André Carmona Hernandes

Análise de Risco de Colisão Usando Redes Bayesianas

Dissertação apresentada à Escola de Engenharia de São Carlos da Universidade de São Paulo, como parte dos requisitos para obtenção do título de Mestre em Engenharia Mecânica

Área de Concentração: Dinâmica das Máquinas & Sistemas
Orientador: Prof. Assoc. Marcelo Becker

ESTE EXEMPLAR TRATA-SE DA VERSÃO CORRIGIDA. A VERSÃO ORIGINAL ENCONTRA-SE DISPONÍVEL JUNTO AO DEPARTAMENTO DE ENGENHARIA MECÂNICA DA EESC-SP

São Carlos
2012

AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica preparada pela Seção de Atendimento ao Usuário do Serviço de Biblioteca – EESC/USP

H557a

Hernandes, André Carmona
Análise de risco de colisão usando redes Bayesianas. / André Carmona Hernandes ; orientador Marcelo Becker. São Carlos, 2012.

Dissertação (Mestrado) – Programa de Pós-Graduação em Engenharia Mecânica e Área de Concentração em Dinâmica das Máquinas & Sistemas -- Escola de Engenharia de São Carlos da Universidade de São Paulo, 2012.

1. Inteligência artificial. 2. Redes Bayesianas. 3. Robôs móveis. 4. Sistemas de auxílio ao motorista. I. Título.

FOLHA DE JULGAMENTO

Candidato: Engenheiro **ANDRÉ CARMONA HERNANDES.**

Título da dissertação: "Análise de risco de colisão usando redes bayesianas".

Data da defesa: 23/08/2012

Comissão Julgadora:	**Resultado:**
Prof. Associado **Marcelo Becker (Orientador)** (Escola de Engenharia de São Carlos/EESC)	APROVADO
Prof. Dr. **Daniel Varela Magalhães** (Escola de Engenharia de São Carlos/EESC)	APROVADO
Prof. Dr. **Bjorn Thorsten Jensen** (Bern University of Applied Sciences/Suíça)	APROVADO

Coordenador do Programa de Pós-Graduação em Engenheira Mecânica:
Prof. Associado **Marcelo Areias Trindade**

Presidente da Comissão de Pós-Graduação:
Prof. Titular **Denis Vinicius Coury**

Dedico este trabalho a minha mãe e aos meus avós que não puderam ver o final do mesmo.

Gostaria de agradecer, primeiramente, meu orientador, o Prof. Assoc. Marcelo Becker, por ter acreditado em mim e no meu trabalho e, por me fazer crer ser possível chegar até aqui, mesmo que eu duvidasse disso.

Gostaria de agradecer à todos os integrantes do Laboratório de Robótica Móvel, que tornaram o período de mestrado uma experiência única e prazerosa. Em especial, gostaria de agradecer ao André Salomão Brito Mendonça, ao Kléber de Oliveira Andrade e ao Rafael Coronel Bueno Sampaio, por todo o apoio que ofereceram, pela paciência em escutar minhas reclamações e desilusões, por dividir o entusiasmo em cada passo do trabalho desenvolvido e acima de tudo, pela amizade, que muito aprecio.

Gostaria de agradecer à todos os meus amigos por me lembrarem que a vida não é só trabalho, e por todos os ótimos momentos experenciados.

Gostaria de agradecer à minha familia, que mesmo longe, sempre foi e será meu ponto de confiança. Em especial, gostaria de agradecer meu pai, Antônio Carlos Hernandes, e minha irmã, Marina Carmona Hernandes, por sempre estarem ao meu lado e constantemente me lembrando que nunca se deve desistir, mesmo nas horas mais difícieis como as que enfrentamos juntos.

Gostaria de agradecer à Deus, por ter me enviado a inspiração no momento crucial para o término da dissertação.

Por fim, gostaria de agradecer a CAPES, pelo apoio financeiro que possibilitou o desenvolvimento desta dissertação.

Epígrafe

"No sensible decision can be made any longer without taking into account not only the world as it is, but the world as it will be."

Isaac Asimov, *Escritor Norte-Americano*

Resumo

HERNANDES, A. C. **Análise de Risco de Colisão Usando Redes Bayesianas.** 2012. Dissertação (Mestrado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2012.

A segurança no tráfego de carros é um assunto em foco nos dias de hoje e, dentro dele, podem-se citar os sistemas de auxílio ao motorista que vêm sendo desenvolvidos com a finalidade de reduzir o grande número de fatalidades em acidentes de trânsito. Tais sistemas de auxílio buscam mitigar falhas humanas como falta de atenção e imprudência. Visto isso, o projeto SENA, desenvolvido pelo Laboratório de Robótica Móvel da Escola de Engeharia de São Carlos, busca contribuir com a evolução dessa assistência ao motorista. O presente trabalho realiza um estudo sobre uma técnica de inteligência artificial chamada de Redes Bayesianas. Essa técnica merece atenção em virtude de sua capacidade de tratar dados incertos em forma de probabilidades. A rede desenvolvida por esse trabalho utiliza, como dados de entrada, os classificadores em desenvolvimento no projeto SENA e tem como resposta um comportamento que o veículo deve executar, por um ser humano ou por um planejador de trajetórias. Em função da alta dimensionalidade do problema abordado, foram realizados dois experimentos em ambiente simulado de duas situações distintas. A primeira, um teste de frenagem próximo a um ponto de intersecção e a segunda, um cenário de entroncamento. Os testes feitos com a rede indicam que classificadores pouco discriminantes deixam o sistema mais propenso a erros e que erros na localização do ego-veículo afetam mais o sistema se comparado a erros na localização dos outros veículos. Os experimentos realizados mostram a necessidade de um sistema de tempo real e um *hardware* mais adequado para tratar as informações mais rapidamente.

Palavras-chave: Inteligência Artificial. Redes Bayesianas. Robôs móveis. Sistemas de Auxílio ao Motorista.

Abstract

HERNANDES, A. C. **Colision Risk Assessment Using Bayesian Networks.** 2012. Dissertação (Mestrado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2012.

The safety of cars in traffic scenarios is being addressed on the past few years. One of its topics is the Advanced Driver-Assistance Systems which have been developed to reduce the fatality numbers of traffic accidents. These systems try to decrease human failures, such as imprudence and lack of attention while driving. For these reasons, the SENA project, in progress on the Mobile Robotics Laboratory at the Sao Carlos School of Engineering (EESC), aims to contribute for the evolution of these assistance systems. This work studies an artificial intelligence technique called Bayesian Networks. It deserves our attention due to its capability of handling uncertainties with probability distributions. The network developed in this Masters Thesis has, as input, the result of the classifiers used on SENA project and has, as output, a behavior which has to be performed by the vehicle with a driver or autonomously by the means of a path planner. Due to the high dimensionality of this issue, two different tests have been carried out. The first one was a braking experiment near a intersection point and the other one was a T-junction scenario. The tests made indicate that weak classifiers leaves the system more instable and error-prone and localization errors of the ego-vehicle have a stronger effect than just localization errors of other traffic participants. The experiments have shown that there is a necessity for a real-time system and a hardware more suitable to deal quickly with the information.

Keywords: Artificial Intelligence. Bayesian Networks. Mobile Robotics. Advanced Driver-Assistance Systems.

Publicações

1. SAMPAIO, R. C. B. ; HERNANDES, A. C. ; FERNANDES, V. ; BECKER, M. ; SIQUEIRA, A. . "*A New Control Architecture for Robust Controllers in Rear Electric Traction Passenger HEVs*". IEEE Vehicular Technology Society / Transactions on Vehicular Technology, 2012.

2. RONCANCIO, H. ; HERNANDES, A. C. ; BECKER, M. . "*Vision-based System for Pedestrian Recognition using a Tuned SVM Classifier*" - In: IEEE Workshop on Engineering Applications 2012 (WEA-2012), 2012, Bogotá. Proc. of IEEE Workshop on Engineering Applications 2012, 2012. v. 1. p. 1-6.

3. RONCANCIO, H. ; HERNANDES, A. C. ; BECKER, M. . "*Reconhecimento de Pedestres à Frente de um Veículo de Passeio Usando uma Máquina de Vetor de Suporte Ajustada*" - In: CONEM 2012 - Congresso Nacional de Engenharia Mecânica, 2012, São Luiz - MA. Anais do CONEM 2012. Rio de Janeiro : ABCM, 2012. v. 1. p. 1-10.

4. DARCIE, F. ; SAMPAIO, R. C. B. ; ANDRADE, K. O. ; HERNANDES, A. C. ; BECKER, M. . "*Detecção de Vagas Livres para Manobra de Estacionamento Paralelo Autônomo Utilizando Sensor Laser em Veículos de Passeio*" - In: CONEM 2012 - Congresso Nacional de Engenharia Mecânica, 2012, São Luiz - MA. Anais do CONEM 2012. Rio de Janeiro : ABCM, 2012. v. 1. p. 1-10.

5. ANDRADE, K. O. ; HERNANDES, A. C. ; BECKER, M. . "*Simulação de um Controlador Neural para o Estacionamento Paralelo de um Robô Móvel*" - In: CONEM 2012 - Congresso Nacional de Engenharia Mecânica, 2012, São Luiz - MA. Anais do CONEM 2012. Rio de Janeiro : ABCM, 2012. v. 1. p. 1-10.

6. JUNIOR, L. H. D. R.; HERNANDES, A. C. ; BECKER, M. . "*Sistema Embarcado de Navegação Autônoma - Detecção de Vias Navegáveis Utilizando Crescimento de Regiões*

e Algoritmos Genéticos" - In: Congresso Brasileiro de Automática - CBA 2012, 2012, Campina Grande/PB. Anais do Congresso Brasileiro de Automática - CBA 2012, 2012.

7. NUNES, R. F.; HERNANDES, A. C. ; BECKER, M. . "*Detecção de Faixas com Câmera Monocular e Otimização Através de Algoritmo Genético*" - In: Congresso Brasileiro de Automática - CBA 2012, 2012, Campina Grande/PB. Anais do Congresso Brasileiro de Automática - CBA 2012, 2012.

8. SAMPAIO, R. C. B. ; BECKER, M. ; FERNANDES, V. ; LIMA, G. S. ; HERNANDES, A. C. . "*Parametric Vehicular Simulator on the Design and the Evaluation of HELVIS mini-HEV*" - In: ASME 2011 International Design Engineering Technical Conferences (IDETC) and Computers and Information in Engineering Conference (CIE), 2011, Washington, DC - USA. Proceedings of the ASME 2011 International Design Engineering Technical Conferences (IDETC) and Computers and Information in Engineering Conference (CIE), 2011.

9. ANDRADE, K. O. ; HERNANDES, A. C. ; BECKER, M. . "*A rule-based controller simulation for an autonomous parallel parking of a car-like robot*" - In: COBEM 2011 - 21st International Congress of Mechanical Engineering, 2011, Natal, RN. Proc. of COBEM 2011. Rio de Janeiro : ABCM, 2011. v. 1. p. 1-10.

10. ARAUJO, R. L. C. ; LACERDA, V. M. ; HERNANDES, A. C. ; MENDONCA, A. S. B. ; BECKER, M. . "*Classificação de pedestres usando câmera e sensor LIDAR*" - In: SBAI 2011 - Simpósio Brasileiro de Automação Inteligente, 2011, São João del Rei - MG. Anais do SBAI 2011. São Paulo : SBA, 2011. v. 1. p. 1-6.

11. HERNANDES, A. C. ; MENDONCA, A. S. B. ; ANDRADE, K. O. ; BECKER, M. . "*Redes neurais artificiais aplicadas à baliza paralela de veículo de passeio em ambiente simulado - CON10-0425*" - In: CONEM 2010 - Congresso Nacional de Engenharia Mecânica, 2010, Campina Grande - PB. Anais do CONEM 2010. Rio de Janeiro : ABCM, 2010. v. 1. p. 1-10.

Lista de Figuras

1.1 Estimativa anual do fornecimento mundial de robôs industriais (adaptado de IFR (2011)). 2

1.2 Figura com os veículos autônomos participantes do *DARPA Grand Challenge* e *DARPA Urban Challenge* 7

1.3 Carro autônomo desenvolvido pela Google (ACKERMAN , 2010) 8

1.4 Carros Autônomos na Europa. Em (a), o veículo desenvolvido pela Oxford (OXFORD , 2011). Em (b), o veículo desenvolvido pela IFSTTAR (GUIZZO , 2012). Em (c), o veículo desenvolvido pela Freie Universität Berlin (REUSCHENBACH et al. , 2011). Em (d), o veículo desenvolvido pela Universidade de Parma (BERTOZZI et al. , 2011). 8

1.5 Carro Autônomo Desenvolvido na Universidade Federal de Minas Gerais (LIMA , 2010) 9

1.6 Carros Autônomos desenvolvidos no ICMC LRM (2011) 9

1.7 Sistema Embarcado de Navegação Autônoma - plataforma GISA (SENA , 2012). (a) Antigo arranjo dos sensores da plataforma GISA. (b) Novo arranjo dos sensores da plataforma GISA 10

2.1 Exemplo da fusão temporal apresentada por BECKER E SIMON (2000). A linha tracejada indica o tempo de aquisição dos sensores e programas, as setas com indicador K indicam o período de tempo no qual o filtro de Kalman fará a fusão temporal. 14

2.2 Detalhe do Mapa do Campus 1 da USP São Carlos. Janela em destaque mostra as informações de distância inerentes ao mapa. 15

2.3 Detalhe do Mapa do Campus 1 da USP São Carlos. Em destaque as placas de PARE presente nos cruzamentos. 15

2.4 Casos factíveis de ocorrerem em cenário de uma via, onde o *FIAT STILO* representa o veículo autônomo. (a)Veículo autônomo seguindo um carro com velocidade variável. (b) Veículo autônomo passando ao lado de outro carro com velocidade variável. (c) Veículo Autônomo sem a presença de carros. (d) Ambiente de tráfego pesado. 18

2.5 Casos factíveis de ocorrerem em cenário com duas vias em Junção perpendicular ou em T. O *FIAT STILO* representa o veículo autônomo. (a) Sem a presença de veículos. (b)Veículo à esquerda com 3 velocidades distintas e 2 comportamentos. (c) Veículo à direita com 3 velocidades distintas e 2 comportamentos. (d) a (g) Dois Veículos, cada qual com 3 velocidades distintas e um comportamento. . . . 19

2.6 Casos estudados nessa dissertação, onde o *FIAT STILO* representa o veículo autônomo. (a)Cenário na qual o veículo autônomo deve começar a frenagem devido a um entroncamento, com um veículo mais lento a frente. (b) Cenário na qual o veículo autônomo deve virar a esquerda, com 2 veículos no entroncamento, ambos andando em linha reta. Este cenário conta com 4 variações de *gap*. O primeiro caso traz dois *gaps* que não permitem o carro autônomo entrar na intersecção antes que os outros carros ultrapassem, enquanto o segundo e o terceiro apresentam pelo menos um dos carros com *gap* grande enquanto o outro tem um *gap* justo. Por fim, o último caso terá *gaps* grandes. 20

3.1 Experimento realizado com o veículo de testes. (a) Imagem coletada. (b) Imagem após mudar o espaço de cores RGB para escala de cinza 28

3.2 Resultado adquirido após o uso do algoritmo de detecção de borda de Canny . . 28

3.3 Cenário de rua nos diferentes espaços de cores. (a) RGB.(b) HSV. (c) Componentes H e S. (d) Componente V. 30

3.4 Resultado obtido após o uso do algoritmo de crescimento de região 31

3.5 Visualização dos dados produzidos pelo Velodyne. Adaptado de MONTEMERLO et al. (2008). (a) Visualização em 3 dimensões.(b) Projeção no plano de movimento. 32

3.6 Aplicação do algoritmo PDBS em um dado de sensor LIDAR. (a) Segmentação via o PDBS, asteriscos azuis representam o dado coletado, marcadores triangulares vermelhos indicam o centro esperado do objeto, enquanto as elipses pretas indicam a variância dos dados.(b) Visualização da cena capturada pelo sensor LIDAR. . . 34

3.7 Resultado adquirido com a fusão entre as informações do LIDAR e da câmera . . 34

4.1 Detalhe do mapa híbrido de uma região do campus 1 da USP - São Carlos próxima ao Departamento de Engenharia Mecânica. 36

4.2 Exemplo de mapa métrico local. 36

4.3 Aplicação do algoritmo IPM. (a) Imagem segmentada pelo detector de bordas de canny.(b) Imagem após o Mapeamento Inverso da Perspectiva (IPM). 38

4.4 Assinatura horizontal da figura 4.3(b) 38

4.5 Aplicação do algoritmo IPM. (a) Imagem segmentada pelo crescimento de regiões. Em (b) tem-se a imagem após o Mapeamento Inverso da Perspectiva (IPM). . . . 39

4.6 Método para tratar os movimentos entre obstáculos. Adaptado de WERLING et al. (2008). (a) Cruzamento e seu modelo.(b) Modelo genérico para tratar o movimento entre objetos dinâmicos 42

5.1 Exemplo de uma Rede Bayesiana. Estrutura DAG e suas respectivas CPTs. Adaptado de DARWICHE (2009). 46

5.2 Exemplo de uma Rede Bayesiana Dinâmica. Adaptado de RUSSEL E NORVIG (2010) 48

5.3 Interface com o usuário do *software* Netica™. Na figura vê-se um exemplo de Rede Bayesiana 52

5.4 Interface com o usuário do *software* Netica™. Na figura, o uso de evidências para realizar a inferência da Rede Bayesiana 52

5.5 Simulador desenvolvido em C# 54

5.6 Detalhe da Rede Bayesiana correspondente a camada de percepção. (a) Variável escondida P e seus observadores L e G.(b) Variável escondida C e seus observadores V e I. 55

5.7 Detalhe da Rede Bayesiana correspondente a situação na qual o carro autônomo se encontra. 56

5.8 Mapa utilizado como fundo verdade para a variável S 57

5.9 Máquina de Estados Finitos desenvolvida para possibilitar a criação dos dados de treinamento da CPT da variável S 58

5.10 Detalhe da Rede Bayesiana correspondente ao comportamento do veículo. 58

5.11 Rede Bayesiana desenvolvida 59

5.12 Filtro Sequencial proposto para o nó B. 60

5.13 Filtro de Segunda Ordem proposto para o nó B. 62

5.14 Cenário desenvolvido para o teste preliminar das 3 Redes propostas 65

6.1 Repetição da figura 2.6 com os casos estudados nessa dissertação. (a)Cenário na qual o veículo autônomo deve começar a frenagem devido a um entroncamento, com um veículo mais lento a frente. (b) Cenário na qual o veículo autônomo deve virar a esquerda, com 2 veículos no entroncamento, ambos andando em linha reta. Este cenário conta com 4 variações de *gap*. O primeiro caso traz dois *gaps* que não permitem o carro autônomo entrar na intersecção antes que os outros carros ultrapassem, enquanto o segundo e o terceiro apresentam pelo menos um dos carros com *gap* grande enquanto o outro tem um *gap* justo. Por fim, o último caso terá *gaps* grandes. 67

6.2 Parâmetros usados no teste do caso de frenagem com o obstáculo à frente. 70

6.3 Modelo adotado de colisão para o caso estudado. 71

6.4 Gráfico resultante do teste $F_\Phi F_\Phi F_\Phi F_\Phi \Phi\Phi$ para o caso 1. Em destaque os comportamentos resultantes da Rede Bayesiana 74

6.5 Gráfico resultante do teste $F_\Phi F_\Phi F_\Phi F_\Phi \Phi\Phi$ para o caso 1. Em destaque o resultado da classificação do nó de Situação Dinâmica D da Rede Bayesiana 75

6.6 Gráfico resultante do teste $F_\Phi F_\Phi F_\Phi F_\Phi \Phi\Phi$ para o caso 1. 76

6.7 Gráfico resultante do teste $F_\Phi F_\Phi F_\Phi F_\Phi \Phi\Phi$ para o caso 1. 77

6.8 Gráfico resultante dos testes de desempenho médio para os níveis de ruído Acerto Ideal, Acerto Alto e Acerto Baixo. A comparação foi realizada com o comportamento WT (*Espere sua Vez*) e as médias calculadas quando esse comportamento foi selecionado pelo teste $F_\Phi F_\Phi F_\Phi F_\Phi \Phi\Phi$. 78

6.9 Gráfico resultante dos testes com as redes de Acerto Ideal, Acerto Alto e Acerto Baixo. 79

6.10 Gráfico resultante dos testes com as redes de Acerto Ideal, Acerto Alto e Acerto Baixo. 80

6.11 Gráfico resultante dos testes com as redes rfF, rFf, rff e rFF. 82

6.12 Comportamentos gerados pelas médias das redes. (a) redes rfF e rFF.(b) redes rFf e rff. 83

6.13 Comportamentos gerados pelas médias das redes. (a) redes rfF e rFF.(b) redes rFf e rff. Detalhe ao pico próximo ao tempo $t = 3$ s 84

6.14 Gráfico resultante da distância ao veículo B para os 24 testes realizados 85

6.15 Parâmetros usados no teste do caso de tomada de decisão em um entroncamento em T. 87

6.16 Modelo adotado de colisão para o caso estudado. 88

6.17 Caso 1, A e B com *gaps* 0 e 1 s, respectivamente. (a) Velocidade SENA e distância a A e B. (b) Comportamento Resultante da Rede Bayesiana. 91

6.18 Análise das probabilidades durante o caso 1 com o sub-caso *erro baixo* (a) Análise entre $0,5$ s e 1 s para as probabilidades P(KG) e P(WT). (b) Análise entre 4 s e 5 s para as probabilidades P(WT) e P(LT). 92

6.19 Caso 2, A e B com *gaps* 0 e 6 s, respectivamente. (a) Velocidade SENA e distância a A e B. (b) Comportamento Resultante da Rede Bayesiana. 93

6.20 Caso 2, A e B com *gaps* 5 e 0 s, respectivamente. (a) Velocidade SENA e distância a A e B. (b) Comportamento Resultante da Rede Bayesiana. 94

6.21 Caso 2, A e B com *gaps* 4 e 5 s, respectivamente. (a) Velocidade SENA e distância a A e B. (b) Comportamento Resultante da Rede Bayesiana. 95

6.22 Caso - Cruzamento em T com dois veículos na via principal (a) Comportamentos do caso 1 para os sub-casos *erro baixo* e o *erro na localização* (b) Comportamentos do caso 2 para os sub-casos *erro baixo* e o *erro na localização.* (c) Comportamentos do caso 3 para os sub-casos *erro baixo* e o *erro na localização.* (d) Comportamentos do caso 4 para os sub-casos *erro baixo* e o *erro na localização* 96

6.23 Caso - Cruzamento em T com dois veículos na via principal (a) Comportamentos do caso 1 para os sub-casos *erro baixo* e o *erro no rastreamento* (b) Comportamentos do caso 2 para os sub-casos *erro baixo* e o *erro no rastreamento.* (c) Comportamentos do caso 3 para os sub-casos *erro baixo* e o *erro no rastreamento.* (d) Comportamentos do caso 4 para os sub-casos *erro baixo* e o *erro no rastreamento* 97

6.24 Caso - Cruzamento em T com dois veículos na via principal (a) Comportamentos do caso 1 para os sub-casos *erro baixo* e o *erro em ambos* (b) Comportamentos do caso 2 para os sub-casos *erro baixo* e o *erro em ambos.* (c) Comportamentos do caso 3 para os sub-casos *erro baixo* e o *erro em ambos.* (d) Comportamentos do caso 4 para os sub-casos *erro baixo* e o *erro em ambos* 98

A.1 Vista geral do problema 111

A.2 Mapa para os carros com foco semi-autônomo 112

A.3 Mapa para os carros com foco autônomo 113

A.4 Mapa dos desafios a serem cumpridos por veículos inteligentes 114

B.1 Mapa Campus 1 da USP São Carlos 116

D.1 Velocidade do Veículo Autônomo e distância aos outros carros para o caso 1 e sub-caso *erro na localização.* 130

D.2 Velocidade do Veículo Autônomo e distância aos outros carros para o caso 1 e sub-caso *erro no rastreamento.* 130

D.3 Velocidade do Veículo Autônomo e distância aos outros carros para o caso 1 e sub-caso *erro em ambos.* 131

D.4 Velocidade do Veículo Autônomo e distância aos outros carros para o caso 2 e sub-caso *erro na localização.* 131

D.5 Velocidade do Veículo Autônomo e distância aos outros carros para o caso 2 e sub-caso *erro no rastreamento*. 132

D.6 Velocidade do Veículo Autônomo e distância aos outros carros para o caso 2 e sub-caso *erro em ambos*. 132

D.7 Velocidade do Veículo Autônomo e distância aos outros carros para o caso 3 e sub-caso *erro na localização*. 133

D.8 Velocidade do Veículo Autônomo e distância aos outros carros para o caso 3 e sub-caso *erro no rastreamento*. 133

D.9 Velocidade do Veículo Autônomo e distância aos outros carros para o caso 3 e sub-caso *erro em ambos*. 134

D.10 Velocidade do Veículo Autônomo e distância aos outros carros para o caso 4 e sub-caso *erro na localização*. 134

D.11 Velocidade do Veículo Autônomo e distância aos outros carros para o caso 4 e sub-caso *erro no rastreamento*. 135

D.12 Velocidade do Veículo Autônomo e distância aos outros carros para o caso 4 e sub-caso *erro em ambos*. 135

Lista de Tabelas

1.1 Mortes em acidentes de trânsito ocorridas em 2007 3

1.2 Lista dos sensores presentes na GISA e suas taxas de envio de dados 11

2.1 Legenda das siglas utilizadas 21

2.2 Testes da rede para o caso apresentado na figura 2.6(a) 22

2.3 Testes da rede para o caso apresentado na figura 2.6(b) 23

4.1 Momentos centrais normalizados de segunda ordem calculados para os modelos de vias utilizados na dissertação 41

4.2 Momentos centrais normalizados de segunda ordem calculados para os modelos de vias da dissertação com os ranges definidos 41

4.3 Sumário dos classificadores utilizados nessa dissertação 43

5.1 Tabela emulando uma lista de casos possíveis que servirão de dados de entrada para o aprendizado da Rede Bayesiana. Adaptado de DARWICHE (2009). . . . 47

5.2 Tabela comparativa dos trabalhos relacionados 51

5.3 CPT da Variável L dado P 56

5.4 CPT da variável B. 59

5.5 Modelo de Transição da Variável P, tal que $p(P_k|P_{k-1})$ 60

5.6 Modelo de Transição da Variável C, tal que $p(C_k|C_{k-1})$ 60

5.7 Relação entre os comportamentos de B. 61

5.8 Matriz de confusão para a variável L considerada como classificador FORTE . . 62

5.9 Matriz de confusão para a variável G considerada como classificador FORTE . . 62

5.10 Matriz de confusão para a variável V considerada como classificador FORTE . . 63

5.11 Matriz de confusão para a variável I considerada como classificador FORTE . . . 63

5.12 Matriz de confusão para a variável L considerada como classificador FRACA . . 63

5.13 Matriz de confusão para a variável G considerada como classificador FRACA . . 63

5.14 Matriz de confusão para a variável V considerada como classificador FRACA . . 63

5.15 Matriz de confusão para a variável I considerada como classificador FRACA . . . 63

5.16 Valor de *pHit* para cada nível de influência do ruído na classificação 64

5.17 Resultados preliminares obtidos com o teste no cenário da Figura 5.14 65

6.1 Lista dos parâmetros utilizados no Caso 1: Frenagem com Obstáculo à frente . . 70

6.2 Lista dos parâmetros utilizados no Caso - Frenagem com Obstáculo à frente . . . 70

6.3 Repetição da Tabela 2.2 com os testes da rede para o caso apresentado na figura 2.6(a) 73

6.4 Probabilidades preliminares dos comportamentos das redes Acerto Ideal, Acerto Alto e Acerto Baixo 77

6.5 Probabilidades preliminares dos comportamentos das redes rfF, rFf, rff e rFF . . 81

6.6 Repetição da Tabela 2.3 com os testes da rede para o caso apresentado na figura 2.6(b) 86

6.7 Lista dos parâmetros utilizados nos Casos estudados e a distinção entre os sub-casos *erro baixo*, *erro na localização*, *erro no Acompanhamento* e *erro em ambos* 86

6.8 Lista dos parâmetros utilizados no Caso - Cruzamento em T com dois veículos na via principal 87

6.9 Análise visual do comportamento do carro autônomo para os casos testados . . . 99

C.1 CPT da variável B. Parte 1 117

C.2 CPT da variável B. Parte 2 118

C.3 CPT da variável B. Parte 3 119

C.4 CPT da variável B. Parte 4 120

C.5 CPT da variável B. Parte 5 121

C.6 CPT da variável B. Parte 6 122

C.7 CPT da variável B. Parte 7 123

C.8 CPT da variável B. Parte 8 124

C.9 CPT da variável B. Parte 9 125

C.10 CPT da variável B. Parte 10 126

C.11 CPT da variável B. Parte 11 127

C.12 CPT da variável B. Parte 12 128

Lista de Abreviaturas e Siglas

Termo	*Descrição*
ACC	*Active Cruise Control*
ADAS	*Advanced Driver Assistance Systems*
AEB	*Automatic Emergency Braking*
ANFAVEA	Associação Nacional dos Fabricantes de Veículos Automotores
ASCI	*Advanced Strategic Computing Initiative*
BOF	*Bayesian Occupancy Filter*
CADU	Carro Autônomo Desenvolvido na Univesidade Federal de Minas Gerais
CARINA	Carro Robótico Inteligente para Navegação Autônoma
C-ELROB	*Civilian* ELROB
CPT	*Conditional Probability Table*
DAG	*Direct Acyclic Graph*
DARPA	*Defense Advanced Research Projects Agency*
DBN	*Dynamic Bayesian Network*
DENATRAN	Departamento Nacional de Transito
EESC	Escola de Engenharia de São Carlos
ELROB	*European Land Robot Trials*
EPFL	*École Polytechinique Fédérale de Lausanne*
ESIGELEC	*École supérieure d'ingénieurs en génie électrique*
FCTA	*Fast Clustering and Tracking Algorithm*
FSM	*Finite State Machine*
GIS	*Geographic Information System*

