



SAULO ALVES GREGO

**ESTUDO DA PADRONIZAÇÃO DE DADOS PARA
DISPOSITIVO REGISTRADOR EM VEÍCULOS
TERRESTRES INTELIGENTES E SISTEMA DE
RECONSTRUÇÃO VISUAL COMO FERRAMENTA DE
SUPORTE PARA A ANÁLISE DE ACIDENTES**

**LAVRAS – MG
2018**

SAULO ALVES GREGO

**ESTUDO DA PADRONIZAÇÃO DE DADOS PARA DISPOSITIVO REGISTRADOR
EM VEÍCULOS TERRESTRES INTELIGENTES E SISTEMA DE
RECONSTRUÇÃO VISUAL COMO FERRAMENTA DE SUPORTE PARA A
ANÁLISE DE ACIDENTES**

Dissertação de Mestrado apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, área de concentração em Engenharia de Sistemas e Automação, para a obtenção do título de Mestre.

Prof. DSc. Arthur de Miranda Neto
Orientador

Prof. DSc. Danilo Alves de Lima
Coorientador

**LAVRAS – MG
2018**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Grego, Saulo Alves.

Estudo da Padronização de Dados para Dispositivo Registrador em Veículos Terrestres Inteligentes e Sistema de Reconstrução Visual como Ferramenta de Suporte para a Análise de Acidentes / Saulo Alves Grego. - 2018.

84 p. : il.

Orientador(a): Arthur de Miranda Neto.

Coorientador(a): Danilo Alves de Lima.

Dissertação (mestrado acadêmico) - Universidade Federal de Lavras, 2018.

Bibliografia.

1. Sistemas de Condução Automatizados. 2. Padrão de Armazenamento de Dados. 3. Reconstrução Visual. I. Neto, Arthur de Miranda. II. Lima, Danilo Alves de. III. Título.

SAULO ALVES GREGO

**ESTUDO DA PADRONIZAÇÃO DE DADOS PARA DISPOSITIVO REGISTRADOR
EM VEÍCULOS TERRESTRES INTELIGENTES E SISTEMA DE
RECONSTRUÇÃO VISUAL COMO FERRAMENTA DE SUPORTE PARA A
ANÁLISE DE ACIDENTES**

**STUDY OF EVENT DATA RECORDER STANDARDIZATION IN INTELLIGENT
TERRESTRIAL VEHICLES AND VISUAL RECONSTRUCTION SYSTEM AS A
SUPPORT TOOL FOR ANALYSIS OF ACCIDENTS**

Dissertação de Mestrado apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, área de concentração em Engenharia de Sistemas e Automação, para a obtenção do título de Mestre.

APROVADA em 26 de Março de 2018.

Prof. DSc. Giovanni Francisco Rabelo	UFLA
Prof. DSc. Sérgio Teixeira da Silva	UFLA
Prof. DSc. Giovani Bernardes Vitor	UNIFEI

Prof. DSc. Arthur de Miranda Neto

Orientador

Prof. DSc. Danilo Alves de Lima

Coorientador

**LAVRAS – MG
2018**

À minha família

AGRADECIMENTOS

Agradeço primeiramente à minha esposa Vanessa pelo apoio, compreensão e companheirismo incondicionais e também meu filho Daniel. Minhas motivações para nunca desistir.

Agradeço também a meu pai e minha mãe. Infelizmente vocês não puderam presenciar este momento, mas esta conquista só foi possível graças a vocês. Saudades.

Aos meus irmãos, em especial, minha irmã Renata, pelo suporte nos momentos difíceis.

À Universidade Federal de Lavras e ao Departamento de Engenharia, obrigado pela oportunidade.

Ao meu orientador, professor Arthur de Miranda Neto, pelos ensinamentos, motivações e por sempre exigir o melhor de mim. Resultados incríveis foram alcançados por isso.

Ao meu coorientador, professor Danilo Alves de Lima, pelos conselhos, esclarecimentos e disposição para a finalização deste trabalho.

Agradeço também ao professor Giovani Bernardes Vitor pelas contribuições e conhecimentos iniciais prestados à pesquisa.

Aos meus amigos, que compreenderam minhas ausências durante os períodos de dedicação aos estudos e vibraram junto comigo a conclusão de cada etapa.

Aos colegas de mestrado, agradeço pelo companheirismo, amizades conquistadas e conhecimentos compartilhados.

Ao Centro Universitário de Formiga – Unifor MG pelo apoio financeiro concedido.

A todos que de forma direta ou indireta contribuíram para esta realização.

Muito obrigado!

*“Você vê coisas e diz: Por quê?
Mas eu, sonho coisas que nunca existiram e digo: Por que não?”
(George Bernard Shaw)*

RESUMO

Veículos equipados com Sistemas de Condução Automatizados (ADS) são capazes de executar ações inteligentes sem a intervenção humana. Elas são baseadas em dados obtidos por sensores embarcados nos veículos, bem como pelas saídas geradas por sistemas especialistas. Esse processo apresenta incertezas que aumentam em conjunto com a complexidade dos ADS. Neste sentido, um novo conceito de dispositivo registrador de dados, visando apoiar perícias técnicas para investigação e resolução de falhas, foi proposto. Entretanto, a visualização do cenário registrado pelos novos registradores pode ser prejudicada tanto pela complexidade dos dados quanto pela ausência de um padrão de armazenamento dos mesmos. Visando auxiliar na regulamentação de veículos equipados com ADS, este estudo discute os dispositivos registradores de dados em um passo adiante, tendo em vista a diversidade de soluções apresentadas pela comunidade científica e a indústria, em um esforço para a obtenção de um padrão de registro dos dados. A pesquisa também apresenta formas de se realizar a reconstrução visual dos dados armazenados com o objetivo de prover transparência na atribuição de responsabilidades em casos de falhas e acidentes envolvendo os ADS. Resultados preliminares apontam para um padrão de armazenamento que será útil no desenvolvimento de ferramentas de reconstrução visual como auxílio para perícias técnicas.

Palavras-chave: Sistemas de Condução Automatizados. Padrão de Armazenamento de Dados. Incertezas. Reconstrução Visual. Certificação e Homologação.

ABSTRACT

Vehicles equipped with Automated Driving Systems (ADS) are capable to perform intelligent actions without human intervention. They are based on data obtained from sensors embedded in the vehicles, as well as the outputs generated by specialist systems. This process presents uncertainties that increase with the complexity of ADS. In this sense, a new concept of data recording device, aiming to support technical expertise for investigation and resolution of failures was proposed. However, the visualization of the scenario recorded by the new registers can be hampered by the complexity of the data and by the absence of a storage pattern. Aimed at assisting in the regulation of vehicles equipped with ADS, this study discusses the data recording devices in a step further, in view of the diversity of solutions presented by the scientific community and the industry, in an effort to obtain a standard of data storage. The research also presents ways of performing a visual reconstruction of the stored data in order to provide transparency in the attribution of responsibilities in cases of failures and accidents involving the ADS. Preliminary results point to a storage pattern that will be useful in the development of a visual reconstruction system as an aid to technical expertise.

Keywords: Automated Driving Systems. Data Storage Standard. Uncertainties. Visual Reconstruction of Data. Certification and Homologation.

LISTA DE FIGURAS

Figura 1 – Reconstrução de dados não tratados de sensores pelo software Autoware.....	27
Figura 2 – Exemplo de mapa digital 3D.....	30
Figura 3 – Interseção de via obtida da leitura de sensor LIDAR 3D.....	31
Figura 4 – Segmentação semântica de imagens.	32
Figura 5 – Imagem de câmera com reflexão da luz.....	33
Figura 6 – Arquitetura para reconstrução visual para dispositivo registrador de dados.....	36
Figura 7 – Padrão de dados para sistema de localização.	38
Figura 8 – <i>Polyline</i> ligando Oakland nos Estados Unidos e Brisbane na Austrália.....	41
Figura 9 – Resultados preliminares de representação do sistema de localização.....	42
Figura 10 – <i>Circle</i> para representação de populações nos Estados Unidos.....	44
Figura 11 – Representação visual 3D para o sistema de localização.	44
Figura 12 – Definição de pose do sistema de localização em formato de grafo.	46
Figura 13 – Quadro retirado de vídeo gerado com as imagens das câmeras.....	47
Figura 14 – Caixas 2D e 3D de oclusão de objetos.	48
Figura 15 – Nuvem de pontos com visualização 3D.....	49
Figura 16 – Nuvem de pontos em conjunto com imagens de câmeras.....	50
Figura 17 – Segmentação semântica utilizando algoritmo <i>DeepScene</i>	51
Figura 18 – Representação visual do sistema de percepção em formato de grafo.	52
Figura 19 – Reconstrução visual de planejamento de sistema de navegação.....	53
Figura 20 – Representação visual de sistema de navegação em formato de grafo.....	54
Figura 21 – Modelagem do <i>cockpit</i> do veículo.	56
Figura 22 – Representação visual 3D com fusão de sistemas.	59
Figura 23 – Página principal da aplicação <i>web</i> de reconstrução visual.....	60
Figura 24 – Sistema de localização sincronizado com imagens das câmeras.	61
Figura 25 – Comportamento inconsistente de pose do veículo.	63
Figura 26 – Reprodução de imagens da câmera.	64
Figura 27 – Caixa de oclusão para objetos em cena.....	65
Figura 28 – Caixa semântica com rótulos para objetos em cena.....	66
Figura 29 – Segmentação semântica de algoritmos <i>CRF as RNN</i> , <i>DeepScene</i> e <i>SegNet</i>	67
Figura 30 – Segmentação semântica com <i>DeepScene</i>	68
Figura 31 – Segmentação semântica de objetos da cena para sistema de percepção.	69

Figura 32 – Reprodução de nuvem de pontos com visão aérea e 3D.....	70
Figura 33 – Nuvem de pontos com representação de distâncias por cores.	70
Figura 34 – Sequência de ações do sistema de controle.....	72
Figura 35 – Reconstrução visual do sistema de controle.....	72
Figura 36 – Reconstrução visual do sistema de controle com caixa de oclusão.	73
Figura 37 – Reconstrução visual do sistema de controle com caixa semântica.	74
Figura 38 – Reconstrução visual do sistema de controle com segmentação semântica.	74
Figura 39 – Reconstrução visual do sistema de controle com nuvem de pontos por cores.....	75

LISTA DE SIGLAS

ADS	Automated Driving System
ADAS	Advanced Driver Assistance System
AIS	Autonomous Intelligent Systems
API	Application Programming Interface
CCD	Charge-Coupled Device
DARPA	Defense Advanced Research Projects Agency
DDT	Dynamic Driving Task
EDR	Event Data Recorder
FDR	Flight Data Recorder
FPS	Frames per Second
GIS	Geographic Information System
GNSS	Global Navigation Satellite System
GPS	Global Positioning System
HAV	Highly Automated Vehicle
IEEE	Institute of Electrical and Electronics Engineers
IMU	Inertial Measurement Unit
INS	Inertial Navigation System
ISO	International Organization for Standardization
IST	Instrumented Sensor Technology
ITS	Intelligent Transportation System
JSON	Javascript Object Notation
LIDAR	Light Detection and Ranging
NHTSA	National Highway Traffic Safety Administration
ODD	Operational Design Domain
OEDR	Object and Event Detection and Response
PNG	Portable Network Graphics
SAE	Society of Automotive Engineers
UFPA	Universidade Federal de Lavras
V2I	Vehicle to Infrastructure
V2V	Vehicle to Vehicle
XML	eXtensible Markup Language

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Objetivos	15
1.2	Justificativa	16
1.3	Estrutura do trabalho	16
2	REFERENCIAL TEÓRICO	17
2.1	Sistemas de Condução Automatizados	17
2.2	Incertezas em Sistemas de Condução Automatizados	19
2.3	Registradores de Dados	21
2.4	Padrão de Armazenamento de Dados	23
2.5	Suporte à Análise de Falhas e à Certificação e Homologação de Sistemas.....	24
2.6	Reconstrução Visual	26
2.6.1	Localização para Sistemas de Condução Automatizados.....	28
2.6.2	Percepção para Sistemas de Condução Automatizados.....	30
2.6.3	Navegação para Sistemas de Condução Automatizados	33
2.6.4	Controle para Sistemas de Condução Automatizados	34
3	METODOLOGIA	36
3.1	Arquitetura do sistema	36
3.2	Padrão dos dados	37
3.3	Base de Dados.....	39
3.4	Sistema de Localização.....	40
3.4.1	Outras Reconstruções para Sistema de Localização.....	44
3.5	Sistema de Percepção.....	47
3.5.1	Outras Reconstruções para Sistema de Percepção.....	52
3.6	Sistema de Navegação	52
3.7	Sistema de Controle	55
3.7.1	Outras Reconstruções para Sistema de Controle	59
4	RESULTADOS E DISCUSSÕES	60
4.1	Sistema de Localização.....	60
4.2	Sistema de Percepção.....	64
4.3	Sistema de Controle	71
4.4	Considerações Finais	75

5	CONCLUSÃO	77
5.1	Produção Científica.....	77
5.2	Trabalhos Futuros	78
	REFERÊNCIAS	79

1 INTRODUÇÃO

Nas últimas décadas, a mobilidade autônoma por meio de veículos terrestres tem sido alvo de estudo de pesquisadores, indústrias e governos, gerando avanços no desenvolvimento de Sistemas de Condução Automatizados (ADS – do inglês *Automated Driving Systems*). Cada vez mais presentes na sociedade, estes sistemas têm seus níveis de automação classificados de acordo com o padrão definido pela Sociedade de Engenheiros Automotivos (SAE – do inglês *Society of Automotive Engineers*).

Composto por uma combinação de componentes que auxiliam na tomada de decisão do veículo, um ADS está presente em veículos de níveis 3, 4 e 5 da SAE e não se restringe apenas a veículos totalmente autônomos. Suas características estão relacionadas a recursos como auxílio em manobras para estacionamento, sistemas anticolisão, detecção e acompanhamento de faixas, entre diversos outros.

Os benefícios a serem alcançados com os veículos equipados com ADS incluem a redução do estresse de condutores, mobilidade para não condutores e portadores de deficiências, segurança, redução de congestionamentos, economia de combustível, redução da poluição, entre outros (LITMAN, 2015). Para Fagnant e Kockelman (2013), estes sistemas implicarão em uma redução de até 90% no número de acidentes. Eles argumentam que 93% dos acidentes ocorridos nos Estados Unidos têm como causa primária os fatores humanos de condução como abuso de velocidade e condutores distraídos ou alcoolizados. Segundo estudo realizado pela *World Health Organization* (2013), 1,24 milhão de acidentes de trânsito ocorreram no mundo em 2010. Somente no Brasil foram aproximadamente 180 mil, a maioria relacionada à negligência do condutor, más condições das vias, etc.

Neste sentido, os avanços da tecnologia e o aumento do interesse da indústria na produção dos ADS em larga escala permitirão que em poucos anos existam veículos conduzidos por humanos e outros com diferentes recursos inteligentes circulando por vias públicas. Assim, tópicos relacionados à segurança e legalidade dos ADS têm ganhado destaque.

Os trabalhos divulgados pela *National Highway Traffic Safety Administration* – (NHTSA) (NHTSA, 2016) e por Maurer et al. (2015) buscam trazer o tema à tona, exibindo sugestões e orientações baseadas em aspectos técnicos, legais e sociais que possibilitem a inserção de veículos equipados com ADS em ambientes urbanos. Além destes, entidades

como o Parlamento Australiano, o Ministério de Transportes Alemão, o Senado Americano e várias outras têm direcionado suas atenções ao assunto.

Entre os principais pontos de questionamento realizados por estas entidades estão a segurança dos ADS e a definição de responsabilidades de condutores e fabricantes em casos de acidente. Devido à possibilidade de veículos operarem em modo manual ou autônomo, saber quem foi o responsável por um incidente pode ser uma tarefa difícil. Além disso, possíveis imperfeições e irregularidades ocasionadas por componentes de terceiros podem dificultar ainda mais o processo.

Dessa forma, um dispositivo registrador de dados de eventos (EDR – do inglês *Event Data Recorder*), similar ao conceito de caixa-preta de aviões, capaz de armazenar as informações do ADS será eficiente para proporcionar agilidade pericial e segurança jurídica (FRANKE et al., 1999). Ele servirá a múltiplos propósitos, como ser capaz de fornecer informações para uma reconstrução precisa das circunstâncias e motivos de uma falha ou acidente, esclarecendo questões relacionadas as responsabilidades pelo mesmo. Além disso, deve ser capaz de fornecer aos fabricantes a possibilidade de melhorias na segurança do modelo, uma vez que serão avaliadas as deficiências reveladas pela falha (AUSTRALIA, 2017).

Antecipando tais necessidades, o conceito de um registrador de dados, voltado para veículos equipados com ADS, foi proposto (BARBOSA et al., 2016). Tal dispositivo visa armazenar, além dos dados brutos de sensores embarcados no veículo, as saídas de cada um dos componentes participantes do processo de tomada de decisão de um ADS. Ele deve registrar ainda as incertezas, calibrações, erros presentes nos hardwares e a possibilidade de mau funcionamento dos algoritmos. Segundo Barbosa et al. (2016, p. 15), o dispositivo impulsionará a difusão dos ADS, permitindo a identificação das causas de acidentes e provendo maior clareza na identificação de responsabilidades.

Porém, a quantidade de opções tecnológicas voltadas aos ADS e a diversidade de fabricantes e atores, existentes na área de sistemas de transportes inteligentes (ITS), bem como os interesses particulares de cada entidade podem se tornar um entrave na disponibilização da tecnologia em larga escala. Uma constante na visão de entidades políticas e governamentais tem sido quanto à necessidade de definição de padrões relevantes como IEEE, ISO, etc. (NHTSA, 2016; AUSTRALIA, 2017; GERMANY, 2017; UNITED

STATES, 2017). Essa padronização deve incluir uma abordagem uniforme para o armazenamento, reconstrução e compartilhamento de dados.

Sendo assim, é necessário desenvolver um dispositivo registrador de dados que possua alta generalidade. Isso significa que é preciso padronizar o registro de todas as etapas de tomada de decisão do ADS, independente do fabricante, visando à possibilidade de reconstrução do registro realizado.

Especificamente para fins de reconstrução, os dados armazenados devem ser mantidos e estar prontamente disponíveis para recuperação, devendo registrar todas as informações relevantes sobre o estado do ADS (NHTSA, 2016). Um sistema que permita a visualização do cenário registrado proverá maior transparência no processo pericial e na elaboração de ações governamentais, que envolvam o processo de homologação e certificação dos ADS no Brasil.

Neste trabalho será apresentada, portanto, uma reflexão quanto à necessidade de padronização das formas de armazenamento de um dispositivo registrador de dados de eventos. Também serão propostas diferentes formas de reprodução visual dos dados, incluindo a representação dos erros e incertezas existentes no processo de tomada de decisão do ADS.

1.1 Objetivos

O objetivo deste trabalho é estudar a necessidade de um padrão de armazenamento em registradores de dados alocados em veículos terrestres equipados com ADS, bem como o desenvolvimento de uma ferramenta que processe estes dados salvos e permita sua visualização de alto nível.

Para tanto, serão considerados os objetivos específicos:

- Estudar as formas mais comuns de representação de dados brutos e processados de sistemas de localização, percepção, navegação e controle;
- Analisar a influência de erros e incertezas nesses dados e formas de representá-las visualmente;
- Estudar a necessidade de padronização para o formato de registro dos dados;
- Desenvolver uma aplicação que simule essa representação, integrando todos os dados registrados disponíveis;

1.2 Justificativa

A pesquisa estuda a necessidade de padronização na forma de armazenamento dos dados por parte dos registradores, possibilitando a uniformidade, compartilhamento e reconstrução dos dados. Além disso, visa à fornecer uma forma de reproduzir as ações planejadas e realizadas por um ADS. Por meio da reconstrução de dados registrados, o sistema poderá indicar a falha de um componente, provendo meios para auxiliar auditorias periciais e jurídicas, principalmente em casos envolvendo acidentes.

A proposta pretende atender ao chamado dos governos quanto à apresentação de soluções para auxiliar no processo de certificação e homologação dos ADS. Entre as contribuições destaca-se a análise de cenários a partir dos dados registrados, permitindo a correção posterior de falhas, favorecendo a evolução da tecnologia com qualidade. O modelo poderá prover maior clareza no processo de decisão, sobretudo ao envolver discussões a respeito da responsabilidade penal ou civil diante de acidentes, oferecendo maior segurança jurídica a indústrias e cidadãos comuns.

1.3 Estrutura do trabalho

O presente trabalho foi desenvolvido como segue: uma revisão da literatura é apresentada no Capítulo 2, demonstrando conceitos relacionados aos ADS e registradores de dados, as incertezas de sistemas automatizados de condução, a padronização e reconstrução de dados e, também, a importância da pesquisa no suporte à identificação de falhas, certificação e homologação dos ADS; a metodologia para realização do trabalho, bem como as ferramentas utilizadas são apresentadas no Capítulo 3; os resultados são demonstrados e discutidos no Capítulo 4; e o Capítulo 5 apresenta as conclusões e trabalhos futuros.

