execução da

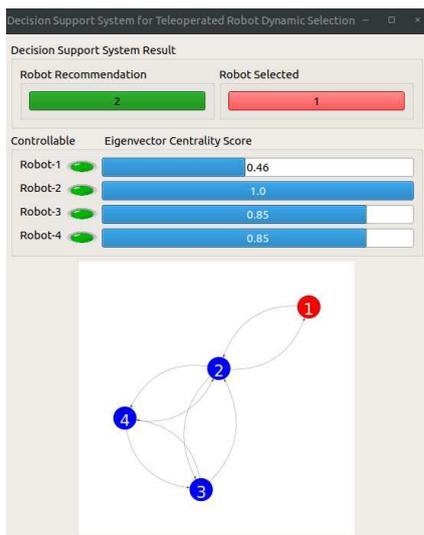


Figura 48 – Interface para seleção de líder com grafo conexo.

tarefa de rendezvous. Caso contrário, este irá apresentar uma convergência mais lenta comprometendo o desempenho na execução da tarefa.

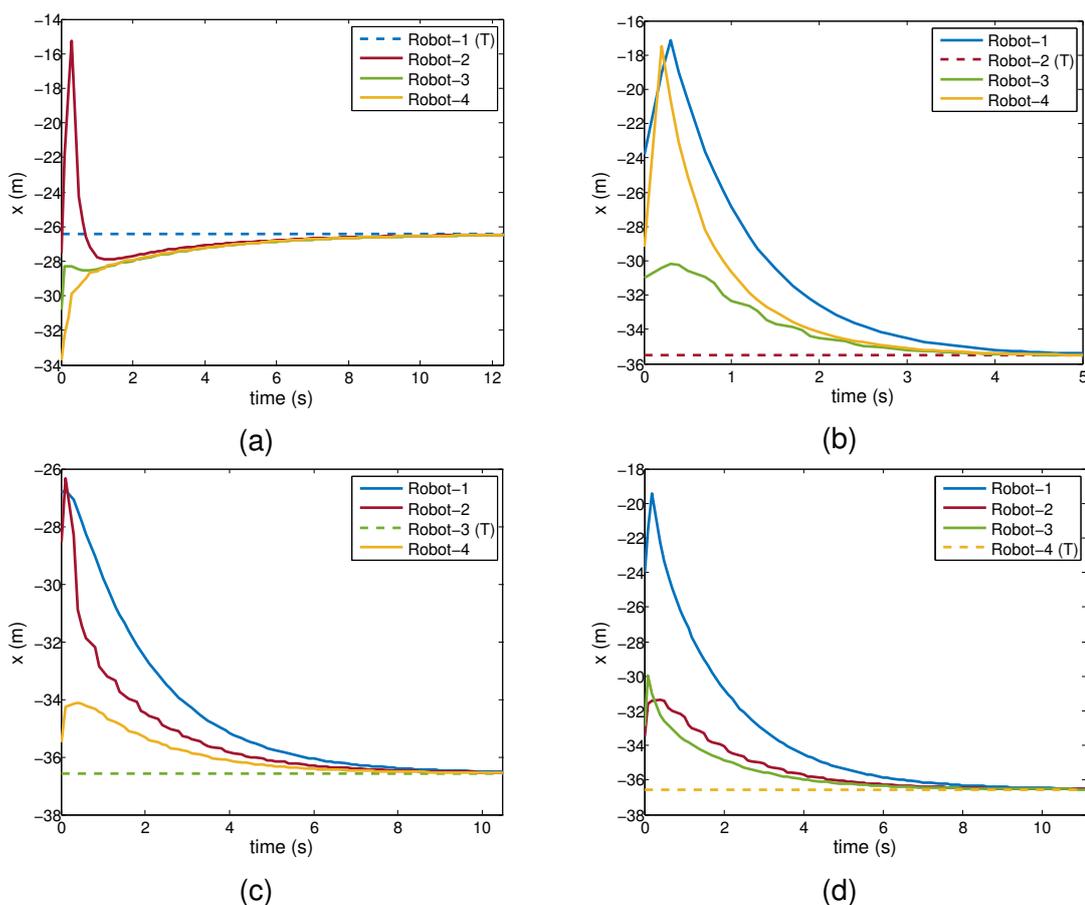


Figura 49 – (a) Consenso da posição x de rendezvous para o robô teleoperado: (a) Robô-1 (b) Robô-2 (c) Robô-3 e (d) Robô-4.

Como pode-se observar pelas Figuras 49 e 50, assim como indicado pelo valor

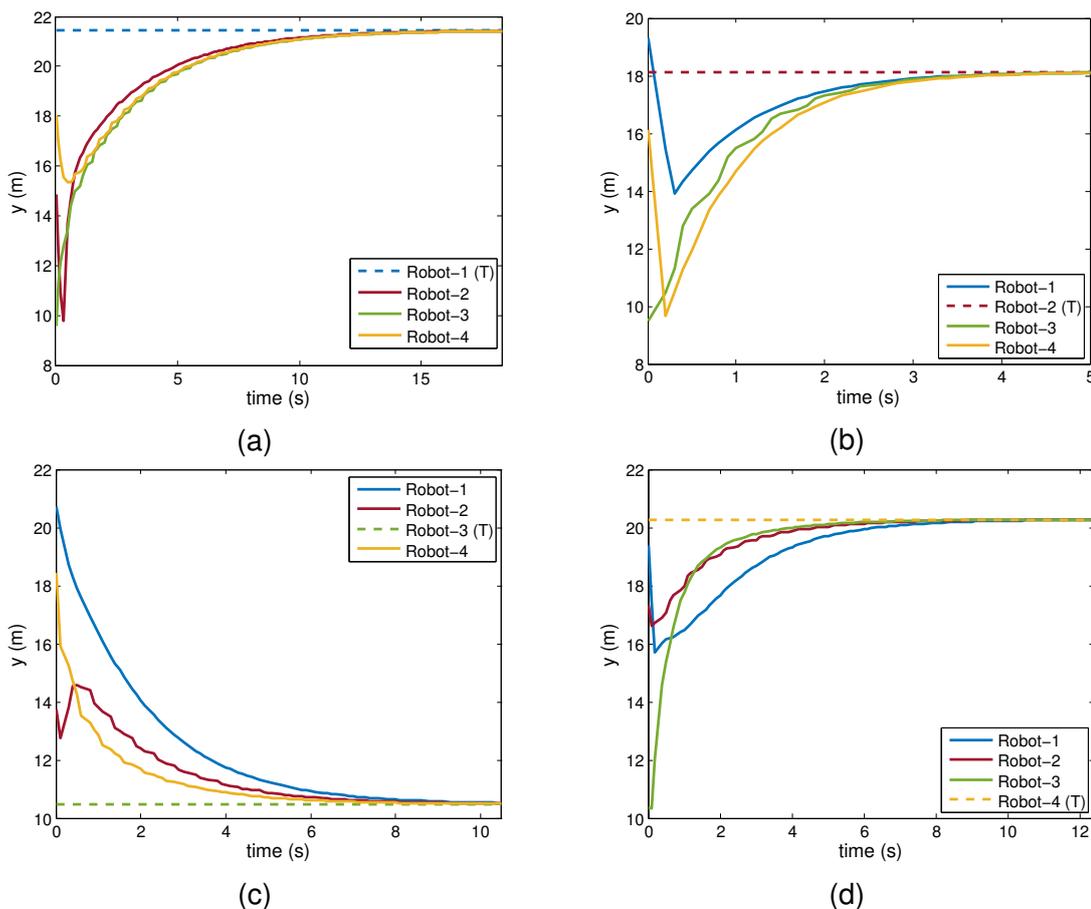


Figura 50 – (a) Consenso da posição y de *rendezvous* para o robô teleoperado: (a) Robô-1 (b) Robô-2 (c) Robô-3 e (d) Robô-4.

do autovetor de centralidade na Figura 48, os gráficos nas Figuras 49a e 50a indicam o caso em que se selecionou o robô-1 para teleoperação, que possui o menor valor do autovetor de centralidade e, como previsto, é o caso em que o tempo para convergência da informação de consenso é maior, em torno de 10,69s para o eixo x e 14,09s para o eixo y . Já os gráficos nas Figuras 49b e 50b indicam o caso de seleção do robô-2 para teleoperação e, como pode ser observado, possui a convergência para o valor de consenso mais rápida entre as quatro possibilidades de seleção para teleoperação, com um valor de cerca de 5,2s para o eixo x e 4,2s para o eixo y . Pode-se repetir a análise para o robô-3 e robô-4 que possuem aproximadamente o mesmo tempo de convergência, uma vez que ambos possuem o mesmo valor do autovetor de centralidade, e ambos possuem um tempo de convergência intermediário sendo o tempo de convergência para o eixo x de cerca de 9,09s e 9,89s e para o eixo y cerca de 8,89s e 8,39s, respectivamente.

Portanto, como afirmado anteriormente, a seleção do robô irá afetar o tempo de convergência para a informação de consenso.

No caso em que o sistema não for conexo, o sistema de sugestão indica para o operador a perda de conexão. Na Figura 51 pode-se observar que a perda de co-

nectividade é indicada por um LED cinza e um texto, com valor das barras horizontais zeradas, indicando a não conectividade do sistema.

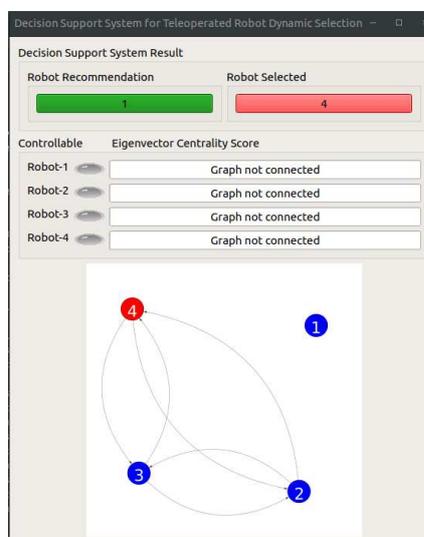


Figura 51 – Interface para seleção de líder com grafo não conexo.