Termo	*Descrição*
GPS	*Global Positioning System*
GPU	*Graphics Processing Unit*
HMM	*Hidden Markov Models*
HSV	*Hue-Saturation-Value*
ICMC	Instituto de Ciências Matemáticas e Computação
IFR	*International Federation of Robotics*
IFSTTAR	*Institut français des sciences et technologies des transports, de l'aménagement et des réseaux*
IMU	*Inertial Measument Unit*
IPM	*Inverse Perspective Mapping*
LIDAR	*Light Detection And Ranging*
LKS	*Lane Keeping System*
M-ELROB	*Military* ELROB
OMS	Organização mundial de saúde
PCR	*Pre-Crash Protection*
PDBS	*Point-Distance Based Segmentation*
RGB	*Red-Green-Blue*
RTK-GPS	*Real Time Kinematic Global Position System*
SENA	Sistema Embarcado de navegação Autônoma
SmartTer	*Smart all Terrain*
UFMG	Universidade Federal de Minas Gerais
USP	Universidade de São Paulo

Lista de Símbolos

Símbolo	*Descrição*	*Unidade*
w_j	j-ésima classe a ser classificada	-
$[a_1, a_2, a_3]^T$	vetor de características genérico	-
$p(w_j \| a_1, a_2, a_3)$	Probabilidade a posteriori da classe w_j	-
$p(a_1, a_2, a_3 \| w_j)$	Verossimilhança da calsse w_j	-
$p(w_j)$	Probabilidade a priori	-
$p(a_1, a_2, a_3)$	probabilidade da evidência	-
F	Classificador forte - altamente discriminante	-
f	Classificador fraco - pouco discriminante	-
Φ	Acerto ideal dos classificadores	-
Pq	Acerto alto dos classificadores	-
GD	Acerto baixo dos classificadores	-
$f(x, y)$	imagem binária	-
m_{00}	área	-
$\bar{x}$	Posição do X do CG	-
$\bar{y}$	Posição do Y do CG	-
m_{10}	coordenada X do CG não normalizada	-
m_{01}	coordenada Y do CG não normalizada	-
m_{11}	produto de inércia	-
m_{20}	momento de inercia de área de x	-
m_{02}	momento de inercia de área de y	-
μ_{20}	momento de inercia de área centrado em x	-
μ_{02}	momento de inercia de área centrado em y	-
μ_{11}	produto de inercia no CG	-

Símbolo	*Descrição*	*Unidade*
η_{pq}	momento normalizado de ordem (p+q)	-
μ_{pq}	momento de inercia de área centrado de ordem (p+q)	-
γ	normalizador	-
x	posicao x do veículo no vetor de estimação	[m]
$\dot{x}$	velocidade x do veículo no vetor de estimação	[m/s]
y	posicao y do veículo no vetor de estimação	[m]
$\dot{y}$	velocidade y do veículo no vetor de estimação	[m/s]
z	posicao z do veículo no vetor de estimação	[m]
$\dot{z}$	velocidade z do veículo no vetor de estimação	[m/s]
θ	ângulo de rolagem do veículo no vetor de estimação	[rad]
$\dot{\theta}$	velocidade de rolagem do veículo no vetor de estimação	[rad/s]
ϕ	ângulo de guinada do veículo no vetor de estimação	[rad]
$\dot{\phi}$	velocidade de guinada do veículo no vetor de estimação	[rad/s]
ψ	ângulo de arfagem do veículo no vetor de estimação	[rad]
$\dot{\psi}$	velocidade de arfagem do veículo no vetor de estimação	[rad/s]

Sumário

Resumo **xi**

Abstract **xiii**

Publicações **xv**

Lista de Figuras **xvii**

Lista de Tabelas **xxv**

Lista de Abreviaturas e Siglas **xxix**

Lista de Símbolos **xxxi**

1 Introdução **1**

1.1 Motivação 1

1.1.1 Segurança 3

1.2 Sistemas Avançados de Auxílio ao Motorista 5

1.2.1 Tecnologias ADAS 5

1.2.2 Carros Autônomos 6

1.2.3 Projeto SENA 10

1.3 Objetivo 11

1.4 Estrutura e Organização do Trabalho 12

2 Formulação do Problema **13**

2.1 Definições e Restrições 13

2.2 Hipóteses Simplificadoras 16

2.3 Casos Estudados 16

2.4 Considerações Finais 23

3 Módulo de Percepção **25**

3.1 Estimação do Estado Interno 25
3.2 Detecção de Sinalização Horizontal 27
3.3 Detecção de Vias Transitáveis 29
3.4 Detecção de Obstáculos 32
3.4.1 Detecção de Pedestres 33
3.5 Considerações Finais 34

4 Módulo de Representação 35
4.1 Classificadores 35
4.1.1 Estimação do Estado Interno e Localização 35
4.1.2 Detecção de Sinalização Horizontal 37
4.1.3 Detecção de Vias Transitáveis 39
4.1.4 Detecção de Obstáculos e Pedestres 42
4.2 Considerações Finais 43

5 Módulo de Cognição 45
5.1 Revisão Teórica 45
5.2 Netica 51
5.3 Simulador em C# 53
5.4 Modelagem da Rede Bayesiana 55
5.5 Testes Preliminares 62

6 Parte Experimental 67
6.1 Comportamentos Simulados 68
6.2 Caso - Frenagem com Obstáculo à Frente 69
6.3 Caso - Cruzamento em T com dois veículos na via principal 85
6.4 Considerações Finais 99

7 Conclusões & Trabalhos Futuros 101

A Mapa conceitual de Veículos inteligentes 111

B Mapa do Campus 1 da USP São Carlos 115

C CPT do Filtro de Segunda Ordem 117

D Comportamentos do Carro Autônomo para o Caso - Cruzamento em T com dois veículos na via principal 129

Capítulo 1

Introdução

1.1 Motivação

Quando Karel Čapek introduziu o termo "Robô" ao mundo pela primeira vez, em 1920, poucas pessoas poderiam imaginar a extensão que esta ideia teria no século XXI, cobrindo áreas que vão desde a automação de indústrias até a medicina, meio ambiente e robôs imersos em nossa sociedade. Por meados de 1940, a robótica migrou da ficção para o mundo real com William Grey Walter e o primeiro robô móvel e Ray Goertz com um manipulador remotamente controlado para manusear materiais radioativos (KUMAR , 2010). Segundo DIETSCH (2010), os robôs móveis já passaram da época na qual eram considerados novidade e muitas vezes temidos, para máquinas presentes na vida cotidiana, com aceitação cada vez maior da sociedade.

Pode-se analisar essa aceitação em números divulgados ao longo dos últimos anos. Dentro do âmbito de robôs móveis, houve um aumento em 4% nas vendas de robôs de serviço profissional entre o período de 2009 a 2010, totalizando 13.741 unidades, enquanto que para robôs de uso pessoal ou domésticos houve um aumento de 35% no mesmo período, representando 2,2 milhões de unidades vendidas (IFR , 2011).

Entretanto, esse sucesso não se restringe apenas aos robôs móveis. Os robôs industriais, nos últimos anos, vem mostrando um grau de maturação em suas vendas. Em termos quantitativos, o gráfico da figura 1.1 mostra a evolução do fornecimento de robôs industriais no cenário mundial (IFR , 2011).

Desconsiderando o ano de 2009, ano da crise financeira mundial (IFR , 2011), desde 2005 a demanda por robôs industriais vem se mantendo em um patamar estável, demonstrando o

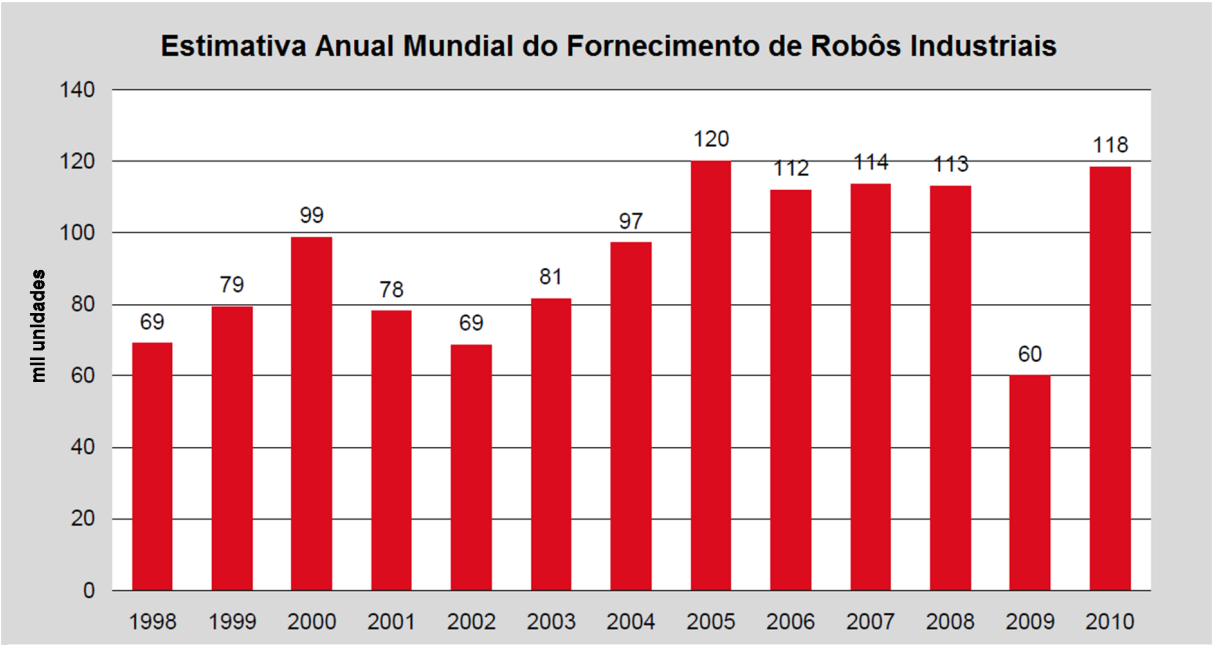

Figura 1.1: Estimativa anual do fornecimento mundial de robôs industriais (adaptado de IFR (2011)).

grau de maturação das indústrias em relação a robótica. Segundo a *International Federation of Robotics* (IFR), grande parte da recuperação entre 2009 e 2010 das vendas de robôs se deve às indústrias automotivas e, para o período de 2012 a 2014, as perspectivas otimistas são de um crescimento médio nas vendas de robôs de 6% ao ano (IFR , 2011).

Toda essa conquista da área da robótica durante os últimos anos deve-se, em parte, aos avanços na área de eletrônica. Um bom exemplo pode ser encontrado em KOGGE (2011), onde este realiza uma comparação entre o supercomputador ASCI Red (acrônimo para *Advanced Strategic Computing Initiative*) desenvolvido em 1997 e o vídeo-game *Playstation 3* ® datado de 2006. Ambos possuem um pico de desempenho de 1,8 *teraflops* ($1,8$ x 10^{12} operações matemáticas por segundo), entretanto o primeiro ocupa um espaço de 150 m^2 e consome 800 kW enquanto o segundo ocupa $0,08$ m^2 e consome menos de 200 W mostrando a notável miniaturização e crescimento da eficácia dos componentes eletrônicos em 9 anos, os quais permitiram flexibilizar os campos de atuação da robótica e inseri-los cada vez mais na sociedade.

Dentro da robótica, a área que se encontra em maior expansão é a de robôs de serviços pessoais ou domésticos, mesmo que estes não representem a maior parte do dinheiro adquirido pelas vendas (IFR , 2011). As projeções de vendas dessa categoria são de $14,4$ milhões de unidades até 2014 e, dentro desse ramo, os robôs de transporte pessoal passarão a ter maior importância. Dentro desse último grupo, podem ser citados os carros autônomos como o táxi

conceito desenvolvido na Alemanha (AUTONOMOSLABS , 2010).

1.1.1 Segurança

Essa última tendência pode ser interpretada como uma busca para solucionar o que foi considerado pela OMS (Organização Mundial de Saúde) como um problema mundial de saúde pública (OMS , 2009): mortes em acidentes de trânsito. Esta foi considerada a nona maior causa de morte no mundo ($1,3$ milhões de pessoas por ano) pela própria entidade e, desde maio de 2011, foi lançada a década de ação pelo trânsito seguro (2011 - 2020) com a finalidade de prevenir tais acidentes (ONUBR , 2011).

Essa preocupação é justificada com uma análise dos dados coletados pela OMS. Segundo a organização, 62% das mortes relatadas em acidentes de trânsito ocorrem em 10 países: África do Sul, Brasil, China, Egito, Estados Unidos, Índia, Indonésia, Irã, México e Rússia (OMS , 2009). A tabela 1.1 apresenta os dados comparativos entre eles.

Tabela 1.1: Mortes em acidentes de trânsito ocorridas em 2007

País	**Número absoluto de Fatalidades**	**Número de Fatalidades a cada 100.000 habitantes**
África do Sul	16.113	$33,2$
Brasil	35.155	$18,3$
China	89.455	$16,5$
Egito	15.983	$41,6$
Estados Unidos	42.642	$13,9$
Índia	105.725	$16,8$
Indonésia	16.548	$16,2$
Irã	22.918	$35,8$
México	22.108	$20,7$
Rússia	35.972	$25,2$

Pode-se observar um alto valor de óbitos tanto em números absolutos como também se for analisada a taxa de mortes por 100.000 habitantes. Dentre todas as razões para um acidente de trânsito ocorrer, mesmo que não-fatal pode-se citar (ALVES , 2011):

- Excesso de velocidade
- Fadiga ou Sono
- Uso de álcool ou drogas
- Má formação de condutores

- Imperícia
- Negligência
- Imprudência
- Desrespeito à sinalização
- Manutenção precária das vias
- Pistas impróprias para trânsito
- Falta de fiscalização e Vistoria

Percebe-se que cada país poderá ter deficiência em um ou mais quesitos dos acima apresentados. Além disso, deve-se frisar que alguns motivos devem-se ao motorista por si só e outros já são problemas inerentes à infraestrutura do país analisado, como a manutenção de vias e a realização de fiscalizações. Ainda há outro agravante, o aumento no número de carros circulando nas vias.

Em âmbito nacional, a frota de automóveis em 2010, segundo a ANFAVEA (Associação Nacional dos Fabricantes de Veículos Automotores) era de 32.064.950 (ANFAVEA , 2011). Já em dezembro de 2011, segundo o DENATRAN (Departamento Nacional de Trânsito), o número de veículos era de 70.543.535, dos quais 39.832.919 são automóveis (DENATRAN , 2011), representando um crescimento de 24,2 %.

O aumento no número de carros, aliado às causas de acidentes de trânsito, como a imprudência ou negligência, justificam os altos números de óbitos no Brasil, sendo responsáveis pela participação do mesmo entre os 10 países com mais mortes em acidentes de trânsito. Uma solução que pode ser adotada é a instalação de sistemas avançados de auxílio ao motorista ou *Advanced Driver-Assistance Systems* (ADAS). Tais sistemas buscam ajudar o motorista realizando tarefas como monitorar objetos em pontos cegos, manter uma distância segura ao carro à frente ou avisar se o veículo está mudando de pista (KOWALENKO , 2010). Desta forma, ADAS podem representar uma ferramenta importante para atender ao projeto da OMS: a década de ação pelo trânsito seguro.

1.2 Sistemas Avançados de Auxílio ao Motorista

1.2.1 Tecnologias ADAS

Atualmente, as tecnologias de auxílio ao motorista começam a entrar no mercado automobilístico, inicialmente como opcionais em carros de luxo e, em um futuro próximo, como um equipamento padrão nos veículos (KOWALENKO , 2010). Dentre as tecnologias ADAS já disponíveis no mercado, pode-se citar como exemplo:

- Controle Ativo de Cruzeiro ou *Active Cruise Control*(ACC): O Controle Ativo de Cruzeiro usa as informações de um sensor de distância, radar por exemplo, e calcula a distância ao veículo frontal. Se essa estiver abaixo de um valor de segurança, o ACC pode avisar o motorista ou simplesmente começar uma manobra de frenagem, como exemplo o ACC presente no Audi A8 2010 (STEVENSON , 2011).

- Sistema de Permanência na Pista ou *Lane Keeping Systems* (LKS): O sistema de Permanência de Pista utiliza as informações de uma câmera para encontrar as faixas limitantes da pista de rolagem e a posição do carro em relação a essas faixas. Caso o veículo comece a sair da pista sem indicar a intenção de deixá-la, o sistema informa o motorista de tal manobra. Um exemplo pode ser encontrado no Ford Fusion modelo de 2013 (FORD , 2011).

- Frenagem Automática de Emergência ou *Automatic Emergency Braking* (AEB): A Frenagem Automática de Emergência utiliza as informações de radares e quando a distância até um certo veículo entra dentro de um limiar de segurança, o sistema ativa os freios com ou sem o consentimento do motorista, visando evitar a possível colisão ou, se não for possível, reduzir os danos de tal acidente. A empresa TRW disponibiliza um módulo desse sistema para ser embarcado em veículos, entretanto esses não estão disponíveis no mercado latino americano (TRW , 2011).

- Proteção Pré-Colisão ou *Pre-Crash Protection* (PCP): O sistema de Proteção Pré-Colisão utiliza radares para determinar a distância ao veículo frontal e, caso a distância seja menor a que uma distância de segurança, o sistema prepara o ambiente interno do carro para diminuir os danos aos seus ocupantes. A empresa TRW disponibiliza um módulo para ser incorporado aos veículos, porém não está disponível para o mercado latino americano (TRW , 2011).

1.2.2 Carros Autônomos

As tecnologias ADAS são perfeitamente capazes de perceber o ambiente, processar as informações adquiridas e mostrar ao motorista alertas sobre o ambiente ou avisá-lo como deve proceder em situações específicas, entretanto, cada módulo age de forma independente e a atuação em sua maioria depende do motorista. Os carros autônomos, em contra-partida, devem executar as funcionalidades de um motorista por completo, ou seja, perceber seu ambiente, tomar a decisão adequada e agir sobre o carro, para os mais diversos tipos de cenário.

Esse tipo de robô de transporte pessoal começou a ganhar visibilidade quando em 2003 a agência DARPA (*Defense Advanced Research Projects Agency*) propôs uma competição na qual um carro autônomo deveria percorrer um percurso em terrenos *off-road*. A competição *DARPA Grand Challenge* em sua primeira edição em 2004 não teve vencedores, entretanto em sua segunda edição, em 2005, o carro da Universidade de Stanford, apelidado de Stanley (Figura 1.2(a)), levou o prêmio de U$ 2 milhões. Para ser o vencedor, Stanley precisava navegar um circuito de 280 *km* no deserto de Mojave nos EUA, feito conseguido usando 5 sensores laser da SICK LMS 291, uma câmera, antena de GPS (*Global Positioning System*), uma IMU (*Inertial Measurement Unit*) dentro do carro e dois radares para realizar a percepção do ambiente (THRUN et al. , 2006).

Em 2007, a DARPA realizou o *DARPA Urban Challenge*, no qual os veículos deveriam navegar em um cenário simulado de trânsito. A Universidade de Stanford participou novamente, dessa vez com o carro apelidado de Junior (Figura 1.2(b)). Usando dessa vez 8 sensores LIDAR (*Light Detection And Ranging*) de diversos modelos (2 SICK LMS 291, 1 REIGL LMS Q 120, 2 SICK LDLRS, 2 ibeo ALASCA XT e 1 Velodyne HDL - 64E), uma antena GPS, um sensor inercial e cinco radares, Junior chegou em segundo lugar na competição (MONTEMERLO et al. , 2008), atrás do carro da Carnegie Mellon (figura 1.2(c)), Boss (BAKER E DOLAN , 2009).

Outra importante competição de veículos autônomos também pode ser citada, como o EL-ROB (*European Robot Trial*) realizada na Europa anualmente (sendo M-ELROB nos anos pares a partir de 2006, e C-ELROB nos anos impares a partir de 2007). No M-ELROB de 2006, foi apresentado o *SmartTer* (*Smart all Terrain*) da EPFL (*École Polytechnique Fédérale de Lausanne*), um veículo autônomo baseado em um Smart car modelo 2005 que contava com três sensores SICK LMS291-S05 instalados no veículo, mais dois sensores de mesmo modelo como parte de um sensor LIDAR rotacional, uma câmera omnidirecional Sony XCD-SX910CR, 1 câmera monocular, 1 sensor inercial e 1 sistema GPS diferencial. O *SmartTer* tinha como objetivo

(a) Stanley (THRUN et al. , 2006)

(b) Junior (MONTEMERLO et al. , 2008)

(c) Boss (BAKER E DOLAN , 2009)

Figura 1.2: Figura com os veículos autônomos participantes do *DARPA Grand Challenge* e *DARPA Urban Challenge*

realizar o mapeamento 3D do terreno utilizando os sensores LIDAR e a câmera omnidirecional enquanto percorria autonomamente uma rota determinada LAMON et al. (2006).

Devido a essas competições, novos carros começaram a ser desenvolvidos, como exemplo pode-se citar o carro desenvolvido pela Google, como mostra a figura 1.3. Com sua aparição em 2010, o mesmo executou aproximadamente 225.308 *km* de testes com apenas uma colisão em sua traseira (ACKERMAN , 2010).

Podem ser citados ainda o carro desenvolvido pela Universidade de Oxford (Figura 1.4(a)) (OXFORD , 2011), o desenvolvido pela IFSTTAR (*Institut français des sciences et technologies des transports, de l'aménagement et des réseaux*) (Figura 1.4(b)) (GUIZZO , 2012), o desenvolvido pela Freie Universität Berlin (Figura 1.4(c)) (REUSCHENBACH et al. , 2011) e o desenvolvido pela Universidade de Parma (Figura 1.4(d)) (BERTOZZI et al. , 2011) como mostra a figura 1.4. Este último, teve uma visibilidade maior devido à viagem de Parma a Shangai realizada em 2010, em um trajeto de cerca de 13.000 Km e 3 meses de duração (BERTOZZI et al. , 2011).

Os carros autônomos também estão presentes no Brasil, um deles é o Carro Autônomo

Figura 1.3: Carro autônomo desenvolvido pela Google (ACKERMAN , 2010)

(a)

(b)

(c)

(d)

Figura 1.4: Carros Autônomos na Europa. Em (a), o veículo desenvolvido pela Oxford (OXFORD , 2011). Em (b), o veículo desenvolvido pela IFSTTAR (GUIZZO , 2012). Em (c), o veículo desenvolvido pela Freie Universität Berlin (REUSCHENBACH et al. , 2011). Em (d), o veículo desenvolvido pela Universidade de Parma (BERTOZZI et al. , 2011).

Desenvolvido na Universidade Federal de Minas Gerais ou CADU, cuja plataforma é um Astra e possui um sensor LIDAR SICK, uma câmera estéreo, um sensor GPS e uma IMU (LIMA , 2010) como mostra a figura 1.5.

Figura 1.5: Carro Autônomo Desenvolvido na Universidade Federal de Minas Gerais (LIMA , 2010)

O projeto CARINA (Carro Robótico Inteligente para Navegação Autônoma), desenvolvido pelo ICMC (Instituto de Ciências Matemáticas e Computação) da USP (Universidade de São Paulo) no campus de São Carlos, atualmente possui duas plataformas, a mais antiga um carro de golfe elétrico (Figura 1.6(a)) usa dois sensores LIDAR SICK e uma câmera estéreo para a navegação, já a mais nova é um Palio Adventure em fase de automação (Figura 1.6(b)) (LRM , 2011).

(a) CARINA 1

(b) CARINA 2

Figura 1.6: Carros Autônomos desenvolvidos no ICMC LRM (2011)

1.2.3 Projeto SENA

Dentre os carros autônomos em desenvolvimento no Brasil, o projeto SENA (Sistema Embarcado de Navegação Autônoma), atualmente em desenvolvimento na EESC (Escola de Engenharia de São Carlos) da USP - Campus de São Carlos, tem como plataforma um FIAT Stilo, apelidado de GISA (Figura 1.7). O projeto SENA iniciou em 2006 como uma iniciativa dos alunos da graduação do curso de Engenharia Mecatrônica da EESC-USP e visa diminuir o grande número de acidentes de trânsito no Brasil usando a robótica como meio de prevenir os erros causados pelos motoristas, tais como a desatenção ou imprudência (SENA , 2012). Essa solução além de boas perspectivas sociais, também apresenta boa perspectiva em sua aceitação na sociedade, como mostra a pesquisa em IFR (2011).

(a) GISA 1

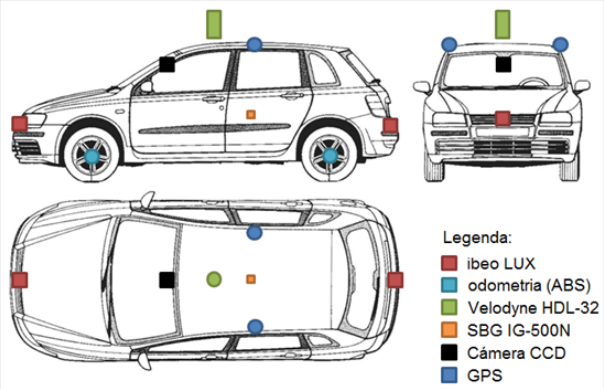

(b) GISA 2

Figura 1.7: Sistema Embarcado de Navegação Autônoma - plataforma GISA (SENA , 2012). (a) Antigo arranjo dos sensores da plataforma GISA. (b) Novo arranjo dos sensores da plataforma GISA

Atualmente em fase de automação, o carro possui um sensor LIDAR Velodyne HDL - 32E, dois sensores LIDAR ibeo LUX, uma câmera AVT Stingray F-033C, uma IMU SBG IG - 500N e um AsteRx2eH RTK - GPS (*Real Time Kinematic Global Positioning System*) da Septentrio que fornecerão dados para 4 computadores embarcados no carro. A tabela 1.2 mostra uma lista dos sensores utilizados e suas respectivas taxas de envio de dados. Pode-se fazer um comparativo entre a antiga arquitetura adotada para GISA e a nova que a mesma terá ao final da fase de automação na figura 1.7. Na figura 1.7(a), vê-se que o veículo apenas continha 2 sensores LIDAR SICK LMS 291, um voltado para a rua e outro focado para detecção de obstáculos e uma câmera colorida SCC-B2313 para o mesmo fim, enquanto no diagrama da figura 1.7(b) vê-se as posições dos sensores previamente citados. Além disso, quando necessário, a atuação feita na GISA será *Drive-by-Wire*. Deve-se aqui frisar que um projeto dentro do âmbito de carros autônomos

contém vários módulos os quais precisam ser desenvolvidos, um exemplo da variedade desses módulos pode ser vista no mapa conceitual do Apêndice A.

Tabela 1.2: Lista dos sensores presentes na GISA e suas taxas de envio de dados

Sensor	**Taxa de envio de dados (em Hz)**	**Breve Descrição**
Velodyne HDL-32E	10	Sensor LIDAR de 32 feixes com área de varredura de 360° e abertura de 40°, alcance de 100 m com precisão de 2 cm
AsteRx2eh RTK-GPS	20	Sistema de geolocalização com entrada de duas antenas, capaz de acessar os sistemas GPS e GLONASS. Possui precisão horizontal de $1,3$ m no modo padrão e precisão horizontal de $0,6$ cm no modo *RTK*
AVT Stingray F-033C	60	Câmera CCD colorida, VGA (656 x 494)
ibeoLUX	$12,5$	Sensor LIDAR de 4 feixes, área de varredura de 85° e abertura de $3,2°$, alcance de 200 m com precisão de 10 cm
IG - 500N	100	IMU que contém 3 giroscópios, 3 acelerômetros e 3 magnetômetros

Dentro do conceito de veículos autônomos, em especial na sub-área de controle deliberativo, pode-se citar algumas vantagens dessa abordagem perante os desafios de lidar com o trânsito de maneira puramente reativa, como a modelagem das regras de trânsito, o gerenciamento de conhecimento e o controle probabilístico, que trata as incertezas inerentes à percepção.

1.3 Objetivo

O objetivo dessa dissertação será testar uma técnica de inteligência artificial chamada Rede Bayesiana quanto ao tratamento dos dados oriundos dos sensores e suas respectivas classificações. A rede bayesiana tem como base o teorema de Bayes para lidar com a transição entre as probabilidades *a priori* para as probabilidades *a posteriori* dadas algumas evidências. Além disso, usa a relação entre estados para transmitir as informações até o estado onde a inferência será realizada. Desse modo, pode-se analisar a robustez do algoritmo quanto aos ruídos sensoriais, aos erros de classificação do módulo intermediário ou de representação.

1.4 Estrutura e Organização do Trabalho

O **Capítulo 2** demonstra a formulação do problema de um ADAS, bem como as hipóteses simplificadoras usadas neste trabalho e os casos estudados.

O **Capítulo 3** descreve algumas técnicas de percepção utilizadas como base neste trabalho. Tais técnicas variam desde detecção de pedestres via visão computacional até a estimação da pose do veículo via a fusão sensorial do GPS com um sensor inercial (IMU)

O **Capítulo 4** apresenta os métodos de representação dos dados coletados no módulo da percepção e por fim, descreve as classes usadas para cada tipo de classificador utilizado como base.

No **Capítulo 5** é demonstrada a técnica abordada para o módulo de cognição do veículo. Deste modo, a teoria de redes bayesianas é brevemente descrita, bem como algumas aplicações usuais. Também é apresentada a solução encontrada para o problema proposto considerando as hipóteses e as restrições impostas e por fim, alguns testes preliminares são mostrados com a ferramenta utilizada.

O **Capítulo 6** mostra os resultados obtidos com as redes bayesianas aplicadas aos casos estudados, bem como algumas ressalvas sobre comportamentos importantes observados.

No **Capítulo 7** são feitas as conclusões e considerações finais e apresentados alguns trabalhos futuros a serem realizados.

Capítulo 2

Formulação do Problema

Esse capítulo busca formalizar o problema focado nessa dissertação. Para tanto, deve-se definir e delinear a área de atuação da mesma bem como expor as hipóteses adotadas pelo projeto de modo que uma solução fosse buscada.

2.1 Definições e Restrições

Primeiramente, a dissertação se propõe a testar uma Rede Bayesiana cuja saída é um comportamento a ser apresentado ao motorista. Desse modo, este trabalho inclui-se no âmbito de um ADAS e dessa forma, as áreas de conhecimento sobre atuação e controle desses comportamentos em um veículo autônomo não serão abordadas. Assim, a saída da rede deve ser robusta quanto à ruídos e ter frequência de atualização compatível com a habilidade do motorista em perceber uma mudança no sistema ADAS. Para isso, os programas usados como base devem ser mais rápidos e os sensores ainda mais rápidos que o tempo de resposta de um condutor normal de veículos. A tabela 1.2 mostra a taxa de saída dos sensores do protótipo GISA.