2 REFERENCIAL TEÓRICO

Este capítulo objetiva a apresentação conceitual sobre sistemas de condução automatizados, registradores de dados, as incertezas de sistemas ADS, os padrões de armazenamento de dados e reconstrução de modelos, enquanto relaciona as tecnologias com trabalhos e metodologias aplicadas ao tema. Ele fornece a base para a contextualização e compreensão dos tópicos abordados nos capítulos posteriores.

2.1 Sistemas de Condução Automatizados

Estudos sobre a mobilidade terrestre se intensificaram com o surgimento da robótica e da inteligência artificial, permitindo avanços nos conceitos e na tecnologia empregada em Sistemas de Condução Automatizados – ADS, utilizados nos chamados veículos inteligentes.

Os ADS são compostos por uma combinação de componentes que auxiliam na tomada de decisão do veículo. Esse conjunto de componentes que envolvem hardware e software deve ser coletivamente capaz de realizar toda a tarefa de condução dinâmica (DDT – do inglês *Dynamic Driving Task*) de forma sustentada, independente de se limitar a um Domínio de Projeto Operacional específico. O DDT refere-se às funções operacionais e táticas em tempo real, necessárias para operar um veículo em tráfego rodoviário. Ele inclui o controle de movimento lateral e longitudinal do veículo, planejamento de manobras, etc. (SAE, 2016).

O Domínio de Projeto Operacional (ODD – do inglês *Operational Design Domain*) de um ADS descreve as condições específicas sobre as quais o ADS pretende operar. O ODD deve incluir suas capacidades e limitações quanto a tipos de vias (local, interestadual, federal, etc.), áreas geográficas (cidades, desertos, montanhas, etc.), faixa de velocidade, condições ambientais (dia, noite, chuva, etc.), entre outras restrições (NHTSA, 2017).

Além destes, outro componente para projetos de um ADS é a Detecção e Resposta a Objetos e Eventos (OEDR – do inglês *Object and Event Detection and Response*). Este refere-se à detecção pelo condutor ou pelo ADS de qualquer circunstância relevante para a tarefa de condução (NHTSA, 2017). Ele inclui a monitoração do ambiente como detecção, reconhecimento e classificação de objetos e eventos, além de executar uma resposta adequada a tais objetos e eventos (SAE, 2016).

Quando ativo, o ADS é responsável por executar toda a tarefa de condução dinâmica nos níveis de automação 3, 4 e 5 da SAE. O nível 3, denominado Automação Condicional, define o condutor como necessário, mas não precisa monitorar o ambiente, devendo assumir o controle do veículo sempre que notificado. No nível 4, chamado de Alta Automação, o ADS é capaz de executar todas as funções de condução sob certas condições, onde o condutor tem a opção de controlar o veículo. Já na Automação Completa do nível 5, o ADS é capaz de executar todas as funções de condução sob todas as condições, também com a opção do condutor controlar o veículo (NHTSA, 2017).

Para possibilitar esses recursos, os ADS fazem uso de um conjunto de sensores embarcados que adquirem informações sobre o ambiente em que o veículo está inserido, além de valores internos do sistema. Estes sensores permitem que o veículo se adapte, aprendendo por meio de experiências e construindo representações internas que são usadas no processo de tomada de decisão (NEHMZOV, 2000).

O conjunto de componentes de hardware e software (lasers, radares, câmeras, odômetros, GPS, computadores, algoritmos especialistas, modelos, filtros, etc.), que auxiliam o ADS na tomada de decisão, é classicamente organizado em uma arquitetura dividida em quatro categorias, sendo Localização, Percepção, Navegação e Controle. A primeira, a Localização, é responsável por definir a posição e orientação do veículo dentro de um referencial global, utilizando dados provenientes de sensores como o GPS e IMU, além de modelos e filtros que refinam os dados obtidos. A Percepção, por sua vez, envolve os componentes necessários para obtenção de informações do ambiente em que o veículo está inserido, identificando obstáculos estáticos e dinâmicos, por exemplo. A terceira, a Navegação, processa os dados adquiridos pelos sistemas de Localização e Percepção e define o melhor caminho a ser seguido pelo veículo, como também seu comportamento ao longo do trajeto, atuando como uma fase de planejamento. Por fim, o Controle é responsável pelo cálculo do acionamento dos atuadores para aceleração, freio e esterçamento do veículo (THRUN et al., 2006).

De forma geral, as categorias e elementos que compõem diferentes projetos para desenvolvimento de ADS apresentam funções e responsabilidades similares. Elas envolvem processos de localização no ambiente em que se atua, bem como perceber os objetos estáticos e dinâmicos nesse ambiente, o tratamento dessas informações e a conseguinte execução das tarefas planejadas, baseadas nos processos anteriores.

Os ADS também fazem intenso uso de recursos de inteligência artificial, aumentando a complexidade do projeto em termos de rastreabilidade das decisões. Alguns dos algoritmos mais avançados nesta área são tão complexos que nem mesmo os engenheiros que os projetam são capazes de isolar os motivos das ações realizadas (KNIGHT, 2017).

Além da complexidade inerente a esses projetos, os sinais recebidos pelo ADS estão sujeitos a ruídos de diferentes naturezas, problemas de calibração e incertezas tanto em hardware quanto em software. Nesse sentido, quando falhas ocorrerem, a melhor fonte de informações para entender suas causas será o próprio sistema, caso este tenha retido os dados das decisões relevantes tomadas. O ADS irá acessar e gerar grande massa de dados sobre o meio, bem como fazer uso desses dados para realizar julgamentos e executar decisões com alto grau de segurança (NHTSA, 2016).

2.2 Incertezas em Sistemas de Condução Automatizados

Sistemas computacionais são modelos abstratos representativos do mundo real que visam manter a integridade e acurácia da representação, apesar de serem considerados apenas aproximações deste. As imperfeições que permeiam estes cenários devem ser integradas aos modelos, buscando fornecer uma visão mais completa e exata.

Tais imperfeições da informação podem ser classificadas em três tipos básicos: erros, imprecisões e incertezas (MOTRO; SMETS, 1997). Um erro ocorre quando a informação armazenada é diferente da informação real. Imprecisões são informações que denotam uma quantidade possível de valores e a informação real está dentro do intervalo de elementos possíveis. Não são consideradas como erros e não comprometem a integridade do sistema. Com relação às incertezas, o conhecimento do mundo real (exato ou inexato) não pode ser declarado com absoluta confiança. Um valor pode ter pouca certeza, mas como este valor é substituído por valores que são progressivamente menos incertos, a certeza aumenta gradualmente, até que finalmente seja máxima para um valor.

A concepção de um ADS deve lidar tanto com os erros quanto com imperfeições e incertezas geradas pelo ambiente e pelos componentes de hardware e software, buscando obter a melhor decisão possível.

Essas incertezas derivam de cinco principais fatores: a imprevisibilidade do ambiente, as limitações dos sensores, desgastes de componentes, falta de acurácia de modelos e

necessidade de processamento computacional de larga escala em tempo real (THRUN; BURGARD; FOX, 2005).

A navegação por ambientes dinâmicos, como é o caso em rodovias e áreas urbanas, com a presença de diversos obstáculos estáticos e móveis, aumenta o grau de incerteza a ser tratado. Já no âmbito dos sensores, a presença de ruídos limita a extração de informações exatas, perturbando as medições realizadas pelos sensores (THRUN; BURGARD; FOX, 2005). Mesmo um GPS de alta precisão pode sofrer interferências causadas pela presença de edifícios, árvores, túneis e campos magnéticos, gerando uma incerteza sobre a real localização do veículo. Câmeras podem ser influenciadas por variações e reflexão da luz, áreas sombreadas, superfícies de baixa textura, presença de objetos de geometria complexa, entre outros fatores (LIMA, 2015). Sonares são unidirecionais e limitados a curtas distâncias, além de não possuírem precisão quanto à dimensão dos obstáculos, assim como os radares, enquanto que lasers apresentam problemas quando aplicados a superfícies metálicas ou transparentes (CHAKLADER et al., 2014).

O desgaste natural dos componentes de hardware como também das peças mecânicas do veículo adicionam incertezas ao modelo robótico utilizado, seja devido ao tempo de uso como também por problemas durante o processo de calibração. Adiciona-se a isso as conexões físicas entre os dispositivos que, com o desgaste, podem provocar mau contato.

Todas essas imperfeições são somadas quando aplicadas aos modelos computacionais de representação do mundo real. Elas podem ainda se propagar pelos diversos algoritmos especialistas envolvidos na geração da tomada de decisão em tempo real. Devido ao alto custo computacional para que um ADS possa executar as devidas ações, muitos algoritmos são aproximados para alcançar uma resposta imediata, que acaba por sacrificar a exatidão das informações (THRUN; BURGARD; FOX, 2005)

Um recente estudo apresenta um modelo formal e matemático para assegurar que um ADS funcione de forma responsável e não cause acidentes pelos quais possa ser responsabilizado (SHWARTZ; SHAMMAH; SHASHUA, 2017). Nele, caso o veículo se envolva em um acidente, é garantido que o mesmo não será causado pelo ADS. Na prática, o veículo precisa conhecer dois estados: Seguro, onde não há risco de que o ADS cause um acidente, mesmo que outros veículos tomem ações imprevisíveis ou imprudentes; e Política de Emergência Padrão, que define a ação evasiva mais concordante que um ADS pode tomar para manter ou retornar ao estado Seguro.

Este estudo traz uma importante contribuição para a redução de acidentes, principalmente durante o período de frota mista, com a presença de veículos equipados com ADS com diferentes níveis de autonomia e condutores humanos no mesmo ambiente. Porém, os erros, imperfeições e incertezas existentes nos projetos de um ADS não o isentam de responsabilidades, já que falhas durante o processamento dos dados podem gerar ações inconsistentes por parte do veículo.

Assim, uma incerteza em qualquer módulo do sistema pode ser responsável por uma falha ou acidente e seu registro por meio de um padrão e a reconstrução visual são cruciais na identificação das causas do problema e servirão de suporte na realização de perícias.

2.3 Registradores de Dados

A análise de um acidente de carro requer evidências físicas, incluindo o local do acidente, testemunhas e traços dos veículos, sendo tais evidências muitas vezes insuficientes para a identificação precisa das causas do acidente (KIM, 2014). Os dados obtidos pelos elementos de percepção de um ADS, por exemplo, podem auxiliar em um processo pericial de coleta de possíveis causas da colisão.

Porém, a instrumentação e monitoramento destes dados em sistemas de tempo real são um problema antigo, envolvendo questões de desempenho, custos de armazenamento e até segurança. Diversas soluções já foram propostas e implementadas, cada qual envolvendo diferentes abordagens combinadas de hardware e software. Uma proposta para garantir a persistência dos dados está na utilização de dispositivos chamados registradores.

Dispositivos registradores de dados não são novidade no mundo dos transportes. Seu uso é originário nos aviões na década de 1930 e está presente também nos setores ferroviários (FABRIS; LONGO; MEDEOSSI, 2008) e rodoviários.

Um exemplo de uso de registradores de dados está no Gravador de Dados de Voo (FDR – *Flight Data Recorder*), popularmente chamado de caixa-preta. Atualmente, a caixa-preta consiste em um chip envolvido em um invólucro resistente a chamas e impactos, com alta capacidade de gravação. Todas as aeronaves comerciais são dotadas deste equipamento, colocada normalmente na cauda do avião. Eles armazenam os parâmetros de desempenho dos aviões, incluindo o estado do motor, altitude, velocidade e posição de superfícies de controle, além da gravação de áudio de bordo, captando as conversas da cabine do piloto. Em caso de

falhas ou acidentes, a caixa-preta auxilia nas investigações e na reconstrução da sequência de eventos que precederam a falha, possibilitando a identificação dos motivos do problema (GORLICK, 1991).

Não somente as aeronaves utilizam esta tecnologia. Segundo o IST (2010, p. 1), os dispositivos de registro de dados foram introduzidos em veículos terrestres em competições de kart, por volta de 1990. Seu objetivo era entender as causas dos acidentes, o comportamento do piloto e proporcionar melhorias nos veículos. Estes dispositivos são conhecidos como EDR's (*Event Data Recorders*).

Os EDR's são similares à caixa-preta utilizada no setor aéreo no que diz respeito ao sistema de armazenamento de dados. Porém, em função da menor complexidade dos veículos rodoviários e de sua aplicação, os EDR's armazenam menor número de informações. O conjunto de informações presente nesses veículos se resume em parâmetros de detecção de acidentes, notificação automática de eventos, rastreamento e gravação de dados relacionados ao veículo e ao ambiente (PARK; KO, 2012).

Essas informações são referentes aos dados brutos dos sensores, sem considerar as informações provenientes de algoritmos ou sistemas inteligentes. Existe ainda a necessidade de se registrar informações relacionadas à calibração, erros, incertezas e saídas geradas pelo processo de transformação dos dados até a execução das ações pelo veículo (PARK et al., 2014).

Especificamente no contexto dos ADS, sinais de entrada obtidos pelos sensores, que já podem estar afetados por erros e incertezas, são condicionados e combinados com dados de outros sensores. Estes dados passam por outros sistemas que, com suas respectivas etapas, acumulam novos erros e incertezas até por fim se chegar a uma ação a ser executada pelos atuadores, que possuem suas próprias incertezas e podem afetar sua correta execução. Cada uma dessas etapas deve ser registrada, armazenando informações do processo como um todo e possibilitando uma análise detalhada sobre as transformações sofridas pelos dados a cada etapa.

Dessa forma, uma variação do FDR e do EDR aplicada exclusivamente para o contexto dos ADS é necessária. Barbosa et al. (2016) propõem uma evolução nos atuais EDR's, visando armazenar não somente dados brutos, mas também as saídas dos componentes participantes do processo de decisão de um veículo equipado com ADS. Este avanço permitirá a identificação de cada uma dessas saídas e assim obter uma plataforma

confiável de informações sobre os fatores que influenciaram a ação efetuada pelo veículo. Os dados devem ser coletados para fins de teste e operação, devendo ser totalmente rastreáveis.

O modelo de dispositivo registrador de dados proposto deve ser capaz de registrar também as incertezas, erros presentes nos hardwares e a possibilidade de mau funcionamento dos algoritmos. Tal dispositivo deve garantir a segurança dos dados armazenados e seu acesso deve ser realizado somente por entidades qualificadas. Ele deve conter informações suficientes para o entendimento e reconstrução de um cenário com acidentes. Isso possibilitará avanços e melhorias constantes dos componentes, provendo suporte para fabricantes, governos, perícias e auditorias.

Neste sentido, os dispositivos registradores dos dados surgem como uma necessidade para os ADS fornecendo informações ricas para agências de certificação e homologação.

2.4 Padrão de Armazenamento de Dados

Atualmente, entidades discutem a necessidade da padronização de nomenclaturas, controles de segurança, modo de operação do ODD e OEDR, bem como dos dados armazenados e outras tecnologias utilizadas pelos ADS (NHTSA, 2016; AUSTRALIA, 2017; GERMANY, 2017).

A padronização internacional dos procedimentos de armazenamento deve ser obtida para garantir a compatibilidade das obrigações de registro ou documentação à medida que as tecnologias automotivas e digitais cruzam cada vez mais as fronteiras nacionais (GERMANY, 2017).

O Senado Americano atribuiu à NHTSA a responsabilidade por identificar os elementos que possam requerer performances padrão incluindo interface humano-máquina, sensores e atuadores, e considerar processos e procedimentos padrão para software e segurança eletrônica (UNITED STATES, 2017).

Embora esta seja uma área em evolução e mais pesquisas são ainda necessárias antes de propor um padrão regulatório, os fabricantes são encorajados a projetar seus ADS seguindo as melhores práticas estabelecidas para sistemas de veículos físicos cibernéticos. Em particular, as entidades devem considerar e incorporar orientações, práticas recomendadas e princípios de design publicados por relevantes organizações de definição de padrões (NHTSA, 2016).

A despeito da propriedade dos dados, tópico ainda em aberto sobre quem detém o direito aos dados armazenados (consumidor, fabricante, governo, etc.), esta padronização não deve influenciar na definição de propriedade ou no segredo intelectual das companhias. Ela é necessária para determinar quais informações precisam ser armazenadas, bem como o formato do registro, visando possibilitar seu compartilhamento, a reprodução mais fidedigna do cenário e auxiliar na identificação de responsabilidades em falhas ou acidentes.

Contudo, este estudo não pretende esgotar o assunto e nem afirmar que a proposta apresentada nos capítulos seguintes solucione todos os problemas. Os exemplos propostos visam gerar uma reflexão e alimentar estudos posteriores quanto à necessidade de definição do padrão de armazenamento dos dados. Questionamentos relacionados à segurança, confiabilidade, acessibilidade dos dados, etc., precisam ser solucionados. Dessa forma, os dispositivos registradores, os padrões de armazenamento e um sistema de reconstrução visual dos dados terão importante participação na certificação e homologação dos ADS, como também no suporte às falhas e acidentes.

2.5 Suporte à Análise de Falhas e à Certificação e Homologação de Sistemas

Os avanços tecnológicos estão forçando governos e sociedade a refletirem sobre mudanças na legislação para atender à demanda de inserção dos ADS em ambientes urbanos. Sua certificação e homologação são justificáveis desde que promovam a redução de danos em comparação à condução humana (GERMANY, 2017). O estado deve avaliar suas leis e regulamentos para resolver impedimentos desnecessários aos testes e operação de veículos equipados com ADS (AUSTRALIA, 2017).

O setor público deve ser responsável por garantir a segurança, licenciamento e monitoramento dos ADS. Seu princípio está na prevenção de acidentes. Entretanto, os riscos tecnologicamente inevitáveis não devem impedir a certificação e homologação dos ADS se os benefícios alcançados forem superiores aos riscos. O objetivo de todas as decisões regulatórias governamentais e políticas é promover o desenvolvimento gratuito e a proteção aos indivíduos, sendo o aprimoramento da segurança o objetivo do desenvolvimento e regulamentação dos ADS (GERMANY, 2017).

Para tanto, evoluções na segurança, privacidade, ética e política precisam ser efetuadas para permitir a disponibilização dos ADS em larga escala. No âmbito da segurança, a presente

proposta visa atender ao chamado dos governos na elucidação de soluções que ofereçam suporte à identificação de falhas dos ADS. Espera-se prover maior clareza em discussões a respeito de responsabilidades, bem como fornecer aos fabricantes informações úteis para auxiliar nas melhorias relacionadas à segurança do modelo.

Como já afirmado, a padronização dos dados armazenados pelos registradores possibilita não somente uma melhor e mais rápida interpretação dos mesmos, mas permite também que estes sejam compartilhados utilizando um protocolo em comum. Isto auxiliará na evolução de aplicações voltadas para a comunicação V2I (*Vehicle-to-Infrastructure*) e V2V (*Vehicle-to-Vehicle*).

O compartilhamento de dados é uma área em rápida evolução que requer mais pesquisas e discussões entre as partes interessadas para desenvolver o consenso sobre os padrões de dados. Por exemplo, muitos fabricantes e outras entidades provavelmente irão querer a capacidade de recuperar os dados dos ADS que fabricam e armazená-los por algum período de tempo (NHTSA, 2016).

Com relação à reconstrução dos dados, a construção de pistas de testes para veículos terrestres equipados com ADS deve receber incentivos do setor público e privado. A criação de ambientes altamente controlados e previsíveis permitem análises combinadas dos dados registrados e os reconstruídos, possibilitando a verificação da consistência dos mesmos. Assim é possível definir as taxas de confiabilidade dos algoritmos, seus erros e imprecisões, possibilitando melhorias de projeto necessárias. Em um ambiente controlado como as pistas de testes, devidamente representada com mapas digitais de alta precisão, é possível fazer análises de calibração dos dados, levantando as incertezas do processo.

Observando que os veículos equipados com ADS e sua evolução para veículos autônomos são uma realidade, o Departamento de Transportes dos Estados Unidos, em conjunto com a NHTSA divulgou um guia de orientações sobre a política federal dos ADS. O documento trabalha com os níveis de automação 3, 4 e 5 conforme definição da SAE. Esse guia de orientações destaca áreas importantes que fabricantes, montadoras e demais entidades, que projetam ADS, devem considerar e abordar à medida que modelam, testam e implementam seus produtos. O guia deve ser considerado por todos os indivíduos e empresas de fabricação, concepção, planejamento, fornecimento, teste, venda, operação e/ou implantação de ADS nos Estados Unidos. Algumas ações subsequentes ao documento envolvem a realização de pesquisas adicionais em áreas como avaliação de benefícios, fatores

humanos, segurança cibernética, métricas de desempenho, testes objetivos, entre outros. Apesar do guia não ser obrigatório, a NHTSA considera futuramente tornar alguns de seus elementos como obrigatórios e vinculativos através de medidas regulamentares (NHTSA, 2016).

