



**ARQUITETURA FUNCIONAL DE VEÍCULOS AUTÔNOMOS: UMA
PROPOSIÇÃO DE TÉCNICAS PARA DETECÇÃO DE OBJETOS,
LOCALIZAÇÃO E INTERAÇÃO HUMANO-VEÍCULO**

GIOVANNI ALMEIDA SANTOS

**TESE DE DOUTORADO EM ENGENHARIA ELÉTRICA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

**FACULDADE DE TECNOLOGIA
UNIVERSIDADE DE BRASÍLIA**

**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

**FUNCTIONAL ARCHITECTURE FOR AUTONOMOUS DRIVING: A
PROPOSITION OF TECHNIQUES FOR OBJECT DETECTION,
LOCALIZATION AND HUMAN-VEHICLE INTERACTION**

**ARQUITETURA FUNCIONAL DE VEÍCULOS AUTÔNOMOS: UMA
PROPOSIÇÃO DE TÉCNICAS PARA DETECÇÃO DE OBJETOS,
LOCALIZAÇÃO E INTERAÇÃO HUMANO-VEÍCULO**

GIOVANNI ALMEIDA SANTOS

**ORIENTADOR: JOÃO PAULO JAVIDI DA COSTA, PROF. DR.-ING.
COORIENTADOR: RAFAEL TIMÓTEO DE SOUSA JÚNIOR, PROF. DR.**

TESE DE DOUTORADO EM ENGENHARIA ELÉTRICA

PUBLICAÇÃO: PPGEE.TD-186/22

BRASÍLIA/DF: JUNHO - 2022

**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

**ARQUITETURA FUNCIONAL DE VEÍCULOS AUTÔNOMOS: UMA
PROPOSIÇÃO DE TÉCNICAS PARA DETECÇÃO DE OBJETOS,
LOCALIZAÇÃO E INTERAÇÃO HUMANO-VEÍCULO**

GIOVANNI ALMEIDA SANTOS

**TESE DE DOUTORADO SUBMETIDA AO DEPARTAMENTO DE ENGENHARIA ELÉTRICA
DA FACULDADE DE TECNOLOGIA DA UNIVERSIDADE DE BRASÍLIA COMO PARTE DOS
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR.**

APROVADA POR:

**Prof. Dr. Rafael Timóteo de Sousa Júnior – ENE/UnB
Presidente**

**Prof. Dr. José Alfredo Ruiz Vargas – ENE/UnB
Examinador Interno**

**Prof. Dr. Edison Pignaton de Freitas – UFRGS
Examinador Externo**

**Dr. Marco Antonio Marques Marinho – Svep Design Center
Examinador Externo**

BRASÍLIA, 30 DE JUNHO DE 2022.

FICHA CATALOGRÁFICA

SANTOS, GIOVANNI A.

Arquitetura Funcional de Veículos Autônomos: Uma Proposição de Técnicas para Detecção de Objetos, Localização e Interação Humano-Veículo [Distrito Federal] 2022.

xviii, 97p., 210 x 297 mm (ENE/FT/UnB, Doutor, Engenharia Elétrica, 2022).

Tese de Doutorado – Universidade de Brasília, Faculdade de Tecnologia.

Departamento de Engenharia Elétrica

1. Veículos Autônomos

2. Localização

3. Detecção de Objetos

4. Assistente Virtual

I. ENE/FT/UnB

II. Título (série)

REFERÊNCIA BIBLIOGRÁFICA

SANTOS, G. A. (2022). Arquitetura Funcional de Veículos Autônomos: Uma Proposição de Técnicas para Detecção de Objetos, Localização e Interação Humano-Veículo. Tese de Doutorado em Engenharia Elétrica, Publicação PPGEE.TD-186/22, Departamento de Engenharia Elétrica, Universidade de Brasília, Brasília, DF, 97p.

CESSÃO DE DIREITOS

AUTOR: Giovanni Almeida Santos

TÍTULO: Arquitetura Funcional de Veículos Autônomos: Uma Proposição de Técnicas para Detecção de Objetos, Localização e Interação Humano-Veículo.

GRAU: Doutor ANO: 2022

É concedida à Universidade de Brasília permissão para reproduzir cópias desta tese de doutorado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte dessa tese de doutorado pode ser reproduzida sem autorização por escrito do autor.

Giovanni Almeida Santos

Rua das Paineiras Lote 4 Torre II Apto 1303

Águas Claras - Brasília/DF - Brasil

CEP 71918-000

Aos meus pais, Antonio e Carminha.

AGRADECIMENTOS

Agradeço ao meu orientador, Prof Dr.-Ing. João Paulo Javidi da Costa, pela confiança depositada em mim e por seu inestimável apoio ao longo desta jornada. Sinto-me muito honrado e orgulhoso de tê-lo como orientador. Sua disponibilidade para discutirmos e debatermos sobre os diversos temas ligados à área de veículos autônomos foi fundamental para o resultado deste trabalho.

Agradeço ao meu coorientador, Prof Dr. Rafael Timóteo de Sousa Júnior, pela valiosa contribuição a este trabalho. Sou muito grato pelas nossas conversas e por ter o privilégio de compartilhar de sua experiência.

Agradeço aos meus orientandos de iniciação científica, Geovana Silva e Guilherme Andrade, pela grande parceria que tivemos ao longo dos últimos quatro anos. Tenham certeza que aprendi muito com vocês.

Meus sinceros agradecimentos a Bruno Dantas, Bruno Praciano, Edna Canedo, Elias Magalhães, Fábio Mendonça, Fernando Cruz, Francisco Molina, Gabriel Pinheiro, Gokulesh Danapal, Iure Brandão e Vandor Rissoli.

Um agradecimento especial para minha companheira, Leonara Rocha, e nossa linda filha, Letícia Almeida, fonte de nossa perseverança e inspiração.

Agradeço o apoio técnico e computacional do Laboratório de Tecnologias para Tomada de Decisão - LATITUDE, da Universidade de Brasília, que conta com apoio do CNPq - Conselho Nacional de Desenvolvimento Científico e Tecnológico (Outorgas 312180/2019-5 PQ-2 e 465741/2014-2 INCT em Cibersegurança), do Ministério da Economia (Outorgas 005/2016 DIPLA e 083/2016 ENAP), do Conselho Administrativo de Defesa Econômica (Outorga CADE 08700.000047/2019-14), da Advocacia Geral da União (Outorga AGU 697.935/2019), do Departamento Nacional de Auditoria do SUS (Outorga DENASUS 23106.118410/2020-85), da Procuradoria Geral da Fazenda Nacional (Outorga PGFN 23106.148934/2019-67) e dos Decanatos de Pesquisa e Inovação e de Pós-Graduação da Universidade de Brasília (Outorga 7129 FUB/EMENDA/DPI/COPEI/AMORIS).

RESUMO

Título: Arquitetura Funcional de Veículos Autônomos: Uma Proposição de Técnicas para Detecção de Objetos, Localização e Interação Humano-Veículo

Autor: Giovanni Almeida Santos

Orientador: João Paulo Javidi da Costa, Prof. Dr.-Ing.

Coorientador: Rafael Timóteo de Sousa Júnior, Prof. Dr.

Programa de Pós-Graduação em Engenharia Elétrica

Brasília, 30 de junho de 2022

Milhões de pessoas são vítimas de acidentes de trânsito no mundo a cada ano. A grande maioria desses acidentes é causada essencialmente por falhas humanas, as quais envolvem excesso de velocidade, utilização de celular enquanto dirige, consumo de bebidas alcoólicas, entre outros fatores. O uso de veículos autônomos, portanto, ao diminuir ou até mesmo eliminar a necessidade de intervenção humana, tem a possibilidade de tornar o trânsito mais seguro e, conseqüentemente, reduzir o número de acidentes e de vítimas. No entanto, ainda há muitos desafios a serem superados para que seja possível ter veículos autônomos circulando efetivamente nas vias urbanas. Nesse sentido, a presente tese de doutorado busca propor soluções que possam ser aplicadas no contexto de veículos autônomos. Três aspectos são abordados nesta pesquisa: fusão de dados de sensores para detecção de objetos, estimação de localização de veículos autônomos e concepção de novos modelos de negócio vinculados ao uso de veículos autônomos. Com relação à detecção de objetos, o principal foco de estudo neste trabalho está relacionado à detecção de veículos e pedestres. No primeiro caso, é proposta uma técnica de fusão de dados brutos de câmera e *Light Detection And Ranging* (LiDAR). No segundo caso, o intuito é buscar e analisar técnicas que possam detectar, de forma confiável, pedestres que estejam obstruídos por outros objetos, fato esse bastante comum quando se tem um veículo trafegando em um cenário urbano. Com relação à localização, a utilização de receptores de sinais de satélite baseados em arranjo de antenas e técnicas tensoriais mostra-se como uma alternativa promissora para mitigar os efeitos de multipercursos e, conseqüentemente, minimizar os erros de posicionamento do veículo. Com relação a novos modelos de negócio envolvendo veículos autônomos, é proposta uma arquitetura de um assistente virtual a ser implantado nos veículos com o intuito de facilitar a interação humano-máquina. Essa arquitetura também descreve as integrações entre o assistente virtual e serviços internos e externos ao veículo. Além disso, também é descrito um processo voltado para o desenvolvimento e evolução da base de conhecimento desse assistente.

Palavras-chave: Veículos Autônomos, Localização, Detecção de Objetos, Assistente Virtual.

ABSTRACT

Title: Functional Architecture for Autonomous Driving: A Proposition of Techniques for Object Detection, Localization and Human-Vehicle Interaction

Author: Giovanni Almeida Santos

Supervisor: João Paulo Javidi da Costa, Prof. Dr.-Ing.

Co-Supervisor: Rafael Timóteo de Sousa Júnior, Prof. Dr.

Post-Graduate Program in Electrical Engineering

Brasília, Jun 30th, 2022

Millions of people are victims of traffic accidents in the world every year. The vast majority of these accidents are essentially caused by human errors, which involve speeding, cell phone use while driving, consumption of alcoholic beverages, among other factors. The use of autonomous vehicles, therefore, by reducing or even eliminating the need for human intervention, has the possibility of making traffic safer and, consequently, reducing the number of accidents and victims. However, there are still many challenges to be overcome in order to have autonomous vehicles operating effectively on urban roads. In this sense, the present doctoral thesis seeks to propose solutions that can be applied in the context of autonomous vehicles. Three aspects are addressed in this research: fusion of sensor data for object detection, positioning estimation and conception of new business models linked to the use of autonomous vehicles. Regarding to the object detection, the main focus is related to the detection of vehicles and pedestrians. In the first case, a technique for fusing raw data from camera and Light Detection And Ranging (LiDAR) is proposed. In the second case, the aim is to seek and analyze techniques that can reliably detect pedestrians who are obstructed by other objects, a fact that is quite common in an urban scenario. Regarding location, the use of satellite signal receivers based on antenna array and tensor techniques is shown to be a promising alternative to mitigate the effects of multipath and, consequently, minimize vehicle positioning errors. Regarding new business models involving autonomous vehicles, an architecture of a virtual assistant is proposed to be implemented in vehicles in order to facilitate human-machine interaction. This architecture also describes the integrations between the virtual assistant and services inside and outside the vehicle. In addition, a process aimed at developing and evolving the knowledge base of this assistant is also described.

Keywords: Autonomous Vehicles, Localization, Object Detection, Virtual Assistant.

SUMÁRIO

1	INTRODUÇÃO	1
1.1	MOTIVAÇÃO	4
1.2	OBJETIVOS	5
1.3	METODOLOGIA	5
1.3.1	CARACTERIZAÇÃO DA PESQUISA	5
1.3.2	FASES DA PESQUISA	6
1.4	CONTRIBUIÇÕES DO TRABALHO	7
1.5	PUBLICAÇÕES VINCULADAS AO TRABALHO	7
1.6	ORGANIZAÇÃO DO TRABALHO	10
2	CONCEITOS E FUNDAMENTAÇÃO	12
2.1	SENSORES E AUTOMAÇÃO DE VEÍCULOS	12
2.2	FUSÃO DE SENSORES	16
2.3	SISTEMAS DE NAVEGAÇÃO VIA SATÉLITE	18
2.3.1	POSICIONAMENTO VIA GNSS	20
2.3.2	ERROS E INTERFERÊNCIAS EM SINAIS DE GNSS	22
2.4	SISTEMA DE NAVEGAÇÃO INERCIAL	24
2.5	MAPAS DE ALTA DEFINIÇÃO	26
2.5.1	NAVIGATION DATA STANDARD (NDS)	28
2.5.2	OPENDRIVE	30
2.5.3	LANELET2	30
2.5.4	MAPAS DINÂMICOS	33
3	ESTIMAÇÃO DE LOCALIZAÇÃO PARA VEÍCULOS AUTÔNOMOS USANDO RECEPTORES DE GNSS BASEADOS EM ARRANJO DE AN- TENAS E TÉCNICAS TENSORIAIS	35
3.1	TÉCNICAS TENSORIAIS PARA MITIGAÇÃO DE INTERFERÊNCIAS DE MUL- TIPERCURSO	35
3.2	ESTIMAÇÃO DE ESTADO E FILTRO DE KALMAN ESTENDIDO	44
3.3	ESTIMAÇÃO DO ERRO DE POSICIONAMENTO DE UM VEÍCULO	48
4	DETECÇÃO DE OBJETOS EM VEÍCULOS AUTÔNOMOS	56
4.1	FUSÃO DE DADOS BRUTOS DE LIDAR E CÂMERA PARA DETECÇÃO DE VEÍCULOS	56
4.2	DETECÇÃO DE PEDESTRES PARCIALMENTE OBSTRUÍDOS	62

5	UMA PROPOSTA ORIENTADA A DIÁLOGO PARA INTERAÇÃO COM VEÍCULOS AUTÔNOMOS.....	66
5.1	TENDÊNCIAS DISRUPTIVAS DO SETOR AUTOMOTIVO.....	66
5.2	MODELOS DE NEGÓCIO ENVOLVENDO VEÍCULOS AUTÔNOMOS	69
5.3	PROPOSTA DE SISTEMA DE INTERAÇÃO ENTRE HUMANO E VEÍCULO AUTÔNOMO	72
5.3.1	MÓDULOS PROPOSTOS PARA O VEÍCULO	73
5.3.1.1	ASSISTENTE VIRTUAL	73
5.3.1.2	INTEGRAÇÃO COM SERVIÇOS DE BORDO	75
5.3.1.3	INTEGRAÇÃO COM SERVIÇOS EXTERNOS	75
5.3.1.4	<i>Business Intelligence</i>	77
5.3.2	MÓDULOS PROPOSTOS PARA A INFRAESTRUTURA DE DESENVOLVIMENTO E OPERAÇÃO.....	78
5.4	PROCESSO DE GERENCIAMENTO DE CONTEÚDO DO <i>Chatbot</i>	80
5.5	PROPOSTA DE DIÁLOGOS	81
6	CONCLUSÕES E RECOMENDAÇÕES.....	86
6.1	CONCLUSÕES GERAIS	86
6.2	RECOMENDAÇÕES PARA TRABALHOS FUTUROS.....	88
	REFERÊNCIAS BIBLIOGRÁFICAS.....	88

LISTA DE FIGURAS

2.1	Representação de alto nível de um sensor inteligente	12
2.2	Exemplo de Configuração de Sensores em um Veículo Autônomo	14
2.3	Arquitetura de fusão de baixo nível	16
2.4	Arquitetura de fusão de nível intermediário	17
2.5	Arquitetura de fusão de alto nível	17
2.6	Arquitetura geral de sistemas GNSS.....	19
2.7	Subfaixas de frequências dos sistemas de GNSS com cobertura global	21
2.8	Exemplos de interferências na propagação dos sinais de satélite	23
2.9	Acoplamento fraco em GNSS/INS	25
2.10	Acoplamento forte em GNSS/INS	26
2.11	Acoplamento profundo em GNSS/INS	26
2.12	Representação de faixas virtuais em um cruzamento	28
2.13	Visão geral da estrutura de dados do NDS	29
2.14	<i>Building blocks</i> do NDS para <i>HD Maps</i>	30
2.15	Exemplo de código no OpenDRIVE.....	31
2.16	Visualização de elementos do <i>Lanelet2</i> na ferramenta JOSM	32
2.17	Visualização de elementos do <i>Lanelet2</i> e indicação do que eles representam ...	32
2.18	Representação das camadas de um Mapa Dinâmico	34
3.1	RMSE da estimação do atraso de tempo do sinal LOS. Comparação envolvendo as técnicas HOSVD, HOSVD+FBA, HOSVD+SPS, HOSVD+ESPS, HOSVD+FBA+SPS, MA e MA+FBA+SPS.....	39
3.2	RMSE da estimação do atraso de tempo do sinal LOS para um arranjo de antenas sem erros. Comparação envolvendo as técnicas HOSVD+FBA+ESPS, DoA/KRF+FBA+SPS e CPD-GEVD	40
3.3	RMSE da estimação do atraso de tempo do sinal LOS para um arranjo de antena com erro em sua geometria. Comparação envolvendo as técnicas HOSVD+FBA+ESPS, DoA/KRF+FBA+SPS e CPD-GEVD	40
3.4	RMSE da estimação do atraso de tempo do sinal LOS. Comparação envolvendo as técnicas HOSVD+FBA+ESPS, DoA/KRF+FBA+SPS e ProKRaft ...	41
3.5	RMSE da estimação do atraso de tempo do sinal LOS. Comparação envolvendo a técnica CPD-GEVD em sinais de GPS de segunda e terceira gerações	42
3.6	RMSE da estimação do atraso de tempo do sinal LOS. Comparação envolvendo a técnica HOSVD+FBA+ESPS em sinais de GPS de segunda e terceira gerações	42

3.7	RMSE da estimação do atraso de tempo do sinal LOS. Comparação envolvendo as técnicas HOSVD+FBA+ESPS e CPD-GEVD em sinais de GPS de segunda geração	43
3.8	RMSE da estimação do atraso de tempo do sinal LOS. Comparação envolvendo as técnicas HOSVD+FBA+ESPS e CPD-GEVD em sinais de GPS de terceira geração	44
3.9	Visão Geral do Filtro de Kalman Estendido	47
3.10	Receptor GNSS do veículo recebendo os componentes LOS and NLOS de uma transmissão via satélite	49
3.11	Cenário de simulação com veículo se deslocando do ponto A para o ponto B. A simulação considera um ponto de referência capaz de refletir os sinais transmitidos pelos satélites	50
3.12	RMSE da estimação do atraso de tempo. Abordagens utilizadas na simulação: receptor GNSS padrão com 1 antena e 1 época, receptor GNSS com 1 antena e K épocas, filtragem bidimensional com abordagem matricial com M antenas e K épocas, e abordagem tensorial com M antenas e K épocas	53
3.13	Erro de posicionamento adicionado ao receptor de GPS devido ao componente NLOS. Abordagens utilizadas na simulação: receptor GNSS padrão com 1 antena e 1 época, receptor GNSS com 1 antena e K épocas, filtragem bidimensional com abordagem matricial com M antenas e K épocas, e abordagem tensorial com M antenas e K épocas	54
3.14	Erro estimado pelo EKF para o posicionamento do veículo. Abordagens utilizadas na simulação: receptor GNSS padrão com 1 antena e 1 época, receptor GNSS com 1 antena e K épocas, filtragem bidimensional com abordagem matricial com M antenas e K épocas, e abordagem tensorial com M antenas e K épocas	55
4.1	Diagrama de blocos do método de fusão de dados brutos de LiDAR e câmera .	57
4.2	Esquema de configuração de sensores no veículo do projeto <i>KITTI</i>	59
4.3	Projeção de pontos do LiDAR no sistema de coordenadas de uma imagem (a) e os correspondentes mapas de refletância (b) e de profundidade (c)	60
4.4	Canais utilizados no método de fusão de dados de LiDAR e câmera.....	60
4.5	Valores de mAP dos três modelos analisados.....	62
4.6	Exemplo de imagem com pedestres parcialmente obstruídos	63
4.7	Diagrama de blocos do framework de treinamento e validação do modelo proposto para detecção de pedestres	65
5.1	Visão Geral de uma Arquitetura de Software para o Contexto Automotivo.....	69
5.2	Ecossistema de Negócio de MaaS.....	70
5.3	Ecossistema de MaaS envolvendo veículos autônomos	71

5.4	Sinergia entre os setores de Mobilidade, Automotivo e Produção de Conteúdo	72
5.5	Arquitetura Proposta para o Sistema de Interação entre Humano e Veículo Autônomo	74
5.6	Visão Geral da Arquitetura para Disponibilização de Serviços	76
5.7	Arquitetura Proposta para o Envio e Processamento de Dados dos Diálogos ...	78
5.8	Método Proposto para o Processo de Gerenciamento do Conteúdo de <i>Chatbot</i>	80

LISTA DE TABELAS

1.1	Síntese da Caracterização da Pesquisa	6
2.1	Sistemas de GNSS com cobertura global.....	18
2.2	Métodos de acesso e subfaixas de frequência dos sistemas de GNSS com cobertura global.....	20
3.1	Parâmetros das Simulações para Estimação de Atraso de Tempo de Sinal LOS	38
3.2	RMSE do dispositivo de referência	55
4.1	Resultados da detecção de veículos nos modelos analisados	61
4.2	Valores das métricas <i>Precision</i> e <i>Recall</i> dos três modelos analisados	62
4.3	Valores das métricas <i>Acurácia</i> , <i>Precision</i> , <i>Recall</i> e <i>F1 Score</i> para os datasets PSU e INRIA	65
5.1	Módulos funcionais para agrupamento dos diálogos da <i>Plataforma Conver-</i> <i>sacional</i>	83
5.2	Diálogos propostos para o módulo funcional de Infoentretenimento	83
5.3	Diálogos propostos para o módulo funcional de Configuração de Bordo.....	84
5.4	Diálogos propostos para o módulo funcional de Navegação	85
5.5	Diálogos propostos para o módulo funcional de Comunicação	85

LISTA DE SÍMBOLOS

Símbolos latinos

\hat{x}_0	Estimativa do estado inicial de um objeto
I	Matriz identidade
J	Matriz Jacobiana
K	Ganho de Kalman
P_0	Matriz de covariância do estado inicial do objeto
Q	Matriz de covariância do ruído do processo
R	Matriz de covariância do ruído da medição
u	Vetor de entradas de controle do sistema
v	Vetor de ruído das medições
w	Vetor de ruído do processo
x	Vetor de estado de um objeto
z	Vetor de medições realizadas
<i>c</i>	Velocidade da luz
<i>x</i>	Posição do objeto no eixo x no sistema de coordenadas cartesianas
<i>y</i>	Posição do objeto no eixo y no sistema de coordenadas cartesianas
<i>z</i>	Posição do objeto no eixo z no sistema de coordenadas cartesianas

LISTA DE ACRÔNIMOS E ABREVIACÕES

ADAS	Sistemas Avançados de Assistência ao Motorista – <i>Advanced Driver Assistance Systems</i> . 14, 27, 29, 62, 82
ASR	Reconhecimento Automático de Fala – <i>Automatic Speech Recognition</i> . 74
AUTOSAR	<i>AUTomotive Open System ARchitecture</i> . 68
BDS-3	<i>BeiDou Navigation Satellite System</i> . 18–20
C/A	<i>Coarse Acquisition</i> . 38, 42, 52
CDMA	Acesso Múltiplo por Divisão de Código – <i>Code-Division Multiple Access</i> . 19, 20
CPD-GEVD	<i>Canonical Polyadic Decomposition by a Generalized Eigenvalue Decomposition</i> . 38, 39, 41–44, 88
DARPA	<i>Defense Advanced Research Projects Agency</i> . 1
DGPS	<i>Differential Global Positioning System</i> . 55
DoA/KRF	<i>Direction of Arrival and Khatri-Rao Factorization</i> . 39, 41, 43
ECEF	<i>Earth-Centered, Earth-Fixed</i> . 22
ECU	Unidade de Controle Eletrônico – <i>Electronic Control Unit</i> . 67, 68
EKF	<i>Extended Kalman Filter</i> . xi, 45, 46, 49, 51, 53–55, 88
ESPS	<i>Expanded Spatial Smoothing</i> . 38, 39, 41–43, 52
FBA	<i>Forward-Backward Averaging</i> . 38, 39, 41–43, 52
FDMA	Acesso Múltiplo por Divisão de Frequência – <i>Frequency-Division Multiple Access</i> . 19, 20
FN	Falsos Negativos – <i>False Negatives</i> . 61, 64
FP	Falsos Positivos – <i>False Positives</i> . 61, 64
GLONASS	<i>Global Navigation Satellite System</i> . 18–20
GNSS	Sistema Global de Navegação por Satélite – <i>Global Navigation Satellite System</i> . x, xiii, 2–7, 10, 13, 14, 18–22, 24–26, 35, 36, 48, 49, 54, 55, 88
GPS	<i>Global Positioning System</i> . 18–20, 38, 41, 43, 52–54, 58

GPU	Unidade de Procesamento Gráfico – <i>Graphics Processing Unit</i> . 68
HOG	<i>Histogram of Oriented Gradients</i> . 63, 64
HOSVD	<i>Higher Order Singular Value Decomposition</i> . 37–39, 41–43, 52
IMU	Unidade de Medição Inercial – <i>Inertial Measurement Unit</i> . 13, 14, 24, 25, 49, 54, 58
INS	Sistema de Navegação Inercial – <i>Inertial Navigation System</i> . x, 24–26
IoU	Interseção sobre União – <i>Intersection over Union</i> . 61
ISO	<i>International Organization for Standardization</i> . 24
ITS	Sistema de Transporte Inteligente – <i>Intelligent Transport System</i> . 33
IVIS	Sistemas de Informação do Veículo – <i>In-Vehicle Information Systems</i> . 82
JOSM	<i>Java OpenStreetMap Editor</i> . x, 31, 32
LiDAR	<i>Light Detection and Ranging</i> . xi, 3, 4, 7, 11, 15, 26, 28, 56–60, 62, 87
LOS	<i>Line of sight</i> . x, xi, xiii, 22, 35–44, 48, 49, 52–54
LRR	Radar de Longo Alcance – <i>Long-Range Radar</i> . 15
MaaS	Mobilidade como um Serviço – <i>Mobility as a Service</i> . 69–71
mAP	<i>Mean Average Precision</i> . xi, 61, 62
MEO	Órbita Média da Terra – <i>Medium Earth Orbit</i> . 18
NASA	<i>National Aeronautics and Space Administration</i> . 45
NDRT	Tarefas Não Relacionadas à Condução – <i>Non-Driving Related Tasks</i> . 82
NDS	<i>Navigation Data Standard</i> . 28–30
NLOS	<i>Non LOS</i> . 24, 36–38, 41, 48, 49, 52, 54
OEM	Fabricante Original do Equipamento – <i>Original Equipment Manufacturer</i> . 70, 78
OMS	Organização Mundial de Saúde. 67
PIB	<i>Produto Interno Bruto</i> . 4

PPP	<i>Precise Point Positioning</i> . 55
PRN	Ruído Pseudo-Aleatório – <i>Pseudorandom Noise</i> . 36, 41
ProKRaft	<i>Procrustes estimation and Khatri-Rao factorization</i> . 39, 41
Radar	<i>Radio Detection and Ranging</i> . 3, 15
RMSE	Raiz do Erro Quadrático Médio – <i>Root Mean Square Error</i> . x, xi, 39–44, 52, 54, 55
RNSS	Serviço de Radionavegação por Satélite – <i>Radionavigation-Satellite Service</i> . 20
ROS	<i>Robot Operating System</i> . 68
RTK	<i>Real Time Kinematic</i> . 55, 88
RTOS	Sistema Operacional de Tempo Real – <i>Real Time Operating System</i> . 68
SBAS	<i>Satellite-based Augmentation System</i> . 55
SDV	Veículo Definido por Software – <i>Software-Defined Vehicle</i> . 67, 75
SECSI	Estrutura Semi-Algébrica para Decomposição Poliádica Canônica Aproximada através de Diagonalizações Simultâneas para Estimação de Atraso – <i>Semi-algebraic framework for approximate Canonical Polyadic Decompositions via Simultaneous Matrix Diagonalizations</i> . 43
SLAM	Localização e Mapeamento Simultâneos – <i>Simultaneous Localization and Mapping</i> . 26
SNR	Razão Sinal-Ruído – <i>Signal-Noise Ratio</i> . 52
SOC	Sistema-em-um-Chip – <i>System-on-a-Chip</i> . 68
SPS	<i>Spatial Smoothing</i> . 38, 39, 41, 52
SRR	Radar de Curto Alcance – <i>Short-Range Radar</i> . 15
SVD	<i>Singular Value Decomposition</i> . 36
SVM	<i>Support Vector Machine</i> . 63, 64
TMBOC	<i>Time Multiplexed Binary Offset Carrier</i> . 41, 43
TN	Verdadeiros Negativos – <i>True Negatives</i> . 64
TP	Verdadeiros Positivos – <i>True Positives</i> . 61, 64
TTS	Texto para Voz – <i>Text to Speech</i> . 74
ULA	Arranjo Linear Uniforme de Antenas – <i>Uniform Linear Array</i> . 36, 52
UX	Experiência do Usuário – <i>User Experience</i> . 73, 88

V2I	<i>Vehicle-to-Infrastructure.</i> 15
V2V	<i>Vehicle-to-Vehicle.</i> 15
V2X	<i>Vehicle-to-Everything.</i> 15
VRU	<i>Vulnerable Road User.</i> 62
XML	<i>Extensible Markup Language.</i> 30
YOLOv3	<i>You Only Look Once - Version 3.</i> 58, 59

1 INTRODUÇÃO

Apesar dos avanços ocorridos nos últimos anos no desenvolvimento de veículos autônomos, muitos desafios ainda precisam ser superados para que eles possam circular de forma efetivamente segura. Um desses desafios envolve a pesquisa e o desenvolvimento de técnicas de localização e detecção de objetos que possam tornar a percepção dos veículos ainda mais robusta e confiável, em especial, em cenários urbanos, onde a presença de um elevado número de objetos e de interferências na recepção de sinais via satélite tornam a realização de manobras uma atividade desafiadora para os veículos autônomos. Além disso, o desenvolvimento de novos modelos de negócio e a integração de novas tecnologias podem contribuir para a expansão do uso de veículos autônomos. Nesse sentido, este capítulo apresenta uma contextualização geral sobre a temática de veículos autônomos, abordando, em especial, a localização, a detecção de objetos em cenários urbanos e a interação homem-máquina. Também são descritos os aspectos motivacionais para o desenvolvimento desta pesquisa, os objetivos pretendidos, a metodologia a ser utilizada e as contribuições almeçadas com este trabalho.

O desejo de desenvolver carros que possam ser conduzidos sem a necessidade de um ser humano ao volante vem de longa data. As primeiras tentativas datam do início da década de 1920, nas quais comunicações via rádio foram empregadas para controlar veículos de forma remota. Embora esse desejo de ter veículos autônomos esteve sempre mais perto de uma utopia do que da realidade durante a maior parte do séc. XX, a partir do início da década de 1980, os avanços tecnológicos ocorridos na área da microeletrônica possibilitaram o desenvolvimento de protótipos capazes de se locomover com a ajuda de câmeras instaladas nos veículos e de técnicas de processamento de imagens [1].

A pesquisa de tecnologias para veículos autônomos teve avanço expressivo no início do séc. XXI, em especial, com as competições promovidas pela *Defense Advanced Research Projects Agency* (DARPA) durante os anos de 2004 e 2007. Diversas instituições e universidades participaram dessas competições utilizando veículos equipados com diferentes tipos de sensores e com o uso de técnicas de inteligência artificial [2]. Os promissores resultados alcançados pelas equipes participantes incentivaram tanto o surgimento de *startups* quanto o interesse de grandes empresas de tecnologia. Dentre essas empresas, a Google foi uma das pioneiras, iniciando suas pesquisas com veículos autônomos em 2009 [3].

A partir de 2015, começaram a surgir as primeiras empresas ofertando serviços de táxi utilizando veículos autônomos em caráter experimental. Atualmente, é possível encontrar empresas que já oferecem serviços de transporte de passageiros e de mercadorias utilizando carros e caminhões autônomos, principalmente, nos Estados Unidos e na China. A grande

maioria dessas empresas, entretanto, ainda opera em fase de testes, com restrições e com a utilização de motoristas humanos como fator de segurança. As autorizações impõem diversas limitações, como a quantidade de veículos a ser testada, as localidades em que podem operar e a velocidade máxima com que podem trafegar nas vias [4].

De acordo com dados de abril de 2022 do Departamento de Trânsito da Califórnia [5], há 48 empresas com permissão para testar veículos autônomos com a utilização de motoristas humanos. Dessas empresas, 7 têm permissão até o momento para testar veículos sem a presença de um motorista humano: *Apollo (Baidu)*, *AutoX*, *Cruise*, *Nuro*, *Waymo*, *Weride* e *Zoox*. Somente 3 delas têm permissão de disponibilizar veículos autônomos ao público em geral e explorar serviços comercialmente: *Cruise*, *Nuro* e *Waymo*.

Conforme levantamento realizado por [6], no período de 2014 a 2018, veículos autônomos de diversos fabricantes foram testados ao longo de mais de 3,7 milhões de milhas. Foram reportados 128 acidentes nesse período, sendo que, em 63% deles, o veículo encontrava-se no modo autônomo. No entanto, somente 6% dos acidentes tiveram como causa o veículo autônomo em si. Os demais 94% foram originados por outras partes, como veículos convencionais, pedestres, ciclistas e motociclistas.

Apesar da capacidade dos veículos autônomos de buscar tomar decisões para evitar possíveis acidentes, situações como a que ocorreu com um veículo de testes da empresa Uber [7], demonstram que ainda há muitos desafios que precisam ser superados para que se possa ter veículos se locomovendo de forma confiável em um ambiente urbano e em condições climáticas que nem sempre são favoráveis a uma boa visibilidade.

Um desses desafios está relacionado com a determinação exata da localização de um veículo autônomo na superfície da Terra, tanto em termos de posição quanto orientação. Em geral, determinar essa localização de forma acurada requer informações precisas sobre posição, velocidade, direção, inclinação e rotação do veículo a uma taxa de atualização bastante elevada. Prover tais informações demanda o uso integrado de diversos dispositivos, tais como receptores de Sistema Global de Navegação por Satélite – *Global Navigation Satellite System* (GNSS), giroscópios, acelerômetros, entre outros, além de um sistema que seja capaz de minimizar os erros das medições desses dispositivos [8].

Em se tratando de GNSS, os sinais transmitidos pelos satélites podem sofrer interferências até chegarem à superfície da Terra. Com isso, a posição calculada pelo receptor pode conter erros, não correspondendo à posição exata na qual se encontra o veículo. Em alguns casos, tais erros podem chegar a dezenas de metros, o que seria inviável em um veículo autônomo, já que o risco de colisão com outros objetos seria bastante elevado. Portanto, é necessária a utilização de métodos que possam mitigar os efeitos dessas interferências, minimizando, assim, os erros de cálculo de posicionamento do veículo.

Uma das interferências que afetam o cálculo realizado pelo receptor de GNSS é cha-

mada de multipercurso. Ela é uma interferência bastante peculiar em ambientes urbanos e caracteriza-se pela reflexão dos sinais transmitidos pelos satélites em objetos existentes na superfície terrestre, tais como prédios e árvores. Tal reflexão faz com que réplicas de um mesmo sinal cheguem até o receptor. Como o cálculo da posição é baseado na estimação do tempo que um sinal leva para trafegar do satélite até o receptor, essas réplicas acabam afetando a acurácia da estimação e, conseqüentemente, a posição calculada será divergente da posição real do veículo.

Para mitigar os efeitos decorrentes do multipercurso, uma possível solução é o uso de receptores de GNSS compostos por múltiplas antenas e de técnicas tensoriais capazes de filtrar os sinais replicados. Ao identificar e descartar os efeitos dos sinais replicados, o receptor pode estimar com melhor acurácia o atraso de tempo do sinal de linha de visada com o satélite.

Outro desafio bastante relevante no contexto de veículos autônomos está relacionado com a percepção dos demais objetos que estão no ambiente em volta do veículo, como carros, motociclistas, ciclistas e pedestres. A utilização de sensores como câmera, *Radio Detection and Ranging* (Radar) e *Light Detection and Ranging* (LiDAR) são fundamentais para a percepção do ambiente externo, porém, cada um deles tem suas limitações. Nesse caso, é importante a utilização de métodos de fusão de dados que possam tornar cada vez mais confiável a capacidade de detecção de objetos com o uso desses sensores de forma complementar.

Assim como hoje os seres humanos utilizam seus *smartphones* para se conectar à Internet e ter acesso a diversos serviços, os veículos autônomos também precisam incorporar essa característica de conectividade. Tal fato é de grande relevância, dado que esses veículos precisam ter acesso a serviços que possam fornecer informações importantes para o seu deslocamento com segurança, tais como serviços de informação sobre a situação do trânsito e condições climáticas em uma determinada rota. Além disso, os veículos autônomos também podem ser utilizados para reportar incidentes de trânsito capturados por meio dos seus sensores de percepção. Obviamente, para a viabilização de veículos autônomos conectados, é fundamental a utilização de infraestruturas de *edge computing* e de redes de comunicação com tecnologias 5G e além, as quais possibilitam altas taxas de transmissão de dados, alta confiabilidade e baixíssima latência [9].

Dessa forma, ao utilizar um veículo autônomo o usuário tem a possibilidade de realizar outras atividades que não estão diretamente ligadas à condução do veículo. Tal fato, associado à conectividade do veículo por meio de redes de comunicação 5G e além, possibilitam que diversos serviços possam ser disponibilizados para acesso ao veículo, bem como ao usuário. Isso permite que novos modelos de negócio também possam ser desenvolvidos, visando atender necessidades que antes eram inexistentes por conta da condução do veículo. Além disso, há também a oportunidade de se pensar em novos conceitos de veículos, bem como em novas formas de interação humano-automóvel.

Nesse sentido, esta pesquisa busca propor técnicas que possam colaborar com a área de veículos autônomos, especialmente, em três aspectos: fusão de dados de sensores de câmera e LiDAR, utilização de técnicas tensoriais para mitigação de efeitos de multipercurso em sinais de GNSS e estimação de posicionamento de veículos autônomos, e desenvolvimento de assistente virtual para interação com veículos autônomos.