Dessa forma, pode-se conceber uma arquitetura de *software* que trate o problema de sincronização. Como proposta por BECKER E SIMON (2000), a fusão temporal pode ser feita através de Filtros de Kalman, cujas entradas são os dados sensoriais e/ou resultados de outros filtros juntamente com seus respectivos tempos e a saída será uma estimativa desse dado para o tempo da fusão. A figura 2.1 ilustra o procedimento acima citado para um exemplo fictício, onde os marcadores verticais indicam a amostragem de cada sistema.

Pode-se ver pela figura 2.1 que entre as amostragens da fusão temporal, que no exemplo

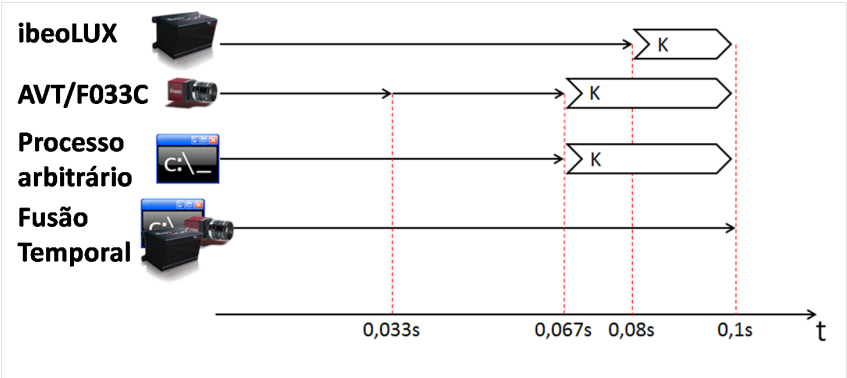

Figura 2.1: Exemplo da fusão temporal apresentada por BECKER E SIMON (2000). A linha tracejada indica o tempo de aquisição dos sensores e programas, as setas com indicador K indicam o período de tempo no qual o filtro de Kalman fará a fusão temporal.

acontecem de $0,1$ em $0,1$ s, ocorrem uma ou mais amostragens dos sensores e programas, e, quando a fusão temporal é feita, os outros programas ainda não tiveram tempo de lançar novas evidências, assim, o Filtro de Kalman (ilustrado pelas setas sem preenchimento com K) usará as informações das amostragens anteriores dos sensores para predizer os valores dos mesmos no tempo em questão.

Em um sistema deliberativo, também é importante saber como está constituída a base de conhecimento do veículo. No caso desta dissertação, o carro terá disponível os mapas de seu trajeto, em específico, o mapa do campus 1 da USP-São Carlos, como mostra o Apêndice B.

O mapa armazenado encontra-se no formato GIS (*Geographic Information System*). Mapas nesse formato possuem a vantagem de possuírem não só as informações de distância, das coordenadas de latitude e longitude e a geometria das ruas, como mostra a figura 2.2, como também podem conter informações, por exemplo, da sinalização vertical presente no mapa, como mostra a figura 2.3.

As figuras 2.2 e 2.3 foram retiradas de um *software* para gerenciamento de mapas do tipo GIS usado no projeto. Com esse *software*, pode-se construir um mapa topológico com as informações contidas no mapa do campus (ANDRADE , 2011). Cada nó conterá as informações de coordenadas para referenciamento e localização, terá também as informações pertinentes quanto as regras de trânsito localmente definidas para aquele nó e a conexão com o mapa métrico local pertinente.

O mapa topológico pode ser modelado como um grafo direcional (BUSCHKA E SAFFIOTTI , 2004) e sua construção foi feita segundo algumas regras. Primeiramente, devido a presença de direção no grafo, cada pista de rolamento deve conter os nós. Segundo SATO E AKAMATSU

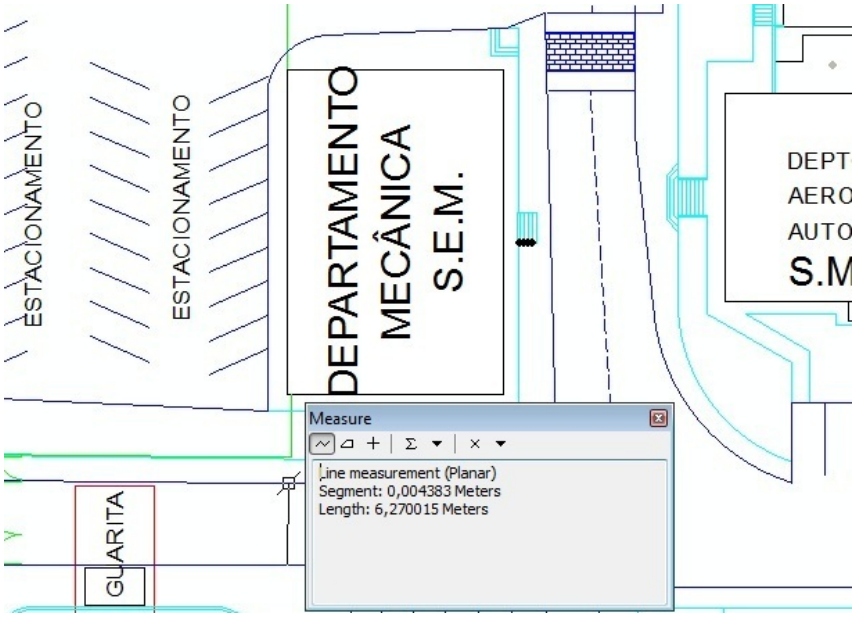

Figura 2.2: Detalhe do Mapa do Campus 1 da USP São Carlos. Janela em destaque mostra as informações de distância inerentes ao mapa.

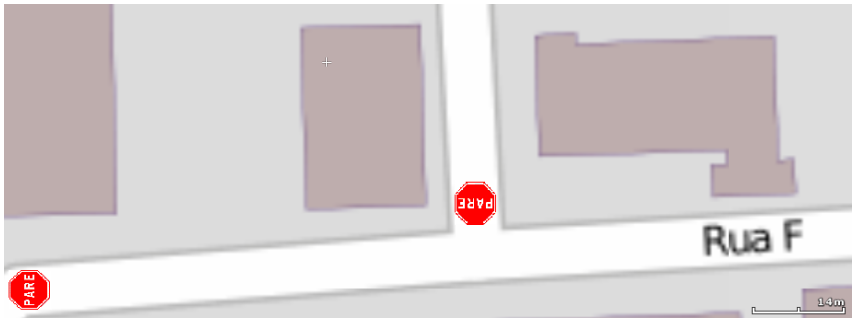

Figura 2.3: Detalhe do Mapa do Campus 1 da USP São Carlos. Em destaque as placas de PARE presente nos cruzamentos.

(2009), os motoristas apresentam variações na distância à um cruzamento para a frenagem, dependendo do trânsito local, variando entre 40 a 60 metros. Assim, um nó foi marcado a 50 metros dos cruzamentos para permitir a redução adequada de velocidade. Por fim, segundo o CONTRAN (2007), as sinalizações verticais de regulamentação referentes aos cruzamentos, como a *parada obrigatória* e o *dê preferência*, devem estar localizados a no máximo 10 metros do entroncamento, indicando, assim, regiões onde a atenção deve ser aumentada e onde ocorre a transição e negociação entre os carros para que os mesmos atravessem o cruzamento. Visto isso, um nó foi posto a 10 metros de cada intersecção de vias.

Com o mapa topológico construído, a rota do carro pode ser planejada. A mesma será feita usando o algoritmo de *dijkstra*, sendo este um algoritmo de busca de custo uniforme conhecido

na literatura (RUSSEL E NORVIG , 2010). Ao final da execução do algoritmo, uma lista é feita contendo a sequência de nós a serem percorridos.

2.2 Hipóteses Simplificadoras

Para o estudo dessa dissertação algumas hipóteses adicionais às restrições foram consideradas. Como foi previamente citado, o veículo terá os mapas de sua rota e os mesmos serão mapas híbridos (BUSCHKA E SAFFIOTTI , 2004), contendo as informações de regulamentação do trânsito. Além do mais, os movimentos realizados pelo carro serão considerados planares com a finalidade de redução de dimensionalidade e complexidade para os modelos adotados.

Quanto à estrutura de cidade analisada, serão considerados os casos contendo apenas as vias de duplo sentido com duas pistas de rolamento. Esse tipo de estrutura apresenta a possibilidade de identificação da permissão ou proibição de ultrapassagens via a coloração da sinalização horizontal, entretanto esse caso não será abordado.

A máxima aceleração e desaceleração consideradas para os cálculos de colisão serão limitadas a $2m/s^2$ devido ao conforto do motorista (COOPER E ZHENG , 2002) e, principalmente, devido à segurança, visto que maiores espaços livres serão necessários para o veículo ultrapassar a intersecção. Futuramente, essa análise pode ser modificada para se adequar as características dos mais diversos tipos de motoristas (POLLATSCHECK et al. , 2002).

Por fim, como comentado no capítulo 1, o protótipo GISA está em fase de automação e, desse modo, os testes do algoritmo desenvolvido devem ser testados em ambiente simulado. Como o objetivo dessa dissertação é testar a Rede Bayesiana para a inferência dos comportamentos do carro, o sistema de percepção não foi emulado, apesar de seu estudo ter sido essencial para implementação e funcionamento do sistema. Assim, o simulador toma como entrada o resultado da classificação de cada módulo da percepção, não existindo a necessidade de se modelar os ruídos dos sensores, mas sim de introduzir o efeito que esses geram na classificação.

2.3 Casos Estudados

Para determinar o número e quais casos devem ser estudados, primeiramente fez-se uma análise, dentro das hipóteses simplificadoras, de quantos casos poderiam existir. Se for posto de lado, em primeira instância, o número de cenários de trânsito (devido a uma infinidade de

possíveis casos), deseja-se encontrar, para apenas 1 cenário de trânsito, quantas combinações de testes da Rede Bayesiana existem. Segundo o modelo desenvolvido, que será melhor elucidado no capítulo 5, existem 4 classificadores na entrada do sistema os quais possuem suas respectivas matrizes de confusão oriundas do treinamento dos mesmos. Há, ainda, mais dois classificadores que não utilizam, no modelo proposto, essa abordagem.

Podem-se definir dois tipos de classificadores por suas respectivas matrizes de confusão. A análise desta permite distinguir classificadores altamente discriminantes de outros pouco discriminantes. O primeiro é capaz de identificar mais certamente a classe correta enquanto o segundo há a presença de mais falsos positivos (DUDA et al. , 2001). A partir desse ponto, chamam-se os classificadores altamente discriminantes de FORTES e serão referenciados como F, enquanto os pouco discriminantes serão chamados de FRACOS e serão referenciados como f.

Além do mais, o efeito do ruído dos sensores e a estocasticidade do ambiente nos classificadores precisam ser simulados. Para isso, foram definidas probabilidades de acerto do classificador dentro da simulação, e assim, podem-se transmitir os efeitos acima citados para a Rede Bayesiana. Nos testes em consideração foram definidas 3 probabilidades de acerto: Acerto ideal, Acerto Alto e Acerto Baixo. A primeira será referenciada como Φ, a segunda como Pq e a última como Gd. Nessa situação, os 6 classificadores serão simulados com os efeitos acima citados.

Por fim, cada caso pode ser modelado como:

- 4 classificadores, os quais apresentam características FORTES ou FRACAS e os 3 sinais de influência do ruído na classificação. Cada classificador forma então o par (m, n) onde $m \in \{F, f\}$ e $n \in \{\Phi, Pq, Gd\}$.
- 2 classificadores, os quais apenas mudam o sinal de influência do ruído na classificação. Cada um pode ser escrito como k, onde $k \in \{\Phi, Pq, Gd\}$.
- Cada caso é modelado pelo conjunto dos 6 classificadores. Dessa forma, pode ser definido como a 6-tupla (a, a, a, a, b, b) onde $a = (m, n)$ e $b = k$.

Pela regra da multiplicação, pode-se determinar o número de possibilidades para cada caso, como mostra a equação 2.1.

$$\#possibilidades = (m \cdot n) \cdot (m \cdot n) \cdot (m \cdot n) \cdot (m \cdot n) \cdot k \cdot k = (m \cdot n)^4 \cdot k^2 = (2 \cdot 3)^4 \cdot 3^2 = 11664. \quad (2.1)$$

Retomando a questão do número de casos, uma análise rápida foi feita com 2 arranjos de

vias: Apenas uma via e uma junção em T. A figura 2.4 mostra possíveis cenários para apenas uma via.

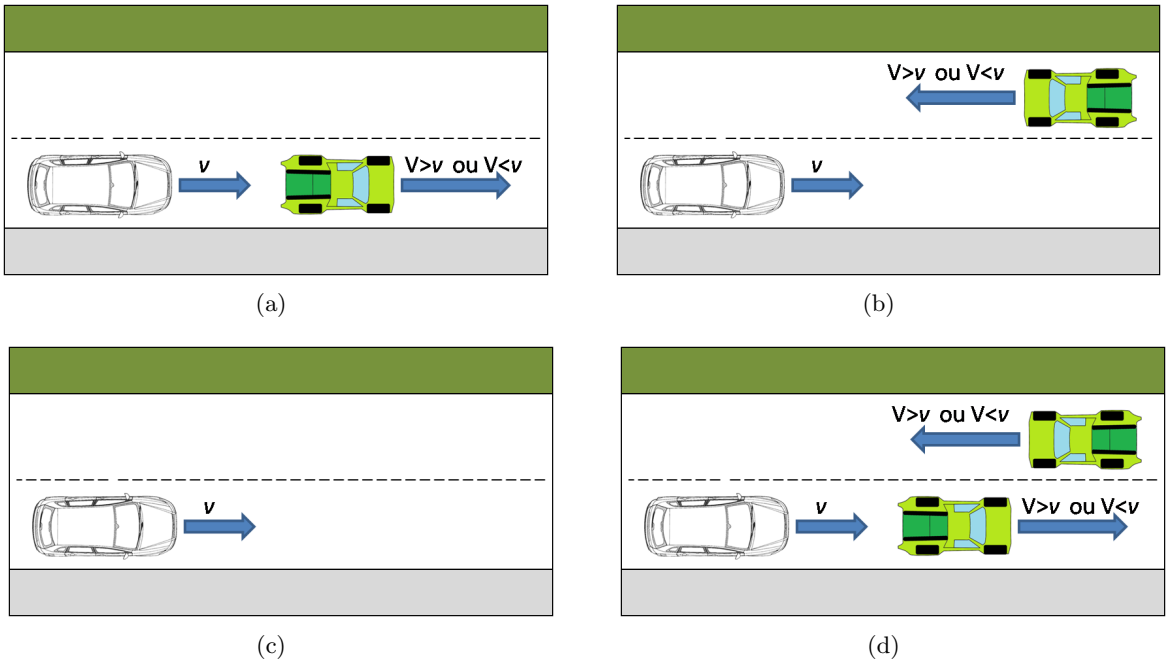

Figura 2.4: Casos factíveis de ocorrerem em cenário de uma via, onde o *FIAT STILO* representa o veículo autônomo. (a)Veículo autônomo seguindo um carro com velocidade variável. (b) Veículo autônomo passando ao lado de outro carro com velocidade variável. (c) Veículo Autônomo sem a presença de carros. (d) Ambiente de tráfego pesado.

Para a figura 2.4(a) e 2.4(b), tem-se 4 casos cada, pois o comportamento do carro autônomo é escolhido do conjunto {*velocidade constante*, *desacelerando* } e o veículo a frente (na mesma pista, ou na pista ao lado) pode ter velocidade menor ou maior do que o veículo autônomo. A figura 2.4(c) apresenta apenas 2 casos, onde o comportamento da plataforma de testes é escolhida do conjunto {*velocidade constante*, *desacelerando* }. Por fim, a figura 2.4(d) terá 8 casos resultante da combinação das velocidades dos 3 veículos. Somando ao todo, para apenas 1 via, 18 casos.

A figura 2.5 ilustra os possíveis cenários para 2 vias em junção perpendicular ou junção em T. Para um melhor entendimento dos casos a seguir, define-se *gap* como o tempo medido, em um cruzamento, entre dois veículos. Como simplificação dos inúmeros *gaps* possíveis em um cruzamento, considerar-se-á apenas 3, o primeiro com um tempo menor do que o necessário para atravessar o cruzamento em segurança, o segundo com o tempo justo e o terceiro com tempo de sobra para realizar a manobra desejada.

A figura 2.5(a) apresenta apenas 2 casos, os quais representam a direção na qual seguir.

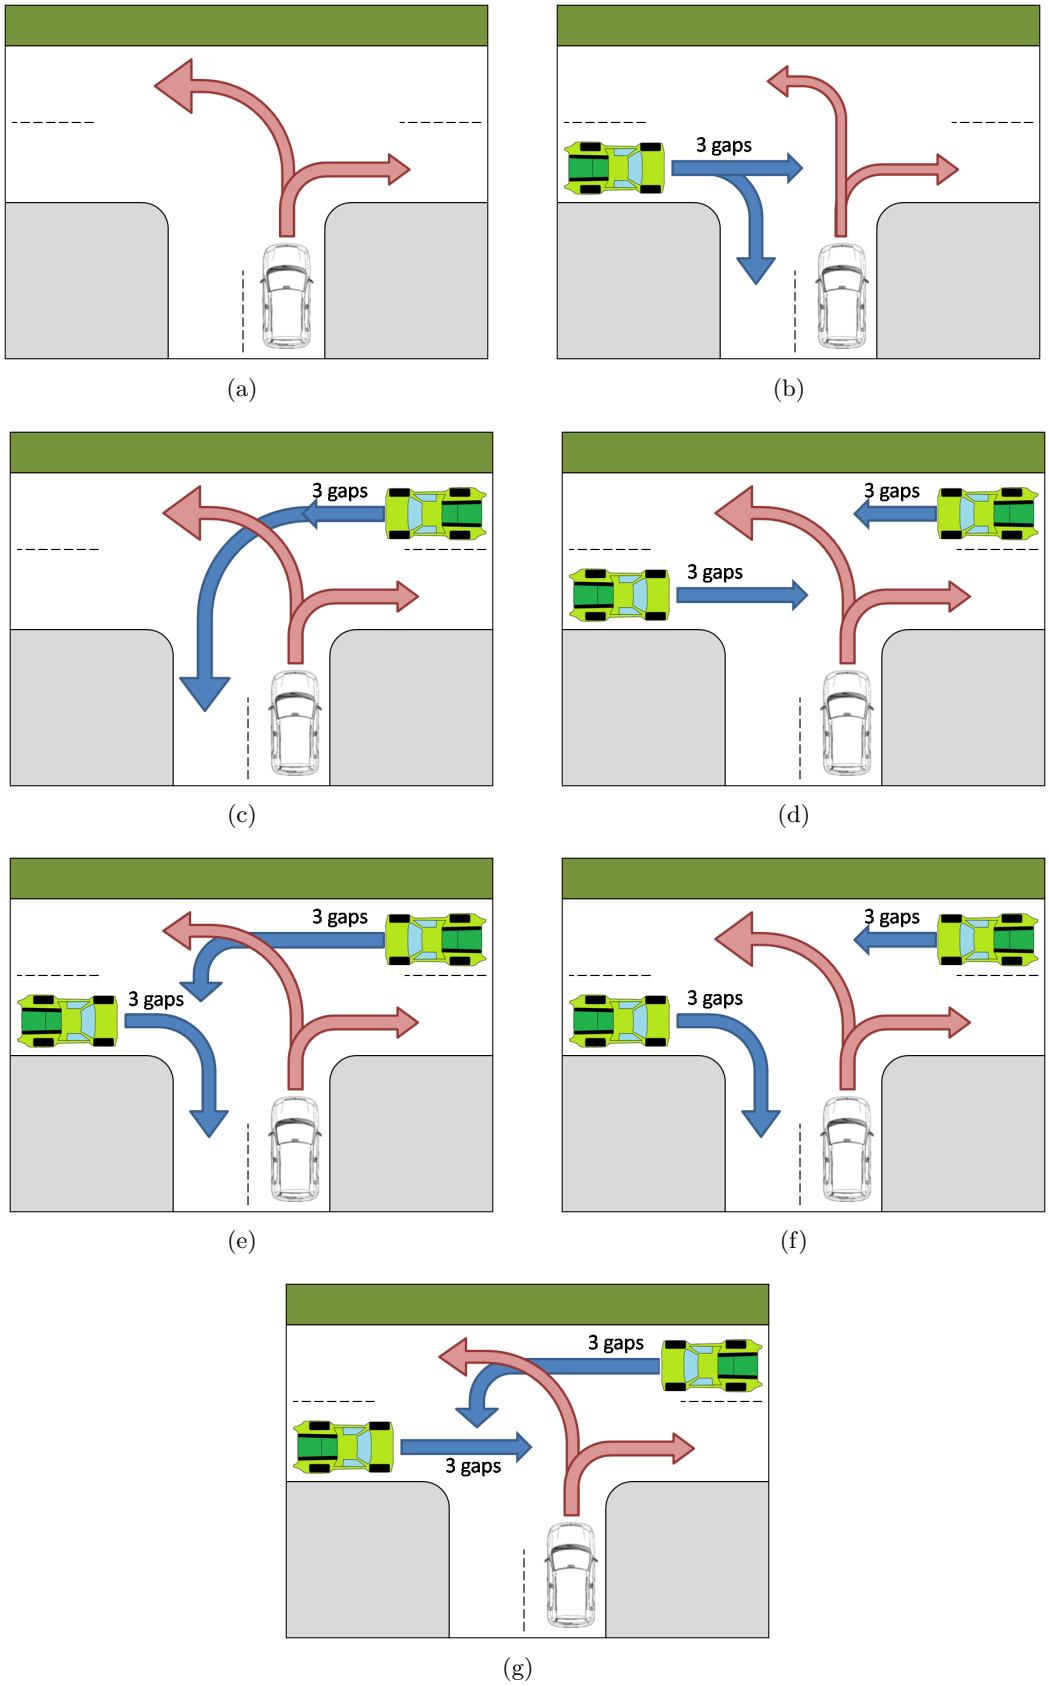

Figura 2.5: Casos factíveis de ocorrerem em cenário com duas vias em Junção perpendicular ou em T. O *FIAT STILO* representa o veículo autônomo. (a) Sem a presença de veículos. (b)Veículo à esquerda com 3 velocidades distintas e 2 comportamentos. (c) Veículo à direita com 3 velocidades distintas e 2 comportamentos. (d) a (g) Dois Veículos, cada qual com 3 velocidades distintas e um comportamento.

As figuras 2.5(b) e 2.5(c) apresentam 12 casos cada, pois há a combinação entre os 3 *gaps* do veículo no cruzamento e as direções a serem tomadas pelos veículos. As figuras 2.5(d) a 2.5(g) representam 18 casos cada, devido a combinação entre os 3 *gaps* dos dois veículos e os comportamentos dos 3 carros no cruzamento. Somando, ao todo, 98 casos.

Se analisarmos agora o número de casos para apenas esses cenários combinado com o teste da rede para cada caso, tem-se o número de testes necessários como mostra a equação 2.2.

$$\#testes = \#casos \cdot \#possibilidades = (98 + 18) \cdot 11664 = 1353024. \tag{2.2}$$

A média, em tempo, para realizar cada teste é de aproximadamente 1 minuto, portanto, para todos os casos serem testados, há uma demanda de $22550,4$ horas, o que são aproximadamente 2 anos e 7 meses. Se os mesmos testes fossem executados em 40 computadores em paralelo, ainda assim, precisaria de $563,76$ horas, o que são 23 dias e meio. Além do mais, o *log* de cada teste tem aproximadamente 30 kbytes, desse modo, precisa-se tratar $38,71$ Gbytes de dados.

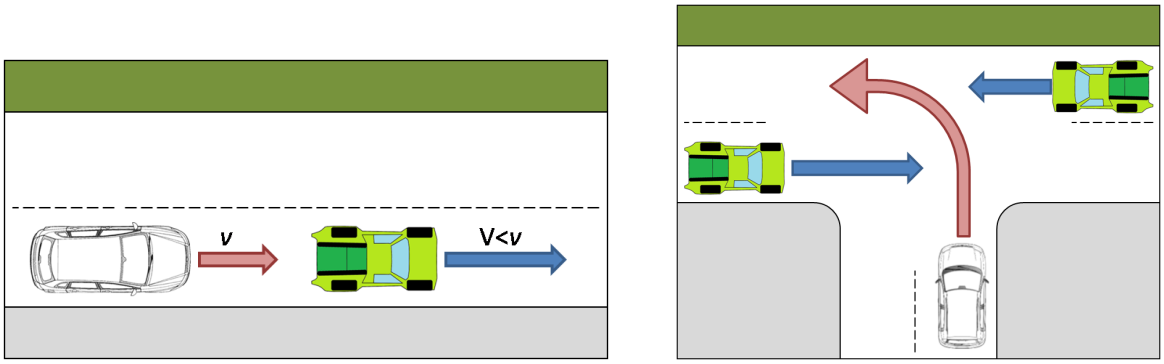

(a) (b)

Figura 2.6: Casos estudados nessa dissertação, onde o *FIAT STILO* representa o veículo autônomo. (a)Cenário na qual o veículo autônomo deve começar a frenagem devido a um entroncamento, com um veículo mais lento a frente. (b) Cenário na qual o veículo autônomo deve virar a esquerda, com 2 veículos no entroncamento, ambos andando em linha reta. Este cenário conta com 4 variações de *gap*. O primeiro caso traz dois *gaps* que não permitem o carro autônomo entrar na intersecção antes que os outros carros ultrapassem, enquanto o segundo e o terceiro apresentam pelo menos um dos carros com *gap* grande enquanto o outro tem um *gap* justo. Por fim, o último caso terá *gaps* grandes.

Como as proporções apresentadas são inviáveis, serão analisado apenas 2 cenários, considerados críticos, e os testes da rede serão voltados para o problema da cada cenário. Os casos a serem estudados podem ser vistos na figura 2.6.

O caso de testes da figura 2.6(a) refere-se ao problema da colisão frontal do veículo quando há

um erro de estimação do comportamento do veículo à frente. Para tanto serão definidos alguns casos a serem testados. A tabela 2.2 mostra os casos estudados para esse cenário, enquanto que a tabela 2.1 contém a legenda das siglas utilizadas.

Tabela 2.1: Legenda das siglas utilizadas

Nome	**Símbolo**	**Descrição**
Fraco	f	Classificador pouco discriminante
Forte	F	Classificador Altamente Discriminante
Acerto Ideal	Φ	Sem interferência de ruídos na classificação
Acerto Alto	Pq	Baixa interferência de ruídos na classificação
Acerto Baixo	Gd	Alta interferência de ruídos na classificação
Identificação	ID	Palavra indicando o tipo de teste realizado
Detector de faixas	MI	Classificador usado para detecção da posição relativa na via
Localização	MII	Classificador usado para detecção da posição relativa na via
Detector de vias	MIII	Classificador usado para detecção do cenário transitado
Cenário do mapa	MIV	Classificador usado para detecção do cenário transitado
Cenário Futuro	MV	Classificador usado para detecção do cenário futuro da rota
Colisão	MVI	Classificador usado para detecção de colisões

Esta primeira bateria com 24 testes e o grupo de controle testa, para o módulo da identificação do cenário (MIII e MIV), as diferentes combinações entre os níveis de ruído dos sensores e suas influências no classificador, bem como testa os dois tipos de discriminantes. Para o módulo de localização na pista (MI e MII), manteve-se um e apenas um classificador *FORTE*, sendo assim este módulo apresenta-se com 2 variações. Para a classificação dos pontos da rota, esta foi considerada de Acerto Alto e para a classificação de colisões, foi considerada de Acerto Baixo.

Os casos de testes representados pela figura 2.6(b) referem-se ao problema da negociação em uma intersecção de vias do tipo T com outros veículos. Serão testados 4 tipos de casos, os quais diferem entre si devido aos *gaps* para cada veículo no entroncamento. O primeiro caso traz dois *gaps* que não permitem o carro autônomo entrar na intersecção antes que os outros carros ultrapassem, enquanto o segundo e o terceiro apresentam pelo menos um dos carros com *gap* grande enquanto o outro tem um *gap* justo. Por fim, o último caso terá *gaps* grandes. A tabela 2.3 contém os valores de *gaps* utilizados onde o veículo A é o veículo mais próximo com direção à direita e o veículo B é o veículo mais afastado rumando para à esquerda.