No trabalho de Maurer et al. (2016), diversos aspectos técnicos, legais e sociais são levantados e discutidos, trazendo questionamentos variados sobre a implantação dos ADS nos ambientes urbanos. Temas discutidos no documento envolvem a interação homem-máquina, a importância da ética para ADS, além da comunicação entre ADS e condutores humanos e seus problemas. O trabalho aborda ainda o controle de tráfego e seus efeitos, benefícios dessa nova tecnologia e tópicos como aceitação, segurança, aprendizado, predição, riscos, oportunidades, direitos e responsabilidades em ADS.

Como pode ser observado, apesar da existência de muitas perguntas que ainda precisam de respostas no âmbito dos ADS, diversas entidades e profissionais têm trabalhado arduamente para que estas questões possam ser sanadas. O intuito é tornar a automação em veículos uma realidade, sendo também este trabalho uma alternativa na busca de soluções de alguns dos problemas elucidados.

Dessa forma, a proposta de definição do padrão de armazenamento dos dados pelo dispositivo registrador e o desenvolvimento de um sistema para reconstrução visual pode prover maior suporte aos governos, indústrias, pesquisadores e sociedade em geral.

2.6 Reconstrução Visual


A reconstrução visual tornou-se um procedimento essencial em realidade virtual, sendo a criação de modelos de ambientes uma importante tarefa em robótica. Um modelo de reconstrução consiste em capturar e recriar as formas e aparências dos objetos reais nos espaços bidimensional e tridimensional (MA et al., 2001).

É desejável que a representação de um objeto provenha um alto grau de realismo. Assim, a precisão de um modelo depende da capacidade dos sensores em capturar dados e da capacidade do sistema de registrar vários conjuntos de dados (CAMPBELL; FLYNN, 2000).

Suas aplicações são diversas e abrangem áreas como medicina, engenharia civil, perícia criminal, reconstrução facial a partir de crânios e também exploração marítima e espacial, dentre outras, sendo uma importante alternativa na redução de custos.

No âmbito da reconstrução dos dados de ADS, esta atualmente se restringe à reprodução das informações obtidas pelos sensores, possibilitando a visualização apenas da composição dos dados brutos registrados. Sistemas e simuladores convencionais como o Autoware (AUTOWARE, 2017) reproduzem somente os dados brutos dos sensores embarcados no veículo. A Figura 1 apresenta a reconstrução realizada pelo Autoware de alguns dados de sensores.

Figura 1 – Reconstrução de dados não tratados de sensores pelo software Autoware.



Fonte: Autoware (2017).

Já o sistema proposto inclui a reconstrução visual dos sinais de entrada e saída dos algoritmos especialistas, exibindo como os dados brutos podem ser combinados com dados processados, apresentando também os erros, imprecisões e incertezas associadas. Isto permitirá o acompanhamento das transformações sofridas pelos dados ao longo do processo até a execução final das ações pelos atuadores.

Tal avanço permite uma análise mais aprofundada e transparente sobre as ações executadas pelos ADS, mostrando a versatilidade entre analisar um dado bruto e o que seu posterior processamento resultou como saída.

2.6.1 Localização para Sistemas de Condução Automatizados

Para uma navegação segura, um conjunto de sensores embarcados no veículo pode ser utilizado para auxiliar no processo de localização e orientação do ADS. Entre os mais utilizados, os Sistemas de Posicionamento Global (GPS – do inglês *Global Positioning System*) permitem a localização no referencial terrestre, sendo a ferramenta de posicionamento e navegação mais utilizada atualmente (TAYLOR; BLEWITT, 1999).

O GPS faz parte do conjunto de sistemas de navegação denominado Sistema Global de Navegação por Satélite (GNSS – do inglês *Global Navigation Satellite System*), sendo um termo genérico para sistemas que fornecem a posição e localização de um receptor em qualquer lugar do mundo. O GPS foi desenvolvido pela Força Aérea dos Estados Unidos no início dos anos 60. Ele consiste de 24 satélites que orbitam a Terra a 20.200 km com resolução temporal de 12 horas, implicando em revisita a um determinado local duas vezes por dia, em seis planos orbitais que estão inclinados a 55 graus em relação ao plano do Equador. O funcionamento do sistema GPS baseia-se no princípio da trilateração (interseção de esferas), em que, com pelo menos três satélites, o receptor pode determinar a posição – latitude e longitude – que é chamada posição fixa ou bidimensional. Com 4 ou mais satélites pode-se determinar a posição tridimensional, com a devida correção da componente tempo da altitude, compondo assim a coordenada posicional precisa, atribuída pelos valores de latitude, longitude e altitude (RUIZ, 2014).

Em um caso ideal, o processo de localização global de um veículo terrestre inteligente faz uso de um sistema integrado de GPS e IMU (*Inertial Measurement Unit*) para fornecer estimativas de velocidade localmente consistentes e precisão de pose (posição e orientação) global (LEVINSON; MONTEMERLO; THRUN, 2008). Sensores do tipo IMU referem-se a um conjunto de sensores inerciais capazes de observar e retornar informações relacionadas à posição e velocidade de um determinado objeto. Eles usam uma combinação de acelerômetros, giroscópios e magnetômetros.

Além da localização global pelo uso de sensores exteroceptivos como o GPS, um ADS também pode utilizar informações da localização baseada em mapas. Informações geográficas e/ou geométricas são fornecidas por um Sistema de Informação Geográfica (GIS – do inglês *Geographic Information System*). A partir dessas informações, busca-se uma correspondência

entre dados locais, ou topológicos, com dados obtidos por um sistema de percepção (GARCIA, 2009).

Porém, como já citado, incertezas relacionadas ao sistema de localização como interferências no GPS por edifícios, árvores, túneis e campos magnéticos, ruídos e erros de calibração, acurácia dos mapas utilizados, entre outras, podem dificultar o processo de definição de pose do veículo. Dessa forma, um mapa digital de alta precisão combinado aos dados de GPS de alta precisão, IMU, modelos e filtros são importantes ferramentas de auxílio no processo de localização do ADS.

Tipicamente, informações sobre o ambiente são fornecidas pelos sensores embarcados no veículo. Porém, dados estáticos podem ser obtidos mais facilmente e de forma mais rápida por meio dos mapas (NOYER, 2008).

Os mapas digitais tornaram-se uma importante ferramenta para a exibição de dados de georreferenciamento, com alto potencial em aplicações baseadas em localização, navegação, planejamento de rotas, etc.

Em comparação com os mapas 2D, mapas 3D apresentam algumas vantagens, especialmente na navegação, pois possibilitam uma melhor visualização do ambiente. Eles agilizam o processo de orientação do usuário pela apresentação volumétrica dos dados ao invés de uma representação plana. Também permitem elevada exatidão na representação de objetos, de forma mais realista e menos simbólica, e exibem informações com perspectivas e mais graus de liberdade no movimento (ABUHADROUS et al., 2003).

Os mapas 3D podem proporcionar benefícios ao usuário por meio de melhor visualização e localização, uma vez que auxiliam na criação de uma imagem das relações espaciais do ambiente local (OULASVIRTA et al., 2009).

Entre os trabalhos recentes na criação de mapas digitais 3D de alta precisão estão o F4Map¹ e Sanborn HD Maps², que exploram a utilização de dados de imagens de câmeras, georeferenciamento e dados aéreos e móveis de sensores, como, por exemplo, do LIDAR (*Light Detection and Ranging*). Um exemplo do F4Map pode ser visto na Figura 2.

¹ <http://demo.f4map.com/>

² <http://www.sanborn.com/highly-automated-driving-maps-for-autonomous-vehicles/>

Figura 2 – Exemplo de Mapa Digital 3D.



Fonte: F4Map (2017).

2.6.2 Percepção para Sistemas de Condução Automatizados

Entre as características de um ADS está a capacidade de perceber e adquirir conhecimento de seu ambiente para conseguir agir sobre ele. Este processo faz uso de sensores que capturam diferentes dados do ambiente e os transformam em informações úteis para o sistema.

Para tanto, o sistema de percepção do ADS faz uso de um conjunto de sensores que quantificam variáveis e interpretam seus dados para extrair características do ambiente, detectando e classificando vias, faixas, obstáculos estáticos e dinâmicos, entre outros (RUIZ, 2014). Entre os sensores mais comumente utilizados para realizar o processo de percepção estão radares, câmeras e sensores laser LIDAR.

A partir dos dados obtidos por estes sensores, algoritmos específicos são aplicados aos mesmos, objetivando a identificação e classificação do ambiente em torno do veículo. Um exemplo é a nuvem de pontos gerada a partir dos dados do sensor LIDAR ou a segmentação semântica por meio da separação e rotulação das imagens obtidas pelas câmeras.

A percepção do ambiente em que um veículo equipado com ADS está inserido é, portanto, uma etapa essencial para a segura tomada de decisões. Uma abordagem para auxiliar nesse processo está na utilização de sensores do tipo LIDAR.

Sensores LIDAR digitalizam o ambiente sobre um campo vertical girando 360 graus e fornecem dados importantes sobre o ambiente, utilizando o formato de nuvem de pontos.


Dependendo do modelo do sensor LIDAR utilizado, é possível obter até 2.2 milhões de pontos por segundo. Esses dados, fundidos com outros sensores e combinados em algoritmos específicos, permitem detectar obstáculos estáticos e dinâmicos no ambiente, auxiliando a tomada de decisão pelos sistemas especialistas de navegação e controle.

Além de outros, seu uso tem sido aplicado tanto em ADS quanto em sistemas de segurança e mapeamento 3D aéreo. Um dos métodos propostos para extrair informações a partir dos dados gerados pelo LIDAR, consiste em converter os dados do sensor em uma nuvem de pontos 3D com coordenadas globais (AMARAL et al., 2015).

Um conjunto de dados de nuvem de pontos é uma coleção de pontos espaciais denominada pontos de dados $\{(x_i, y_i, z_i); i = 1, \dots, n\}$ em que: i é o índice de pontos de dados; n é o número total de pontos de dados na nuvem de pontos; $(x_i, y_i) \in D \subset R^2$, denominada coordenada de terra do ponto de dados i , é a coordenada georreferenciada no terreno do i -ésimo ponto de dados; D é o domínio de dados no qual todas as coordenadas de terra são distribuídas irregularmente; e z_i é a elevação adquirida na coordenada de terra i (ZHAO; LI; HE, 2014).

Um exemplo de utilização dos dados gerados pelo sensor LIDAR e sua respectiva nuvem de pontos pode ser observado na Figura 3.

Figura 3 – Interseção de via obtida da leitura de sensor LIDAR 3D.



Fonte: Do autor (2018).

Porém, como já citado, um sensor laser como o LIDAR pode ter resposta indesejada quando aplicado a superfícies metálicas ou transparentes. Este comportamento possibilita a

presença de erros e incertezas na informação de distância dos objetos refletidos. Tais imperfeições podem ainda ser ampliadas após o processamento dos dados pelos algoritmos.

O sistema de percepção faz ainda intenso uso de visão computacional. O campo de reconhecimento de objetos tornou-se um tópico essencial em se tratando de sistemas robóticos. Entre as técnicas existentes para realizar esta tarefa, a visão computacional ou visão robótica tem sido um assunto constantemente abordado e estudado por especialistas. Seu objetivo é permitir que um computador perceba e entenda seu ambiente, além de tomar ações apropriadas e aprender com tais experiências, de forma semelhante aos humanos (VITOR, 2010).

Diversas técnicas existentes no campo da visão computacional como o processamento digital de imagens, a segmentação semântica, e outras, podem ser utilizadas para auxiliar um ADS na percepção do ambiente.

Com relação à segmentação semântica, esta busca obter uma melhor compreensão da imagem por meio de sua divisão em um número finito de regiões não-sobrepostas e significativas. O objetivo é reconhecer e entender os objetos que estão na imagem em nível de pixel, realizando a rotulação desses objetos. Esta é ainda uma tarefa desafiadora devido à lacuna semântica existente entre os recursos visuais de baixo nível e a interpretação humana de alto nível da semântica da imagem (ZHU; WANG; JIANG, 2010).

Xu et al. (2013) propõem uma abordagem de segmentação de imagens através da fusão de informação de diferentes sensores, como câmeras estéreo e sensores laser LIDAR. Estes perceberão o ambiente de diferentes formas e com módulos independentes de classificação temporal e de texturas, que processam a saída destes sensores para classificar cada segmento da imagem. Um exemplo de segmentação semântica de imagens de câmeras pode ser visualizado na Figura 4.

Figura 4 – Segmentação semântica de imagens.



Legenda: Imagem original à esquerda e segmentação semântica da imagem por visão robótica à direita
 Fonte: Adaptado de Xu et al. (2013).

Entretanto, incertezas relacionadas à aquisição dos dados podem influenciar no resultado. Variações da iluminação, presença de áreas sombreadas e reflexão da luz, entre outras, podem inviabilizar a técnica, gerando imperfeições que se propagam para as etapas seguintes. A Figura 5 exibe um exemplo de imagem com reflexão da luz, ofuscando a visão e saturando o Dispositivo de Carga Acoplada (CCD – *Charge-Coupled Device*) da câmera.

Figura 5 – Imagem de câmera com reflexão da luz.



Fonte: Do autor (2018).

2.6.3 Navegação para Sistemas de Condução Automatizados

O sistema de navegação, também conhecido como sistema de planejamento, refere-se ao processo de tomada de decisões pelo ADS para que o veículo atinja metas, levando-o de um local inicial até o destino. Além disso, a navegação é responsável por definir seu comportamento, evitando obstáculos e realizando otimizações ao longo do trajeto. Esse sistema é geralmente decomposto em três diferentes processos: Planejamento de Missão, Planejamento de Comportamento e Planejamento de Movimento (PENDLETON et al., 2017).

O Planejamento de Missão é responsável por considerar os objetivos de alto nível, como a definição de rotas para se atingir a meta. Um planejamento de alto nível fornece orientação para a navegação pela criação de representação da rota que permita a manipulação eficiente dos dados, usando-os para planejar a rota em um modelo de localização global (ARMSTRONG, 2007).

O sistema de navegação pode ainda trabalhar com um modelo local, por meio da inserção das informações referentes ao posicionamento do veículo no modelo. Para tanto, ele utiliza os dados do sistema de localização, além da caracterização, predição e inserção de informações dinâmicas como posição, velocidade e tamanho de objetos detectados no modelo. Por fim, ele mantém uma lista de pontos da missão que identificam a via correta de percurso (ARMSTRONG, 2007).

O Planejamento de Comportamento gera decisões de interação com agentes externos, seguindo restrições e considerando objetivos locais classificados como navegação primária na via, navegação em área aberta, manobra de mudança de faixa, direção reversa, interseção e estacionamento (PENDLETON et al., 2017).

Planejamentos adaptativos são considerados no Planejamento de Movimento por operar sobre um número finito de comportamentos e definir como o ADS irá operar sobre variadas condições de direção. Eles também realizam decisões inteligentes fazendo uso de sistemas especialistas de avaliação da situação, gerando caminhos apropriados e conjuntos de ações para se alcançar um objetivo, evitando colisões com obstáculos no trajeto (ARMSTRONG, 2007).

Um ADS deve ter capacidade de planejar de forma rápida e robusta uma trajetória em um ambiente repleto de incertezas (MOUHAGIR et al., 2017). Composto essencialmente por componentes de hardware, algoritmos e sistemas especialistas, a navegação, portanto, processa os dados adquiridos pelos sistemas de localização e percepção, podendo adicionar novas imperfeições durante as transformações dos dados. O desgaste natural do hardware, atualizações de softwares e a necessidade de processamento em tempo real geram novas possibilidades de erros e incertezas no ADS.

2.6.4 Controle para Sistemas de Condução Automatizados

O sistema de controle é responsável pelo acionamento dos atuadores (acelerador, freio e esterçamento das rodas) que regulam as velocidades longitudinal e lateral resultantes do veículo. Ele executa efetivamente o que foi planejado pelo sistema de navegação, dadas as restrições cinemáticas e dinâmicas no seu modelo, convertendo intenções em ações.

Ele possibilita a geração de movimentos no veículo por meio de entradas de hardware, aplicando em termos de força e energia, o planejamento realizado para a velocidade e posição

do veículo em relação ao ambiente. Medições podem ser usadas para determinar como o sistema está se comportando e o controlador pode reagir para rejeitar distúrbios e alterar a dinâmica do sistema, adaptando-se a novas situações (PENDLETON et al., 2017).

As incertezas para o sistema de controle são advindas do desgaste natural dos componentes de hardware e peças mecânicas do próprio veículo devido ao tempo de uso. Isso leva a questionamentos sobre prazos de validade dos ADS, garantias, coberturas de seguros, frequência de calibração, entre outros.

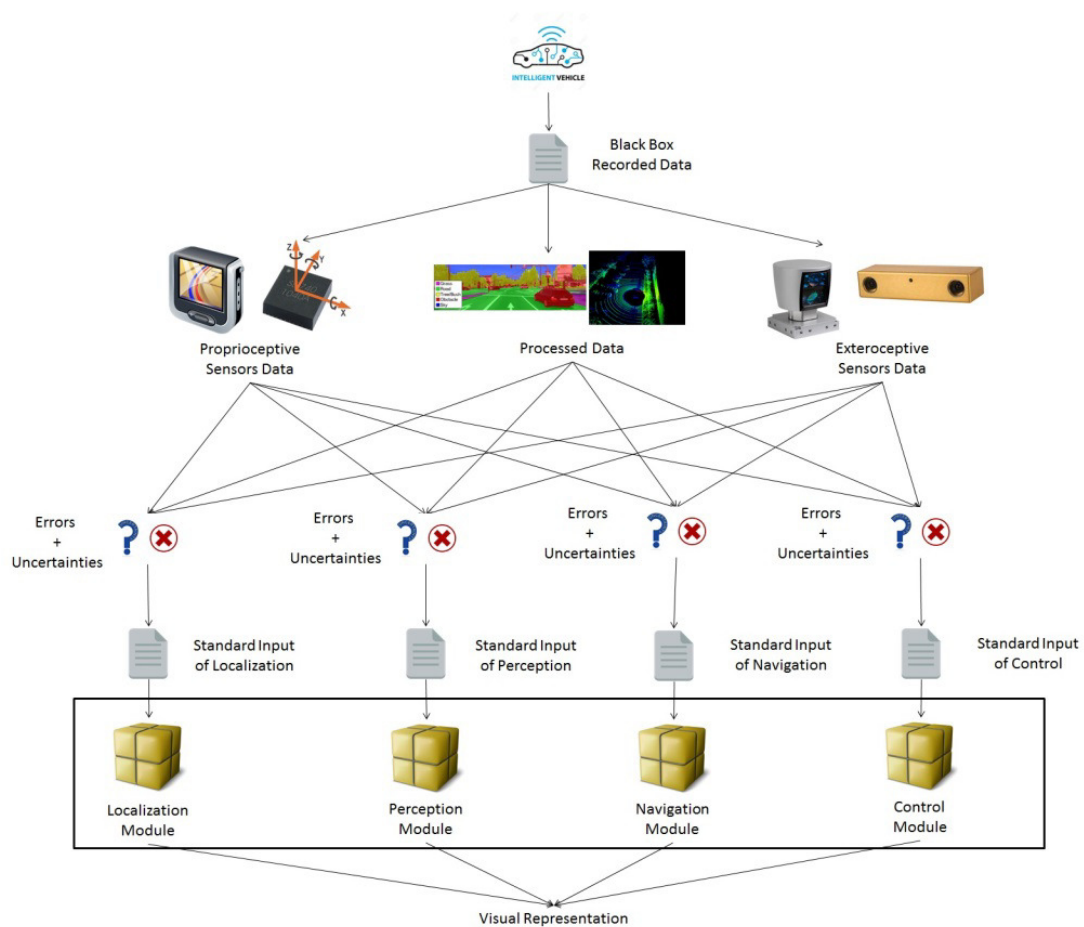
3 METODOLOGIA

Neste capítulo será apresentada a metodologia utilizada, demonstrando a arquitetura do sistema, o padrão de armazenamento proposto e os passos para o desenvolvimento das reconstruções visuais separadas por sistemas, bem como outras representações sugeridas.

3.1 Arquitetura do sistema

A arquitetura consiste em obter os dados dos dispositivos registradores dos ADS, armazenados conforme o padrão de dados definido. Estes dados são utilizados como entrada para os módulos do sistema que geram diferentes representações visuais dos cenários registrados como saída. A arquitetura do sistema pode ser vista na Figura 6.

Figura 6 – Arquitetura para reconstrução visual para dispositivo registrador de dados.



Fonte: Do autor (2018).

Além dos dados brutos registrados pelos sensores de veículo equipado com ADS, o sistema proposto inclui a reconstrução visual dos sinais de entrada e saída dos algoritmos especialistas, apresentando também os erros, imprecisões e incertezas associadas. Para tanto, ele exibe como os dados brutos foram combinados com dados processados, permitindo assim o acompanhamento das transformações ao longo do processo até a execução final das ações pelos atuadores.

Cada módulo é responsável pelo processamento de seu respectivo arquivo de entrada. Combinações dos dados de diferentes sistemas podem ser realizadas para a geração de reconstruções mais detalhadas, como será explanado nas próximas seções.