1.1 MOTIVAÇÃO

Milhões de pessoas no mundo são vítimas de acidentes de trânsito a cada ano. Estimativas mostram que, anualmente, esses acidentes são responsáveis pela morte de aproximadamente 1,35 milhão de pessoas e por deixar outras 20 a 50 milhões com alguma sequela decorrente de lesões não fatais [10].

Apesar dos avanços tecnológicos promovidos pela indústria automotiva ao longo do tempo para tornar os veículos cada vez mais seguros, o número de acidentes e vítimas continua bastante elevado, correspondendo à oitava maior causa de mortes no mundo. Já quando se observa o número de mortes de crianças e jovens entre 5 e 29 anos, o trânsito representa a primeira causa de mortes. Em termos financeiros, há também um impacto significativo, já que o gasto do sistema de saúde de cada país para cuidar dessas vítimas gira em torno de 3% do *Produto Interno Bruto* (PIB).

Analisando as causas dos acidentes, estudos demonstram que mais de 90% têm como causa a imprudência e a imperícia de motoristas, enquanto menos de 1% têm como origem falhas técnicas nos veículos [11, 12].

Um caminho possível para tornar o trânsito mais seguro, portanto, é dotar o veículo de inteligência que seja capaz de autoconduzi-lo, realizando tomadas de decisão nas mais diversas situações e cenários, com o mínimo de necessidade de interferência humana.

A utilização de veículos autônomos pode gerar, ainda, outros benefícios para a sociedade, por exemplo, a destinação do tempo que seria desperdiçado pelo motorista ao volante para outras atividades relevantes. Tais veículos também podem servir como tecnologia assistiva de pessoas idosas ou com necessidades especiais, propiciando um sistema de mobilidade mais inclusivo. Além disso, algoritmos inteligentes implementados nos veículos podem proporcionar melhor eficiência na condução, minimizando acelerações e frenagens desnecessárias. Dessa forma, tem-se um consumo mais eficiente de combustível e, em caso de veículos elétricos, da energia armazenada na bateria.

Portanto, a elaboração desta pesquisa e sua aplicação no contexto de veículos autônomos é um aspecto motivacional bastante importante porque possibilita colaborar com uma área que, no futuro, pode promover um trânsito mais inteligente, eficiente e seguro.

1.2 OBJETIVOS

O objetivo geral desta pesquisa é propor um conjunto de técnicas para melhoria da percepção, localização e interação humano-computador em veículos autônomos.

Para alcançar esse objetivo geral, os seguintes objetivos específicos foram estabelecidos:

- **OE1:** Identificar técnicas e algoritmos do estado da arte utilizados na detecção de objetos e localização de veículos autônomos;
- **OE2:** Identificar e analisar técnicas tensoriais para minimização de erros de posicionamento em receptores de GNSS baseados em arranjo de antenas;
- **OE3:** Propor métodos e algoritmos de fusão de sensores, de detecção de objetos e de localização para melhoria da percepção em veículos autônomos;
- **OE4:** Propor um modelo de assistente virtual para interação humano-computador em veículos autônomos.

1.3 METODOLOGIA

A pesquisa científica caracteriza-se como um conjunto de ações que busca, em sua essência, gerar conhecimentos sobre um determinado assunto. Tais ações têm como base procedimentos sistemáticos cujo objetivo principal é encontrar respostas para um problema específico [13].

Nesse sentido, com foco no objetivo geral estabelecido neste documento, faz-se necessário estabelecer o conjunto de procedimentos que será adotado ao longo desta pesquisa.

Para tornar mais claro o detalhamento da metodologia aqui empregada, esta seção encontra-se dividida em subseções. A subseção 1.3.1 apresenta os critérios que caracterizam como esta pesquisa está estruturada. A subseção 1.3.2 detalha as etapas que previstas durante a execução do processo de pesquisa.

1.3.1 Caracterização da Pesquisa

A caracterização desta pesquisa tem como base os critérios de natureza, objetivos do estudo, abordagem do problema e procedimentos técnicos, definidos de acordo com [13].

Quanto à natureza, duas classificações são estabelecidas: básica e aplicada. A primeira procura gerar conhecimentos novos, sem previsão de aplicação prática, enquanto a segunda tem o foco na produção de produtos ou processos com finalidade de aplicação imediata na

solução de problemas específicos. A pesquisa aqui descrita é, portanto, aplicada, já que o intuito é buscar uma solução prática para a otimização da localização e da detecção de objetos em veículos autônomos.

Do ponto de vista dos objetivos, três tipos de classificação são estabelecidos: exploratória, descritiva e explicativa. Esta pesquisa caracteriza-se como exploratória, tendo como propósito explicitar melhor as ideias e os conceitos relacionados ao problema, visando, assim, identificar caminhos para uma tomada de decisão mais correta e formular soluções mais precisas.

Quanto à abordagem do problema, a pesquisa pode ser classificada como qualitativa ou quantitativa. No caso deste trabalho, a abordagem será prioritariamente qualitativa, embora métodos quantitativos também serão levados em conta, já que este trabalho demanda o uso de modelos e técnicas estatísticas para garantir a acurácia dos resultados e evitar contradições no processo de análise e interpretação.

Os procedimentos técnicos referem-se à maneira pela qual os dados necessários à elaboração da pesquisa são coletados. No contexto desta pesquisa, dois procedimentos serão adotados. O primeiro será a pesquisa bibliográfica, elaborada a partir de material previamente publicado em artigos e livros. O segundo será a pesquisa experimental, na qual um objeto de estudo é determinado, as variáveis capazes de influenciá-lo são selecionadas e as formas de controle e de observação dos efeitos dessas variáveis são definidas.

A Tabela 1.1 apresenta, de forma resumida, a caracterização desta pesquisa nas diferentes categorias apresentadas.

Tabela 1.1 – Síntese da Caracterização da Pesquisa

Abordagem	Natureza	Objetivos	Procedimentos Técnicos
Qualitativa	Aplicada	Exploratória	Pesquisa Bibliográfica e Pesquisa Experimental

Fonte: Elaborada pelo autor.

1.3.2 Fases da Pesquisa

Para que esta pesquisa possa acontecer com melhor planejamento e controle, faz-se necessário organizá-la em fases. Ao todo, três fases deverão ser cumpridas.

A primeira fase engloba a revisão bibliográfica acerca dos tópicos de fundamentação desta pesquisa. De uma maneira geral, os seguintes tópicos serão estudados ao longo desta fase: fusão de dados de sensores, algoritmos de redes neurais para detecção de objetos, estimação de posicionamento e localização de veículos autônomos, receptores de GNSS baseados em arranjo de antenas e técnicas tensoriais, mapas de alta definição, e ferramentas e modelos para o desenvolvimento de assistentes virtuais.

A segunda fase engloba a proposição de uma solução integrada que possibilite a um veículo autônomo ter uma melhor capacidade de percepção de si mesmo e dos objetos a sua volta. Tal solução, portanto, envolverá a utilização integrada de receptores de GNSS baseados em arranjo de antenas e técnicas tensoriais, e técnicas aprimoradas de fusão de sensores.

A terceira fase envolve a prospecção de novos modelos de negócio utilizando veículos autônomos. Nessa fase, será feita a proposição de uma solução de assistente virtual capaz de auxiliar na interação humano-veículo.

1.4 CONTRIBUIÇÕES DO TRABALHO

A realização desta pesquisa visa promover as seguintes contribuições:

- **Melhoria na acurácia da localização de um veículo autônomo:** em cenários urbanos, principalmente, os cálculos de localização realizados pelos receptores de GNSS são bastante afetados pela interferência de multipercurso, a qual é decorrente da presença de diversos obstáculos ao longo do trajeto, como edifícios, viadutos, árvores, entre outros. A utilização de arranjos de antenas e de técnicas tensoriais pode contribuir para a minimização dos efeitos desse tipo de interferência no receptor. Ao melhorar a acurácia da localização, possibilita-se que um veículo possa se locomover com mais confiabilidade em um cenário que envolve a presença de diversos outros objetos, como é o caso do cenário urbano;
- **Melhoria da acurácia na detecção de objetos:** nesse ponto será levada em consideração a fusão de dados brutos de câmera e de LiDAR com foco na detecção de veículos;
- **Propor um modelo de assistente virtual para facilitar a interação entre usuários e veículos autônomos:** a utilização em larga escala de veículos autônomos permite que os usuários possam dedicar o tempo gasto com a condução dos veículos em outras atividades. Com isso, novos modelos de negócio podem ser propostos para atender necessidades desses usuários durante o período de tempo em que não estão dirigindo.

1.5 PUBLICAÇÕES VINCULADAS AO TRABALHO

A lista a seguir apresenta os artigos que foram publicados em revistas durante o desenvolvimento deste trabalho. Os artigos presentes nesta lista encontram-se organizados por ordem decrescente de data de publicação.

- Santos, G. A.; Andrade, G. G.; Silva, G. R. S.; Duarte Jr, F. C. M.; da Costa, J. P. J.; de Sousa Jr, R. T. de. *A Conversation-Driven Approach for Chatbot Management*. IEEE Access, v. 10, p. 8474–8486, 2022.
- Pinheiro, G. P. M.; Miranda, R. K.; Praciano, B. J.; Santos, G. A.; Mendonça, F. L. L.; Javidi, E.; da Costa, J. P. J.; de Sousa Jr, R. T. *Multi-Sensor Wearable Health Device Framework for Real-Time Monitoring of Elderly Patients Using a Mobile Application and High-Resolution Parameter Estimation*. Frontiers in Human Neuroscience vol. 15 750591, 2022.

A lista a seguir apresenta os artigos que foram publicados em conferências durante o desenvolvimento deste trabalho. Os artigos presentes nesta lista encontram-se organizados por ordem decrescente de data de publicação.

- Santos, G. A.; da Costa, J. P. C. L.; Lima, D. V. de; Zanatta, M. da R.; Praciano, B. J. G.; Pinheiro, G. P. M.; Mendonça, F. L. L. de; de Sousa Jr, R. T. *Improved localization framework for autonomous vehicles via tensor and antenna array based GNSS receivers*. In: 2020 Workshop on Communication Networks and Power Systems (WCNPS), 2020, Brasília, Brazil. Proceedings [...]. Piscataway, NJ: IEEE, 2020. p. 1–6.
- Danapal, G.; Santos, G. A.; da Costa, J. P. C. L.; Praciano, B. J. G.; Pinheiro, G. P. M. *Sensor fusion of camera and LiDAR raw data for vehicle detection*. In: 2020 Workshop on Communication Networks and Power Systems (WCNPS), 2020, Brasília, Brazil. Proceedings [...]. Piscataway, NJ: IEEE, 2020. p. 1–6.
- Castelino, R. M.; Pinheiro, G. P. M.; Praciano, B. J. G.; Santos, G. A.; Weichenberger, L.; de Sousa Jr, R. T. *Improving the Accuracy of Pedestrian Detection in Partially Occluded or Obstructed Scenarios*. In: 10th International Conference on Advanced Computer Information Technologies (ACIT), 2020, Deggendorf, Germany. Proceedings [...]. Piscataway, NJ: IEEE, 2020. p. 834–838.
- Andrade, G. G.; Silva, G.; Duarte Jr, F.; Santos, G. A.; Mendonça, F. L.; de Sousa Jr, R. T. *EvaTalk: A Chatbot System for the Brazilian Government Virtual School*. In: 22nd International Conference on Enterprise Information Systems (ICEIS), 2020, Prague, Czech Republic. Proceedings [...]. Setúbal, Portugal: SciTePress, 2020. v. 1, p. 556–562.

A lista a seguir apresenta outros artigos que foram publicados em conferências e revistas desde o ingresso no curso de doutorado. Os artigos presentes nesta lista encontram-se organizados por ordem decrescente de data de publicação.

- Magalhães, E. B. M.; Santos, G. A.; Molina Jr, F. C. D.; da Costa, J. P. J.; de Mendonça, F. L. L.; de Sousa Jr, R. T. *Student Dropout Prediction in MOOC using Machine Learning Algorithms*. In: 2021 Workshop on Communication Networks and Power Systems (WCNPS), 2021, Brasília, Brazil. Proceedings [...]. Piscataway, NJ: IEEE, 2021. p. 1–6.
- Silva, G. R. S.; Santos, G. A.; Rissoli, V. R. V. *A Importância da Linguagem Nativa para a Aprendizagem Significativa em Lógica de Programação*. In: XXXI Simpósio Brasileiro de Informática na Educação (SBIE), 2020, Natal, Brazil. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2020. p. 1803–1812.
- Silva, G.; Santos, G.; Canedo, E. D.; Rissoli, V.; Praciano, B.; Andrade, G. *Impact of Calango language in an Introductory Computer Programming Course*. In: 2020 IEEE Frontiers in Education Conference (FIE), 2020, Uppsala, Sweden. Proceedings [...]. Piscataway, NJ: IEEE, 2020. p. 1–9.
- Leão, H. A. T.; Canedo, E. D.; Costa, P. H. T.; Okimoto, M. V.; Santos, G. A. *Use of AHP and Promethee for Research Project Portfolio Selection*. In: Misra S. et al. (Ed.). Computational Science and Its Applications – ICCSA 2019. Cham: Springer International Publishing, 2019. (Lecture Notes in Computer Science, v. 11619), p. 504–517.
- Brandão, I. V.; da Costa, J. P. C. L.; Santos, G. A.; Praciano, B. J. G.; Duarte Jr, F.C. M.; de Sousa Jr, R. T. *Classification and predictive analysis of educational data to improve the quality of distance learning courses*. In: 2019 Workshop on Communication Networks and Power Systems (WCNPS), 2019, Brasília, Brazil. Proceedings [...]. Piscataway, NJ: IEEE, 2019. p. 1–6.
- Canedo, E. D.; Santos, G. A. *Factors Affecting Software Development Productivity: An Empirical Study*. In: XXXIII Brazilian Symposium on Software Engineering, 2019, Salvador, Brazil. Proceedings [...]. New York, NY, USA: Association for Computing Machinery, 2019. (SBES 2019), p. 307–316.
- Canedo E.D.; Leão H.A.T.; de Carvalho R. R.; da Costa R. P.; Santos G. A.; Okimoto M. V. (2019) *Educational Data Mining: A Profile Analysis of Brazilian Students*. In: Misra S. et al. (Ed.). Computational Science and Its Applications – ICCSA 2019. Cham: Springer International Publishing, 2019. (Lecture Notes in Computer Science, v. 11619), p. 473–488.
- Canedo, E. D.; Valença, K.; Santos, G. A. *An Analysis of Measurement and Metrics Tools: A Systematic Literature Review*. In: 52nd Hawaii International Conference on System Sciences (HICSS), 2019, Maui, Hawaii. Proceedings [...]. Honolulu, HI: University of Hawaii at Manoa, 2019. p. 6970–6980.

- Souza, L.; Santos, G. A.; Rissoli, V. *SAE - Sistema de Apoio Educacional*. In: VIII Congresso Brasileiro de Informática na Educação (CBIE), 2019, Brasília, Brazil. Anais dos Workshops [...]. Porto Alegre: Sociedade Brasileira de Computação, 2019. p. 1413–1416.
- Canedo, E. D.; Santos, G. A.; Leite, L. L. *An assessment of the teaching-learning methodologies used in the introductory programming courses at a Brazilian University*. Informatics in Education, v. 17, n. 1, p. 45–59, 2018.
- Nunes, C. F. D.; Santos, G. A.; Rissoli, V. R. V. *Tecnologia Inteligente no apoio ao Processo Educacional em Engenharia*. In: 10th International Symposium on Project Approaches in Engineering Education (PAEE) and 15th Active Learning in Engineering Education Workshop (ALE), 2018, Brasília, Brazil. Proceedings [...]. Guimarães, Portugal: School of Engineering of University of Minho, 2018. p. 840–847.
- Canedo, E. D.; Santos, G. A.; Mendes, F. F.; Venson, E.; Figueiredo, R. M. d. C. *Why there is still few women in Engineering? A perspective from female students and professors in an Engineering campus*. In: 2018 IEEE Frontiers in Education Conference (FIE), 2018, San Jose, CA, USA. Proceedings [...]. Piscataway, NJ: IEEE, 2018. p. 1–8.

1.6 ORGANIZAÇÃO DO TRABALHO

Além deste capítulo de introdução, este documento contém mais cinco capítulos, conforme descrição a seguir.

O Capítulo 2 apresenta os conceitos que formam a fundamentação teórica necessária aos capítulos subsequentes. Tal fundamentação engloba uma visão geral dos sensores utilizados na automação de um veículo, técnicas clássicas utilizadas para fusão de dados, características dos principais sistemas globais de navegação via satélite e de sistemas de navegação inercial, além de conceitos relacionados a mapas de alta definição.

No Capítulo 3, é descrita uma proposta de um método para estimação de localização para veículos autônomos baseado na aplicação de técnicas tensoriais sobre os dados obtidos a partir de receptores de GNSS compostos por arranjos de antenas. O objetivo principal desta proposta é mitigar interferências de multipercurso nos receptores, especialmente, em cenários urbanos, onde a presença de prédios, árvores e outros objetos pode gerar múltiplos componentes dos sinais transmitidos pelos satélites.

O Capítulo 4 apresenta propostas de métodos e técnicas voltados para percepção em veículos autônomos, em especial, um método de detecção de veículos baseado na fusão de

dados brutos de câmera e LiDAR e um método para a detecção de pedestres que se encontram parcialmente obstruídos.

O Capítulo 5 apresenta uma prospecção sobre modelos de negócio que podem ser vislumbrados com a utilização de veículos autônomos. Em especial, é proposto um modelo de assistente virtual para facilitar a interação entre os usuários e os veículos autônomos, bem como o acesso a serviços externos disponíveis em uma infraestrutura de *edge computing*. Também é feita a proposição de um processo de gerenciamento da base de conhecimento do assistente.

O Capítulo 6, por sua vez, apresenta as conclusões desta pesquisa e sugestões de trabalhos futuros que possam ser conduzidos a partir dos resultados aqui alcançados.

2 CONCEITOS E FUNDAMENTAÇÃO


Este capítulo apresenta uma explanação sobre conceitos que serão utilizados ao longo deste documento. Inicialmente, serão abordados conceitos relacionados a sensores e a importância da fusão de sensores no contexto de veículos autônomos. Em seguida, serão apresentadas características dos principais sistemas globais de navegação via satélite, bem como serão abordados conceitos de sistemas de navegação inercial. Em conjunto, ambos os sistemas desempenham importante papel na localização de veículos autônomos. Por fim, serão apresentados conceitos relacionados a mapas de alta definição.

2.1 SENSORES E AUTOMAÇÃO DE VEÍCULOS

Sensores são dispositivos compostos por elementos capazes de interagir com o ambiente e de perceber alguma propriedade física ou atributo, por exemplo, ondas eletromagnéticas, calor, luz, som, pressão ou movimento. Para ser útil, o sensor deve ser capaz de mapear o valor da propriedade ou atributo em uma medição quantitativa, de maneira consistente e previsível. Alguns tipos de sensores ditos inteligentes, além do elemento de medição, são integrados por outros componentes, como microprocessadores, controladores e software embarcado. Esse conjunto integrado de hardware e software é responsável por realizar funções adicionais, tais como processamento de sinais, calibração e comunicação [14].

A Figura 2.1 mostra um diagrama de blocos de alto nível de um sensor inteligente. O elemento sensor realiza a medição e gera um sinal analógico para a unidade de conversão analógico-digital (A/D). Nessa unidade, o sinal é amplificado, filtrado e convertido para um sinal digital. Esse sinal é, então, enviado para ser processado pelo microprocessador (μ P), sendo posteriormente enviado para o mundo externo pela unidade de transmissão/recepção (T/R) utilizando uma interface e um protocolo de comunicação padronizados. Dependendo do tipo de sensor, ele também pode receber comandos e dados do mundo externo por meio da unidade T/R.

Figura 2.1 – Representação de alto nível de um sensor inteligente



Fonte: Adaptada de [14].

Algumas características são relevantes para compreender o comportamento de cada sensor e da tecnologia utilizada. Conforme [8], embora outras características mais específicas possam também ser levadas em conta de acordo com os objetivos pretendidos, as que estão contidas na lista a seguir possibilitam ter um melhor entendimento das capacidades do sensor e, dessa forma, ter subsídios para avaliar se ele atende aos requisitos definidos para uma determinada aplicação:

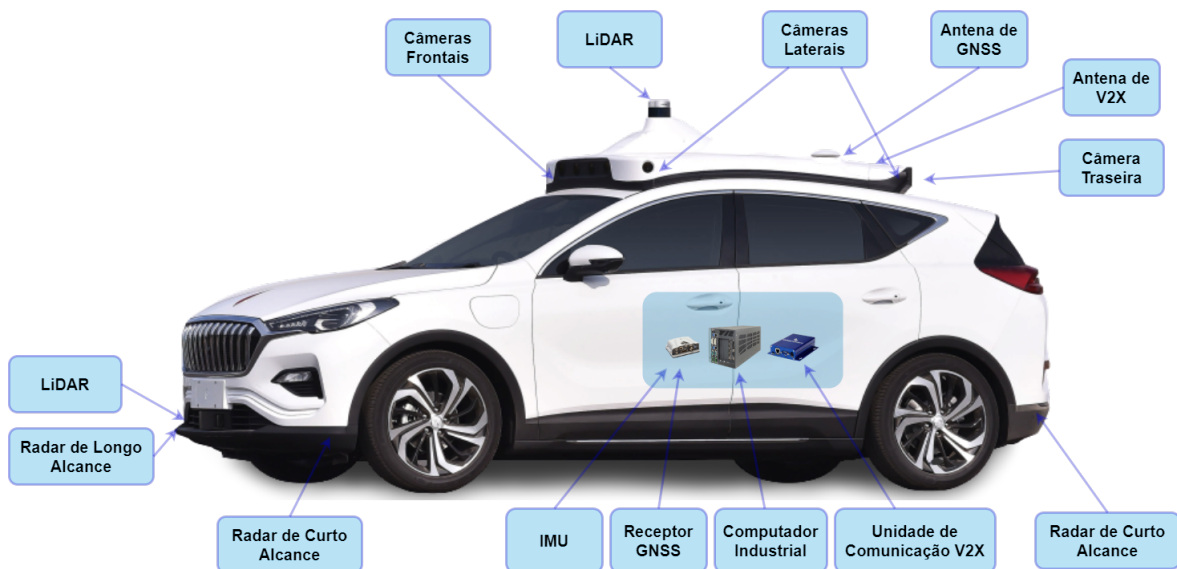
- *Acurácia*: erro entre o valor verdadeiro e o valor medido, que pode incluir ruídos e interferências externas;
- *Resolução*: a diferença mínima entre duas medições;
- *Sensibilidade*: o menor valor que pode ser detectado ou medido;
- *Alcance dinâmico*: os valores máximo e mínimo que podem ser detectados com a máxima acurácia;
- *Perspectiva*: pode indicar quantidades que caracterizam o desempenho do sensor, tais como alcance, campo de visão, etc.;
- *Ativo versus passivo*: se o sensor emite algum pulso de energia e captura o sinal refletido ou se ele somente capta sinais emitidos por outras fontes;
- *Escala de tempo*: pode indicar quantidades referentes à taxa de amostragem do sensor, largura de banda de frequência da medição, entre outras;
- *Tecnologia da interface*: pode indicar o tipo de sinal de saída do sensor, formato de dados, protocolos utilizados, etc.

A Figura 2.2 mostra um modelo de um veículo destinado ao transporte de pessoas e a indicação de alguns dos seus sensores e de outros componentes utilizados para automação. Nesse contexto, os sensores podem ser agrupados em duas categorias principais: aqueles voltados para realizar medições acerca do estado do veículo e os que são destinados para a percepção do ambiente externo.

O receptor de GNSS é considerado um sensor da primeira categoria, que fornece informações de posicionamento e velocidade do veículo a partir de um sistema de navegação via satélite. Os sinais de satélite chegam até o receptor por meio de uma antena de GNSS geralmente localizada no teto do veículo.

Outro sensor desta categoria é a Unidade de Medição Inercial – *Inertial Measurement Unit* (IMU), que mede a velocidade angular e a aceleração linear em cada um dos três eixos ortogonais do veículo (lateral, longitudinal e vertical). Dependendo do fabricante, o receptor

Figura 2.2 – Exemplo de Configuração de Sensores em um Veículo Autônomo



Fonte: Elaborada pelo autor.

de GNSS e o IMU podem estar contidos no mesmo dispositivo físico, conforme mostrado na Figura 2.2, ou podem ser dispositivos distintos.

Outros exemplos de sensores dessa primeira categoria, que não estão visíveis na Figura 2.2, são listados a seguir:

- Sensores de estado do motor, tais como de temperatura do líquido de arrefecimento do motor, nível de combustível, rotações do motor, nível de oxigênio, etc;
- Sensor de Velocidade das Rodas (do inglês, *Wheel Speed Sensor*), que mede o número de rotações por minuto de cada roda;
- Sensor de Ângulo de Direção (do inglês, *Steering Angle Sensor*), que mede o ângulo de direção do volante do veículo;
- Sensor de Torque no Volante (do inglês, *Steering Torque Sensor*), que determina a quantidade de força que está sendo aplicada ao volante em um determinado instante.

Entretanto, para atender às necessidades de Sistemas Avançados de Assistência ao Motorista – *Advanced Driver Assistance Systems* (ADAS) e de veículos autônomos, apenas os sensores dessa primeira categoria não são suficientes, sendo necessário um conjunto capaz de fornecer informações em relação ao ambiente externo do veículo. Em outras palavras, além das informações do estado do veículo, são necessários sensores que possam fornecer uma percepção do ambiente ao seu redor, detectando de forma adequada outros objetos, sejam eles dinâmicos, como pedestres e outros veículos, sejam estáticos, como placas de trânsito e marcações na pista.

A *Câmera* é um sensor passivo utilizado para capturar informação visual em torno do veículo. Em veículos autônomos, é comum se ter câmeras frontais, laterais e traseiras, fornecendo, assim, uma visão de 360°. Com o intuito de gerar imagens com informação de profundidade, podem ser empregados pares de câmeras monoculares ou, então, soluções envolvendo câmera estéreo.

O LiDAR é um sensor ativo que emite feixes de sinais de laser. Ao atingir um objeto, parte dos sinais emitidos é refletida, possibilitando determinar o tempo que os sinais levam para retornar ao sensor e, dessa forma, calcular a distância até cada ponto de reflexão. A partir desse conjunto de pontos é possível não apenas determinar a distância do sensor até cada objeto, mas também construir uma visão tridimensional dos objetos percebidos pelo sensor. Existem modelos que podem fornecer uma visão de 360°, bem como há modelos com campo de visão mais restrito, que podem ser instalados na frente, nas laterais ou na traseira do veículo.

O Radar é um sensor ativo que emite sinais de rádio e tem a capacidade de medir a distância e a velocidade de outros objetos com base no tempo que os sinais refletidos levam para retornar ao sensor. Na parte frontal do veículo é comumente instalado um Radar de Longo Alcance – *Long-Range Radar* (LRR), enquanto nas laterais pode ser utilizado o Radar de Curto Alcance – *Short-Range Radar* (SRR).

Apesar de não estar indicado na Figura 2.2, também podem ser utilizados sensores ultrasônicos, os quais emitem ondas sonoras de alta frequência e calcula a distância dos objetos com base nos sinais refletidos. São sensores de baixo custo e indicados para curtas distâncias, sendo comumente empregados em sistemas de assistência a estacionamento do veículo.

Além dos sensores citados, é possível observar na Figura 2.2 a presença de uma unidade de comunicação *Vehicle-to-Everything* (V2X), a qual, por meio da antena de V2X, possibilita a comunicação direta com outros veículos, chamada de *Vehicle-to-Vehicle* (V2V), ou com a infraestrutura da rodovia ou cidade, denominada de *Vehicle-to-Infrastructure* (V2I).

Por fim, para executar o software responsável pelos módulos de percepção, localização, planejamento e controle do veículo, se faz necessário um computador que demonstre capacidade de manter sua integridade funcional na presença de certas condições ambientais, como vibrações, mudanças de temperatura e interferências eletromagnéticas. Esse tipo de computador é comumente chamado de computador industrial (do inglês, *industrial grade computer*).

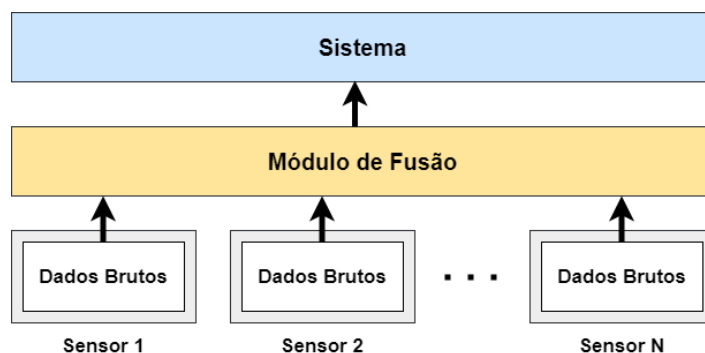
2.2 FUSÃO DE SENSORES

Em geral, os sensores são utilizados em conjunto como forma de reduzir incertezas e interferências. Para isso, é necessário um processo de fusão de dados capaz de agregar as medições realizadas por cada sensor, provendo informações adequadas para uma tomada de decisão com um alto grau de confiabilidade, robustez e acurácia.

Do ponto de vista arquitetural, a fusão de sensores pode ser categorizada em três modelos clássicos: fusão de baixo nível (do inglês, *low-level fusion*), fusão ao nível de *features* (do inglês, *feature-level fusion*), também denominada de nível intermediário, e fusão de alto nível (do inglês, *high-level fusion*) [15].

Na arquitetura de fusão de baixo nível, conforme mostrada na Figura 2.3, cada sensor transmite seus dados brutos para um módulo de fusão centralizado. Não há, portanto, pré-processamento de dados no sensor. O módulo de fusão é responsável por processar os dados brutos, extrair as características necessárias e gerar a saída que será repassada para um sistema central de rastreamento (do inglês, *tracking*) dos objetos detectados.

Figura 2.3 – Arquitetura de fusão de baixo nível



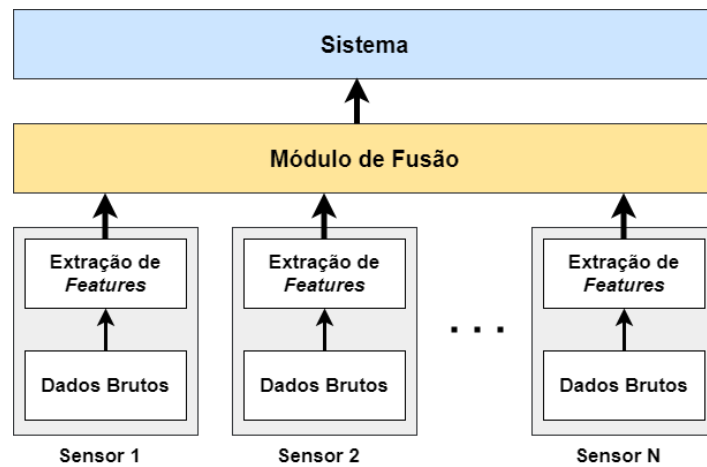
Fonte: Adaptada de [15].

Apesar dessa arquitetura ter como vantagem a fusão de dados em um estágio inicial, ela apresenta algumas desvantagens. Uma delas é a necessidade de uma largura de banda maior para suportar o volume de medições realizadas pelos sensores. Outra desvantagem é que ela gera um forte acoplamento entre o módulo de fusão e os sensores, conseqüentemente, demandando mudanças no módulo de fusão caso haja a necessidade de incorporar novos tipos de sensores.

No caso da arquitetura de fusão de nível intermediário, conforme mostrada na Figura 2.4, cada sensor é responsável por pré-processar os dados brutos, extraindo características mais genéricas, que são enviadas ao módulo de fusão. Essa arquitetura, portanto, requer que os sensores utilizem um modelo de dados comum. Contrastando com a de baixo nível, essa arquitetura demanda menos necessidade de largura de banda, já que o volume de dados entre o sensor e o módulo de fusão tende a ser bem menor. Similar ao que acontece na de baixo

nível, a saída do módulo de fusão é enviada para um sistema central de rastreamento de objetos.

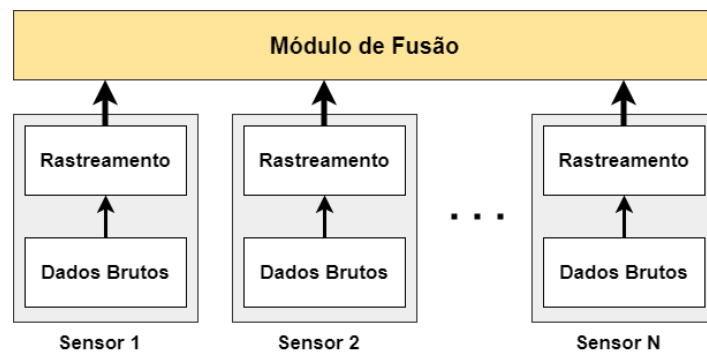
Figura 2.4 – Arquitetura de fusão de nível intermediário



Fonte: Adaptada de [15].

Já na arquitetura de alto nível, conforme mostrada na Figura 2.5, os sensores são dotados de algoritmos capazes de realizar a detecção e o rastreamento de objetos. Dessa forma, o módulo de fusão atua em um nível de representação mais elevado (do inglês, *track-to-track*), realizando a associação dos objetos que foram gerados por cada sensor de forma descentralizada e independente.

Figura 2.5 – Arquitetura de fusão de alto nível



Fonte: Adaptada de [15].

Com relação às vantagens da arquitetura de fusão de alto nível, ela permite abstrair detalhes específicos de cada sensor, possibilitando o encapsulamento de dados e a modularidade dos sensores. A princípio, um determinado sensor pode ser mais facilmente incorporado a essa arquitetura, desde que ele siga o modelo global de objetos definido por ela. Por outro lado, a fusão pode tornar-se mais complexa devido à variabilidade da capacidade de rastreamento e confiabilidade dos sensores utilizados. Pode ser que um objeto seja apenas parcialmente observado por cada um dos sensores e, dessa forma, a classificação desse objeto

pode se tornar mais difícil porque os algoritmos de detecção a nível de sensor têm menos informações que lhes possibilitem associar os dados brutos das medições a objetos do modelo global.

2.3 SISTEMAS DE NAVEGAÇÃO VIA SATÉLITE

Sistemas de GNSS têm se tornado cada vez mais fundamentais em diversos tipos de aplicações. Transporte aéreo, marítimo e terrestre, agricultura de precisão, monitoramento do meio ambiente e respostas a catástrofes e desastres naturais são exemplos de aplicações que dependem de informações precisas de posicionamento e velocidade para garantir a segurança e eficácia de suas operações. De maneira análoga, diversas aplicações fazem uso de informações de tempo e sincronização fornecidas por sistemas de GNSS, tais como redes de distribuição de energia elétrica, redes de telecomunicações e *gateways* para transações financeiras [16].

Atualmente, quatro sistemas de GNSS com cobertura global encontram-se em operação, os quais estão listados na Tabela 2.1.

Tabela 2.1 – Sistemas de GNSS com cobertura global

Sistema	Origem	Número de Satélites ¹	Altitude (Km)	Planos Orbitais
<i>Global Positioning System (GPS)</i>	EUA	27	20.200	6
<i>Global Navigation Satellite System (GLONASS)</i>	Rússia	24	19.140	3
Galileo	Europa	24	23.222	3
<i>BeiDou Navigation Satellite System (BDS-3)</i> ²	China	24	21.528	3

Fonte: Elaborada pelo autor.

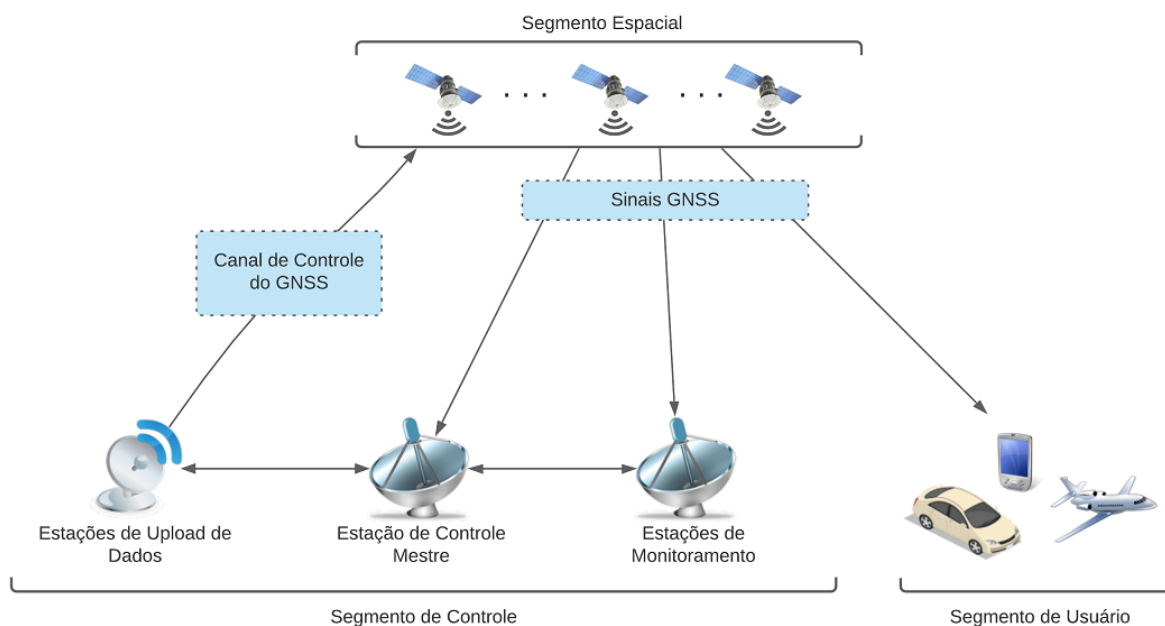
A arquitetura desses sistemas é baseada em três principais segmentos: espacial, de controle e de usuário. A Figura 2.6 mostra uma visão geral desses segmentos. O segmento espacial representa a chamada constelação de satélites, a qual encontra-se distribuída na órbita terrestre de tal maneira que ao menos quatro satélites possam ser observados de qualquer ponto da Terra. O segmento de controle envolve um conjunto de estações terrestres responsáveis por continuamente monitorar e controlar os satélites. Normalmente, essas estações são caracterizadas, de acordo com sua responsabilidade, em: estação mestre de controle, de monitoramento e de *upload* de dados. A estação mestre tem como objetivo ajustar os parâmetros da órbita e do relógio atômico dos satélites. As estações de monitoramento recebem

¹Quantidade referente apenas aos satélites operacionais localizados na Órbita Média da Terra – *Medium Earth Orbit (MEO)*. Também não inclui os satélites sobressalentes. Dados referentes a março de 2021.