Para cada um desses casos, serão feitos 4 testes, ou subcasos, de modo a por a prova o quão grande é a influência dos ruídos na localização e no acompanhamento dos obstáculos para o classificador de colisões e, com isso, testar quão robusta é a saída da rede para esse tipo de erro. Os sub-casos serão definidos como *erro baixo* (*lowError*), *erro na localização* (*localizationError*),

Tabela 2.2: Testes da rede para o caso apresentado na figura 2.6(a)

ID	**MI**	**MII**	**MIII**	**MIV**	**MV**	**MVI**
$f_{Pq}F_{Pq}f_{\Phi}F_{\Phi}PqGd$	f e Pq	F e Pq	f e Φ	F e Φ	Pq	Gd
$f_{Pq}F_{Pq}f_{Pq}F_{Pq}PqGd$	f e Pq	F e Pq	f e Pq	F e Pq	Pq	Gd
$f_{Pq}F_{Pq}f_{Gd}F_{Gd}PqGd$	f e Pq	F e Pq	f e Gd	F e Gd	Pq	Gd
$f_{Pq}F_{Pq}F_{\Phi}f_{\Phi}PqGd$	f e Pq	F e Pq	F e Φ	f e Φ	Pq	Gd
$f_{Pq}F_{Pq}F_{Pq}f_{Pq}PqGd$	f e Pq	F e Pq	F e Pq	f e Pq	Pq	Gd
$f_{Pq}F_{Pq}F_{Gd}f_{Gd}PqGd$	f e Pq	F e Pq	F e Gd	f e Gd	Pq	Gd
$f_{Pq}F_{Pq}f_{\Phi}f_{\Phi}PqGd$	f e Pq	F e Pq	f e Φ	f e Φ	Pq	Gd
$f_{Pq}F_{Pq}f_{Pq}f_{Pq}PqGd$	f e Pq	F e Pq	f e Pq	f e Pq	Pq	Gd
$f_{Pq}F_{Pq}f_{Gd}f_{Gd}PqGd$	f e Pq	F e Pq	f e Gd	f e Gd	Pq	Gd
$f_{Pq}F_{Pq}F_{\Phi}F_{\Phi}PqGd$	f e Pq	F e Pq	F e Φ	F e Φ	Pq	Gd
$f_{Pq}F_{Pq}F_{Pq}F_{Pq}PqGd$	f e Pq	F e Pq	F e Pq	F e Pq	Pq	Gd
$f_{Pq}F_{Pq}F_{Gd}F_{Gd}PqGd$	f e Pq	F e Pq	F e Gd	F e Gd	Pq	Gd
$F_{Pq}f_{Pq}f_{\Phi}F_{\Phi}PqGd$	F e Pq	f e Pq	f e Φ	F e Φ	Pq	Gd
$F_{Pq}f_{Pq}f_{Pq}F_{Pq}PqGd$	F e Pq	f e Pq	f e Pq	F e Pq	Pq	Gd
$F_{Pq}f_{Pq}f_{Gd}F_{Gd}PqGd$	F e Pq	f e Pq	f e Gd	F e Gd	Pq	Gd
$F_{Pq}f_{Pq}F_{\Phi}f_{\Phi}PqGd$	F e Pq	f e Pq	F e Φ	f e Φ	Pq	Gd
$F_{Pq}f_{Pq}F_{Pq}f_{Pq}PqGd$	F e Pq	f e Pq	F e Pq	f e Pq	Pq	Gd
$F_{Pq}f_{Pq}F_{Gd}f_{Gd}PqGd$	F e Pq	f e Pq	F e Gd	f e Gd	Pq	Gd
$F_{Pq}f_{Pq}f_{\Phi}f_{\Phi}PqGd$	F e Pq	f e Pq	f e Φ	f e Φ	Pq	Gd
$F_{Pq}f_{Pq}f_{Pq}f_{Pq}PqGd$	F e Pq	f e Pq	f e Pq	f e Pq	Pq	Gd
$F_{Pq}f_{Pq}f_{Gd}f_{Gd}PqGd$	F e Pq	f e Pq	f e Gd	f e Gd	Pq	Gd
$F_{Pq}f_{Pq}F_{\Phi}F_{\Phi}PqGd$	F e Pq	f e Pq	F e Φ	F e Φ	Pq	Gd
$F_{Pq}f_{Pq}F_{Pq}F_{Pq}PqGd$	F e Pq	f e Pq	F e Pq	F e Pq	Pq	Gd
$F_{Pq}f_{Pq}F_{Gd}F_{Gd}PqGd$	F e Pq	f e Pq	F e Gd	F e Gd	Pq	Gd
$F_{\Phi}F_{\Phi}F_{\Phi}F_{\Phi}\Phi\Phi$	F e Φ	F e Φ	F e Φ	F e Φ	Φ	Φ

erro no Acompanhamento (*trackingError*) e *erro em ambos* (*bothError*). Desse modo, a segunda bateria contém 16 testes.

Esta última bateria foi feita na rede $f_{\Phi}F_{\Phi}f_{\Phi}F_{\Phi}\Phi\Phi$, assim, para o módulo da identificação do cenário (MIII e MIV), o algoritmo da visão foi selecionado como classificador pouco discriminante, enquanto o reconhecimento do cenário via o mapa foi considerado altamente discriminante. Em ambos a influencia do ruído na classificação foi retirada. Para o módulo de localização na pista (MI e MII), o algoritmo da visão foi selecionado como classificador pouco discriminante, enquanto a localização da pista via o mapa foi considerado altamente discriminante. A influencia do ruído na classificação também foi retirada em ambos. A classificação da rota e o classificador de colisões foram designados como de Acerto Ideal.

Com isso, reduz-se a dimensionalidade dos casos testados de 1353024 para 41, os quais testam a rede em casos específicos e considerados críticos caso haja um erro no comportamento decidido.

Tabela 2.3: Testes da rede para o caso apresentado na figura 2.6(b)

ID	***Gap* do veículo A** [s]	***Gap* do veículo B** [s]
casoI	0	1
casoII	0	6
casoIII	5	0
casoIV	4	5

2.4 Considerações Finais

As hipóteses e as restrições foram assumidas com a finalidade de testar uma característica específica do sistema. Entretanto, a generalização pode ser feita, por exemplo, coletando os mapas de mais áreas da cidade e/ou cidades, e, desse modo, ampliando os modelos de ruas e por conseguinte, o número de classes do sistema. Também pode-se aumentar o número de casos estudados caso o número de computadores aumente e possibilite o tratamento desses em paralelo.

Capítulo 3

Módulo de Percepção

O módulo de percepção é de extrema importância para sistemas robóticos. Com ele, é possível lidar com a dinâmica do ambiente ao redor do robô, uma vez que sem o mesmo, eles dependeriam única e exclusivamente de modelos matemáticos de si e do ambiente onde atuam. O emprego de sistemas confiáveis, com alta repetibilidade e, acima de tudo, seguros, atendem às necessidades de robôs perceberem seu estado e o ambiente ao redor.

A percepção de sistemas robóticos é feita através de sensores que podem ser divididos em duas categorias: proprioceptivos e exteroceptivos (CHRISTENSEN E HAGER , 2008). Os sensores proprioceptivos são responsáveis por mensurar os estados internos do robô, como giroscópios e *encoders*. Já os sensores exteroceptivos captam as informações oriundas do ambiente externo ou em relação ao mesmo, como sensores laser, câmeras e GPS (CHRISTENSEN E HAGER , 2008), (SIEGWART et al. , 2011).

3.1 Estimação do Estado Interno

Pode-se dizer que antes de realizar uma tarefa, o robô móvel precisa saber sua localização. Para isso, precisa, primeiramente, encontrar sua posição e pose em relação a um referencial inercial. O sensor mais utilizado para esse fim, entre as aplicações *outdoor*, é o sensor GPS.

O sistema GPS pode ser explicado simplificadamente da seguinte forma: um grupo de satélites em órbita manda sinais de rádio com o tempo de seus respectivos relógios internos de forma codificada. As antenas do dispositivo captam esse sinal e o módulo receptor usa essa informação para calcular o *delay* entre a transmissão e a recepção (DUDEK E JENKIN , 2008).

Para a estimação de sua posição e resolver a diferença entre os relógios do satélite e do receptor, o dispositivo precisa receber pelo menos 4 sinais de satélite, sendo assim capaz de estimar a posição no globo (SANTOS , 2007). O erro de estimação dessa técnica normalmente é de 15 a 20 metros, entretanto existem outros modos de operação que melhoram a acurácia do sistema, um deles é o RTK - GPS.

O RTK - GPS utiliza dois receptores, um primário e outro secundário, cuja comunicação é feita através de um canal de tempo-real. Esse modo usa as observações enviadas e resolve as ambiguidades em movimento, em contraste com as técnicas anteriores que necessitavam de um tempo com o sistema imóvel para executar o mesmo processamento. Nesse modo, o erro de estimação fica na ordem de centímetros (SANTOS , 2007).

Além disso, podem-se empregar dados de sensores inerciais para estimar o estado interno do robô móvel. O uso de uma IMU traz a estimação para um âmbito mais local, pois emprega um sistema de coordenadas inercial local. Através de giroscópios e acelerômetros, a IMU estima as acelerações, velocidades e posições nos 6 graus de liberdade de um robô móvel (posição em x, y e z e ângulos de rolagem θ, guinada ϕ e arfagem ψ). Para tanto, ela precisa passar por duplas integrações, visto que os dados sensoriais são de aceleração, tornando, assim, a IMU muito suscetível à propagação de erros de medida. Isto inviabiliza a localização baseada apenas em IMU por longos períodos de tempo (DUDEK E JENKIN , 2008).

Em ambos os casos, o vetor de estimação interna para robôs móveis pode ser escrito como : $[x\ \dot{x}\ y\ \dot{y}\ z\ \dot{z}\ \theta\ \dot{\theta}\ \phi\ \dot{\phi}\ \psi\ \dot{\psi}]^T$ onde sua localização no sistema de referência é (x, y, z) e as velocidades lineares são $(\dot{x}, \dot{y}, \dot{z})$, enquanto a pose é definida por (θ, ϕ, ψ) e as respectivas velocidades angulares são $(\dot{\theta}, \dot{\phi}, \dot{\psi})$. Deve-se aqui frisar que neste trabalho foram considerados apenas movimentos em duas dimensões, ou seja, o vetor de estimação de estado interno fica $[x\ \dot{x}\ y\ \dot{y}\ \theta\ \dot{\theta}]^T$. Mesmo ciente que, em certas aplicações, pode ser interessante considerar as alterações na altitude da pista e a pose completa do veículo, por exemplo.

Buscou-se, então, otimizar a estimação desses estados, utilizando as vantagens de ambos os sensores, GPS e a IMU. Para suprimir as desvantagens de ambos, realizou-se uma fusão sensorial. Desse modo, a IMU fornece observações durante os períodos que o sistema GPS não disponibiliza os dados (por bloqueio de sinal, por exemplo) e as observações de posição do GPS ajudam a minimizar os erros de integração da IMU, deixando a estimação de estado interno mais confiável (DUDEK E JENKIN , 2008). O algoritmo mais comumente empregado para realizar a fusão é o filtro de Kalman, seu algoritmo pode ser visto de forma simplificada no algoritmo 1 e pode ser

encontrado em mais detalhes na literatura (DURRANT-WHYTE E HENDERSON , 2008).

Algoritmo 1: FiltroDeKalman($\hat{x}_{k-1|k-1}$, u_k, z_k)

Entrada: Estado Anterior, Ação de Controle e Medidas: $\hat{x}_{k-1|k-1}$, u_k e z_k
Saída: Estimativa do Estado e sua Covariância: $\hat{x}_{k|k}$ e $\mathbf{P}_{k|k}$
Dados: $\mathbf{F}_k$, $\mathbf{B}_k$, $\mathbf{P}_{k-1|k-1}$, $\mathbf{G}_k$, $\mathbf{Q}_k$, $\mathbf{R}_k$, $\mathbf{H}_k$

```
/* F_k é a matriz com o modelo de transição do estado, usualmente algum
   modelo cinemático do robô móvel.  B_k é a matriz com o modelo de
   transição das ações de controle.  P_{k-1|k-1} é a matriz de covariância do
   estado anterior, G_k é a matriz de transição do ruído do processo, Q_k é a
   matriz do ruído do processo, R_k é a matriz com o ruído dos sensores e H_k
   é a matriz com o modelo das medições.                                  */
1  início
     /* O Filtro de Kalman pode ser dividido em dois passos:  Predição e
        Atualização                                                       */
2    enquanto verdade faça
       /* Fase da Predição                                                */
3      x̂_{k|k-1} ← F_k · x̂_{k-1|k-1} · F_k^T + B_k · u_k ;   /* x̂_{k|k-1} é a predição do estado */
4      P_{k|k-1} ← F_k · P_{k-1|k-1} · F_k^T + G_k · Q_k · G_k^T ;      /* P_{k|k-1} é a predição da
       covariância */
       /* Fase da Atualização                                             */
5      S_k ← R_k + H_k · P_{k|k-1} · H_k^T ; /* S_k é chamada de matriz de covariância da
       inovação */
6      W_k ← P_{k|k-1} · H_k · S_k^{-1};            /* W_k é chamada de Ganho de Kalman */
7      x̂_{k|k} ← x̂_{k|k-1} + W_k · [z_k − H_k · x̂_{k|k-1}] ;
8      P_{k|k} ← P_{k|k-1} − W_k · S_k · W_k^T ;
9    fim
10 fim
```

3.2 Detecção de Sinalização Horizontal

Ainda no tema de localização, entretanto mais focado ao domínio de carros autônomos, a detecção da sinalização horizontal nas vias é de grande importância. Primeiramente, por fornecer mais um indicativo da posição do veículo na pista de rolamento, segundo, pois é capaz de introduzir algumas regras de tráfego, como a proibição ou permissão de ultrapassagem.

Esta dissertação usará as informações da sinalização horizontal apenas para a localização, entretanto, a implementação de um algoritmo que também considere as informações sobre as leis de tráfego na via não é complexa.

A detecção das faixas é feita através de uma câmera monocular fixada no veículo, resultando em uma imagem de 640 por 480 *pixels* no espaço de cores RGB (*Red, Green, Blue*). A figura

3.1(a) mostra uma imagem exemplo dessa aquisição.

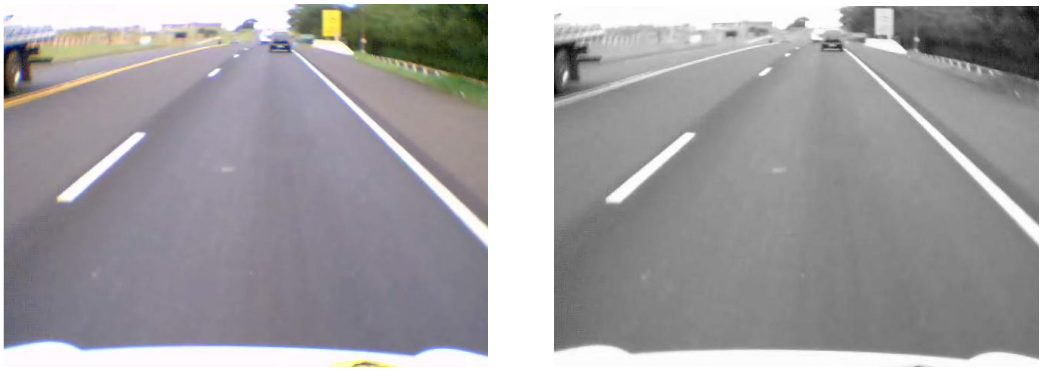

(a) (b)

Figura 3.1: Experimento realizado com o veículo de testes. (a) Imagem coletada. (b) Imagem após mudar o espaço de cores RGB para escala de cinza

Devido à hipótese simplificadora de usar as faixas apenas para localização, a informação de cor não se faz tão essencial e sim a diferença de contraste entre a faixa e a rua. Desse modo, pode-se usar a imagem em escala de cinza, como mostra a figura 3.1(b).

Uma vez realizada a aquisição da imagem e mudado o espaço de cor, um algoritmo de detecção de borda deverá ser utilizado para extrair as posições das faixas (KURDZIEL , 2008). Tais algoritmos são baseados na primeira ou segunda derivada da imagem (GONZALEZ et al. , 2003). Entre os mais variados métodos, optou-se pelo detector de bordas de Canny, esse é brevemente explicado no algoritmo 2 e o mesmo pode ser visto em mais detalhes em GONZALEZ et al. (2003). Uma imagem exemplo do resultado desse algoritmo pode ser visto em 3.2. O uso da imagem resultante será melhor detalhado no capítulo 4.

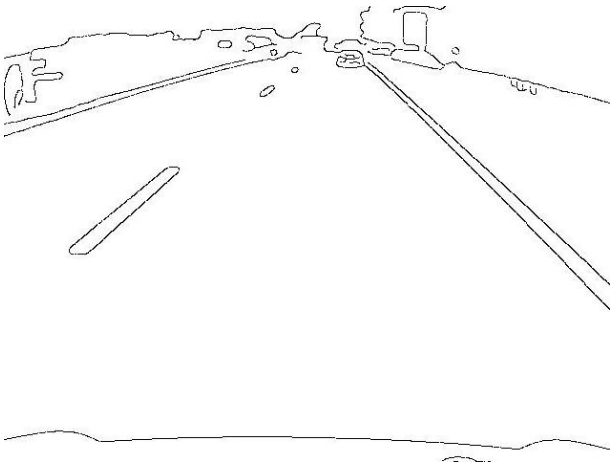

Figura 3.2: Resultado adquirido após o uso do algoritmo de detecção de borda de Canny

Algoritmo 2: Detector de Bordas de Canny

Entrada: Imagem em escala de cinza: $I = f(x, y)$, $T1$ e $T2$, com $T1 < T2$
Saída: Imagem binária com as bordas detectadas

1 **início**
2 $ImagemSuavizada \leftarrow FiltroGaussiano(I)$; `/* Suavização com a finalidade de reduzir ruídos */`
3 **para todo** *pixel* $(x, y) \subset I$ **faça**
4 $gradiente(x, y) \leftarrow [(\partial I/\partial x)^2 + (\partial I/\partial y)^2]^{0.5}$; `/* Primeira derivada para detecção de bordas */`
5 $\alpha(x, y) \leftarrow \arctan\left(\frac{\partial I/\partial y}{\partial I/\partial x}\right)$; `/* Direção do gradiente */`
6 **fim**
7 $ImagemGradiente \leftarrow SupressaoNaoMaxima(gradiente(x, y), \alpha(x, y))$; `/* Imagem resultante com bordas mais finas */`
8 **para todo** *pixel* $(x, y) \subset ImagemGradiente$ **faça**
9 **se** $ImagemGradiente(x, y) \geq T2$ **então**
10 $ImagemGradiente(x, y)$ *classificada como Borda Forte*
11 **senão se** $ImagemGradiente(x, y) \geq T1$ **então**
12 $ImagemGradiente(x, y)$ *classificada como Borda Fraca*
13 **senão**
14 $ImagemGradiente(x, y)$ *classificada como Não Borda*
15 **fim**
16 **fim**
17 **para todo** *pixel* $(x, y) \subset ImagemGradiente$ **faça**
18 **se** $ImagemGradiente(x, y)$ *for uma Borda Fraca* **então**
19 **para cada** *pixel* (x_i, y_i) $8 -$ *conectado ao pixel* (x, y) **faça**
20 **se** (x_i, y_i) *for uma Borda Forte* **então**
21 $ImagemGradiente(x, y)$ *classificada como Borda Forte*
22 **fim**
23 **fim**
24 **fim**
25 **fim**
Resultado: Imagem binária com as bordas detectadas
26 **fim**

3.3 Detecção de Vias Transitáveis

Dentre os módulos de percepção, encontrar os caminhos onde se pode transitar também é preciso. No que tange carros autônomos, a localização das pistas de rolamento indicam onde e como o veículo deve trafegar.

Para encontrar as regiões transitáveis, como as vias, podem-se empregar algoritmos de visão computacional. Segundo KASTNER et al. (2011), atualmente a detecção de vias sem auxílio de modelos pode ser feita treinando-se um algoritmo de detecção com uma pequena região à frente do veículo e, depois de treinada, realizando uma busca na imagem por características similares

às treinadas.

Esta dissertação usará a metodologia proposta por KASTNER et al. (2011). Uma imagem no espaço RGB é capturada (Fig. 3.3(a)). Como as cores nesse espaço mudam com a iluminação, torna-se um desafio para os algoritmos de detecção. Uma das soluções mais empregadas é encontrar um espaço de cor no qual um dos eixos contém a contribuição da iluminação e os outros dois responsáveis apenas pelas informações da cena. O espaço de cores HSV (*Hue - Saturation - Value*) permite essa mudança, onde o eixo nomeado de *Value* contém as informações de iluminação (GONZALEZ et al. , 2003).

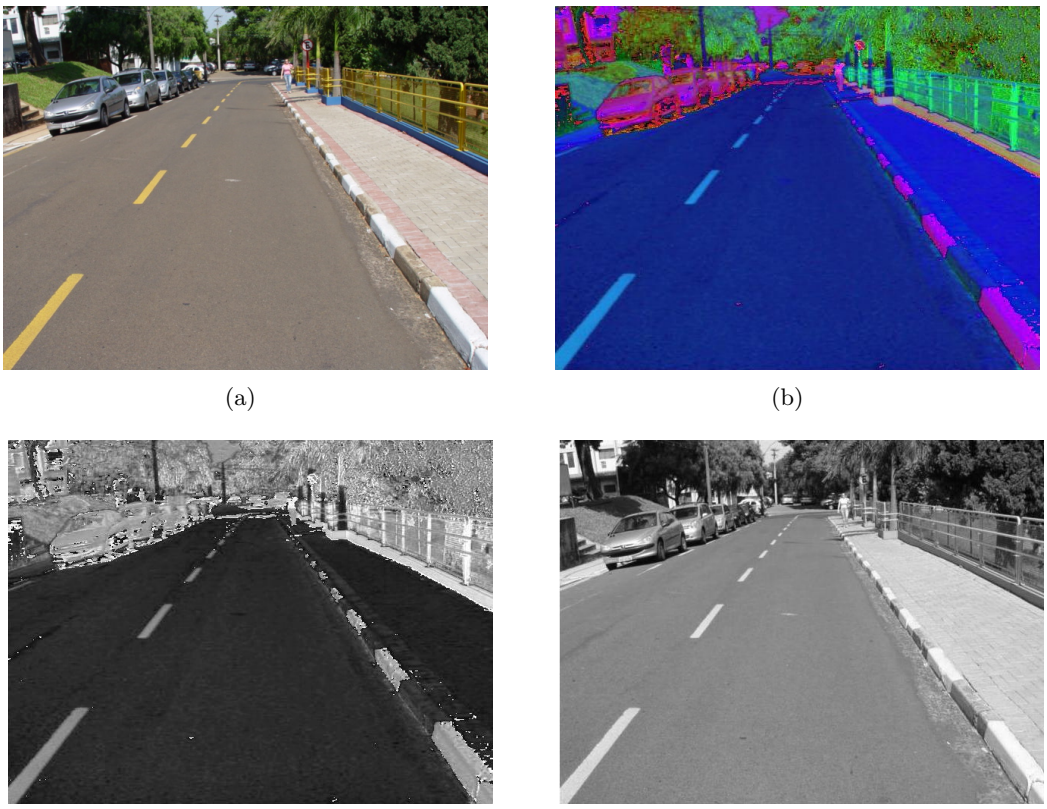

(a) (b) (c) (d)

Figura 3.3: Cenário de rua nos diferentes espaços de cores. (a) RGB.(b) HSV. (c) Componentes H e S. (d) Componente V.

A figura 3.3(b) mostra um cenário de rua no espaço de cores HSV, enquanto as figuras 3.3(c) e 3.3(d) mostram o mesmo cenário para as componentes HS combinadas e V, respectivamente. Mesmo que a projeção dos *pixels* da imagem no plano HS não seja completamente invariante à iluminação, o treinamento do algoritmo neste plano produz resultados mais estáveis do que usando apenas o espaço de cores RGB. A robustez desse tipo de detecção foge ao escopo dessa dissertação, cuja intenção é apenas mostrar formas de realizar esse tipo de percepção.

Seguindo a ideia de THRUN et al. (2006), uma região à frente do veículo foi definida e, na sequência, classificada como via transitável. A partir dessa região, retiram-se um valor ou valores para comparação. Esses valores são usados como parâmetros de entrada para o método de crescimento de região. O mesmo está descrito de forma simplificada pelo algoritmo 3 e pode também ser visto em mais detalhes em GONZALEZ et al. (2003). Ao fim da busca pela região com valores próximos aos que devem ser comparados chega-se em uma imagem como a figura 3.4, na qual a via é identificada.

Algoritmo 3: Crescimento de Região()

Entrada: I = Imagem no espaço HS, ROI = região de interesse, T = *Threshold*
Saída: R = região detectada como via navegável

```
1  início
2      sementes ← RandomPixels(ROI, n) ;   /* Escolhe n pixels aleatoriamente da
       Região de Interesse ROI e os atribui em uma fila */
3      propertiesVector ← getProperties(ROI) ; /* Encontra as propriedades a serem
       comparadas da Região de Interesse */
4      R ← sementes ;              /* Inicializa a região da via com as sementes */
5      enquanto sementes(i) ≠ VAZIO faça
6          para cada pixel p_i 8 − conectado a semente(i) faça
7              se |getProperties(pi) − propertiesVector| < T então
8                  semente(i + 1) ← p_i ; /* Se p_i for similar a semente(i), então ela
                   entra na fila */
9                  R ← R + pi ;                    /* A região R é aumentada de p_i */
10             fim
11         fim
12         i ← i + 1;
13     fim
14 fim
```

Figura 3.4: Resultado obtido após o uso do algoritmo de crescimento de região

3.4 Detecção de Obstáculos

Uma vez detectadas regiões navegáveis e com conhecimento de sua posição, o robô móvel deve, antes de realizar um movimento, estar ciente dos obstáculos ao seu redor. Podem-se encontrar na literatura vários tipos de sensores para esse fim, onde os mais usuais são os sensores de alcance ativo, como o ultrassom ou os sensores LIDAR (*Light Detection And Ranging*) (SIEGWART et al. , 2011).

Uma das técnicas mais comuns para a medição da distância aos objetos dos sensores de alcance ativo é o tempo de voo, no qual o sistema de detecção mensura o tempo entre a emissão do sinal e a recepção do mesmo, e sabendo a sua velocidade de propagação, é possível estimar a distância. Para uma detecção omnidirecional dos obstáculos, sensores LIDAR em 3 dimensões como o Velodyne podem ser usados, como apresentado por MONTEMERLO et al. (2008). Um exemplo da aquisição dos dados do Velodyne pode ser vista na figura 3.5(a).

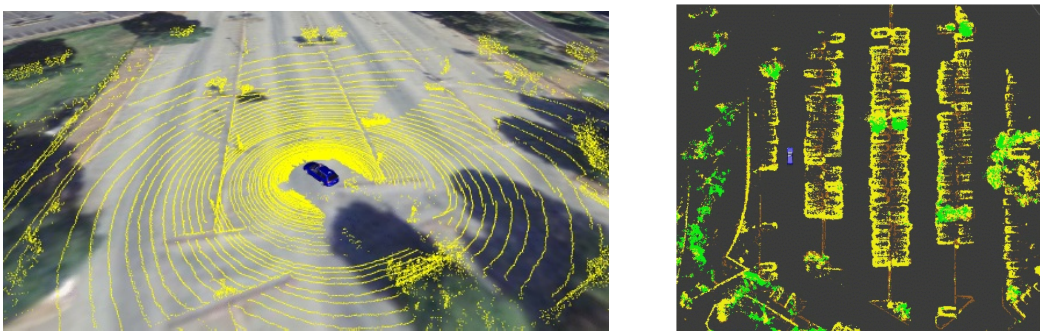

(a) (b)

Figura 3.5: Visualização dos dados produzidos pelo Velodyne. Adaptado de MONTEMERLO et al. (2008). (a) Visualização em 3 dimensões.(b) Projeção no plano de movimento.

Considerando a hipótese de movimento planar de um veículo, os dados coletados nas 3 dimensões são projetados no plano xy no qual os vetores de velocidade pode ser descritos. Um exemplo dessa projeção pode ser vista na figura 3.5(b).

Uma vez projetados os dados, os mesmos devem passar por um processo de segmentação a fim de se identificar os obstáculos bem como suas respectivas posições. Uma das técnicas utilizadas nessa etapa é o *Point-Distance Based Segmentation* (PDBS), o algoritmo 4 brevemente descreve o funcionamento do PDBS, e uma explicação do processo pode ser encontrada em ARAÚJO et al. (2011). A figura 3.6 ilustra o resultado da aplicação do PDBS em dados de um sensor LIDAR.

A figura 3.6(b) mostra a visualização dos dados coletados por um sensor LIDAR mostrados

Algoritmo 4: pointDistanceSegmentation()

Entrada: V, vetor de distâncias do sensor LIDAR em coordenadas polares (ρ, θ)
Saída: S, vetor de distâncias segmentado pelo número de objetos

1 **início**
2 $c_0 \leftarrow constante$; `/* Valor que define uma pequena imunidade à ruídos de medição */`
3 $c_1 \leftarrow \sqrt{2(1-\cos\alpha)}$; `/*` α `é a variação angular entre 2 feixes consecutivos */`
4 $contador \leftarrow 1$; `/* Inicializa o contador de objetos */`
5 $S[1] \leftarrow 1$; `/* Primeiro ponto recebe a classificação de primeiro objeto */`
6 **para cada** par $(\rho_i, \theta_i) \in V$ **faça**
7 $distancia \leftarrow \sqrt{\rho_i^2 + \rho_{i+1}^2 - 2\rho_i\rho_{i+1}\cos\alpha}$; `/* distância medida entre os dois pontos no objeto */`
8 $D_{th} \leftarrow c_0 + c_1 min(\rho_i, \rho_{i+1})$; `/* Distância máxima para classificar se é ou não o mesmo objeto */`
9 **se** $distancia > D_{th}$ **então**
10 $contador \leftarrow contador + 1$; `/* Aumenta o número de objetos detectados */`
11 **fim**
12 $S[i+1] \leftarrow contador$;
13 **fim**
14 **fim**

na figura 3.6(a). A mesma mostra os dados em azul, os centros de cada objeto de vermelho e a variância desse objeto como elipses pretas.

3.4.1 Detecção de Pedestres

Ainda dentro do tópico de detecção de obstáculos, uma classe desses é considerada uma classe de risco quando se fala em trânsito. Os pedestres são os participantes de tráfego com maior propensão a morte caso sofram um acidente e, por isso, encontrá-los deve ser considerado um item de segurança que não pode tolerar falhas críticas. Deve-se, então, utilizar um classificador adicional para esse tipo de participante do trânsito. Uma das maneiras de realizar essa classificação adicional é utilizar uma câmera juntamente com um sensor LIDAR (ARAÚJO et al. , 2011). A figura 3.7 mostra essa fusão de informações.

Na figura 3.7, as linhas verdes indicam os obstáculos identificados pelo sensor LIDAR, uma vez identificado na imagem as regiões a serem buscadas, faz-se uso de um algoritmo baseado em uma arquitetura de cascata de rejeição cujos classificadores são baseados em *Haar-like Features*, reduzindo o tempo de processamento da imagem e reduzindo o número de falsos positivos do LIDAR (ARAÚJO et al. , 2011).

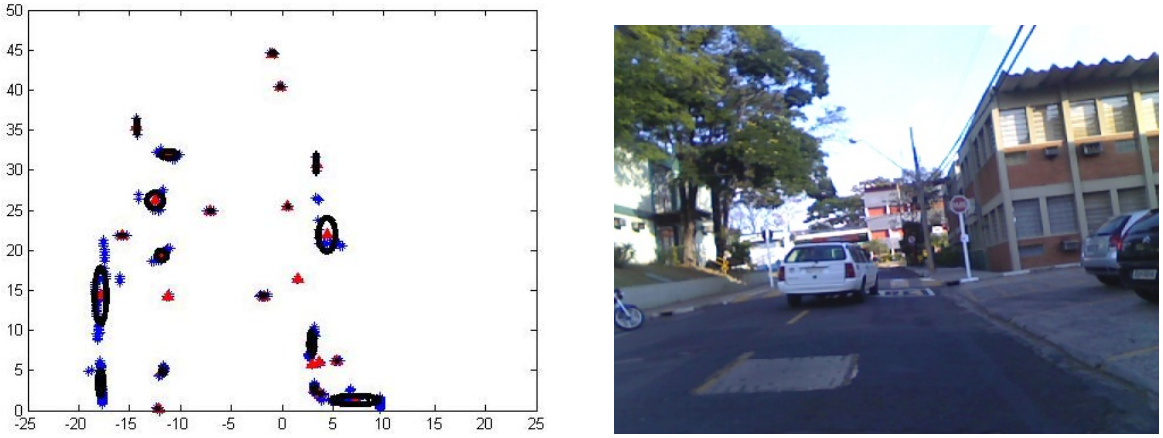

(a) (b)

Figura 3.6: Aplicação do algoritmo PDBS em um dado de sensor LIDAR. (a) Segmentação via o PDBS, asteriscos azuis representam o dado coletado, marcadores triangulares vermelhos indicam o centro esperado do objeto, enquanto as elipses pretas indicam a variância dos dados.(b) Visualização da cena capturada pelo sensor LIDAR.