3.2 Padrão dos dados

A proposta apresentada optou pela separação dos dados pelos sistemas de Localização, Percepção, Navegação e Controle. Os dados são declarados em um cabeçalho e, por conseguinte, a sequência de informações obtidas e processadas. A Figura 7 exibe um exemplo de padronização sugerida para dados do sistema de Localização.

Conforme observado durante o desenvolvimento da ferramenta, para a reconstrução visual do sistema de localização são necessários dados que definam a pose (posição e orientação) final do veículo em um referencial global. Assim, o arquivo padrão de entrada para este sistema inclui dados de latitude, longitude e altitude do GPS representados pelas letras x , y e z no cabeçalho e seus respectivos valores já processados. Também são necessários os dados do sensor IMU representados pelos valores $roll$, $pitch$ e yaw , incluindo seus valores finais processados.

Além destes valores, os erros associados a cada um também são armazenados e representados pelos símbolos dx , dy , dz , $droll$, $dpitch$ e $dyaw$. Estes valores permitem a reconstrução visual das incertezas com relação à pose do veículo. Como já afirmado, ruídos, perda de sinal do GPS, modelos e filtros utilizados e falhas de calibração podem afetar os dados e apresentar diferenças entre a pose final armazenada e real do veículo.

Outro dado observado e definido como necessário para a reconstrução visual é a frequência dos dados, ou seja, a periodicidade com que foram adquiridos e processados. As representações visuais são apresentadas em quadros (*frames*), gerando visualizações em formato de vídeo. A quantidade de quadros por segundo (*fps* – do inglês *Frames per Second*)

é definida utilizando a frequência. Esta informação deve estar presente nos arquivos de todos os sistemas.

Figura 7 – Padrão de Dados para Sistema de Localização.

```
System: Localization
Double data: x, y, z, roll, pitch, yaw
Double error: dx, dy, dz, droll, dpitch, dyaw
Integer data: frequency
Boolean data: mode [false]manual [true]autonomous
Timestamp
Node: GPS
Node: IMU
Node: Kalman Filter
Node: MLR Model

49.029698 8.441083 112.532791 0.051893 0.009702 1.469669
0.001221 0.00311 0.002877 0.00459 0.00951 0.00892
100
true
2017-11-27 13:15:56.0084
49.029572 8.441111 112.532734
0.051885 0.009715 1.469677
49.029635 8.441095 112.532757 0.051890 0.009708 1.469672
49.029698 8.441083 112.532791 0.051893 0.009702 1.469669

49.028698 8.451083 112.532691 0.050634 0.009785 1.455273
0.001221 0.00311 0.002877 0.00459 0.00951 0.00892
100
true
2017-11-27 13:15:57.0094
49.028572 8.451152 112.532773
0.050629 0.009710 1.455215
49.029635 8.451101 112.532729 0.050631 0.009754 1.455246
49.028698 8.451083 112.532691 0.050634 0.009785 1.455273
```

Fonte: Do autor (2018).

Também são necessários os dados de modo de condução – manual ou autônomo. Assim como a frequência, o modo de condução também deve estar presente nos arquivos de todos os sistemas, permitindo verificar a cada momento quem estava responsável pelo controle do veículo: o ADS ou o condutor.

As marcas de tempo (*timestamp*) de cada informação também devem estar disponíveis, possibilitando uma análise do momento exato das ocorrências dos dados.

Nas seções seguintes serão demonstradas reconstruções visuais que possibilitem o acompanhamento das transformações dos dados ao longo do processo por meio da utilização de grafos. Para estas representações, somente os dados finais de pose do veículo não são suficientes. Existe ainda a necessidade de registro e disponibilização de quais foram os sensores, algoritmos, atuadores e todo conjunto de componentes que de alguma forma fizeram uso dos dados para definição de pose do veículo. Dessa forma, cada item será um nó do grafo representado pelos valores das linhas *Node* presentes no cabeçalho e suas respectivas saídas na área de valores. Esta representação possibilitará um acompanhamento ainda mais detalhado sobre as decisões tomadas pelo ADS.

As informações necessárias para as reconstruções visuais variam conforme o sistema a ser tratado. Por exemplo, para o sistema de percepção, valores de lasers, radares, câmeras, saídas de segmentação semântica, processamento digital de imagens, entre vários outros, devem ser disponibilizados no arquivo de entrada de percepção. Ao sistema de navegação, saídas de algoritmos especialistas, filtros, obstáculos identificados, informações de velocidade e tipo da via e decisões planejadas podem fazer parte dos dados do arquivo de entrada de navegação. Para o sistema de controle, valores como aceleração, frenagem, ângulo do volante, grau de esterçamento das rodas e saídas de Sistemas Avançados de Auxílio ao Condutor (ADAS – do inglês *Advanced Driver Assistance Systems*) devem estar presentes no arquivo de entrada de controle.

Como já afirmado, a proposta apresentada não pretende esgotar o assunto ou determinar este como o padrão correto a ser utilizado. As sugestões são uma elucidação quanto à necessidade de se definir a padronização dos dados visando auxiliar na identificação dos motivos de falhas e acidentes, no compartilhamento e reconstrução dos dados. Espera-se ainda prover transparência na atribuição de responsabilidades e suporte para a certificação e homologação dos ADS.

3.3 Base de Dados

Como referência para validação da ferramenta proposta neste trabalho, foram utilizados os dados da base pública *KITTI Vision Benchmark Suite*³ (GEIGER, 2013), tendo

³ <http://www.cvlibs.net/datasets/kitti/>

em vista a inexistência de base comum na indústria automotiva ou dos fornecedores das tecnologias em estudo neste trabalho.

O conjunto de dados da base KITTI foi obtido em 156 testes realizados no período de 26 de setembro a 03 de outubro de 2011 na cidade de Karlsruhe na Alemanha, áreas rurais e rodovias próximas. O veículo utilizado é um Volkswagen Passat B6 apelidado de AnnieWAY dotado de um sistema de navegação inercial (GPS/IMU), um sensor laser LIDAR Velodyne, duas câmeras estéreo em escalas de cinza e duas câmeras estéreo em cores.

A base obtida contém mais de 2 mil diretórios e quase 290 mil arquivos, totalizando aproximadamente 184 Gigabytes de dados.

Entre os diversos diretórios existentes na base KITTI, a validação da ferramenta foi realizada com três diferentes conjuntos de dados. Foi selecionado como base definitiva o diretório *2011_09_26_drive_0022_sync*, com tempo total de duração de um minuto e vinte segundos (01:20). A escolha foi realizada de acordo com a quantidade e variedade de informações disponíveis para atender aos propósitos da reconstrução visual, bem como pelo tempo de duração do teste. As outras bases testadas foram *2011_09_26_drive_0001_sync* com onze segundos de duração (00:11) e *2011_09_30_drive_0028_sync* com oito minutos e trinta e oito segundos (08:38) de duração.

Os dados da base KITTI são armazenados utilizando padronização própria. Suas informações são distribuídas em diversos arquivos de texto separados por tempo de aquisição. Eles contêm, entre outros, dados referentes à latitude, longitude, altitude, velocidades, aceleração e angulação do veículo. Além disso, a base disponibiliza arquivos de imagens das câmeras em formato PNG e nuvens de pontos do sensor LIDAR em arquivos com formato binário. Dessa forma, um pré-processamento com modificações nos arquivos é necessário para atender ao padrão de entrada de cada sistema.

3.4 Sistema de Localização

Entre as possibilidades de representação visual do sistema de localização está a reconstrução das informações finais de pose do ADS, com base nos dados de latitude, longitude, altitude e erros relativos. Estas informações devem estar presentes no arquivo de entrada padrão do módulo de localização.

A visualização para estes dados pode ser realizada por meio da movimentação de um marcador representando o veículo e uma elipse representando as incertezas das medidas, proporcional à dimensão do veículo real sobre um mapa 2D.

Para o desenvolvimento desta representação visual foi utilizada uma adaptação do recurso *Polyline* fornecido pela *Google Maps Javascript API* (POLYLINE, 2018). Esta API (*Application Programming Interface*) define uma sobreposição linear de segmentos de linha conectados no mapa. Um objeto *Polyline* consiste em uma matriz de localizações *LatLng* e cria uma série de segmentos de linha que conectam estas localizações em uma ordem sequencial, com opções para configuração da linha como cor, opacidade e estilo. A Figura 8 exibe um exemplo de utilização do *Polyline* sobre o mapa.

Figura 8 – *Polyline* ligando Oakland nos Estados Unidos e Brisbane na Austrália.



Fonte: Polyline (2018).

Porém, por padrão, a exibição do segmento de linha ocorre completamente, ou seja, é feita a leitura de todas as latitudes e longitudes e estas são aplicadas diretamente ao mapa, exibindo a trajetória completa realizada. Além disso, é necessário especificar os valores das latitudes e longitudes de forma fixa como um vetor de objetos no próprio código fonte, impedindo sua execução de forma dinâmica.

Uma adaptação ao recurso *Polyline* foi realizada objetivando exibir a rota do ADS no mapa de forma iterativa e sincronizada com as imagens das câmeras. As alterações também

têm como propósito permitir sua execução com resultados dinâmicos por meio da leitura dos dados armazenados nos arquivos de entrada de localização.

Para tanto, foram adicionadas funções ao código *Javascript* existente, que permitem a atualização automática de posição do marcador no mapa. A cada novo conjunto de coordenadas obtido do arquivo, um novo segmento de linha é conectado ao caminho atual, gerando a trajetória realizada pelo veículo, posição por posição. A representação visual é apresentada pelo acompanhamento da mudança de posição do veículo no mapa com base nas latitudes e longitudes lidas do arquivo.

Foram utilizados os dados de latitude e longitude extraídos dos arquivos da base KITTI para a definição de pose inicial do marcador no mapa e sua respectiva movimentação. Para o correto funcionamento da leitura dos dados, estes foram extraídos do arquivo de entrada e inseridos em um arquivo JSON no formato de uma matriz de localizações *LatLng* utilizando-se algoritmos na linguagem Java. Resultados preliminares podem ser observados na Figura 9.

Figura 9 – Resultados preliminares de representação do sistema de localização.



Fonte: Do autor (2018).

O marcador indica a pose atual do veículo, obtida do arquivo de entrada padrão de localização. A cada nova informação de pose lida do arquivo, conforme o tempo de

frequência de aquisição dos dados, o marcador se movimenta, deixando um segmento de linhas que representa a trajetória do veículo.

A informação de frequência na aquisição dos dados é necessária para possibilitar a exibição da pose do veículo no mapa sincronizada às imagens das câmeras. Isso permite a comparação entre os valores armazenados e a navegação real. Porém, a base KITTI não disponibiliza tal informação, estando acessível apenas a marca de tempo (*timestamp*) em que cada sinal do GPS foi adquirido.

Assim, algoritmos em Java foram desenvolvidos para calcular o tempo médio de obtenção de cada dado pelos sensores. Foram calculadas as diferenças das marcas de tempo atual e a próxima. Nos testes realizados foi identificada a frequência de 100 milissegundos para a aquisição de cada sinal do GPS. Esta informação foi inserida no arquivo de entrada de localização e utilizada para determinar a velocidade de movimentação do marcador sobre o mapa.

Além da pose final do ADS, a reconstrução visual proposta inclui ainda as incertezas para o sistema de localização. Como já afirmado, tais incertezas podem surgir de interferências causadas pela presença de edifícios, árvores, túneis e campos magnéticos, perda de sinal do GPS, erros de calibração, entre outros. Uma forma de se representar esta incerteza é por meio da exibição de uma elipse de tamanho variável em torno do marcador.

Para possibilitar esta representação foi utilizado o recurso *Circle* também disponibilizado pela *Google Maps Javascript API* (CIRCLE, 2018). Este recurso insere uma elipse no mapa, com variáveis para definição de área da elipse, posição central definida por objeto *LatLng* assim como no *Polyline*, cor, opacidade, entre outras configurações. A Figura 10 exibe um exemplo de utilização do recurso *Circle*.

No contexto do sistema de localização, uma elipse é desenhada na posição inicial do veículo com movimentações automáticas no mapa por meio da leitura do conjunto de dados de latitude e longitude armazenados nos arquivos de entrada de localização.

A área da elipse que representa a incerteza sobre a pose do ADS não é disponibilizada na base KITTI. Dessa forma, valores aleatórios de raio de círculos foram inseridos manualmente no arquivo de entrada da localização visando a validação da proposta.

Figura 10 – *Circle* para representação de populações nos Estados Unidos.



Fonte: Circle (2018).

Em seguida, para exibição da elipse, foi aplicada a equação de cálculo de área conforme a equação em 3.1.

$$A = \pi r^2 \quad (3.1)$$

Os resultados finais obtidos são discutidos no capítulo seguinte.

3.4.1 Outras Reconstruções para Sistema de Localização

Além da reconstrução desenvolvida, outras possibilidades de representação visual do sistema de localização são propostas, visando permitir melhor análise sobre a pose final do ADS. As sugestões apresentadas não foram implementadas devido à indisponibilidade dos dados e recursos necessários, mas estão presentes na pesquisa para discutir as diferentes opções de exibição dos dados de localização e sua importância na interpretação do cenário registrado.

Entre as propostas, pode-se realizar a inclusão do veículo em um mapa digital 3D de alta precisão, possibilitando uma melhor visualização do ambiente. Um exemplo de mapa digital 3D usando o F4Map no sistema proposto pode ser visualizado na Figura 11, com a inserção da representação visual do ADS no ambiente e sua área de incerteza.

Figura 11 – Representação visual 3D para o sistema de localização.



Fonte: Adaptado de F4Map (2017).

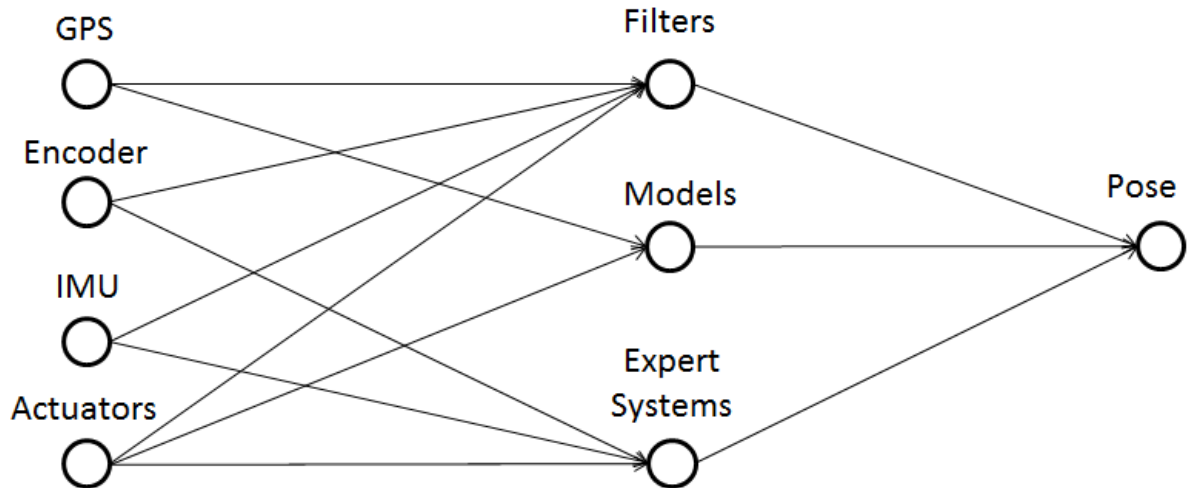
Além do F4Map, ferramentas como OSM-3D, Marble e o GDI3D são opções para desenvolvimento da representação visual proposta, utilizando mapas digitais 3D, sendo o F4Map uma ferramenta proprietária.

Contudo, somente a representação visual final não é suficiente para possibilitar a análise completa do processo de definição de pose do ADS. Além disso, a visualização das entradas e saídas tratadas internamente pelos algoritmos especialistas permite também a adição de informações ricas para a análise de perícias técnicas.

Esta representação pode ser realizada por meio da exibição de grafos. Um grafo é um modelo matemático que representa relações entre objetos e são utilizados na definição e/ou resolução de problemas de diversas áreas. É um tipo abstrato de estrutura de dados onde dado um número de objetos, há um conjunto de conexões entre pares destes objetos (ZIVIANI, 1999).

Por exemplo, caso o processo de definição de pose possua filtros e/ou modelos matemáticos para refinar as informações de localização, estes se tornam nós do grafo, além dos sensores e atuadores. As informações de entrada e saída serão representadas nas arestas. Um exemplo de representação das informações em formato de grafo para um sistema de localização é apresentado na Figura 12.

Figura 12 – Definição de pose do sistema de localização em formato de grafo.



Fonte: Do autor (2018).

Esta forma de representação permite o acompanhamento da transformação das informações durante o processo de definição de pose do ADS. Com base nos dados, nos erros e nas incertezas presentes nos arquivos, são definidos valores de referência para determinar os limites de tolerância para os valores de entrada e saída de cada nó, dando destaque ao nó quando um ou mais destes componentes ultrapassarem o limiar.

Se realizada paralelamente às demais reconstruções, esta representação visual permitirá identificar se uma falha foi causada por um erro ou incerteza, com origem em algum módulo ou subsistema representado em um nó do grafo. Também será possível visualizar o momento em que a falha ocorreu, ressaltando a importância da exibição visual das imperfeições do processo.

Entretanto, não foram encontradas ferramentas para manipulação de grafos de forma iterativa para exibição dinâmica das informações conforme sugerido. Softwares como o Graphviz⁴ podem ser utilizados para a geração dos grafos e em seguida exportados como imagens. Em conjunto a outros recursos, podem ser gerados vídeos exibindo a troca de informações entre os nós, representando-os dinamicamente.

⁴ <https://www.graphviz.org/>

3.5 Sistema de Percepção

Dados de sensores como lasers, radares e câmeras são combinados para permitir que um ADS perceba o ambiente ao seu redor. Devido à diversidade de elementos de hardware e software nesse processo, variadas formas de representação visual das informações podem ser realizadas.

A reprodução das imagens das câmeras pode auxiliar na comparação com as informações dos outros sistemas, que, sincronizada aos demais dados, permite validar ou refutar alguma inconsistência observada em outros processos.

A primeira opção para reconstrução visual do sistema de percepção foi a geração de vídeos a partir das imagens disponibilizadas pelas câmeras da base KITTI. Para tanto foi utilizado o aplicativo *FFmpeg* que, utilizando a frequência de 100 milissegundos de intervalo entre as aquisições das imagens das câmeras, gera um vídeo com 10 quadros por segundo. Na Figura 13 observa-se um quadro de vídeo gerado utilizando imagens da base KITTI.

Figura 13 – Quadro retirado de vídeo gerado com as imagens das câmeras.

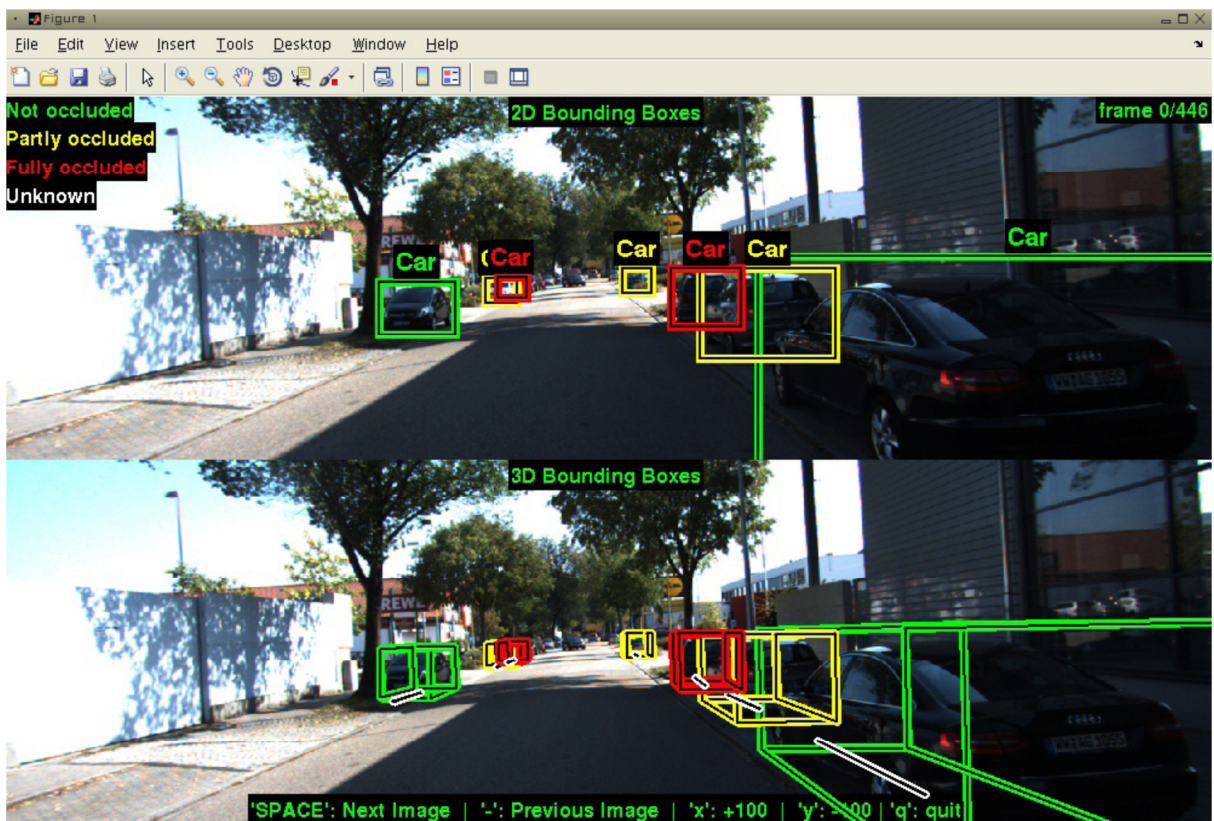


Fonte: Do autor (2018).