Por fim para o caso de um grafo direcionado a não existência de uma árvore de extensão é indicada por um LED vermelho e, portanto, este agente mesmo que possua um valor de centralidade mais elevado, este não fará parte do processo de seleção da recomendação para o operador, como pode ser observado na Figura 53. Na Figura 52 é apresentado um exemplo de grafo em que o agente com maior valor do autovetor de centralidade não possui uma árvore de extensão. E, portanto, não é capaz de levar o sistema ao consenso e por isso, não faz parte da lista ordenada de recomendação para seleção do agente teleoperado.

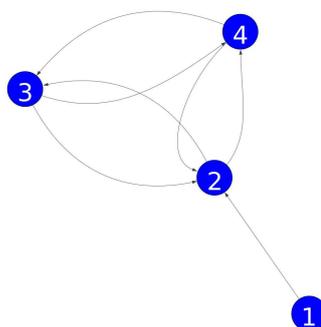


Figura 52 – Exemplo de grafo em que o nó com maior valor do autovetor de centralidade não possui uma árvore de extensão.

Nas Figuras 54 e 55 pode-se observar o que já havia sido indicado na Figura 53 pela interface de seleção de líder, que não é viável apenas selecionar o agente com maior autovetor de centralidade, uma vez que para ocorrer o consenso é necessário

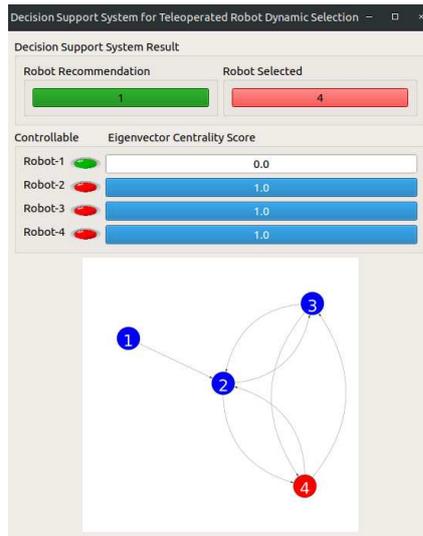


Figura 53 – Interface para seleção de líder com um nó sem árvore de extensão.

que exista uma árvore de extensão à partir do nó selecionado para teleoperação. Sendo assim, pode-se observar que apenas na Figura 54a e 55a que ocorre o consenso, sendo que nos casos das Figuras 54b e 55b, 54c e 55c, 54d e 55d os robôs convergem para valores distintos, ou seja, o sistema não é capaz de atingir o consenso.

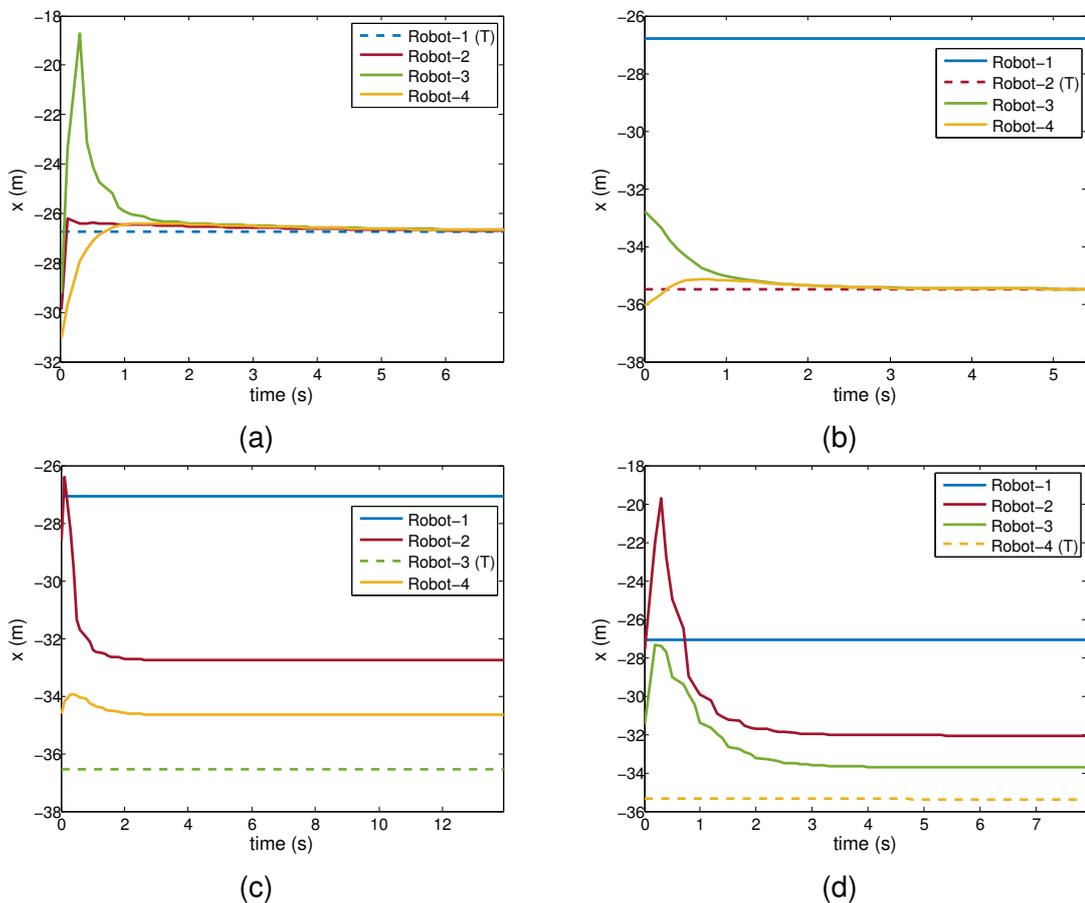


Figura 54 – (a) Consenso da posição x de *rendezvous* para o robô teleoperado: (a) Robô-1 (b) Robô-2 (c) Robô-3 e (d) Robô-4.

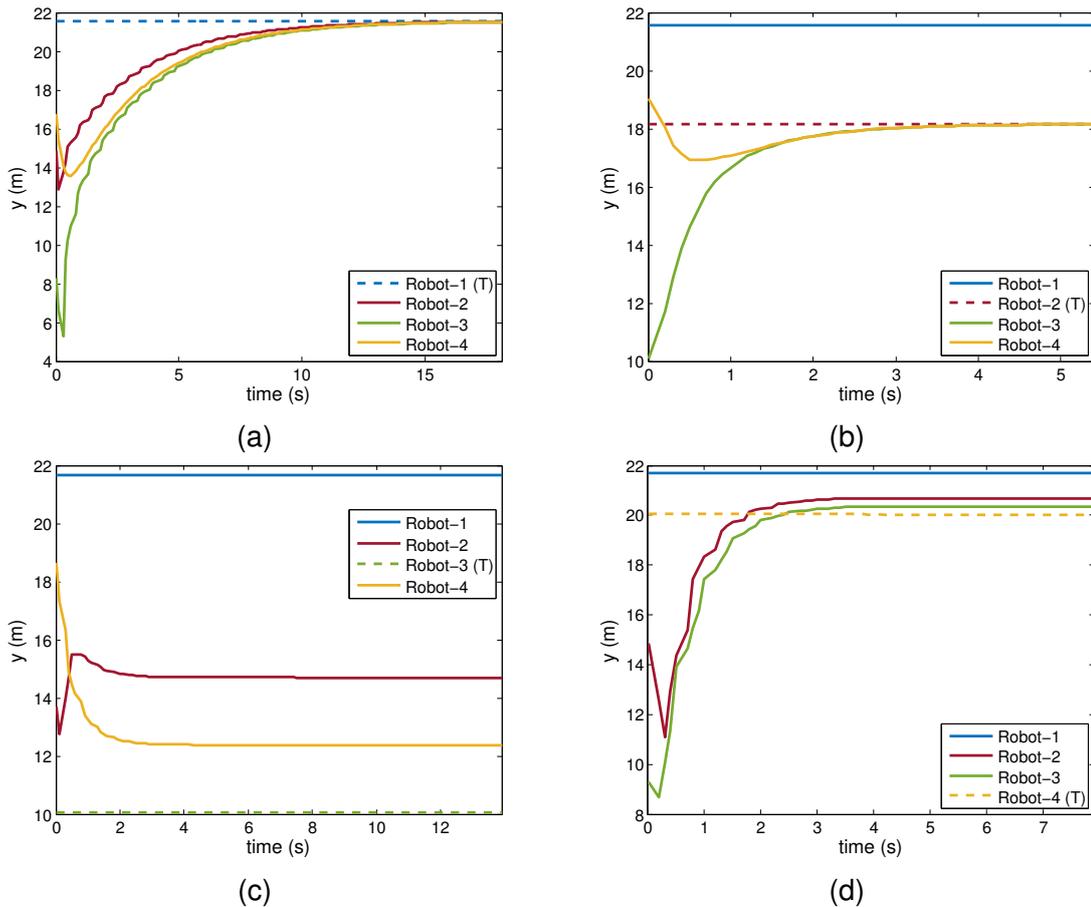


Figura 55 – (a) Consenso da posição y de rendezvous para o robô teleoperado: (a) Robô-1 (b) Robô-2 (c) Robô-3 e (d) Robô-4.

Portanto, encerramos a seção de resultados e simulações referentes ao teleoperador com as contribuições para avaliação e suporte do sistema com uma abordagem centrada no humano. O próximo capítulo trata do encerramento da tese com o resumo dos objetivos que foram atingidos, sugestões de futuros trabalhos e contribuições resultantes durante o desenvolvimento desta tese e do doutorado.

5 CONSIDERAÇÕES FINAIS

Nesta seção apresenta-se os objetivos aqui alcançados, possíveis ramificações da proposta de tese aqui desenvolvida e as conclusões.

5.1 OBJETIVOS ALCANÇADOS

Os objetivos propostos são apresentados mais uma vez aqui.

1. Propor uma plataforma para aplicar o framework de agência para sistemas IHS.
2. Propor métodos de auxílio e suporte à tarefa de teleoperação.
3. Identificar e propor ferramentas de validação de desempenho do *swarm*.

Observa-se que os três objetivos propostos foram atingidos. As argumentações finais, publicações e conclusões que corroboram para esta afirmação são apresentados na seção final.