²Considera-se aqui a terceira fase deste sistema, a qual passou a ter cobertura global a partir de 2020.

os sinais transmitidos pelos satélites e compartilha informações com a estação mestre. As estações de *upload* de dados são utilizadas para enviar aos satélites as correções geradas pela estação mestre. O segmento de usuário, por sua vez, engloba os equipamentos dos usuários, que processam os sinais recebidos dos satélites e provêm informações georreferenciadas para uso em diversas aplicações.

Figura 2.6 – Arquitetura geral de sistemas GNSS



Fonte: Elaborada pelo autor.

Ao longo dos anos, os sistemas de GNSS têm passado por modernizações, tanto para incorporar evoluções tecnológicas nos satélites quanto para incorporar novos sinais e mensagens que possam atender de forma eficiente e segura as necessidades das aplicações que dependem desses sistemas.

Em relação à transmissão dos sinais, os sistemas GPS, Galileo e BDS-3 utilizam o método Acesso Múltiplo por Divisão de Código – *Code-Division Multiple Access* (CDMA). Com o uso desse método, os satélites podem transmitir sinais simultaneamente em uma mesma frequência. Para isso são associados códigos a cada satélite, permitindo, assim, que o receptor possa identificar o emissor da mensagem. Já o sistema GLONASS utiliza o método denominado Acesso Múltiplo por Divisão de Frequência – *Frequency-Division Multiple Access* (FDMA), o qual requer que cada satélite utilize uma frequência distinta para a transmissão dos sinais, exceto se eles se encontrarem em lados opostos da Terra. No entanto, com o intuito de possibilitar futura interoperabilidade com os demais sistemas, o GLONASS tem incorporado o CDMA aos novos satélites que têm sido lançados.

A transmissão de sinais nos sistemas GNSS utiliza subfaixas de frequência dentro da faixa conhecida como Banda L, que vai de 1 a 2 GHz, mais especificamente, subfaixas

no espectro do Serviço de Radionavegação por Satélite – *Radionavigation-Satellite Service* (RNSS). Cada subfaixa recebe uma identificação e pode ser designada para transmitir mensagens específicas ou prover serviços para determinados tipos de aplicação. Além disso, essas subfaixas podem transmitir sinais tanto para uso civil quanto militar.

A Tabela 2.2 mostra a identificação das subfaixas em cada sistema, bem como as frequências correspondentes. A Figura 2.7, por sua vez, mostra uma visão geral da alocação das subfaixas presentes na Tabela 2.2 no espectro de frequências da Banda L.

Apesar dos sistemas Galileo e BDS-3 utilizarem identificações distintas, suas frequências também estão na Banda L. No sistema Galileo, a subfaixa E5 é dividida ainda em duas subfaixas, E5a e E5b. No BDS-3, a subfaixa B2 é dividida em duas subfaixas, B2a e B2b. No sistema GLONASS, as subfaixas identificadas como L1 e L2 transmitem sinais utilizando o método FDMA, enquanto L3 utiliza CDMA.

Tabela 2.2 – Métodos de acesso e subfaixas de frequência dos sistemas de GNSS com cobertura global

Sistema	Método de Acesso	Identificação	Frequência Central (MHz)
GPS	CDMA	L1	1575.42
		L2	1227.60
		L5	1176.45
GLONASS	FDMA	L1	1602.0
		L2	1246.0
	CDMA	L3	1202.025
Galileo	CDMA	E1	1575.42
		E5	1191.795
		E5a	1176.45
		E5b	1207.14
		E6	1278.75
BDS-3	CDMA	B1	1575.42
		B2	1191.795
		B2a	1176.45
		B2b	1207.14
		B3	1268.52

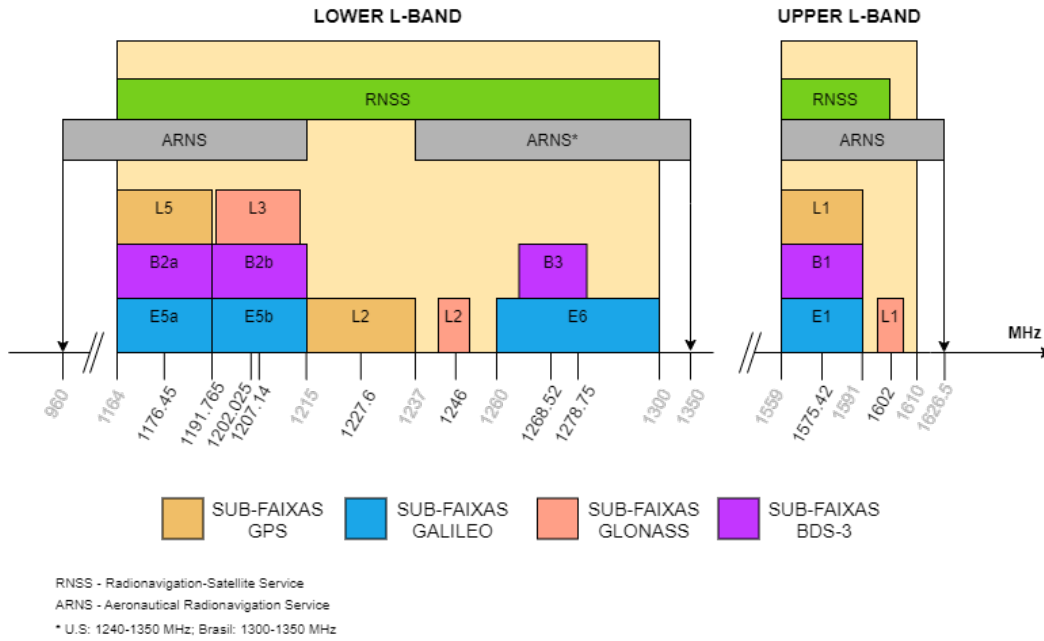
Fonte: Elaborada pelo autor.

2.3.1 Posicionamento via GNSS

Os satélites presentes em cada um desses sistemas transmitem mensagens regularmente via sinais de rádio. A velocidade com que esses sinais trafegam pelo espaço é próxima à da luz, em torno de 299.792 quilômetros por segundo (km/s).

Cada mensagem transmitida por um satélite contém, entre outras informações: (i) a *efeméride*, informação que possibilita ao receptor determinar a posição do satélite na órbita no

Figura 2.7 – Subfaixas de frequências dos sistemas de GNSS com cobertura global



Fonte: Elaborada pelo autor.

momento da transmissão; (ii) o *status*, que indica se há algum problema com o satélite e, dessa forma, suas mensagens não devem ser utilizadas pelo receptor; e (iii) o *instante de tempo* (t_0) de transmissão da mensagem, o qual é extremamente preciso, já que é gerado por um relógio atômico a bordo do satélite.

Quando um receptor recebe uma mensagem, ele registra o instante de tempo de chegada (t_1) com base em seu relógio local. A diferença entre os instantes t_1 e t_0 caracteriza o tempo de propagação do sinal (Δt). Com base na velocidade da luz (c) e no tempo de propagação, e desconsiderando quaisquer outros erros, o receptor é capaz de calcular sua distância geométrica até o satélite (r), conforme mostrado na Equação (2.1).

$$r = c(t_1 - t_0) \quad (2.1)$$

Entretanto, dificilmente os relógios do satélite e do receptor estarão sincronizados. Os relógios podem estar atrasados ou adiantados em relação ao tempo real do sistema. Na prática, é preciso incorporar essa diferença ao instante de tempo efetivamente registrado. Considerando δ_s como sendo o erro do relógio do satélite e δ_r como o erro do relógio do receptor, e tomando por base a Equação (2.1), é possível estimar a *pseudodistância*, ρ , entre o receptor e o satélite, conforme mostrado na Equação (2.2).

$$\begin{aligned}
 \rho &= c(t_1 + \delta_s - t_0 - \delta_r) \\
 &= c(t_1 - t_0) + c(\delta_s - \delta_r) \\
 &= r + c(\delta_s - \delta_r)
 \end{aligned} \quad (2.2)$$

Como a distância calculada na Equação (2.2) contém erros, ela não reflete a real distância geométrica entre o satélite e o receptor. Por conta disso, o termo pseudodistância é comumente utilizado na literatura para indicar a distância estimada pelo receptor.

A Equação (2.2) pode também ser expressa na forma de coordenadas cartesianas utilizando o sistema de referência *Earth-Centered, Earth-Fixed* (ECEF), conforme mostrado na Equação (2.3).

$$\rho = \sqrt{(x_s - x_r)^2 + (y_s - y_r)^2 + (z_s - z_r)^2} + c(\delta_s - \delta_r) \quad (2.3)$$

onde (x_s, y_s, z_s) representa a posição do satélite e (x_r, y_r, z_r) representa a posição do receptor.

Devido ao fato do relógio do satélite ser altamente preciso quando comparado a um relógio utilizado em um receptor, pode-se considerar que o erro δ_s é muito menor que o erro δ_r . Nesse caso, a Equação (2.3) pode ser expressa na forma da Equação (2.4) [17].

$$\rho = \sqrt{(x_s - x_r)^2 + (y_s - y_r)^2 + (z_s - z_r)^2} + c\delta_r \quad (2.4)$$

Para que um receptor possa determinar sua posição em três dimensões na superfície da Terra, é necessário que ele receba sinais diretamente de, no mínimo, quatro satélites do sistema de GNSS utilizado. Em outras palavras, é necessário que o receptor tenha linha de visada – do inglês, *Line of sight* (LOS) – com tais satélites. Dessa forma, a Equação (2.4) pode ser expandida para o conjunto de equações (2.5).

$$\rho_1 = \sqrt{(x_{s,1} - x_r)^2 + (y_{s,1} - y_r)^2 + (z_{s,1} - z_r)^2} + c\delta_r \quad (2.5a)$$

$$\rho_2 = \sqrt{(x_{s,2} - x_r)^2 + (y_{s,2} - y_r)^2 + (z_{s,2} - z_r)^2} + c\delta_r \quad (2.5b)$$

$$\rho_3 = \sqrt{(x_{s,3} - x_r)^2 + (y_{s,3} - y_r)^2 + (z_{s,3} - z_r)^2} + c\delta_r \quad (2.5c)$$

$$\rho_4 = \sqrt{(x_{s,4} - x_r)^2 + (y_{s,4} - y_r)^2 + (z_{s,4} - z_r)^2} + c\delta_r \quad (2.5d)$$

onde $(x_{s,i}, y_{s,i}, z_{s,i})$ representa a posição em três dimensões do i -ésimo satélite visível.

O conjunto de equações (2.5) forma um sistema de equações não lineares que podem ser resolvidas para as quatro variáveis não conhecidas $(x_r, y_r, z_r, \delta_r)$ utilizando uma variedade de técnicas numéricas. Uma possível solução envolve a linearização das equações de pseudodistância aplicando aproximação de Série de Taylor [8].

2.3.2 Erros e interferências em sinais de GNSS

Além dos erros de relógio do satélite e do receptor, outros erros podem também interferir no cálculo da posição:

- *Erros de órbita*: erros decorrentes de variação na posição do satélite na órbita terrestre;
- *Ruído no receptor*: este tipo de erro está ligado ao hardware e software utilizado no receptor. Em geral, quanto mais tecnologicamente avançado é o receptor, menor é o ruído.

Os sinais transmitidos pelos satélites também podem sofrer interferências ao longo da propagação, conforme mostrado na Figura 2.8. Tais interferências são descritas a seguir:

- *Refração*: fenômeno que ocorre quando o sinal atravessa as camadas ionosfera e troposfera;
- *Obstrução*: caracteriza-se por objetos na superfície da Terra, tais como edifícios, túneis e pontes, os quais impedem a chegada do sinal ao receptor;
- *Reflexão*: caracteriza-se pela chegada ao receptor de sinais que foram refletidos em objetos existentes na superfície da Terra, por exemplo, edifícios. Essa interferência é denominada de multipercurso.

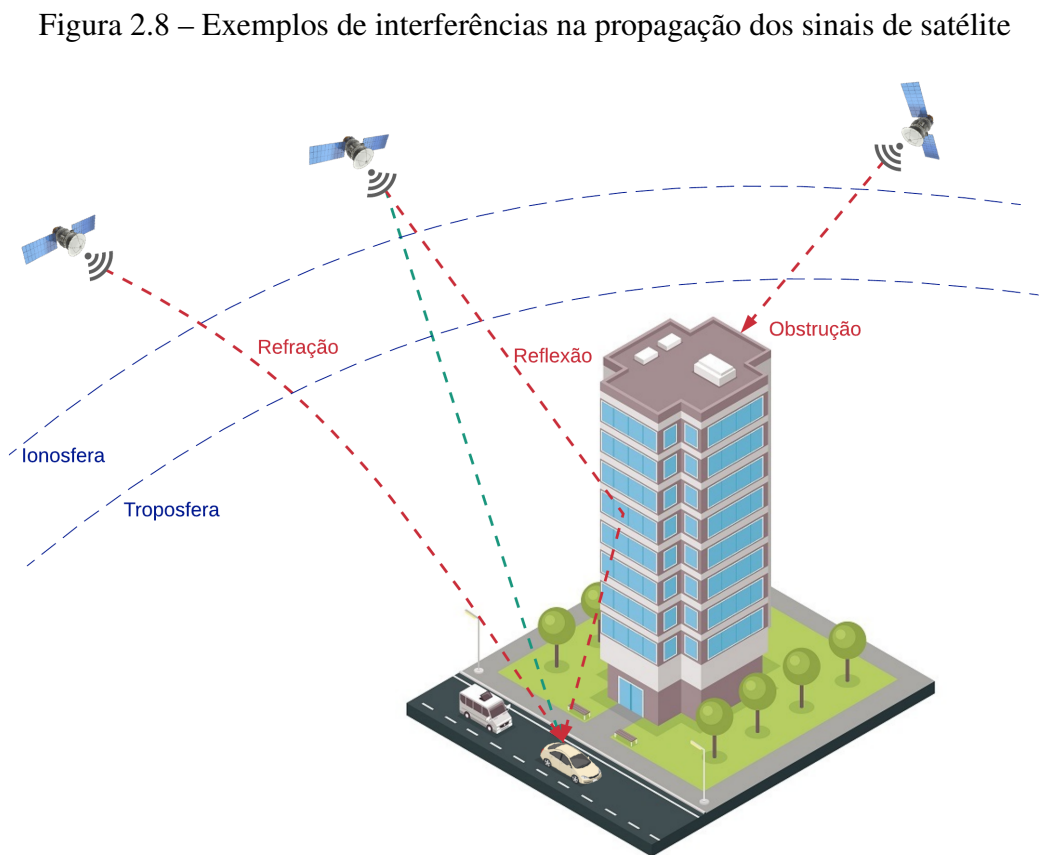


Figura 2.8 – Exemplos de interferências na propagação dos sinais de satélite

Fonte: Elaborada pelo autor.

Crédito: Imagem do prédio elaborada por macrovector / Freepik.

Com exceção da obstrução, cujo sinal sequer chega ao receptor, a refração e a reflexão interferem no tempo de propagação do sinal, o que também influencia no cálculo da pseudo-distância que o receptor realiza. Consequentemente, a posição calculada pelo receptor pode não corresponder à posição exata em que ele está.

Os sinais que chegam ao receptor por conta de interferências de multipercurso são denominados em inglês de *Non LOS* (NLOS).

2.4 SISTEMA DE NAVEGAÇÃO INERCIAL

Um Sistema de Navegação Inercial – *Inertial Navigation System* (INS) é um sistema capaz de determinar a posição, a velocidade e a orientação de um objeto em movimento ao longo do tempo [18]. O INS utiliza métodos de navegação estimada (do inglês, *dead reckoning*), a qual determina a posição corrente do objeto a partir da distância percorrida e da direção seguida por ele em relação a uma localização inicial [19].

Em geral, as medições em um INS são realizadas por um sensor denominado de IMU, o qual é dotado de acelerômetros e giroscópios, que medem, respectivamente, a aceleração linear e a velocidade angular em cada um dos três eixos ortogonais. A partir dos dados da IMU, um INS pode determinar os movimentos realizados por um veículo.

O número de movimentos independentes que o veículo realiza é chamado de graus de liberdade (do inglês, *degrees of freedom*). No contexto de veículos autônomos, costuma-se utilizar seis graus de liberdade, sendo três movimentos de rotação em torno dos eixos X, Y e Z, e três movimentos de translação ao longo desses eixos. Aqui se está considerando o sistema de eixos de referência do veículo definido conforme a norma ISO 8855:2011 [20], de forma que os eixos X e Z são paralelos ao plano longitudinal de simetria do veículo e apontam, respectivamente, para a frente e para cima, enquanto o eixo Y é perpendicular a esse plano e aponta para a esquerda do veículo.

Os movimentos de rotação são denominados em inglês de *yaw* (em torno do eixo Z), *pitch* (em torno do eixo Y) e *roll* (em torno do eixo X). Já os de translação são denominados em inglês de *heave* (ao longo do eixo Z), *surge* (ao longo do eixo X) e *sway* (ao longo do eixo Y) [21].

Sistemas baseados em métodos de *dead reckoning*, como é o caso de INS, apresentam algumas limitações. Uma delas é justamente o fato de depender de um ponto de referência inicial. Outro problema crítico é que, diferentemente dos sistemas de GNSS, onde os erros de posicionamento não se acumulam ao longo do tempo, os erros no cálculo da posição vão sendo acumulados a cada nova medição dos sensores inerciais. Como as estimativas da posição e da orientação feitas pelo INS dependem de dupla integração da aceleração e de in-

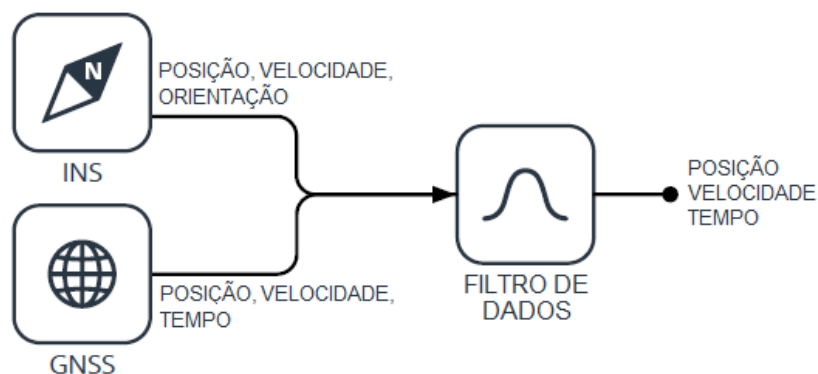
tegração simples da velocidade angular, respectivamente, ocorre um crescimento quadrático do erro de estimação da posição e um crescimento linear do erro de estimação da orientação com o tempo [19].

Portanto, é comum a utilização integrada de INS e GNSS com o intuito de tirar proveito de suas características complementares, bem como, corrigir mutuamente os erros inerentes a cada um desses sistemas. Dessa forma, é possível prover uma solução de navegação mais robusta e confiável.

Conforme o nível de integração GNSS/INS, a arquitetura do sistema pode ser classificada em três categorias: acoplamento fraco (do inglês, *loose coupling*), acoplamento forte (do inglês, *tight coupling*) ou acoplamento profundo (do inglês, *deep coupling*) [22].

O acoplamento fraco, conforme mostrado na Figura 2.9, utiliza as saídas geradas pelo GNSS e pelo INS como entradas para o subsistema de fusão de dados, o qual gera então as estimativas de navegação. As saídas do subsistema de fusão não são utilizadas para efetuar qualquer modificação nos subsistemas GNSS e INS.

Figura 2.9 – Acoplamento fraco em GNSS/INS

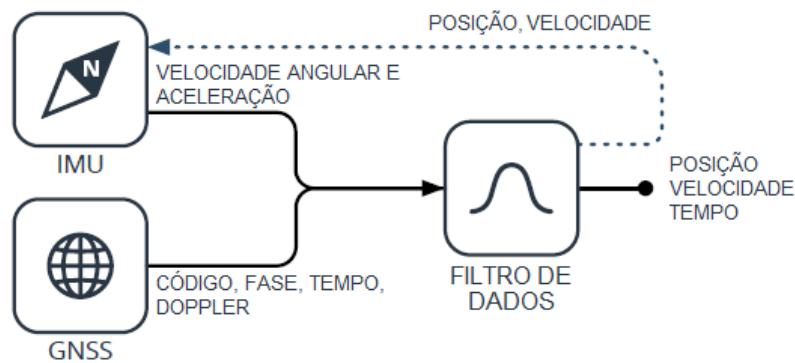


Fonte: Adaptada de [22].

No acoplamento forte, conforme mostrado na Figura 2.10, a fusão de dados é feita a partir de medições de mais baixo nível. Ou seja, ao invés do subsistema de fusão receber dados previamente processados pelo GNSS e pelo INS, tais como posição e velocidade, esse subsistema recebe dados brutos das medições dos sensores, como velocidade angular, aceleração, entre outros. Uma das vantagens desse tipo de acoplamento em relação ao fraco é que os parâmetros dos sensores do INS, como a IMU, podem ser continuamente calibrados a partir das estimativas que são geradas pelo subsistema de fusão de dados.

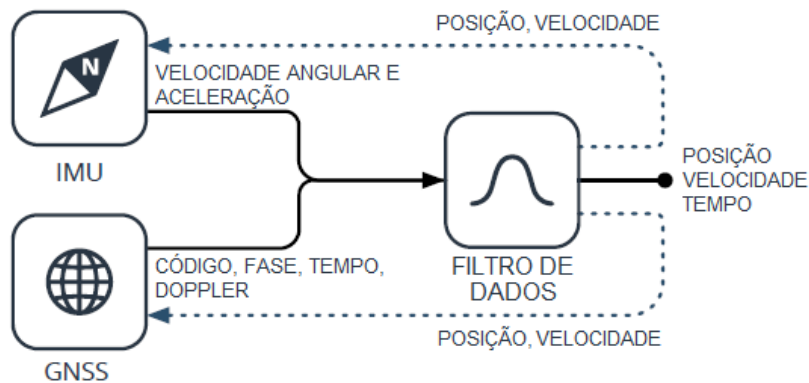
O acoplamento profundo, conforme mostrado na Figura 2.11 é bastante similar ao acoplamento forte, porém, as estimativas geradas pelo subsistema de fusão são utilizadas para recalibrar parâmetros tanto dos sensores do INS quanto do GNSS. Por exemplo, as estimativas de posição podem ser utilizadas para efetuar em um menor tempo a reaquisição de sinais no receptor após interrupções do GNSS.

Figura 2.10 – Acoplamento forte em GNSS/INS



Fonte: Adaptada de [22].

Figura 2.11 – Acoplamento profundo em GNSS/INS



Fonte: Adaptada de [22].

2.5 MAPAS DE ALTA DEFINIÇÃO

Um veículo autônomo precisa garantir confiabilidade, robustez e segurança nas mais diversas situações de trânsito. Para isso, ele precisa ser dotado de um conjunto de sensores e de tecnologia embarcada capazes de continuamente perceber e rastrear os objetos que estão a sua volta. E mais, ele precisa determinar, de forma acurada, sua localização na superfície terrestre, bem como sua localização relativa aos obstáculos estáticos e dinâmicos presentes ao longo do seu trajeto.

Uma das técnicas que podem ser adotadas para a locomoção do veículo é a técnica conhecida como Localização e Mapeamento Simultâneos – *Simultaneous Localization and Mapping* (SLAM) [23]. Ela possibilita que o veículo construa um mapa dos obstáculos em seu entorno a partir dos dados obtidos dos seus sensores de percepção, como câmera, LiDAR e radar, e, simultaneamente, utilize esse mapa para se autolocalizar.

Apesar de ser bastante utilizada na área de robótica, essa técnica demanda elevado custo computacional para processamento de imagens de câmera e nuvens de pontos do LiDAR. Além disso, como cada sensor possui limitações em termos das medições que ele pode rea-

lizar, a percepção e a localização do veículo podem ser afetadas, em maior ou menor grau, dependendo dos sensores utilizados. Por exemplo, o veículo pode ter dificuldades em detectar objetos que estejam distantes ou, então, objetos cuja detecção seja prejudicada por estarem obstruídos, parcial ou integralmente, por algum obstáculo [24].

Para minimizar esses problemas, os chamados Mapas de Alta Definição (do inglês, *High-Definition Maps* ou, de forma mais sucinta, *HD Maps*) têm se tornado elementos fundamentais na direção autônoma, já que eles podem prover informações sobre o ambiente em torno do veículo sem ser afetados pelas limitações de percepção em tempo real dos sensores. Além disso, eles também podem fornecer entradas críticas para outros componentes do veículo, como localização, planejamento de movimento, controle do veículo, suporte a ADAS, entre outros [25].

Diferentemente de um mapa digital construído para utilização por seres humanos, que normalmente tem informações limitadas sobre as vias e cuja acurácia pode girar em torno de alguns metros, um *HD Map* precisa fornecer informações geométricas com acurácia da ordem de centímetros. Ele também precisa descrever semanticamente a rede viária, suas regras de trânsito e os elementos que a circundam, para que, dessa forma, possa efetivamente atender aos requisitos de segurança necessários a um veículo autônomo.

Conforme descrito em [26], os elementos que compõem um *HD Map* podem ser classificados em três tipos: objetos estáticos, dispositivos de controle de tráfego e geometria da estrada. Um objeto estático representa algo que o veículo pode colidir, como edifícios, paredes, árvores, postes e barreiras. Os dispositivos de controle de tráfego podem fornecer informações sobre as regras de tráfego que devem ser seguidas na estrada, como marcações na superfície da estrada, lombadas, placas de trânsito e semáforos. A geometria da rodovia fornece informações que devem ser seguidas por veículos para chegar ao destino desejado e pode ser representada por polilinhas, curvas polinomiais ou *splines*.

A estrutura de um *HD Map*, conforme descrita em [27], pode ser dividida em três camadas lógicas: o modelo da estrada (*Road Model*), o modelo de faixa (*Lane Model*) e o modelo de localização (*Localization Model*).


O modelo da estrada representa a rede viária e está ligado ao suporte à navegação. Atributos normalmente representados nessa camada são o tipo da estrada, a curvatura, a elevação e as ligações entre as seções e vias. O tipo da estrada representa o propósito principal dela, por exemplo, rodovia, estrada rural, etc. Dependendo da especificação, a curvatura pode ser representada por uma linha de pontos ou pode ter sua geometria definida matematicamente.

O modelo de faixa engloba atributos que descrevem as faixas da estrada, provendo informações detalhadas e acuradas para suporte à percepção e ao planejamento tático do veículo, por exemplo, na execução de manobras. Atributos geralmente presentes nesse modelo descrevem o tipo da faixa, as linhas que separam as faixas, marcações horizontais na pista,

sentido da faixa, regulamentações do trânsito, conectividade entre as faixas, entre outros. No caso das regulamentações do trânsito, os atributos podem descrever aspectos válidos para a estrada como um todo ou para cada faixa específica. Por exemplo, em alguns países há estradas com diferentes limites de velocidade por faixa.

Com relação à conectividade entre as faixas, é possível definir as ligações virtuais, as quais são relevantes em cruzamentos de vias largas. A Figura 2.12 mostra um exemplo de um cruzamento entre vias e, representadas na cor azul, as possíveis ligações virtuais entre as diversas faixas.

Figura 2.12 – Representação de faixas virtuais em um cruzamento



Fonte: Elaborada pelo autor.

O modelo de localização contém recursos georreferenciados que podem ser utilizados como apoio à localização do veículo no *HD Map*. Tais recursos englobam objetos estáticos localizados à margem da via, tais como sinais de trânsito, *guardrails* e postes. Para auxiliar na localização do veículo, eles devem ser combinados, de forma confiável, com os dados de imagens e nuvens de pontos coletados a partir dos sensores de percepção, como câmeras e LiDAR, bem como com os dados de pose do veículo obtidos a partir dos sensores inerciais.

2.5.1 Navigation Data Standard (NDS)


Em termos de especificação de *HD Maps*, é possível encontrar modelos tanto proprietários quanto abertos. O *Navigation Data Standard* (NDS), por exemplo, é um padrão da indústria desenvolvido por um consórcio de grandes empresas dos setores automotivo, de mapeamento e de telecomunicações [28]. Por ser um padrão fechado, somente os membros desse consórcio podem utilizá-lo em suas soluções.

O armazenamento e processamento dos dados no NDS utiliza uma versão adaptada do *SQLite*, um banco de dados relacional, de código aberto, desenvolvido em linguagem C e que é bastante utilizado em sistemas embarcados. A Figura 2.13 mostra uma visão geral

da estrutura dos dados no NDS. Os dados de mapeamento e navegação são divididos em regiões. Cada região contém os chamados *building blocks*, que são equivalentes ao conceito de camadas, conforme definido em [27]. Os *building blocks* são compostos por unidades menores chamadas de *tiles*. A organização dos dados em regiões permite às empresas oferecer soluções específicas para cada mercado. Além disso, os dados de cada região podem ser atualizados de forma independente [29].

Os *tiles* correspondem a células no mapa. A organização do mapa como uma grade de células possibilita melhor eficiência em termos de consulta e atualização dos dados de mapeamento e navegação. Por exemplo, durante um deslocamento, somente é necessário buscar no banco os *tiles* que estão nas imediações da rota a ser seguida pelo veículo. Já no caso de necessidade de atualização das informações do mapa, é possível atualizar apenas os *tiles* que sofreram alguma modificação, não sendo, portanto, necessário atualizar o mapa por inteiro [30].

Figura 2.13 – Visão geral da estrutura de dados do NDS

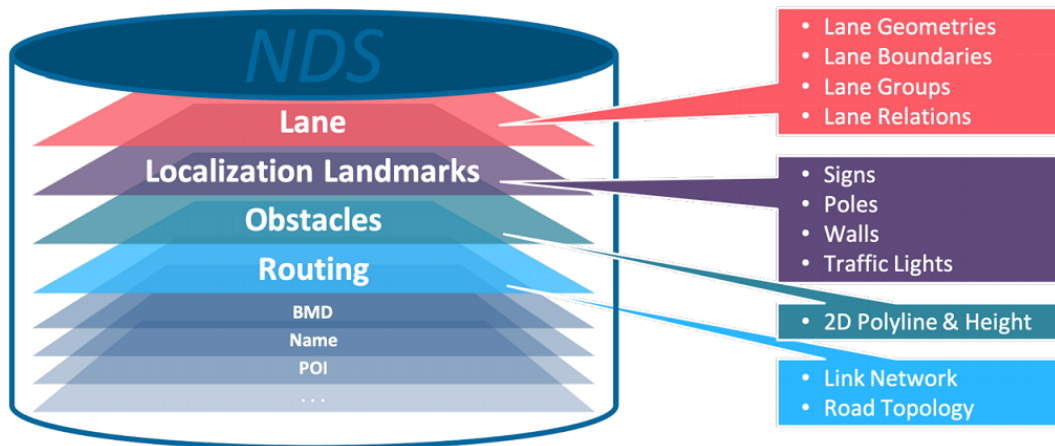


Fonte: [29].

Embora o NDS tenha sido inicialmente projetado para atender necessidades de navegação, atualmente ele fornece *building blocks* que foram incorporados ao modelo para representar *HD Maps* e, assim, fornecer suporte a ADAS e veículos autônomos [31]. Conforme mostrado na Figura 2.14, quatro *building blocks* foram incluídos na estrutura do NDS para atender às necessidades de automação.

O *Lane building block* contém atributos para descrição das faixas, como geometria, linhas de divisão entre as faixas, marcações horizontais na pista, etc. Essa camada equivale ao modelo de faixa descrito em [27]. Já o *Localization Landmarks* e o *Obstacles* equivalem ao modelo de localização definido por [27], ambos descrevendo objetos ao longo da via que podem ser utilizados para auxiliar na localização do veículo. O primeiro descreve objetos como semáforos, placas de trânsito e postes, enquanto o segundo fornece estruturas para modelar obstáculos às margens da via, como *guardrails*, paredes, cercas, etc. O *Routing building block*, por sua vez, define atributos para descrever a estrada, correspondendo ao modelo de estrada definido por [27].

Figura 2.14 – *Building blocks* do NDS para *HD Maps*



Fonte: [31].

Embora o NDS seja um modelo proprietário, há uma versão não comercial, porém, com recursos limitados, chamada de *Open Lane Model* [32].

2.5.2 OpenDRIVE

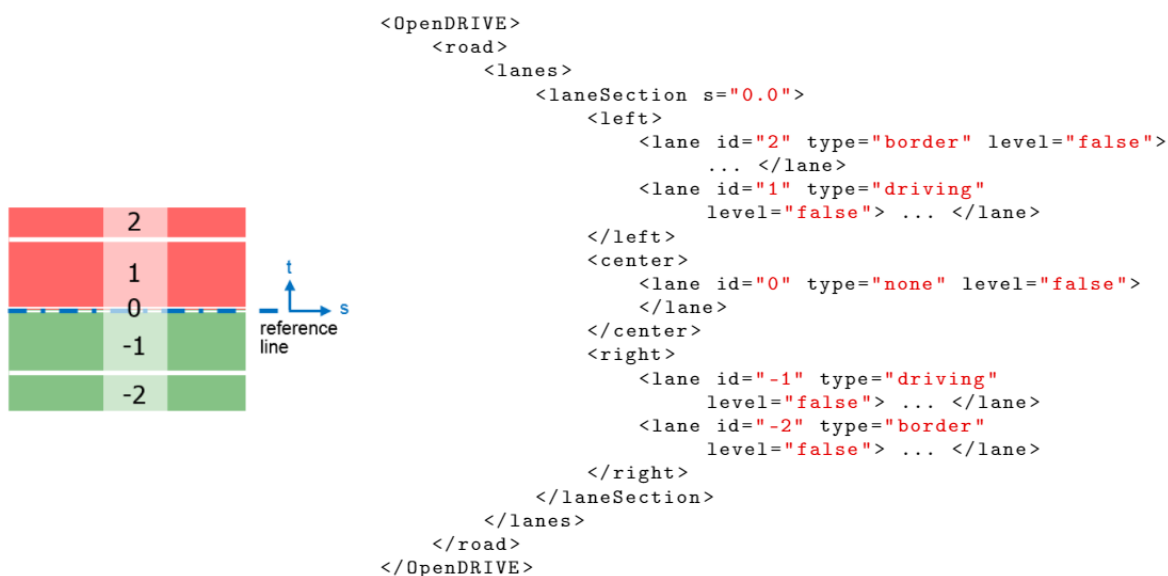
Com relação a modelos abertos, tem destaque o padrão de indústria chamado OpenDRIVE [33]. Diferentemente do NDS, onde a estrutura dos dados é representada na forma de camadas, no OpenDRIVE é utilizada uma estrutura hierárquica no formato *Extensible Markup Language* (XML) para descrever os elementos da rede viária, como estradas, faixas, sinalizações, etc. Seu foco principal são as ferramentas de simulação, sendo utilizado, por exemplo, no simulador de veículos autônomos CARLA [34].

A Figura 2.15 mostra um exemplo de descrição de uma via usando o formato OpenDRIVE. Por questões de simplicidade, alguns detalhes foram subtraídos. Nessa descrição pode-se observar a definição de uma estrada contendo cinco faixas. A faixa central, identificada com o valor 0, serve apenas como referência para a numeração das demais faixas e não tem largura. As faixas à esquerda da central são numeradas com valores em ordem crescentes no sentido positivo do eixo t , enquanto as faixas à direita da central são numeradas em ordem decrescente no sentido negativo do eixo t . As faixas numeradas com -1 e 1 estão representadas com o tipo *driving*, o que indica que o tráfego de veículos é permitido. Já as faixas numeradas com -2 e 2 estão representadas com o tipo *border*, indicando que elas são faixas de acostamento.

2.5.3 Lanelet2

Outro modelo para a especificação de *HD Maps* de código aberto é o chamado *Lanelet2* [35]. Esse modelo utiliza o formato XML definido pelo *OpenStreetMap* e estabelece

Figura 2.15 – Exemplo de código no OpenDRIVE



Fonte: Elaborada pelo autor.

cinco elementos para construir um mapa: pontos, linhas, *lanelets*, áreas e elementos regulatórios.

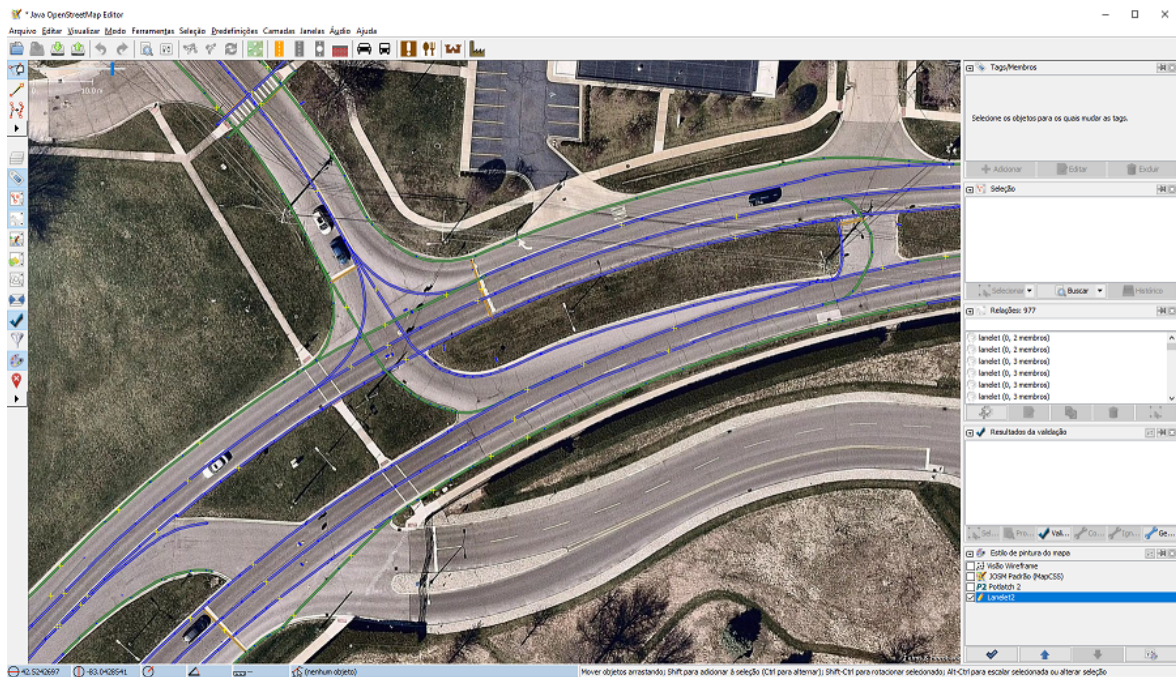
Os pontos são os elementos básicos de um mapa, a partir dos quais os outros elementos são constituídos. O ponto é o único elemento que tem informação de posição, a qual é definida pelas suas coordenadas tridimensionais. Eles podem ser utilizados tanto de forma única, por exemplo, para representar um poste, quanto de forma conjunta na composição de linhas. As linhas são elementos compostos por uma sequência de dois ou mais pontos. Elas podem ser utilizadas para representar as bordas das faixas, as marcações na pista, áreas, etc.