A base KITTI disponibiliza ainda um arquivo XML contendo anotações quanto aos objetos identificados, classificando-os como carros, vans, caminhões, pedestres, ciclistas e outros. Na base utilizada para validação da ferramenta, durante o teste de um minuto e vinte segundos são identificados 53 carros, 4 vans, 1 caminhão, 2 pedestres e 3 miscelâneas (sem identificação exata). Além das anotações de definição de objetos, também estão disponíveis nesse arquivo, dados sobre os quadros em que estes elementos estão visíveis, tamanho do objeto, oclusão, entre outras informações.

Este arquivo XML, juntamente com algoritmos em C++/MatLab (GEIGER, 2013) possibilitaram a geração de arquivos de imagem PNG e conseguinte geração de dois vídeos utilizando o aplicativo *FFmpeg* para o sistema de percepção: o primeiro com a inserção de retângulos de diferentes cores simbolizando a oclusão dos objetos presentes e o segundo, a partir de modificações realizadas no algoritmo original, para a inserção de retângulos de diferentes cores simbolizando a rotulação dos objetos. A Figura 14 apresenta um exemplo de utilização da caixa de oclusão nos objetos presentes na cena.

Figura 14 – Caixas 2D e 3D de oclusão de objetos.



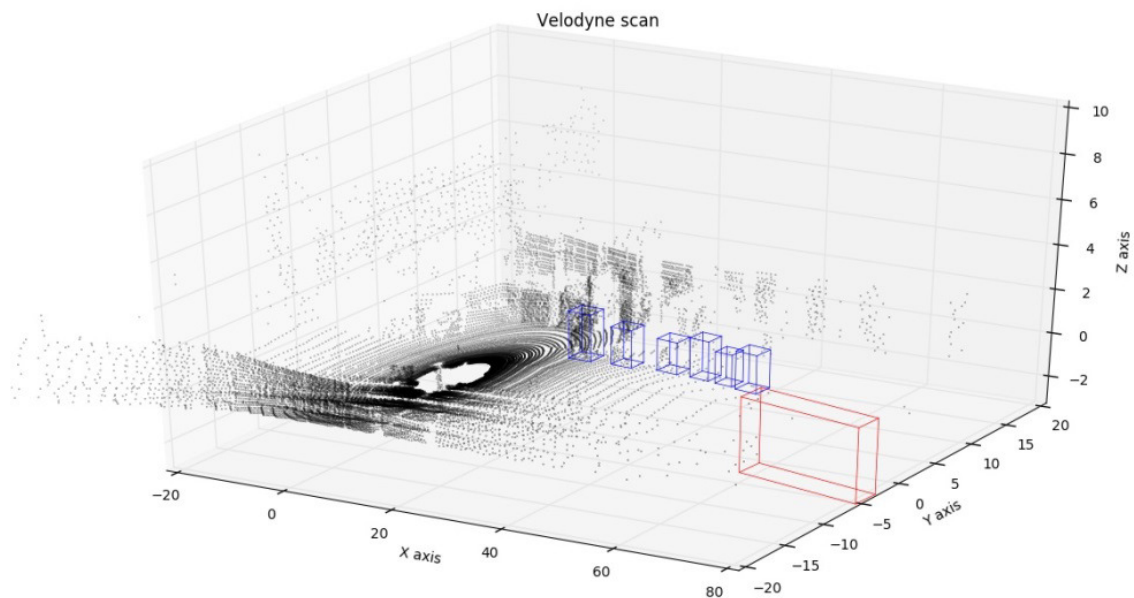
Fonte: Geiger (2013).

Saídas geradas pelos algoritmos na base de validação utilizada, tanto com a caixa de oclusão quanto com a caixa de rotulação de objetos, são apresentadas e discutidas no capítulo seguinte.

Além das imagens das câmeras e o arquivo XML de rotulação, também foram realizadas reconstruções visuais utilizando dados de sensores LIDAR. Estes sensores fornecem dados importantes sobre o ambiente no formato de nuvem de pontos.

A nuvem de pontos foi reconstruída utilizando o aplicativo *pykitti* (STARAVOITAU, 2017). Algoritmos específicos permitem variadas formas de visualização, gerando imagens em formato PNG que foram transformadas em vídeo por meio do aplicativo *FFmpeg*. Este processo permitiu a reconstrução da nuvem de pontos em três dimensões e pelo chamado *bird's-eye view*. Um exemplo de nuvem de pontos utilizando a ferramenta pode ser visualizado na Figura 15.

Figura 15 – Nuvem de pontos com visualização 3D.



Fonte: Staravoitau (2017).

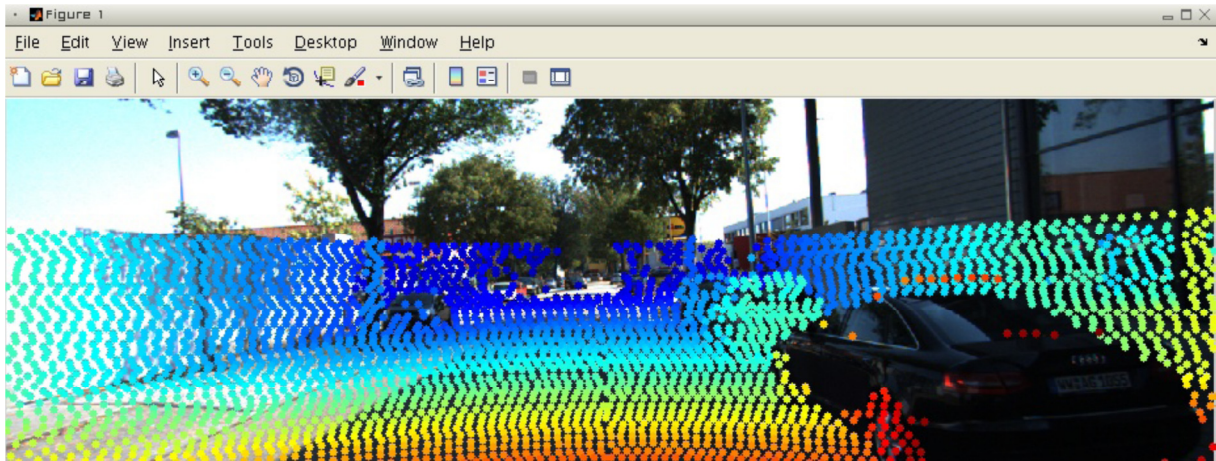
Resultados das nuvens de pontos obtidas especificamente com o aplicativo *pykitti* estão presentes nos resultados e discussões.

Porém, como já citado, um sensor laser pode ter resposta imprecisa quando aplicado a superfícies metálicas ou transparentes. Isso faz com que a informação de distância dos objetos refletidos apresente erros e incertezas, somadas pelos algoritmos utilizados para sua representação. Por esta razão, uma combinação de dados do sensor LIDAR com as imagens das câmeras pode fornecer importantes informações quanto à distância dos objetos, retornada pelos sensores.

Algoritmos em MatLab (GEIGER, 2013) permitem a representação dos pontos identificados pelo sensor LIDAR e sua inserção nas imagens das câmeras. A Figura 16 exhibe

um exemplo de junção das informações. Enquanto que pontos mais distantes são representados por cores azuis, pontos de maior proximidade do veículo são exibidos em tons avermelhados.

Figura 16 – Nuvem de pontos em conjunto com imagens de câmeras.



Fonte: Geiger (2013).

Porém, por uma questão de custo computacional, o algoritmo original ignora alguns pontos armazenados nos arquivos disponibilizados pela base KITTI. Uma modificação foi realizada no algoritmo para que fossem utilizados todos os pontos disponíveis obtidos pelo sensor LIDAR. Além disso, para cada quadro da base de validação utilizada foram gerados arquivos PNG com sua respectiva nuvem de pontos e em seguida seu vídeo com o aplicativo *FFmpeg*. Estas alterações permitiram a visualização do teste completo utilizando as imagens das câmeras e as distâncias dos objetos obtidas pelo sensor. Resultados são apresentados e discutidos no capítulo seguinte.

Por fim, o sistema de percepção faz ainda intenso uso de visão computacional. A visão robótica tem sido um assunto constantemente abordado e estudado por especialistas e apresenta diferentes técnicas como o processamento digital de imagens, a segmentação semântica, etc.


Para a presente proposta, a segmentação semântica foi escolhida para exibição da interpretação e rotulação dos objetos identificados na cena pelas câmeras.

Três diferentes algoritmos de segmentação foram testados, todos eles disponíveis *online* para a realização de *upload* da imagem e sua posterior disponibilização já segmentada:

o primeiro da Universidade de Cambridge chamado *SegNet*⁵, o segundo da Universidade de Oxford denominado *CRF as RNN*⁶ e o terceiro da AIS – *Autonomous Intelligent Systems* chamado *DeepScene*⁷.

Todos os 800 quadros de imagens em formato PNG, disponíveis na base de validação, foram submetidos aos três algoritmos e em seguida gerados em vídeo utilizando o aplicativo *FFmpeg*. A Figura 17 exibe a saída da segmentação semântica realizada pelo algoritmo *DeepScene*.

Figura 17 – Segmentação semântica utilizando algoritmo *DeepScene*.



Fonte: Do autor (2018).

Os resultados obtidos pelos algoritmos de segmentação semântica são apresentados e discutidos no capítulo seguinte.

⁵ <http://mi.eng.cam.ac.uk/projects/segnet/demo.php#demo>

⁶ <http://www.robots.ox.ac.uk/~szheng/crfasrnn/demo>

⁷ <http://deepscene.cs.uni-freiburg.de/>

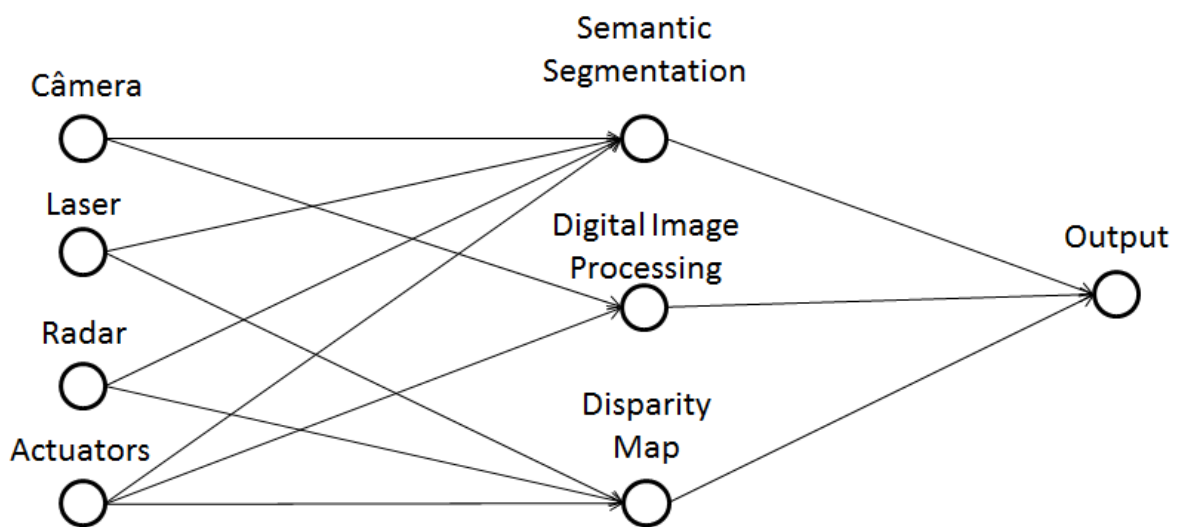
3.5.1 Outras Reconstruções para Sistema de Percepção

Grafos também podem ser adotados no sistema de percepção, apresentando os valores de entrada e saída em cada componente participante do processo.

Assim como no sistema de localização, essa forma de representação permite o acompanhamento da transformação das informações durante o processo de percepção do ADS. Erros e incertezas também são utilizados para definição dos valores de referência para determinar os limites de tolerância de cada nó, destacando os nós que ultrapassarem o limiar.

Também é sugerido realizar esta representação visual paralelamente às demais apresentadas, auxiliando na identificação das causas de falhas, bem como o momento em que ela ocorreu. A Figura 18 exibe um exemplo de apresentação do grafo do sistema de percepção.

Figura 18 – Representação visual do sistema de percepção em formato de grafo.



Fonte: Do autor (2018).


3.6 Sistema de Navegação

Como afirmado anteriormente, o sistema de navegação é responsável pela tomada de decisões do ADS, utilizando dados dos sistemas de localização e percepção. Porém, devido à inexistência de dados armazenados pelos registradores sobre o planejamento realizado, as

reconstruções visuais deste módulo não foram implementadas, permanecendo no âmbito das sugestões de possibilidades de representação.

Entre as sugestões para o sistema de navegação está a visualização do trajeto planejado/realizado, além das restrições durante o processo de navegação como obstáculos, por exemplo. A Figura 19 apresenta uma proposta de como esta reconstrução pode ser realizada. Esta representação visa permitir observar quais foram os passos definidos pelo sistema de navegação para se desviar de obstáculos identificados pelo sistema de percepção. Informações como velocidade máxima da via, tipos de faixas, entre outros, podem ser adicionados a esta representação visual.


Figura 19 – Reconstrução visual de planejamento de sistema de navegação.



Fonte: Adaptada de Mouhagir (2017).

Além disso, é importante visualizar a participação de cada um destes componentes no processo, seus limiares de tolerância para valores de entrada e saída e as transições dos dados entre os objetos. Neste sentido, outra representação visual proposta, em formato de grafo, é apresentada na Figura 20.

Figura 20 – Representação visual de sistema de navegação em formato de grafo.



Fonte: Do autor (2018).

O uso do grafo para a representação do sistema de navegação exhibe, de forma geral, os sinais de entrada, processamentos e sinais de saída para geração da tomada de decisão do ADS. Neste grafo, além dos dados fornecidos pelos sensores embarcados e algoritmos especialistas, as ações realizadas pelo condutor também devem ser exibidas para auxiliar a avaliação das decisões tomadas pelo ADS.

3.7 Sistema de Controle

O sistema de controle é responsável por acionar os atuadores e comandos na direção do veículo, executando o que foi planejado pelo sistema de navegação.

Informações diversas das ações finais executadas pelo ADS como velocidade, esterçamento das rodas, ângulo do volante e acionamento de freios estão entre as representações visuais possíveis para este sistema. Outra informação importante a ser representada visualmente é qual a forma de condução do veículo no momento de registro dos dados, sendo com ou sem intervenção do condutor. Isso permite análises sobre a atribuição de responsabilidades em caso de falhas ou acidentes.

Para este sistema foi realizada a representação da visão interna do *cockpit* do veículo. Assim, todos os dados constantes no painel como velocidade, rotação do volante, saídas de sistemas ADAS, entre outras, podem ser exibidas, proporcionando uma análise mais adequada das ações executadas pelo veículo e/ou pelo condutor. Entre os atuadores envolvidos, foram selecionadas as informações de velocidade, angulação do volante e frenagem do veículo para reconstrução.

A representação exibe o volante, velocímetro digital e luz de acionamento de freio. As imagens das câmeras também foram utilizadas para possibilitar o acompanhamento das informações exibidas. O ambiente final foi representado utilizando a ferramenta *Blender Game Engine*, em conjunto com algoritmos escritos na linguagem *Python*.

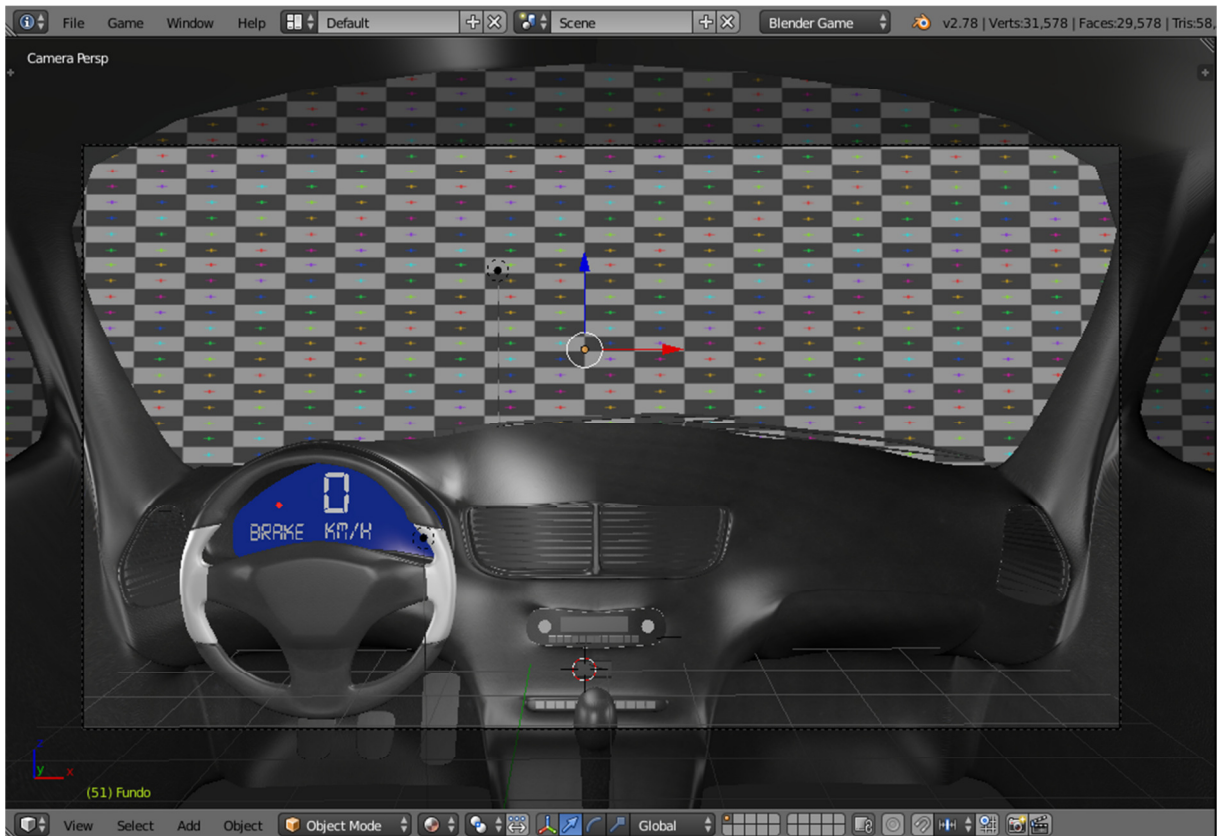
Foi realizada inicialmente a modelagem do volante virtual, do painel do veículo, do velocímetro digital e da luz de frenagem. Ao fundo foi adicionado um componente plano que exibe as imagens da câmera. Um botão *Play* também foi adicionado para permitir a execução da animação somente quando acionado. Resultados preliminares da modelagem inicial podem ser observados na Figura 21.

Para a exibição das imagens da câmera foi utilizado como referência um script *Python* padrão, disponível na página de tutoriais do Blender (BLENDER, 2017). O mesmo foi modificado para permitir o início da execução do vídeo somente quando o botão *Play* for acionado.

Para exibição dos dados de velocidade do veículo foi implementado um script *Python* que, após acionado o botão *Play*, inicia a leitura e execução dos dados armazenados no arquivo de entrada de controle previamente gerado na fase de pré-processamento dos dados.

Para a representação da velocidade foi utilizada a informação v_f (*forward velocity*) dos arquivos presentes na base KITTI, inseridos no arquivo de entrada de controle.

Figura 21 – Modelagem do *cockpit* do veículo.



Fonte: Do autor (2018).

A informação, armazenada originalmente em metros por segundo, foi convertida para quilômetros por hora pela multiplicação dos valores pelo fator 3,6, em virtude das correspondências entre unidades de medida de espaço e tempo, sendo um quilômetro igual a 1000 metros e uma hora igual a 3600 segundos.

Ao componente de velocímetro modelado foram adicionadas as propriedades *speed* e *count*. A primeira armazena a velocidade atual obtida do arquivo e a segunda controla a posição da informação a ser lida, sendo incrementada a cada nova velocidade adquirida, com este processo sendo repetido até o final do arquivo. Além destas propriedades, um sensor do tipo *Delay* foi adicionado para definir a frequência de tempo com que uma nova informação será lida do arquivo e a alteração da velocidade será aplicada na renderização. O tempo de

espera aplicado foi de 100 milissegundos, conforme já definido anteriormente como a frequência de aquisição dos dados.