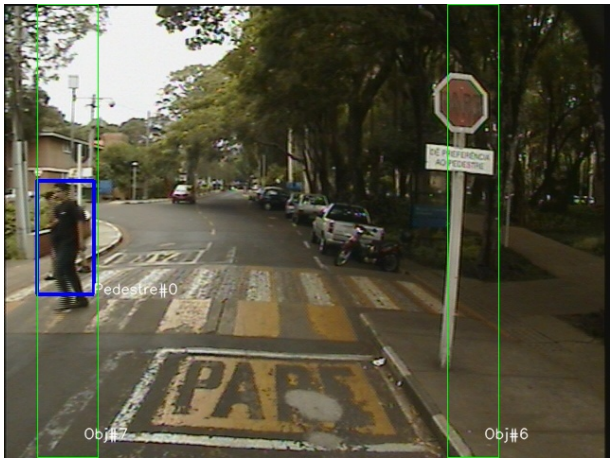

Figura 3.7: Resultado adquirido com a fusão entre as informações do LIDAR e da câmera

3.5 Considerações Finais

Esse capítulo se propôs a mostrar exemplos de algoritmos para coletar as informações vitais a um carro autônomo para o mesmo navegar no ambiente de forma segura. É importante ressaltar que não é o objetivo dessa dissertação implementar e otimizar cada um deles de modo a deixá-los robustos à ruídos e tolerantes à falhas. Entretanto, é válido conhecer como as informações caminham por completo, desde sua aquisição com os sensores até chegar na característica desejada, como demonstrado por esse capítulo.

Capítulo 4

Módulo de Representação

O módulo de representação é a camada intermediária entre os sensores e o módulo de cognição, este último responsável por tomar as decisões em uma arquitetura deliberativa. A representação tem por função traduzir os sinais detectados na percepção, primeiramente os agrupando por similaridade, processo esse chamado de segmentação. Após, descrevem-se os grupos buscando representar cada grupo como um vetor de características, processo chamado de extração de características. Por fim, tais características são designadas a classes distintas, processo chamado de classificação. Este último processo é executado por classificadores e que, devido a estocasticidade do ambiente, podem trabalhar com a probabilidade de um objeto pertencer a uma classe ou outra (DUDA et al. , 2001). As evidências dessas classes, bem como suas crenças, são utilizadas como entrada no módulo de cognição dessa dissertação, que é uma Rede Bayesiana.

A seguir são apresentados os classificadores utilizados nessa dissertação.

4.1 Classificadores

4.1.1 Estimação do Estado Interno e Localização

No caso da estimação do estado interno, a localização em um mapa conhecido permite realizar algum tipo de classificação *a posteriori*. Os mapas podem adquirir diversos tipos de representações, cada qual mais apto a atender determinadas funções (SIEGWART et al. , 2011). Dentre os modelos de mapas, pode-se afirmar que os mapas híbridos são os mais adequados à hipótese dessa dissertação. Pois são os mapas que usam as vantagens de um mapa métrico bem como as vantagens de um mapa topológico (BUSCHKA E SAFFIOTTI , 2004).

Segundo BUSCHKA E SAFFIOTTI (2004), pode-se definir um mapa híbrido como um par $H =< \mathcal{M}, \mathcal{C} >$, onde H é o mapa híbrido, $\mathcal{M}$ é o conjunto definido por $\mathcal{M} = \{T, M_1, M_2, ..., M_n\}$, onde T representa o mapa topológico, M_i é o i-ésimo mapa métrico e $\mathcal{C}$ contém as ligações entre os mapas. No caso em questão, cada nó k de T conecta-se com um mapa métrico M_k. Desse modo, pode-se montar o mapa híbrido como mostra a figura 4.1.

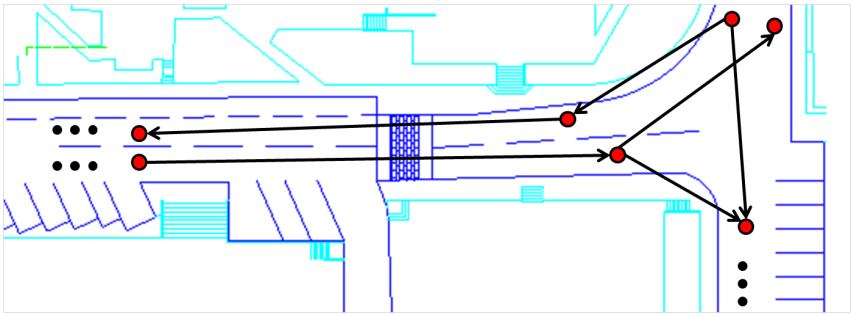

Figura 4.1: Detalhe do mapa híbrido de uma região do campus 1 da USP - São Carlos próxima ao Departamento de Engenharia Mecânica.

A figura 4.1 ilustra uma pequena parcela do mapa híbrido construído do campus 1 da USP - São Carlos. Como elucidado no capítulo 2, o mapa do campus é um mapa do tipo GIS e desse modo, pode-se extrair as informações de distância e geometria das ruas, como em um mapa métrico. Mais, cada nó em vermelho na figura 4.1 representa um nó do mapa topológico construído segundo as hipóteses também esclarecidas no capítulo 2.

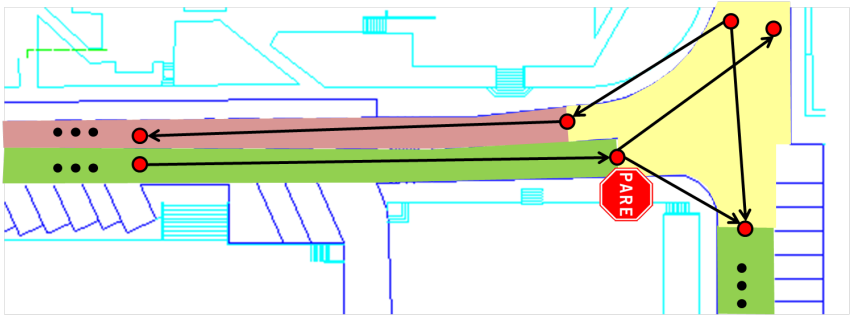

Figura 4.2: Exemplo de mapa métrico local.

O mapa topológico usa como estrutura de dados o grafo, e, em específico para o caso utilizado, um grafo direcional. A escolha desse último tipo de estrutura de dados deve ao fato da necessidade de deixar explícito os sentidos das pistas de rolamento de cada via. Por fim, podem-se criar mapas como os apresentados em KASTNER et al. (2011) e como mostra a figura 4.2.

Usam-se as regras de trânsito (circulação pelo lado direito da via) mais as informações extras

do GIS para compor o mapa da figura 4.2. A mesma mostra as pistas de rolamento corretas para o tráfego em verde, se for suposto que o carro autônomo encontra-se à esquerda do mapa com direção ao cruzamento. Em vermelho, por consequência, estão as pistas cuja direção de fluxo é contrária a desejada pelo veículo, tornando-se assim, proibitivo seu tráfego naquela região. Pode-se ainda notar que as informações de controle de fluxo, como a placa de *Parada Obrigatória*, está destacada ao lado da intersecção em amarelo. Esse mapa é futuramente dividido em submapas de modo a atender o pré-requisito da construção de mapas híbridos acima citados.

Com o conhecimento do mapa, o carro autônomo pode estimar sua localização, encontrando e acompanhando o nó k no qual está e, por conseguinte, o mapa M_k. No mapa métrico M_k pode-se comparar o vetor de estimação do estado interno do robô. Uma vez localizado, uma classificação baseada nas informações do mapa pode ser feita.

Dado o controle de fluxo oriundo do GIS e a hipótese dessa dissertação de vias de mão dupla, com uma pista de rolamento para cada sentido, como elucidado no capítulo 2, a localização do carro pode ser dividida em *pista à direita*(*right_lane*), *pista à esquerda*(*left_lane*), *curva à direita*(*right_turn*) e *curva à esquerda*(*left_turn*).

Ainda mais, pode-se classificar a estrutura da rua na qual o carro trafega, sendo assim, pelas hipóteses dessa dissertação tem-se: *via reta*(*straight*), *junção de entrada*(*junction_in*), *junção de saída*(*junction_out*), *curva à direita*(*right_turn*) e *curva à esquerda*(*left_turn*).

Por fim, pode-se usar a classificação da estrutura da rua na rota que o carro deve percorrer. Segundo a hipótese elucidada no capítulo 2, há pontos de rota perto das bifurcações ou junções e no meio de vias. Desse modo, as classes para os pontos de rota são *via reta*(*straight*), *junção de entrada*(*junction_in*) e *junção de saída*(*junction_out*).

4.1.2 Detecção de Sinalização Horizontal

Uma vez classificada a localização oriunda do módulo de estimação do estado interno, pode-se ter redundância nas informações, quanto à localização, usando o detector de sinalização horizontal. Para tanto, precisa-se descrever a imagem detectada, como apresentado pela figura 3.2 no capítulo 3, e compará-la com algum modelo. Normalmente os modelos das vias são feitos considerando a visão superior das mesmas, e para essa comparação poder ser realizada, a imagem segmentada deve passar por um processo de retirada da perspectiva, chamada de Mapeamento Inverso da Perspectiva ou *Inverse Perspective Mapping (IPM)* (KURDZIEL , 2008).

Uma premissa para esse mapeamento funcionar adequadamente é o conhecimento dos parâmetros internos da câmera (como o foco) bem como seus parâmetros externos (como sua posição no carro). Tais parâmetros podem ser adquiridos graças à um processo de calibração, como brevemente descrito por SIEGWART et al. (2011). Após a calibração da câmera, o algoritmo de IPM pode ser aplicado, como mostrado em KURDZIEL (2008). A figura 4.3 mostra o resultado do IPM sobre a imagem segmentada.

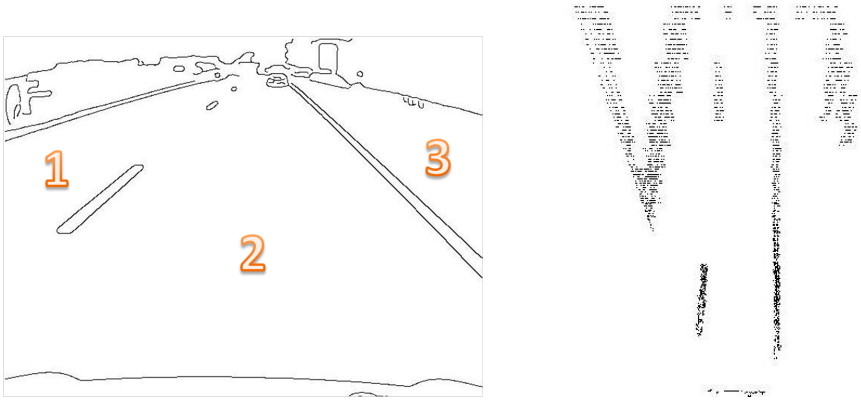

(a) (b)

Figura 4.3: Aplicação do algoritmo IPM. (a) Imagem segmentada pelo detector de bordas de canny.(b) Imagem após o Mapeamento Inverso da Perspectiva (IPM).

Pode-se ver ainda que na figura 4.3(a), há 3 pistas de rolamento, as quais devem ser identificadas pelo algoritmo em questão. Se uma assinatura horizontal da imagem for feita, podem-se extrair informações da estrutura da via. Esse tipo de representação pode ser feita usando um histograma como mostra a figura 4.4 (KURDZIEL , 2008).

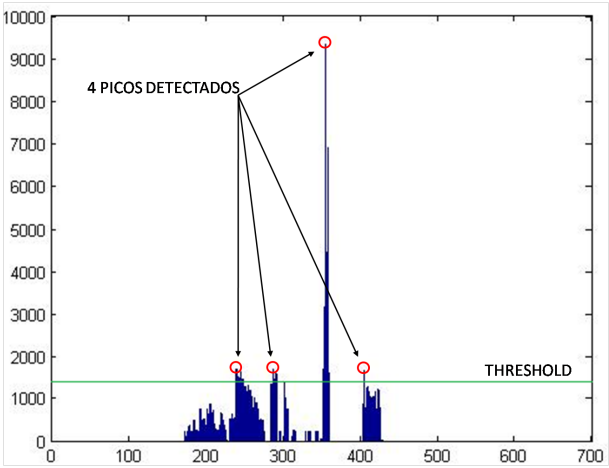

Figura 4.4: Assinatura horizontal da figura 4.3(b)

Segundo KURDZIEL (2008), se for aplicado um *threshold* para eliminar ruídos e executado

um algoritmo para detecção de máximos locais no histograma, ter-se-á uma combinação das pistas de rolamento. No caso da imagem teste mostrada em 4.3(a), o histograma detectou 4 pontos de máximos locais, condizendo com as 3 pistas do teste. No caso dessa dissertação, o número de combinações máximas esperado é 3 (3 faixas detectadas).

Com isso pode-se estimar a localização do veículo baseado na probabilidade das bordas da pista de rolamento, nas métricas de quão longe do tamanho padrão está a pista, quão longe está o centro da pista com o centro óptico da câmera e o quão longe está a nova pista detectada com relação a detectada anteriormente no tempo (KURDZIEL , 2008).

A pista candidata com maior probabilidade é selecionada e então classificada entre *pista à direita*(*right_lane*), *pista à esquerda*(*left_lane*) e *Não Reconhecida*(*Don't Know*). Esta última classe é ativada caso não haja sinalização horizontal discernível na via.

4.1.3 Detecção de Vias Transitáveis

Em adição à detecção de sinalização horizontal na pista, pode-se obter redundância de informações na estimação da geometria da rua usando a detecção de vias navegáveis. Uma vez detectada tal área com o crescimento de região (ver figura 4.5(a)), faz-se o IPM (KURDZIEL , 2008) na região detectada como mostra a figura 4.5.

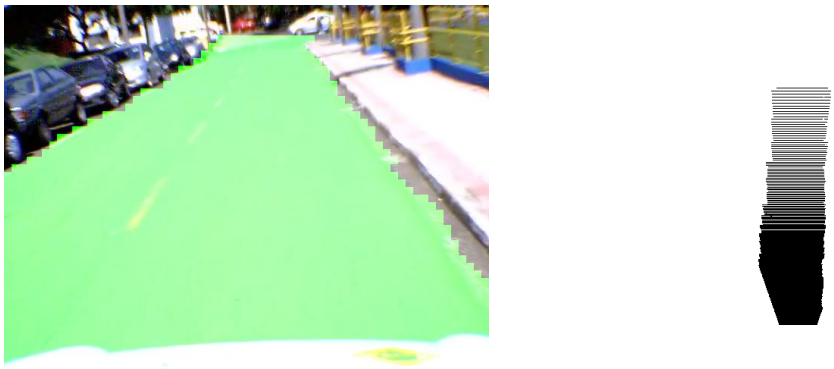

(a) (b)

Figura 4.5: Aplicação do algoritmo IPM. (a) Imagem segmentada pelo crescimento de regiões. Em (b) tem-se a imagem após o Mapeamento Inverso da Perspectiva (IPM).

Como descritores para as regiões podem-se usar os momentos centrais de inércia, também conhecidos como momentos centrais de segunda ordem como mostram as equações 4.1 a 4.3 (GONZALEZ et al. , 2003).

$$\mu_{20} = m_{20} - \bar{x}m_{10} \tag{4.1}$$

$$\mu_{02} = m_{02} - \bar{y}m_{01} \tag{4.2}$$

$$\mu_{11} = m_{11} - \bar{y}m_{10} \tag{4.3}$$

Onde:

$$\bar{x} = \frac{m_{10}}{m_{00}} \tag{4.4}$$

$$\bar{y} = \frac{m_{01}}{m_{00}} \tag{4.5}$$

$$m_{pq} = \sum\sum x^p y^q f(x,y) \tag{4.6}$$

$$f(x,y) = \begin{cases} 1 & \text{se} \quad (x,y) \in \textit{Região} \\ 0 & \text{caso contrário} \end{cases} \tag{4.7}$$

Os momentos centrais de segunda ordem são definidos por μ_{20}, μ_{02} e μ_{11}, que são respectivamente, o momento central de inércia em x, o momento central de inércia em y e o produto central de inércia. Tem-se que m_{pq} é o momento de ordem $p+q$ discreto e $f(x,y)$ é a função definida pela imagem da região segmentada. Por fim, $\bar{x}$ e $\bar{y}$ são os centros de massa, respectivamente, em x e em y.

Devido os altos valores calculados, busca-se uma normalização para se obter valores com *ranges* mais limitados. Como apresentado por GONZALEZ et al. (2003), pode-se normalizar os momentos de ordem $p+q$ pela equação 4.8.

$$\eta_{pq} = \frac{\mu_{pq}}{m_{00}^{\gamma}} \tag{4.8}$$

Onde γ é igual a $(p+q)+1$ e m_{00} é a área da região detectada. Desse modo, pode-se calcular os momentos centrais normalizados para os modelos propostos para essa dissertação,

como mostra a tabela 4.1

Tabela 4.1: Momentos centrais normalizados de segunda ordem calculados para os modelos de vias utilizados na dissertação

Cenário	η_{20}	η_{02}	η_{11}
Via Reta	$0,0291$	$0,2544$	$-0,0111$
Junção em T	$0,0634$	$0,1415$	$0,0149$
Curva à esquerda	$0,0735$	$0,3015$	$0,1218$
Curva à direita	$0,0602$	$0,2758$	$-0,0945$

Os dados calculados na tabela 4.1 foram obtidas a partir de imagens modelos capturadas em teste. Estas foram obtidas através de capturas específicas dos cenários em questão e aplicadas à transformada IPM. Desse modo, um conjunto de vetores de características de 3 dimensões foi obtido e com esse conjunto treinou-se um classificador do tipo *Naive Bayes*. Tal classificador assume a independência entre as características para determinar a probabilidade *a posteriori* da classe, juntamente com o teorema de *Bayes*, como mostra a equação 4.9 (DUDA et al. , 2001).

$$p(w_j|a_1, a_2, a_3) = \frac{p(a_1, a_2, a_3|w_j)p(w_j)}{p(a_1, a_2, a_3)} = \frac{p(w_j)\prod p(a_i|w_j)}{\sum p(w_j)\prod p(a_i|w_j)} \tag{4.9}$$

A análise dos dados dos modelos da tabela 4.1 permite a definição de alguns *ranges* para os valores dos momentos centrais de inércia como uma medida de tentar reduzir a variância intraclasses, como mostra a tabela 4.2.

Tabela 4.2: Momentos centrais normalizados de segunda ordem calculados para os modelos de vias da dissertação com os ranges definidos

Cenário	η_{20}	η_{02}	η_{11}		
	I	**II**	**III**	**IV**	**V**
Via Reta	1	0	0	1	0
Junção em T	0	1	0	1	0
Curva à esquerda	0	0	0	0	1
Curva à direita	0	0	1	0	0

Onde no *range* I estão os valores menores ou iguais a $0,04$, no *range* II estão os valores menores ou iguais a $0,17$, no *range* III estão os valores menores que $-0,05$, no *range* IV estão os valores entre $-0,05$ e $0,05$, inclusive. Por fim, no *range* V estão os valores maiores que $0,05$.

Cada classe agora apresenta um vetor de características com 5 parâmetros os quais podem ser 1 (*verdadeiro*) ou 0 (*falso*), e com um processo simples de contagem, pode-se treinar o classificador *Naive Bayes*. Desse modo, pode-se, enfim, classificar a geometria da rua como *via reta*(*straight*), *junção*(*junction*), *curva à direita*(*right_turn*) ou *curva à esquerda*(*left_turn*).

4.1.4 Detecção de Obstáculos e Pedestres

Podem-se, agora, classificar os obstáculos detectados, tanto carros quanto pedestres, cada qual com uma prioridade. Tais obstáculos serão analisados no plano de movimento do veículo, pois esse permite a inferência sobre possíveis colisões.

Uma vez detectados os obstáculos, deve-se manter uma estimativa de suas posições, bem como de suas velocidades no referencial do carro. Se for utilizado um filtro de Kalman, como descrito pelo algoritmo 1 no capítulo 3, pode-se acompanhar cada objeto detectado e mais, pode-se estimar sua respectiva velocidade (BECKER et al. , 2009). Desse modo, usar-se-á como descritor para os obstáculos o vetor $[x\ y\ \dot{x}\ \dot{y}]^T$.

Segundo WERLING et al. (2008), pode-se determinar o risco de colisão segundo algumas hipóteses simplificadoras e cálculos de cinemática de robôs móveis. A figura 4.6(a) ilustra como pode-se modelar o problema e a figura 4.6(b) ilustra o caso genérico a ser considerado.

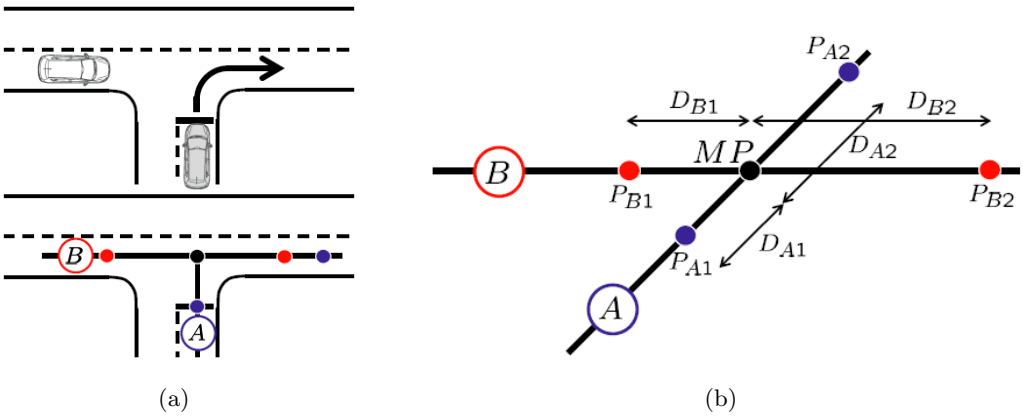

Figura 4.6: Método para tratar os movimentos entre obstáculos. Adaptado de WERLING et al. (2008). (a) Cruzamento e seu modelo.(b) Modelo genérico para tratar o movimento entre objetos dinâmicos

Vê-se na figura 4.6(a) que um cenário de junção em T pode ser modelado como o caso genérico apresentado em 4.6(b), com as ressalvas de que, antes da intersecção das retas, as mesmas são perpendiculares e, após a intersecção, elas são coincidentes. Um olhar mais clínico à figura 4.6(b) permite a visualização de alguns parâmetros importantes para a segurança do veículo. Tais parâmetros precisam ser testados e ajustados até que o critério de segurança seja satisfeito. As considerações a serem feitas residem em duas ideias principais, a primeira de que o veículo A deve passar do ponto de segurança P_{A1} até o ponto P_{A2} antes que o veículo B chegue ao ponto P_{B1}. A segunda refere-se ao veículo B, este deve sair de P_{B1} e chegar a P_{B2} antes que A chegue em P_{A1}. Somente quando todas as condições forem satisfeitas, o veículo A pode

trafegar com segurança. Qualquer outra combinação de casos, haverá uma colisão nesse cenário, e portanto, o carro autônomo deve ser informado.

Uma última consideração a ser feita reside na escolha da prioridade dos veículos, ou participantes de trânsito se forem considerados nesse cenário os pedestres. A prioridade deve ser dada aos veículos em vias preferenciais e sempre aos pedestres. No caso dos veículos, a prioridade deve ser considerada em caso de tempos muito justos para a entrada na intersecção. Por questões de segurança, será determinado ao veículo autônomo sempre esperar em situações nas quais uma análise de prioridade deva ser feita. Entretanto, esse comportamento pode ser adaptado conforme a personalidade do motorista, se o mesmo se mostrar impaciente a espera (POLLATSCHECK et al. , 2002).

Isso posto, pode-se classificar os cenários como *via livre*(*freeRoad*) ou como *colisão*(*colision*).

4.2 Considerações Finais

Esse capítulo mostrou algumas técnicas utilizadas a fim de transformar os dados adquiridos na camada de percepção e prepará-los para o módulo de cognição, o qual usa classes discretas como entrada.

Reforça-se que não é o objetivo dessa dissertação implementar e testar a robustez de cada algoritmo apresentado cabendo a outros membros do projeto SENA realizar o mesmo. Por fim, um resumo dos classificadores pode ser visto na tabela 4.3.

Tabela 4.3: Sumário dos classificadores utilizados nessa dissertação

Módulo	**Sensores**	**Classes**
Localização	GPS e IMU	*pista à direita*, *pista à esquerda*, *curva à direita*, *curva à esquerda*
Localização	Câmera	*pista à direita*, *pista à esquerda*, *Não Reconhecida*
Geometria da via	GPS e IMU	*via reta*, *junção de entrada*, *junção de saída*, *curva à direita*, *curva à esquerda*
Geometria da via	Câmera	*via reta*, *junção*, *curva à direita*, *curva à esquerda*
Rota	GPS	*via reta*, *junção de entrada*, *junção de saída*
Colisão	Velodyne e ibeo LUX	*via livre*, *colisão*

Capítulo 5

Módulo de Cognição

O módulo de cognição é o módulo responsável por tomar as decisões de um sistema robótico e informá-lo como agir. Existem muitos tipos de algoritmos os quais podem ser usados para esse fim, cada qual mais adequado a algumas características do ambiente do que outras. O conhecimento do domínio da aplicação é fundamental para o sucesso ou o fracasso do projeto de um sistema inteligente (RUSSEL E NORVIG , 2010).

No caso de carros autônomos, pode-se dizer que o ambiente é parcialmente observável, ou seja, nem sempre o veículo tem acesso a todas as informações do ambiente. Pode-se dizer também que o ambiente é estocástico, pois não é possível determinar completamente o seu estado futuro, dado o estado atual, ou seja, há situações imprevisíveis. Por fim, pode-se dizer que o ambiente também é dinâmico, no sentido de que o mesmo muda sua estrutura com o tempo, pois pode apresentar objetos móveis (RUSSEL E NORVIG , 2010).

Há vários meios de tratar essas incertezas, entretanto a ferramenta mais empregada nessas situações é a probabilidade, e, dentre os agentes probabilísticos, pode-se citar em destaque as Redes Bayesianas.

5.1 Revisão Teórica

As Redes Bayesianas são mecanismos representacionais capazes de sintetizar o conhecimento de uma determinada aplicação de forma coerente. Pode-se separar essa síntese em duas componentes: a qualitativa e a quantitativa.

A primeira refere-se à estrutura da rede. Esta é vista como um grafo acíclico direcional,

em inglês *Direct Acyclic Graph* (DAG), cujos nós são as variáveis do domínio do problema e as arestas mostram as informações de dependência entre as mesmas. A segunda refere-se ao uso da probabilidade para quantificar a conexão ou dependência entre as variáveis. Essas características trazem a vantagem de não existirem a necessidade de calcular a probabilidade conjunta de duas variáveis se as mesmas não estiverem conectadas (DARWICHE , 2009).

A construção de uma Rede Bayesiana pode ser feita através de 3 metodologias distintas. A primeira deriva o modelo estrutural ou DAG via o conhecimento de especialistas do domínio. Também é possível extrair as tabelas de probabilidades condicionais, em inglês *Conditional Probability Table* (CPT), item quantificador de um nó da Rede Bayesiana, com o conhecimento do especialista sobre a frequência em que ocorrem os casos na rede. Para facilitar a compreensão do leitor, suponha uma Rede Bayesiana sobre a relação entre a gripe e os possíveis sintomas. Um médico poderá dizer que os efeitos da gripe são dor-de-garganta e febre e que, segundo estatísticas, $87,5\%$ dos casos de gripe apresentam febre e em 75% dos casos há dor-de-garganta. A figura 5.1 mostra uma ilustração do modelo que representa essa situação.

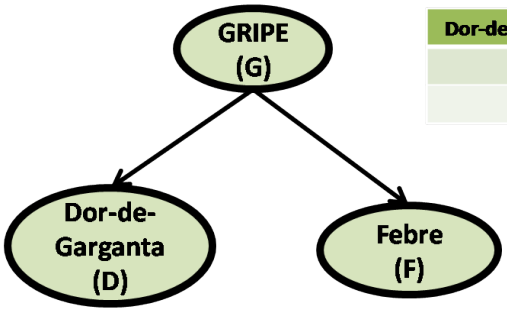

Dor-de-Garganta (D)	P(D|G = SIM)	P(D|G = NÃO)
SIM	0,75	0,25
NÃO	0,25	0,75

FEBRE (F)	P(F|G = SIM)	P(F|G = NÃO)
SIM	0,875	0,125
NÃO	0,125	0,875

Figura 5.1: Exemplo de uma Rede Bayesiana. Estrutura DAG e suas respectivas CPTs. Adaptado de DARWICHE (2009).

O segundo método extrai o DAG via o conhecimento representado formalmente, podendo através dele encontrar tanto a relação estrutural de *causa-efeito* quanto as CPTs do modelo. Usando o exemplo da gripe, um engenheiro de conhecimento (REZENDE , 2003), que trabalhe com o domínio em questão, poderia ter definido as seguintes proposições sobre o problema:

$$\textbf{Se}\, G = SIM \Rightarrow P(F = SIM) = 0,875$$

$$\textbf{Se}\, G = SIM \Rightarrow P(D = SIM) = 0,75$$

O que resultaria na mesma estrutura apresentada na figura 5.1.

Por fim, pode-se aprender a estrutura e/ou as CPTS da rede via exemplos usando, por exemplo, abordagem de máxima verossimilhança, que busca encontrar uma rede e/ou suas probabilidades que maximizem as chances de encontrar o caso de testes apresentado. No caso da gripe em questão, poderia-se ter uma lista de casos como mostra a tabela 5.1

Tabela 5.1: Tabela emulando uma lista de casos possíveis que servirão de dados de entrada para o aprendizado da Rede Bayesiana. Adaptado de DARWICHE (2009).