5.2 CONCLUSÃO

A plataforma de IHS proposta e o framework para avaliar o senso de agência se demonstraram como um recurso valioso para avaliar os diferentes aspectos do projeto de sistemas sociotécnicos e capturar a dinâmica e interações entre operadores, usuários, artefatos técnicos e o ambiente, que resultaram na submissão do artigo: TCHILIAN, R.; MORENO, U. F.; NETTO, M. Human-Swarm Interaction Platform to Assess Sense of Agency. *Journal of Control, Automation and Electrical Systems*.

A solução proposta fornece concepção valiosa para os princípios de fatores humanos, para orientar o projeto centrado no ser humano e a implementação desses sistemas, como forma de melhorar o desempenho do operador/supervisor em uma variedade de missões em ambientes não estruturados e dinâmicos.

Como prova de conceito, foi demonstrada a capacidade de fornecer uma avaliação para analisar como o LoA impacta o problema de desempenho OOTL por meio de um estudo de caso de supervisão e controle de *swarms* urbanos autônomos para cidades inteligentes e interação segura com humanos. Desta forma, a estrutura proposta pode ajudar no projeto, especificação e avaliação de futuros sistemas IHS para melhorar a equipe humano-máquina, mantendo o operador de forma clara, inequívoca e segura dentro da malha de controle.

Afinal, uma melhor compreensão de como o senso de agência evolui no caso das interações entre humanos e sistema automatizado certamente refinaria os diferentes modelos de agência e, de forma mais geral, modelos de controle.

Os métodos apresentados como alternativa para suporte na teleoperação de líderes em um sistema IHS, com respectiva resposta na interface de operação, se mostraram uma alternativa viável afim de remediar diversos fatores humanos que afetam no desempenho do sistema, uma vez que os resultados de identificação da tarefa de teleoperação com redes neurais recorrentes no problema de *rendezvous* apresentou acurácia suficiente para identificar o modelo de comportamento humano nesta tarefa específica juntamente com o sistema de suporte preditivo e o sistema de suporte para seleção de líderes se mostraram ferramentas valiosas para melhorar o desempenho do sistema.

O sistema de suporte para teleoperação resultou na publicação: TCHILIAN, R.; MORENO, U. F.; NETTO, M.. Assisted teleoperation for a human-swarm interaction system. IFAC-PapersOnLine, v. 53, n. 5, p. 602-607, 2020.

Além disso, as propostas aqui desenvolvidas geraram mais de cinco mil linhas de código e contribuíram na forma de coautoria para outros três artigos: CORNET, M.; TCHILIAN, R.; NETTO, M.. A swarm of luggage transport robots moving through an airport. IFAC-PapersOnLine, v. 55, n. 2, p. 102-107, 2022; SALEM, F. A. TCHILIAN, R., CARVALHO, S. R., MORENO, U.. Opinion dynamics over a finite set in cooperative multi-robot systems: An asynchronous gossip-based consensus approach. In: Congresso Brasileiro de Automática-CBA. 2020.; SALEM, F. A.; TCHILIAN, R.; MORENO, U. Evolution of discrete opinions on human-swarm interaction in influence networks. 14º Simpósio Brasileiro de Automação Inteligente. Ouro Preto, MG, Brazil: Galoá, v. 1, p. 2344-2349, 2019.

5.3 TRABALHOS FUTUROS

Sugestões de trabalhos futuros incluem testar os tipos de distração que o operador humano pode lidar como: cognitiva (por exemplo, ao se adicionar uma tarefa de contagem regressiva), visual (ao se adicionar a leitura de um texto periférico, por exemplo), visuomotor (realizar outra tarefa com controle visual obrigatório) e motor (realizar outra tarefa enquanto se mantém o contato visual com a tarefa em execução). E ser capaz de identificar e discriminar entre essas situações, assim como também identificar fatores como estilos de direção, fadiga, atenção e etc, em tempo de execução e ser capaz de auxiliar na execução da tarefa primária.

Além disso, medidas como da confiança relatadas explicitamente pelo usuário, são úteis para trabalhos futuros na construção de um modelo de confiança do usuário, pelo qual o próprio *swarm* pode estimar o nível de confiança atual do operador e adaptar seu comportamento de acordo, ou seja, como efetivamente e adequadamente escolher o nível adequado de autonomia. Muito potencial está em abordagens que otimizam o nível de autonomia com relação à confiança humana na execução de determinada tarefa, isto é, modelando a confiança na automação e na autoconfiança

humana. Uma vez que um requisito essencial para permitir robustez e eficiência nas equipes de humanos-robôs é a capacidade de ajustar dinamicamente o nível de autonomia para otimizar o uso de recursos e capacidades à medida que as condições evoluem. Embora a autonomia deslizante seja bem definida e compreendida em aplicações em que um único humano esteja trabalhando com um único robô, esta é pouco explorada quando aplicada a equipes de humanos que trabalham com vários robôs. Há diversas propostas preliminares de autonomia deslizante, autonomia ajustável e autonomia adaptativa para sistemas IHS, na qual o nível de autonomia do sistema varia durante o tempo de execução, mas ainda é uma questão em aberto e pesquisas na área são escassas.

Outro caminho a ser explorado é o desenvolvimento de uma arquitetura de controle que ajusta as funções autônomas da equipe do robô com base na carga de trabalho monitorada e na consciência situacional, afim de permitir que humanos e robôs funcionem como uma equipe. Portanto, o controle compartilhado e de iniciativa mista é um conceito de controle promissor para futuras pesquisas, na qual tanto o operador humano quanto o agente autônomo são responsáveis pela mesma tarefa de controle. Ou seja, identificar como a intenção humana leva a diferentes entradas de comando é necessário. O reconhecimento da intenção humana poderia então ser potencialmente usado pelo *swarm* para ajustar seu comportamento de forma adaptável a diferentes intenções. Além disso, pode ajudar a entender porque e como as propriedades do *swarm* afetam o comportamento humano.

Trabalhos futuros irão explorar os diferentes aspectos da plataforma proposta. Por exemplo, para avaliar o senso de agência para um cenário complexo envolvendo o controle de um sistema IHS com vários graus de nível de automação e vários participantes. Aplicar medidas implícitas (vinculação intencional) e explícitas (relatos verbais) de agência para demonstrar como as diferentes propriedades do sistema afetam o senso de agência. Dessa forma, ampliando a literatura sobre o senso de agência como uma estrutura para avaliar as interações humano-automação, identificando as condições para experimentar a agência em ambientes de automação complexos e fornecendo diretrizes para o projeto de sistemas IHS, bem como novas medidas para quantificar experiência de controle sobre esses sistemas críticos complexos. Dentre outros aspectos que poderiam ser explorados, mas que não fizeram parte do escopo desta tese, poderíamos citar a incorporação do comportamento humano e tecnológico levando-se em consideração questões éticas.

REFERÊNCIAS

- ADLER, Rachel F; BENBUNAN-FICH, Raquel. Juggling on a high wire: Multitasking effects on performance. **International Journal of Human-Computer Studies**, Elsevier, v. 70, n. 2, p. 156–168, 2012.
- AMRAI, Saman Amirpour *et al.* Explicit vs. tacit leadership in influencing the behavior of swarms. *In*: IEEE. 2014 IEEE International Conference on Robotics and Automation (ICRA). [S.l.: s.n.], 2014. p. 2209–2214.
- ANDRAS, Peter. The equivalence of support vector machine and regularization neural networks. **Neural Processing Letters**, Springer, v. 15, n. 2, p. 97–104, 2002.
- ASAMA, Hajime; MATSUMOTO, Akihiro; ISHIDA, Yoshiki. Design Of An Autonomous And Distributed Robot System: Actress. *In*: IROS. [S.l.: s.n.], 1989. p. 283–290.
- ATMAN, Made Widhi Surya *et al.* Motion synchronization for semi-autonomous robotic swarm with a passivity-short human operator. **International Journal of Intelligent Robotics and Applications**, Springer, v. 2, n. 2, p. 235–251, 2018.
- B.E.A. Final Report on the accident of the flight AF 447 Rio de Janeiro-Paris. <http://www.bea.aero/fr/enquetes/vol.af.447/rapport.final.fr.php>, 2012.
- BENI, Gerardo. The concept of cellular robotic system. *In*: IEEE. INTELLIGENT Control, 1988. Proceedings., IEEE International Symposium on. [S.l.: s.n.], 1988. p. 57–62.
- BERBERIAN, B. Man-Machine teaming: a problem of Agency. **IFAC-PapersOnLine**, Elsevier, v. 51, n. 34, p. 118–123, 2019.
- BERBERIAN, Bruno; LE BLAYE, Patrick *et al.* Data transmission latency and sense of control. *In*: SPRINGER. INTERNATIONAL conference on engineering psychology and cognitive ergonomics. [S.l.: s.n.], 2013. p. 3–12.
- BERBERIAN, Bruno; SARRAZIN, Jean-Christophe *et al.* Automation technology and sense of control: a window on human agency. **PloS one**, Public Library of Science San Francisco, USA, v. 7, n. 3, e34075, 2012.
- BERBERIAN, Bruno; SOMON, Bertille *et al.* The out-of-the-loop Brain: a neuroergonomic approach of the human automation interaction. **Annual Reviews in Control**, Elsevier, v. 44, p. 303–315, 2017.
- BILLINGS, Charles E. **Human-centered aircraft automation: A concept and guidelines**. [S.l.]: National Aeronautics e Space Administration, Ames Research Center, 1991. v. 103885.

BISHOP, Christopher M. **Pattern recognition and machine learning**. [S.l.]: springer, 2006.

BONACICH, Phillip. Technique for analyzing overlapping memberships. **Sociological methodology**, JSTOR, v. 4, p. 176–185, 1972.

BOND, Alan H; GASSER, Les. **Readings in distributed artificial intelligence**. [S.l.]: Morgan Kaufmann, 2014.

CALLOUD, Philippe *et al.* Indoor automation with many mobile robots. *In*: IEEE. INTELLIGENT Robots and Systems' 90.'Towards a New Frontier of Applications', Proceedings. IROS'90. IEEE International Workshop on. [S.l.: s.n.], 1990. p. 67–72.

CAMPBELL, Donald J. Task complexity: A review and analysis. **Academy of management review**, Academy of Management Briarcliff Manor, NY 10510, v. 13, n. 1, p. 40–52, 1988.