Já a representação de movimentação do volante foi realizada utilizando a informação *yaw* dos arquivos da base KITTI armazenada em radianos e a reprodução ocorre juntamente com os demais componentes após o acionamento do botão *Play*. Nenhuma conversão da informação foi necessária, uma vez que o script *Python* implementado utiliza a informação do ângulo em radianos para efetuar a rotação do volante.

Assim como o velocímetro, duas propriedades denominadas *angle* e *count* foram adicionadas para, respectivamente, armazenar o ângulo de rotação em radianos obtido do arquivo e controlar a posição da informação a ser lida. A variável *count* também é incrementada a cada novo ângulo obtido, repetindo até o término do arquivo. Outro sensor *Delay* foi adicionado para o componente do volante com a frequência de aquisição dos dados de 100 milissegundos para alterar a posição nos instantes corretos.

Entretanto, a informação *yaw* ou guinada, refere-se ao movimento em torno do eixo vertical, perpendicular ao eixo longitudinal do corpo. Isso significa que ela representa o quanto um corpo rotacionou em torno do eixo Z, não representando os ângulos de rotação do volante, mas sim do próprio veículo. A base KITTI não dispõe da informação de ângulo de rotação do volante, sendo necessário realizar manipulações adicionais após a leitura dos dados e, portanto, sendo a representação final do volante apenas uma aproximação da realidade. Para uma reprodução mais fidedigna, o arquivo padrão de entrada do módulo de controle deve dispor de informações específicas de rotação do volante e não somente do veículo.

Assim, movimentos adicionais de retorno do volante à sua posição original foram necessários. Para tanto, valores de ângulos em radianos foram inseridos manualmente no arquivo de entrada de controle para que, após o término do movimento do veículo, o volante pudesse retornar a sua posição inicial. A cada leitura do arquivo referente ao ângulo de rotação do veículo é verificada a diferença entre o ângulo atual e o próximo. Caso este valor seja menor que 0.001 graus radianos, o volante pode ser movimentado para seu estado inicial. Este limiar foi definido conforme observação do comportamento do veículo e indica que o mesmo não está mais executando um deslocamento lateral e sim realizando um percurso em linha reta.

É importante reforçar que o valor para o limiar entre o movimento de curva ou reta foi aplicado apenas para possibilitar uma representação do volante mais próxima à realidade. Os

dados reais não são disponibilizados pela base KITTI no formato exigido e a não aplicação deste recurso deixaria o volante na posição de realização de uma curva, mesmo quando o veículo estivesse em linha reta. A possibilidade de aplicação da ferramenta proposta em outras bases contendo os dados específicos de ângulo de rotação do volante implicam na adaptação do algoritmo *Python* para não mais efetuar a manipulação de retorno do volante para a posição original.

Um algoritmo *Python* também foi desenvolvido para permitir o acendimento de uma luz no painel do veículo sinalizando o acionamento dos freios. Para este processo também foi adicionada uma propriedade *count* para controlar a posição da informação a ser lida, sendo também incrementada a cada novo valor obtido, repetindo até o término do arquivo. Outro sensor *Delay* foi adicionado com a frequência de aquisição dos dados de 100 milissegundos para sincronização com os demais componentes.

Entretanto, a base KITTI não disponibiliza informações de frenagem do veículo. Dessa forma, para fins de validação, os valores foram inseridos manualmente no arquivo de entrada de controle sendo valor 1 (um) para freios acionados e 0 (zero) para não acionamento. Os valores foram definidos conforme observações realizadas no teste validado, onde a redução de velocidade do veículo indicaria acionamento dos freios.

Todos os componentes dinâmicos do módulo de controle (volante, velocímetro, luz de freio e câmera) possuem a propriedade *set*. Esta propriedade define quando deve ser iniciada a leitura dos dados do arquivo e consequente execução das ações. Configurada inicialmente com o valor 0 (zero), esta é alterada para 1 (um) após clique com o botão esquerdo do *mouse* no botão *Play*, dando início à animação.

Além desta, outra propriedade chamada *file* está presente em todos os componentes do módulo. Esta propriedade indica o caminho físico do arquivo de entrada de controle para leitura.

Por fim, combinações da representação visual realizada para os sistemas de localização e percepção podem ainda ser fundidas à visão interna do veículo. Isso possibilita alternar entre as imagens de mapas digitais 3D de alta precisão, câmeras, segmentação semântica da cena ou da nuvem de pontos com informações relativas às distâncias dos pontos.

Para tanto, o algoritmo original de exibição do vídeo no painel que representa as imagens da câmera foi modificado, visando alternar entre as diferentes possibilidades. Por exemplo, após iniciar a execução da animação, ao pressionar a tecla S do teclado será exibido


o vídeo de segmentação semântica do sistema de percepção mencionado na seção 3.5. Caso o usuário escolha por voltar à visão das imagens originais das câmeras, deve-se pressionar a tecla C do teclado. Os resultados do sistema de controle são apresentados e discutidos no capítulo seguinte.

3.7.1 Outras Reconstruções para Sistema de Controle

Na Figura 22 está representada uma proposta de reconstrução para um sistema de controle com a fusão dos dados dos sistemas de percepção, localização e navegação. Nesta representação são adicionados os elementos adquiridos por GPS, lasers, câmeras, algoritmos de processamento e ações realizadas pelo próprio veículo.

Informações sobre frenagem podem ser reproduzidas acendendo-se as luzes de freio do veículo reconstruído. Além disso, uma movimentação livre na cena pode permitir visualizar o esterçamento das rodas e a angulação do veículo, dados estes, por exemplo, armazenados por odômetros, sensores de rotação do volante e IMU.

Figura 22 – Representação visual 3D com fusão de sistemas.



Fonte: Youtube (2018).

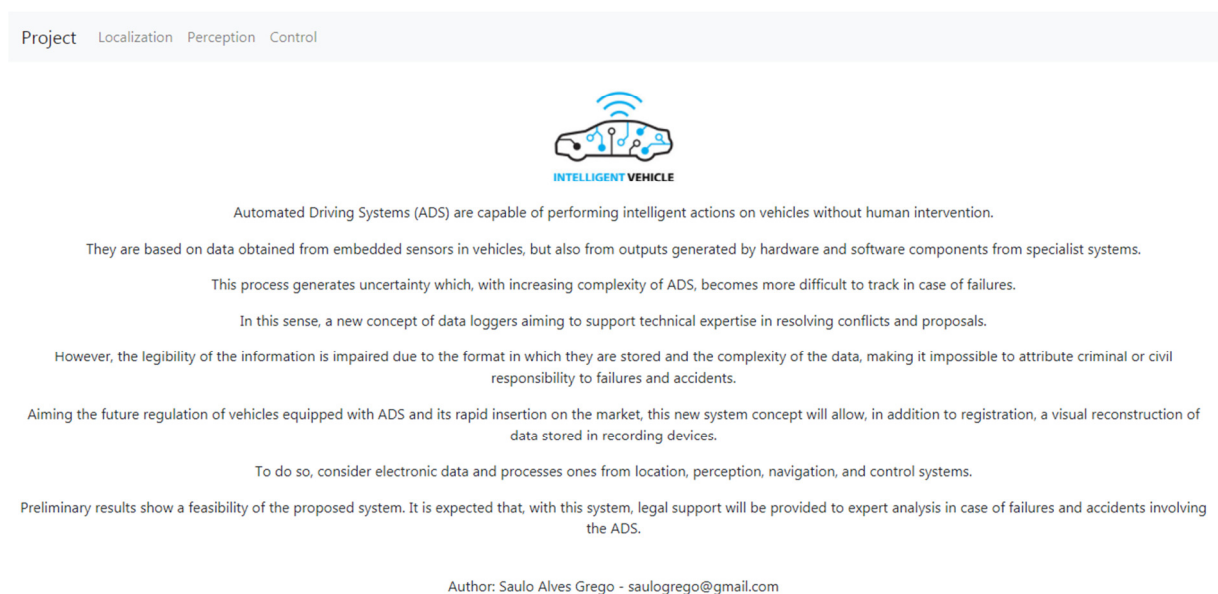
Esta reconstrução visual não foi implementada, dada a ausência de dados necessários, bem como a complexidade para o desenvolvimento da mesma.

4 RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados e discutidos os resultados obtidos para a reconstrução visual dos sistemas de localização, percepção e controle.

Todas as reconstruções visuais realizadas foram integradas em uma aplicação *web*, dividida por sistemas. O módulo de localização foi implementado utilizando a linguagem *Javascript* enquanto que os demais sistemas envolveram a geração de imagens em formato PNG e posterior geração de vídeo que é reproduzido após acionamento dos mesmos. A opção pelos vídeos foi determinada pela incompatibilidade das linguagens utilizadas como MatLab, *pykitti*, Blender, entre outras, com sua execução em ambiente *web*. A Figura 23 exibe a página principal da aplicação.

Figura 23 – Página principal da aplicação *web* de reconstrução visual.



Fonte: Do autor (2018).

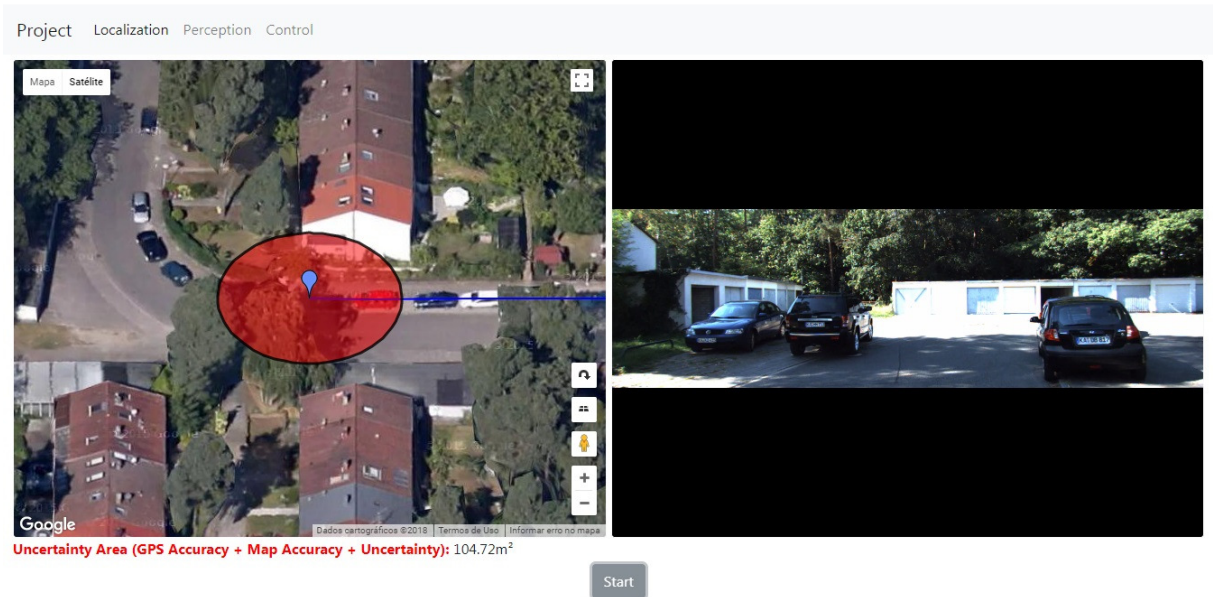
4.1 Sistema de Localização

Os resultados obtidos para o sistema de localização apontam para a viabilidade da proposta realizada, permitindo a representação de forma visual das informações armazenadas pelos registradores de dados.

Os recursos *Polyline* e *Circle* da *Google Maps Javascript API* permitiram a reprodução da pose do ADS e sua respectiva área de incerteza em mapa 2D de forma

sincronizada às imagens das câmeras. O resultado da execução do sistema de localização pode ser observado na Figura 24.

Figura 24 – Sistema de localização sincronizado com imagens das câmeras.



Fonte: Do autor (2018).

O mapa é exibido do lado esquerdo da tela enquanto que o vídeo com imagem das câmeras é reproduzido do lado direito. Abaixo do mapa são exibidas as informações referentes à área de incertezas do sistema de localização.

A animação é iniciada após o acionamento do botão *Start*, presente na parte inferior da tela. O marcador indica a pose atual do veículo com base nos valores de latitude e longitude armazenados no arquivo de entrada de localização obtido da base KITTI. A linha azul representa a trajetória realizada pelo veículo e o círculo vermelho a área de incertezas. Devido à inexistência de informações sobre a acurácia do GPS, acurácia do mapa e erros relativos, os valores de incerteza foram inseridos manualmente no arquivo de entrada de localização com valores aleatórios de raios de círculos e aplicadas na equação 3.1 de cálculo de área.

Todas as representações são atualizadas a cada nova informação de latitude e longitude lida do arquivo, que acontece a cada 100 milissegundos, valor este encontrado previamente como a taxa de aquisição dos dados.

Nesta representação, a elipse tem tamanho variável conforme o nível de incerteza do módulo de localização. Isso significa que as informações finais de pose do ADS inserem-no

na posição exibida pelo marcador. Porém, devido às incertezas causadas pela presença de árvores, edifícios e/ou campos magnéticos, o veículo pode se encontrar em qualquer local dentro da área da elipse. Estes estão relacionados ao sinal do GPS e demais sensores e também às transformações sofridas pelos dados durante o processo até a definição de pose do ADS no mapa. Para a correta execução deste módulo, é necessário acesso à internet.

É importante ressaltar a exatidão das latitudes e longitudes armazenadas, permitindo uma boa representação da pose do veículo, com exceção dos testes realizados no conjunto de dados do diretório *2011_09_30_drive_0028_sync* da base KITTI. Durante a fase de avaliação das bases e utilizando o citado diretório composto de 5177 quadros, especificamente nas informações presentes no intervalo entre as amostras de quadros 843 e 1007, é possível observar que o marcador invade a região onde existem casas. Este comportamento mostra-se inconsistente ao observado nas câmeras, voltando posteriormente na amostra 1008 para a representação de pose correta.

A Figura 25 exhibe o momento em que a representação da pose fica incoerente ao registrado nas imagens, com latitudes e longitudes que inserem o marcador de trajetória sobre regiões não executadas pelo ADS.

Tal comportamento pode ser justificado pela falha na aquisição dos dados referentes à latitude e longitude devido à presença de vegetação alta na região, causando perda ou má qualidade de sinal do sensor GPS. A base KITTI não faz uso de modelos ou filtros para refinar os valores de pose do ADS.

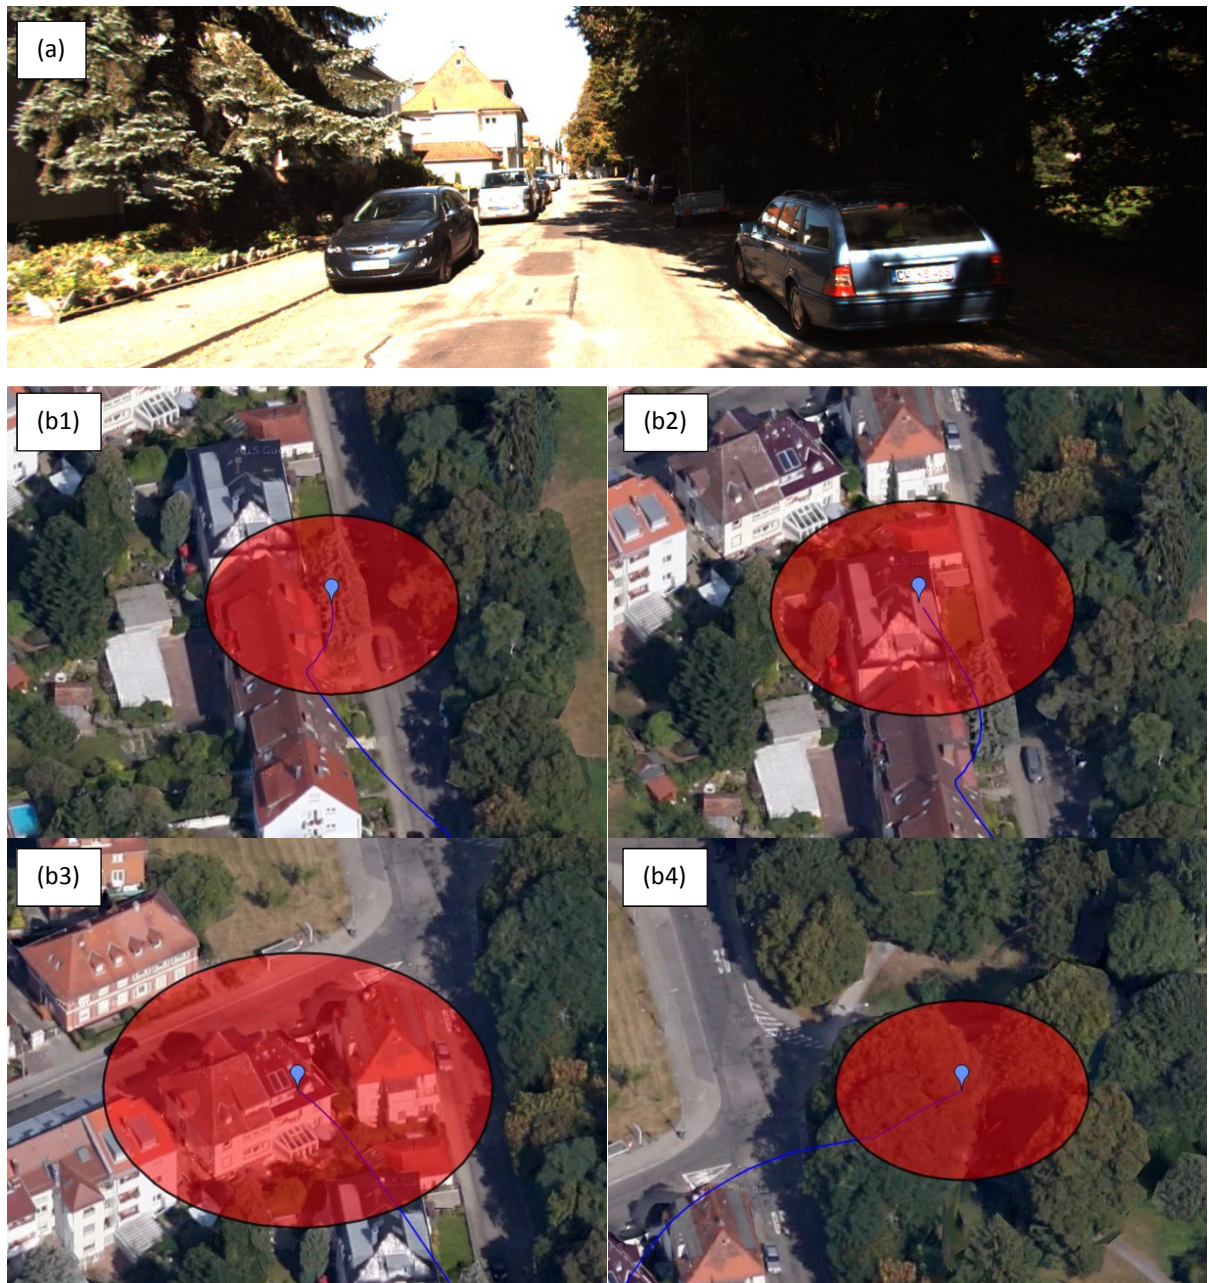
Portanto, é possível afirmar que a reconstrução visual para o sistema de localização utilizando um mapa 2D permitiu observar a acurácia dos dados de pose, verificando a consistência das informações de trajetória. A exibição do marcador sobre o mapa em conjunto com as imagens das câmeras possibilita uma validação simplificada dos valores finais de pose obtidos pelo sistema de localização.

Por meio da reconstrução visual desenvolvida, a inconsistência observada na Figura 25 permite afirmar que, caso um acidente ocorresse naquele instante e o veículo estivesse sendo conduzido pelo ADS, o sistema de localização poderia ser o responsável pelo mesmo.

Análises mais aprofundadas são necessárias para se determinar se a falha ocorreu pela perda de sinal do GPS, ruídos, erros de calibração ou mesmo em algum modelo ou filtro utilizado para refinar a pose final. Por este motivo, as demais reconstruções sugeridas como a

transição das informações em formato de grafo são úteis para se encontrar exatamente o componente responsável pela falha.

Figura 25 – Comportamento inconsistente de pose do veículo.



Legenda: (a) Localização do ADS na amostra 882 da câmera exibindo o veículo conduzido corretamente pela rua. (b) Sequência entre amostras 843 a 1007 do GPS com pose do ADS inconsistente com as imagens da câmera inserindo-o em região que invade a área de casas.

Fonte: Do autor (2018).

Apesar de não ser completamente suficiente para definir as causas de um acidente, a reconstrução realizada para o sistema de localização pode auxiliar no direcionamento de perícias técnicas para a identificação das falhas, atendendo partes dos objetivos propostos para a pesquisa.