Os elementos chamados de *lanelets* são seções no mapa onde podem ocorrer movimentos direcionados, incluindo não somente faixas para trânsito de veículos, mas também locais de travessia de pedestres e trilhos de trem. Esses elementos têm seus limites definidos por duas linhas, uma à esquerda e outra à direita. Já as áreas são constituídas por polígonos, ou seja, um conjunto de linhas que delimitam um local ou região. Em geral, são utilizadas para representar áreas de estacionamento, parques, quadras, prédios, etc.

Por último, os elementos regulatórios especificam as regras de trânsito, como limite de velocidade, semáforos, regras de preferência, linhas de parada, etc. Esses elementos podem ser referenciados tanto por *lanelets* quanto por áreas. Além disso, eles podem ser dinâmicos, ou seja, podem representar regras de trânsito que são válidas apenas em um determinado período do dia ou em condições específicas.

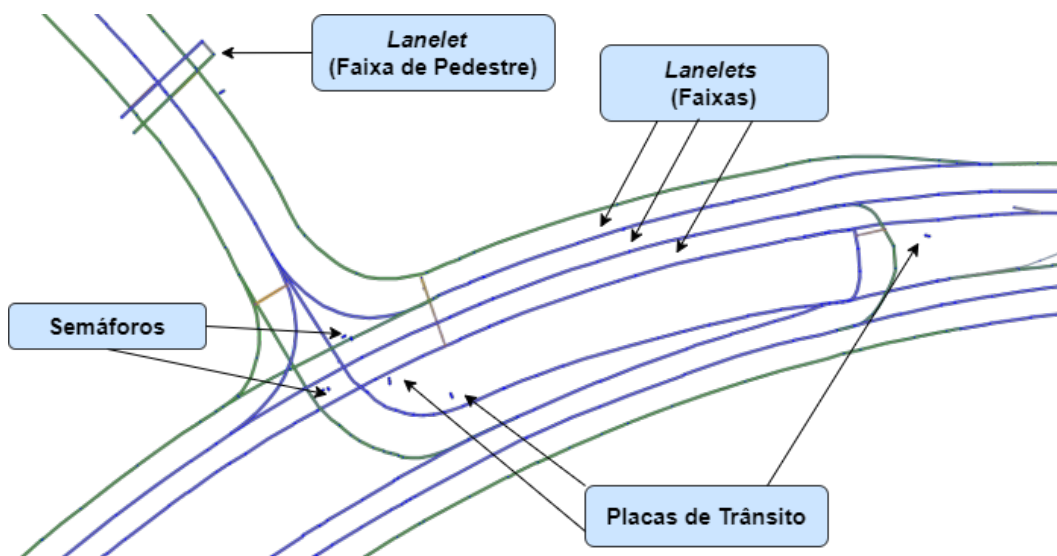
A Figura 2.16 mostra a visualização na ferramenta *Java OpenStreetMap Editor (JOSM)* de um *HD Map* construído com os elementos do *Lanelet2*. Para simplificar a visualização, a Figura 2.17 mostra os pontos e linhas contidos no mapa da Figura 2.16, e o que representam.

Figura 2.16 – Visualização de elementos do *Lanelet2* na ferramenta JOSM



Fonte: Elaborada pelo autor.

Figura 2.17 – Visualização de elementos do *Lanelet2* e indicação do que eles representam



Fonte: Elaborada pelo autor.

Com base nos elementos básicos, um mapa no *Lanelet2* é estruturado em três camadas lógicas: física, relacional e topológica. A camada física é composta pelos pontos e linhas definidos no mapa. A camada relacional engloba os *lanelets*, áreas e elementos regulatórios, ou seja, elementos que são constituídos a partir da interconexão daqueles contidos na camada física. Por fim, a camada topológica é resultante das relações e interconexões que podem ser estabelecidas entre os elementos da camada relacional. Por exemplo, quais faixas se conectam entre si, quais faixas são exclusivas para determinados tipos de veículos, etc.

2.5.4 Mapas Dinâmicos

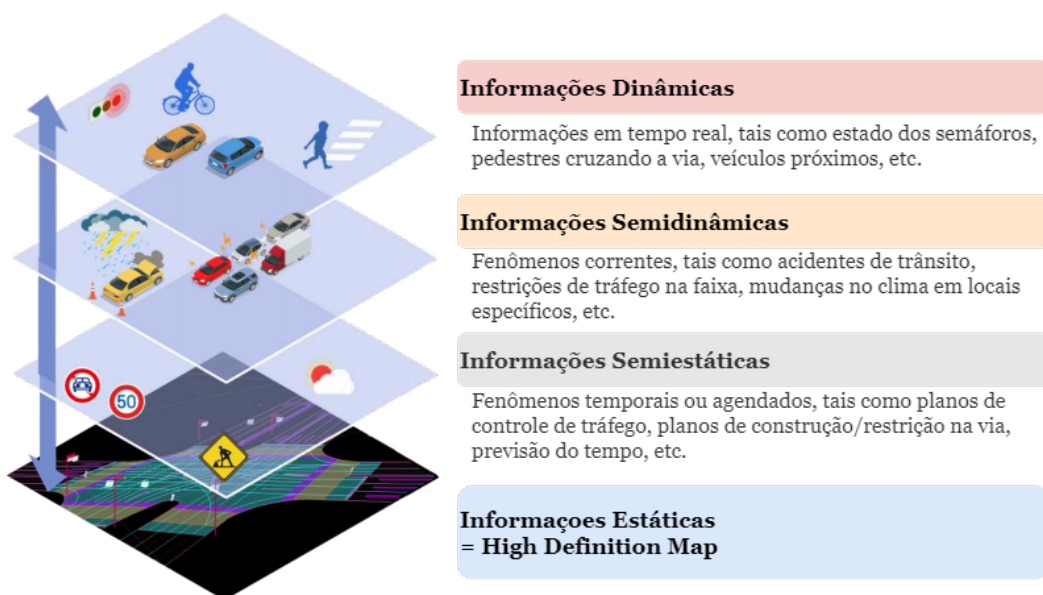
O mapeamento acurado dos elementos estáticos da rede viária na forma de *HD Maps* pode contribuir significativamente para tornar a localização do veículo mais robusta e confiável. Contudo, apenas o mapeamento dos objetos estáticos presente nesses mapas não garante a segurança necessária à locomoção e à realização de manobras de veículos autônomos, devido à possibilidade de ocorrência de eventos temporais e dinâmicos ao longo da via.

Nesse sentido, os *HD Maps* podem servir como uma camada de suporte sobre a qual podem ser sobrepostas camadas que representam informações dinâmicas providas por um Sistema de Transporte Inteligente – *Intelligent Transport System* (ITS).

A Figura 2.18, baseada em um projeto que vem sendo desenvolvido desde 2014 no Japão, envolvendo representantes da indústria, governo e academia, apresenta um modelo chamado de Mapas Dinâmicos. Nesse modelo, há a presença de três camadas sobrepostas à camada estática representada pelos *HD Maps*.

A camada denominada semiestática envolve informações referentes a fenômenos que ocorrem de forma periódica, como informações climáticas em um determinado período do ano, ou eventos agendados, como obstruções na via para a realização de obras. A camada de informações semidinâmicas provê informações sobre eventos correntes no sistema viário, como acidentes de trânsito, restrições em uma via ou faixa, chuvas em pontos específicos, etc. Já a camada de informações dinâmicas é responsável por prover dados em tempo real, tais como o estado dos semáforos, pedestres cruzando a via, veículos próximos, etc.

Figura 2.18 – Representação das camadas de um Mapa Dinâmico



Fonte: Adaptada de [36].

3 ESTIMAÇÃO DE LOCALIZAÇÃO PARA VEÍCULOS AUTÔNOMOS USANDO RECEPTORES DE GNSS BASEADOS EM ARRANJO DE ANTENAS E TÉCNICAS TENSORIAIS

Este capítulo está relacionado aos objetivos específicos OE1, OE2 e OE3, conforme descritos na Seção 1.2 deste documento. Ele apresenta uma proposta de um método robusto para estimação de localização para veículos autônomos baseada na aplicação de técnicas tensoriais sobre os dados obtidos a partir de receptores de GNSS compostos por arranjos de antenas. Tal proposta visa minimizar os erros de localização nos receptores, especialmente, em cenários urbanos, onde a presença de prédios, árvores e outros objetos pode causar interferências nos sinais recebidos dos satélites. Inicialmente, serão apresentadas técnicas tensoriais utilizadas para a mitigação de interferências de multipercorso. Em seguida, será apresentada uma visão geral da técnica de estimação de estado conhecida como Filtro de Kalman Estendido, a qual tem sido amplamente utilizada no contexto de veículos autônomos. Por fim, serão apresentados os resultados alcançados com a utilização do método de estimação proposto.

3.1 TÉCNICAS TENSORIAIS PARA MITIGAÇÃO DE INTERFERÊNCIAS DE MULTIPERCURSO

A interferência denominada de multipercorso acontece quando o sinal do GNSS sofre reflexão em objetos existentes na superfície da Terra, tais como edifícios, árvores, entre outros. Dessa forma, múltiplos componentes do sinal podem chegar ao receptor com atraso maior no tempo de propagação, conseqüentemente, fazendo com que o receptor gere uma estimação incorreta de sua posição. Esse é um tipo de problema bastante comum em grandes cidades, onde a existência de avenidas com prédios altos formam os chamados cânions urbanos [37].

Ao longo dos últimos anos, diversas soluções têm sido propostas com o intuito de mitigar os efeitos da interferência de multipercorso e estimar o tempo de atraso do sinal LOS de um satélite com melhor acurácia. Para o contexto deste trabalho, o foco será nas soluções propostas que buscam explorar a estrutura multidimensional dos dados de GNSS, conside-

rando a dimensão espacial devido ao uso de arranjo de antenas e as dimensões temporais de amostragem e periodicidade. Dessa forma, é possível representar tal estrutura como um tensor de terceira ordem e, conseqüentemente, utilizar técnicas tensoriais para filtragem de sinais, mitigando, assim, os efeitos decorrentes do multipercurso.

Nesse cenário, algumas premissas precisam ser estabelecidas. Considera-se que há D satélites visíveis. O receptor GNSS é formado por um Arranjo Linear Uniforme de Antenas – *Uniform Linear Array* (ULA), composto por M elementos. As observações são coletadas durante K períodos (também chamados de épocas), cada uma com N amostras. Para cada satélite d , assume-se L_d sinais recebidos, sendo um sinal LOS e $L_d - 1$ componentes NLOS. O número total de sinais recebidos, incluindo seus componentes de multipercurso, é dado por $L = \sum_{d=1}^D L_d$.

Para a aplicação de técnicas tensoriais para a filtragem de sinais, é necessário estabelecer um modelo de dados de pré-correlação que represente o tensor de recepção. Conforme apresentado em [38], o sinal gerado na saída dos M elementos do arranjo de antenas pode ser representado por um tensor de terceira ordem, conforme mostrado na Equação (3.1).

$$\mathcal{X} = \mathcal{I}_{3,L} \times_1 \tilde{\mathbf{\Gamma}}^T \times_2 \tilde{\mathbf{C}}^T \times_3 \tilde{\mathbf{A}} + \mathcal{N} \in \mathbb{C}^{K \times N \times M}, \quad (3.1)$$

onde $\mathcal{I}_{3,L} \in \mathbb{C}^{L \times L \times L}$ corresponde ao tensor identidade de terceira ordem, $\tilde{\mathbf{\Gamma}}^T \in \mathbb{C}^{K \times L}$ é a matriz de amplitudes de cada componente do sinal, $\tilde{\mathbf{C}}^T \in \mathbb{R}^{N \times L}$ é a matriz de códigos de Ruído Pseudo-Aleatório – *Pseudorandom Noise* (PRN), $\tilde{\mathbf{A}} \in \mathbb{C}^{M \times L}$ é a matriz de respostas, e \mathcal{N} é o tensor de ruído branco gaussiano de terceira ordem.

O modelo de dados de pós-correlação é caracterizado pela aplicação de um banco de correladores correspondente a cada satélite, com o objetivo de separar o sinal LOS dos componentes NLOS decorrentes de multipercurso. Um banco de correladores correspondente ao d -ésimo satélite \mathbf{Q}_d é uma matriz que possui Q réplicas deslocadas do código $\mathbf{c}_d \in \mathbb{R}^N$ com atraso τ_q , $q = 1, \dots, Q$, conforme mostrado na Equação (3.2).

$$\mathbf{Q}_d = [\mathbf{c}_d[\tau_1] \dots \mathbf{c}_d[\tau_Q]] \in \mathbb{R}^{N \times Q}, \quad (3.2)$$

onde $\tau_1 < \dots < \tau_Q$.

Dado que a aplicação direta do banco de correladores \mathbf{Q}_d transforma o ruído branco em colorido, se faz necessária a utilização de um banco comprimido gerado a partir de uma versão reduzida do método *Singular Value Decomposition* (SVD), chamada de *Thin SVD*. Dessa forma, é possível realizar a correlação cruzada preservando as estatísticas do ruído. O banco de correladores comprimido é mostrado na Equação (3.3).

$$\mathbf{Q}_\omega^{(d)} = \mathbf{Q}_d (\mathbf{\Sigma} \mathbf{V}^H)^{-1} \in \mathbb{R}^{N \times Q} \quad (3.3)$$

A transposta do banco de correladores comprimido $\mathbf{Q}_\omega^{(d)}$ é utilizada, então, para correlacionar o sinal recebido, representado pelo tensor \mathcal{X} , de forma a separar o sinal do d -ésimo satélite dos demais sinais dos outros satélites. Com isso, efetuando o produto modo-2 dessa transposta com a Equação (3.1), tem-se o modelo de dados de pós-correlação, conforme mostrado na Equação (3.4).

$$\begin{aligned}
\mathcal{Y} &= \mathcal{X} \times_2 (\mathbf{Q}_\omega^{(d)})^T \\
&= \mathcal{I}_{3,L_d} \times_1 \mathbf{\Gamma}^T \times_2 (\mathbf{CQ}_\omega^{(d)})^T \times_3 \mathbf{A} + \mathcal{N} \times_2 (\mathbf{Q}_\omega^{(d)})^T + \mathcal{M} \\
&= \mathcal{I}_{3,L_d} \times_1 \mathbf{\Gamma}^T \times_2 (\mathbf{CQ}_\omega^{(d)})^T \times_3 \mathbf{A} + \mathcal{N}_\omega + \mathcal{M} \\
&\approx \mathcal{I}_{3,L_d} \times_1 \mathbf{\Gamma}^T \times_2 (\mathbf{CQ}_\omega^{(d)})^T \times_3 \mathbf{A} + \mathcal{N}_\omega,
\end{aligned} \tag{3.4}$$

onde $\mathcal{I}_{3,L_d} \in \mathbb{C}^{L_d \times L_d \times L_d}$ é o tensor identidade, $\mathbf{\Gamma}^T \in \mathbb{C}^{K \times L_d}$ é a matriz de amplitudes complexas dos L_d componentes do sinal do d -ésimo satélite obtido a partir da matriz $\tilde{\mathbf{\Gamma}}^T$, $(\mathbf{CQ}_\omega^{(d)})^T \in \mathbb{R}^{N \times L_d}$ é a matriz de fatores de códigos correlacionados, $\mathbf{A} \in \mathbb{C}^{M \times L_d}$ é a matriz de L_d respostas dos sinais do d -ésimo satélite obtida a partir de $\tilde{\mathbf{A}}$, e $\mathcal{N}_\omega \in \mathbb{C}^{K \times Q \times M}$ é o tensor de ruído branco gaussiano após a correlação.

O tensor \mathcal{M} representa a interferência de acesso múltiplo de outros satélites e seus respectivos componentes de multipercurso. Entretanto, esse tensor não foi levado em consideração no trabalho desenvolvido em [38], tendo em vista que o objetivo era mitigar o efeito dos $L_d - 1$ componentes NLOS correspondentes a cada satélite separadamente.

A partir do modelo de dados de pós-correlação \mathcal{Y} especificado na Equação (3.4), é possível derivar abordagens tanto matriciais quanto tensoriais para a estimação do atraso de tempo do sinal LOS dos satélites.

Com o intuito de auxiliar na escolha da técnica mais adequada ao contexto de veículos autônomos, foi feita uma análise do estado da arte das técnicas tensoriais propostas para estimação do atraso de tempo do sinal LOS. Os artigos utilizados nessa análise foram [39], [40], [41], [42] e [43]. Esses artigos tomaram como base um conjunto de simulações para realizar a estimação do atraso de tempo.

A Tabela 3.1 apresenta um resumo dos principais parâmetros e valores utilizados nas simulações realizadas nesses artigos. A coluna M representa a quantidade de elementos sensores do arranjo de antenas, L é a quantidade de componentes LOS e NLOS que chegam ao receptor, N é o número de amostras coletadas por época, K corresponde ao número de épocas e MC indica o total de simulações Monte Carlo realizadas.

No trabalho descrito em [39], os autores utilizaram diferentes abordagens para mitigar os efeitos dos componentes NLOS e estimar o atraso de tempo do sinal LOS. Em termos de abordagem tensorial, os autores empregaram o algoritmo *Higher Order Singular Value Decomposition* (HOSVD). Além disso, para separar os componentes altamente correlacionados

Tabela 3.1 – Parâmetros das Simulações para Estimação de Atraso de Tempo de Sinal LOS

Artigo	Sistema	Sinal	Frequência	Bandwidth	M	L	N	K	MC
[39]	GPS	C/A	L1	1023 MHz	8	2	2046	30	2000
[40]	GPS	C/A	L1	1023 MHz	8	2	2046	30	2000
[41]	GPS	C/A	L1	1023 MHz	8	2	2046	30	2000
[42]	GPS	C/A, L1C	L1	12276 MHz	8	2	245520	30	2000
[43]	GPS	C/A, L1C	L1	12276 MHz	8	3	245520	30	2000

Fonte: Elaborada pelo autor.

do sinal, os autores também utilizaram combinações com métodos de pré-processamento *Forward-Backward Averaging* (FBA), *Spatial Smoothing* (SPS) e *Expanded Spatial Smoothing* (ESPS). Também foi feita a utilização de uma abordagem matricial, assim como a combinação dessa com os métodos FBA e SPS.

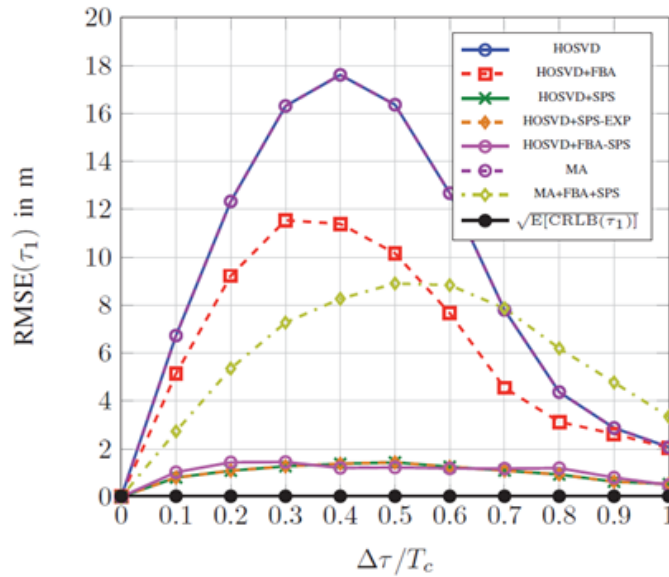
A Figura 3.1 mostra os resultados das simulações realizadas pelos autores. Os valores referentes a $\Delta\tau/T_c$ indicam a diferença do atraso de tempo entre o sinal LOS e os componentes NLOS. Em geral, $\Delta\tau/T_c \approx [0, 0.2]$ indica que o sinal LOS e os componentes NLOS estão fortemente correlacionados, enquanto $\Delta\tau/T_c \approx [0.8, 1]$ indica que esses sinais estão fracamente correlacionados. Observa-se, pelo gráfico, que os valores mais elevados de erro para as abordagens que utilizam tensores ocorrem quando $\Delta\tau/T_c \approx [0.3, 0.5]$. No caso do uso do algoritmo HOSVD apenas, o erro máximo foi de aproximadamente 18 m. Com a inclusão do método de pré-processamento FBA, o erro máximo foi reduzido para pouco menos de 12 m. Já com relação ao uso do HOSVD combinado com SPS e com ESPS, assim como a combinação conjunta com FBA e SPS, observa-se uma diminuição expressiva do erro, que ficou em torno de 1.8 m.

Por outro lado, observando o comportamento da abordagem matricial, nota-se que o erro máximo foi de aproximadamente 18 m quando $\Delta\tau/T_c = 0.4$, vindo a ter uma redução para 9 m quando $\Delta\tau/T_c \approx [0.5, 0.6]$ com o uso combinado dos métodos de pré-processamento FBA e SPS.

No trabalho descrito em [40], os autores propuseram uma abordagem tensorial para a mitigação dos efeitos de multipercurso baseada no algoritmo *Canonical Polyadic Decomposition by a Generalized Eigenvalue Decomposition* (CPD-GEVD). Segundo os autores, uma das vantagens no uso do CPD-GEVD é seu baixo custo computacional na decomposição de tensores. Esse algoritmo foi utilizado para estimar as matrizes de fatores tanto dos códigos correlacionados quanto das amplitudes complexas dos sinais. Para estimar o atraso de tempo do sinal LOS, dois esquemas podem ser utilizados: baseado em maior potência do sinal ou baseado no menor atraso.

Para avaliar o desempenho do CPD-GEVD, os autores também realizaram simulações utilizando duas outras abordagens tensoriais: HOSVD, com FBA e ESPS como técnicas de

Figura 3.1 – RMSE da estimação do atraso de tempo do sinal LOS. Comparação envolvendo as técnicas HOSVD, HOSVD+FBA, HOSVD+SPS, HOSVD+ESPS, HOSVD+FBA+SPS, MA e MA+FBA+SPS



Fonte: Adaptada de [39].


pré-processamento, e *Direction of Arrival and Khatri-Rao Factorization* (DoA/KRF), com FBA e SPS como técnicas de pré-processamento.

A Figura 3.2 mostra os resultados das simulações realizadas pelos autores para o caso de um arranjo de antenas ideal, sem erros. Observa-se que o erro utilizando a técnica combinada HOSVD+FBA+ESPS oscilou entre 0.8 e 0.83 m, apresentando um pico quando $\Delta\tau/T_c = 0.45$. Enquanto isso, a técnica combinada DoA/KRF+FBA+SPS e a abordagem proposta CPD-GEVD tiveram um desempenho similar, mantendo-se ambas com erro em torno de 0.675 m.

A Figura 3.3, por sua vez, mostra os resultados das simulações realizadas pelos autores para o caso de um arranjo de antenas com erros em sua geometria. Nesse caso, os autores definem como erro o valor que excede a metade de um comprimento de onda. É possível observar que o CPD-GEVD mostrou-se robusto às imperfeições do arranjo, ao passo que HOSVD+FBA+ESPS e DoA/KRF+FBA+SPS foram afetados. No primeiro caso, o erro máximo aumentou para pouco mais de 1.8 m quando $\Delta\tau/T_c = 0.45$. Na segunda abordagem, o erro máximo subiu para 1.4 m quando $\Delta\tau/T_c = 0.45$.


No trabalho descrito em [41], a abordagem tensorial para a mitigação dos efeitos de multipercursos proposta pelos autores foi baseada no algoritmo *Procrustes estimation and Khatri-Rao factorization* (ProKRaft). Segundo os autores, a abordagem é baseada em um algoritmo iterativo que alterna entre o Problema Ortogonal de Procrustes e a fatoração de mínimos quadrados do *Khatri-Rao* para separar, simultaneamente, as matrizes de fator da

Figura 3.2 – RMSE da estimação do atraso de tempo do sinal LOS para um arranjo de antenas sem erros. Comparação envolvendo as técnicas HOSVD+FBA+ESPS, DoA/KRF+FBA+SPS e CPD-GEVD



Fonte: Adaptada de [40].

Figura 3.3 – RMSE da estimação do atraso de tempo do sinal LOS para um arranjo de antena com erro em sua geometria. Comparação envolvendo as técnicas HOSVD+FBA+ESPS, DoA/KRF+FBA+SPS e CPD-GEVD




Fonte: Adaptada de [40].

direção de chegada e das amplitudes complexas. De posse dessas matrizes, é possível filtrar as sequências de código PRN e estimar o atraso de tempo para os componentes LOS e NLOS.

Similar ao trabalho apresentado em [40], para avaliar o desempenho do ProKRaft, os autores também realizaram simulações com as abordagens tensoriais HOSVD+FBA+ESPS e DoA/KRF+FBA+SPS.

A Figura 3.4 mostra os resultados das simulações realizadas pelos autores com uma diferença do ângulo de azimute de $\Delta\phi = \pi/3$. Observa-se que o erro utilizando a técnica combinada HOSVD+FBA+ESPS oscilou entre 0.74 e 0.79 m, apresentando seu ponto máximo quando $\Delta\tau/T_c = 0.45$. A técnica combinada DoA/KRF+FBA+SPS apresentou um erro consistente em torno de 0.64 m. Já a abordagem proposta ProKRaft teve um erro máximo de 0.64 m quando $\Delta\tau/T_c \approx [0.65, 1]$ e mostrou um melhor desempenho quando $\Delta\tau/T_c \approx [0.1, 0.4]$, com erro em torno de 0.625 m.

Figura 3.4 – RMSE da estimação do atraso de tempo do sinal LOS. Comparação envolvendo as técnicas HOSVD+FBA+ESPS, DoA/KRF+FBA+SPS e ProKRaft




Fonte: Adaptada de [41].

O trabalho desenvolvido em [42] utilizou tanto a abordagem tensorial CPD-GEVD como a HOSVD+FBA+ESPS em simulações envolvendo sinais de satélites de terceira geração do sistema GPS. Uma característica dessa geração é que ela incorporou a transmissão do quarto sinal civil, denominado de L1C, além de uma nova técnica de modulação, chamada *Time Multiplexed Binary Offset Carrier* (TMBOC), os quais buscam prover melhorias na recepção de sinais GPS em cenários urbanos, minimizando, assim, os efeitos dos componentes de multipercurso [44].

A Figura 3.5 mostra os resultados das simulações realizadas pelos autores utilizando um arranjo de antenas e a abordagem tensorial CPD-GEVD. Tais simulações foram realizadas

tanto para o sinal civil legado *Coarse Acquisition (C/A)*, transmitido pelos satélites da segunda geração, quanto para o sinal L1C da terceira geração. Observa-se que, no caso da segunda geração, o erro máximo foi de aproximadamente 0.08 m, ao passo que para o caso da terceira geração, o erro ficou em torno de 0.076 m.

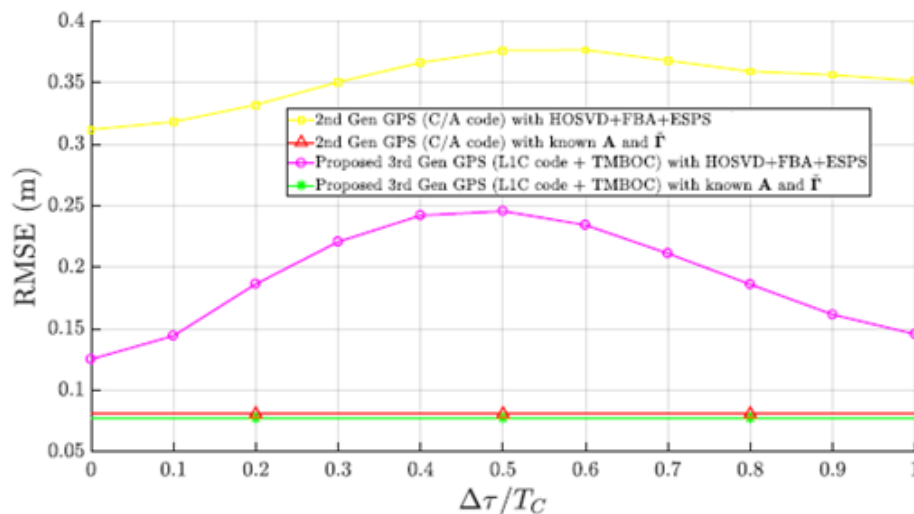
Figura 3.5 – RMSE da estimação do atraso de tempo do sinal LOS. Comparação envolvendo a técnica CPD-GEVD em sinais de GPS de segunda e terceira gerações



Fonte: Adaptada de [42].

Os autores também realizaram simulações semelhantes àquelas feitas com a abordagem CPD-GEVD, só que utilizando a abordagem combinada HOSVD+FBA+ESPS. A Figura 3.6 apresenta os resultados alcançados. Observa-se que, no caso da segunda geração, o erro varia entre 0.3 e 0.37 m, com o valor máximo ocorrendo quando $\Delta\tau/T_c \approx [0.5, 0.6]$. Já no caso da terceira geração, o erro máximo é de 0.24 m, ocorrendo quando $\Delta\tau/T_c = 0.5$.

Figura 3.6 – RMSE da estimação do atraso de tempo do sinal LOS. Comparação envolvendo a técnica HOSVD+FBA+ESPS em sinais de GPS de segunda e terceira gerações




Fonte: Adaptada de [42].

No trabalho [43], para realizar a estimação do atraso de tempo de sinal GPS de segunda e terceira geração, os autores propuseram a utilização da técnica Estrutura Semi-Algébrica para Decomposição Poliádica Canônica Aproximada através de Diagonalizações Simultâneas para Estimação de Atraso – *Semi-algebraic framework for approximate Canonical Polyadic Decompositions via Simultaneous Matrix Diagonalizations* (SECSI), em conjunto com HOSVD. Nas simulações contidas nesse trabalho, os autores fizeram comparações da abordagem proposta com outras técnicas do estado-da-arte para estimação de atraso: HOSVD+FBA+ESPS, DoA/KRF e CPD-GEVD.

A Figura 3.7 apresenta os resultados das simulações realizadas para as quatro abordagens para GPS de segunda geração. É possível observar que a técnica proposta pelos autores utilizando HOSVD+SECSI apresenta um erro próximo a 0.08 m, similar ao valor alcançado com o uso de DoA/KRF. A técnica CPD-GEVD também atinge esse valor, porém, no intervalo $\Delta\tau/T_c \approx [0.5, 0.6]$. Já no caso de sinais fortemente correlacionados, CPD-GEVD tem erro máximo de 0.2 m quando $\Delta\tau/T_c = 0.2$. A técnica combinada HOSVD+FBA+ESPS, por sua vez, apresenta um erro consistente em torno de 0.28 m.

Figura 3.7 – RMSE da estimação do atraso de tempo do sinal LOS. Comparação envolvendo as técnicas HOSVD+FBA+ESPS e CPD-GEVD em sinais de GPS de segunda geração




Fonte: Adaptada de [43].

A Figura 3.8 apresenta os resultados de erro para as simulações das técnicas utilizando GPS de terceira geração. Observa-se que tanto a abordagem proposta quanto DoA/KRF têm um erro em torno de 0.08 m, com HOSVD+SECSI apresentando uma pequena variação quando $\Delta\tau/T_c = 0$. Observa-se ainda que tanto HOSVD+FBA+ESPS quanto CPD-GEVD apresentam melhoria nos resultados quando comparado ao uso com GPS de segunda geração. Tal fato pode ser atribuído ao uso da modulação TMBOC na terceira geração, o que permite uma melhor separação espacial dos sinais e, conseqüentemente, melhora o desempenho em cenários de multipercurso. No caso de HOSVD+FBA+ESPS, o erro máximo ficou próximo

a 0.13 m. Já o erro com o uso da técnica CPD-GEVD foi de 0.15 m quando $\Delta\tau/T_c = 0$ e manteve-se em torno de 0.08 m para $\Delta\tau/T_c \geq 0.1$.

Figura 3.8 – RMSE da estimação do atraso de tempo do sinal LOS. Comparação envolvendo as técnicas HOSVD+FBA+ESPS e CPD-GEVD em sinais de GPS de terceira geração



Fonte: Adaptada de [43].

3.2 ESTIMAÇÃO DE ESTADO E FILTRO DE KALMAN ESTENDIDO

A descrição de um sistema dinâmico, seja linear ou não, é fundamentada na noção de estado, o qual é caracterizado como a menor quantidade de dados que se deve saber sobre o comportamento passado do sistema para prever seu comportamento futuro [45]. O estado refere-se, portanto, a um conjunto mínimo de variáveis capaz de descrever matematicamente o sistema. Considerando um automóvel movimentando-se em um plano, por exemplo, variáveis como as coordenadas de sua posição e sua velocidade seriam integrantes do conjunto de variáveis de estado.

Os valores das variáveis de estado podem ser determinados a partir de medições, em geral, realizadas por meio de sensores. No entanto, lidar com medições é lidar com incertezas. Até mesmo os sensores mais avançados possuem algum nível de imprecisão ou podem sofrer interferências durante suas medições. Além disso, nem sempre é possível obter os valores das variáveis de estado por medições, seja por conta de limitações físicas ou por questões de custo dos sensores [46].

Para minimizar os efeitos dessas incertezas, é necessário trabalhar com estimações. De maneira geral, a estimação do estado de um sistema pode ser definida como o processo de atribuir valores a variáveis de estado com base nas medições desse sistema e de acordo com determinados critérios. Normalmente, o processo é baseado em métodos estatísticos, que

estimam o valor da variável de forma a minimizar ou maximizar o critério selecionado [47].

Os métodos estatísticos para lidar com incertezas, em geral, são baseados no Filtro de Bayes. No entanto, o surgimento do Filtro de Kalman [45] como um framework para estimar o estado de um sistema na presença de medições com ruído trouxe um impacto significativo, em especial, porque ele possibilitou atingir níveis de acurácia elevados em um tempo menor e com redução considerável no uso de recursos computacionais quando comparado com outras soluções de filtragem à época.

Uma das aplicações práticas mais emblemáticas do Filtro de Kalman foi na estimação de trajetória de navegação do módulo lunar no programa Apollo 11 da *National Aeronautics and Space Administration* (NASA). No entanto, pelo fato da proposição original do Filtro de Kalman levar em consideração sistemas com modelo linear, adaptações tiveram que ser realizadas pela equipe da NASA para que o filtro pudesse ser utilizado em sistemas não lineares. Tais adaptações resultaram no que ficou conhecido como Filtro de Kalman Estendido – *Extended Kalman Filter* (EKF) [48].

Durante os estudos realizados para aplicação do Filtro de Kalman no programa Apollo 11, as seguintes inovações foram incorporadas: (i) demonstração de que a teoria original de Kalman poderia ser adaptada para problemas não lineares, (ii) linearização em torno da melhor estimativa do estado do sistema, de maneira a reduzir os efeitos das não linearidades, e (iii) decomposição do algoritmo original em duas partes separadas, predição (*time-update* ou *prediction*) e atualização (*measurement-update* ou *update*), de forma que as medições pudessem ser processadas em qualquer intervalo de tempo arbitrário [48]. Tais inovações resultaram na extensão do Filtro de Kalman que é conhecida como EKF.

Para o contexto deste trabalho, será considerado o problema de estimação do estado de um sistema dinâmico, não linear, estocástico e discreto.

Inicialmente, faz-se necessário descrever o mundo real por meio de um conjunto de equações diferenciais não lineares de primeira ordem, conforme mostrado, respectivamente, pelas equações (3.5a) e (3.5b) [46].

$$\mathbf{x}_k = \mathbf{f}(\mathbf{x}_{k-1}, \mathbf{u}_k) + \mathbf{w}_k \quad (3.5a)$$

$$\mathbf{y}_k = \mathbf{h}(\mathbf{x}_k) + \mathbf{v}_k \quad (3.5b)$$

Na Equação (3.5a), \mathbf{x}_k representa o vetor de estado do sistema e $\mathbf{f}(\cdot)$ corresponde à função vetorial cujos elementos são funções não lineares que descrevem as variáveis do estado do sistema. O vetor \mathbf{u}_k corresponde ao vetor de entradas externas de controle e \mathbf{w}_k é o ruído do processo.

Já com relação à Equação (3.5b), \mathbf{y}_k é o vetor de saída, a função $\mathbf{h}(\cdot)$ corresponde à função vetorial não linear das medições e \mathbf{v}_k é o ruído das medições.