CAO, Y.U. *et al.* Cooperative mobile robotics: antecedents and directions. **Intelligent Robots and Systems, IEEE/RSJ International Conference on**, IEEE Computer Society, Los Alamitos, CA, USA, v. 1, p. 226, 1995. DOI: <http://doi.ieeecomputersociety.org/10.1109/IROS.1995.525801>.

CASPAR, Emilie A; CHRISTENSEN, Julia F *et al.* Coercion changes the sense of agency in the human brain. **Current biology**, Elsevier, v. 26, n. 5, p. 585–592, 2016.

CASPAR, Emilie A; VUILLAUME, Laurène *et al.* The influence of (dis) belief in free will on immoral behavior. **Frontiers in psychology**, Frontiers, v. 8, p. 20, 2017.

CAVALCANTI, João *et al.* A real-time web-based networked control system education platform. **International Journal of Electrical Engineering Education**, SAGE Publications Sage UK: London, England, v. 55, n. 2, p. 130–141, 2018.

CHAIMOWICZ, Luiz; PEREIRA, Guilherme A.S.; CAMPOS, Mario F. M. Robótica Cooperativa. *In*: ROMERO, Roseli *et al.* (Ed.). **Robótica Móvel**. [S.l.]: LTC, 2014. cap. 13, p. 242–255.

CHAMBON, Valerian; HAGGARD, Patrick. Sense of control depends on fluency of action selection, not motor performance. **Cognition**, Elsevier, v. 125, n. 3, p. 441–451, 2012.

CHEN, Jessie YC; BARNES, Michael J. Human-agent teaming for multirobot control: A review of human factors issues. **IEEE Transactions on Human-Machine Systems**, IEEE, v. 44, n. 1, p. 13–29, 2014.

CHIOU, Manolis *et al.* Towards the principled study of variable autonomy in mobile robots. *In: IEEE. 2015 IEEE International Conference on Systems, Man, and Cybernetics.* [S.l.: s.n.], 2015. p. 1053–1059.

CLARK, Andrew; BUSHNELL, Linda; POOVENDRAN, Radha. A supermodular optimization framework for leader selection under link noise in linear multi-agent systems. **IEEE Transactions on Automatic Control**, IEEE, v. 59, n. 2, p. 283–296, 2013.

CLARK, Andrew; BUSHNELL, Linda; POOVENDRAN, Radha. Leader selection games under link noise injection attacks. *In: PROCEEDINGS of the 1st international conference on High Confidence Networked Systems.* [S.l.: s.n.], 2012. p. 31–40.

CROIX, Jean-Pierre de la; EGERSTEDT, Magnus B. Controllability characterizations of leader-based swarm interactions. *In: GEORGIA INSTITUTE OF TECHNOLOGY.*

CUMMINGS, Mary L *et al.* Task versus vehicle-based control paradigms in multiple unmanned vehicle supervision by a single operator. **IEEE Transactions on Human-Machine Systems**, IEEE, v. 44, n. 3, p. 353–361, 2014.

DE VISSER, Ewart J *et al.* Towards a theory of longitudinal trust calibration in human–robot teams. **International journal of social robotics**, Springer, v. 12, n. 2, p. 459–478, 2020.

DEHAIS, Frédéric *et al.* Cognitive conflict in human–automation interactions: a psychophysiological study. **Applied ergonomics**, Elsevier, v. 43, n. 3, p. 588–595, 2012.

DEKKER, Sidney WA; WOODS, David D. MABA-MABA or abracadabra? Progress on human–automation co-ordination. **Cognition, Technology & Work**, Springer, v. 4, n. 4, p. 240–244, 2002.

DESAI, Munjal; YANCO, Holly A. Blending human and robot inputs for sliding scale autonomy. *In: IEEE. ROMAN 2005. IEEE International Workshop on Robot and Human Interactive Communication, 2005.* [S.l.: s.n.], 2005. p. 537–542.

DIAS, Charitha *et al.* Calibrating a social force based model for simulating personal mobility vehicles and pedestrian mixed traffic. **Simulation Modelling Practice and Theory**, Elsevier, v. 87, p. 395–411, 2018.

DRAGAN, Anca D; SRINIVASA, Siddhartha S. A policy-blending formalism for shared control. **The International Journal of Robotics Research**, SAGE Publications Sage UK: London, England, v. 32, n. 7, p. 790–805, 2013.

- EGERSTEDT, Magnus *et al.* Interacting with networks of mobile agents. *In: LARGE-SCALE Networks in Engineering and Life Sciences*. [S.l.]: Springer, 2014. p. 199–224.
- ENDSLEY, Mica R. Automation and situation awareness. *In: AUTOMATION and human performance: Theory and applications*. [S.l.]: CRC Press, 2018. p. 163–181.
- ENDSLEY, Mica R. Measurement of situation awareness in dynamic systems. **Human factors**, SAGE Publications Sage CA: Los Angeles, CA, v. 37, n. 1, p. 65–84, 1995.
- ENDSLEY, Mica R. Situation awareness global assessment technique (SAGAT). *In: IEEE. PROCEEDINGS of the IEEE 1988 national aerospace and electronics conference*. [S.l.: s.n.], 1988. p. 789–795.
- ERHART, S.; HIRCHE, S. Model and Analysis of the Interaction Dynamics in Cooperative Manipulation Tasks. **IEEE Transactions on Robotics**, v. 32, n. 3, p. 672–683, jun. 2016. ISSN 1552-3098. DOI: 10.1109/TR0.2016.2559500.
- FLEMISCH, Frank *et al.* Towards a dynamic balance between humans and automation: authority, ability, responsibility and control in shared and cooperative control situations. **Cognition, Technology & Work**, Springer, v. 14, n. 1, p. 3–18, 2012.
- FRANCHI, Antonio; BÜLTHOFF, Heinrich H; GIORDANO, Paolo Robuffo. Distributed online leader selection in the bilateral teleoperation of multiple UAVs. *In: IEEE. 2011 50th IEEE Conference on Decision and Control and European Control Conference*. [S.l.: s.n.], 2011. p. 3559–3565.
- FRANCHI, Antonio; GIORDANO, Paolo Robuffo. Online leader selection for improved collective tracking and formation maintenance. **IEEE transactions on control of network systems**, IEEE, v. 5, n. 1, p. 3–13, 2016.
- FRANCHI, Antonio; SECCHI, Cristian *et al.* Shared control: Balancing autonomy and human assistance with a group of quadrotor UAVs. **IEEE Robotics & Automation Magazine**, IEEE, v. 19, n. 3, p. 57–68, 2012.
- FRITH, Chris D. Action, agency and responsibility. **Neuropsychologia**, Elsevier, v. 55, p. 137–142, 2014.
- FUKUDA, Toshio; NAKAGAWA, Seiya. A dynamically reconfigurable robotic system (concept of a system and optimal configurations). *In: INTERNATIONAL SOCIETY FOR OPTICS e PHOTONICS. ROBOTICS and IECON'87 Conferences*. [S.l.: s.n.], 1987. p. 588–595.
- FUNAHASHI, Ken-ichi; NAKAMURA, Yuichi. Approximation of dynamical systems by continuous time recurrent neural networks. **Neural networks**, Elsevier, v. 6, n. 6, p. 801–806, 1993.

- GAL, Yarin. Uncertainty in deep learning. **University of Cambridge**, v. 1, p. 3, 2016.
- GALLAGHER, Shaun. Philosophical conceptions of the self: implications for cognitive science. **Trends in cognitive sciences**, Elsevier, v. 4, n. 1, p. 14–21, 2000.
- GERKEY, Brian P; KONOLIGE, Kurt. Planning and control in unstructured terrain. *In*: CITESEER. ICRA workshop on path planning on costmaps. [S.l.: s.n.], 2008.
- GHAZIZADEH, Mahtab; LEE, John D; BOYLE, Linda Ng. Extending the Technology Acceptance Model to assess automation. **Cognition, Technology & Work**, Springer, v. 14, p. 39–49, 2012.
- GLEICH, David F. PageRank beyond the Web. **siam REVIEW**, SIAM, v. 57, n. 3, p. 321–363, 2015.
- GOLD, Christian *et al.* “Take over!” How long does it take to get the driver back into the loop? *In*: SAGE PUBLICATIONS SAGE CA: LOS ANGELES, CA, 1. PROCEEDINGS of the human factors and ergonomics society annual meeting. [S.l.: s.n.], 2013. p. 1938–1942.
- GOODRICH, Michael A; KERMAN, Sean; JUN, Shin-Young. On leadership and influence in human-swarm interaction. *In*: 2012 AAAI Fall Symposium Series. [S.l.: s.n.], 2012.
- GOODRICH, Michael A; OLSEN, Dan R *et al.* Experiments in adjustable autonomy. *In*: SEATTLE, WA. PROCEEDINGS of IJCAI Workshop on autonomy, delegation and control: interacting with intelligent agents. [S.l.: s.n.], 2001. p. 1624–1629.
- GOODRICH, Michael A; QUIGLEY, Morgan; COSENZO, Keryl. Task switching and multi-robot teams. *In*: MULTI-ROBOT Systems. From Swarms to Intelligent Automata Volume III. [S.l.]: Springer, 2005. p. 185–195.
- GOODRICH, Michael A; SCHULTZ, Alan C. Human-robot interaction: a survey. **Foundations and Trends® in Human–Computer Interaction**, Now Publishers, Inc., v. 1, n. 3, p. 203–275, 2008.
- GREFF, Klaus *et al.* LSTM: A search space odyssey. **IEEE transactions on neural networks and learning systems**, IEEE, v. 28, n. 10, p. 2222–2232, 2016.
- HAGGARD, Patrick; CLARK, Sam; KALOGERAS, Jeri. Voluntary action and conscious awareness. **Nature neuroscience**, Nature Publishing Group, v. 5, n. 4, p. 382–385, 2002.
- HAMMER, Barbara; GERSMANN, Kai. A note on the universal approximation capability of support vector machines. **neural processing letters**, Springer, v. 17, n. 1, p. 43–53, 2003.

HANCOCK, Peter A *et al.* A meta-analysis of factors affecting trust in human-robot interaction. **Human factors**, Sage Publications Sage CA: Los Angeles, CA, v. 53, n. 5, p. 517–527, 2011.