4.2 Sistema de Percepção

Diferentes representações para o sistema de percepção foram propostas e desenvolvidas. Dentre elas a exibição de vídeo gerado com as imagens das câmeras, caixa de oclusão nos objetos da cena, caixa semântica para rotulação de objetos da cena, segmentação semântica, nuvem de pontos de sensor LIDAR e nuvem de pontos com indicativos de distância por cores.

A Figura 26 exibe a opção de reprodução dos dados brutos das câmeras para o sistema de percepção. O botão *Start* na parte inferior da tela inicia a reprodução do vídeo.

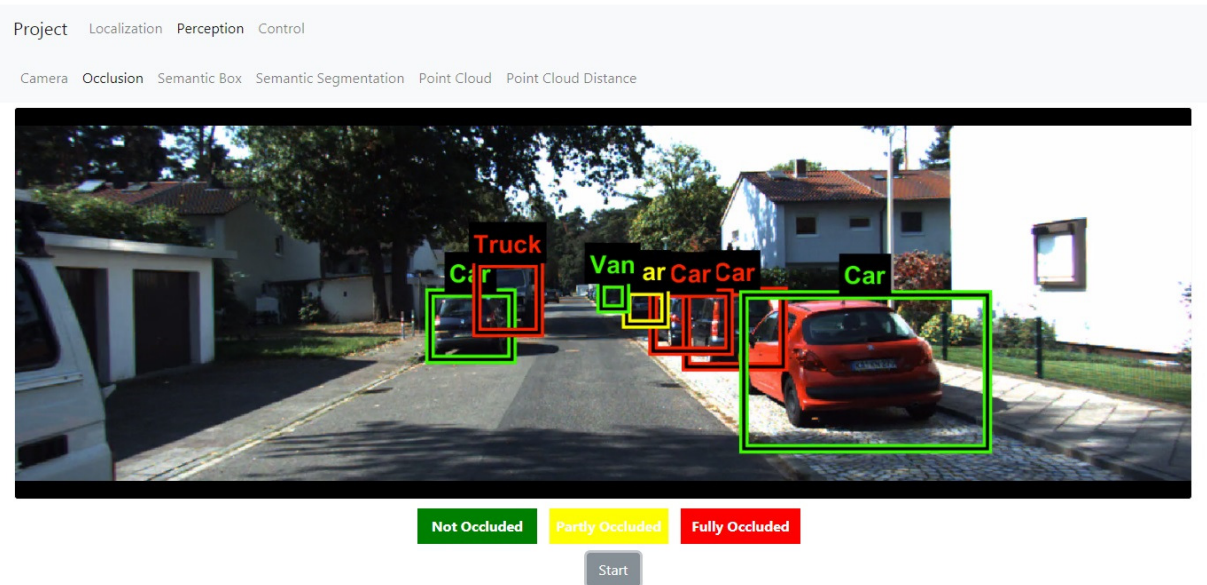
Figura 26 – Reprodução de imagens da câmera.



Fonte: Do autor (2018).

Além da reprodução da câmera, foi aplicado o algoritmo de inserção de caixa de oclusão utilizando o arquivo XML com anotações disponibilizadas pela base KITTI. A reconstrução do vídeo utilizando a caixa de oclusão pode ser observada na Figura 27.

Figura 27 – Caixa de oclusão para objetos em cena.



Fonte: Do autor (2018).

Objetos totalmente oclusos são representados com caixas vermelhas, parcialmente oclusos com caixas amarelas e objetos não oclusos com caixas verdes.

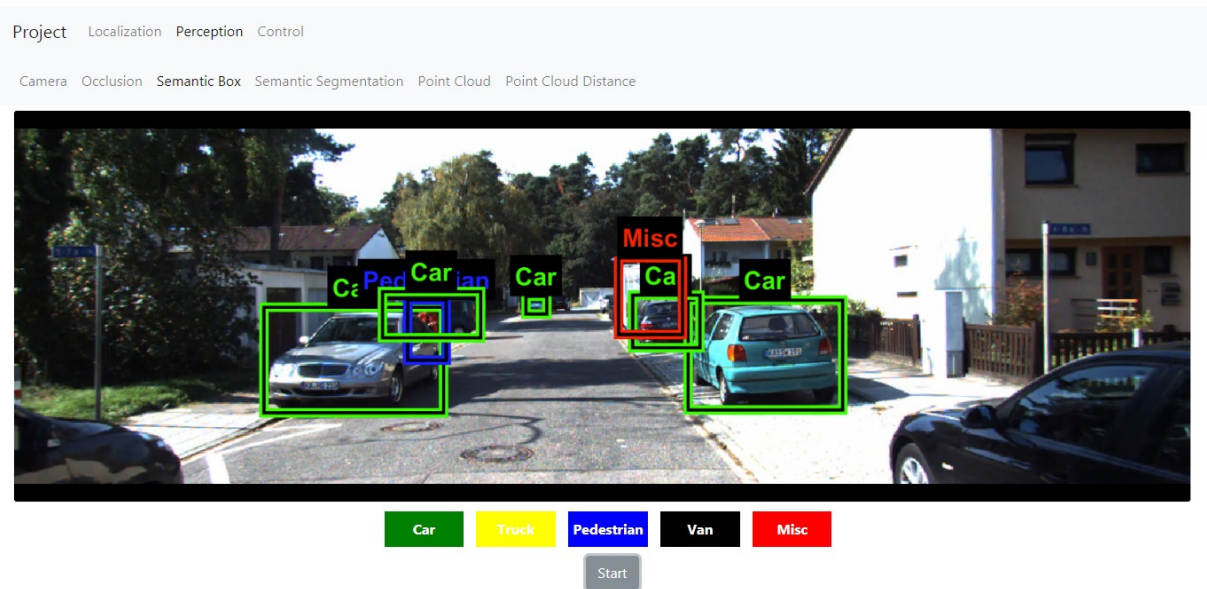
Entretanto, as informações de oclusão presentes no arquivo XML são estáticas, não sendo uma classificação realizada em tempo real por algoritmos especialistas com base na análise das imagens.

Ainda assim é possível considerar a reconstrução visual destas classificações de forma dinâmica, bem como sua importância na percepção do ambiente pelo ADS. Em conjunto com outras informações, a oclusão pode ser utilizada para que o ADS realize planejamentos e tomadas de decisão com base no quanto um objeto está visível.

A investigação das causas de um acidente pode ser realizada com esta reconstrução visual observando se o ADS foi capaz de analisar corretamente a oclusão de objetos e em seguida prever as ações de obstáculos dinâmicos para evitar colisões.

Ainda fazendo uso do arquivo XML de anotações da base KITTI e após realizar alterações no algoritmo original de inserção de caixa de oclusão, foram geradas imagens com classificação de objetos de cena utilizando uma caixa semântica. O resultado desta alteração pode ser visualizado na Figura 28.

Figura 28 – Caixa semântica com rótulos para objetos em cena.



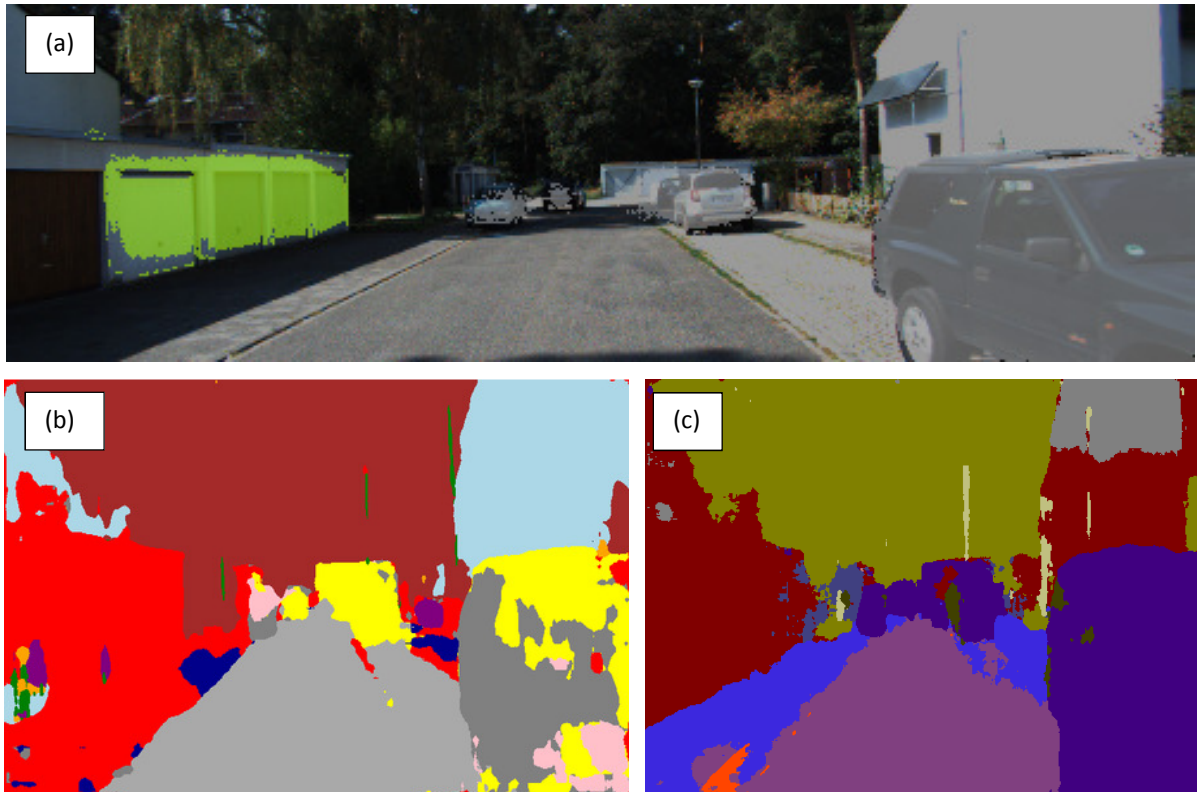
Fonte: Do autor (2018).

A reprodução do vídeo é iniciada após clique no botão *Start* na parte inferior da tela. A legenda com os rótulos das caixas por cores foi inserida abaixo do vídeo, sendo carros identificados com caixas na cor verde, caminhões em amarelo, pedestres em azul, vans com a cor preta e miscelânea em vermelho.

Porém, assim como na caixa de oclusão, os rótulos para classificação dos objetos são estáticos. Dessa forma, a segmentação semântica das imagens de forma dinâmica com base na análise de objetos na cena foi realizada com o objetivo de se observar as incertezas existentes em algoritmos de visão robótica, muito utilizados em sistemas de percepção. A Figura 29 exibe as saídas obtidas com os algoritmos *CRF as RNN*, *DeepScene* e *SegNet* citados na seção 3.5.

O algoritmo *CRF as RNN* classifica os objetos em cena nos seguintes rótulos: Avião, Barco, Bicicleta, Cachorro, Cadeira, Carro, Cavalo, Garrafa, Gato, Mesa, Motocicleta, Ônibus, Ovelha, Pássaro, Pessoa, Planta, Sofá, Trem, TV/Monitor e Vaca. Na Figura 29(a) é possível observar que diversos objetos não são classificados pelo algoritmo. Além disso, os muros da casa foram classificados como Trem. Dessa forma, a segmentação semântica do algoritmo *CRF as RNN* foi considerada insuficiente para os objetivos da proposta.

Figura 29 – Segmentação semântica de algoritmos CRF as RNN, DeepScene e SegNet.




Legenda: (a) Segmentação semântica do algoritmo *CRF as RNN*. (b) Segmentação semântica do algoritmo *DeepScene*. (c) Segmentação semântica do algoritmo *SegNet*.

Fonte: Do autor (2018).

Já os algoritmos *DeepScene* e *SegNet* são capazes de classificar todos os objetos presentes na cena. Porém, após a geração dos vídeos de ambas as segmentações, foi possível observar inconstâncias do algoritmo *DeepScene* quanto à rotulação dos objetos. Suas classificações são divididas em: Calçada, Carro/Ônibus/Caminhão, Cerca, Céu, Ciclista, Pessoa, Poste, Prédio, Rodovia, Sinalização de Trânsito, Vegetação e Nulo (Sem Classificação). Na Figura 30 é possível observar tal comportamento inconstante.

Em três amostras seguidas, especificamente as amostras 88, 89 e 90, é possível observar diferentes classificações para o que pode ser considerado pela imagem da câmera como área de vegetação. Segundo legenda do algoritmo *DeepScene*, a cor roxa representa Calçada, azul representa Rodovia e marrom representa Cerca. Além destes, observa-se ainda mudanças na classificação de diversos outros objetos da cena.

Figura 30 – Segmentação semântica com *DeepScene*.



Legenda: (a) Amostra 88 de imagem da câmera. (b) Segmentação semântica da amostra 88. (c) Segmentação semântica da amostra 89. (d) Segmentação semântica da amostra 90.

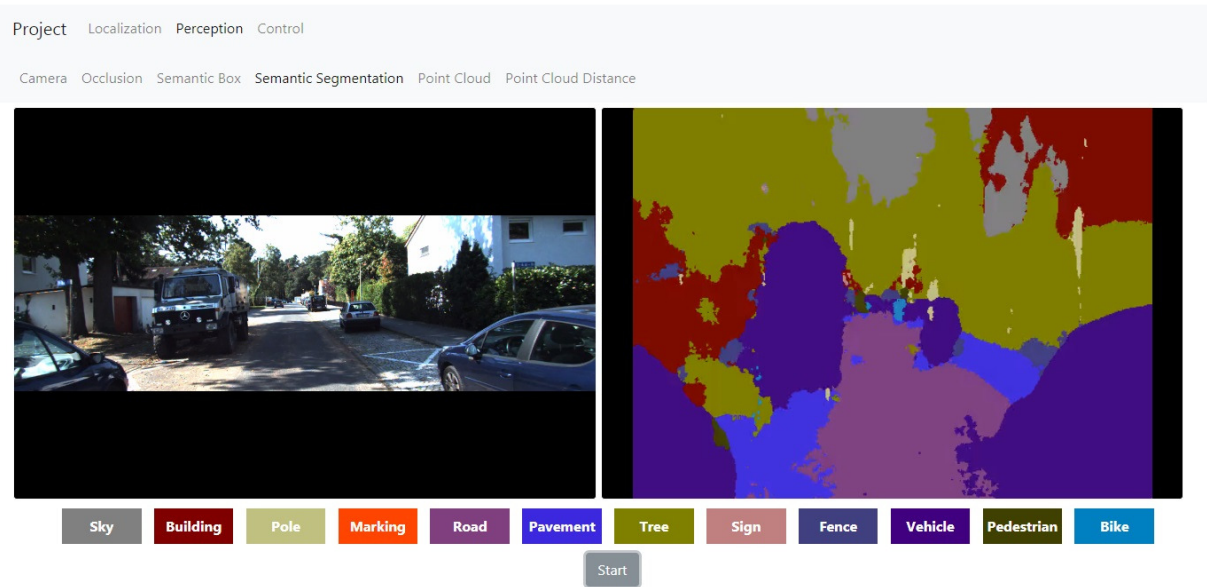
Fonte: Do autor (2018).

Dentre os algoritmos testados, o *SegNet* obteve os melhores resultados. Apesar de incertezas e falhas observáveis nas classificações, problema comum já discutido anteriormente na seção 2.2, o algoritmo apresentou constância na rotulação dos objetos. O *SegNet* foi então selecionado para a representação visual da segmentação semântica para o sistema de percepção.

A Figura 31 apresenta o resultado do algoritmo de segmentação semântica *SegNet*, o qual é executado de forma sincronizada com o vídeo original das imagens da câmera para comparação dos resultados, após clique no botão *Start* na parte inferior da tela. Abaixo dos vídeos está a legenda com as classificações realizadas pelo algoritmo, sendo divididas em: Árvore, Bicicleta, Calçada, Cerca, Céu, Marcação de Via, Pedestre, Poste, Prédio, Rua, Sinalização e Veículo.

Na figura é possível observar a correta classificação de objetos como veículos, rua, calçada, árvores, prédios e céu. Caso um acidente ocorresse e o veículo estivesse sendo conduzido pelo ADS, a reconstrução visual realizada poderia auxiliar na análise das causas da falha. Uma identificação errônea de objetos na cena poderia determinar o algoritmo de segmentação semântica como responsável pela falha.

Figura 31 – Segmentação semântica de objetos da cena para sistema de percepção.



Fonte: Do autor (2018).

Assim, a rotulação dos dados segmentados deve ser registrada, bem como todo o processo necessário para se chegar a tal classificação. Ela deve permitir a reconstrução visual da interpretação semântica realizada pelo sistema de percepção e, conseqüentemente, identificar possíveis falhas na categorização dos objetos.

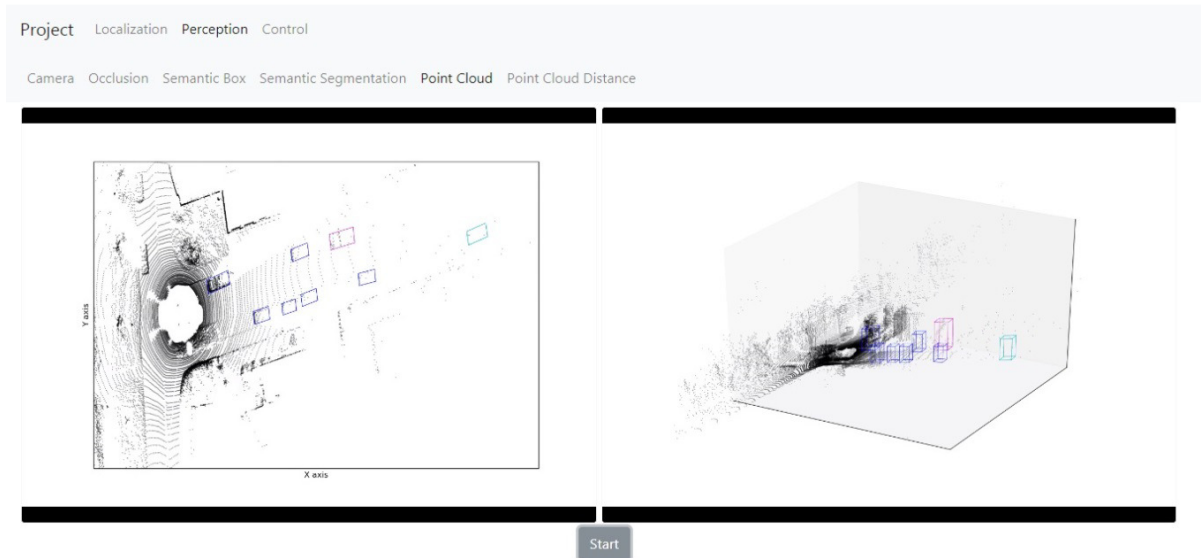
Além das imagens das câmeras e algoritmos que fazem uso dos dados destas, o sensor laser LIDAR, que também é utilizado no processo de percepção do ambiente, fornece um conjunto de possibilidades para reconstruções visuais na proposta.

Dentre elas, a mais básica refere-se à reprodução dos dados brutos do sensor no formato de nuvem de pontos. Apesar de não necessitarem de nenhum tipo de processamento adicional, os dados deste sensor são úteis na análise dos objetos estáticos ou dinâmicos identificados pelo ADS.

Utilizando o aplicativo *pykitti*, a nuvem de pontos foi reconstruída utilizando duas versões diferentes: a primeira com uma visão aérea (*bird's eye view*) e a segunda em 3D. O resultado pode ser visualizado na Figura 32.

A reprodução dos vídeos é iniciada após o clique no botão *Start* presente na parte inferior da tela e as duas versões são executadas de forma sincronizada. As caixas tridimensionais em cores exibidas em conjunto com a nuvem de pontos são criadas com base nos dados do arquivo XML com anotações, disponibilizado pelo KITTI.


Figura 32 – Reprodução de nuvem de pontos com visão aérea e 3D.



Fonte: Do autor (2018).

A última reconstrução visual realizada para o sistema de percepção envolve a nuvem de pontos do sensor laser LIDAR, imagens das câmeras e algoritmos. Esta reconstrução analisa a nuvem de pontos com as informações de distância e as insere nas imagens das câmeras com classificações por cores. A Figura 33 apresenta a saída do algoritmo.

Figura 33 – Nuvem de pontos com representação de distâncias por cores.



Fonte: Do autor (2018).

Esta reconstrução permite a exibição de incertezas nas informações do sistema de percepção. Pontos mais distantes são representados por cores azuis enquanto que pontos de maior proximidade do veículo são exibidos em tons avermelhados.

Na figura é possível observar a presença de pontos sobre o veículo que estão relativamente próximos ao sensor serem apresentados na cor azul. É possível observar ainda a presença de áreas sem classificação devido à falta de retorno de informação do sensor.

Análises podem ser realizadas e conclusões sobre acidentes podem ser extraídas a partir da reconstrução realizada, onde uma colisão pode ser causada pela ausência de retorno do sensor laser LIDAR ou pela falha dos algoritmos que processam estes dados.