# Caso	**GRIPE**	**FEBRE**	**DOR-DE-GARGANTA**
1	SIM	SIM	SIM
2	SIM	SIM	SIM
3	SIM	SIM	NÃO
4	SIM	SIM	SIM
5	SIM	SIM	SIM
6	SIM	NÃO	SIM
7	SIM	SIM	SIM
8	SIM	SIM	NÃO

E o resultado do algoritmo de aprendizado seria o apresentado pela figura 5.1. Como será elucidado mais a frente, a estrutura DAG usada nesta dissertação foi feita através do conhecimento de especialista. Entretanto, as CPTs utilizadas foram feitas tanto por extração de conhecimento do especialista como também foram aprendidas via dados apresentados.

Uma vez modelada a Rede Bayesiana, deseja-se inferir algumas proposições, responder perguntas sobre o domínio do problema. Dentre os possíveis meios de realizar a inferência na rede, pode-se citar como pergunta mais comum o cálculo de probabilidades marginais *a priori* e *a posteriori*.

Pode-se entender por probabilidade marginal a projeção da probabilidade conjunta de n variáveis em um grupo menor de m variáveis (DARWICHE , 2009). Quando a projeção é feita sem nenhuma evidência, ela é dita ser *a priori*. No exemplo da gripe da figura 5.1, pode-se perguntar qual a probabilidade *a priori* de uma pessoa ter gripe. No caso em questão, o nó G não possui pais e, desse modo, sua probabilidade marginal *a priori* é a mesma que a sua própria, por exemplo, $0,4$ para o caso de uma pessoa estar com gripe e $0,6$ para o caso contrário.

Entretanto, pode-se fazer a mesma pergunta após ter-se verificado os sintomas da pessoa em questão. Quando faz-se a projeção da probabilidade conjunta dado um conjunto de evidências, chama-se de probabilidade marginal *a posteriori*. No exemplo, se o paciente estiver com febre e dor-de-garganta, tem-se que a probabilidade *a posteriori* do mesmo apresentar gripe é de $0,933$.

Os algoritmos para calcular tais probabilidades podem ser divididos em exatos ou aproximados. Os primeiros obtêm respostas mais precisas a custo do tempo de processamento, enquanto o segundo busca diminuir o custo computacional em detrimento da precisão da resposta obtida. Existem vários métodos na literatura para realizar tanto um método quanto outro e ambos podem ser melhor analisados em DARWICHE (2009) e RUSSEL E NORVIG (2010).

Redes Bayesianas, como a apresentada na figura 5.1, trabalham com domínios estáticos, ou seja, as análises são feitas sem considerar o efeito do tempo. Se o domínio estudado for de característica dinâmica, como é o caso desta dissertação, a desconsideração do efeito do tempo no problema pode gerar inferências errôneas.

Entretanto, este problema pode ser contornado se um modelo de transição do ambiente for feito. Desse modo, as inferências podem evoluir com o tempo. Em adição a isto, as observações no tempo t juntamente com o modelo dos sensores ajudam a manter as atualizações nas crenças da rede (RUSSEL E NORVIG , 2010).

Formalmente, o modelo de transição pode ser descrito como $P(\mathbf{X}_t|\mathbf{X}_{0:t-1})$, onde $\mathbf{X}_t$ é o estado atual e $\mathbf{X}_{0:t-1}$ são todos os estados anteriores. Para evitar que $\mathbf{X}_{0:t-1}$ cresça infinitamente, usa-se a hipótese de Markov que afirma que o estado atual depende de um número limitado de estados anteriores. Tem-se, então, $P(\mathbf{X}_t|\mathbf{X}_{0:t-1}) = P(\mathbf{X}_t|\mathbf{X}_{t-k:t-1})$. Já o modelo das observações ou modelo dos sensores pode ser escrito como $P(\mathbf{E}_t|\mathbf{X}_t)$, assumindo o modelo Markoviano (RUSSEL E NORVIG , 2010).

A rede Bayesiana que leva em consideração os estados anteriores de uma ou mais variáveis é dita Rede Bayesiana Dinâmica, em inglês *Dynamic Bayesian Networks* (DBN), como mostra a figura 5.2.

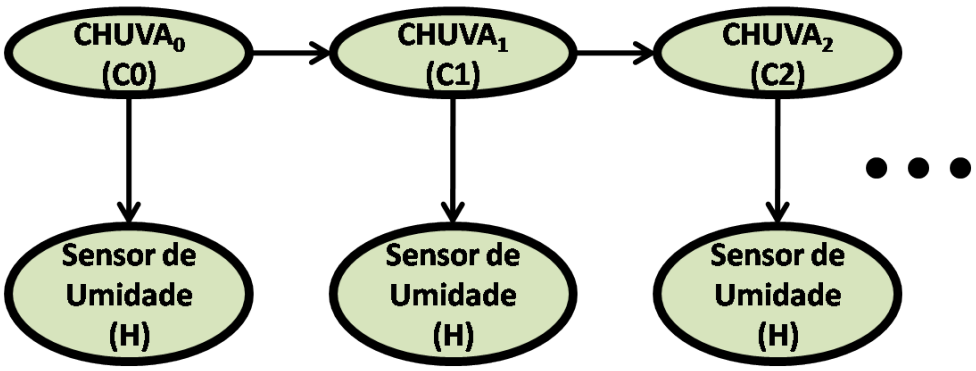

Figura 5.2: Exemplo de uma Rede Bayesiana Dinâmica. Adaptado de RUSSEL E NORVIG (2010)

O exemplo mostrado na figura 5.2 é uma simplificação de um modelo hipotético de previsão de tempo usando apenas um sensor de umidade para facilitar o entendimento do leitor. No caso em questão, a crença de que vai chover no dia t é apenas influenciada se choveu no dia anterior e pela observação feita pelo sensor de umidade.

Se agora for considerado o domínio de veículos autônomos, pode-se citar alguns trabalhos que empregaram a teoria probabilística para resolver o problema como GINDELE et al. (2010), LEFÈVRE et al. (2011), LAUGIER et al. (2011) e SCHUBERT E WANIELIK (2011).

Segundo GINDELE et al. (2010), há a necessidade de se entender o contexto do trânsito para um veículo autônomo conseguir dirigir por um longo período de tempo. Para isso, abordam este tema como um problema de filtragem de tempo discreto e, com isso, usam uma DBN como um filtro.

Esta rede usa as informações estimadas dos veículos identificados e o contexto do ambiente na forma de métricas, como a distância lateral do veículo à faixa da pista. Assim, essas informações são empregadas para inferir qual o tipo de situação o carro se encontra, como por exemplo, a probabilidade de definir a proximidade de um veículo dada a distância medida estar *longe* ou *perto*. Essas variáveis influenciam o comportamento que o veículo deve ter e, por consequência, a trajetória a ser percorrida.

Em testes feitos em cenários de rodovia, o acerto dessa técnica variou de $87,5\%$ a $91,7\%$ devido ao nível de ruído nas observações dos estados, com o desvio padrão variando de $0,25$ a $0,05$ respectivamente.

Segundo LEFÈVRE et al. (2011), não considerar as interações dos veículos na predição da manobra do carro autônomo, ou seja, considerar, por hipótese, a independência entre as rotas dos veículos, produz falsos positivos em um sistema ADAS. Para cenários de intersecção de vias, informações do contexto do trânsito se fazem necessárias.

O problema foi abordado com uma Rede Bayesiana que usa as informações do curso a ser seguido pelos veículos na intersecção, as poses dos mesmos no mapa e a distância deles a pontos previamente modelados em um mapa digital. Esses pontos representam as posições onde os carros fazem a "negociação" com os outros para atravessar a intersecção. Usam também um nó determinístico para realizar a consistência entre a intenção de um veículo em deixar outro passar na intersecção com a necessidade de fazê-lo, por segurança. Estes influenciam a inferência da cena e a ação a ser tomada. Essa variável em específico tem sua CPT feita a partir de modelos probabilísticos do comportamento dos motoristas como a aceitação dos *gaps* (ver definição no

capítulo 2) e padrões de frenagem.

Segundo LAUGIER et al. (2011), para um sistema ADAS realizar uma predição probabilística é necessário o uso do contexto do trânsito. Além disso, um sistema ADAS deve fornecer respostas mais rápidas que um motorista humano, havendo, assim, a necessidade de algoritmos eficientes e rápidos.

Usando 2 sensores ibeo LUX e uma câmera estéreo, os autores construíram um gride para o veículo e usaram um filtro de ocupação bayesiano (*Bayesian Occupancy Filter* ou BOF) para realizar a fusão dos dados. Cada célula do gride filtrado possui a probabilidade em estar ocupado juntamente com a velocidade com a qual se move. O mesmo serve de entrada para um algoritmo de rápido agrupamento e acompanhamento (*Fast Clustering and Tracking Algorithm* ou FCTA) cujo objetivo é encontrar os objetos móveis no cenário. Boa parte desses algoritmos foram processados na placa de vídeo, em inglês *Graphics Processing Unit* (GPU), do computador para obterem maior velocidade.

A inferência sobre o comportamento dos veículos foi feita com o uso de uma cadeia escondida de Markov (*Hidden Markov Models* ou HMM) em dois níveis. A camada de nível mais baixo possuía HMMs para cada tipo de manobra modelado, e as variáveis ditas não-observáveis representam a evolução temporal de cada manobra e seus observadores recebem os dados do FCTA.

Cada tipo de manobra atualiza sua crença e o vetor contendo todas essas crenças serve como observador para a HMM de nível mais alto, cuja variável escondida é o comportamento do veículo. Cada comportamento possui uma trajetória correlata e cada trajetória passa por um processo de representação probabilística a fim de modelar a evolução do veículo dada a rota. Esse modelo, por fim, é usado para verificar se 2 ou mais veículos estão em rota de colisão. Em uma análise feita em cenário de rodovia, 4 comportamentos foram testados, *seguir na pista*, *virar à esquerda*, *virar à direita* e *realizar uma ultrapassagem* e o algoritmo foi capaz de identificar corretamente $91,9\%$, $81,1\%$, $82,5\%$ e $61,6\%$, respectivamente enquanto que o algortimo para análise de colisão se provou eficiente em ambiente simulado.

Segundo SCHUBERT E WANIELIK (2011), uma ligação mais direta deve ser feita entre os filtros probabilísticos da percepção (como filtros de Kalman ou filtros de histograma) e a Rede Bayesiana no módulo de cognição. Essa ligação é feita através de nós de verossimilhança adaptativa.

O nó de verossimilhança define a probabilidade $P(x|\mathbf{X})$, onde x é uma métrica ou propriedade

definida e **X** a classe relacionada a um intervalo de x. A ideia é deixar o intervalo com fronteiras probabilísticas (baseadas em modelos gaussianos) dependentes da variância σ_x^2. Testes foram feitos em cenários de rodovias, em que um algoritmo de acompanhamento de veículos e um sistema de reconhecimento de pistas servem de entrada para a Rede Bayesiana. Esta ainda usa nós de utilidade, juntamente com nós de decisão para a escolha do comportamento de manter a faixa, trocá-la para a direita ou trocá-la para a esquerda. Os testes mostraram a rapidez e confiabilidade na decisão. A Tabela 5.2 correlaciona e destaca algumas diferenças e semelhanças entre os trabalhos relacionados e o desenvolvido nesta dissertação.

Tabela 5.2: Tabela comparativa dos trabalhos relacionados

Características	**Entrada**	**Saída**	**Cenário Utilizado**
GINDELE et al. (2010)	*Estimador de estados*	*Trajetória Predita*	*Rodovia*
LEFÈVRE et al. (2011)	*Estimador de estados*	*Trajetória Predita*	*Cidade*
LAUGIER et al. (2011)	*BOF*	*Comportamento*	*Rodovia*
SCHUBERT E WANIELIK (2011)	*Estimador de estados*	*Comportamento*	*Rodovia*
Dissertação	*Classificadores*	*Comportamento*	*Cidade*

O presente trabalho utiliza uma rede bayesiana dinâmica na qual esta leva em consideração as informações do ambiente somente na forma discretizada por classes. Diferentemente dos trabalhos apresentados na literatura, evita-se o uso de métricas e cálculos de trajetórias de forma explícita. Este também usa o cenário de cidades para o teste de comportamento da mesma, sendo o comportamento a saída buscada. Apesar dos módulos de representação e/ou percepção usarem estimadores e métricas para suas classificações, estas não estão modeladas na Rede desenvolvida por essa dissertação, ao contrário dos trabalhos relacionados. Descreve-se, agora, as ferramentas utilizadas para modelar as Redes usadas nessa dissertação.

5.2 Netica

O Netica™ é um *software* desenvolvido pela *Norsys Software Corporation* utilizado comercialmente por empresas como a IDI, *Innovative Decisions, Inc.*, empresa de consultoria sobre análise de risco (IDI , 2012) e a IET, *Information Extraction & Transport*, companhia que desenvolve sistemas especialistas usando essa técnica de Inteligência Artificial (IET , 2012).

A versão completa deste *software* é vendida pela *Norsys*™, entretanto uma versão demo pode ser utilizada gratuitamente. Esta tem limitações quanto ao número de variáveis a serem modeladas. No caso em questão são 15 nós(NORSYS , 2012).

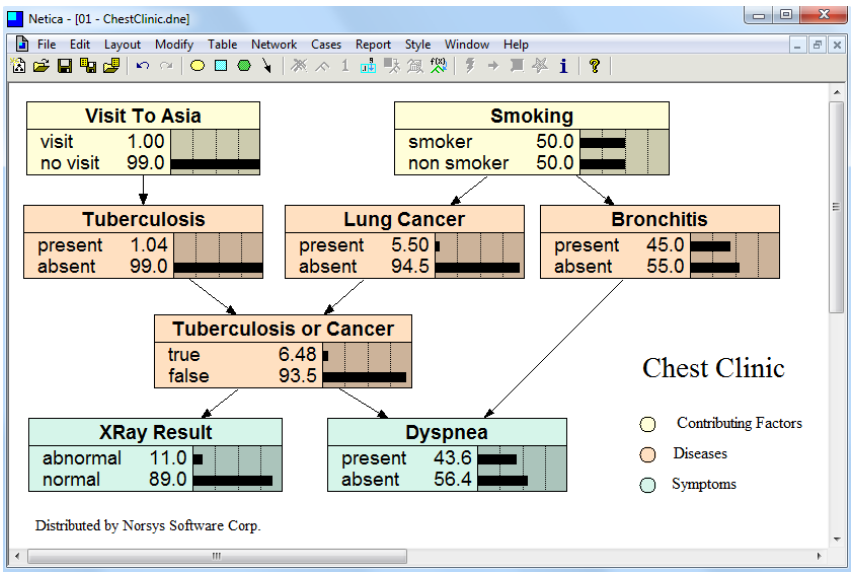

Figura 5.3: Interface com o usuário do *software* Netica™. Na figura vê-se um exemplo de Rede Bayesiana

O Netica™ possui uma API para a linguagem de programação C# de fácil instalação e que utiliza uma interface COM para transmitir os dados do programa de inferência para o programa o qual o usuário está desenvolvendo. Também apresenta uma interface amigável com o usuário, como mostra a figura 5.3.

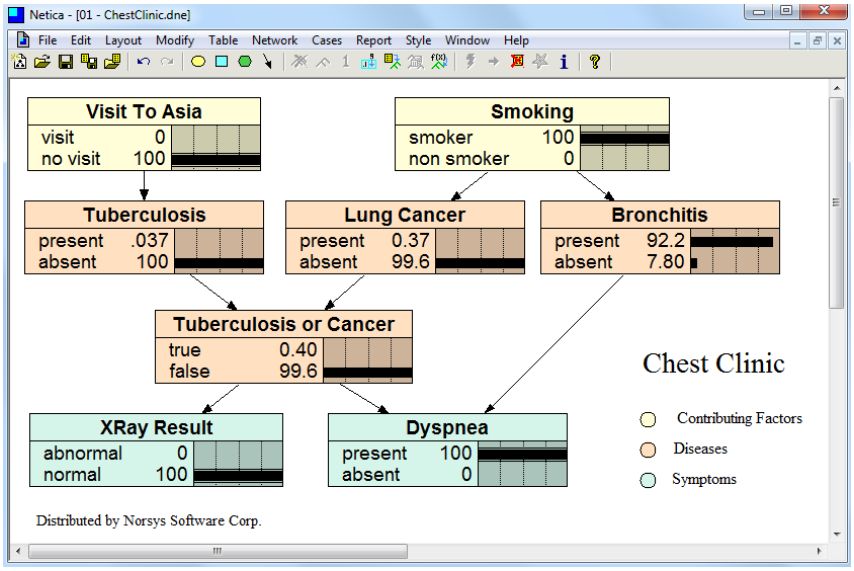

Figura 5.4: Interface com o usuário do *software* Netica™. Na figura, o uso de evidências para realizar a inferência da Rede Bayesiana

Pode-se observar na figura 5.3 um exemplo de Rede Bayesiana que acompanha o *software* em sua instalação, nela, cada nó é uma variável no modelo para análise clínica e cada uma apresenta sua probabilidade marginal *a priori*, as arestas do DAG são facilmente construídas e, assim, ajudam no desenvolvimento da Rede. Por fim, pode-se observar o processo de inferência e interação com o mesmo adicionando ou removendo evidências, como mostra a figura 5.4. Nesta, as evidências de Dispnenia, Raio-X normal, e sabendo que o paciente não visitou a Ásia e é um fumante, tem-se que a doença mais provável seja Bronquite.

O processo de inferência no Netica™ foi feito de modo a otimizar os algoritmos para inferências exatas. No caso em questão, o Netica™ usa uma ordem de eliminação de variáveis juntamente com a construção de uma árvore de junção cujos nós são fatores (um ou um conjunto de variáveis do DAG), transformando assim o DAG em uma estrutura cujo cálculo das probabilidades é feito mais rapidamente. Os algoritmos podem ser vistos em mais detalhes em DARWICHE (2009).

Desse modo, considerando a estabilidade do *software* e algumas vantagens oferecidas, como a integração com programas feitos em C#, optou-se por utilizar o demo dessa ferramenta, mesmo considerando as desavantagens inerentes de usar esse tipo de versão, para a modelagem e testes das Redes Bayesianas desta dissertação.

5.3 Simulador em C#

Como elucidado no capítulo 1, o protótipo de testes GISA está em fase de automação, sendo assim, necessária a construção de um simulador com a finalidade de pôr a prova os algoritmos desenvolvidos. Para isso, optou-se por desenvolvê-lo no ambiente *Microsoft Visual C# 2008*, cuja linguagem é voltada à orientação a objetos e passível de integração com o Netica™.

A figura 5.5 apresenta a interface com o usuário do simulador desenvolvido. Pode-se ver 5 regiões de interesse marcadas de A a E. Em A, encontra-se uma lista de possíveis cenários a serem simulados. Em B, tem-se a leitura do *status* do veículo protótipo, que são a velocidade longitudinal, a aceleração longitudinal e o ângulo de esterçamento da roda. Em C, vê-se um console para interface com o usuário, onde este pode definir alguns valores de esterçamento, velocidade ou aceleração para o veículo protótipo. Em D, encontra-se a saída de cada módulo observado da Rede Bayesiana, a princípio utilizado para verificação do funcionamento da rede por completo, depois usado para mostrar ao usuário o comportamento o qual a rede decidiu,

este último é mostrado na caixa de texto mais acima da caixa D. Por fim, em E tem-se a tela do simulador, no caso da figura 5.5, vê-se o mapa da cidade usado nas simulações.

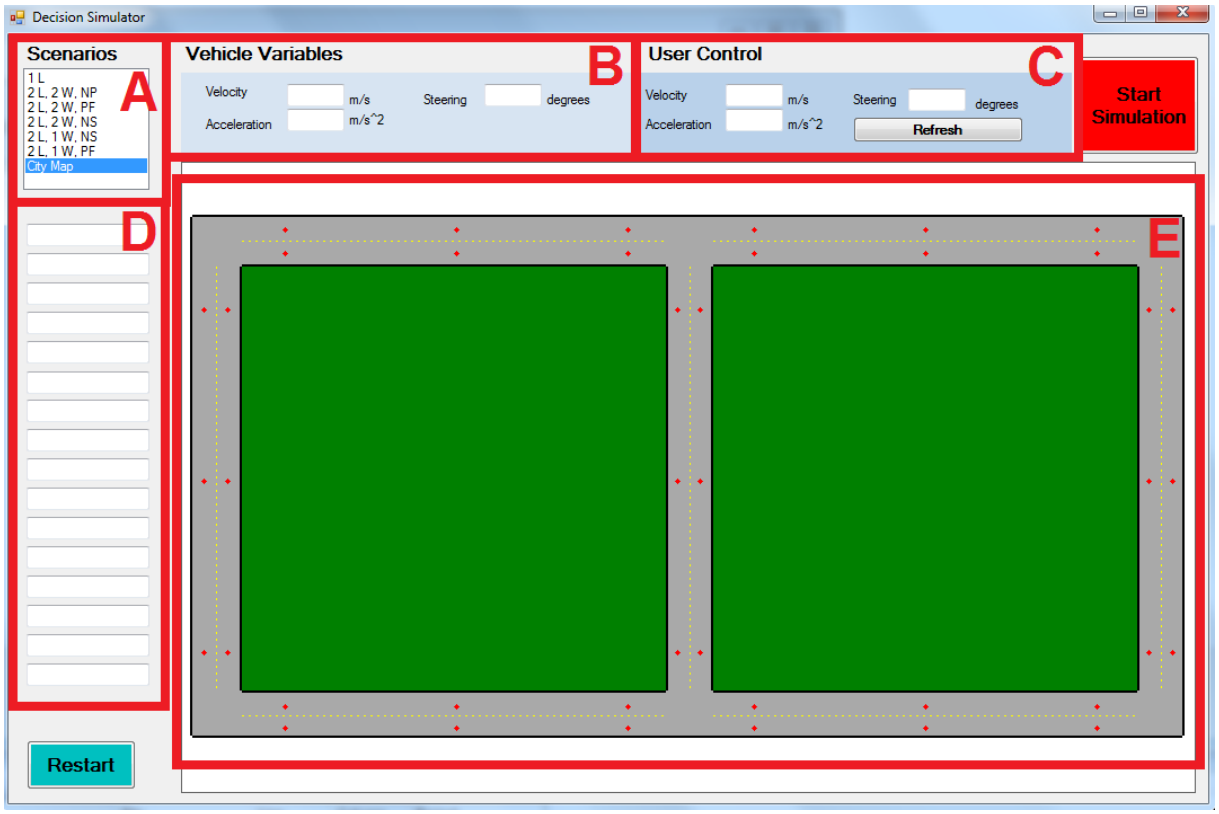

Figura 5.5: Simulador desenvolvido em C#

Em específico, se o mapa da cidade modelado for observado, pode-se reparar que esta atende as hipóteses apresentadas no capítulo 2, como vias de apenas duas pistas de rolamento e pontos de GPS dispostos a 10 metros do cruzamento, por exemplo. Além disso, o modelo cinemático do carro adotado foi o modelo da bicicleta, como apresentado em SIEGWART et al. (2011). Por fim, os classificadores foram emulados via a posição do veículo no mapa. Essa é construída através de uma classe responsável por introduzir ruídos na medição e, assim, desacoplar o ambiente de simulação das entradas simuladas. O modelo dos ruídos considerado foi de uma distribuição gaussiana com média μ na pose medida ($[x\ y\ \theta]$) e o vetor de variância $[\sigma_x\ \sigma_y\ \sigma_\theta]$.

Cada classificador possui atributos que permitem a mudança no nível de interferência dos ruídos na classificação, como brevemente comentado no capítulo 2 e como será elucidado na seção 5.5.

5.4 Modelagem da Rede Bayesiana

Usando as ferramentas citadas em 5.2 e 5.3, considerando as hipóteses simplificadoras do capítulo 2 e, conhecendo o fluxo de informações da percepção, bem como suas classes, pode-se modelar a Rede Bayesiana utilizada nesta dissertação.

Primeiramente, como apontado por GINDELE et al. (2010), LEFÈVRE et al. (2011) e LAUGIER et al. (2011), as informações sobre o contexto do cenário devem contar na escolha do comportamento do veículo. Além disso, segundo LABERGE et al. (2006) há uma sequência de atitudes necessárias para um motorista passar por uma intersecção, dentre elas, detectar um cruzamento, desacelerar, observar o veículo à frente (se houver), detectar veículos se aproximando e seus respectivos *gaps*, aceitar ou não os *gaps* e, por fim, completar a manobra.

No que tange a percepção do cenário, deve-se modelar essa camada de modo que a mesma receba as informações necessárias para que uma decisão seja tomada com segurança. Assim, os nós desse módulo foram definidos como *Posição Atual* (*Actual Position* ou P), cujas classes são *pista à direita*, *pista à esquerda*, *curva à direita* e *curva à esquerda*, *Cenário Atual* (*Actual Scenario* ou C), cujas classes são *via reta*, *junção*, *curva à direita* e *curva à esquerda*, *Pista Futura* (*Future Lane* ou F), cujas classes são *junção de entrada*, *junção de saída* e *via reta*, por fim, *Situação Dinâmica* (*Dynamic Situation* ou D), cujas classes são *colisão* e *via livre*.

As variáveis *Pista Futura* e *Situação Dinâmica* são observadas pelos classificadores descritos em 4.1.1 e 4.1.4, respectivamente. Entretanto, as variáveis *Posição Atual* e *Cenário Atual* são consideradas não-observáveis ou escondidas e seus observadores são *Localização via Câmera* (L) e *Localização via GPS e IMU* (G) para a *Posição Atual* e *Cenário via Visão* (V) e *Cenário via GPS e IMU* (I) para o *Cenário Atual*. A figura 5.6 ilustra o tipo de estrutura para os observadores.

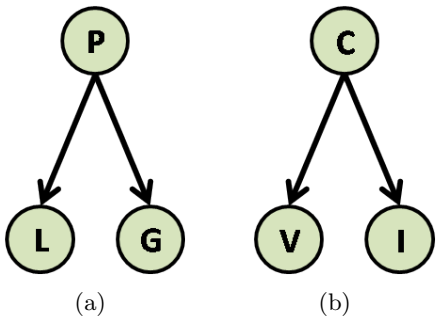

Figura 5.6: Detalhe da Rede Bayesiana correspondente a camada de percepção. (a) Variável escondida P e seus observadores L e G.(b) Variável escondida C e seus observadores V e I.

Para esse tipo de arquitetura, tem-se como CPT para os nós L,G,V e I, as probabilidades $p(L|P)$, $p(G|P)$, $p(V|C)$ e $p(I|C)$. Será usado como exemplo a construção da CPT da variável L, porém, a metodologia aqui estende-se para os outros nós acima citados. Sabe-se que o nó L possui três classes $\{l_1, l_2, l_3\}$ e o nó P possui quatro classes $\{p_1, p_2, p_3, p_4\}$. Pode-se então, montar a tabela 5.3 com as seguintes probabilidades condicionais.

Tabela 5.3: CPT da Variável L dado P

Variáveis	$L = l_1$	$L = l_2$	$L = l_3$
$P = p_1$	$p(L = l_1\|P = p_1)$	$p(L = l_2\|P = p_1)$	$p(L = l_3\|P = p_1)$
$P = p_2$	$p(L = l_1\|P = p_2)$	$p(L = l_2\|P = p_2)$	$p(L = l_3\|P = p_2)$
$P = p_3$	$p(L = l_1\|P = p_3)$	$p(L = l_2\|P = p_3)$	$p(L = l_3\|P = p_3)$
$P = p_4$	$p(L = l_1\|P = p_4)$	$p(L = l_2\|P = p_4)$	$p(L = l_3\|P = p_4)$

A tabela 5.3 é também chamada de matriz de confusão de um classificador (DUDA et al. , 2001), em que, dado a classe P, deseja-se determinar a verossimilhança de L. A probabilidade *a posteriori* de P pode ser calculada como mostra a equação 5.1.

$$p(P|L) = \frac{p(L|P)p(P)}{p(L)} = \frac{p(P)p(L|P)}{\sum_j p(P_j)p(L|P_j)} \tag{5.1}$$

Assim, usar-se-á as probabilidades $p(L|P)$ definidas pelo treinamento do respectivo classificador e $p(P)$, considerada a probabilidade *a priori* do posicionamento atual. Foi adotado que $p(P_0)$ é uma distribuição uniforme (condição inicial) e, conforme o tempo evolui, $p(P_k)$ também será atualizado.

Isto posto, deseja-se criar uma variável de modo a explicitar o contexto do veículo autônomo. Essa variável é chamada de *Situação* (*Situation* ou S), cujas classes são *Pista Correta*, *Pista Errada*, *Próximo à Junção*, *Na Junção*, *Vire à Direita* e *Vire à Esquerda*. A figura 5.7 ilustra a relação de dependências entre as variáveis P, C, F e S.

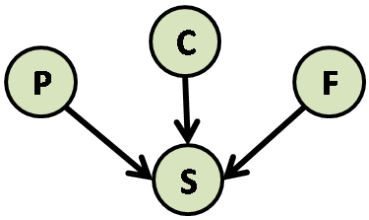

Figura 5.7: Detalhe da Rede Bayesiana correspondente a situação na qual o carro autônomo se encontra.

Vê-se pela figura 5.7 que o nó S é dependente dos nós P,C e F. A CPT para essa variável foi

feita via treinamento. Para isto, usou-se o simulador desenvolvido em C# para a aquisição dos dados que serão usados no treino.

Primeiro, definiu-se um mapa que serviu como fundo verdade para o nó *Situação* e assim, foi possível de encontrar a probabilidade conjunta $p(P, C, F, S)$. A figura 5.8 mostra o mapa utilizado, bem como sua legenda.