Assume-se aqui que o ruído do processo tem distribuição gaussiana com média zero e covariância \mathbf{Q} , conforme a Equação (3.6a), ao passo que o ruído das medições também tem distribuição gaussiana com média zero e covariância \mathbf{R} , conforme a Equação (3.6b).

$$p(\mathbf{w}) \sim \mathcal{N}(0, \mathbf{Q}) \quad (3.6a)$$

$$p(\mathbf{v}) \sim \mathcal{N}(0, \mathbf{R}) \quad (3.6b)$$

As matrizes de covariância \mathbf{Q} e \mathbf{R} são dadas, respectivamente, pelas equações (3.7a) e (3.7b).

$$\mathbf{Q} = E[\mathbf{w}\mathbf{w}^T] \quad (3.7a)$$

$$\mathbf{R} = E[\mathbf{v}\mathbf{v}^T] \quad (3.7b)$$

Assume-se que o vetor de estado do sistema não tem correlação com os ruídos do processo e das medições, bem como os ruídos não têm correlação entre si, conforme as equações (3.8a), (3.8b) e (3.8c).

$$E[\mathbf{x}\mathbf{w}^T] = 0 \quad (3.8a)$$

$$E[\mathbf{x}\mathbf{v}^T] = 0 \quad (3.8b)$$

$$E[\mathbf{w}\mathbf{v}^T] = 0 \quad (3.8c)$$

A Figura 3.9 apresenta uma visão geral do funcionamento do EKF. Por questões de notação, será utilizado o índice $k|k-1$ para se referir à estimação no k -ésimo instante de tempo (posterior), dada a estimação no instante $k-1$ (anterior).

A entrada inicial para o filtro é representada pela estimativa do estado inicial, $\hat{\mathbf{x}}_0$, e pela matriz de covariância desse estado, \mathbf{P}_0 , que representa a incerteza inicial. A matriz \mathbf{Q} , por sua vez, representa a matriz de covariância do ruído do processo.

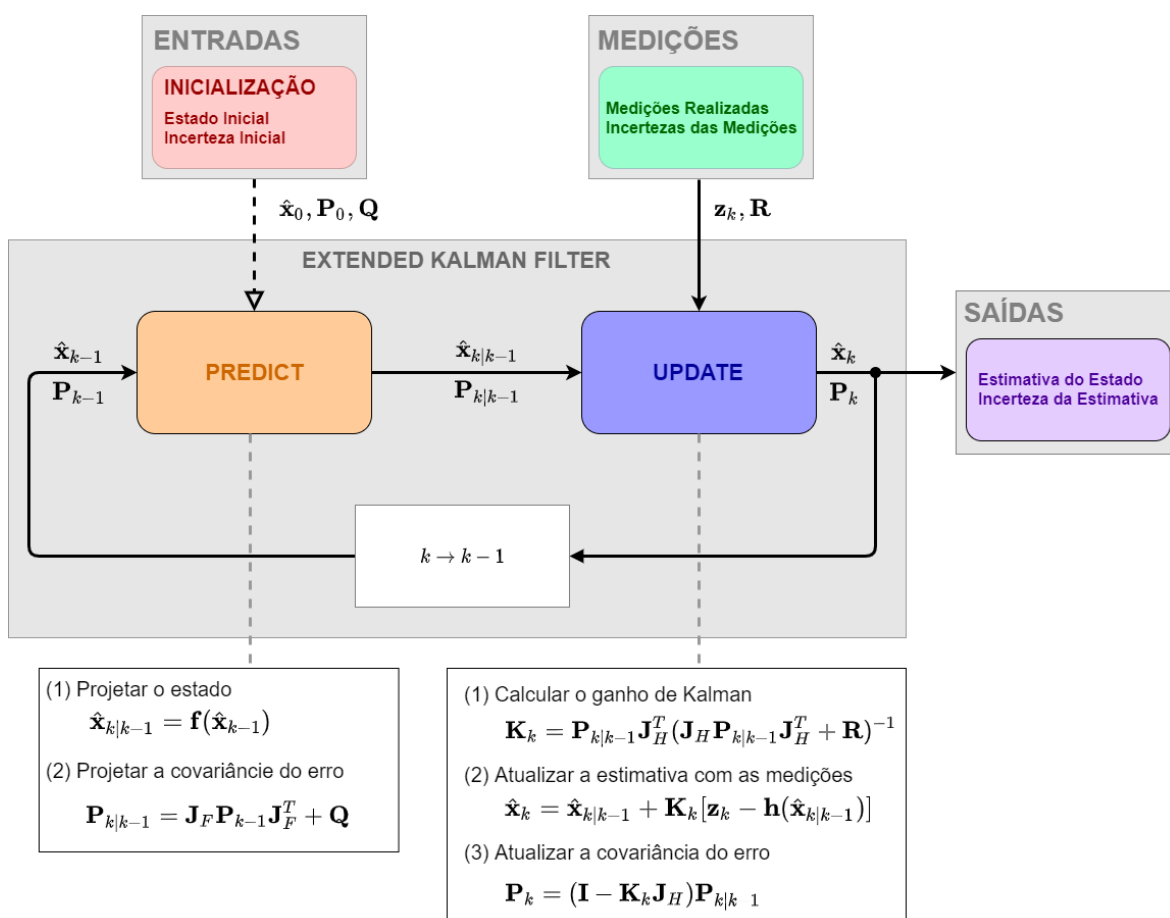
A etapa de predição (*Predict*) é responsável por projetar o vetor de estado e a covariância com base nas estimações feitas na etapa anterior, $\hat{\mathbf{x}}_{k-1}$ e \mathbf{P}_{k-1} . Ou seja, $\hat{\mathbf{x}}_{k|k-1}$ e $\mathbf{P}_{k|k-1}$ correspondem às predições, respectivamente, do estado e da covariância para o k -ésimo instante de tempo, dada a informação da estimação no instante $k-1$.

O vetor de estado da etapa de predição é calculado pela função vetorial $\mathbf{f}(\cdot)$, que representa o processo não linear, conforme a Equação (3.9).

$$\hat{\mathbf{x}}_{k|k-1} = \mathbf{f}(\hat{\mathbf{x}}_{k-1}) \quad (3.9)$$

Pelo fato de $\mathbf{f}(\cdot)$ ser uma função não linear, não é possível aplicá-la diretamente no cálculo

Figura 3.9 – Visão Geral do Filtro de Kalman Estendido



Fonte: Elaborada pelo autor.

da matriz de covariância $\mathbf{P}_{k|k-1}$. Nesse caso, é necessário fazer a linearização da função em torno da melhor estimativa do estado. Tal linearização pode ser obtida com o uso de matriz Jacobiana, a qual é composta pelas derivadas parciais de primeira ordem da função $\mathbf{f}(\cdot)$ em relação às variáveis do vetor de estado, conforme mostrado em (3.10).

$$\mathbf{J}_F = \left. \frac{\partial \mathbf{f}}{\partial \mathbf{x}} \right|_{\hat{\mathbf{x}}_{k-1}} = \begin{bmatrix} \frac{\partial f_1}{\partial x_1} & \dots & \frac{\partial f_1}{\partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial f_n}{\partial x_1} & \dots & \frac{\partial f_n}{\partial x_n} \end{bmatrix} \quad (3.10)$$

Dessa forma, pode-se utilizar a matriz Jacobiana \mathbf{J}_F no cálculo da matriz de incerteza, $\mathbf{P}_{k|k-1}$, referente à predição do estado, conforme mostrado na Equação (3.11).

$$\mathbf{P}_{k|k-1} = \mathbf{J}_F \mathbf{P}_{k-1} \mathbf{J}_F^T + \mathbf{Q} \quad (3.11)$$

A etapa de atualização (*Update*) é responsável por gerar a estimativa do estado com base nos valores da predição e das medições realizadas.

Inicialmente, é preciso estabelecer o chamado ganho de Kalman, \mathbf{K} , o qual é calculado conforme a Equação (3.12).

$$\mathbf{K}_k = \mathbf{P}_{k|k-1} \mathbf{J}_H^T (\mathbf{J}_H \mathbf{P}_{k|k-1} \mathbf{J}_H^T + \mathbf{R})^{-1}, \quad (3.12)$$

onde \mathbf{R} representa a matriz de covariância das medições e \mathbf{J}_H denota a matriz Jacobiana da função de medição $\mathbf{h}(\cdot)$, composta pelas derivadas parciais de primeira ordem da função $\mathbf{h}(\cdot)$ em relação às variáveis do vetor de estado, conforme mostrado na Equação (3.13).

$$\mathbf{J}_H = \left. \frac{\partial \mathbf{h}}{\partial \mathbf{x}} \right|_{\hat{\mathbf{x}}_{k|k-1}} = \begin{bmatrix} \frac{\partial h_1}{\partial x_1} & \dots & \frac{\partial h_1}{\partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial h_m}{\partial x_1} & \dots & \frac{\partial h_m}{\partial x_n} \end{bmatrix} \quad (3.13)$$

O vetor de estado estimado no instante k a partir da predição e das medições realizadas é calculado pela Equação (3.14).

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k [\mathbf{z}_k - \mathbf{h}(\hat{\mathbf{x}}_{k|k-1})], \quad (3.14)$$

onde \mathbf{z}_k representa o vetor das medições realizadas no instante k .

A covariância do erro da estimação é, então, calculada conforme a Equação (3.15).

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{J}_H) \mathbf{P}_{k|k-1}, \quad (3.15)$$

onde \mathbf{I} representa a matriz identidade.

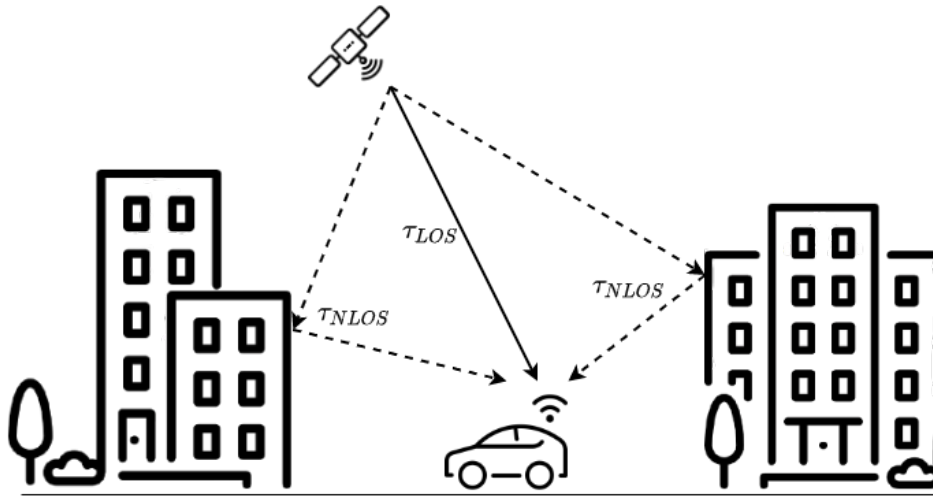
3.3 ESTIMAÇÃO DO ERRO DE POSICIONAMENTO DE UM VEÍCULO

Apesar da modernização tecnológica pela qual os diferentes sistemas de GNSS vêm passando ao longo do tempo, a acurácia da estimação da pseudodistância entre o receptor e cada satélite ainda é bastante impactada em cenários urbanos. Conseqüentemente, a estimação da posição do veículo também é afetada. Isso se dá principalmente pela interferência de multipercurso provocada pela reflexão dos sinais em edifícios e outras estruturas presentes ao longo das vias.

A Figura 3.10 apresenta um cenário no qual um receptor de GNSS instalado em um veículo recebe um sinal transmitido por um satélite localizado na órbita da Terra. O componente LOS representa o sinal de linha de visada recebido diretamente do satélite. Já os componentes NLOS representam os sinais recebidos decorrentes de interferências de multipercurso.

Dado que o sinal gerado pelo satélite sofre atraso de tempo até chegar à superfície da Terra, τ_{LOS} corresponde ao atraso do componente LOS, enquanto os valores de τ_{NLOS} referem-se ao atraso de cada componente NLOS. De uma maneira geral, $\tau_{LOS} \leq \tau_{NLOS}$.

Figura 3.10 – Receptor GNSS do veículo recebendo os componentes LOS and NLOS de uma transmissão via satélite



Fonte: Elaborada pelo autor.

Com o intuito de apresentar uma proposta para melhoria da estimação de posicionamento de veículos autônomos, uma implementação do método EKF foi desenvolvida, incorporando o uso de receptores de GNSS baseados em arranjo de antenas e técnicas tensoriais para estimação de atraso de tempo dos sinais LOS dos satélites. Os resultados alcançados foram publicados previamente em [49] e estão detalhados neste capítulo.

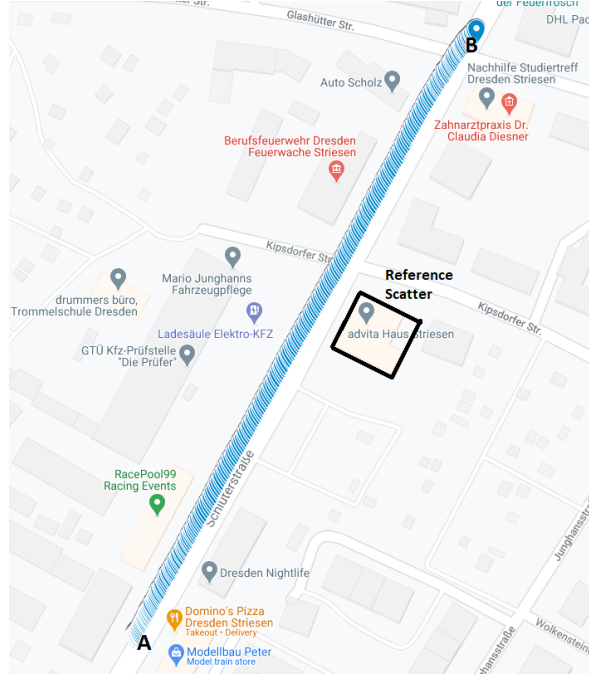
A Figura 3.11 apresenta o cenário da simulação, no qual há um veículo movendo-se do ponto A em direção ao ponto B. A distância entre esses dois pontos é de 250m, aproximadamente. O arquivo com os dados de medições contém, no total, 1.300 medições obtidas com o uso de um receptor de GNSS e uma IMU. Um prédio ao lado da via foi considerado na simulação como um ponto de referência, denotado por *Reference Scatter*, capaz de gerar reflexão dos sinais transmitidos pelos satélites.

A taxa de amostragem do receptor de GNSS é de 10Hz enquanto o IMU opera em 50Hz. Com isso, ocorre uma medição do receptor de GNSS a cada cinco medições do IMU. O receptor de GNSS fornece a latitude, longitude, altitude, velocidade e direção (*heading*) do veículo. Latitude e longitude estão representados em graus decimais, altitude em metros, velocidade em metros por segundo (m/s) e direção em graus. As medições realizadas com o IMU são a velocidade angular em torno do eixo vertical do veículo (*yaw rate*) e a aceleração. A velocidade angular é dada em graus por segundo e a aceleração em m/s^2 .

Para a modelagem do sistema dinâmico deste trabalho, foi definido um vetor de estado composto de seis variáveis: posições x e y , direção (ψ), velocidade (v), velocidade angular

$(\dot{\psi})$ e aceleração longitudinal (a), conforme mostrado em (3.16).

Figura 3.11 – Cenário de simulação com veículo se deslocando do ponto A para o ponto B. A simulação considera um ponto de referência capaz de refletir os sinais transmitidos pelos satélites



Fonte: Elaborada pelo autor.

Crédito: Imagem do mapa obtida do Google Maps, ©2019.

$$\mathbf{x}_k = \begin{bmatrix} x_k \\ y_k \\ \psi_k \\ v_k \\ \dot{\psi}_k \\ a_k \end{bmatrix} \quad (3.16)$$

Com base na Equação (3.5a), é necessário definir a função não linear $\mathbf{f}(\cdot)$ que represente a dinâmica do sistema. Considerando o movimento de um veículo em um plano com velocidade angular ($\dot{\psi}$) e aceleração (a) constantes, tem-se o modelo de movimento do veículo representado por (3.17).

$$\mathbf{f}(\cdot) = \begin{bmatrix} x + \frac{-\dot{\psi}v \sin(\psi) - a \cos(\psi) + a \cos(T\dot{\psi} + \psi) + (T\dot{\psi}a + \dot{\psi}v) \sin(T\dot{\psi} + \psi)}{\dot{\psi}^2} \\ y + \frac{\dot{\psi}v \cos(\psi) - a \sin(\psi) + a \sin(T\dot{\psi} + \psi) + (-T\dot{\psi}a - \dot{\psi}v) \cos(T\dot{\psi} + \psi)}{\dot{\psi}^2} \\ T\dot{\psi} + \psi \\ Ta + v \\ \dot{\psi} \\ a \end{bmatrix} \quad (3.17)$$

Dada a necessidade de linearização da função $\mathbf{f}(\cdot)$ em torno da estimação, é necessário calcular a sua matriz Jacobiana. Nesse caso, aplicando a Equação (3.10) em (3.17), tem-se o cálculo da matriz Jacobiana, \mathbf{J}_F , conforme mostrado em (3.18). Os resultados das derivadas parciais estão mostrados na Equação (3.19), os quais serão utilizados no EKF.

$$\mathbf{J}_F = \begin{bmatrix} \frac{\partial f_x}{\partial x} & \frac{\partial f_x}{\partial y} & \frac{\partial f_x}{\partial \psi} & \frac{\partial f_x}{\partial v} & \frac{\partial f_x}{\partial \dot{\psi}} & \frac{\partial f_x}{\partial a} \\ \frac{\partial f_y}{\partial x} & \frac{\partial f_y}{\partial y} & \frac{\partial f_y}{\partial \psi} & \frac{\partial f_y}{\partial v} & \frac{\partial f_y}{\partial \dot{\psi}} & \frac{\partial f_y}{\partial a} \\ \frac{\partial f_\psi}{\partial x} & \frac{\partial f_\psi}{\partial y} & \frac{\partial f_\psi}{\partial \psi} & \frac{\partial f_\psi}{\partial v} & \frac{\partial f_\psi}{\partial \dot{\psi}} & \frac{\partial f_\psi}{\partial a} \\ \frac{\partial f_v}{\partial x} & \frac{\partial f_v}{\partial y} & \frac{\partial f_v}{\partial \psi} & \frac{\partial f_v}{\partial v} & \frac{\partial f_v}{\partial \dot{\psi}} & \frac{\partial f_v}{\partial a} \\ \frac{\partial f_{\dot{\psi}}}{\partial x} & \frac{\partial f_{\dot{\psi}}}{\partial y} & \frac{\partial f_{\dot{\psi}}}{\partial \psi} & \frac{\partial f_{\dot{\psi}}}{\partial v} & \frac{\partial f_{\dot{\psi}}}{\partial \dot{\psi}} & \frac{\partial f_{\dot{\psi}}}{\partial a} \\ \frac{\partial f_a}{\partial x} & \frac{\partial f_a}{\partial y} & \frac{\partial f_a}{\partial \psi} & \frac{\partial f_a}{\partial v} & \frac{\partial f_a}{\partial \dot{\psi}} & \frac{\partial f_a}{\partial a} \end{bmatrix} \quad (3.18)$$

$$\mathbf{J}_F = \begin{bmatrix} 1 & 0 & \frac{-\dot{\psi}v \cos(\psi) + a \sin(\psi) - a \sin(T\dot{\psi} + \psi) + (T\dot{\psi}a + \dot{\psi}v) \cos(T\dot{\psi} + \psi)}{\dot{\psi}^2} & \frac{-\dot{\psi} \sin(\psi) + \dot{\psi} \sin(T\dot{\psi} + \psi)}{\dot{\psi}^2} \\ 0 & 1 & \frac{-\dot{\psi}v \sin(\psi) - a \cos(\psi) + a \cos(T\dot{\psi} + \psi) - (-T\dot{\psi}a - \dot{\psi}v) \sin(T\dot{\psi} + \psi)}{\dot{\psi}^2} & \frac{\dot{\psi} \cos(\psi) - \dot{\psi} \cos(T\dot{\psi} + \psi)}{\dot{\psi}^2} \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix}$$

$$\begin{bmatrix} \frac{-T a \sin(T\dot{\psi} + \psi) + T(T\dot{\psi}a + \dot{\psi}v) \cos(T\dot{\psi} + \psi) - v \sin(\psi) + (Ta + v) \sin(T\dot{\psi} + \psi)}{\dot{\psi}^2} & \frac{2(-\dot{\psi}v \sin(\psi) - a \cos(\psi) + a \cos(T\dot{\psi} + \psi) + (T\dot{\psi}a + \dot{\psi}v) \sin(T\dot{\psi} + \psi))}{\dot{\psi}^3} \\ \frac{T a \cos(T\dot{\psi} + \psi) - T(-T\dot{\psi}a - \dot{\psi}v) \sin(T\dot{\psi} + \psi) + v \cos(\psi) + (-Ta - v) \cos(T\dot{\psi} + \psi)}{\dot{\psi}^2} & \frac{2(\dot{\psi}v \cos(\psi) - a \sin(\psi) + a \sin(T\dot{\psi} + \psi) + (-T\dot{\psi}a - \dot{\psi}v) \cos(T\dot{\psi} + \psi))}{\dot{\psi}^3} \\ T \\ 0 \\ 1 \\ 0 \end{bmatrix}$$

$$\begin{bmatrix} \frac{T\dot{\psi} \sin(T\dot{\psi} + \psi) - \cos(\psi) + \cos(T\dot{\psi} + \psi)}{\dot{\psi}^2} \\ \frac{-T\dot{\psi} \cos(T\dot{\psi} + \psi) - \sin(\psi) + \sin(T\dot{\psi} + \psi)}{\dot{\psi}^2} \\ 0 \\ T \\ 0 \\ 1 \end{bmatrix} \quad (3.19)$$

Embora o vetor de estado \mathbf{x} seja composto por seis variáveis, apenas cinco delas estão sendo medidas ao longo da trajetória do veículo: x , y , v , $\dot{\psi}$ e a . Como as medições estão linearmente relacionadas ao vetor de estado \mathbf{x} , a função vetorial $h(\cdot)$ é definida conforme a

Equação (3.20).

$$\mathbf{h}(\cdot) = \begin{bmatrix} x \\ y \\ v \\ \dot{\psi} \\ a \end{bmatrix} \quad (3.20)$$

Nesse caso, a matriz Jacobiana da função $\mathbf{h}(\cdot)$, \mathbf{J}_H , é dada pela Equação (3.21).

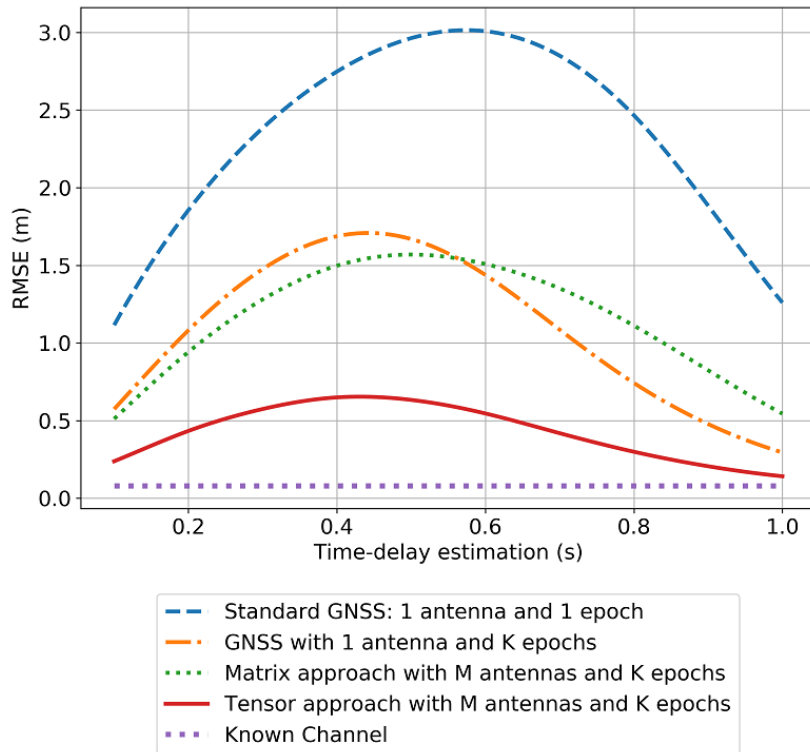
$$\mathbf{J}_H = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (3.21)$$

A Figura 3.12 mostra a Raiz do Erro Quadrático Médio – *Root Mean Square Error* (RMSE) da estimação do atraso de tempo de propagação do satélite para cinco diferentes abordagens. A curva *Standard GNSS* representa um receptor com apenas uma antena e uma observação, ou seja, sem pré-processamento dos sinais recebidos do satélite. A curva *GNSS* refere-se a um receptor onde os dados foram coletados durante K períodos, mas ainda usando apenas uma antena. A curva *Matrix* corresponde à abordagem na qual é utilizada uma técnica baseada em cálculo matricial combinada com os métodos de pré-processamento FBA e SPS. A curva *Tensor* representa a abordagem tensorial HOSVD em conjunto com os métodos FBA e ESPs para pré-processamento. A curva *Known Channel* corresponde ao caso ideal e serve como referência para o menor valor de erro em cenários com ruído.

Os valores de RMSE mostrados na Figura 3.12 foram obtidos por meio de simulação, utilizando o método Monte Carlo com a execução de 2.000 iterações. As observações foram coletadas durante $K = 30$ períodos, com cada época tendo um período de duração de $\Delta t = 10ms$. A simulação foi realizada considerando o sistema GPS de segunda geração, transmissão do código C/A, largura de banda $B_{2nd} = 12276$ MHz e Razão Sinal-Ruído – *Signal-Noise Ratio* (SNR) pós-correlação de $SNR \approx -25$ dB. Foi considerado um cenário com apenas dois caminhos ($L = 2$), com um componente LOS e um NLOS. O arranjo de antenas do receptor de GPS foi considerado como sendo do tipo ULA, composto de $M = 8$ elementos sensores. Para o caso da abordagem tensorial, dado que ela utiliza FBA e ESPs para pré-processamento, esse arranjo é dividido em subarranjos. Nesse caso, tem-se $L_S = 5$ subarranjos, cada um deles composto por $M_S = 4$ elementos sensores.

Conforme o cenário de simulação da Figura 3.11, para cada medição referente ao receptor de GPS, foi calculada a estimação do atraso de tempo do sinal LOS devido à interferência do componente NLOS, $\Delta\tau/T_c$. Cada valor do atraso de tempo obtido foi usado para determinar

Figura 3.12 – RMSE da estimação do atraso de tempo. Abordagens utilizadas na simulação: receptor GNSS padrão com 1 antena e 1 época, receptor GNSS com 1 antena e K épocas, filtragem bidimensional com abordagem matricial com M antenas e K épocas, e abordagem tensorial com M antenas e K épocas



Fonte: Elaborada pelo autor.

o erro a ser adicionado à cada medição realizada pelo receptor de GPS, utilizando, para tal, a interpolação *spline* cúbica.

Para adicionar o erro a cada posição cartesiana, x e y , do veículo, foi necessário efetuar uma conversão para coordenadas polares, adicionar o valor do erro e , em seguida, converter o valor resultante para coordenadas cartesianas novamente, conforme mostrado na Equação (3.22).

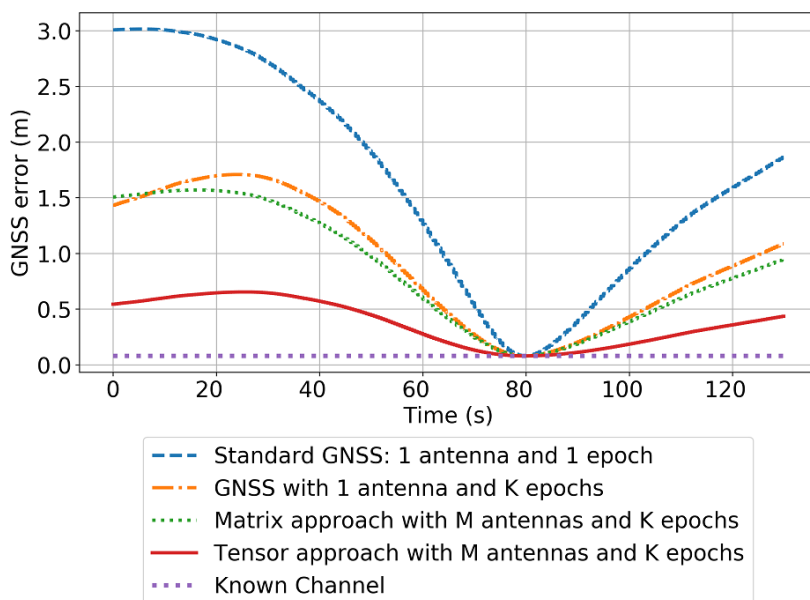
$$\begin{aligned}
 \theta &= \arctan(y, x) \\
 r &= x/\cos(\theta) \\
 x &= (r + error) * \cos(\theta) \\
 y &= (r + error) * \sin(\theta),
 \end{aligned}
 \tag{3.22}$$

onde *error* refere-se ao valor do erro correspondente à estimação do atraso de tempo do GPS.

A Figura 3.13 mostra os valores de erro adicionados ao longo do tempo durante o trajeto do veículo. Para cada uma das cinco abordagens de estimação do atraso de tempo do sinal LOS, foi executada uma implementação do algoritmo EKF, incorporando os erros às

medições do receptor de GPS e efetuando a fusão com as medições obtidas da IMU.

Figura 3.13 – Erro de posicionamento adicionado ao receptor de GPS devido ao componente NLOS. Abordagens utilizadas na simulação: receptor GNSS padrão com 1 antena e 1 época, receptor GNSS com 1 antena e K épocas, filtragem bidimensional com abordagem matricial com M antenas e K épocas, e abordagem tensorial com M antenas e K épocas

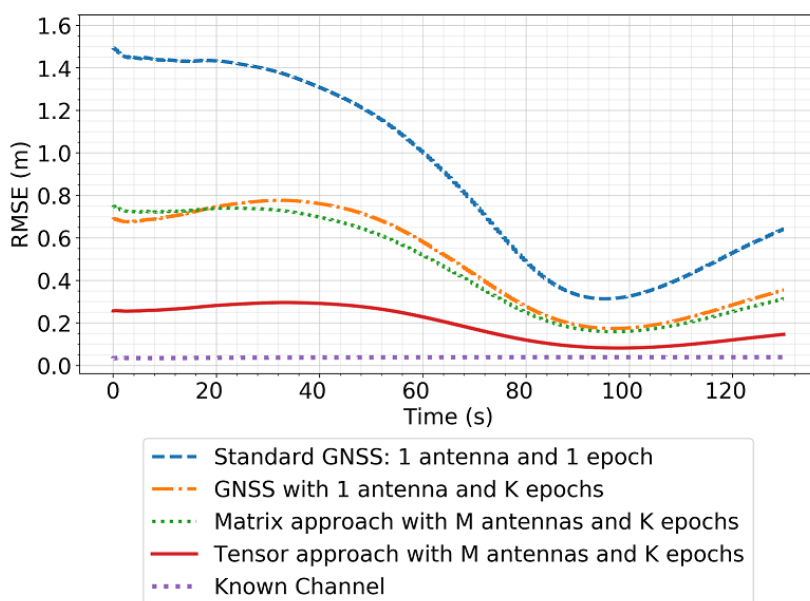


Fonte: Elaborada pelo autor.

A Figura 3.14 mostra o erro do posicionamento do veículo que foi estimado pelo EKF durante o trajeto no cenário de simulação para as cinco abordagens utilizadas. Conforme pode ser observado, quanto mais próximo o veículo está do prédio, menor é o valor do erro, dado que o atraso do tempo do componente NLOS tende a se aproximar do atraso referente ao componente LOS. Dentre as abordagens analisadas, a tensorial utilizando M antenas é a que apresenta o menor erro, até mesmo em condições com um atraso de tempo elevado do componente NLOS devido à interferência do prédio. O valor máximo do erro com essa abordagem ficou em torno de 30cm . Observando a curva referente a um receptor de GNSS padrão (*Standard GNSS*), o erro nas mesmas condições ficou em torno de 1.5m , valor inviável para o contexto de veículos autônomos.

Para questões de comparação, a Tabela 3.2 apresenta os valores de RMSE de posicionamento de um dispositivo de GNSS+IMU utilizado como referência neste trabalho [50]. É possível observar que a acurácia desse dispositivo ao nível de centímetro somente é atingida com o uso de serviços de correção de posicionamento, os quais, geralmente, requerem o pagamento de assinatura para utilização e têm custo relativamente elevado. Além disso, tais acurácias são difíceis de ser alcançadas em cenários urbanos. Os fabricantes de dispositivos de GNSS normalmente anunciam as acurácias obtidas em condições controladas, com linha de visada direta para um céu claro, que é o melhor cenário, porém, não realista para aplicações com requisitos exigentes [22].

Figura 3.14 – Erro estimado pelo EKF para o posicionamento do veículo. Abordagens utilizadas na simulação: receptor GNSS padrão com 1 antena e 1 época, receptor GNSS com 1 antena e K épocas, filtragem bidimensional com abordagem matricial com M antenas e K épocas, e abordagem tensorial com M antenas e K épocas



Fonte: Elaborada pelo autor.

Tabela 3.2 – RMSE do dispositivo de referência

Sistema de Correção	RMSE (m)
GNSS Padrão (sem correção)	1,5
<i>Satellite-based Augmentation System (SBAS)</i>	0,6
<i>Differential Global Positioning System (DGPS)</i>	0,4
<i>Precise Point Positioning (PPP)</i>	0,04
<i>Real Time Kinematic (RTK)</i>	0,01

Fonte: Elaborada pelo autor.

4 DETECÇÃO DE OBJETOS EM VEÍCULOS AUTÔNOMOS

Este capítulo está relacionado aos objetivos específicos OE1 e OE3, conforme descritos na Seção 1.2 deste documento. Ele apresenta um conjunto de propostas de métodos e técnicas voltados para a melhoria da percepção em veículos autônomos. A Seção 4.1 aborda um método de detecção de veículos baseado na fusão de dados brutos de câmera e LiDAR. A Seção 4.2 apresenta um método para a detecção de pedestres que se encontram parcialmente obstruídos por outros objetos.

4.1 FUSÃO DE DADOS BRUTOS DE LIDAR E CÂMERA PARA DETECÇÃO DE VEÍCULOS

Para que um veículo possa ser capaz de trafegar de forma autônoma e segura, ele precisa, primeiramente, ter uma percepção confiável acerca dos objetos que estão ao seu redor. Tais objetos podem ser dinâmicos, como veículos, pedestres, ciclistas e animais, ou estáticos, como placas de trânsito e marcações na pista. Essa percepção é viabilizada por algoritmos de fusão de dados que operam sobre as medições adquiridas pelos sensores presentes no veículo, como câmeras, radares e LiDAR.

Nenhum tipo de sensor é capaz de atender sozinho, e em quaisquer condições, as funções existentes em um veículo autônomo. À medida que o nível de automação de um veículo aumenta, os requisitos em termos de percepção se tornam mais complexos, demandando a utilização de múltiplos sensores e de métodos de fusão capazes de prover a confiabilidade e a acurácia necessárias.

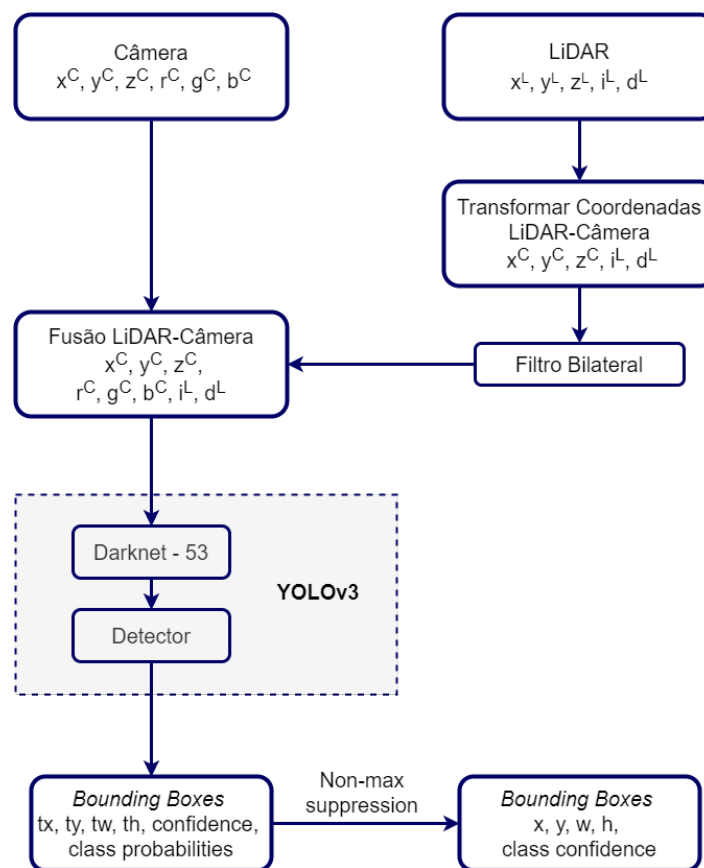
Em termos de percepção, câmera e LiDAR são dois tipos de sensores que podem ser utilizados de forma complementar. A câmera tem a capacidade de capturar uma representação mais rica do ambiente do que o LiDAR, como semáforos e sinalizações de trânsito. Por outro lado, o LiDAR supera a capacidade da câmera quando se trata de obter informações referentes à distância dos objetos. Dessa forma, a fusão desses dois sensores pode proporcionar vantagens que superam as limitações individuais de cada um deles.

Apesar de arquiteturas de fusão de alto nível terem sua relevância no contexto de veículos autônomos, arquiteturas de baixo nível ainda são bastante empregadas e têm mostrado eficácia, principalmente, em situações que envolvem a fusão de dados provenientes de dois sensores sincronizados.

Nesse sentido, o método de fusão aqui apresentado baseia-se na aplicação de uma arquitetura de baixo nível, utilizando dados brutos obtidos a partir de sensores de câmera e LiDAR de um veículo.

A Figura 4.1 mostra um diagrama de blocos que descreve o funcionamento desse método. Cada ponto gerado pelo LiDAR é representado por suas coordenadas tridimensionais e pela sua refletância (x^L, y^L, z^L, i^L). A refletância é a razão entre a radiação de luz refletida e a radiação incidente sobre o ponto. As imagens da câmera são representadas por pontos contendo dados sobre as coordenadas cartesianas e sua cor no modelo RGB ($x^C, y^C, z^C, r^C, g^C, b^C$).

Figura 4.1 – Diagrama de blocos do método de fusão de dados brutos de LiDAR e câmera



Fonte: Adaptada de [51].