HARRIOTT, Caroline E *et al.* Biologically-inspired human-swarm interaction metrics. *In*: SAGE PUBLICATIONS SAGE CA: LOS ANGELES, CA, 1. PROCEEDINGS of the Human Factors and Ergonomics Society Annual Meeting. [S.l.: s.n.], 2014. p. 1471–1475.

HART, Peter E; NILSSON, Nils J; RAPHAEL, Bertram. A formal basis for the heuristic determination of minimum cost paths. **IEEE transactions on Systems Science and Cybernetics**, IEEE, v. 4, n. 2, p. 100–107, 1968.

HELBING, Dirk. A mathematical model for the behavior of pedestrians. **Behavioral science**, Wiley Online Library, v. 36, n. 4, p. 298–310, 1991.

HELBING, Dirk. **Quantitative sociodynamics: stochastic methods and models of social interaction processes**. [S.l.]: Springer Science & Business Media, 2010.

HELBING, Dirk; MOLNAR, Peter. Social force model for pedestrian dynamics. **Physical review E**, APS, v. 51, n. 5, p. 4282, 1995.

HORNIK, Kurt; STINCHCOMBE, Maxwell; WHITE, Halbert *et al.* Multilayer feedforward networks are universal approximators. **Neural networks**, v. 2, n. 5, p. 359–366, 1989.

HUSSEIN, Aya; ABBASS, Hussein. Mixed initiative systems for human-swarm interaction: Opportunities and challenges. *In*: IEEE. 2018 2nd Annual Systems Modelling Conference (SMC). [S.l.: s.n.], 2018. p. 1–8.

JIN, Liang; NIKIFORUK, Peter N; GUPTA, Madan M. Approximation of discrete-time state-space trajectories using dynamic recurrent neural networks. **IEEE Transactions on Automatic Control**, IEEE, v. 40, n. 7, p. 1266–1270, 1995.

JONES, Charles M. What do we know about high-frequency trading? **Columbia Business School Research Paper**, n. 13-11, 2013.

JONES, Christopher Vernon. **A Principled Design Methodology for Minimalist Multi-robot System Controllers**. 2005. Tese (Doutorado) – Los Angeles, CA, USA. AAI3196826. ISBN 0-542-41076-1.

KABALAN, Bachar. **Crowd dynamics: modeling pedestrian movement and associated generated forces**. 2016. Tese (Doutorado) – Université Paris-Est.

KABER, David B; ENDSLEY, Mica R. The effects of level of automation and adaptive automation on human performance, situation awareness and workload in a dynamic

control task. **Theoretical Issues in Ergonomics Science**, Taylor & Francis, v. 5, n. 2, p. 113–153, 2004.

KABER, David B; ONAL, Emrah; ENDSLEY, Mica R. Design of automation for telerobots and the effect on performance, operator situation awareness, and subjective workload. **Human factors and ergonomics in manufacturing & service industries**, Wiley Online Library, v. 10, n. 4, p. 409–430, 2000.

KANJANAWANISHKUL, Kiattisin. Coordinated Path Following for Mobile Robots Using a Virtual Structure Strategy with Model Predictive Control. **Automatika–Journal for Control, Measurement, Electronics, Computing and Communications**, v. 55, n. 3, 2014.

KATZ, Leo. A new status index derived from sociometric analysis. **Psychometrika**, Springer, v. 18, n. 1, p. 39–43, 1953.

KAWASHIMA, Hiroaki; EGERSTEDT, Magnus. Leader selection via the manipulability of leader-follower networks. *In: IEEE. 2012 American Control Conference (ACC). [S.l.: s.n.], 2012. p. 6053–6058.*

KOLEN, John F; KREMER, Stefan C. **A field guide to dynamical recurrent networks**. [S.l.]: John Wiley & Sons, 2001.

KOLLING, Andreas *et al.* Human interaction with robot swarms: A survey. **IEEE Transactions on Human-Machine Systems**, IEEE, v. 46, n. 1, p. 9–26, 2015.

KOSKO, Bart. Fuzzy systems as universal approximators. **IEEE transactions on computers**, IEEE, v. 43, n. 11, p. 1329–1333, 1994.

LAMNABHI-LAGARRIGUE, Françoise *et al.* Systems & Control for the future of humanity, research agenda: Current and future roles, impact and grand challenges. **Annual Reviews in Control**, Elsevier, v. 43, p. 1–64, 2017.

LE GOFF, Kevin; REY, Arnaud; BERBERIAN, Bruno. Toward a model for effective human-automation interaction: The mediated agency. *In: SPRINGER. INTERNATIONAL Conference on Digital Human Modeling and Applications in Health, Safety, Ergonomics and Risk Management. [S.l.: s.n.], 2015. p. 274–283.*

LE GOFF, Kevin; REY, Arnaud; HAGGARD, Patrick *et al.* Agency modulates interactions with automation technologies. **Ergonomics**, Taylor & Francis, v. 61, n. 9, p. 1282–1297, 2018.

LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning. **nature**, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015.

LEE, Dongjun; SPONG, Mark W. Bilateral teleoperation of multiple cooperative robots over delayed communication networks: Theory. *In: IEEE. PROCEEDINGS of the 2005 IEEE international conference on robotics and automation. [S.l.: s.n.], 2005. p. 360–365.*

LEE, JD. Trust, trustworthiness, and trustability. *In: PRESENTATION at the Workshop on Human Machine Trust for Robust Autonomous Systems. [S.l.: s.n.], 2012.*

LEE, John D; SEE, Katrina A. Trust in automation: Designing for appropriate reliance. **Human factors**, SAGE Publications Sage UK: London, England, v. 46, n. 1, p. 50–80, 2004.

LEWIS, Michael. Human interaction with multiple remote robots. **Reviews of Human Factors and Ergonomics**, SAGE Publications Sage CA: Los Angeles, CA, v. 9, n. 1, p. 131–174, 2013.

LEWIS, Michael; WANG, Jijun; HUGHES, Stephen. USARSim: Simulation for the study of human-robot interaction. **Journal of Cognitive Engineering and Decision Making**, SAGE Publications Sage CA: Los Angeles, CA, v. 1, n. 1, p. 98–120, 2007.

LEWKOWICZ, Michal A; AGARWAL, Rohil; CHAKRABORTY, Nilanjan. Distributed algorithm for selecting leaders for supervisory robotic swarm control. *In: IEEE. 2019 International Symposium on Multi-Robot and Multi-Agent Systems (MRS). [S.l.: s.n.], 2019. p. 112–118.*

LI, Hong-Xing; CHEN, CL Philip. The equivalence between fuzzy logic systems and feedforward neural networks. **IEEE Transactions on Neural Networks**, IEEE, v. 11, n. 2, p. 356–365, 2000.

LI, Shu-Qin *et al.* Design and Development of Multi-Robot Architecture and Decision-Making Model. *In: IEEE. 2007 International Conference on Machine Learning and Cybernetics. [S.l.: s.n.], 2007. p. 610–616.*

LI, Wei. Notion of control-law module and modular framework of cooperative transportation using multiple nonholonomic robotic agents with physical rigid-formation-motion constraints. **IEEE transactions on cybernetics**, IEEE, v. 46, n. 5, p. 1242–1248, 2016.

MA, Cui-Qin; XIE, Lihua. Necessary and sufficient conditions for leader-following bipartite consensus with measurement noise. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, IEEE, v. 50, n. 5, p. 1976–1981, 2018.

MANDIC, Danilo P; CHAMBERS, Jonathon. **Recurrent neural networks for prediction: learning algorithms, architectures and stability.** [S.l.]: John Wiley & Sons, Inc., 2001.

MARS, Franck; CHEVREL, Philippe. Modelling human control of steering for the design of advanced driver assistance systems. **Annual Reviews in Control**, Elsevier, v. 44, p. 292–302, 2017.

MCRUER, Duane T. Human pilot dynamics in compensatory systems-theory, models, and experiments with controlled element and forcing function variations. **AFFDL-TR-65-15**, 1965.

MCRUER, Duane T; KRENDEL, Ezra S. **Mathematical models of human pilot behavior**. [S.l.], 1974.

MOORE, James W; MIDDLETON, D *et al.* Exploring implicit and explicit aspects of sense of agency. **Consciousness and cognition**, Elsevier, v. 21, n. 4, p. 1748–1753, 2012.

MOORE, James W; OBHI, Sukhvinder S. Intentional binding and the sense of agency: a review. **Consciousness and cognition**, Elsevier, v. 21, n. 1, p. 546–561, 2012.

MORAY, Neville. Monitoring behavior and supervisory control. John Wiley & Sons, 1986.

MORETTO, Giovanna; WALSH, Eamonn; HAGGARD, Patrick. Experience of agency and sense of responsibility. **Consciousness and cognition**, Elsevier, v. 20, n. 4, p. 1847–1854, 2011.

MUSIĆ, Selma; HIRCHE, Sandra. Control sharing in human-robot team interaction. **Annual Reviews in Control**, Elsevier, v. 44, p. 342–354, 2017.

NAGAVALLI, Sasanka *et al.* Neglect benevolence in human control of robotic swarms. *In*: IEEE. 2014 IEEE International Conference on Robotics and Automation (ICRA). [S.l.: s.n.], 2014. p. 6047–6053.

NETTO, Mariana; SPURGEON, Sarah K. Special section on Cyber-Physical & Human Systems (CPHS). **Annual Reviews in Control**, v. 44, p. 249–251, 2017.

NORMAN, Donald A. The ‘problem’with automation: inappropriate feedback and interaction, not ‘over-automation’. **Philosophical Transactions of the Royal Society of London. B, Biological Sciences**, The Royal Society London, v. 327, n. 1241, p. 585–593, 1990.

NORMAN, Donald A. **The psychology of everyday things**. [S.l.]: Basic books, 1988.

NUNNALLY, Steven *et al.* Human influence of robotic swarms with bandwidth and localization issues. *In*: IEEE. 2012 IEEE International Conference on Systems, Man, and Cybernetics (SMC). [S.l.: s.n.], 2012. p. 333–338.

OGUNMOLU, Olalekan *et al.* Nonlinear systems identification using deep dynamic neural networks. **arXiv preprint arXiv:1610.01439**, 2016.

OLSEN, Dan R; GOODRICH, Michael A. Metrics for evaluating human-robot interactions. *In*: CITESEER. PROCEEDINGS of PERMIS. [S.l.: s.n.], 2003. p. 4.