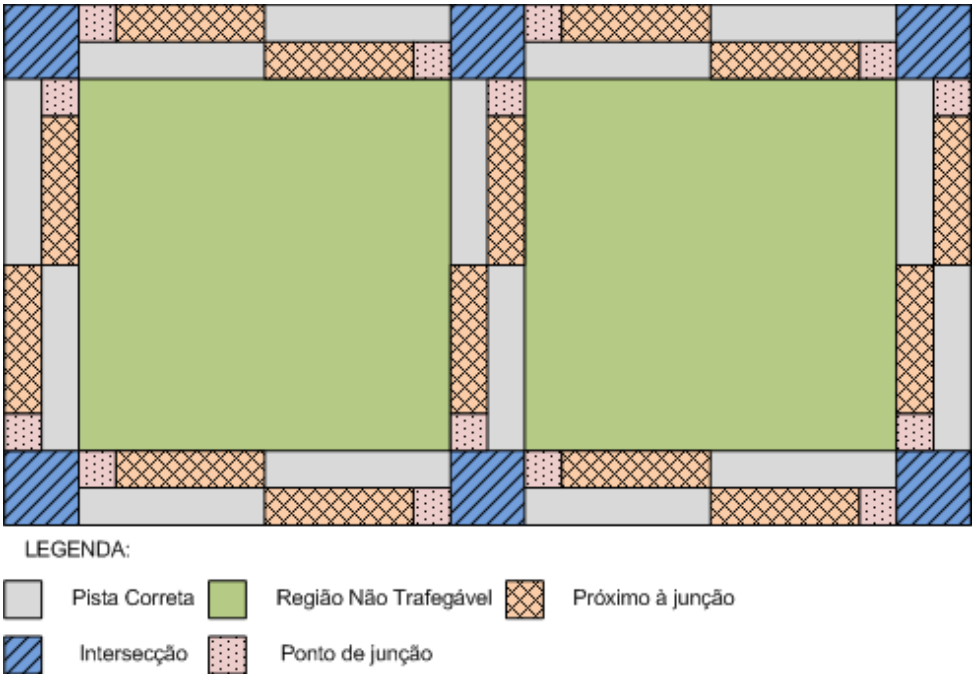

Figura 5.8: Mapa utilizado como fundo verdade para a variável S

Tem-se que a região definida por *Intersecção* apresenta as classes *Vire à Direita* e *Vire à Esquerda* dependendo do caminho o qual o carro está percorrendo e define-se *Pista Errada* quando o veículo está dirigindo contrariamente à orientação de fluxo definido pelo mapa. As demais regiões apresentam as classes com seus respectivos nomes.

Após a definição do mapa, modelaram-se as variáveis de entrada de modo a serem observadas corretamente com 85% de acerto, introduzindo, assim, ruído nas observações da probabilidade conjunta.

Por fim, a coleta de dados foi feita simulando o carro protótipo e fornecendo uma rota para que o veículo seguisse autonomamente. Para isso, uma Máquina de Estados Finitos (*Finite State Machine* ou FSM) foi desenvolvida. A figura 5.9 ilustra a FSM.

Os estados definidos foram *Mantenha a Pista* (KL), *Vire à Direita* (TR) e *Vire à Esquerda* (TL) e a transição dos mesmos ocorre fazendo-se uma análise da rota determinada.

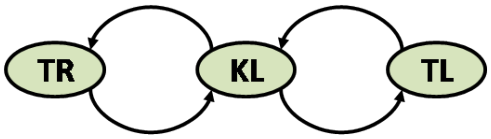

Figura 5.9: Máquina de Estados Finitos desenvolvida para possibilitar a criação dos dados de treinamento da CPT da variável S

Com isso, podem-se criar as amostras para o treinamento. Ao todo, foram feitas 200.077 amostras e para cada combinação de P,C,F,S foi feita uma contagem a fim de encontrar sua respectiva probabilidade conjunta $p(P, C, F, S)$. Buscando evitar o aparecimento de combinações determinísticas como $p(P, C, F, S) = 0$ ou $p(P, C, F, S) = 1$, fez-se a suavização k de Laplace (RUSSEL E NORVIG , 2010). Esta pode ser calculada como mostra a equação 5.2.

$$p(P, C, F, S) = \frac{\#ocorrências + k}{\#casos + \#possibilades} \tag{5.2}$$

Onde $\#ocorrências$ corresponde ao número de observações do caso $\{P = p_i, C = c_j, F = f_k, S = s_n\}$, $\#casos$ é o número total de casos apresentados no treinamento, $\#possibilades$ é o número de combinações possíveis para $\{P, C, F, S\}$ e k é um número inteiro tal que $1 \leq k \leq \#possibilades$. Assim, mesmo que não seja observado nenhum caso, ele terá uma pequena probabilidade em ocorrer, prevenindo de deixar a CPT do nó S, de algum modo, determinística devido ao treinamento. No caso em questão, existem 288 combinações para a probabilidade conjunta e foi escolhido $k = 30$.

A partir das novas probabilidades conjuntas calculadas, pôde-se criar a CPT de modo a obter $p(S|P, C, F)$. Uma vez rearranjada a tabela, a mesma precisa passar por uma normalização para garantir que $\sum_{i=1}^{6} p(S = s_i|P, C, F) = 1$ para qualquer combinação de P, C, F. Por fim, o *comportamento do veículo* (*Behaviour* ou B) é modelado como mostra a figura 5.10.

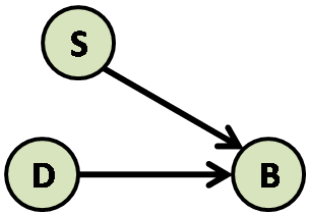

Figura 5.10: Detalhe da Rede Bayesiana correspondente ao comportamento do veículo.

Vê-se na figura 5.10 que D é o nó da *Situação Dinâmica*, que é observável pelo classificador apresentado em 4.1.4 e S é o nó de *Situação* previamente explicado. O nó B possui as

classes *Siga em Frente* (*keep_going* ou KG), *Desacelere* (*deceleration* ou DC), *Espere sua Vez* (*wait4yourTurn* ou WT), *Acelere* (*aceleration* ou AC), *Vire à Esquerda* (*left_turn* ou LT), *Vire à Direita* (*right_turn* ou RT), *Mude de Pista* (*change_lane* ou CL) e *Frenagem de Emergência* (*emergency_brakes* ou EB) e sua CPT foi construída a partir das regras de direção defensiva. A tabela 5.4 mostra a CPT da variável B.

Tabela 5.4: CPT da variável B.

Classes		KG	DC	WT	AC	LT	RT	CL	EB
Via Livre	*Pista Correta*	93	1	1	1	1	1	1	1
	Pista Errada	1	1	1	1	1	1	93	1
	Vire à Esquerda	1	1	1	1	93	1	1	1
	Vire à Direita	1	1	1	1	1	93	1	1
	Na Junção	1	1	1	93	1	1	1	1
	Próximo à Junção	1	93	1	1	1	1	1	1
Colisão	*Pista Correta*	15	30	1	1	1	1	1	50
	Pista Errada	1	1	1	1	1	1	93	1
	Vire à Esquerda	1	1	24	1	1	1	1	70
	Vire à Direita	1	1	24	1	1	1	1	70
	Na Junção	1	1	93	1	1	1	1	1
	Próximo à Junção	1	1	24	1	1	1	1	70

Vê-se pela tabela 5.4 que é dado preferência a comportamentos que evitem danos ao veículo. Além disso, a CPT também foi modelada de modo a evitar que o nó B tivesse alguma combinação determinística. Desse modo, a Rede Bayesiana fica como mostra a figura 5.11

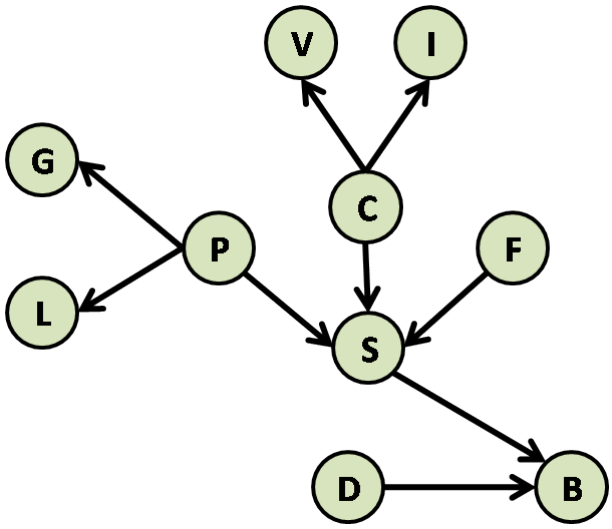

Figura 5.11: Rede Bayesiana desenvolvida

Foram desenvolvidas ainda mais 2 tipos de arquitetura de rede. Uma Rede Bayesiana Dinâmica com um filtro o qual será chamado de filtro sequencial e uma DBN com um filtro o qual será chamado de filtro de segunda ordem. Segue uma breve explicação sobre as mesmas.

A DBN foi construída com as variáveis P, C e B dependentes de seus estados anteriores. Os modelos de transição para os nós P e C são os mesmos entre a DBN com o filtro sequencial e a DBN com o filtro de segunda ordem, assim, a diferença entre as duas está no modelo de transição da variável B. As tabelas 5.5 e 5.6 ilustram as CPT entre o estado atual e o estado anterior das variáveis P e C respectivamente.

Tabela 5.5: Modelo de Transição da Variável P, tal que $p(P_k|P_{k-1})$

Classes	*Pista à Direita*	*Pista à Esquerda*	*Curva à Esquerda*	*Curva à Direita*
Pista à Direita	60	16	12	12
Pista à Esquerda	16	60	12	12
Curva à Esquerda	12	12	60	16
Curva à Direita	12	12	16	60

Tabela 5.6: Modelo de Transição da Variável C, tal que $p(C_k|C_{k-1})$

Classes	*Via Reta*	*Junção*	*Curva à Esquerda*	*Curva à Direita*
Via Reta	60	30	5	5
Junção	10	70	10	10
Curva à Esquerda	30	5	60	5
Curva à Direita	30	5	5	60

As tabelas 5.5 e 5.6 foram criadas de modo a tratar a influência dos ruídos na classificação. Definiu-se, para a primeira, que em apenas 60% dos casos a transição não ocorre e a probabilidade das transições deveriam ser tão semelhantes quanto possível. Já para a segunda, a sequência inerente de como os cenários evoluem influenciaram na escolha dos valores de transição.

A transição em B foi modelada de 2 modos distintos. O primeiro, aqui chamado de filtro sequencial, usa as distribuições de probabilidade do estado atual de B, juntamente com os estados de B em $k-1$ e $k-2$ de modo sequencial ou em forma de cascata. A figura 5.12 ilustra a arquitetura aqui proposta.

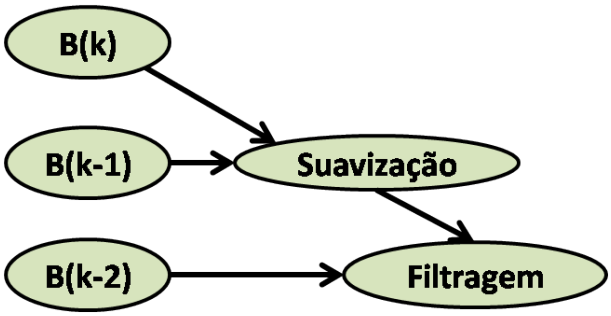

Figura 5.12: Filtro Sequencial proposto para o nó B.

Nesta figura, tem-se que os nós $B(k)$, $B(k-1)$ e $B(k-2)$ representam, respectivamente o

estado atual de B, o estado em uma iteração passada e o estado em duas iterações passadas. A variável *Filtragem* é a saída da rede apresentada na figura 5.12. Para se ter o entendimento da construção da Matriz de transição, primeiro se faz necessário modelar como os comportamentos evoluem no tempo. Segundo as hipóteses propostas nesta dissertação, podem-se encontrar as relações entre os comportamentos apresentadas na tabela 5.7.

Tabela 5.7: Relação entre os comportamentos de B.

O comportamento ...	**Transiciona para...**
Keep Going(KG)	DC, CL e EB
Deceleration(DC)	WT, AC, CL e EB
Wait 4 your Turn(WT)	AC
Acceleration(AC)	LT, RT e EB
Left Turn(LT)	KG e EB
Right Turn(RT)	KG e EB
Change Lane(CL)	KG e DC
Emergency Brake(EB)	KG, DC, WT, LT e RT

Desse modo, define-se três eventos para a modelagem da CPT, w_{NT}, w_T, w_S e duas variáveis auxiliares, x_{OLD} e x_{ACTUAL}. O evento w_{NT} é definido como a conjunção entre as variáveis x_{OLD} e x_{ACTUAL}, tal que x_{ACTUAL} não pertence a lista de transição de x_{OLD}. O evento w_T é definido como a conjunção entre as variáveis x_{OLD} e x_{ACTUAL}, tal que x_{ACTUAL} pertence a lista de transição de x_{OLD} e o evento w_S é definido como a conjunção entre as variáveis x_{OLD} e x_{ACTUAL}, tal que x_{ACTUAL} é igual a x_{OLD}. Isto posto, pode-se agora definir as probabilidades $p(Suavização|w_{NT})$, $p(Suavização|w_T)$, $p(Suavização|w_S)$, $p(Filtragem|w_{NT})$, $p(Filtragem|w_T)$ e $p(Filtragem|w_S)$, onde as 3 primeiras referem-se a construção da CPT do nó *Suavização* e as 3 últimas, ao nó de inferência *Filtragem*.

Tem-se então que $p(Suavização = x_{OLD}|w_S) = p(Filtragem = x_{OLD}|w_S) = 0,93$ e $0,01$ caso contrário, $p(Suavização = x_{OLD}|w_T) = p(Filtragem = x_{OLD}|w_T) = 0,7$, $p(Suavização = x_{ACTUAL}|w_T) = p(Filtragem = x_{ACTUAL}|w_T) = 0,24$ e $0,01$ caso contrário e $p(Suavização = x_{OLD}|w_{NT}) = p(Filtragem = x_{OLD}|w_{NT}) = 0,93$ e $0,01$ caso contrário.

O segundo método, chamado de filtro de segunda ordem, usa as distribuições do estado atual de B, do estado em uma iteração passada e do estado em duas iterações passadas de forma mais direta. A arquitetura desse filtro pode ser vista na figura 5.13

Neste caso, a CPT do nó *Filtragem* foi baseado no modelo de evolução dos comportamentos apresentado na tabela 5.7 com algumas modificações para o seu preenchimento. A tabela completa pode ser vista no Apêndice C.

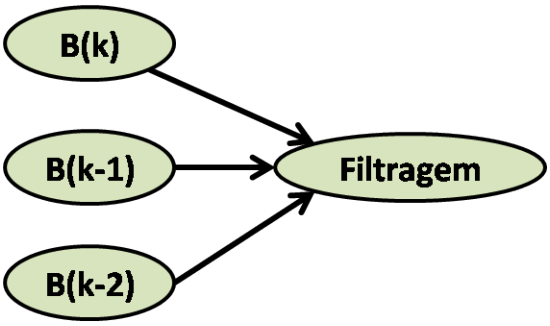

Figura 5.13: Filtro de Segunda Ordem proposto para o nó B.

5.5 Testes Preliminares

A fim de testar as respostas das 3 Redes propostas, foi feito um teste preliminar para analisá-las. Para a execução desses e dos mesmos realizados no capítulo 6 define-se aqui as matrizes de confusão dos classificadores FORTES e as matrizes dos classificadores FRACOS utilizados nessa dissertação. Os níveis de ruído também são, aqui, definidos.

Tabela 5.8: Matriz de confusão para a variável L considerada como classificador FORTE

Classes	*Pista à Direita*	*Pista à Esquerda*	*Não Reconhecida*
Pista à Direita	84	8	8
Pista à Esquerda	8	84	8
Curva à Esquerda	8	8	84
Curva à Direita	8	8	84

Tabela 5.9: Matriz de confusão para a variável G considerada como classificador FORTE

Classes	*Pista à Direita*	*Pista à Esquerda*	*Curva à Esquerda*	*Curva à Direita*
Pista à Direita	85	5	5	5
Pista à Esquerda	5	85	5	5
Curva à Esquerda	5	5	85	5
Curva à Direita	5	5	5	85

Dentre os classificadores apresentados, existem 4 que dependem da matriz de confusão, segundo a arquitetura proposta na rede Bayesiana. São eles: *Localização via Câmera* (L), *Localização via GPS e IMU* (G), *Cenário via Visão* (V) e *Cenário via GPS e IMU* (I). Suas matrizes de confusão consideradas FORTES encontram-se respectivamente nas Tabelas 5.8, 5.9, 5.10 e 5.11 e as matrizes FRACAS encontram-se respectivamente nas Tabelas 5.12, 5.13, 5.14 e 5.15.

Os níveis de ruído na classificação foram modelados segundo o algoritmo 5 e cada nível de acerto teve seu valor de *pHIT* alterado como mostra a Tabela 5.16.

Tabela 5.10: Matriz de confusão para a variável V considerada como classificador FORTE

Classes	*Via Reta*	*Junção*	*Curva à Esquerda*	*Curva à Direita*
Via Reta	85	5	5	5
Junção	5	85	5	5
Curva à Esquerda	5	5	85	5
Curva à Direita	5	5	5	85

Tabela 5.11: Matriz de confusão para a variável I considerada como classificador FORTE

Classes	*Via Reta*	*Junção de Entrada*	*Junção de Saída*	*Curva à Esquerda*	*Curva à Direita*
Via Reta	76	2	18	2	2
Junção	4	84	4	4	4
Curva à Esquerda	4	4	4	84	4
Curva à Direita	4	4	4	4	84

Tabela 5.12: Matriz de confusão para a variável L considerada como classificador FRACA

Classes	*Pista à Direita*	*Pista à Esquerda*	*Não Reconhecida*
Pista à Direita	60	20	20
Pista à Esquerda	20	60	20
Curva à Esquerda	20	20	60
Curva à Direita	20	20	60

Tabela 5.13: Matriz de confusão para a variável G considerada como classificador FRACA

Classes	*Pista à Direita*	*Pista à Esquerda*	*Curva à Esquerda*	*Curva à Direita*
Pista à Direita	55	15	15	15
Pista à Esquerda	15	55	15	15
Curva à Esquerda	15	15	55	15
Curva à Direita	15	15	15	55

Tabela 5.14: Matriz de confusão para a variável V considerada como classificador FRACA

Classes	*Via Reta*	*Junção*	*Curva à Esquerda*	*Curva à Direita*
Via Reta	55	15	15	15
Junção	15	55	15	15
Curva à Esquerda	15	15	55	15
Curva à Direita	15	15	15	55

Tabela 5.15: Matriz de confusão para a variável I considerada como classificador FRACA

Classes	*Via Reta*	*Junção de Entrada*	*Junção de Saída*	*Curva à Esquerda*	*Curva à Direita*
Via Reta	40	10	30	10	10
Junção	11	56	11	11	11
Curva à Esquerda	11	11	11	56	11
Curva à Direita	11	11	11	11	56

Algoritmo 5: Introdução de Ruídos à Classificação

Entrada: Classificação aferida *class*, Percentual de Acerto *pHit*
Saída: Classificação Ruidosa *noisyClass*

1 **início**
2 $varX \leftarrow DistribuicaoUniforme()$; `/* Variável aleatória X recebe uma Distribuição Uniforme */`
3 $u \leftarrow varX(k)$; `/* u recebe uma amostragem de varX no instante k */`
4 **se** $u \leq pHit$ **então**
5 $noisyClass \leftarrow class$; `/* A variável` *noisyClass* `recebe a classificação correta` *class* `*/`
6 **senão**
7 $noisyClass \leftarrow \neg class$; `/* A variável` *noisyClass* `recebe a classificação errada pertencente ao conjunto` $\neg class$`. Este varia de tamanho conforme o classificador e sua escolha também é feita de forma aleatória. */`
8 **fim**
Resultado: Classificação Ruidosa *noisyClass*
9 **fim**

Tabela 5.16: Valor de *pHit* para cada nível de influência do ruído na classificação

Tipo de Acerto	*pHit*
Acerto Ideal	1
Acerto Alto	0.88
Acerto Baixo	0.58

Feito as definições, pode-se descrever o teste preliminar realizado. Primeiramente, foi escolhido o cenário em que o teste deve ser efetuado. Este pode ser visto na Figura 5.14.

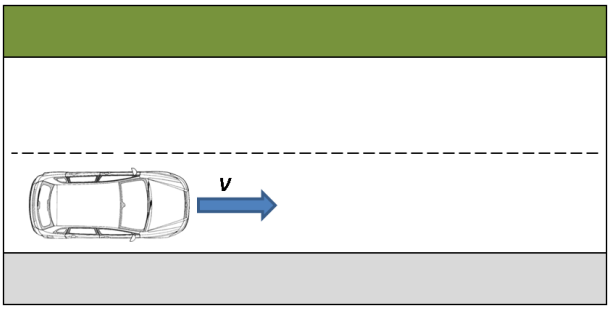

Figura 5.14: Cenário desenvolvido para o teste preliminar das 3 Redes propostas

Este cenário simples possui apenas uma classe possível como resposta e assim, se é possível analisar a taxa de acerto das 3 arquiteturas sobre a influência de grandes ruídos nas classificações. Além disso, foi feito um teste para a verificação do tempo de processamento médio do algoritmo desenvolvido. Este foi realizado em um computador com processador *Intel Core 2 Duo* com frequência de $2,1GHz$ e $1Gbytes$ de memória RAM.

Para cada arquitetura foram utilizados dois tipos de procedimentos. O primeiro foi realizado sem influência dos ruídos na classificação e os classificadores que dependem de matrizes de confusão, como a tabela 5.3, foram definidos como classificadores FORTES, sendo esse o caso $F_\Phi F_\Phi F_\Phi F_\Phi \Phi\Phi$, como visto no capítulo 2. Esse teste foi escolhido pois serve como base de comparação para o teste seguinte, com a introdução dos ruídos. O segundo procedimento apresenta agora, em todos os classificadores, altos níveis de ruído, sendo esse o caso $F_{Gd}F_{Gd}F_{Gd}F_{Gd}GdGd$. Foi decidido manter a mesma arquitetura de rede para a análise comparativa.

Foram realizadas 2000 medições para cada caso em conjunto com uma arquitetura, totalizando 6 testes no cenário descrito. A Tabela 5.17 mostra os resultados preliminares de cada teste.

Tabela 5.17: Resultados preliminares obtidos com o teste no cenário da Figura 5.14

Arquitetura testada	**Caso testado**	*Taxa de Acerto [%]*	*Tempo Médio de Processamento [ms]*
Rede sem Filtro	$F_\Phi F_\Phi F_\Phi F_\Phi \Phi\Phi$	100	57
	$F_{Gd}F_{Gd}F_{Gd}F_{Gd}GdGd$	$56,8$	72
Rede com Filtro Sequencial	$F_\Phi F_\Phi F_\Phi F_\Phi \Phi\Phi$	100	91
	$F_{Gd}F_{Gd}F_{Gd}F_{Gd}GdGd$	$55,7$	88
Rede com Filtro de 2 ordem	$F_\Phi F_\Phi F_\Phi F_\Phi \Phi\Phi$	100	74
	$F_{Gd}F_{Gd}F_{Gd}F_{Gd}GdGd$	$97,96$	73

Vê-se pela Tabela 5.17 que todos as arquiteturas implementadas ficaram com média de processamento menor que 100 ms, entretanto apenas a rede com o filtro de segunda ordem obteve uma resposta aceitável ao teste com alta interferência de ruídos (taxas de acerto de 58%), com aproximadamente 98% de acerto. Assim, foi escolhido o filtro de segunda ordem para os testes apresentados no capítulo 6.

Capítulo 6

Parte Experimental

Como citado no capítulo 2, a quantidade de testes a serem feitos para validar a decisão em cenários de trânsito podem atingir números intratáveis. Desse modo, com a finalidade de reduzir a dimensionalidade dos testes, propôs-se analisar dois casos que são considerados mais críticos, como ilustrados pela figura 2.6, que aqui é repetida por conveniência.

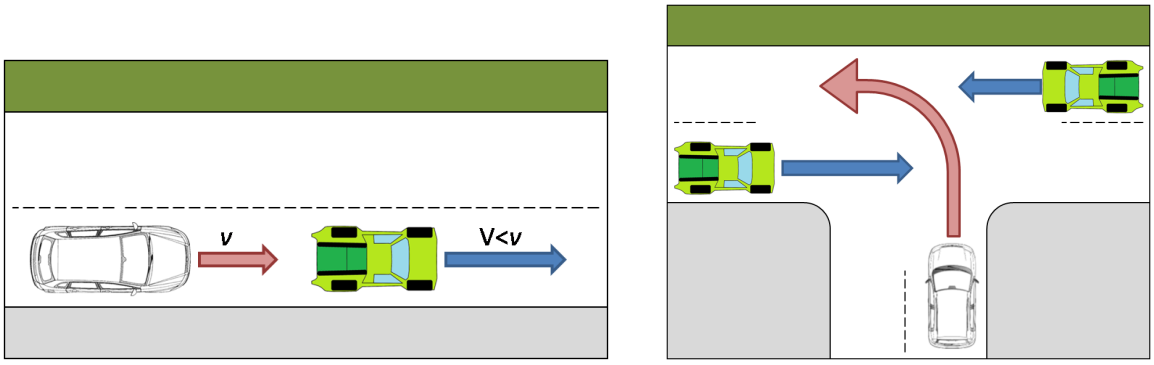

(a) (b)

Figura 6.1: Repetição da figura 2.6 com os casos estudados nessa dissertação. (a)Cenário na qual o veículo autônomo deve começar a frenagem devido a um entroncamento, com um veículo mais lento a frente. (b) Cenário na qual o veículo autônomo deve virar a esquerda, com 2 veículos no entroncamento, ambos andando em linha reta. Este cenário conta com 4 variações de *gap*. O primeiro caso traz dois *gaps* que não permitem o carro autônomo entrar na intersecção antes que os outros carros ultrapassem, enquanto o segundo e o terceiro apresentam pelo menos um dos carros com *gap* grande enquanto o outro tem um *gap* justo. Por fim, o último caso terá *gaps* grandes.

Cada um dos casos estudados apresenta comportamentos distintos que o carro autônomo deve executar e, em se tratando de um ambiente dinâmico, a ação efetuada no tempo $k-1$ influencia a percepção no tempo k e sua decisão, por consequência.

Descrevem-se, então, os comportamentos adotados para essa dissertação. Deve-se ressaltar que esta não foi desenvolvida para ter robustez por não ser esse o foco desse trabalho.

6.1 Comportamentos Simulados

Como foi apresentado no capítulo 5, os comportamentos são: *Siga em Frente* (KG), *Desacelere* (DC), *Espere sua Vez* (WT), *Acelere* (AC), *Vire à Esquerda* (LT), *Vire à Direita* (RT), *Mude de Pista* (CL) e *Frenagem de Emergência* (EB).

O *Siga em Frente* foi modelado para manter o ângulo de esterçamento em zero e manter a velocidade do veículo se esta for superior a $2m/s$. Caso contrário, o veículo deverá acelerar a $2m/s^2$ até atingir $2m/s$.

O *Desacelere* apresenta um comportamento mais dinâmico. Estima-se a desaceleração desejada através da distância até o próximo ponto da rota, a velocidade estimada do veículo e a velocidade ao final da desaceleração. Esta foi considerada como $4m/s$ e a desaceleração limitada à máxima feita pelo veículo, no caso $-8m/s^2$ (RODAS , 2006).

O *Acelere* tem um comportamento semelhante ao *Desacelere*, entretanto sua velocidade desejada é de $15m/s$ e a aceleração é limitada à $2m/s^2$.

O *Espere sua Vez* foi modelado de forma a não ultrapassar metade da desaceleração máxima do carro. Além disso, em situações de cruzamento, o comportamento se torna dinâmico e a desaceleração muda, de maneira similar ao *Desacelere*, para que o veículo tenha velocidade nula no cruzamento.

Tanto o *Vire à Esquerda* quanto o *Vire à Direita* foram modelados de modo a evitar o planejamento de trajetórias do carro, que não é o foco desta dissertação. Para tanto, definiu-se que o esterçamento seria proporcional à norma do produto vetorial da velocidade do veículo com a força produzida por um campo $\vec{\mathbf{A}}$ centrado no próximo ponto da rota capaz de atrair o carro.

A força de campo de $\vec{\mathbf{A}}$ pode ser escrita como mostra a equação 6.1.

$$\vec{\mathbf{F}}_{campo} = \frac{constante}{\rho^2}(\cos\alpha\vec{\mathbf{i}} + \sin\alpha\vec{\mathbf{j}}) \tag{6.1}$$

Onde $constante = 3,9 \cdot 10^8\ N \cdot m^2$ determinada empiricamente, ρ é a distância do carro ao próximo ponto da rota em metros, $\vec{\mathbf{i}}$ é o versor da coordenada x do sistema, $\vec{\mathbf{j}}$ é o versor da

coordenada y do sistema, $\vec{\mathbf{F}}_{campo}$ é a força de campo de $\vec{\mathbf{A}}$ medida em N e α é o ângulo medido entre o eixo x e o vetor $\vec{\mathbf{F}}_{campo}$. Desse modo, o esterçamento pode ser calculado como mostra a equação 6.2.

$$steering = K_s \left\| \vec{\mathbf{v}} \times \vec{\mathbf{F}}_{campo} \right\| \tag{6.2}$$

Onde *steering* é o esterçamento do veículo no modelo da bicicleta, K_s é a constante de proporcionalidade, $\vec{\mathbf{v}}$ é o vetor velocidade do carro, em m/s e $\vec{\mathbf{F}}_{campo}$ é a força calculada na equação 6.1. O esterçamento foi limitado dado o raio máximo de giro do veículo (FIAT , 2005) em $-26,346 \leq steering \leq 26,346$ medido em graus e o valor K_s foi determinado empiricamente como $2\ ^{\circ}/(N \cdot m/s)$.

Além disso, caso a velocidade do veículo fosse inferior a $7m/s$, a aceleração do mesmo era considerada como $2m/s^2$ até atingir $7m/s$, e $0m/s^2$ caso contrário.

O comportamento *Mude de Pista* foi modelado para ter 10% do esterçamento máximo para a direita e por fim, o *Frenagem de Emergência* tem a máxima desaceleração que o veículo consegue fazer, no caso $-8m/s^2$.

Com os comportamentos definidos, descrevem-se agora os testes feitos em detalhes com os respectivos resultados. Ressalta-se que todos os testes realizados foram feitos com tempo de simulação igual a 10 ms para melhor visualização dos processos da rede em questão.

6.2 Caso - Frenagem com Obstáculo à Frente

O primeiro caso estudado é o caso do veículo estar se aproximando de um entroncamento e, por isso, deve começar uma manobra de desaceleração e há um veículo mais lento à frente. Este teste busca validar as características da rede bem como emular a aparição de um veículo, que poderia estar no acostamento, e entra na pista ainda mais lento.