Para realizar a fusão, é necessário utilizar um sistema de coordenadas comum. Nesse caso, os pontos gerados pelo LiDAR são submetidos a uma transformação, que envolve rotação e translação, de acordo com o plano de imagem gerado pela câmera. Para tornar a nuvem de pontos gerada pelo LiDAR mais densa, aplica-se o filtro bilateral [52], minimizando, assim, a característica esparsa dos dados do LiDAR.

Utilizando as coordenadas uniformes dos pontos do LiDAR e da câmera, e os dados relativos à cor RGB, à refletância e à distância desses pontos, o bloco rotulado *Fusão LiDAR-Câmera* gera cinco representações diferentes de cada imagem: três delas provenientes dos

canais RGB da câmera, e as outras duas provenientes dos dados de refletância e distância gerados pelo LiDAR.

Para a detecção dos veículos presentes na imagem, optou-se por utilizar o algoritmo *You Only Look Once - Version 3* (YOLOv3), tendo em vista o seu desempenho em termos do tempo de inferência, quando comparado com outros algoritmos de detecção de objetos do estado da arte [53].

A saída do algoritmo de detecção do YOLOv3 é composta por um conjunto de caixas delimitadoras (do inglês, *bounding boxes*) que representam os objetos que foram detectados. No entanto, algumas dessas *bounding boxes* podem se referir ao mesmo objeto. Então, é necessário aplicar um algoritmo de pós-processamento para filtrar essas *bounding boxes*, gerando apenas uma detecção por objeto. Nesse caso, o algoritmo de pós-processamento aqui utilizado é o *Non-max suppression*, o qual avalia as *bounding boxes* que se sobrepõem e que se referem a uma mesma classe de objeto, mantendo apenas aquela com o maior índice de confiança da detecção.

Para exemplificar o funcionamento do método de fusão aqui descrito, foi utilizada a base de dados *KITTI dataset* [54], que é composta de imagens e nuvens de pontos geradas, respectivamente, a partir de um conjunto de quatro câmeras frontais e do LiDAR instalados em um veículo. Informações de localização do veículo também são geradas a partir de um sistema de GPS/IMU.

A Figura 4.2 mostra o esquema de configuração dos sensores no veículo do projeto *KITTI*. Os sistemas de coordenadas das câmeras, do LiDAR e do GPS/IMU têm suas direções definidas conforme a lista a seguir:

- Câmera: x = para direita, y = para baixo, z = para frente
- LiDAR: x = para frente, y = para esquerda, z = para cima
- GPS/IMU: x = para frente, y = para esquerda, z = para cima


A transformação do sistema de coordenadas do LiDAR para o sistema de coordenadas da câmera é dada por $\mathbf{T}_L^C \in \mathbb{R}^{4 \times 4}$, conforme mostrada na Equação (4.1).

$$\mathbf{T}_L^C = \begin{bmatrix} \mathbf{R}_L^C & \mathbf{t}_L^C \\ \mathbf{0}_{1 \times 3} & 1 \end{bmatrix}, \quad (4.1)$$

onde $\mathbf{R}_L^C \in \mathbb{R}^{3 \times 3}$ e $\mathbf{t}_L^C \in \mathbb{R}^{1 \times 3}$ são, respectivamente, a matriz de rotação e o vetor de translação entre o LiDAR e a câmera.

Dessa forma, um ponto no sistema de coordenadas do LiDAR pode ser projetado no plano de imagem bidimensional da câmera utilizando a Equação (4.2).

Figura 4.2 – Esquema de configuração de sensores no veículo do projeto *KITTI*



Fonte: [54].

$$\begin{bmatrix} x_k^C \\ y_k^C \\ z_k^C \\ 1 \end{bmatrix} = \mathbf{P}_{rect}^{(i)} \mathbf{R}_{rect}^{(0)} \mathbf{T}_L^C \begin{bmatrix} x_k^L \\ y_k^L \\ z_k^L \\ 1 \end{bmatrix}, \quad (4.2)$$

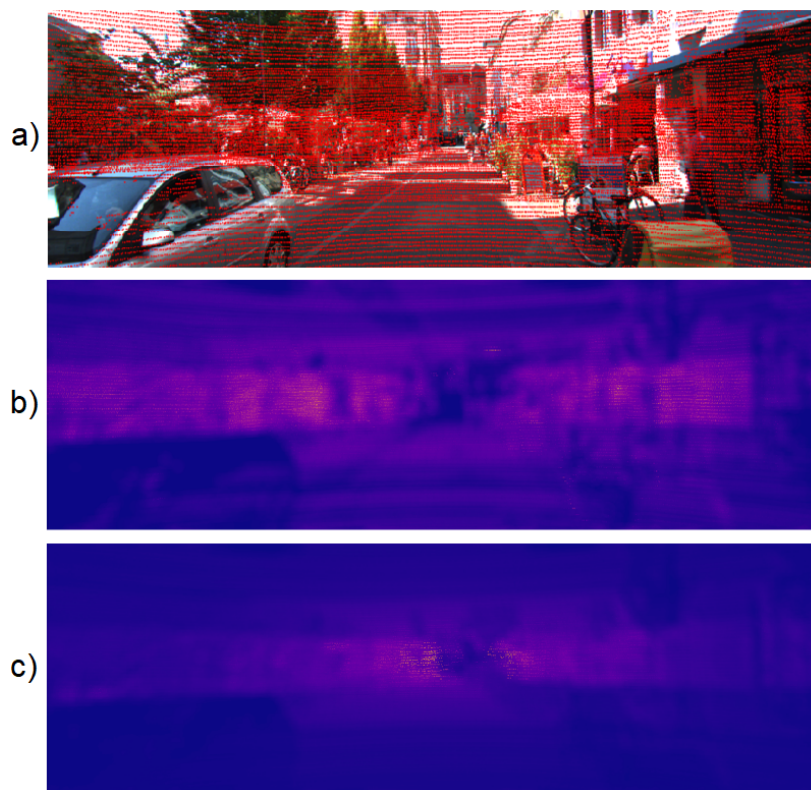
onde $\mathbf{R}_{rect}^{(0)} \in \mathbb{R}^{4 \times 4}$ e $\mathbf{P}_{rect}^{(i)} \in \mathbb{R}^{3 \times 4}$ são, respectivamente, a matriz de rotação de retificação da câmera de referência (câmera com id 0 no *KITTI dataset*) e a matriz de projeção da i -ésima câmera após a retificação. Vale salientar que tais matrizes já se encontram pré-calculadas no *KITTI dataset*.

A partir dos pontos projetados, e dos dados da refletância e da distância gerados pelo LiDAR, são construídos os mapas de refletância e de profundidade. A Figura 4.3 apresenta um exemplo de um conjunto de pontos do LiDAR projetados sobre o plano de uma imagem do *KITTI dataset*, bem como os mapas de refletância e de profundidade correspondentes a essa projeção.

A Figura 4.4, por sua vez, mostra os cinco canais que serão utilizados como entrada para o algoritmo de detecção YOLOv3, sendo três construídos a partir dos valores RGB dos pontos gerados pela câmera e os outros dois formados pelos mapas de refletância e de profundidade oriundos dos dados do LiDAR.


Para avaliar o desempenho da detecção de veículos com o método de fusão aqui proposto, três modelos foram então treinados no YOLOv3: um com base apenas nas imagens da câmera, outro com base apenas nos dados dos pontos gerados pelo LiDAR, e o terceiro envolvendo a fusão dos dados brutos da câmera e do LiDAR, conforme aqui apresentado. Tais modelos foram nomeados, respectivamente, YOLO-Câmera, YOLO-LiDAR e YOLO-RF. Para o treinamento de cada um desses modelos, foram utilizadas 7481 imagens presentes no *KITTI dataset*, das quais 15% foram destinadas para o conjunto de imagens de teste.

Figura 4.3 – Projeção de pontos do LiDAR no sistema de coordenadas de uma imagem (a) e os correspondentes mapas de refletância (b) e de profundidade (c)



Fonte: Adaptada de [51].

Figura 4.4 – Canais utilizados no método de fusão de dados de LiDAR e câmera



Fonte: Adaptada de [51].

Com os modelos treinados, foi feita uma avaliação utilizando 1048 imagens contendo um total de 4095 veículos possíveis de detecção. Para cada veículo, existe uma indicação de sua *bounding box* verdadeira (do inglês, *ground-truth*). Três métricas iniciais foram computadas nessa avaliação, conforme descritas na lista a seguir:

- Verdadeiros Positivos – *True Positives* (TP): quando o veículo está presente na imagem e o modelo consegue detectá-lo;
- Falsos Negativos – *False Negatives* (FN): quando o veículo está presente na imagem, mas o modelo não consegue detectá-lo;
- Falsos Positivos – *False Positives* (FP): quando o veículo não está presente na imagem, mas o modelo indica a detecção de um veículo.

A contabilização dessas métricas é baseada na interseção entre *bounding boxes* previstas pelo modelo e *bounding boxes* verdadeiras, também chamada de Interseção sobre União – *Intersection over Union* (IoU). Para ser considerada uma detecção correta, o valor de IoU deve ser maior ou igual a 50% [55]. A Tabela 4.1 mostra os valores de TP, FN e FP resultantes da avaliação de cada um dos três modelos.

Tabela 4.1 – Resultados da detecção de veículos nos modelos analisados

Modelo	Verdadeiros Positivos	Falsos Negativos	Falsos Positivos
YOLO-Câmera	2995	1100	754
YOLO-LiDAR	2531	1564	551
YOLO-DF	3230	865	1246
YOLO-RF (Proposto)	3323	772	691

Fonte: Adaptada de [51].

A partir dos valores de TP, FN e FP resultantes de cada modelo, foram obtidas duas outras métricas: *precision* e *recall*. *Precision*, calculada conforme a Equação (4.3a), indica a proporção de detecções corretas. *Recall*, calculada conforme a Equação (4.3b), representa a proporção de detecções realizadas em relação à quantidade de objetos possíveis de detecção. Os valores dessas duas métricas para cada um dos três modelos analisados são mostrados na Tabela 4.2.

$$Precision = \frac{TP}{TP + FP} \quad (4.3a)$$

$$Recall = \frac{TP}{TP + FN} \quad (4.3b)$$

Por fim, foi adotada uma métrica conhecida como *Mean Average Precision* (mAP), que é bastante utilizada na visão computacional para avaliação de detecção de objetos. Para obter o valor dessa métrica, calcula-se a precisão média [55] de cada classe de objetos detectados


Tabela 4.2 – Valores das métricas *Precision* e *Recall* dos três modelos analisados

Modelo	<i>Precision</i>	<i>Recall</i>
YOLO-Câmera	79.9%	73.1%
YOLO-LiDAR	82.1%	61.8%
YOLO-DF	72.2%	78.9%
YOLO-RF (Proposto)	82.8%	81.1%

Fonte: Elaborada pelo autor.

e calcula-se a média desses valores. A Figura 4.5 mostra os valores de mAP para cada um dos três modelos analisados.

Figura 4.5 – Valores de mAP dos três modelos analisados



Fonte: Adaptada de [51].

Conforme pode ser observado, o modelo de detecção de veículos utilizando o método proposto de fusão de dados brutos de câmera e LiDAR (YOLO-RF) obteve um ganho de aproximadamente 13% em relação ao modelo utilizando dados apenas da câmera (YOLO-Câmera) e de aproximadamente 32% em relação ao modelo com dados apenas do LiDAR (YOLO-LiDAR).

4.2 DETECÇÃO DE PEDESTRES PARCIALMENTE OBSTRUÍDOS

Graças à pesquisa e análise de dados de colisão, bem como ao avanço da engenharia na construção de veículos e no desenvolvimento de tecnologias de segurança veicular, os veículos vêm cada vez mais oferecendo recursos capazes de proteger os seus ocupantes em caso de acidentes. Estimativas mostram que equipamentos como cintos de segurança e *airbags*, associados a controles de segurança providos por determinados tipos de ADAS, contribuíram para uma redução de 56% do risco de fatalidade para os ocupantes de veículos modernos em comparação com veículos da década de 1960. Com isso, estima-se que em torno de 600.000 vidas foram salvas entre o período de 1960 e 2012 [56].


No entanto, quando se analisa a segurança dos usuários vulneráveis do sistema rodoviário – *Vulnerable Road User* (VRU), que envolvem pedestres, ciclistas e motociclistas, observa-

se que eles representam mais da metade das mortes ocorridas em acidentes de trânsito no mundo. Pedestres e ciclistas correspondem a 26% e motociclistas correspondem a 28% do total [10].

Além de mais vulneráveis, os pedestres estão mais susceptíveis a situações em que ocorrem a obstrução, e até mesmo a oclusão, por parte de outros objetos maiores, tais como veículos e caminhões estacionados ao longo da via. Esses também são objetos que têm um comportamento de locomoção mais errático e imprevisível quando comparado com veículos. Por exemplo, um pedestre pode tomar a decisão de atravessar uma via sem necessariamente utilizar uma faixa de pedestre.

Nesse contexto, uma capacidade importante que veículos autônomos precisam ter é a detecção de pedestres. Porém, essa capacidade torna-se uma tarefa ainda mais desafiadora em cenários onde os pedestres se encontram obstruídos por outros objetos, conforme exemplo mostrado na Figura 4.6, podendo resultar em elevadas taxas de não detecção.

Figura 4.6 – Exemplo de imagem com pedestres parcialmente obstruídos



Fonte: Adaptada de [57].

Uma abordagem que pode ser aplicada na detecção de pedestres é a utilização de técnicas de extração de *features* a partir de imagens, combinadas com algoritmos de aprendizagem supervisionada responsáveis por realizar a classificação dos objetos a partir de tais *features*.

A abordagem proposta aqui neste documento será baseada, portanto, na aplicação da técnica *Histogram of Oriented Gradients* (HOG), que é bastante utilizada na área de visão computacional para processamento de imagens e extração de *features*. Já em termos de algoritmos de aprendizagem supervisionada, será utilizado o *Support Vector Machine* (SVM).

A técnica HOG é um algoritmo baseado no cálculo do gradiente de cada píxel, com o intuito de normalizar o contraste e o brilho da imagem. A imagem é dividida em M células de $N \times N$ píxeis. Para cada célula é calculado Um histograma com X colunas, que é normalizado a partir do gradiente de cada píxel. Os histogramas são então concatenados,

produzindo um vetor de tamanho $N \times M$ que representa a imagem [58].

Para cada píxel, é necessário calcular as diferenças de intensidade entre os seus adjacentes, tanto na direção horizontal quanto na vertical. Supondo $f(x, y)$ como sendo a função que determina a intensidade do píxel localizado na posição (x, y) , as diferenças de intensidade horizontal e vertical, i_x e i_y , podem ser representadas conforme a Equação (4.4).

$$i_x = f(x + 1, y) - f(x - 1, y) \quad (4.4a)$$

$$i_y = f(x, y + 1) - f(x, y - 1) \quad (4.4b)$$

A partir dessas diferenças de intensidade, o valor do gradiente é calculado, sendo representado por um vetor composto pela magnitude m e direção θ em cada píxel, respectivamente, calculados conforme as equações (4.5a) e (4.5b).

$$m = \sqrt{i_x^2 + i_y^2} \quad (4.5a)$$

$$\theta = \arctan\left(\frac{i_y}{i_x}\right) \quad (4.5b)$$

Os histogramas gerados pelo HOG descrevem padrões numéricos (*features*) que possibilitam sua utilização no treinamento de um modelo de classificação subsequente. Para o escopo deste trabalho, foi adotado o SVM Linear, o qual permite criar um hiperplano que separa os dados em classes, nesse caso, pedestres e não pedestres.

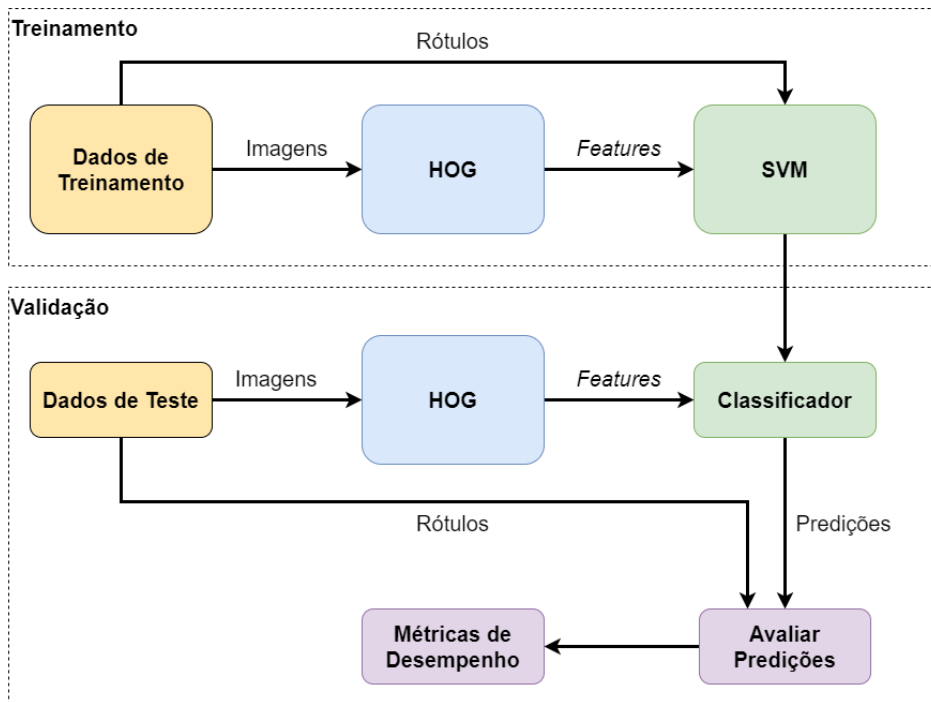
A Figura 4.7 apresenta um diagrama de blocos do framework de treinamento e validação para a detecção de pedestres proposto neste trabalho. Os dados com as imagens rotuladas foram divididos em duas partes, sendo 80% destinados para treinamento e 20% para validação. Durante a etapa de treinamento, as imagens são processadas pelo HOG para a extração de *features*. As *features* geradas, juntamente com os rótulos (do inglês, *labels*), são processadas pelo SVM para gerar um modelo treinado (Classificador). Na etapa de validação, também é utilizado o HOG para extrair as *features* das imagens de teste. Nesse caso, o Classificador atua sobre as *features* e gera as predições de classes. As predições são comparadas com os rótulos dos dados de teste e são geradas as métricas de desempenho.

As métricas adotadas nesse framework são *Acurácia*, *Precision*, *Recall* e *F1 Score*. *Precision* e *Recall* são calculadas, respectivamente, conforme a Equação (4.3a) e a Equação (4.3b). Já a *Acurácia* e *F1 Score* são calculadas conforme a Equação (4.6a) e a Equação (4.6b), respectivamente.

$$Acurácia = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.6a)$$

$$F1\ Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (4.6b)$$

Figura 4.7 – Diagrama de blocos do framework de treinamento e validação do modelo proposto para detecção de pedestres



Fonte: Adaptada de [59].

Para avaliar o modelo proposto na Figura 4.7, foi utilizado o *dataset* de imagens de pedestres PSU [60]. Uma das características desse *dataset* é que ele possui um foco em imagens de pedestres parcialmente obstruídos, diferentemente de outros *datasets* existentes. A título de comparação, o mesmo framework também foi aplicado no *dataset* INRIA [61], que é um *dataset* com imagens de pedestres sem obstrução..

A Tabela 4.3 mostra os resultados das quatro métricas com base na aplicação do framework nos dois *datasets*. Conforme pode ser observado, a acurácia do modelo proposto em relação ao PSU foi de 82%, um valor considerável quando comparado à acurácia atingida em relação ao INRIA, que foi de 86%, dada a característica mais complexa das imagens presentes no PSU.

Tabela 4.3 – Valores das métricas *Acurácia*, *Precision*, *Recall* e *F1 Score* para os datasets PSU e INRIA

<i>Dataset</i>	<i>Acurácia</i>	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>
PSU	82%	64%	74%	78%
INRIA	86%	92%	87%	89%

Fonte: Adaptada de [59].

Ao comparar os resultados alcançados em relação ao trabalho utilizado como referência [60], observa-se um ganho significativo, tendo em vista que a acurácia alcançada lá foi de 55%.

5 UMA PROPOSTA ORIENTADA A DIÁLOGO PARA INTERAÇÃO COM VEÍCULOS AUTÔNOMOS

Os veículos autônomos, além de promover diversos benefícios à sociedade em termos de um trânsito mais seguro, inclusivo e eficaz, abre a possibilidade para o desenvolvimento de diversos outros modelos de negócio. Nesse sentido, este capítulo está relacionado ao objetivo específico OE4, conforme descrito na Seção 1.2 deste documento. Na seção 5.1 é feita uma contextualização sobre as quatro principais tendências disruptivas da indústria automotiva. A seção 5.2 apresenta uma explanação sobre modelos de negócio que podem ser desenvolvidos ou potencializados com o uso de veículos autônomos. Na seção 5.3 é apresentada uma proposta de um sistema de interação humano-veículo baseado no conceito de assistente virtual. A seção 5.4 descreve um processo de gerenciamento de conteúdo de chatbot, o qual norteia o desenvolvimento do assistente virtual. A seção 5.5 apresenta um conjunto de diálogos propostos para o assistente virtual.

5.1 TENDÊNCIAS DISRUPTIVAS DO SETOR AUTOMOTIVO

As recentes mudanças climáticas, a crescente expansão urbana e os avanços tecnológicos em termos de digitalização de serviços são alguns dos principais fatores que têm provocado mudanças nos hábitos de consumo e de comportamento da sociedade. Como consequência, esses fatores também têm influenciado fortemente quatro tendências disruptivas na indústria automotiva: eletrificação, mobilidade compartilhada, direção autônoma e conectividade [62].

Em termos de eletrificação, essa é uma tendência que visa diminuir o impacto ambiental causado pela emissão de poluentes e de gases de efeito estufa. De uma maneira geral, os veículos elétricos apresentam vantagens quando comparados aos veículos com motor a combustão, tais como zero emissão de poluentes, simplicidade em termos do número de elementos que compõem o motor, maior confiabilidade e conforto aos ocupantes devido à diminuição de vibrações e barulho do motor. Por outro lado, ainda há desafios significativos no desenvolvimento de baterias mais eficientes, tais como distância percorrida até ser necessário recarregar a bateria, tempo de recarga, custo de produção e peso das baterias [63].

Com relação à mobilidade, observa-se que o modelo tradicional baseado na aquisição e uso do próprio automóvel vem diminuindo ao longo dos últimos anos. Para se ter uma ideia,

no início dos anos 2000, o número de carros adquiridos por jovens americanos até 34 anos era de 5 veículos para cada 100 pessoas. Em 2015, esse número caiu para 3,5, ao passo que a média de idade dos novos compradores aumentou em aproximadamente 7 anos no mesmo período [3]. Principalmente entre a população mais jovem, tem cada vez mais crescido a opção por modelos de mobilidade compartilhada e sob demanda. Estudos apontam que, por volta de 2030, mais de 30% dos quilômetros percorridos em deslocamentos nas cidades envolverá o uso de meios compartilhados [64].

Os recentes avanços tecnológicos na área de inteligência artificial e, mais especificamente, em redes neurais e aprendizado de máquina, têm contribuído para a entrada de empresas de tecnologia no setor automotivo. Tais empresas têm investido significativamente no desenvolvimento de veículos autônomos. Com a utilização de veículos autônomos em larga escala, diversos benefícios para a sociedade são vislumbrados. Dado que mais de 90% dos acidentes de trânsito são causados por falhas humanas, esses veículos podem contribuir de forma significativa para um trânsito mais seguro e eficiente. Eles também podem funcionar como uma tecnologia assistiva da mobilidade de pessoas idosas ou com necessidades especiais. Tal fator é de grande relevância para a melhoria da qualidade de vida dessas pessoas. De acordo com estimativas da Organização Mundial de Saúde (OMS), a população mundial de idosos acima de 60 anos, atualmente em 1 bilhão de pessoas, atingirá a cifra de 2 bilhões até 2050 [65]. Além disso, estima-se que há atualmente 1 bilhão de pessoas com alguma forma de deficiência física [66].

A quarta tendência disruptiva está relacionada a veículos conectados, os quais podem se comunicar com outros veículos ou se conectar a uma infraestrutura de rede de comunicação. Por meio dessa infraestrutura de rede, o veículo conectado pode ter acesso a diversos serviços, os quais podem ser providos por uma cidade inteligente, pelo fabricante do veículo ou por empresas especializadas. A conectividade também é um dos pontos fundamentais para a viabilidade de veículos autônomos, já que o grande número de sensores disponíveis nos veículos e o volume de dados gerados requer uma infraestrutura de rede confiável, com alta taxa de transmissão e baixa latência [67]. Para isso, é de fundamental importância a implantação de infraestruturas de computação de borda (do inglês, *edge computing*), bem como de redes com tecnologias 5G e além [68].

Para viabilizar essas tendências, os veículos precisam cada vez mais ter suas funcionalidades implementadas via software ao invés de hardware. Em outras palavras, o modelo convencional de veículo composto por um grande número de Unidades de Controle Eletrônico – *Electronic Control Units* (ECUs) dedicadas precisa migrar para um modelo onde as funcionalidades possam ser definidas e controladas por software. Esse modelo tem sido chamado de Veículo Definido por Software – *Software-Defined Vehicle* (SDV) [69].

O suporte a esse modelo requer mudanças arquiteturais em termos de hardware e de software. No caso da arquitetura de hardware, a tendência é diminuir o número de ECUs presente

no veículo, substituindo por uma arquitetura baseada em um número menor de unidades de controle, porém, com um alto desempenho. Essas unidades podem executar software de diferentes domínios, tais como assistência ao motorista e infoentretenimento [70].

Com relação à arquitetura de software, a tendência é a utilização de uma arquitetura baseada em camadas. Devido à separação de papéis de cada camada, esse modelo de arquitetura provê diversos benefícios, possibilitando abstrair complexidades inerentes aos dispositivos eletrônicos dos veículos, bem como facilitar o reuso de software e o desenvolvimento de novas funcionalidades e aplicações.

A Figura 5.1 mostra uma visão geral de uma arquitetura de software em camadas para o contexto automotivo [71].

A camada de *Aplicação* engloba as aplicações e os módulos funcionais desenvolvidos para o veículo. Nessa camada incluem-se, por exemplo, os módulos responsáveis por executar as tarefas de um veículo autônomo, como percepção, localização e planejamento, assim como aplicações de infoentretenimento, de interação entre o usuário e o veículo, entre outras.

A camada denominada *Framework de Execução* disponibiliza algoritmos e bibliotecas na forma de serviços que podem ser chamados pelas aplicações. Ela também atua como uma camada de abstração para acesso a componentes básicos de software providos pelas camadas inferiores. Exemplos de *frameworks* são *Robot Operating System* (ROS) [72], *AUTomotive Open System ARchitecture* (AUTOSAR) *Adaptive Platform* [73] e Apex.OS [74].

A camada denominada *Middleware* é responsável por prover mecanismos de comunicação e de transporte de dados entre os serviços que executam no veículo, bem como entre o veículo e demais serviços externos disponíveis em uma infraestrutura de *edge computing* ou *cloud computing*. Um exemplo de *middleware* é o Apex.Middleware [75] e RabbitMQ [76].

A camada de *Sistema Operacional* é responsável por intermediar o acesso das camadas superiores de software à camada de hardware. Entre suas principais funções estão o gerenciamento de memória, o escalonamento de processos e o gerenciamento de entrada/saída. No contexto automotivo, devido aos requisitos de tempo de resposta, é comum o uso de um Sistema Operacional de Tempo Real – *Real Time Operating System* (RTOS), como FreeRTOS [77] e Blackberry QNX [78].

Por fim, a camada de *Hardware* representa os componentes físicos do veículo, tais como sensores, ECUs, elementos do tipo Sistema-em-um-Chip – *System-on-a-Chip* (SOC), Unidades de Procesamento Gráfico – *Graphics Processing Units* (GPUs) e computadores veiculares.

Figura 5.1 – Visão Geral de uma Arquitetura de Software para o Contexto Automotivo



Fonte: Adaptada de [71]

5.2 MODELOS DE NEGÓCIO ENVOLVENDO VEÍCULOS AUTÔNOMOS

O desenvolvimento de modelos de negócio que incorporem a utilização de veículos autônomos é um ponto fundamental para torná-los uma alternativa viável. Embora tais veículos possam ser adquiridos também em um modelo de mobilidade tradicional, no qual há a propriedade do veículo, porém, sem compartilhamento, é no contexto de mobilidade compartilhada onde inicialmente se espera o uso em maior escala de veículos autônomos.

Um modelo de negócio dentro desse contexto de mobilidade compartilhada é o chamado Mobilidade como um Serviço – *Mobility as a Service* (MaaS). MaaS refere-se a um modelo de mobilidade inteligente, com foco no usuário, no qual os diferentes modais de transporte são integrados a um único provedor de mobilidade, geralmente denominado *Provedor MaaS*, e disponibilizados aos usuários por meio de uma única plataforma digital [79]. Os modais de transporte podem envolver não apenas aqueles pertencentes ao sistema de transporte público coletivo, como ônibus e táxis, mas também podem envolver bicicletas, patinetes e carros compartilhados [80]. MaaS é, portanto, um serviço de mobilidade sob demanda, que busca prover aos usuários um deslocamento mais eficiente, seguro e sustentável, com maior disponibilidade e redundância dos modais e com menor custo.

A Figura 5.2 apresenta o ecossistema de MaaS proposto por [79] a partir da teoria sobre ecossistemas de negócio descrita em [81]. Tal ecossistema está organizado em camadas, as quais representam o nível de relação de diferentes setores e empresas que atuam em colaboração com o *Provedor MaaS*. A camada denominada *Negócio Principal* é composta pelo *Provedor MaaS* e pelos atores ligados mais diretamente ao negócio, como os clientes e os provedores de transporte e de dados. A camada seguinte, denominada *Empresa Estendida*,

representa os atores responsáveis pela cadeia de suprimentos do negócio. Em outras palavras, ela representa a rede de empresas que fornecem produtos ou serviços para suporte ao negócio principal do ecossistema. A camada mais externa, denominada *Ecossistema de Negócio* envolve os *stakeholders* que podem influenciar de forma significativa o modelo de negócio, embora não estejam diretamente envolvidos na sua operação.

Figura 5.2 – Ecossistema de Negócio de MaaS



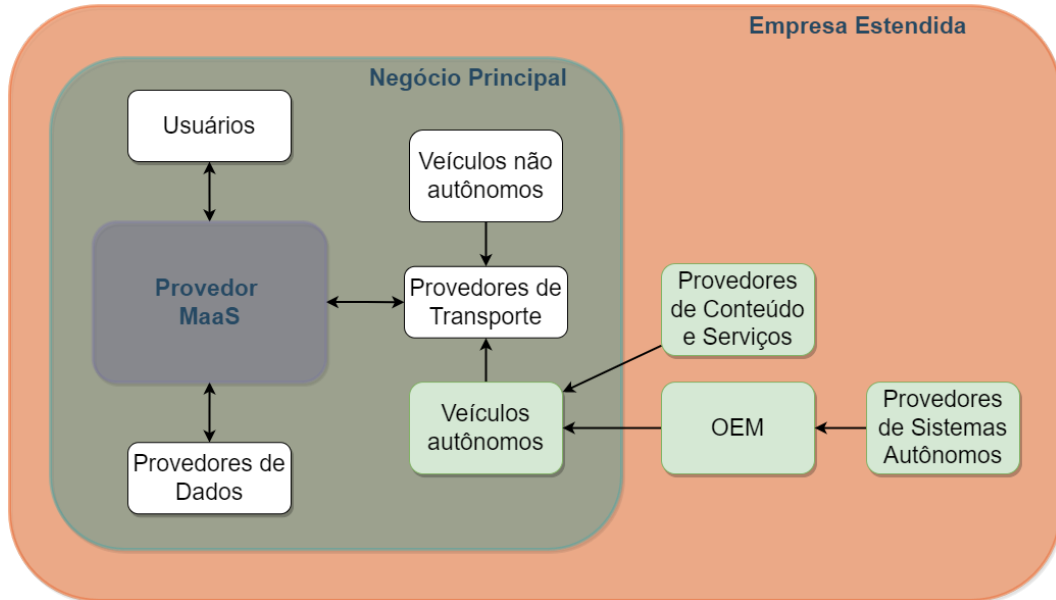
Fonte: Adaptada de [79]

No trabalho descrito em [82], os autores abordam três possíveis cenários para o desenvolvimento de MaaS – controlado apenas pelo setor privado, controlado somente pelo setor público ou controlado por parceria público-privada – e suas implicações para o transporte público. Além disso, eles incorporam dois papéis na cadeia de valor do *Provedor de MaaS*: *integrador*, responsável pela mediação com os provedores de serviço de transporte, realizando integração técnica, gerenciamento de contratos e compensação financeira, e *operador*, que fornece ao usuário final o acesso aos recursos de planejamento do deslocamento, pagamento e utilização do serviço de transporte.

Diante dessas definições, observa-se que os veículos autônomos podem ser incorporados ao ecossistema de MaaS por meio dos *Provedores de Transporte*, os quais são responsáveis pela operação da frota de veículos e podem englobar tanto empresas públicas quanto privadas. No entanto, por se tratar de veículos com características especiais, faz-se necessária a incorporação de outros atores nesse ecossistema, conforme destacado na Figura 5.3. Dois atores fundamentais são o Fabricante Original do Equipamento – *Original Equipment Manufacturer* (OEM) e os *Provedores de Sistemas Autônomos*, os quais são responsáveis pela

produção do veículo e desenvolvimento da solução autônoma, respectivamente. Esses atores podem corresponder a um única empresa ou podem ser empresas distintas trabalhando colaborativamente.

Figura 5.3 – Ecossistema de MaaS envolvendo veículos autônomos

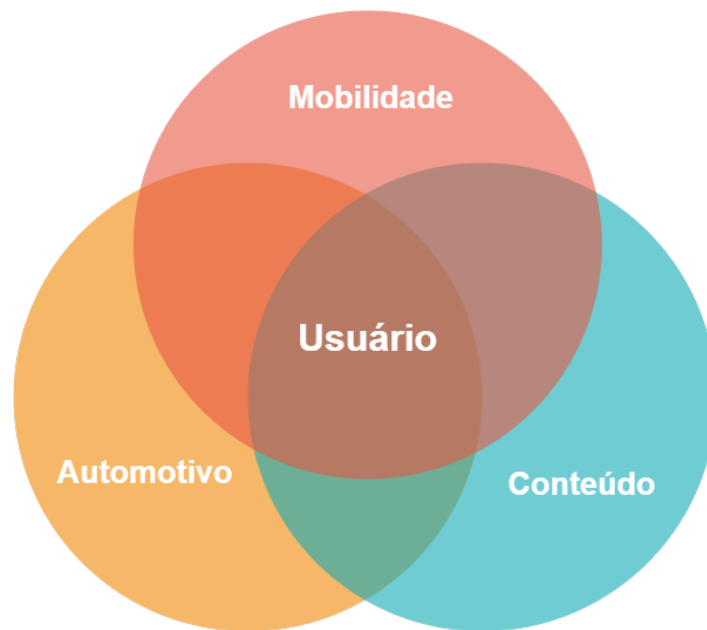


Fonte: Elaborada pelo autor.

Outro ator a ser incorporado ao ecossistema são os *Provedores de Conteúdo e Serviços*, os quais são responsáveis por prover tecnologias e soluções que possam oferecer aos usuários a possibilidade de realizar outras tarefas enquanto são transportados por um veículo autônomo. Dessa forma, conforme destacado na Figura 5.4, a inserção de veículos autônomos no ecossistema de MaaS possibilita uma sinergia entre os setores de Mobilidade, Automotivo e de Conteúdo para entregar uma experiência de usuário mais significativa.

Dependendo da finalidade do uso, até mesmo o conceito do veículo pode ser repensado, de forma a possibilitar a incorporação de novas tecnologias e o desenvolvimento de novos modelos de negócio [83]. No caso do transporte de passageiros, por exemplo, o veículo autônomo pode ser transformado em um espaço que ofereça aos usuários não apenas um meio de locomoção, mas também um conjunto de serviços digitais que possibilite aos usuários realizar outras tarefas e, assim, aproveitar melhor o tempo dentro do veículo.

Figura 5.4 – Sinergia entre os setores de Mobilidade, Automotivo e Produção de Conteúdo



Fonte: Elaborada pelo autor.

5.3 PROPOSTA DE SISTEMA DE INTERAÇÃO ENTRE HUMANO E VEÍCULO AUTÔNOMO

Um recurso tecnológico que tem sido adotado por diversas organizações públicas e privadas nos últimos anos é a utilização de assistentes virtuais para agilizar o processo de suporte ao usuários. Tais assistentes normalmente são representados por personagens virtuais que buscam incorporar características de humanização, envolvendo aspectos emotivos que possam tornar a interação com o usuário mais amigável e confiável [84].

Dada a popularização dos aplicativos de envio e recebimento de mensagens, tem sido bastante comum a implementação desses assistentes na forma de *chatbots*, cuja interface de interação pode estar disponível no site da própria organização ou podem ser acessados via aplicativos, como *Whatsapp* ou *Telegram*. O trabalho descrito em [85] mostra um *chatbot* chamado *Eva*, que foi construído para atender aos usuários de uma escola de governo brasileira, provendo respostas a dúvidas comuns, como recuperação de senha, emissão de certificados, inscrição em cursos, etc. Esse *chatbot* é capaz de processar sentenças em linguagem natural, ou seja, ele recebe mensagens escritas pelo usuário, interpreta-as e produz uma resposta adequada caso o conteúdo da conversa pertença ao seu domínio de conhecimento.

Da mesma forma como hoje tem sido cada vez mais comum a interação entre as pessoas e os seus dispositivos de *smartphones* e assistentes virtuais, é preciso também pensar sobre a interação futura entre humanos e veículos autônomos, bem como entre veículos e a infraestrutura de computação de borda (do inglês, *edge computing*) das cidades.

Nesse sentido, o desenvolvimento de assistentes virtuais que possam ser incorporados aos veículos autônomos apresenta-se como uma solução viável para facilitar a interação com os usuários humanos. Contudo, é preciso estabelecer mecanismos para que essa interação possa ocorrer de forma eficaz. Embora o uso de *chatbots* seja adequado, é preciso fazer adaptações, já que seu mecanismo tradicional de interação por meio de digitação é um fator limitante ao uso dentro de um veículo em movimento.