ORDOÑEZ, Bernardo *et al.* Generation of trajectories using predictive control for tracking consensus with sensing and connectivity constraint. *In*: COOPERATIVE robots and sensor networks. [S.l.]: Springer, 2014. p. 19–37.

PACAUX-LEMOINE, Marie-Pierre *et al.* Designing intelligent manufacturing systems through Human-Machine Cooperation principles: A human-centered approach. **Computers & Industrial Engineering**, Elsevier, v. 111, p. 581–595, 2017.

PACHERIE, Elisabeth. 14 The Phenomenology of Joint Action: Self-Agency versus Joint Agency. **Joint attention: New developments in psychology, philosophy of mind, and social neuroscience**, MIT Press, p. 343, 2011.

PACHERIE, Elisabeth. The phenomenology of action: A conceptual framework. **Cognition**, Elsevier, v. 107, n. 1, p. 179–217, 2008.

PACHERIE, Elisabeth. The sense of control and the sense of agency. **Psyche**, v. 13, n. 1, p. 1–30, 2007.

PARASURAMAN, Raja; MOLLOY, Robert; SINGH, Indramani L. Performance consequences of automation-induced 'complacency'. **The International Journal of Aviation Psychology**, Taylor & Francis, v. 3, n. 1, p. 1–23, 1993.

PARASURAMAN, Raja; SHERIDAN, Thomas B; WICKENS, Christopher D. Situation awareness, mental workload, and trust in automation: Viable, empirically supported cognitive engineering constructs. **Journal of cognitive engineering and decision making**, Sage Publications Sage CA: Los Angeles, CA, v. 2, n. 2, p. 140–160, 2008.

PAUSCH, Randy; CREA, Thomas; CONWAY, Matthew. A literature survey for virtual environments: Military flight simulator visual systems and simulator sickness. **Presence: Teleoperators & Virtual Environments**, MIT Press One Rogers Street, Cambridge, MA 02142-1209, USA journals-info . . . , v. 1, n. 3, p. 344–363, 1992.

REN, Wei; BEARD, Randal W. **Distributed consensus in multi-vehicle cooperative control**. [S.l.]: Springer, 2008.

REN, Wei; CAO, Yongcan. **Distributed coordination of multi-agent networks: emergent problems, models, and issues**. [S.l.]: Springer Science & Business Media, 2010.

RILEY, Jennifer M *et al.* Situation awareness in human-robot interaction: Challenges and user interface requirements. **Human-Robot Interactions in Future Military Operations**, Ashgate Publishing, p. 171–192, 2010.

ROUNDTREE, Karina A; GOODRICH, Michael A; ADAMS, Julie A. Transparency: Transitioning from human–machine systems to human-swarm systems. **Journal of Cognitive Engineering and Decision Making**, SAGE Publications Sage CA: Los Angeles, CA, v. 13, n. 3, p. 171–195, 2019.

SAEIDI, Hamed; MIKULSKI, Dariusz G; WANG, Y. Trust-based leader selection for bilateral haptic teleoperation of multi-robot systems. *In*: IEEE. 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). [S.l.: s.n.], 2017. p. 6575–6581.

SAHAI, Aisha *et al.* Predictive mechanisms are not involved the same way during human-human vs. human-machine interactions: a review. **Frontiers in neurorobotics**, Frontiers, v. 11, p. 52, 2017.

SALEH, Louay *et al.* Shared steering control between a driver and an automation: Stability in the presence of driver behavior uncertainty. **IEEE Transactions on Intelligent Transportation Systems**, IEEE, v. 14, n. 2, p. 974–983, 2013.

SARTER, Nadine B; WOODS, David D. How in the world did we ever get into that mode? Mode error and awareness in supervisory control. **Human factors**, SAGE Publications Sage CA: Los Angeles, CA, v. 37, n. 1, p. 5–19, 1995.

SCHÄFER, Anton Maximilian; ZIMMERMANN, Hans Georg. Recurrent neural networks are universal approximators. *In*: SPRINGER. INTERNATIONAL Conference on Artificial Neural Networks. [S.l.: s.n.], 2006. p. 632–640.

SCHMITT, Fabian; ROTH, Gunar; SCHULTE, Axel. Design and evaluation of a mixed-initiative planner for multi-vehicle missions. *In*: SPRINGER. INTERNATIONAL Conference on Engineering Psychology and Cognitive Ergonomics. [S.l.: s.n.], 2017. p. 375–392.

SEBANZ, Natalie; BEKKERING, Harold; KNOBLICH, Günther. Joint action: bodies and minds moving together. **Trends in cognitive sciences**, Elsevier, v. 10, n. 2, p. 70–76, 2006.

SHERIDAN, Thomas B; VERPLANK, William L. **Human and computer control of undersea teleoperators**. [S.l.], 1978.

SHNEIDERMAN, Ben; PLAISANT, Catherine. **Designing the user interface: Strategies for effective human-computer interaction**. [S.l.]: Pearson Education India, 2010.

SILVA TCHILIAN, Renan da; MORENO, Ubirajara Franco; NETTO, Mariana. Assisted Teleoperation for a Human-Swarm Interaction System. **IFAC-PapersOnLine**, Elsevier, v. 53, n. 5, p. 602–607, 2020.

SIMON, Haykin. **Neural networks: a comprehensive foundation**. [S.l.]: Prentice hall, 1999.

SIMON, Herbert A. Rational choice and the structure of the environment. **Psychological review**, American Psychological Association, v. 63, n. 2, p. 129, 1956.

SRIVASTAVA, Nitish *et al.* Dropout: a simple way to prevent neural networks from overfitting. **The journal of machine learning research**, JMLR. org, v. 15, n. 1, p. 1929–1958, 2014.

STEELS, L. Cooperation between distributed agents through self-organisation. *In*: INTELLIGENT Robots and Systems '90. 'Towards a New Frontier of Applications', Proceedings. IROS '90. IEEE International Workshop on. [S.l.: s.n.], jul. 1990. 8–14 supl. DOI: 10.1109/IROS.1990.262534.

STEINFELD, Aaron *et al.* Common metrics for human-robot interaction. *In*: PROCEEDINGS of the 1st ACM SIGCHI/SIGART conference on Human-robot interaction. [S.l.: s.n.], 2006. p. 33–40.

TAVARES, Augusto de Holanda BM *et al.* Dynamic leader allocation in multi-robot systems based on nonlinear model predictive control. **Journal of Intelligent & Robotic Systems**, Springer, v. 98, p. 359–376, 2020.

TIWARI, Rohan *et al.* Effect of Leader Placement on Robotic Swarm Control. *In*: AAMAS. [S.l.: s.n.], 2017. p. 1387–1394.

TRENTESAUX, Damien; MILLOT, Patrick. A human-centred design to break the myth of the “magic human” in intelligent manufacturing systems. *In*: SERVICE orientation in holonic and multi-agent manufacturing. [S.l.]: Springer, 2016. p. 103–113.

UEDA, Sayako; NAKASHIMA, Ryoichi; KUMADA, Takatsune. Influence of levels of automation on the sense of agency during continuous action. **Scientific reports**, Nature Publishing Group, v. 11, n. 1, p. 1–13, 2021.

VALERO, Yeltsin *et al.* Adaptation and calibration of a social force based model to study interactions between electric scooters and pedestrians. *In*: IEEE. 2020 IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC). [S.l.: s.n.], 2020. p. 1–7.

VERBERNE, Frank MF; HAM, Jaap; MIDDEN, Cees JH. Trust in smart systems: Sharing driving goals and giving information to increase trustworthiness and

acceptability of smart systems in cars. **Human factors**, Sage Publications Sage CA: Los Angeles, CA, v. 54, n. 5, p. 799–810, 2012.

WALKER, Phillip; AMRAI, Saman Amirpour; CHAKRABORTY, Nilanjan *et al.* Human control of robot swarms with dynamic leaders. *In*: IEEE. 2014 IEEE/RSJ International Conference on Intelligent Robots and Systems. [S.l.: s.n.], 2014. p. 1108–1113.

WALKER, Phillip; AMRAI, Saman Amirpour; LEWIS, Michael *et al.* Control of swarms with multiple leader agents. *In*: IEEE. 2014 IEEE International Conference on Systems, Man, and Cybernetics (SMC). [S.l.: s.n.], 2014. p. 3567–3572.

WALKER, Phillip; AMRAI, Saman Amirpour; LEWIS, Michael *et al.* Human control of leader-based swarms. *In*: IEEE. 2013 IEEE International Conference on Systems, Man, and Cybernetics. [S.l.: s.n.], 2013. p. 2712–2717.

WAMPLER, Jared *et al.* Towards adjustable autonomy for human-robot interaction in marine systems. *In*: IEEE. OCEANS 2017-Aberdeen. [S.l.: s.n.], 2017. p. 1–7.

WANG, Linna *et al.* Cooperative Control of Robotic Swarm Based on Self-organized Method and Human Swarm Interaction. *In*: IEEE. 2018 WRC Symposium on Advanced Robotics and Automation (WRC SARA). [S.l.: s.n.], 2018. p. 129–134.

WEGNER, Daniel M; WHEATLEY, Thalia. Apparent mental causation. **Moral Psychology: Historical and Contemporary Readings**, John Wiley & Sons, p. 264, 2010.

WEI, Hengyang *et al.* An experimental analysis of situation awareness for cockpit display interface evaluation based on flight simulation. **Chinese Journal of Aeronautics**, Elsevier, v. 26, n. 4, p. 884–889, 2013.

WEISS, Carmen; HERWIG, Arvid; SCHÜTZ-BOSBACH, Simone. The self in action effects: selective attenuation of self-generated sounds. **Cognition**, Elsevier, v. 121, n. 2, p. 207–218, 2011.

WIENER, Earl L. Cockpit automation. *In*: HUMAN factors in aviation. [S.l.]: Elsevier, 1988. p. 433–461.

WIENER, Earl L. Human factors of advanced technology (glass cockpit) transport aircraft, 1989.

XU, Shuting *et al.* Review of control models for human pilot behavior. **Annual Reviews in Control**, Elsevier, v. 44, p. 274–291, 2017.