Em resumo, as reconstruções visuais realizadas para o sistema de percepção apresentaram bons resultados e atingiram os objetivos da pesquisa de se reproduzir as incertezas bem como prover suporte às perícias na análise de falhas e acidentes. Ainda assim, as demais reconstruções sugeridas para o sistema de percepção, como saídas de algoritmos de processamento de imagens e a transição das informações entre os componentes no formato de grafo são úteis para se realizar uma análise mais aprofundada do problema.


4.3 Sistema de Controle

Entre as propostas de reconstrução visual para o sistema de controle, a visão interna do *cockpit* do veículo foi desenvolvida e seus resultados permitiram a exibição das informações de velocidade do veículo, rotação do volante e acionamento dos freios. Estas informações são reproduzidas de forma sincronizada com as imagens das câmeras, sendo sua reconstrução visual consistente por todo o conjunto de dados.

A velocidade do veículo é exibida em formato numérico e o acionamento dos freios é sinalizado pelo acendimento de uma luz vermelha, ambos exibidos no painel virtual do veículo desenvolvido. As curvas realizadas pelo veículo são percebidas tanto pelas imagens das câmeras quanto pela movimentação do volante.

A sequência de ações realizadas pelo sistema de controle durante o teste com a base de validação pode ser observado na Figura 34.

Figura 34 – Sequência de ações do sistema de controle.



Fonte: Do autor (2018).

Todas as informações são lidas do arquivo de entrada de controle e executadas conforme a frequência de aquisição dos dados definida anteriormente. A Figura 35 exibe o resultado da execução do vídeo gerado para o sistema de controle.

Figura 35 – Reconstrução visual do sistema de controle.



Fonte: Do autor (2018).

Como já afirmado, o modelo criado para a reprodução dos movimentos do volante sofre inconsistências com o modelo real devido aos valores de ângulo de rotação não serem disponibilizados pela base KITTI. Dessa forma, cálculos adicionais foram necessários para simular o comportamento do veículo. Além disso, os dados de acionamento dos freios foram adicionados manualmente no arquivo de entrada de controle conforme observações de redução da velocidade do veículo, uma vez que a base KITTI também não disponibiliza esta informação. Espera-se que testes com outras bases de dados sejam realizados e desde que as informações referentes aos ângulos de rotação do volante e acionamento dos freios sejam corretamente disponibilizadas, a funcionalidade da ferramenta seja devidamente validada.

Por fim, combinações da saída do sistema de controle foram combinadas com as saídas do sistema de percepção, visando possibilitar diferentes análises das ações realizadas pelo ADS. Para tanto, o vídeo original das câmeras foi substituído pelos vídeos de caixa de oclusão, caixa semântica, segmentação semântica e distâncias por cores usando a nuvem de pontos, como pode ser visto respectivamente nas figuras 36, 37, 38 e 39.

Figura 36 – Reconstrução visual do sistema de controle com caixa de oclusão.



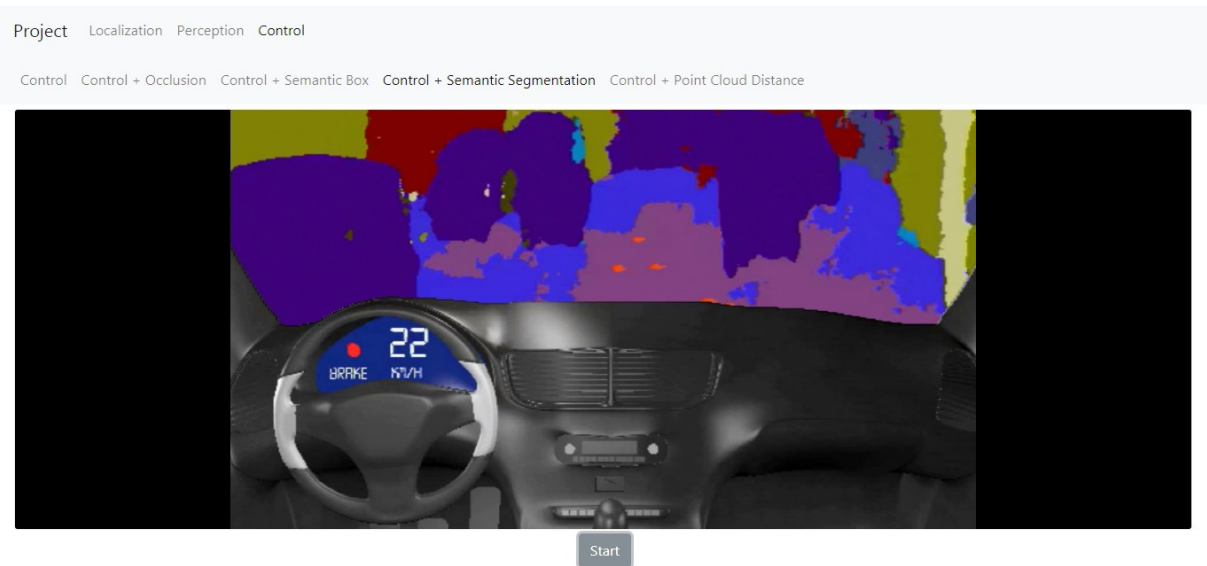
Fonte: Do autor (2018).

Figura 37 – Reconstrução visual do sistema de controle com caixa semântica.



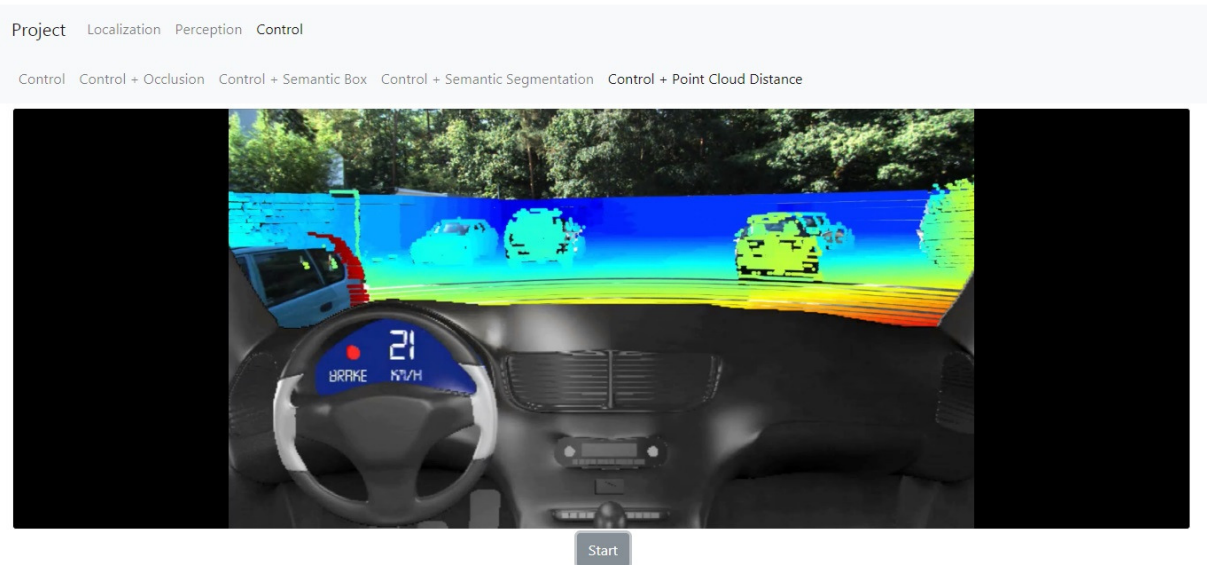
Fonte: Do autor (2018).

Figura 38 – Reconstrução visual do sistema de controle com segmentação semântica.



Fonte: Do autor (2018).

Figura 39 – Reconstrução visual do sistema de controle com nuvem de pontos por cores.



Fonte: Do autor (2018).

Informações adicionais podem ser incluídas na reconstrução realizada, como as saídas de sistemas ADAS, o modo de condução (manual ou autônomo), alteração de cores de pedais quando acionados e diversas outras, para prover mais informações sobre o estado do veículo e de seu ADS.

4.4 Considerações Finais

Muitas possibilidades surgem a partir do presente trabalho. Diferentes padrões de dados podem ser definidos, conforme observação das necessidades para o compartilhamento e reconstrução dos dados. Novas representações visuais sobre os dados armazenados pelos dispositivos registradores podem ser necessárias, sendo as sugestões apresentadas uma elucidação quanto à necessidade de definição do padrão e da reconstrução dos cenários registrados.

Diferentemente de sistemas convencionais que reproduzem apenas os dados brutos armazenados, a proposta se baseou ainda na reconstrução das imperfeições inerentes aos ADS. Para tanto, foi sugerida a representação visual dos erros e incertezas existentes nos sensores, equipamentos, algoritmos especialistas e demais componentes. Elas permitirão o acompanhamento na transformação dos dados desde sua aquisição pelos sensores até a sua

execução, auxiliando assim na identificação das causas de falhas ou acidentes envolvendo um ADS, provendo maior clareza nas discussões sobre a atribuição de responsabilidades. As propostas podem prover conhecimento suficiente para a evolução na qualidade dos ADS, uma vez que falhas poderão ser identificadas e corrigidas.

Os resultados obtidos têm auxiliado na compreensão sobre a importância do padrão dos dados e quais serão as melhores formas de se realizar tal armazenamento. Além disso, as variadas formas de reconstrução visual das informações que foram sugeridas e desenvolvidas abrem um leque de possibilidades para trabalhos futuros e evoluções da tecnologia, fortalecendo o processo de certificação e homologação dos ADS.

5 CONCLUSÃO

Este trabalho buscou discutir a importância da padronização no formato dos dados armazenados pelos dispositivos registradores em veículos terrestres inteligentes para, entre outros propósitos, permitir a reconstrução visual dos cenários registrados. O padrão sugerido divide os arquivos de entrada nos sistemas de localização, percepção, navegação e controle e realiza a separação do arquivo em uma área de cabeçalho com os dados, seguida pelos seus respectivos valores. Tais valores incluem os dados brutos de sensores, dados processados pelos algoritmos especialistas, erros e incertezas existentes no processo, além de dados definidos como necessários para permitir a reconstrução visual.

Diferentes formas de representação visual foram desenvolvidas, utilizando a reprodução dos dados separada por sistemas, com diferentes propostas para cada módulo. Erros e incertezas dos dados foram reproduzidos visualmente, permitindo validar a influência dos mesmos no processo de tomada de decisão. Além das representações desenvolvidas, sugestões de reconstrução visual foram realizadas para oferecer mais opções de visualização dos dados registrados.

Os resultados atestam a necessidade de criação de uma ferramenta de reconstrução visual dos dados armazenados pelos dispositivos registradores para auxiliar na análise de falhas e acidentes envolvendo veículos equipados com ADS, viabilizada pela definição de um padrão para os dados registrados.

5.1 Produção Científica

Este trabalho gerou a submissão do artigo “*Event Data Recorder Standardization and how to Reproduce the Saved Data*” para a revista IEEE Latin America, estando em fase de análise.

Além disso, todo material desenvolvido está disponibilizado no Laboratório de Mobilidade Terrestre (LMT) da UFLA, onde poderá ser utilizado e continuado em trabalhos futuros.

5.2 Trabalhos Futuros

Diferentes necessidades surgem a partir do presente trabalho. Novos padrões de dados podem ser definidos conforme observação das necessidades para o compartilhamento e reconstrução dos dados.

Novas formas de se realizar a representação visual armazenada pelos registradores podem ser propostas. Melhorias e evoluções devem ser realizadas, buscando a consistência, confiabilidade e robustez da ferramenta.

Para tanto, para o futuro, pretende-se realizar os seguintes trabalhos:

- Identificação de novos dados necessários para os sistemas de localização, percepção, navegação e controle;
- Elaboração de novas possibilidades de reconstrução visual dos dados registrados;
- Pesquisa e/ou desenvolvimento de ferramentas que possibilitem as reconstruções visuais sugeridas, mas não implementadas;

REFERÊNCIAS

ABUHADROUS, I. et al. Onboard real-time system for 3D urban environment reconstruction. In: IEEE. **Intelligent Vehicles Symposium**. Paris, 2003. p. 479–483.

AMARAL, E. M. A. et al. Detecção e rastreamento de veículos em movimento para automóveis robóticos autônomos. In: **XII Simpósio Brasileiro de Automação Inteligente (SBAI)**. Natal, 2015. p. 801–806.

ARMSTRONG, D. et al. **Autonomous navigation technologies developed to support the 2007 Darpa Urban Challenge**. Gainesville, 2007.

AUSTRALIA, Parliament of the Commonwealth of. **Social issues relating to land-based automated vehicles in Australia**. Canberra, 2017.

AUTOWARE. **CPFL/Autoware: Open-source to self-driving**. Disponível em: <<https://github.com/CPFL/Autoware>>. Acesso em 06 nov. 2017.

BARBOSA, H. C. et al. The new generation of standard data recording device for intelligent vehicles. In: IEEE. **19th International Conference of Intelligent Transportation Systems**. Rio de Janeiro, 2016.

BLENDER. **Playing movies – Blender 3D Game Engine**. Disponível em: <http://www.tutorialsforblender3d.com/Game_Engine/VideoTexture/VideoTexture_Movie_4.html>. Acesso em 18 jul. 2017.

CAMPBELL, R. J.; FLYNN, P. J. A survey of free-form object representation and recognition techniques. In: **Computer Vision and Image Understanding**. Columbus, Ohio, 2001. v. 81, p. 166–210.

CHAKLADER, S. et al. Black box: An emergency rescue dispatch system for road vehicles for instant notification of road accidents and post crash analysis. In: IEEE. **Informatics, Electronics & Vision (ICIEV), 2014 International Conference on**. Dhaka, 2014.

CIRCLE. **Circles**. Disponível em: <<https://developers.google.com/maps/documentation/javascript/examples/circle-simple?hl=pt-br>>. Acesso em 25 mar. 2017.

F4MAP. **F4Map Demo – Interactive 3D Map**. Disponível em: <<http://demo.f4map.com/#lat=52.4639706&lon=13.4272982&zoom=19&camera.theta=43.568>>. Acesso em: 29 jan. 2017.

FABRIS, S.; LONGO, G.; MEDEOSSI, G. Automated analysis of train event recorder data to improve micro-simulation models. In: **WIT Transactions on State of the Art in Science and Engineering**. Italy, 2010. v. 40, p. 125–134.

FAGNANT, D. J.; KOCKELMAN, K. Preparing a nation for autonomous vehicles: opportunities, barriers and policy recommendations. **Transportation Research**. ScienceDirect. [S.l.], 2015. v. 77, p. 167–181.

FRANKE, U. et al. Autonomous driving approaches downtown. In: IEEE. **Intelligent Systems and their Applications**. [S.l.], 1999. v. 13, n. 6, p. 40–48.

GARCIA, D. A. N. **Contribución a la autolocalización de robots móviles basada en la fusión de información multissensorial**. 2009. 322 p. Tese (Doutorado em Automação e Informática Industrial)-Universidad Politecnica de Valencia, Valencia, 2009.

GEIGER, A. et al. Vision meets robotics: The KITTI Dataset. In: **International Journal of Robotics Research (IJRR)**. [S.l.], 2013.

GERMANY, Federal Ministry of Transport and Digital Infrastructure. **Ethics comission: Automated and connected driving**. Germany, 2017.

GORLICK, M. M. **The flight recorder: An architectural aid for system monitoring**. Los Angeles, 1991. p. 175–183.

IST, Instrumented Sensor Techonology. **Indy race cars are equipped with crash data recorders to improve safety**. Okemos, 2010.

KIM, M.; KIM, K. Data forgery detection for vehicle black box. In: IEEE. **2014 International Conference on Information and Communication Technology Convergence (ICTC) on Busan**. Daejeon, 2014. p. 636–637.

KNIGHT, W. **The dark secret at the heart of AI**. Disponível em: <<https://www.technologyreview.com/s/604087/the-dark-secret-at-the-heart-of-ai/>>. Acesso em: 09 out. 2017.

LEVINSON, J.; MONTEMERLO, M.; THRUN, S. Map-based precision vehicle localization in urban environments. In: MIT Press. **Robotics: Science and Systems III**. [S.l.], 2008.

LIMA, D. A. de. **Sensor-based navigation applied to intelligent electric vehicles**. 2015. 158 p. Tese (Doutorado em Tecnologia de Informação de Sistemas)-Université de Technologie de Compiègne, Compiègne, 2015.

LITMAN, T. **Autonomous vehicle implementation predictions: implications for transport planning**. [S.l.], 2015.

MA, Y. et al. **An invitation to 3-D vision: From image to geometric models**. 1st ed. Berkeley: Springer. 2005.

MAURER, M. et al. **Autonomous driving: Technical, legal and social aspects**. Germany. 2015. ISBN: 978-3-662-48845-4.

MOTRO, A.; SMETS, P. **Uncertainty management in information systems: From needs to solutions**. 1st ed. United States of America: Springer. 1997.

MOUHAGIR, H. et al. Trajectory planning for autonomous vehicle in uncertain environment using evidential grid. In: **20th IFAC World Congress**. Toulouse, 2017.

NEHMZOW, U. **Mobile robotics: A practical introduction**. 2nd ed. London: Springer. 2003.

NHTSA, National Highway Traffic Safety Administration. **Federal automated vehicles policy: Accelerating the next revolution in roadway safety**. Washington, U.S. Department of transportation, 2016.

NHTSA, National Highway Traffic Safety Administration. **Automated driving systems 2.0: A vision for safety**. Washington, U.S. Department of Transportation, 2017.

NOYER, U. et al. Generating high precision maps for advanced guidance support. In: IEEE. **Intelligent Vehicles Symposium**. Eindhoven, 2008.

OULASVIRTA, A.; ESTLANDER, S.; NURMINEN, A. Embodied interaction with a 3D versus 2D mobile map. **Personal and Ubiquitous Computing**, Helsinki, 2009. v. 13, p. 303–320.

PARK, D. W. et al. Forensic analysis technique of car black box. In: **International Journal of Software Engineering and Its Applications**. South Korea, 2014. vol. 8, n. 11, p. 1–10.

PARK, H.; KO, D. A design of the intelligent black box using mining algorithm. In: **International Journal of Smart Home**. Korea, 2012. v. 6, n. 2, p. 1–6.

PENDLETON, S. D. et al. Perception, planning, control and coordination of autonomous vehicle. In: **Machines**. [S.l.], 2017.

POLYLINE. **Simple Polylines**. Disponível em: <<https://developers.google.com/maps/documentation/javascript/examples/polyline-simple?hl=pt-br>>. Acesso em: 15 jun. 2017.

RUIZ, M. F. R. **Desenvolvimento de um sistema de localização híbrido para navegação autônoma de veículos terrestres em ambiente simulado**. 2014. 112 p. Dissertação (Mestrado em Engenharia Mecânica)-Universidade Estadual de Campinas, Campinas, 2014.

SAE Standard J3016. **Taxonomy and definitions for terms related to driving automation systems for on-road motor vehicles**. United States of America, 2016.

SHALEV-SHWARTZ, S.; SHAMMAH, S.; SHASHUA, A. **On a formal model of safe and scalable self-driving cars**. United States of America, 2017.

STARAVOITAU, A. **Visualizing lidar data**. Disponível em: <<https://navoshta.com/kitti-lidar/>>. Acesso em: 07 set. 2017.

TAYLOR, G.; BLEWITT, G. Virtual differential GPS & road reduction filtering by map matching. In: **Proceedings of the 12th International Technical Meeting of the Satellite Division of The Institute of Navigation (ION GPS 1999)**. Nashville, 1999. p. 1675–1684.

THRUN, S.; BURGARD, W.; FOX, D. In: MIT Press. **Probabilistic robotics**. [S.l.], 2005.

THRUN, S. et al. Stanley: The robot that won the DARPA Grand Challenge. In: **Journal of Fields Robotics**. California, 2006, p. 661–692.

UNITED STATES, Senate of. **H.R.3388**: An act. United States of America, 2017.

VITOR, G. B. **Rastreamento de alvo móvel em mono-visão aplicado no sistema de navegação autônoma utilizando GPU**. 2010. 154 p. Dissertação (Mestrado em Engenharia Mecânica)-Universidade Estadual de Campinas, Campinas, 2010.

WORLD HEALTH ORGANIZATION. **Global status report on road safety**. Geneva, 2013.

XU, P. et al. Information fusion on oversegmented images: an application for urban scene understanding. In: **Proceedings of the Thirteenth IAPR International Conference on Machine Vision Applications (MVA)**. Kyoto, 2013. p. 189–193.

YOUTUBE. **Pave Video**. Disponível em:
<https://www.youtube.com/watch?time_continue=4&v=cd_2M30o-PY>. Acesso em: 12 out. 2017.

ZHAO, Q.; LI, Z.; HE, X. **Building extraction from LIDAR Point Cloud Data using marked point process**. Liaoning, 2014.

ZHU, Z.; WANG, Y.; JIANG, G. Statistical image modeling for semantic segmentation. In: **IEEE Transactions on Consumer Electronics**. China, 2010, v. 56, n. 2, p. 777–782.

ZIVIANI, N. **Projetos de algoritmos com implementações em Pascal e C**. 3. ed. Belo Horizonte: Cengage Learning, 2010.