Uma alternativa à digitação do usuário que pode ser incorporada à solução de *chatbots* é o uso de um sistema de reconhecimento de voz. Neste caso, é necessário um sistema capaz de converter a voz do usuário em texto a ser processado pelo *chatbot*, bem como realizar a conversão da resposta do *chatbot* em voz.

Baseado na arquitetura estabelecida para o *chatbot* descrito em [85], a Figura 5.5 apresenta uma proposta de arquitetura para um sistema de interação entre seres humanos e veículos autônomos. De uma maneira geral, essa proposta de arquitetura descreve os módulos que deverão estar presentes no veículo, bem como aqueles que devem estar presentes na infraestrutura de apoio, seja ela de desenvolvimento e evolução do *chatbot*, seja de provimento de serviços externos que devem ser acessados pelo veículo.

A subseção 5.3.1 descreve o módulo do assistente virtual presente no veículo e os módulos responsáveis por integração e comunicação do veículo com outros serviços, tanto internos quanto externos. A subseção 5.3.2 descreve os módulos que integram o ambiente de desenvolvimento e operação do assistente virtual.

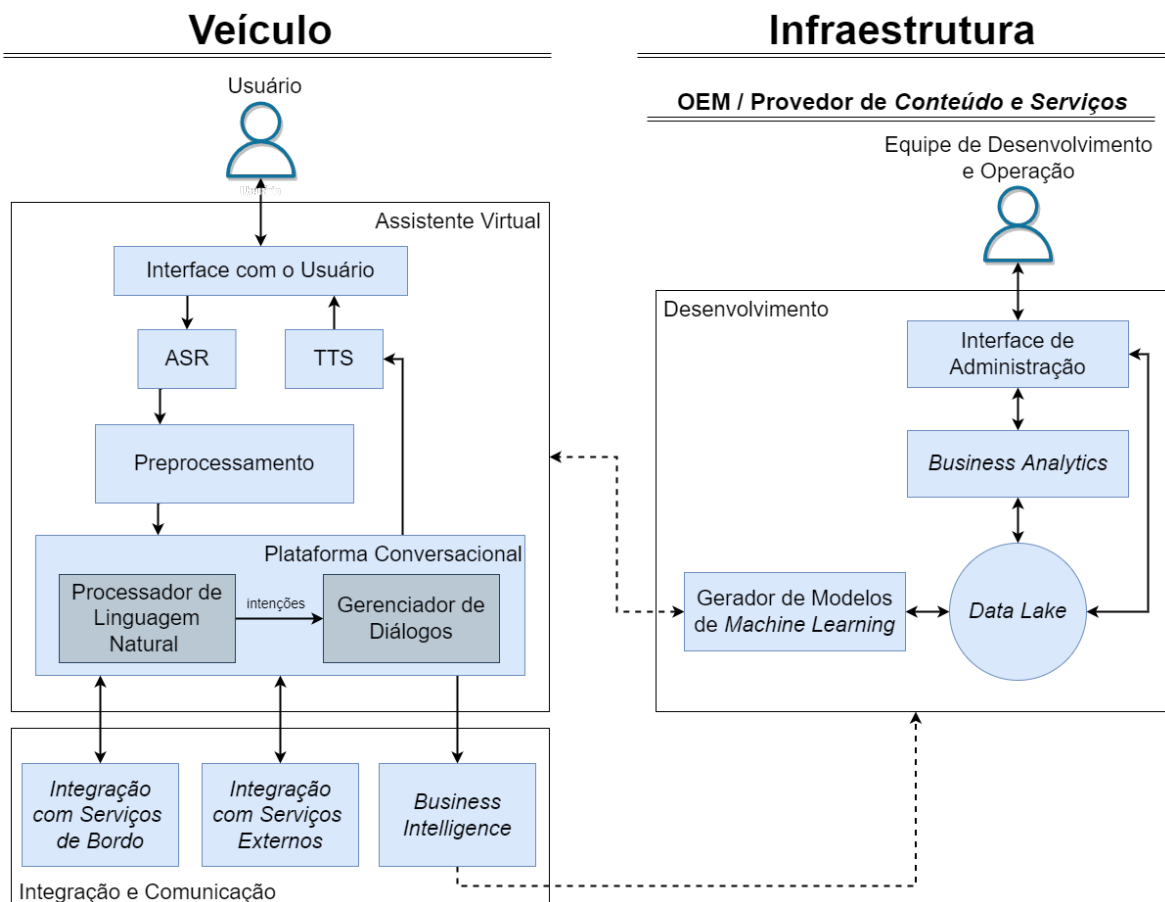
5.3.1 Módulos Propostos para o Veículo

5.3.1.1 Assistente Virtual

O *Assistente Virtual* é o software que faz a intermediação entre o usuário e os demais recursos e serviços disponibilizados tanto interna quanto externamente ao veículo. Ele é composto por um conjunto integrado de módulos, os quais são descritos a seguir.

O módulo denominado *Interface com o Usuário* fornece o meio para que o usuário possa interagir com o Assistente Virtual. De uma maneira geral, as bibliotecas para a construção de *chatbots* possibilitam ter independência em relação à interface com o usuário, fornecendo, assim, a capacidade de trabalhar com múltiplas formas de interação simultaneamente. Embora a solução descrita em [85] seja focada no uso de uma interface baseada em digitação, é recomendado que o módulo de interface aqui proposto seja dotado de dispositivo para captura e reprodução de áudio para facilitar a interação entre o usuário e o veículo. Contudo, levando-se em consideração aspectos de Experiência do Usuário – *User Experience* (UX), elementos gráficos podem ser incorporados à interface com o objetivo de torná-la visualmente intuitiva, como ícones, botões, etc.

Figura 5.5 – Arquitetura Proposta para o Sistema de Interação entre Humano e Veículo Autônomo



Fonte: O autor.

O módulo de *Interface com o Usuário* interage com dois outros módulos: Reconhecimento Automático de Fala – *Automatic Speech Recognition* (ASR) e Texto para Voz – *Text to Speech* (TTS). O primeiro é responsável por receber o áudio capturado pela interface e convertê-lo na sequência de caracteres correspondente. Já o segundo converte em áudio a resposta gerada pela *Plataforma Conversacional*.

O módulo chamado de *Preprocessamento* incorpora os *middlewares* propostos por [85], sendo responsável por processar o texto gerado, efetuando possíveis substituições de acordo com regras definidas durante o desenvolvimento do *chatbot* e separando o texto em sentenças, quando necessário. Obviamente que, dependendo das necessidades específicas de cada cenário onde o *chatbot* poderá atuar, esse módulo pode incorporar outros *middlewares*.

O módulo identificado como *Plataforma Conversacional* representa o *chatbot* e é dividido em dois submódulos: o *Processador de Linguagem Natural* e o *Gerenciador de Diálogos*. O primeiro realiza a conversão das mensagens do usuário para uma forma estruturada mais adequada ao processamento por máquina. Essas mensagens estruturadas são comumente denominadas de *intenções* (do inglês, *intents*). Já o segundo, processa as mensagens

estruturadas para produzir, a partir da base de conhecimento do *chatbot*, uma resposta adequada ao usuário.

5.3.1.2 Integração com Serviços de Bordo

O módulo denominado de *Integração com Serviços de Bordo* possibilita à *Plataforma Conversacional* interagir com o próprio veículo. Essa interação pode ser para obter dados acerca do estado do veículo ou para acionar determinados controles. No primeiro caso, por exemplo, o usuário pode solicitar informações sobre pressão dos pneus, nível de combustível ou de carga da bateria, temperatura do motor, entre outros. Já com relação ao segundo caso, o usuário pode solicitar o travamento/destravamento das portas do veículo, a sintonia em uma estação de rádio específica, o acionamento dos limpadores de para-brisa, a parada do veículo em um local seguro, entre outros.

A existência ou não de um determinado tipo de serviço de bordo vai depender do tipo do veículo autônomo e do contexto em que ele é utilizado. Por exemplo, alguns serviços podem existir em um veículo de transporte coletivo de passageiros, como um miniônibus, e não existir em um veículo autônomo destinado à entrega de mercadorias.

Considerando a tendência de SDV, conforme discutido na Seção 5.1, a implementação desses serviços tende a ser facilitada com a utilização de uma arquitetura de software baseada em camadas.

5.3.1.3 Integração com Serviços Externos

O módulo de *Integração com Serviços Externos* fornece à *Plataforma Conversacional* a possibilidade de acesso a serviços que podem ser disponibilizados por provedores de serviços, os quais podem estar vinculados ou não a uma infraestrutura de cidade inteligente.

Em um contexto geral, os serviços são disponibilizados em infraestruturas centralizadas de computação em nuvem. No entanto, para atender requisitos de baixa latência e alta taxa de transmissão, pode ser necessária a utilização de arquiteturas de rede, computação e armazenamento que possam disponibilizar esses serviços em infraestruturas mais próximas do usuário. Dessa forma, determinados serviços podem ser executados em uma infraestrutura de borda, baseada em modelos arquiteturais de *edge computing* e *fog computing* [86].

Assim, para atender demandas dos usuários de um veículo autônomo, a *Plataforma Conversacional* pode consultar esses serviços para fornecer respostas que vão além de sua base de conhecimento.

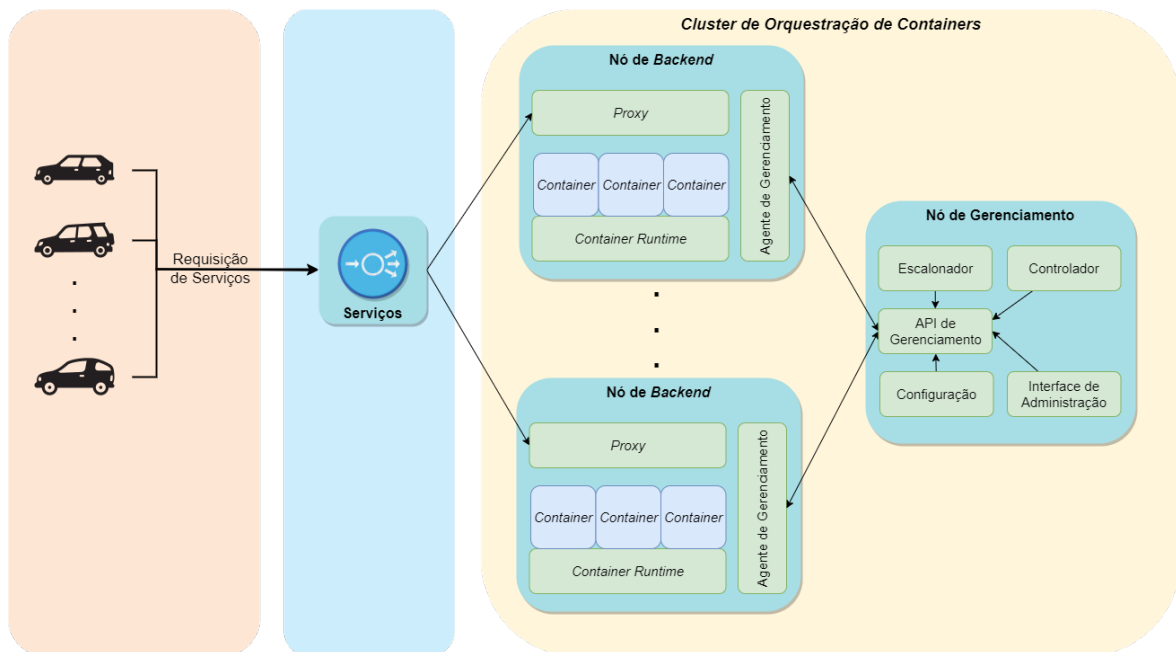
Tais serviços podem envolver a obtenção de informações, tais como condições de tráfego e previsão do tempo, bem como podem ser serviços que possibilitem ao usuário rea-

lizar outras tarefas não vinculadas à condução do veículo, como jogar, assistir a um vídeo, comunicar-se com outras pessoas, etc.

Em termos do desenvolvimento e da operação desses serviços externos ao veículo, é fundamental a utilização de uma arquitetura baseada em orquestração de contêineres [87], de forma a garantir requisitos de confiabilidade, escalabilidade, balanceamento de carga, disponibilidade, tolerância a falhas e segurança. Para isso, também é fortemente recomendado que a arquitetura seja baseada no conceito de microsserviços, os quais possibilitam melhor flexibilidade e fraco acoplamento na construção de aplicações [88]. A ideia principal desse tipo de arquitetura é proporcionar aos times de desenvolvimento a capacidade de construir e manter aplicações em ambientes corporativos a partir da composição de microsserviços, os quais são caracterizados por ter uma única responsabilidade e por ter uma infraestrutura própria e independente [89].

A Figura 5.6 apresenta uma visão geral de uma arquitetura para a disponibilização de serviços a serem acessados pelo módulo de *Integração com Serviços Externos* do veículo.

Figura 5.6 – Visão Geral da Arquitetura para Disponibilização de Serviços



Fonte: O autor.

O *Cluster de Orquestração de Contêineres* é composto por um conjunto de nós, onde cada um deles corresponde a uma máquina virtual ou física. Os chamados *Nós de Backend* são responsáveis por executar os microsserviços, os quais são disponibilizados por meio de contêineres. Cada contêiner é uma instância de um imagem, ou seja, é um pacote de software que contém o código executável do microsserviço e as bibliotecas, aplicações e configurações necessárias à sua execução. Os contêineres são executados pelo elemento chamado *Container Runtime*. O *Proxy* é o elemento responsável por definir o endereçamento virtual

dos contêineres e por controlar e direcionar o acesso a eles. Já o *Agente de Gerenciamento* representa o elemento de interação com o *Nó de Gerenciamento*.

O chamado *Nó de Gerenciamento* é responsável por controlar o funcionamento do cluster. O *Escalonador* é o componente responsável por criar contêineres e decidir em quais nós eles serão alocados para execução. O *Controlador* cuida do monitoramento da saúde dos nós. Ele é responsável por identificar nós e contêineres que estejam com falha na execução e tomar as medidas corretivas necessárias para a continuidade do serviço. Dentre tais medidas estão a reinicialização do nó ou a migração dos contêineres para outro nó que não esteja com problema. O elemento de *Configuração* é responsável por armazenar as configurações globais do cluster. A *Interface de Administração* possibilita aos membros da equipe de desenvolvimento e operações efetuar configurações no cluster, realizar a implantação de novos serviços, monitorar o desempenho dos nós do cluster, entre outras atividades de gerenciamento.

O componente denominado de *Serviços* representa uma abstração das aplicações que podem ser requisitadas pelos veículos. Eles são formados pela composição de um ou mais microsserviços em execução nos contêineres presentes nos *Nós de Backend*. Uma das grandes vantagens deste modelo é o fraco acoplamento que há entre os Serviços e os microsserviços a ele vinculados. Na ocorrência de falha durante a execução de um contêiner, por exemplo, ele pode ser facilmente reinicializado dentro do mesmo *Nó de Backend* ou então ser instanciado em um outro nó do cluster, sendo transparente para o *Serviço*.

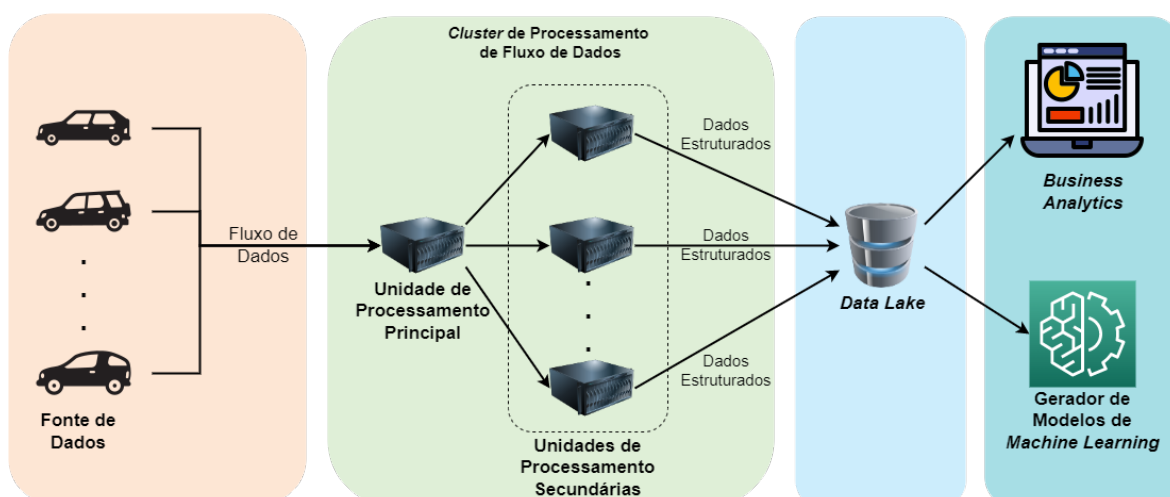
5.3.1.4 *Business Intelligence*

O módulo denominado de *Business Intelligence* trata da coleta, organização e compartilhamento de dados relacionados aos diálogos entre usuários e a *Plataforma Conversacional*. Tais dados podem englobar, dentre outros, as mensagens dos usuários, as classificações de assunto e as respostas geradas pela *Plataforma Conversacional*. A coleta e análise desses dados são de grande relevância para o processo de evolução da *Plataforma Conversacional*. Eles podem ser utilizados para orientar mudanças necessárias no fluxo conversacional, servindo de base para a ampliação dos modelos de *machine learning* já treinados, bem como a criação de novos modelos.

A Figura 5.7 apresenta uma proposta de arquitetura para o processamento dos dados enviados pelo módulo de *Business Intelligence*.

Cada veículo representa uma fonte que gera dados continuamente e os envia a uma plataforma de processamento de fluxo de dados (do inglês, *stream processing platform*). Tal plataforma de processamento é responsável por realizar consultas e operações sobre os dados à medida em que eles são recebidos, como transformações, agregações, classificações, etc.

Figura 5.7 – Arquitetura Proposta para o Envio e Processamento de Dados dos Diálogos



Fonte: O autor.

A estruturação da plataforma em unidades de processamento executando em um *cluster* tem como objetivo não apenas melhorar o desempenho do processamento, mas também proporcionar escalabilidade e tolerância a falhas. No caso da escalabilidade, unidades de processamento secundárias adicionais podem ser incorporadas ao *cluster* para atender aumentos momentâneos no fluxo de dados. Já na ocorrência de falha em alguma unidade de processamento, os processos podem ser migrados para outras unidades dentro do *cluster*.

Conforme destacado na Figura 5.7, a unidade de processamento principal é responsável por receber os dados de entrada e distribuí-los às unidades de processamento secundárias. Essas, por sua vez, processam os fluxos de dados e geram os dados estruturados a serem armazenados no *Data Lake*. Os dados armazenados nesse repositório são utilizados para alimentar as ferramentas de *Business Analytics* e no treinamento dos algoritmos pelo *Gerador de Modelos de Machine Learning*.

Vale destacar que o *cluster* pode estar localizado *on-premise*, ou seja, nas instalações físicas da empresa provedora do serviço, ou então pode ser disponibilizado em um provedor de nuvem pública.

5.3.2 Módulos Propostos para a Infraestrutura de Desenvolvimento e Operação

Com relação à infraestrutura de desenvolvimento e operação do *Assistente Virtual* presente na Figura 5.5, ela pode ser fornecida pelo próprio OEM ou por Provedores de Conteúdo e Serviços responsáveis pelo desenvolvimento e evolução da base de conhecimento da *Plataforma Conversacional*.

Conforme a Figura 5.5, o módulo denominado *Interface de Administração* é responsável por prover a interface de acesso a serviços específicos de acordo com o papel de cada membro

da equipe. O processo de desenvolvimento de assistentes virtuais envolve a participação de membros de diferentes áreas de conhecimento. Assim, é fundamental que este módulo forneça as abstrações adequadas para que esses membros possam desempenhar suas tarefas da melhor forma possível.

O módulo de *Business Analytics* é responsável por realizar análises sobre os dados enviados pelo módulo de *Business Intelligence* contido nos veículos. Ele é composto por ferramentas e métodos computacionais qualitativos, quantitativos e estatísticos, utilizados para analisar os dados, obter *insights* e apoiar a tomada de decisões. As análises podem envolver o uso de uma variedade de técnicas, incluindo modelos de diagnóstico, preditivos, prescritivos e de otimização [90]. As informações geradas por este módulo podem ser integradas ao módulo de *Interface de Administração*, fornecendo aos membros da equipe de desenvolvimento e operação análises que possam indicar possíveis necessidades de evolução e aprimoramento do assistente virtual.

O *Data Lake* representa um repositório de dados escalável, capaz de receber e manipular um grande volume de dados, tanto estruturados quanto não estruturados. Os dados inseridos em um *Data Lake* podem ser dos mais variados tipos, tais como dados de sensores, posições georreferenciadas, arquivos de texto, imagens, vídeos, áudios, assim como quaisquer outros dados úteis para as necessidades da empresa e de seus sistemas analíticos [91]. Na arquitetura aqui proposta, um dos objetivos do *Data Lake* é também armazenar dados enviados pelo módulo de *Business Intelligence* dos veículos, os quais são catalogados e indexados para uso pelos demais módulos do ecossistema de desenvolvimento e operação do assistente virtual.

O módulo denominado *Gerador de Modelos de Machine Learning* verifica periodicamente a existência de novas mudanças no *Data Lake* e realiza o treinamento e validação dos modelos de *machine learning* do assistente virtual. Esses modelos validados são então disponibilizados para implantação nos veículos. Dependendo da estratégia adotada, a atualização dos modelos no veículos pode se dar basicamente de duas formas. Uma delas é a própria *Plataforma Conversacional* periodicamente consultar um repositório de modelos para checar se há alguma nova versão dos modelos. A desvantagem dessa estratégia é que pode haver um volume elevado de consultas desnecessárias caso a frequência de atualização dos modelos seja baixa. Para resolver esse problema, pode ser adotada a estratégia de notificação da *Plataforma Conversacional*. Ou seja, quando o *Gerador de Modelos* disponibilizar uma versão atualizada dos modelos, uma notificação é enviada aos veículos para que façam o download e a implantação da nova versão na *Plataforma Conversacional*.

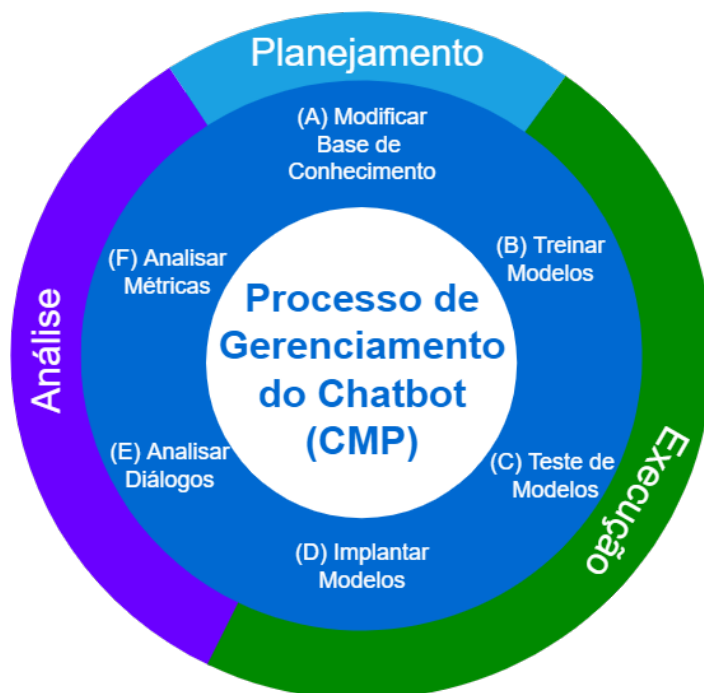
5.4 PROCESSO DE GERENCIAMENTO DE CONTEÚDO DO *CHATBOT*

Como pode ser observado pela Figura 5.5, o processo de desenvolvimento e gerenciamento de conteúdo do *chatbot* se dá em um ciclo contínuo, no qual a base de conhecimento do *chatbot* pode ser enriquecida ao longo do tempo. Isso possibilita que o *chatbot* possa aprender continuamente a partir das interações com os usuários, bem como adaptar-se a novos requisitos elencados pela empresa ou provedor do serviço [92].

Dessa forma, além do processo de desenvolvimento do *chatbot* em si, é importante estabelecer um método com fases e etapas bem definidas para realizar o gerenciamento do conteúdo.

Baseado no trabalho descrito em [93], a Figura 5.8 apresenta uma proposta de processo para gerenciamento do conteúdo de *chatbot*, o qual é dividido em seis etapas, distribuídas em três fases.

Figura 5.8 – Método Proposto para o Processo de Gerenciamento do Conteúdo de *Chatbot*



Fonte: Adaptada de [93]

A fase denominada *Planejamento* é composta por uma única etapa identificada por (A) *Modificar Base de Conhecimento*. Esta etapa envolve a inclusão das mudanças necessárias à evolução do *chatbot*. Tais mudanças caracterizam-se pela adição, modificação ou remoção de dados da base de conhecimento com o objetivo de melhorar a capacidade de entendimento e a qualidade das respostas providas pelo *chatbot*. Para a primeira versão do *chatbot*, é comum que os desenvolvedores utilizem sua experiência no domínio de aplicação e fontes de

conteúdo dentro da organização, caso existam, para construir a base inicial de conhecimento do *chatbot*, permitindo que ele possa estabelecer diálogos mais comuns dentro do seu contexto. Para as versões subsequentes do *chatbot*, esta etapa deve utilizar como fonte adicional os dados coletados a partir dos diálogos estabelecidos pelos usuários.

A fase denominada *Execução* é composta por três etapas. A etapa (B) *Treinar Modelos* é responsável por executar os algoritmos de *machine learning* para gerar os modelos treinados. No caso de *chatbots*, é comum utilizar como dados de treinamento os chamados *intents*, os quais representam possíveis variações de uma mesma sentença que podem ser geradas pelos usuários em um diálogo. Dessa forma, a partir de um conjunto de *intents* previamente rotulados e preparados, pode-se realizar o treinamento utilizando-se algoritmos de aprendizagem supervisionada.

A etapa (C) *Teste de Modelos* engloba a avaliação dos modelos treinados. Em outras palavras, a organização pode estabelecer métricas que precisam ser atendidas para que um modelo possa ser considerado como aceitável. Caso as métricas não atinjam valores satisfatórios, o fluxo do processo precisa retornar à etapa (A) para que sejam feitos os devidos ajustes na base de conhecimento, bem como promover ajustes nos hiperparâmetros dos algoritmos de *machine learning* e realizar novos treinamentos.

A etapa (D) *Implantar Modelos*, por sua vez, tem por responsabilidade disponibilizar os modelos treinados e validados no ambiente de produção.

A fase denominada *Análise* engloba o monitoramento do desempenho do *chatbot*, permitindo acompanhar como o *chatbot* está lidando com os diálogos com os usuários. Duas etapas estão envolvidas nessa fase. A etapa (E) *Analisar Diálogos* utiliza dados provenientes dos diálogos para construir um melhor entendimento sobre o comportamento dos usuários e, assim, realizar as devidas mudanças na base de conhecimento do *chatbot*.

A etapa (F) *Analisar Métricas* é responsável por avaliar métricas gerais da eficiência do *chatbot*. O conjunto de métricas a ser adotado depende do contexto do *chatbot*. Alguns exemplos são percentual de mensagens do usuário que foram respondidas de forma não correta, o nível de satisfação do usuário, entre outras.

5.5 PROPOSTA DE DIÁLOGOS

Ao iniciar a utilização de um assistente virtual, normalmente o usuário não tem a completa noção dos recursos oferecidos por tal assistente. Nessa situação, tanto é possível encontrar usuários que realizem pouca interação com o assistente quanto aqueles que fazem uso de diferentes frases e assuntos para testar o que o assistente é capaz de responder.

Portanto, ao construir a base de conhecimento inicial do assistente é importante ter uma

equipe multidisciplinar que possa realizar um processo de introspecção com o intuito de prever as diferentes possibilidades de interação que os usuários possam ter com o assistente [94].

Atualmente, automóveis pertencentes a linhas mais sofisticadas já dispõem de Sistemas de Informação do Veículo – *In-Vehicle Information Systems* (IVIS), os quais envolvem sistemas de navegação via satélite, informações sobre trânsito, informações sobre o estado do veículo, etc., bem como sistemas de alerta ou de assistência ao motorista em caso de emergência, conhecidos como ADAS [95]. Diversos modelos também já contam com centrais multimídia que permitem a integração com *smartphones* por meio de aplicativos como *Google Auto* e *Apple CarPlay*.

Contudo, no contexto de veículos autônomos abre-se um leque de possibilidades para as chamadas Tarefas Não Relacionadas à Condução – *Non-Driving Related Tasks* (NDRT) [96], as quais envolvem atividades que os usuários podem fazer enquanto o veículo está com o modo autônomo acionado. Tais atividades podem estar relacionadas tanto com entretenimento, como ouvir música, ler um livro, assistir a vídeos ou jogar um jogo em um console, quanto com trabalho, como participar de uma reunião virtual, enviar e receber mensagens, entre outras.

Além disso, com a implantação das redes de comunicação 5G e *Beyond 5G* (B5G), as quais podem proporcionar altas taxas de transmissão de dados, alta confiabilidade de comunicação e baixa latência, os veículos podem ter acesso a diversos outros serviços disponibilizados em uma infraestrutura de computação de borda (do inglês, *edge computing*).

Nesse sentido, este documento propõe um conjunto de diálogos para formar a base de conhecimento inicial da *Plataforma Conversacional*. Tais diálogos estão agrupados por módulos funcionais, conforme a Tabela 5.1.

O módulo funcional correspondente a Infoentretenimento engloba diálogos que permitem ao usuário ter acesso a conteúdos de informações e entretenimento disponibilizados como serviços a bordo do veículo ou por meio de serviços externos disponíveis em uma infraestrutura de rede. A Tabela 5.2 apresenta uma proposta de diálogos vinculados a esse módulo.

O módulo funcional correspondente a Configuração de Bordo engloba diálogos que permitem ao usuário requisitar informações de estado e acionar controles do veículo. A Tabela 5.3 apresenta uma proposta de diálogos relacionados a esse módulo.

O módulo funcional de Navegação é o que permite ao usuário utilizar o veículo autônomo para sua mobilidade. Os diálogos propostos são mostrados na Tabela 5.4.

O módulo funcional de Comunicação, cujos diálogos encontram-se na Tabela 5.5, possibilita ao usuário interagir com outras pessoas durante o percurso, por meio da conexão do veículo com uma rede de dados.

Tabela 5.1 – Módulos funcionais para agrupamento dos diálogos da *Plataforma Conversacional*

Módulo Funcional	Descrição
Infoentretenimento	Possibilita ao usuário fazer solicitações a serviços que proveem conteúdo relacionado a informações e entretenimento.
Configuração de Bordo	Possibilita ao usuário obter informações sobre o estado do veículo, bem como alterar configurações internas.
Navegação	Permite que o usuário possa indicar o destino desejado, bem como realizar outras solicitações relacionadas com a navegação do veículo.
Comunicação	Possibilita ao usuário estabelecer a comunicação com outras pessoas por meio do envio de mensagens ou a realização de ligações telefônicas utilizando o sistema de comunicação do veículo.

Fonte: Elaborada pelo autor.

Tabela 5.2 – Diálogos propostos para o módulo funcional de Infoentretenimento

Diálogo	Descrição
Procurar vídeo	Solicitar a busca e exibição de vídeo ou filme disponível em um serviço de <i>streaming</i> .
Procurar música	Solicitar a busca e execução de uma determinada música disponível em um serviço de <i>streaming</i> .
Pausar música	Solicitar a interrupção temporária da execução da música.
Continuar música	Solicitar a continuação da execução da música.
Solicitar recomendação de local	Procurar por locais desejados pelo usuário, como restaurantes, farmácias, cinema, etc. Caso o usuário escolha um dos locais sugeridos, a localização do mesmo deve ser utilizada como destino no módulo de Navegação.
Assistir a vídeo-aula	Buscar vídeo-aula sobre um determinado assunto disponível em uma plataforma de conteúdo de aulas.
Acessar jogo online	Buscar um jogo desejado em uma plataforma de jogos online.

Fonte: Elaborada pelo autor.

Tabela 5.3 – Diálogos propostos para o módulo funcional de Configuração de Bordo

Diálogo	Descrição
Calibragem dos pneus	Solicitar informações sobre a pressão atual dos pneus.
Nível de combustível/bateria	Solicitar informações sobre o nível de combustível ou da bateria em carros elétricos.
Autonomia do veículo	Solicitar informações sobre a distância que o carro ainda pode percorrer antes de precisar reabastecer ou recarregar.
Estado geral do veículo	Solicitar informações sobre o funcionamento geral do veículo.
Ligar/desligar luz interna	Controlar o estado da luz do habitáculo do veículo.
Ligar/desligar faróis	Controlar o estado dos faróis do veículo.
Ligar/desligar limpadores de para-brisas	Controlar o estado dos limpadores de para-brisas do veículos.
Travar/destravar portas	Solicitar abertura ou trancamento das portas do veículo.
Levantar/baixar vidros laterais	Controlar o acionamento dos vidros laterais do veículo.
Abrir/fechar teto solar	Controlar o funcionamento do teto solar do veículo.
Parar veículo	Solicitar ao veículo que pare em um local permitido e seguro.
Ligar/desligar veículo	Solicitar ao veículo que ligue/desligue o motor.
Sintonizar estação de rádio	Informar uma estação de rádio desejada.
Avançar/retroceder rádio	Solicitar que avance ou retroceda para outra estação de rádio.
Aumentar/diminuir volume	Controlar o volume do sistema de saída de áudio do veículo.
Sintonizar canal de TV	Informar um canal de TV desejado.
Avançar/retroceder canal de TV	Avançar ou retroceder para outro canal de TV.

Fonte: Elaborada pelo autor.

Tabela 5.4 – Diálogos propostos para o módulo funcional de Navegação

Diálogo	Descrição
Informar local de destino	Indicar qual o local ou endereço de destino desejado.
Iniciar percurso	Solicitar o início do percurso para o destino selecionado.
Informar ponto de parada na rota	Adicionar outro local ou endereço de parada ao longo de um percurso.
Recalcular rota	Solicitar novo cálculo de rota para o destino desejado.
Selecionar a rota	Escolher uma rota dentre as sugeridas.
Cancelar viagem	Solicitar o cancelamento da viagem.
Procurar local de estacionamento	Solicitar ao veículo que se direcione a um local de estacionamento próximo ao local de destino.

Fonte: Elaborada pelo autor.

Tabela 5.5 – Diálogos propostos para o módulo funcional de Comunicação

Diálogo	Descrição
Realizar chamada de áudio	Solicitar a realização de uma chamada de áudio informando o número do destinatário.
Realizar chamada de vídeo	Solicitar a realização de uma chamada de vídeo informando o número do destinatário.
Atender chamada	Atender uma chamada de áudio ou de vídeo utilizando o sistema de multimídia do veículo.
Ligar/desligar vídeo	Solicitar a ativação ou desativação do vídeo durante uma chamada.
Suspender/retornar chamada	Solicitar que a chamada seja colocada temporariamente em modo de espera. Também pode ser solicitado o retorno a uma chamada em espera.
Encerrar chamada	Solicitar o encerramento da chamada.

Fonte: Elaborada pelo autor.

6 CONCLUSÕES E RECOMENDAÇÕES

6.1 CONCLUSÕES GERAIS

O desenvolvimento de veículos autônomos tem evoluído significativamente nos últimos dez anos. Fatores como o interesse de grandes empresas de tecnologia por essa área, os avanços em termos de algoritmos de aprendizado de máquina e de redes neurais, e o crescente poder computacional dos processadores gráficos têm sido fundamentais para tornar os veículos autônomos uma solução de mobilidade viável e segura.

Diversos benefícios são esperados para a sociedade com o uso de veículos autônomos. Dentre eles, podem ser destacados:

- Redução significativa no número de acidentes de trânsito e, conseqüentemente, na quantidade de mortes de pessoas vítimas desses acidentes;
- Diminuição dos gastos nos serviços de saúde para o tratamento de vítimas de acidentes de trânsito;
- Melhor fluidez no trânsito e, conseqüentemente, menos congestionamentos, dado que veículos autônomos conectados podem cooperar entre si na formação de comboios;
- Melhor eficiência no consumo de combustível e de energia de bateria e, conseqüentemente, menos poluição ambiental e sonora, devido ao fato de veículos autônomos poderem controlar de forma mais eficiente a aceleração;
- Viabilização de mobilidade mais inclusiva, atendendo pessoas idosas e portadoras de necessidades especiais;
- Ampliação do modelo de mobilidade compartilhada em detrimento do modelo tradicional de propriedade do veículo. Com isso, pode-se ter um número menor de veículos em circulação e, conseqüentemente, espaços destinados a estacionamento podem ser revertidos em locais mais úteis à população.

Obviamente, a expansão do uso de veículos autônomos está ligada à superação de vários desafios atualmente existentes. Um deles é o custo, já que o veículo precisa ser dotado de sensores e tecnologias que ainda têm preço elevado. Outro desafio está relacionado a questões de regulamentação. Não à toa, a grande maioria das empresas que utilizam veículos autônomos tem se concentrado mais fortemente nos Estados Unidos e China, onde legislações específicas possibilitam a realização de testes e disponibilização de serviços. Já

a aceitação por parte dos consumidores representa outro obstáculo adicional, o qual passa principalmente pela confiança na segurança funcional da solução autônoma.

Como pode ser observado, o desenvolvimento de veículos autônomos e sua incorporação efetiva no contexto de mobilidade urbana requer o trabalho conjunto de diversos *stakeholders*. Do lado do setor privado, empresas fabricantes de veículos, fornecedores de equipamentos e desenvolvedoras de tecnologias para soluções autônomas. Do lado do setor público, governos, legisladores e demais entidades responsáveis pela viabilização de legislações adequadas, pelo planejamento da infraestrutura das cidades e pela governança dos serviços prestados aos cidadãos. Permeando esses dois setores, tem-se também instituições de pesquisa e universidades, sejam elas públicas ou privadas.