YAN, Yan; ZHENMIN, Tang. Control Architecture for autonomous multi-robot system: Survey and Analysis. *In*: IEEE. INTELLIGENT Computation Technology and

Automation, 2009. ICICTA'09. Second International Conference on. [S.l.: s.n.], 2009. p. 376–379.

ZAYCHIK, Kirill; CARDULLO, Frank; GEORGE, Gary. A conspectus on operator modeling: past, present and future. *In*: AIAA modeling and simulation technologies conference and exhibit. [S.l.: s.n.], 2006. p. 6625.

Apêndices

APÊNDICE A – TREINAMENTO E VALIDAÇÃO DA LSTM

Obtenção de dados:

O pré-processamento de dados visa tornar os dados brutos disponíveis mais acessíveis às redes neurais. Isso inclui vetorização, normalização, manipulação de valores ausentes e extração de características.

Uma maneira comum de descrever um conjunto de dados é com uma matriz de dados. Uma matriz de dados é uma matriz que contém um exemplo diferente em cada linha. E cada coluna da matriz corresponde a uma característica diferente. Obviamente, para descrever um conjunto de dados como uma matriz de dados, deve ser possível descrever cada exemplo como um vetor, e cada um desses vetores deve ter o mesmo tamanho, mas nem sempre isto é possível. Em casos como esses, em vez de descrever o conjunto de dados como uma matriz com m linhas, descreve-se como um conjunto contendo m elementos, que implica que quaisquer dois vetores de exemplo não precisam ter o mesmo tamanho.

A obtenção de dados para o treinamento da RNN foi realizada selecionando-se seis voluntários, que realizaram um pré-treinamento de operação para se familiarizarem com a interface humano-robô. E por interface, refere-se a um dispositivo de entrada e saída que permite que um operador humano recupere/envie informações de/para um ou mais robôs ao mesmo tempo. A interface é constituída por uma parte física, capaz de registrar as ações humanas e fornecer um *feedback* sensorial ao humano, uma unidade de processamento e um módulo de comunicação.

Os participantes foram voluntários e receberam um breve questionário para preenchimento, perguntando idade, sexo, uso semanal médio do computador e gasto médio semanal jogando jogos de computador.

É importante que os exemplos de teste não sejam usados de forma alguma para fazer escolhas sobre o modelo, incluindo seus hiperparâmetros. Por esse motivo, nenhum exemplo do conjunto de testes foi utilizado no conjunto de validação. Portanto, construiu-se o conjunto de validação a partir dos dados de treinamento. Especificamente, dividimos os dados de treinamento em dois subconjuntos separados. Um desses subconjuntos é usado para aprender os parâmetros. O outro subconjunto é o conjunto de validação, usado para estimar o erro de generalização durante ou após o treinamento, permitindo que os hiperparâmetros sejam atualizados de acordo. O subconjunto de dados usado para aprender os parâmetros ainda é normalmente chamado de conjunto de treinamento, mesmo que isso possa ser confundido com o conjunto maior de dados usados para todo o processo de treinamento. O subconjunto de dados usado para orientar a seleção de hiperparâmetros é chamado de conjunto de validação. Sendo assim, como o conjunto de validação é usado para “treinar” os hiperparâmetros, o erro do conjunto de validação subestima o erro de generalização,

embora normalmente em uma quantidade menor do que o erro de treinamento. Após a conclusão de toda a otimização do hiperparâmetro, o erro de generalização é estimado usando o conjunto de testes.

Sendo assim, cada voluntário gerou dados de cinco tentativas bem sucedidas, que se entende por cumprir a tarefa de *rendezvous* com todos os agentes na linha ou dentro da região de interesse, sem ocorrer colisões e dentro de um período não maior que um minuto e trinta segundos. Sendo assim, todas as tentativas bem sucedidas geraram dados que foram utilizados para o treinamento e validação da rede neural. Ao total foram trinta simulações, sendo vinte e cinco para treinamento, dos quais trinta por cento foram separados para validação (um total de 772 dados) e os outros setenta por cento foram utilizados para treinamento (um total de 1542 dados). As cinco simulações restantes foram utilizadas para teste e avaliar o desempenho da rede.

Os dados gerados correspondem a posição no eixo x , posição no eixo y e orientação θ de todos os dez robôs que compõe o sistema. Esses fatores representam o vetor de entrada da RNN. E o vetor de saída é representado pelas entradas de controle, ou seja, velocidade linear e velocidade angular imposta pelo operador ao agente teleoperado através do dispositivo de entrada (*joystick*).

Ao todo foram realizadas trinta e seis simulações com operadores humanos, das quais 83% foram bem sucedidas e utilizadas para o treinamento da RNN. Os mesmos cenários foram repetidos com apenas agentes autônomos, semelhante ao apresentado nos cenários 2 e 3, que teve taxa de sucesso de 61%. Importante notar que a posição inicial dos agentes é definida de forma aleatória pelo algoritmo e, portanto, tem forte influência se ocorrerá consenso ou não, uma vez que a topologia é dinâmica e dependente da distância entre os agentes.

Treinamento e validação da RNN:

Neste trabalho, os métodos de RNN e DL, particularmente LSTMs, são estudados e empregados com o objetivo de aprender modelos de sistemas híbridos humano-*swarm* a partir de dados experimentais. A viabilidade de empregar RNN é estudada a princípio para aprender um modelo de comportamento em uma tarefa de *rendezvous* em um conjunto de dados simulado. Os modelos podem ser aprendidos para previsões, recuperando assim previsões em determinados intervalos de tempo. Sendo assim, este trabalho incorpora a capacidade das RNNs em aprender dinâmicas não modeladas de um sistema humano-*swarm* pela primeira vez, de acordo com o nosso conhecimento, e que pode servir como base para o desenvolvimento futuro e aplicação de métodos de ML em modelagem e controle de sistemas de IHS.

Importante notar que no ML são assumidas duas hipóteses fortes

- i. as saídas podem ser previstas, conhecendo-se as entradas.
- ii. dados disponíveis são suficientemente informativos para aprender o relaciona-

mento entre entradas e saídas.

Então a questão fundamental no ML é a tensão no treinamento entre otimização e generalização. Otimização refere-se ao processo de ajustar o modelo para obter o melhor desempenho possível nos dados de treinamento (o aprendizado em ML), enquanto generalização refere-se ao desempenho do modelo treinado em dados nunca antes vistos. Esses dois fatores correspondem aos dois desafios centrais do ML: sub-ajuste e sobre-ajuste. Sub-ajuste ocorre quando o modelo não é capaz de obter um valor de erro suficientemente baixo no conjunto de treinamento. O sobre-ajuste ocorre quando a diferença entre o erro de treinamento e o erro de teste é muito grande.

No início do treinamento, a otimização e a generalização estão correlacionadas: quanto menor a função de perda no treinamento, menor a função de perda no teste. Enquanto isso está acontecendo, o modelo é considerado sub-ajustado: ainda há progresso a ser feito; a rede ainda não modelou todos os padrões relevantes nos dados de treinamento. Porém, após um certo número de iterações nos dados de treinamento, a generalização para de melhorar e as métricas de validação param e começam a se degradar: o modelo está começando a se sobre-ajustar. Ou seja, está começando a aprender padrões específicos dos dados de treinamento, mas enganosos ou irrelevantes quando se trata de novos dados.

Outros fatores essenciais no ML é a otimização rivalizando em importância com a regularização, que é qualquer modificação que se faz no algoritmo que visa reduzir seu erro de generalização, mas não seu erro de treinamento.

O *dropout* é uma das técnicas de regularização mais eficazes e mais usadas para redes neurais, desenvolvida por (SRIVASTAVA *et al.*, 2014). *Dropout*, aplicado a uma camada, consiste em eliminar aleatoriamente (definindo como zero) uma série de saídas da camada durante o treinamento. A taxa de *dropout* é a fração das saídas que são zeradas; geralmente definida entre 0,2 e 0,5. Mas como aplicar corretamente o *dropout* em redes recorrentes não é uma questão trivial. Sabe-se há muito tempo que a aplicação de *dropout* antes de uma camada recorrente dificulta o aprendizado, em vez de ajudar na regularização. (GAL, 2016) determinou a maneira correta de usar o *dropout* com uma rede recorrente: a mesma máscara de *dropout* (o mesmo padrão de unidades descartadas) deve ser aplicada a cada passo do tempo ao invés de uma máscara de *dropout* que varia aleatoriamente a cada passo no tempo. Além disso, para regularizar as representações formadas pelos portões recorrentes de camadas como LSTM, uma máscara de *dropout* temporariamente constante deve ser aplicada às ativações recorrentes internas da camada. O uso da mesma máscara de *dropout* a cada passo do tempo permite que a rede propague adequadamente seu erro de aprendizado ao longo do tempo; uma máscara de *dropout* temporariamente aleatória interromperia esse sinal de erro e seria prejudicial ao processo de aprendizado.

Uma vez obtidos os dados de simulação no formato *bag* que representa o

formato de armazenamento de mensagens de tópicos no ROS, estes foram convertidos para o formato *.csv* e pré-processados. Na etapa de pré-processamento primeiramente se fez uma verificação por inconsistências no banco de dados como variáveis sem valor como ("NaN" ou "None"). Em seguida foram descartados os últimos dois segundos de simulação que correspondem ao tempo necessário entre o fim da tarefa e o término da execução do programa e, por consequência, da gravação das mensagens por último enviadas que representam ação nenhuma. Finalmente, após esta etapa preliminar todos os dados foram concatenados e normalizados.

Uma vez tratados os dados, estes foram inseridos na RNN que possui a estrutura apresentada na Figura 56.

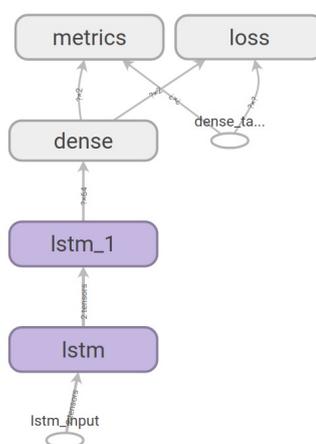


Figura 56 – Estrutura das RNN com duas camadas de LSTM.

Na Figura 56 a camada *dense* indica uma camada densa, também chamada de camada totalmente conectada, que é uma camada usada nos estágios finais da rede neural. Essa camada ajuda a alterar a dimensionalidade da saída da camada anterior para que o modelo possa definir facilmente a relação entre os valores dos dados nos quais o modelo está trabalhando; *loss* indica para a rede neural uma função de perda para o processo de otimização a fim de calcular o erro do modelo e a camada *metrics* é utilizada para monitorar e medir o desempenho do modelo (durante o treinamento e o teste).

Na análise da RNN frequentemente medimos a precisão do modelo que indica a proporção de exemplos para os quais o modelo produz a saída correta. Também podemos obter informações equivalentes medindo a taxa de erro, a proporção de exemplos para os quais o modelo produz uma saída incorreta. Foram realizados testes com seis configurações de RNN para ajuste dos hiperparâmetros e cinquenta épocas de treinamento para cada uma das configurações para ajuste dos pesos. Na Figura 57 são apresentados a acurácia nos dados de validação de cada configuração.

Ao todo foram variados o número de células entre 8,16 e 32 e cada uma dessas

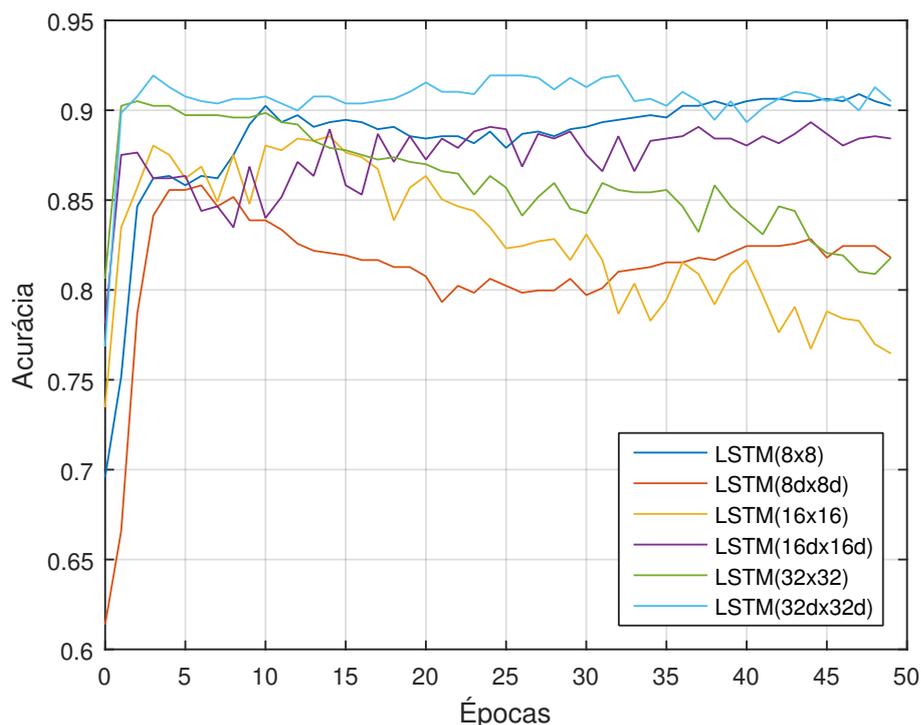


Figura 57 – Configurações de hiperparâmetros de seis tipos para a estrutura do LSTM para validação da acurácia.

configurações foi repetida com técnica de regularização de *dropout*, com valor de 0,2 para tentar evitar sobre-ajuste. Como pode-se observar pelo gráfico as piores configurações são representadas pelas linhas amarela (16×16), vermelha (8×8 com *dropout*) e verde (32×32). E as três melhores foram as representadas pela linha roxa (16×16 com *dropout*), azul escuro (8×8) e azul claro (32×32 com *dropout*) ao final das cinquenta épocas.

Pode-se observar também que o treinamento após quatro épocas se torna estável ou começa a degradar, uma indicação de sobre-ajuste. E, portanto, um treinamento de quatro épocas é o suficiente para ajustar os pesos da LSTM, que torna a linha verde (32×32) e a linha azul claro (32×32 com *dropout*) as melhores escolhas, com preferência para a linha azul claro que não apresentou degradação durante o treinamento devido a regularização por *dropout*.

Como pode-se verificar nas Tabelas 4 e 5 as células em branco são as que apresentaram melhor resultado quando comparado com o outro cenário e as células em cinza exatamente o oposto. As Tabelas 4 e 5 apresentam os dados obtidos para vinte e cinco simulações bem-sucedidas, nas quais os operadores foram capazes de realizar a tarefa de rendezvous sem colisões com todos os robôs dentro da área desejada ao redor do agente teleoperado, para dois cenários diferentes com e sem o suporte a teleoperação.

Tabela 4. Comparação entre o sistema com teleoperação pura e com suporte.

Tipo	Teleoperado sem suporte			Teleoperado com suporte		
	tempo (s)	$\ v\ _1 (\frac{m}{s})$	$\ \omega\ _1 (\frac{rad}{s})$	tempo (s)	$\ v\ _1 (\frac{m}{s})$	$\ \omega\ _1 (\frac{rad}{s})$
Teste 1	15,10	149,69	86,77	9,90	90,72	80,69
Teste 2	8,80	114,32	29,38	11,50	117,00	37,44
Teste 3	6,30	65,13	23,92	8,10	69,69	64,46
Teste 4	11,80	151,29	61,04	10,40	106,00	42,80
Teste 5	16,00	181,46	75,67	16,70	130,99	137,75
Teste 6	5,60	81,06	53,31	6,30	58,00	35,27
Teste 7	7,20	74,43	16,66	6,50	48,06	54,31
Teste 8	8,60	108,52	39,41	8,30	79,40	57,21
Teste 9	9,20	111,38	61,22	8,30	78,98	52,55
Teste 10	7,20	106,99	31,55	6,40	64,00	27,31
Teste 11	9,60	122,19	51,34	8,20	80,00	30,95
Teste 12	8,80	99,37	35,87	7,50	73,00	36,34
Teste 13	14,60	170,58	54,48	7,40	70,54	29,74
Teste 14	9,30	104,01	38,06	7,20	66,92	35,03
Teste 15	22,80	219,97	57,89	15,80	134,38	66,89
Teste 16	11,30	146,42	63,64	9,00	77,37	88,00
Teste 17	7,70	76,88	24,72	5,80	47,05	33,47
Teste 18	11,30	134,47	40,97	7,60	73,00	44,25
Teste 19	9,60	104,01	35,38	8,10	64,29	67,02
Teste 20	14,00	184,09	89,59	8,40	80,00	55,25
Teste 21	6,40	70,56	43,69	9,70	86,71	64,54
Teste 22	6,30	59,71	26,97	7,80	76,00	39,66
Teste 23	7,90	84,23	40,90	8,30	78,52	58,81
Teste 24	8,40	111,81	100,76	9,90	92,45	68,08
Teste 25	6,90	89,47	61,29	9,00	68,10	40,35

Legenda: A célula sombreada é o caso com pior desempenho quando comparado entre sistema com e sem teleoperação.

Tabela 5. Comparação entre o sistema com teleoperação pura e com suporte.

Tipo	Teleoperação sem Suporte			Teleoperação com Suporte		
	tempo (s)	$\ v\ _1$ ($\frac{m}{s}$)	$\ \omega\ _1$ ($\frac{rad}{s}$)	tempo (s)	$\ v\ _1$ ($\frac{m}{s}$)	$\ \omega\ _1$ ($\frac{rad}{s}$)
Test 1	18.16	182.83	107.27	11.14	134.43	113.57
Test 2	11.34	137.81	37.73	13.70	173.13	52.49
Test 3	7.87	84.08	29.44	9.05	97.99	96.24
Test 4	14.34	186.03	75.62	11.53	158.52	60.37
Test 5	19.23	219.41	93.54	19.76	188.35	200.15
Test 6	6.86	99.08	67.48	7.25	86.16	52.21
Test 7	9.08	94.71	20.50	7.18	72.07	77.48
Test 8	10.42	134.20	50.97	9.73	118.38	84.34
Test 9	11.89	136.44	75.11	9.25	111.89	76.80
Test 10	8.70	135.03	39.44	7.15	89.88	39.92
Test 11	12.26	151.15	63.89	9.78	114.83	46.03
Test 12	11.00	124.61	45.91	8.53	109.18	52.75
Test 13	18.69	208.15	69.56	8.20	102.52	43.31
Test 14	11.51	131.03	46.16	7.98	100.10	52.52
Test 15	27.93	270.58	73.29	18.74	196.17	96.82
Test 16	14.34	176.84	80.84	10.29	108.55	123.99
Test 17	9.96	95.85	30.31	6.76	70.34	48.10
Test 18	14.46	168.55	49.67	8.38	107.57	66.24
Test 19	11.91	132.38	45.66	9.47	90.67	100.32
Test 20	17.70	221.63	110.93	9.59	114.43	81.29
Test 21	8.20	88.30	56.43	10.77	128.96	94.88
Test 22	7.81	73.42	33.56	9.07	108.01	57.64
Test 23	10.22	104.51	52.58	9.89	115.10	84.34
Test 24	10.40	136.86	129.04	11.07	133.64	98.00
Test 25	8.77	113.32	77.58	10.70	96.43	58.08

Legenda: A célula sombreada é o caso com pior desempenho quando comparado entre sistema com e sem teleoperação.

APÊNDICE B – ARQUITETURA DO ROBOT OPERATING SYSTEM (ROS)

Os conceitos fundamentais da implementação do ROS são nós, mensagens, tópicos e serviços. Nós são processos executáveis. O ROS foi projetado para ser modular em uma escala refinada: um sistema geralmente é composto por muitos nós. Nesse contexto, o termo “nó” é intercambiável com “módulo de software”. O uso do termo “nó” decorre de visualizações de sistemas baseados em ROS em tempo de execução: quando muitos nós estão em execução, é conveniente renderizar o ponto a ponto das comunicações entre pares como um grafo, com processos como nós de grafos e as conexões ponto a ponto como arestas.

Um nó envia uma mensagem publicando-a em um determinado tópico. Um nó interessado em um determinado tipo de dados se inscreverá no tópico apropriado. Pode haver vários editores e assinantes simultâneos para um único tópico, e um único nó pode publicar e/ou assinar vários tópicos. Em geral, editores e assinantes não estão cientes da existência um do outro.