Conforme os objetivos específicos delineados para esta pesquisana Seção 1.2, buscou-se estudar e propor soluções em três tópicos relacionados ao desenvolvimento tecnológico de veículos autônomos.

O primeiro tópico, relacionado aos objetivos **OE1**, **OE2** e **OE3**, englobou questões relativas à estimação de posicionamento em veículos autônomos. Este é um aspecto fundamental para a viabilização da circulação de veículos autônomos em cenários urbanos, já que a presença de prédios, túneis, árvores e outros objetos existentes ao longo das vias afetam significativamente a recepção dos sinais oriundos dos sistemas de navegação via satélite. Nesse ponto foi estudada a adoção de receptores baseados em arranjo de antenas e a utilização de técnicas tensoriais capazes de mitigar os efeitos decorrentes das interferências de multipercurso.

O segundo tópico pesquisado diz respeito à detecção de objetos em volta do veículo e está relacionado aos objetivos **OE1** e **OE3**. Para isso, o veículo autônomo precisa fazer uso de um conjunto de sensores de percepção capazes de coletar dados do mundo em volta do veículo e utilizar técnicas e algoritmos para realizar a fusão desses dados, gerando informações mais precisas sobre os objetos detectados. Nesse ponto, a pesquisa focou no estudo e avaliação de um método de detecção de veículos baseado na fusão de dados brutos de sensores de câmera e LiDAR, demonstrando que esta estratégia de fusão apresentou-se mais eficaz quando comparada com estratégias de fusão de alto nível.

O terceiro e último tópico estudado, relacionado ao objetivo específico **OE4**, está atrelado à concepção de novos modelos de negócio vinculados ao uso de veículos autônomos. Nesse ponto, foi proposta uma arquitetura de um assistente virtual a ser implantado nos veículos com o intuito de facilitar a interação humano-máquina. Essa arquitetura também descreve as integrações entre o assistente virtual e os serviços internos e externos ao veículo. Além disso, foi proposto um processo para o desenvolvimento e evolução da base de conhecimento desse assistente.

6.2 RECOMENDAÇÕES PARA TRABALHOS FUTUROS

Embora este trabalho de pesquisa tenha buscado propor soluções para alguns problemas pertinentes à área de veículos autônomos, a complexidade de tais problemas e as soluções propostas possibilitam vislumbrar oportunidades para diversos trabalhos futuros. Dessa forma, tem-se a seguir um conjunto de recomendações de trabalhos que podem ser investigados a partir dos resultados alcançados nesta pesquisa.

Para o tópico abordado no Capítulo 3, que trata da estimação de localização de veículos autônomos, seria bastante interessante ter *datasets* com medições coletadas em vias do Distrito Federal. Obviamente que a geração desses *datasets* requer a utilização de sensores de GNSS mais avançados, que utilizem técnicas de RTK, para produzir medições verdadeiras (do inglês, *ground truth*) a ser utilizadas como referencial. Outro ponto importante é implementar a solução utilizando outras técnicas tensoriais. Uma sugestão é utilizar a técnica denominada CPD-GEVD e comparar o desempenho com a solução proposta neste documento. Embora se tenha utilizado aqui o modelo EKF, existem outras extensões do Filtro de Kalman que podem ser também avaliadas. Bibliotecas como *Rednose*¹ e *filterpy*² implementam algumas dessas extensões. A comparação do desempenho entre soluções utilizando diferentes extensões é um caminho que pode ser seguido também.

Com relação ao tópico abordado no Capítulo 4, que trata da detecção de objetos, é importante realizar o treinamento utilizando uma quantidade maior de épocas para melhorar a acurácia do modelo. É importante treinar o modelo utilizando versões mais recentes do YOLO para avaliar o desempenho da solução, assim como utilizar não apenas métricas quantitativas para avaliar os resultados, mas métricas qualitativas também. Além disso, considerando a importância da simulação para o contexto de veículos autônomos, é importante implementar e avaliar o desempenho dos modelos em um simulador. Uma opção, nesse caso, é utilizar o simulador CARLA, tendo em vista que é um simulador de código aberto.

Por fim, no tópico abordado no Capítulo 5, é interessante implementar um painel para a interface do assistente virtual, levando-se em conta aspectos ligados a UX. Também é importante validar os diálogos com a participação de pessoas de diferentes áreas e com diferentes níveis de conhecimento, bem como treinar o assistente para compreender múltiplos idiomas. Outro aspecto a ser explorado como trabalho futuro é implementar o assistente virtual como um software embarcado em um veículo real. Além disso, dada a necessidade de comunicação entre o veículo e serviços externos, torna-se relevante também implementar e validar mecanismos de segurança da informação para evitar a possibilidade de ataques cibernéticos e o comprometimento da comunicação.

¹<https://github.com/commaai/rednose>

²<https://github.com/r1abbe/filterpy>

REFERÊNCIAS BIBLIOGRÁFICAS

- 1 KRÖGER, F. Automated Driving in Its Social, Historical and Cultural Contexts. In: _____. *Autonomous Driving: Technical, Legal and Social Aspects*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2016. p. 41–68. ISBN 978-3-662-48847-8. Disponível em: <https://doi.org/10.1007/978-3-662-48847-8_3>. Acesso em: 29 abr. 2022.
- 2 CHENG, H. *Autonomous Intelligent Vehicles: Theory, algorithms, and implementation*. London: Springer-Verlag London, 2011. ISBN 978-1-4471-2280-7. Disponível em: <<https://doi.org/10.1007/978-1-4471-2280-7>>.
- 3 BURNS, L. D.; SHULGAN, C. *Autonomy: The Quest to Build the Driverless Car - And How It Will Reshape Our World*. New York, NY, USA: HarperCollins Publishers Inc., 2018.
- 4 HAWKINS, A. J. *Baidu is the sixth company approved to test fully driverless cars in California*. 2021. Disponível em: <<https://www.theverge.com/2021/1/27/22252944/baidu-driverless-cars-test-permit-california-dmv>>. Acesso em: 28 mar. 2021.
- 5 DMV - DEPARTMENT OF MOTOR VEHICLES. *Autonomous Vehicle Testing Permit Holders*. 2022. Disponível em: <<https://www.dmv.ca.gov/portal/vehicle-industry-services/autonomous-vehicles/autonomous-vehicle-testing-permit-holders/>>. Acesso em: 03 mai. 2022.
- 6 WANG, J.; ZHANG, L.; HUANG, Y.; ZHAO, J. Safety of autonomous vehicles. *Journal of Advanced Transportation*, Hindawi Limited, v. 2020, 2020. ISSN 2042-3195. Disponível em: <<https://doi.org/10.1155/2020/8867757>>.
- 7 MCCAUSLAND, P. *Self-driving Uber car that hit and killed woman did not recognize that pedestrians jaywalk*. 2019. Disponível em: <<https://www.nbcnews.com/tech/tech-news/self-driving-uber-car-hit-killed-woman-did-not-recognize-n1079281>>. Acesso em: 28 mar. 2021.
- 8 ÖZGÜNER, Ü.; ACARMAN, T.; REDMILL, K. *Autonomous Ground Vehicles*. Norwood, MA: Artech House, 2011. ISBN 978-1-60807-192-0.
- 9 SAMDANIS, K.; TALEB, T. The road beyond 5g: A vision and insight of the key technologies. *IEEE Network*, v. 34, n. 2, p. 135–141, 2020. Disponível em: <<https://doi.org/10.1109/MNET.001.1900228>>.
- 10 WHO - WORLD HEALTH ORGANIZATION. *Global status report on road safety 2018*. Geneva: World Health Organization, 2018. Disponível em: <https://www.who.int/violence_injury_prevention/road_safety_status/2018/en/>. Acesso em: 20 nov. 2020.
- 11 SINGH, S. *Critical Reasons for Crashes Investigated in the National Motor Vehicle Crash Causation Survey*. Washington, DC: National Highway Traffic Safety Administration, 2018. Disponível em: <<https://crashstats.nhtsa.dot.gov/Api/Public/ViewPublication/812506>>. Acesso em: 04 mai. 2022.

- 12 CACILO, A.; SCHMIDT, S.; WITTLINGER, P.; HERRMANN, F.; SAWADE, O.; DODERER, H.; HARTWIG, M.; SCHOLZ, V. *Hochautomatisiertes Fahren auf Autobahnen—industriepolitische Schlussfolgerungen, Dienstleistungsprojekt 15/14, Studie im Auftrag des Bundesministeriums für Wirtschaft und Energie (BMWi)*. Stuttgart, Germany: Fraunhofer-Institut für Arbeitswirtschaft und Organisation IAO, 2015. Disponível em: <<https://www.bmwi.de/Redaktion/DE/Downloads/H/hochautomatisiertes-fahren-auf-autobahnen.html>>. Acesso em: 04 mai. 2022.
- 13 PRODANOV, C. C.; FREITAS, E. C. de. *Metodologia do Trabalho Científico: Métodos e técnicas da pesquisa e do trabalho acadêmico*. Novo Hamburgo: Feevale, 2013. ISBN 978-85-7717-158-3.
- 14 MITCHELL, H. B. *Data Fusion: Concepts and Ideas*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. ISBN 978-3-642-27221-9. Disponível em: <<https://doi.org/10.1007/978-3-642-27222-6>>.
- 15 AEBERHARD, M.; KAEMPCHEN, N. High-Level Sensor Data Fusion Architecture for Vehicle Surround Environment Perception. In: 8th International Workshop on Intelligent Transportation (WIT), 2011, Hamburg, Germany. *Proceedings [...]*. [S.l.], 2011. p. 173–178.
- 16 FALLETTI, E.; MARGARIA, D.; MARUCCO, G.; MOTELLA, B.; NICOLA, M.; PINI, M. Synchronization of critical infrastructures dependent upon gns: Current vulnerabilities and protection provided by new signals. *IEEE Systems Journal*, v. 13, n. 3, p. 2118–2129, 2019. Disponível em: <<https://doi.org/10.1109/JSYST.2018.2883752>>.
- 17 KAPLAN, E. D.; HEGARTY, C. J. *Understanding GPS/GNSS: Principles and applications*. Norwood, MA: Artech House, 2017. ISBN 978-1-63081-058-0.
- 18 KLANČAR, G.; ZDEŠAR, A.; BLAŽIČ, S.; ŠKRJANC, I. Sensors Used in Mobile Systems. In: _____. *Wheeled Mobile Robotics: from fundamentals towards autonomous systems*. Oxford, United Kingdom: Butterworth-Heinemann, 2017. p. 207–288. ISBN 978-0-12-804204-5. Disponível em: <<https://doi.org/10.1016/B978-0-12-804204-5.00005-6>>.
- 19 EDELKAMP, S.; SCHRÖDL, S. Vehicle Navigation. In: _____. *Heuristic Search: Theory and applications*. Burlington, Massachusetts: Morgan Kaufmann, 2012. cap. 17, p. 737–757. ISBN 978-0-12-372512-7. Disponível em: <<https://doi.org/10.1016/B978-0-12-372512-7.00017-1>>.
- 20 ISO - INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. *Road vehicles — Vehicle dynamics and road-holding ability — Vocabulary (ISO 8855:2011)*. Geneva, Switzerland, 2011. Disponível em: <<https://www.iso.org/standard/51180.html>>. Acesso em: 04 mai. 2022.
- 21 CHRIST, R. D.; WERNLI, R. L. Navigational sensors. In: _____. *The ROV Manual: A user guide for remotely operated vehicles*. Second edition. Oxford: Butterworth-Heinemann, 2014. cap. 17, p. 453 – 475. ISBN 978-0-08-098288-5. Disponível em: <<https://doi.org/10.1016/B978-0-08-098288-5.00017-8>>.
- 22 PENDÃO, C.; FERREIRA, A.; MOREIRA, A.; MARTINS, C.; SILVA, H. Challenges in characterization of gns precise positioning systems for automotive. In: International Conference on Localization and GNSS (ICL-GNSS 2020), 2020, Tampere,

- Finland. *Proceedings* [...]. Aachen, Germany: CEUR, 2020. p. 1–13. Disponível em: <<http://ceur-ws.org/Vol-2626/paper4.pdf>>. Acesso em: 04 mai. 2022.
- 23 DISSANAYAKE, M. W. M. G.; NEWMAN, P.; CLARK, S.; DURRANT-WHYTE, H. F.; CSORBA, M. A solution to the simultaneous localization and map building (slam) problem. *IEEE Transactions on Robotics and Automation*, v. 17, n. 3, p. 229–241, 2001. Disponível em: <<https://doi.org/10.1109/70.938381>>.
- 24 VAN BRUMMELEN, J.; O'BRIEN, M.; GRUYER, D.; NAJJARAN, H. Autonomous vehicle perception: The technology of today and tomorrow. *Transportation Research Part C: Emerging Technologies*, v. 89, p. 384–406, 2018. ISSN 0968-090X. Disponível em: <<https://doi.org/10.1016/j.trc.2018.02.012>>.
- 25 JIAO, J. Machine learning assisted high-definition map creation. In: 2018 IEEE 42ND ANNUAL COMPUTER SOFTWARE AND APPLICATIONS CONFERENCE (COMPSAC), 2018, Tokyo, Japan. *Proceedings* [...]. Piscataway, NJ: IEEE, 2018. p. 367–373. Disponível em: <<https://www.doi.org/10.1109/COMPSAC.2018.00058>>.
- 26 JO, K.; KIM, C.; SUNWOO, M. Simultaneous localization and map change update for the high definition map-based autonomous driving car. *Sensors*, v. 18, n. 9, 2018. ISSN 1424-8220. Disponível em: <<https://www.doi.org/10.3390/s18093145>>.
- 27 LIU, R.; WANG, J.; ZHANG, B. High Definition Map for Automated Driving: Overview and Analysis. *Journal of Navigation*, Cambridge University Press, v. 73, n. 2, p. 324–341, 2020. Disponível em: <<https://doi.org/10.1017/S0373463319000638>>.
- 28 NDS. *Navigation Data Standard: The worldwide standard for map data in automotive eco-systems*. 2020. Disponível em: <<https://nds-association.org/>>. Acesso em: 04 mai. 2022.
- 29 KLEINE-BESTENA, T.; BEHRENS, R.; PöCHMÜLLER, W.; ENGELSBERGB, A. Digital maps for adas. In: WINNER, H.; HAKULI, S.; LOTZ, F.; SINGER, C. (Ed.). *Handbook of Driver Assistance Systems: Basic Information, Components and Systems for Active Safety and Comfort*. Switzerland: Springer International Publishing, 2015.
- 30 KONRAD, M.; SZCZOT, M.; SCHULE, F.; DIETMAYER, K. Generic grid mapping for road course estimation. In: 2011 IEEE INTELLIGENT VEHICLES SYMPOSIUM (IV), 2011, Baden-Baden, Germany. *Proceedings* [...]. Piscataway, NJ: IEEE, 2011. p. 851–856. Disponível em: <<https://doi.org/10.1109/IVS.2011.5940514>>.
- 31 HUBERTUS, P. *The Benefits of a Common Map Data Standard for Autonomous Driving*. [S.l.], 2019. Disponível em: <https://nds-association.org/wp-content/uploads/2019/06/NDS-White-Paper__Benefits-of-Map-Data-Standard-for-Autonomous-Driving.pdf>. Acesso em: 04 mai. 2022.
- 32 NDS. *NDS Open Lane Model*. 2020. Disponível em: <<https://www.openlanemodel.org/>>. Acesso em: 04 mai. 2022.
- 33 ASAM. *OpenDRIVE*. 2020. Disponível em: <<https://www.asam.net/standards/detail/opendrive/>>. Acesso em: 04 mai. 2022.

- 34 DOSOVITSKIY, A.; ROS, G.; CODEVILLA, F.; LOPEZ, A.; KOLTUN, V. CARLA: An Open Urban Driving Simulator. In: 1ST ANNUAL CONFERENCE ON ROBOT LEARNING, 2017, Mountain View, California. *Proceedings [...]*. PMLR, 2017. p. 1–16. Disponível em: <<http://proceedings.mlr.press/v78/dosovitskiy17a.html>>. Acesso em: 04 mai. 2022.
- 35 POGGENHANS, F.; PAULS, J.; JANOSOVITS, J.; ORF, S.; NAUMANN, M.; KUHNT, F.; MAYR, M. Lanelet2: A high-definition map framework for the future of automated driving. In: 2018 21ST INTERNATIONAL CONFERENCE ON INTELLIGENT TRANSPORTATION SYSTEMS (ITSC), 2018, Maui, HI, USA. *Proceedings [...]*. Piscataway, NJ: IEEE, 2018. p. 1672–1679. Disponível em: <<https://www.doi.org/10.1109/ITSC.2018.8569929>>.
- 36 FUKUSHIMA, M.; OGAWA, N. Overview of sip dynamic map research and development for automated driving. In: *SIP-adus: Project Reports, 2014-2018 - Automated Driving for Universal Services*. Tokyo, Japan: [s.n.], 2018. Disponível em: <https://en.sip-adus.go.jp/file/rd-result_all.pdf>. Acesso em: 04 mai. 2022.
- 37 XIE, P.; PETOVELLO, M. G. Measuring gnss multipath distributions in urban canyon environments. *IEEE Transactions on Instrumentation and Measurement*, v. 64, n. 2, p. 366–377, 2015. Disponível em: <<https://doi.org/10.1109/TIM.2014.2342452>>.
- 38 ZANATTA, M. da R.; DE MENDONÇA, F. L. L.; ANTREICH, F.; DE LIMA, D. V.; MIRANDA, R. K.; GALDO, G. D.; DA COSTA, J. P. C. L. Tensor-based time-delay estimation for second and third generation global positioning system. *Digital Signal Processing*, Elsevier Inc., v. 92, p. 1–19, sep 2019. ISSN 1051-2004. Disponível em: <<https://doi.org/10.1016/j.dsp.2019.04.003>>.
- 39 HAMMOUD, B.; ANTREICH, F.; NOSSEK, J. A.; DA COSTA, J. P. C. L.; DE ALMEIDA, A. L. F. Tensor-Based Approach for Time-Delay Estimation. In: WSA 2016; 20th International ITG Workshop on Smart Antennas, 2016, Munich, Germany. *Proceedings [...]*. Berlin, Germany: VDE, 2016. p. 103–109. Disponível em: <<https://ieeexplore.ieee.org/document/7499110>>. Acesso em: 04 mai. 2022.
- 40 DE LIMA, D. V.; DA COSTA, J. P. C. L.; ANTREICH, F.; MIRANDA, R. K.; GALDO, G. D. Time-Delay estimation via CPD-GEVD applied to tensor-based GNSS arrays with errors. In: 2017 IEEE 7th International Workshop on Computational Advances in Multi-Sensor Adaptive Processing (CAMSAP), 2017, Curacao, Netherlands Antilles. *Proceedings [...]*. Piscataway, NJ: IEEE, 2017. p. 1–5. Disponível em: <<https://doi.org/10.1109/CAMSAP.2017.8313098>>.
- 41 DE LIMA, D. V.; DA COSTA, J. P. C. L.; MARANHÃO, J. P. A.; DE SOUSA JÚNIOR, R. T. Time-Delay Estimation via Procrustes Estimation and Khatri-Rao Factorization for GNSS Multipath Mitigation. In: 2017 11TH INTERNATIONAL CONFERENCE ON SIGNAL PROCESSING AND COMMUNICATION SYSTEMS (ICSPCS), 2017, Gold Coast, QLD, Australia. *Proceedings [...]*. Piscataway, NJ: IEEE, 2017. p. 1–7. Disponível em: <<https://doi.org/10.1109/ICSPCS.2017.8270464>>.
- 42 ZANATTA, M. da R.; MIRANDA, R. K.; DA COSTA, J. P. C. L.; ANTREICH, F.; DE LIMA, D. V. Antenna Array based Receivers for Third Generation Global Positioning System. In: 2017 Workshop on Communication Networks and Power Systems (WCNPS),

- 2017, Brasília, Brazil. *Proceedings [...]*. Piscataway, NJ: IEEE, 2017. p. 1–4. Disponível em: <<https://doi.org/10.1109/WCNPS.2017.8252937>>.
- 43 ZANATTA, M. da R.; DE LIMA, D. V.; DA COSTA, J. P. C. L.; MIRANDA, R. K.; ANTREICH, F.; DE SOUSA JÚNIOR, R. T. Técnica tensorial de estimação de atraso para gps de segunda e terceira geração. In: XXXVI Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBRT2018), 2018, Campina Grande, Brasil. *Anais [...]*. Rio de Janeiro, Brasil: Sociedade Brasileira de Telecomunicações, 2018. p. 1054–1059. Disponível em: <<https://doi.org/10.14209/SBRT.2018.130>>.
- 44 U.S. AIR FORCE. *Interface Specification IS-GPS-800D: Navstar GPS Space Segment/User Segment L1C Interface*. 2013. Disponível em: <<https://www.gps.gov/technical/icwg/IS-GPS-800D.pdf>>. Acesso em: 04 mai. 2022.
- 45 KALMAN, R. E. A New Approach to Linear Filtering and Prediction Problems. *Journal of Basic Engineering*, v. 82, n. 1, p. 35–45, 1960. ISSN 0021-9223. Disponível em: <<https://doi.org/10.1115/1.3662552>>. Acesso em: 04 mai. 2022.
- 46 BARFOOT, T. D. *State Estimation for Robotics*. Cambridge: Cambridge University Press, 2017.
- 47 WOOD, A. J.; WOLLENBERG, B. F.; SHEBLÉ, G. B. *Power Generation, Operation, and Control*. Hoboken, NJ: John Wiley & Sons Inc., 2013.
- 48 MCGEE, L. A.; SCHMIDT, S. F. Discovery of the Kalman filter as a practical tool for aerospace and industry. 1985.
- 49 SANTOS, G. A.; DA COSTA, J. P. C. L.; DE LIMA, D. V.; ZANATTA, M. da R.; PRACIANO, B. J. G.; PINHEIRO, G. P. M.; DE MENDONÇA, F. L. L.; DE SOUSA JÚNIOR, R. T. Improved localization framework for autonomous vehicles via tensor and antenna array based GNSS receivers. In: 2020 Workshop on Communication Networks and Power Systems (WCNPS), 2020, Brasília, Brasil. *Proceedings [...]*. Piscataway, NJ: IEEE, 2020. p. 1–6. Disponível em: <<https://doi.org/10.1109/WCNPS50723.2020.9263757>>.
- 50 NOVATEL. *PwrPak7-E1 Product Sheet*. 2017. Disponível em: <<https://novatel.com/products/gnss-inertial-navigation-systems/combined-systems/pwrpak7-e1>>. Acesso em: 04 mai. 2022.
- 51 DANAPAL, G.; SANTOS, G. A.; DA COSTA, J. P. C. L.; PRACIANO, B. J. G.; PINHEIRO, G. P. M. Sensor fusion of camera and LiDAR raw data for vehicle detection. In: 2020 Workshop on Communication Networks and Power Systems (WCNPS), 2020, Brasília, Brasil. *Proceedings [...]*. Piscataway, NJ: IEEE, 2020. p. 1–6. Disponível em: <<https://doi.org/10.1109/WCNPS50723.2020.9263724>>.
- 52 DIGNE, J.; FRANCHIS, C. de. The Bilateral Filter for Point Clouds. *Image Processing On Line*, IPOL - Image Processing on Line, v. 7, p. 278 – 287, 2017. Disponível em: <<https://doi.org/10.5201/ipol.2017.179>>.
- 53 REDMON, J.; FARHADI, A. Yolov3: An incremental improvement. *arXiv preprint arXiv:1804.02767*, 2018. Disponível em: <<https://arxiv.org/abs/1804.02767>>. Acesso em: 04 mai. 2022.

- 54 GEIGER, A.; LENZ, P.; STILLER, C.; URTASUN, R. Vision meets robotics: The kitti dataset. *International Journal of Robotics Research (IJRR)*, SAGE Publishing, v. 32, p. 1231–1237, sep 2013. ISSN 0278-3649. Disponível em: <<https://doi.org/10.1177/0278364913491297>>.
- 55 EVERINGHAM, M.; GOOL, L. V.; WILLIAMS, C. K. I.; WINN, J.; ZISSERMAN, A. The PASCAL Visual Object Classes (VOC) Challenge. *International Journal of Computer Vision*, Springer, v. 88, p. 303–338, 2010. Disponível em: <<https://doi.org/10.1007/s11263-009-0275-4>>.
- 56 NHTSA - NATIONAL HIGHWAY TRAFFIC SAFETY ADMINISTRATION. *Newer Cars Are Safer Cars*. Washington, DC: National Highway Traffic Safety Administration, 2018. Disponível em: <<https://www.nhtsa.gov/newer-cars-are-safer-cars>>. Acesso em: 04 mai. 2022.
- 57 DOLLAR, P.; WOJEK, C.; SCHIELE, B.; PERONA, P. Pedestrian detection: A benchmark. In: 2009 IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2009, Miami, FL, USA. *Proceedings [...]*. Piscataway, NJ: IEEE, 2009. p. 304–311. Disponível em: <<https://doi.org/10.1109/CVPR.2009.5206631>>.
- 58 DALAL, N.; TRIGGS, B. Histograms of oriented gradients for human detection. In: 2005 IEEE COMPUTER SOCIETY CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR'05), 2005, San Diego, CA, USA. *Proceedings [...]*. Piscataway, NJ: IEEE, 2005. v. 1, p. 886–893 vol. 1. Disponível em: <<https://doi.org/10.1109/CVPR.2005.177>>.
- 59 CASTELINO, R. M.; PINHEIRO, G. P. M.; PRACIANO, B. J. G.; SANTOS, G. A.; WEICHENBERGER, L.; DE SOUSA JÚNIOR, R. T. Improving the Accuracy of Pedestrian Detection in Partially Occluded or Obstructed Scenarios. In: 10th International Conference on Advanced Computer Information Technologies (ACIT), 2020, Deggendorf, Germany. *Proceedings [...]*. Piscataway, NJ: IEEE, 2020. p. 834–838. ISBN 978-1-7281-6760-2. Disponível em: <<https://doi.org/10.1109/ACIT49673.2020.9208877>>.
- 60 THU, M.; SUVONVORN, N.; KARNJANADECHA, M. A new dataset benchmark for pedestrian detection. In: 3RD INTERNATIONAL CONFERENCE ON BIOMEDICAL SIGNAL AND IMAGE PROCESSING, 2018, Seoul, Republic of Korea. *Proceedings [...]*. New York, NY, USA: Association for Computing Machinery, 2018. p. 17–22. Disponível em: <<https://doi.org/10.1145/3278229.3278243>>.
- 61 DALAL, N. *INRIA Person Dataset*. 2018. Disponível em: <<http://pascal.inrialpes.fr/data/human/>>. Acesso em: 28 mar. 2021.
- 62 SIMONAZZI, A.; SANGINÉS, J. J. C.; RUSSO, M. The future of the automotive industry: dangerous challenges or new life for a saturated market? *Institute for New Economic Thinking Working Paper Series*, Institute for New Economic Thinking, p. 1–34, 11 2020. Disponível em: <<https://doi.org/10.36687/INETWP141>>.
- 63 SANGUESA, J. A.; TORRES-SANZ, V.; GARRIDO, P.; MARTINEZ, F. J.; MARQUEZ-BARJA, J. M. A review on electric vehicles: Technologies and challenges. *Smart Cities*, v. 4, n. 1, p. 372–404, 2021. ISSN 2624-6511. Disponível em: <<https://doi.org/10.3390/smartcities4010022>>.

- 64 BROWN, D.; FLICKENSCHILD, M.; MAZZI, C.; GASPAROTTI, A.; PANAGIOTIDOU, Z.; DINGEMANSE, J.; BRATZEL, S. *The Future of the EU Automotive Sector*. Luxembourg: Policy Department for Economic, Scientific and Quality of Life Policies - European Parliament, 2021. Disponível em: <[https://www.europarl.europa.eu/RegData/etudes/STUD/2021/695457/IPOL_STU\(2021\)695457_EN.pdf](https://www.europarl.europa.eu/RegData/etudes/STUD/2021/695457/IPOL_STU(2021)695457_EN.pdf)>. Acesso em: 29 abr. 2022.
- 65 WHO - WORLD HEALTH ORGANIZATION. *Ageing*. Geneva: World Health Organization, 2022. Disponível em: <<https://www.who.int/health-topics/ageing>>. Acesso em: 29 abr. 2022.
- 66 THE WORLD BANK. *Disability Inclusion Overview*. Washington: The World Bank, 2022. Disponível em: <<https://www.worldbank.org/en/topic/disability>>. Acesso em: 29 abr. 2022.
- 67 SILVA, M. M. da; GUERREIRO, J. On the 5g and beyond. *Applied Sciences*, MDPI AG, v. 10, n. 20, p. 1–12, Oct 2020. ISSN 2076-3417. Disponível em: <<https://doi.org/10.3390/app10207091>>.
- 68 LIU, S.; LIU, L.; TANG, J.; YU, B.; WANG, Y.; SHI, W. Edge computing for autonomous driving: Opportunities and challenges. *Proceedings of the IEEE*, v. 107, n. 8, p. 1697–1716, 2019. Disponível em: <<https://doi.org/10.1109/JPROC.2019.2915983>>.
- 69 WINDPASSINGER, H. On the Way to a Software-defined Vehicle. *ATZelectronics worldwide 2022*, Springer, v. 17, n. 7, p. 48–51, jul 2022. ISSN 2524-8804. Disponível em: <<https://doi.org/10.1007/S38314-022-0779-Z>>.
- 70 RUCKRIEGEL, H.; FLOYD, J.; RICHTER, W. *Automotive transformation to software-defined vehicles: Red Hat point of view and synergies with state-of-the-art IT*. 2021. Disponível em: <<https://www.redhat.com/en/blog/automotive-transformation-software-defined-vehicles-red-hat-point-view-and-synergies-state-art-it>>. Acesso em: 10 jul. 2022.
- 71 ARSLAN, S. *With Apex.AI to the Software-Defined Vehicle*. 2020. Disponível em: <<https://www.apex.ai/post/with-apex-ai-to-the-software-defined-vehicle>>. Acesso em: 10 jul. 2022.
- 72 ROBOT Operating System. 2022. <<https://ros.org>>. Acesso em: 10 jul. 2022.
- 73 AUTOSAR. *Adaptive Platform*. 2022. <<https://www.autosar.org/standards/adaptive-platform/>>. Acesso em: 10 jul. 2022.
- 74 APEX.MIDDLEWARE. 2022. <<https://www.apex.ai/apex-middleware>>. Acesso em: 10 jul. 2022.
- 75 APEX.OS. 2022. <<https://www.apex.ai/apex-os>>. Acesso em: 10 jul. 2022.
- 76 RABBITMQ. 2022. <<https://www.rabbitmq.com/>>. Acesso em: 10 jul. 2022.
- 77 FREERTOS. *Real-time operating system for microcontrollers*. 2022. <<https://www.freertos.org/>>. Acesso em: 10 jul. 2022.
- 78 QNX. *Blackberry QNX*. 2022. <<https://blackberry.qnx.com>>. Acesso em: 10 jul. 2022.

- 79 KAMARGIANNI, M.; MATYAS, M. The business ecosystem of mobility as a service. In: 96th Transportation Research Board (TRB) Annual Meeting, 2017, Washington DC, US. *Proceedings [...]*. London, UK: UCL discovery, 2017. p. 1–14. Disponível em: <<https://discovery.ucl.ac.uk/id/eprint/10037890/>>. Acesso em: 29 abr. 2022.
- 80 JITTRAPIROM, P.; CAIATI, V.; FENERI, A. M.; EBRAHIMIGHAREHBAGHI, S.; ALONSO-GONZÁLEZ, M. J.; NARAYAN, J. Mobility as a service: A critical review of definitions, assessments of schemes, and key challenges. *Urban Planning*, Cogitatio Press, v. 2, p. 13–25, 2017. ISSN 2183-7635. Disponível em: <<https://doi.org/10.17645/UP.V2I2.931>>.
- 81 MOORE, J. F. Predators and prey: a new ecology of competition. *Harvard business review*, Harvard Business School Publishing, v. 71, n. 3, p. 75–86, 1993. Disponível em: <<http://blogs.harvard.edu/jim/files/2010/04/Predators-and-Prey.pdf>>. Acesso em: 29 abr. 2022.
- 82 SMITH, G.; SOCHOR, J.; KARLSSON, I. C. M. Mobility as a service: Development scenarios and implications for public transport. *Research in Transportation Economics*, Elsevier, v. 69, p. 592–599, 9 2018. ISSN 0739-8859. Disponível em: <<https://doi.org/10.1016/J.RETREC.2018.04.001>>.
- 83 WOLFF, S.; AUERNHAMMER, J.; SCHOCKENHOFF, F.; ANGERER, C.; WITTMANN, M. MOBILITY BOX: A DESIGN RESEARCH METHODOLOGY TO EXAMINE PEOPLE’S NEEDS IN RELATION TO AUTONOMOUS VEHICLE DESIGNS AND MOBILITY BUSINESS MODEL. In: *Proceedings of the Design Society: DESIGN Conference*. Cambridge University Press, 2020. v. 1, p. 1185–1194. Disponível em: <<https://doi.org/10.1017/dsd.2020.285>>.
- 84 RISSOLI, V. R. V.; SANTOS, G. A. O Agente Pedagógico Animado MInA. In: XXIV Simpósio Brasileiro de Informática na Educação (SBIE), 2013, Campinas, São Paulo. *Anais do [...]*. Porto Alegre: Sociedade Brasileira de Computação, 2013. p. 828–837. ISSN 2316-6533. Disponível em: <<http://doi.org/10.5753/cbie.sbie.2013.828>>.
- 85 DE ANDRADE, G. G.; SILVA, G. R. S.; DUARTE JÚNIOR, F. C. M.; SANTOS, G. A.; DE MENDONÇA, F. L. L.; DE SOUSA JÚNIOR, R. T. EvaTalk: A Chatbot System for the Brazilian Government Virtual School. In: 22nd International Conference on Enterprise Information Systems (ICEIS), 2020, Prague, Czech Republic. *Proceedings [...]*. Setúbal, Portugal: SciTePress, 2020. v. 1, p. 556–562. ISBN 978-989-758-423-7. Disponível em: <<https://doi.org/10.5220/0009418605560562>>.
- 86 IORGA, M.; FELDMAN, L.; BARTON, R.; MARTIN, M.; GOREN, N.; MAHMOUDI, C. *Fog Computing Conceptual Model*. Special Publication (NIST SP), National Institute of Standards and Technology, Gaithersburg, MD, 2018. Disponível em: <<https://doi.org/10.6028/NIST.SP.500-325>>. Acesso em: 29 abr. 2022.
- 87 WASEEM, M.; LIANG, P.; SHAHIN, M. A Systematic Mapping Study on Microservices Architecture in DevOps. *Journal of Systems and Software*, Elsevier, v. 170, p. 1–30, 12 2020. ISSN 0164-1212. Disponível em: <<https://doi.org/10.1016/J.JSS.2020.110798>>.

- 88 CERNY, T.; DONAHOO, M. J.; TRNKA, M. Contextual understanding of microservice architecture: current and future directions. *ACM SIGAPP Applied Computing Review*, ACM, New York, NY, USA, v. 17, p. 29–45, 1 2018. ISSN 1559-6915. Disponível em: <<https://doi.org/10.1145/3183628.3183631>>.
- 89 CASTRO E MARTINS, L. M.; CALDAS FILHO, F. L.; DE SOUSA JÚNIOR, R. T.; GIOZZA, W. F.; DA COSTA, J. P. C. L. Proposta de adoção de microsserviços em IoT. *Conferências Ibero-Americanas WWW/Internet e Computação Aplicada*, 2017.
- 90 POWER, D. J.; HEAVIN, C.; MCDERMOTT, J.; DALY, M. Defining business analytics: An empirical approach. *Journal of Business Analytics*, Taylor & Francis, v. 1, n. 1, p. 40–53, 2018. Disponível em: <<https://doi.org/10.1080/2573234X.2018.1507605>>.
- 91 MILOSLAVSKAYA, N.; TOLSTOY, A. Big Data, Fast Data and Data Lake Concepts. *Procedia Computer Science*, v. 88, p. 300–305, 2016. ISSN 1877-0509. Disponível em: <<https://doi.org/10.1016/j.procs.2016.07.439>>.
- 92 CHAVES, A. P.; GEROSA, M. A. How should my chatbot interact? a survey on social characteristics in human–chatbot interaction design. *International Journal of Human–Computer Interaction*, Taylor & Francis, v. 0, n. 0, p. 1–30, 2020. Disponível em: <<https://doi.org/10.1080/10447318.2020.1841438>>.
- 93 SANTOS, G. A.; DE ANDRADE, G. G.; SILVA, G. R. S.; DUARTE JÚNIOR, F. C. M.; DA COSTA, J. P. J.; DE SOUSA JÚNIOR, R. T. A Conversation-Driven Approach for Chatbot Management. *IEEE Access*, v. 10, p. 8474–8486, 2022. ISSN 2169-3536. Disponível em: <<https://doi.org/10.1109/ACCESS.2022.3143323>>.
- 94 VALÉRIO, F. A. M.; GUIMARÃES, T. G.; PRATES, R. O.; CANDELLO, H. Here’s What I Can Do: Chatbots’ Strategies to Convey Their Features to Users. In: *Proceedings of the XVI Brazilian Symposium on Human Factors in Computing Systems*. New York, NY, USA: Association for Computing Machinery, 2017. (IHC 2017). ISBN 9781450363778. Disponível em: <<https://doi.org/10.1145/3160504.3160544>>.
- 95 ZIAKOPOULOS, A.; THEOFILATOS, A.; PAPADIMITRIOU, E.; YANNIS, G. A meta-analysis of the impacts of operating in-vehicle information systems on road safety. *IATSS Research*, Elsevier, v. 43, n. 3, p. 185–194, 2019. Disponível em: <<https://doi.org/10.1016/j.iatssr.2019.01.003>>.
- 96 LEE, S. C.; YOON, S. H.; JI, Y. G. Effects of Non-Driving-Related Task Attributes on Takeover Quality in Automated Vehicles. *International Journal of Human–Computer Interaction*, Taylor & Francis, v. 37, n. 3, p. 211–219, 2021. Disponível em: <<https://doi.org/10.1080/10447318.2020.1815361>>.