Para simular essa situação, supõe-se que o carro autônomo não observa os obstáculos no começo da via e quando se aproxima do ponto intermediário, um veículo com velocidade menor é observado a uma certa distância. Para garantir a repetibilidade dos testes, foram definidos os parâmetros presentes na Tabela 6.1 e ilustrados na figura 6.2.

Nesta figura, os veículos A e B são respectivamente, o carro autônomo e o obstáculo detectado. Como características dos testes, foram utilizadas as estimações das variáveis pertinentes.

Tabela 6.1: Lista dos parâmetros utilizados no Caso 1: Frenagem com Obstáculo à frente

Símbolo	**Breve Descrição**	**Valor**	**Unidade**
V_{oA}	Velocidade inicial do carro autônomo	15	m/s
V_{oB}	Velocidade inicial do veículo à frente	$6,4$	m/s
D_{AB}	Distância entre os veículos	$19,2$	m
a_B	Aceleração do veículo à frente	$-0,6$	m/s^2
O_{xy}	Ponto de GPS da pista da direita há 50 m da intersecção, por consequência, há 40 m do próximo ponto de GPS	$[0\ 0]^T$	m
P_{oA}	Posição inicial do carro autônomo	O_{xy}	m
P_{oB}	Posição inicial do veículo à frente	$P_{oA} + [D_{AB}\ 0]^T$	m

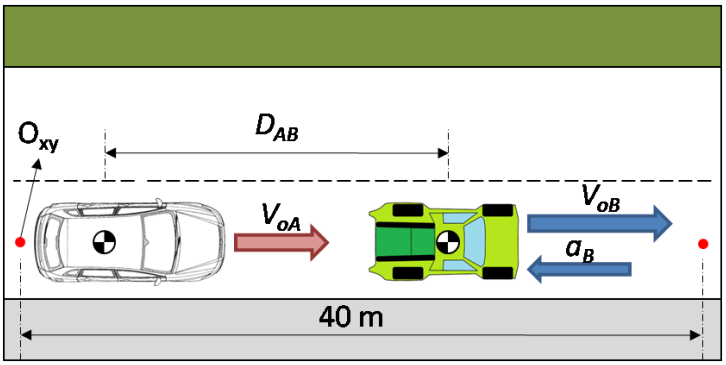

Figura 6.2: Parâmetros usados no teste do caso de frenagem com o obstáculo à frente.

Todas foram consideradas como uma distribuição gaussiana e suas características podem ser vistas na Tabela 6.2.

Tabela 6.2: Lista dos parâmetros utilizados no Caso - Frenagem com Obstáculo à frente

Estimador	**Média**	**Desvio Padrão**	**Unidade**
$\hat{V}_A$	V_A	$0,25$	m/s
$\hat{P}_{xA}$	P_{xA}	$0,06$	m
$\hat{P}_{yA}$	P_{yA}	$0,06$	m
$\hat{\theta}_A$	θ_A	$0,02$	rad
$\hat{V}_{xB}$	V_{xB}	$0,25$	m/s
$\hat{V}_{yB}$	V_{yB}	$0,25$	m/s
$\hat{P}_{xB}$	P_{xB}	$0,1$	m
$\hat{P}_{yB}$	P_{yB}	$0,1$	m

Os estimadores da Tabela 6.2 com o subscrito A, referem-se a saída do filtro de Kalman para localização como elucidado na seção 3.1. Já os estimadores com o subscrito B referem-se a saída do filtro de Kalman na estimação da posição de obstáculos como explicado na seção 4.1.4. As variáveis do obstáculo estão no referencial do veículo enquanto as variáveis do carro autônomo são estimadas no mapa métrico local.

Como, por hipótese, tem-se o mapa métrico, pode-se modelar o grafo de colisão como apresentado na seção 4.1.4 e ilustrado na figura 6.3.

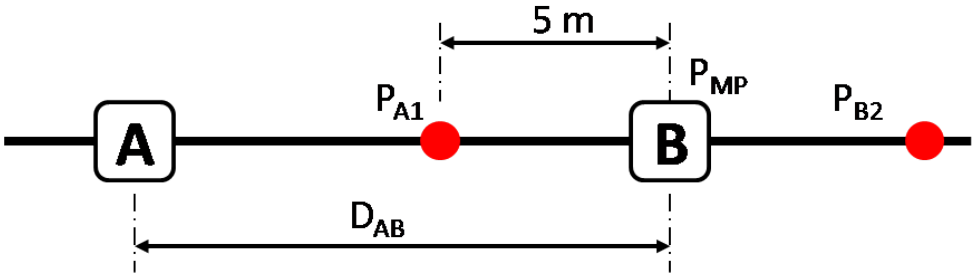

Figura 6.3: Modelo adotado de colisão para o caso estudado.

Vê-se na figura 6.3 que o ponto de encontro P_{MP} foi definido como a própria posição de B, P_{B2} é o ponto de GPS no final do Mapa Métrico para a frenagem e começo do mapa da intersecção e P_{A1} foi definido como o ponto a 5 metros atrás da posição de B.

Pela Hipótese simplificadora de não ultrapassagem estabelecida no capítulo 2, somente resta para a análise de colisão se o obstáculo, nomeado como B, consegue chegar a P_{B2} antes que o carro autônomo, nomeado de A, chegue em P_{A1}. Segundo WERLING et al. (2008), para classificar como *via livre*, dois critérios precisam ser cumpridos:

1. O tempo que A leva para chegar ao ponto de encontro P_{MP} deve ser maior que o tempo que B leva para chegar ao mesmo ponto mais um tempo de espera ΔT_{BA}.

2. O veículo A deve percorrer uma distância até, no máximo, a distância a P_{A1}, enquanto B chega em P_{B2}.

Segundo o grafo definido na figura 6.3, o tempo que B leva para chegar a P_{MP} é 0. Assim, a primeira verificação deve ser $t_{A\to B} > \Delta T_{BA}$, onde ΔT_{BA} é definido empiricamente e medido em segundos e $t_{A\to B}$ é calculado pela equação 6.3.

$$t_{A\to B} = \frac{\hat{V}_A^2 - \sqrt{\hat{V}_A^2 - 4D_{AB}}}{2} \tag{6.3}$$

Para a segunda verificação, precisa-se, primeiro, passar o ponto P_{B2}, definido no mapa métrico local para o sistema preso ao carro autônomo. Feito isso, descobre-se o tempo necessário para o veículo B chegar em P_{B2}, através da equação 6.4.

$$t_{B\rightarrow P2} = \frac{\sqrt{(P_{xB2} - \hat{P}_{xB})^2 + (P_{yB2} - \hat{P}_{yB})^2}}{\sqrt{\hat{V}_{xB}^2 + \hat{V}_{yB}^2}} \tag{6.4}$$

Onde $[P_{xB2}\ P_{yB2}]^T$ é o vetor posição do ponto P_{B2} no sistema de coordenadas do carro autônomo. Assim, a segunda verificação pode ser calculada segundo a equação 6.5.

$$\hat{V}_A \cdot t_{B\rightarrow P2} - t_{B\rightarrow P2}^2 < D_{AB} - 5 \tag{6.5}$$

Quando as duas verificações são verdadeiras, a classificação é dita como *via livre*, caso contrário é marcada como *colisão*.

Uma vez com o caso a ser estudado bem estruturado, os testes podem ser efetuados. Como dito no capítulo 2, serão feitos 24 testes variando alguns detalhes na arquitetura empregada mais um teste que será usado para as comparações. A Tabela 2.2 que mostra os testes a serem executados, é repetida na tabela 6.3 por conveniência.

Onde f refere-se ao classificador pouco discriminante ou fraco, F ao classificador altamente discriminante ou forte. As matrizes de confusão dos respectivos classificadores *FORTES* e/ou *FRACOS* encontram-se nas Tabelas 5.8 a 5.15. Φ refere-se a taxa de Acerto Ideal, Pq a taxa de Acerto Alto e Gd a taxa de Acerto Baixo e os valores encontram-se na Tabela 5.16. Por fim, MI é o classificador usado para detecção da posição relativa na via referente ao nó da Rede Bayesiana L, MII é o classificador usado para detecção da posição relativa na via referente ao nó da Rede Bayesiana G, MIII é o classificador usado para detecção do cenário transitado referente ao nó da Rede Bayesiana V, MIV é o classificador usado para detecção do cenário transitado referente ao nó da Rede Bayesiana I, MV é o classificador usado na detecção do cenário futuro da rota correspondente ao nó da Rede Bayesiana F e por fim, MVI é o classificador usado para detecção de colisões correspondente ao nó da Rede Bayesiana D.

A figura 6.4 mostra a resposta para o teste $F_\Phi F_\Phi F_\Phi F_\Phi \Phi\Phi$ que será usado como padrão de comparação.

Observa-se na figura 6.4 as probabilidades de 4 comportamentos que são relevantes para o caso analisado, *Siga em Frente* (KG), *Desacelere* (DC), *Espere sua Vez* (WT) e *Frenagem de Emergência* (EB) e a evolução dos mesmos no tempo. Vê-se, também, o comportamento resultante do veículo autônomo, sendo este gerado pela análise da maior probabilidade entre os comportamentos possíveis. O mesmo pode ser explicado pela lista de transição definida no

Tabela 6.3: Repetição da Tabela 2.2 com os testes da rede para o caso apresentado na figura 2.6(a)

ID	**MI**	**MII**	**MIII**	**MIV**	**MV**	**MVI**
$f_{Pq}F_{Pq}f_{\Phi}F_{\Phi}PqGd$	f e Pq	F e Pq	f e Φ	F e Φ	Pq	Gd
$f_{Pq}F_{Pq}f_{Pq}F_{Pq}PqGd$	f e Pq	F e Pq	f e Pq	F e Pq	Pq	Gd
$f_{Pq}F_{Pq}f_{Gd}F_{Gd}PqGd$	f e Pq	F e Pq	f e Gd	F e Gd	Pq	Gd
$f_{Pq}F_{Pq}F_{\Phi}f_{\Phi}PqGd$	f e Pq	F e Pq	F e Φ	f e Φ	Pq	Gd
$f_{Pq}F_{Pq}F_{Pq}f_{Pq}PqGd$	f e Pq	F e Pq	F e Pq	f e Pq	Pq	Gd
$f_{Pq}F_{Pq}F_{Gd}f_{Gd}PqGd$	f e Pq	F e Pq	F e Gd	f e Gd	Pq	Gd
$f_{Pq}F_{Pq}f_{\Phi}f_{\Phi}PqGd$	f e Pq	F e Pq	f e Φ	f e Φ	Pq	Gd
$f_{Pq}F_{Pq}f_{Pq}f_{Pq}PqGd$	f e Pq	F e Pq	f e Pq	f e Pq	Pq	Gd
$f_{Pq}F_{Pq}f_{Gd}f_{Gd}PqGd$	f e Pq	F e Pq	f e Gd	f e Gd	Pq	Gd
$f_{Pq}F_{Pq}F_{\Phi}F_{\Phi}PqGd$	f e Pq	F e Pq	F e Φ	F e Φ	Pq	Gd
$f_{Pq}F_{Pq}F_{Pq}F_{Pq}PqGd$	f e Pq	F e Pq	F e Pq	F e Pq	Pq	Gd
$f_{Pq}F_{Pq}F_{Gd}F_{Gd}PqGd$	f e Pq	F e Pq	F e Gd	F e Gd	Pq	Gd
$F_{Pq}f_{Pq}f_{\Phi}F_{\Phi}PqGd$	F e Pq	f e Pq	f e Φ	F e Φ	Pq	Gd
$F_{Pq}f_{Pq}f_{Pq}F_{Pq}PqGd$	F e Pq	f e Pq	f e Pq	F e Pq	Pq	Gd
$F_{Pq}f_{Pq}f_{Gd}F_{Gd}PqGd$	F e Pq	f e Pq	f e Gd	F e Gd	Pq	Gd
$F_{Pq}f_{Pq}F_{\Phi}f_{\Phi}PqGd$	F e Pq	f e Pq	F e Φ	f e Φ	Pq	Gd
$F_{Pq}f_{Pq}F_{Pq}f_{Pq}PqGd$	F e Pq	f e Pq	F e Pq	f e Pq	Pq	Gd
$F_{Pq}f_{Pq}F_{Gd}f_{Gd}PqGd$	F e Pq	f e Pq	F e Gd	f e Gd	Pq	Gd
$F_{Pq}f_{Pq}f_{\Phi}f_{\Phi}PqGd$	F e Pq	f e Pq	f e Φ	f e Φ	Pq	Gd
$F_{Pq}f_{Pq}f_{Pq}f_{Pq}PqGd$	F e Pq	f e Pq	f e Pq	f e Pq	Pq	Gd
$F_{Pq}f_{Pq}f_{Gd}f_{Gd}PqGd$	F e Pq	f e Pq	f e Gd	f e Gd	Pq	Gd
$F_{Pq}f_{Pq}F_{\Phi}F_{\Phi}PqGd$	F e Pq	f e Pq	F e Φ	F e Φ	Pq	Gd
$F_{Pq}f_{Pq}F_{Pq}F_{Pq}PqGd$	F e Pq	f e Pq	F e Pq	F e Pq	Pq	Gd
$F_{Pq}f_{Pq}F_{Gd}F_{Gd}PqGd$	F e Pq	f e Pq	F e Gd	F e Gd	Pq	Gd
$F_{\Phi}F_{\Phi}F_{\Phi}F_{\Phi}\Phi\Phi$	F e Φ	F e Φ	F e Φ	F e Φ	Φ	Φ

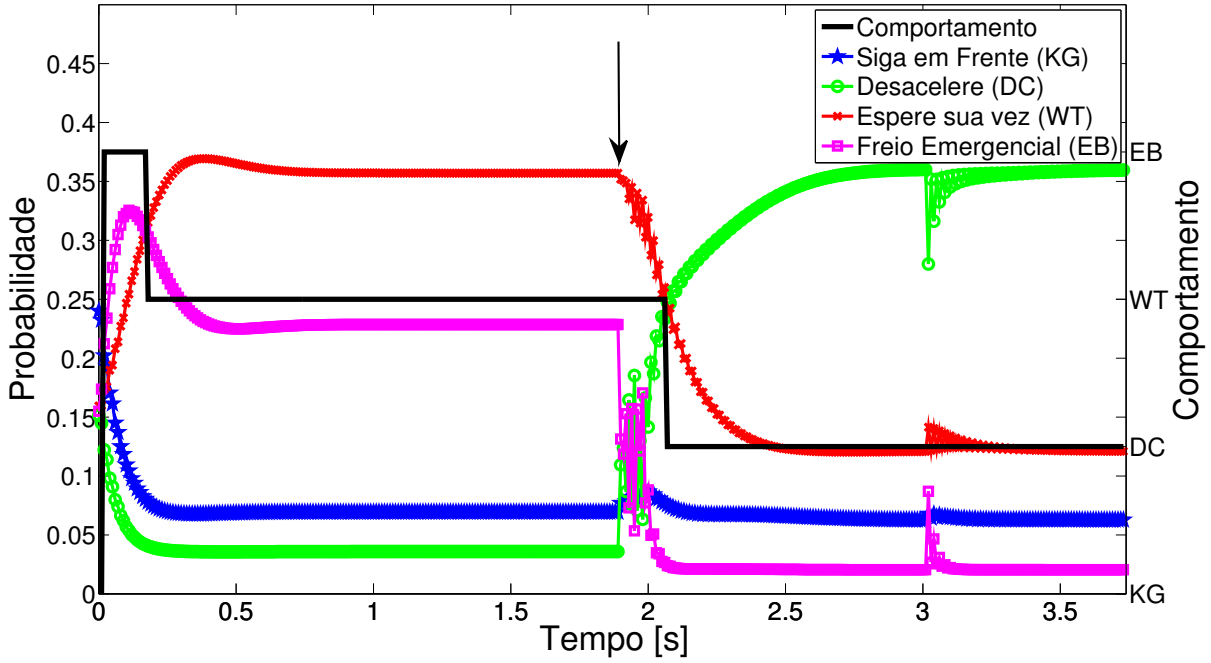

Figura 6.4: Gráfico resultante do teste $F_\Phi F_\Phi F_\Phi F_\Phi \Phi\Phi$ para o caso 1. Em destaque os comportamentos resultantes da Rede Bayesiana

capítulo 5 (Tabela 5.7) e o cenário utilizado.

A princípio, o veículo entra na área de desaceleração com o comportamento anterior de *Siga em Frente*, entretanto, a colisão eminente decresce a crença do carro nesse estado e aumenta a dos estados *Espere sua Vez* e *Frenagem de Emergência*. Analisando as transições, vê-se que o último pertence à lista de transições de KG, ao contrário do WT. Assim, a crença em EB aumenta mais rapidamente do que a de WT e, quando a probabilidade de EB for maior que a probabilidade de KG, há uma troca no comportamento, sendo este escolhido como *Frenagem de Emergência*.

Porém, este último estado fica ativo por volta de $0,15$ s, uma vez que WT agora pertence à lista de transições de EB. Após a nova troca de comportamentos, este fica ativo por, aproximadamente $1,9$ s. Este patamar de estabilidade pode ser explicado pela asserção do classificador de situação dinâmica como colisão e também por WT não possuir os outros 3 estados relevantes para o caso estudado na sua lista de transição, sendo assim, uma mudança de estados dar-se-á de forma lenta. Percebe-se, um período de instabilidade próximo a $t = 2$s de aproximadamente $0,15$ s nas probabilidades de EB e DC enquanto a crença em WT diminui de forma suave até ocorrer a troca no comportamento.

Vê-se pela figura 6.4 que as altas crenças ajudam na robustez da escolha do comportamento. Um exemplo encontra-se perto dos 3 s, onde há uma instabilidade nas crenças, porém a grande diferença entra as mesmas permitiu suprimir esse tipo de erro e manter o comportamento.

As instabilidades geradas podem ser explicadas pela resposta do classificador de situação dinâmica, como mostra a figura 6.5.

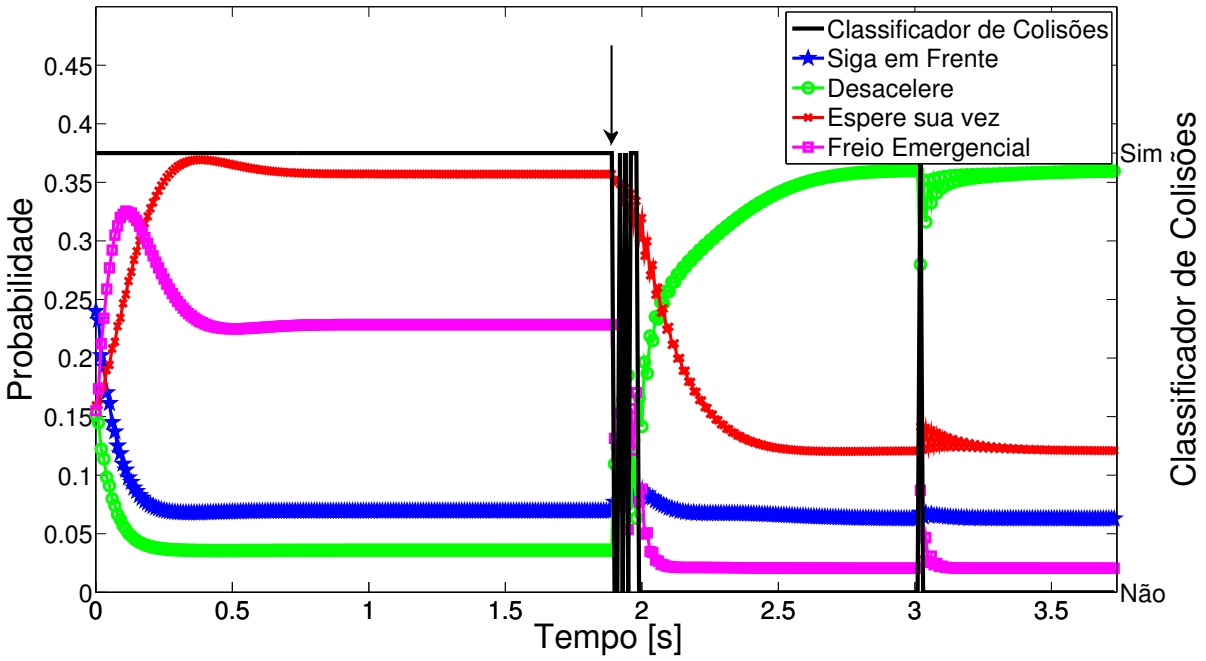

Figura 6.5: Gráfico resultante do teste $F_\Phi F_\Phi F_\Phi F_\Phi \Phi\Phi$ para o caso 1. Em destaque o resultado da classificação do nó de Situação Dinâmica D da Rede Bayesiana

Vê-se, na figura 6.5, que as instabilidades estão altamente relacionadas a mudança na classificação das colisões. Destaca-se a região entre $1,9$ e $2,1$ segundos de teste, onde há uma variação grande na asserção sobre a colisão com o obstáculo à frente. Essa instabilidade pode ser interpretada como o efeito dos estimadores no detector de colisões, uma vez que o veículo encontra-se na iminência de sair de uma situação de *colisão* para uma situação de *via livre*, desse modo, com um classificador sem robustez para esse tipo de ruído, uma mudança nos valores apresentados de velocidade e distância devido à estocasticidade dos estimadores provoca uma mudança na saída do classificador.

A figura 6.6 mostra o comportamento do carro autônomo através do seu estimador de velocidade e a figura 6.7 mostra a distância D_{AB} decrescida de $4,2$ m, valor esse equivalente ao comprimento de um Fiat Stilo (FIAT , 2005), uma vez que D_{AB} foi definido como a distância de centro a centro dos veículos. Além disso, defini-se uma distância de segurança de 1 m. Essa

pode ser vista na área rosada da figura 6.7.

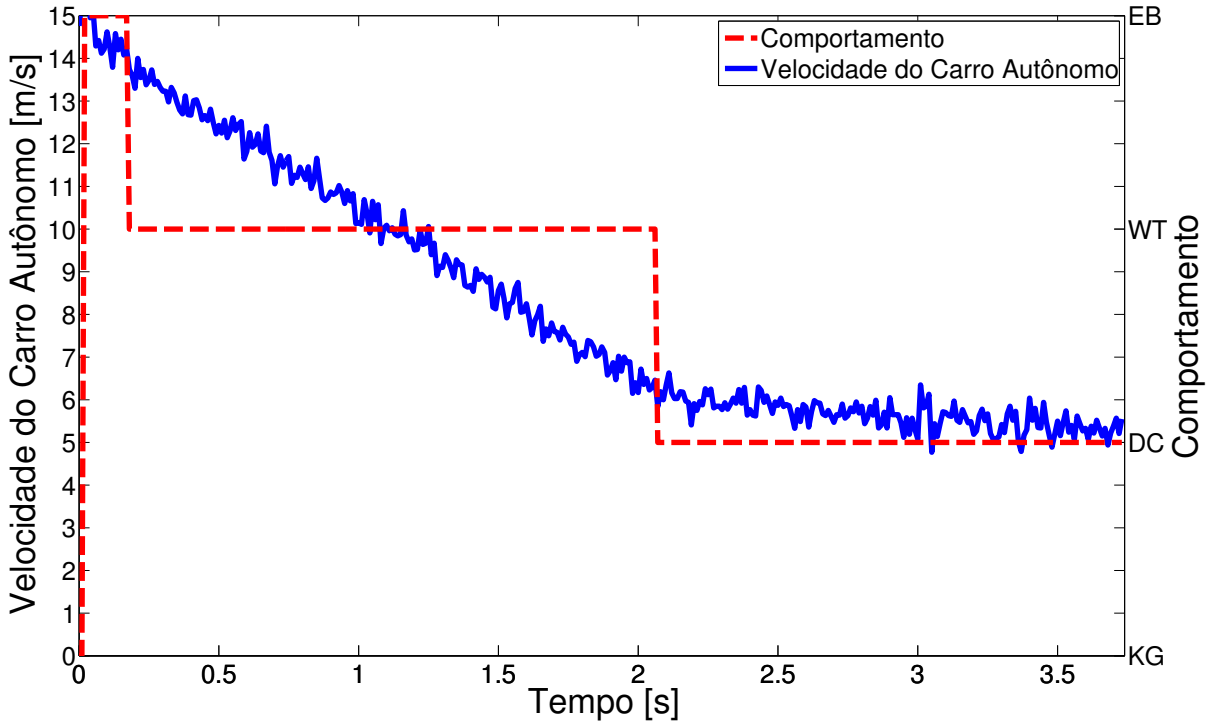

Figura 6.6: Gráfico resultante do teste $F_\Phi F_\Phi F_\Phi F_\Phi \Phi\Phi$ para o caso 1.

Tanto a figura 6.6 quanto a figura 6.7 mostram que o comportamento resultante do veículo foi satisfatório, reduzindo a velocidade e a estabilizando ao final do trajeto e mantendo uma distância segura com relação ao veículo frontal.

Uma vez que o nível de crença e a diferença entre as mesmas são fatores que influenciam na robustez da rede quanto a falhas nas classificações, fez-se o comparativo do desempenho médio das mesmas com os diferentes níveis de ruído. Como proposto pela tabela 2.2, esses níveis foram apenas modificados nos classificadores do cenário (nós V e I da Rede Bayesiana), enquanto a interferência dos ruídos foi mantida constante nos outros nós da rede. Tem-se, então, que os testes com o subscrito Φ em MIII e MIV fornecem os dados para o cálculo do desempenho médio para as redes com Acerto Ideal, os testes com subscrito Pq em MIII e MIV, para as redes de Acerto Alto e, por fim, os testes com subscrito Gd em MIII e MIV, para as redes de Acerto Baixo.

Fez-se uma análise preliminar das probabilidades das médias das redes antes das mesmas entrarem no filtro de segunda ordem. Para tanto, 2 momentos do teste foram analisados, um quando a asserção de colisão tinha probabilidade de acerto de $0,58\%$ (modelado como Gd, ver Tabela 2.2) e outro quando o oposto ocorreu. Assim, por probabilidades totais, obteve-se os

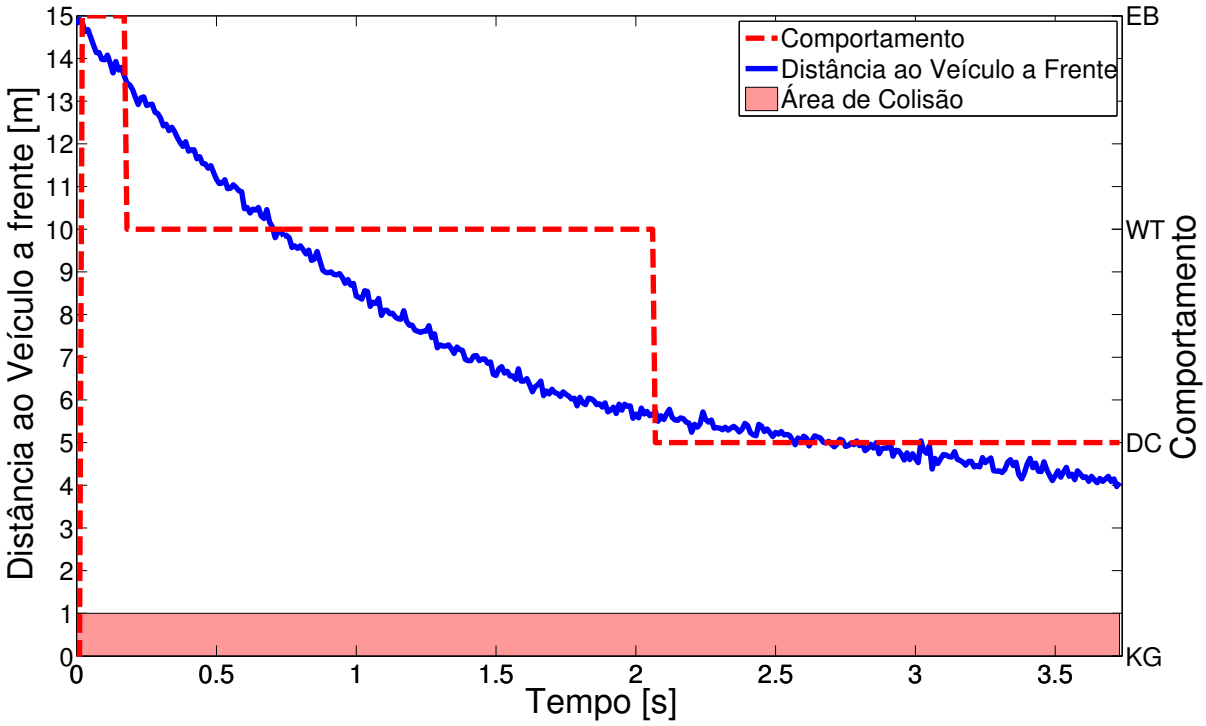

Figura 6.7: Gráfico resultante do teste $F_\Phi F_\Phi F_\Phi F_\Phi \Phi\Phi$ para o caso 1.

dados da Tabela 6.4. Os mesmos foram obtidos supondo conhecidos os estados de *Posição Atual* (nó P) e de *Pista Futura* (nó F) como $P =$*pista à direita* e $F =$*via reta*.

Tabela 6.4: Probabilidades preliminares dos comportamentos das redes Acerto Ideal, Acerto Alto e Acerto Baixo

Comportamento	**Rede**	$P(colisão) = 1$	$P(colisão) = 0,58$	$P(colisão) = 0,42$	$P(colisão) = 0$
$P(DC)$	*Acerto Ideal*	$0,0097$	$0,3282$	$0,4495$	$0,768$
	Acerto Alto	$0,0240$	$0,3112$	$0,4207$	$0,708$
	Acerto Baixo	$0,0336$	$0,2526$	$0,3361$	$0,555$
$P(EB)$	*Acerto Ideal*	$0,6444$	$0,3780$	$0,2765$	$0,010$
	Acerto Alto	$0,6237$	$0,3660$	$0,2678$	$0,010$
	Acerto Baixo	$0,5708$	$0,3350$	$0,2455$	$0,010$

Observa-se na Tabela 6.4, em uma análise por colunas, que os erros de classificação nos nós V e I conseguem transmitir os mesmos para a probabilidade dos comportamentos. Quando a colisão é predominante, o comportamento EB perde a crença com o aumento dos erros. Em contrapartida, o comportamento DC aumenta sua crença, deixando os dois níveis mais próximos e, assim, deixando o comportamento resultante mais oscilatório. Pode-se, agora, analisar o comportamento simulado das redes. A figura 6.8 ilustra os desempenhos comparativos das mesmas.

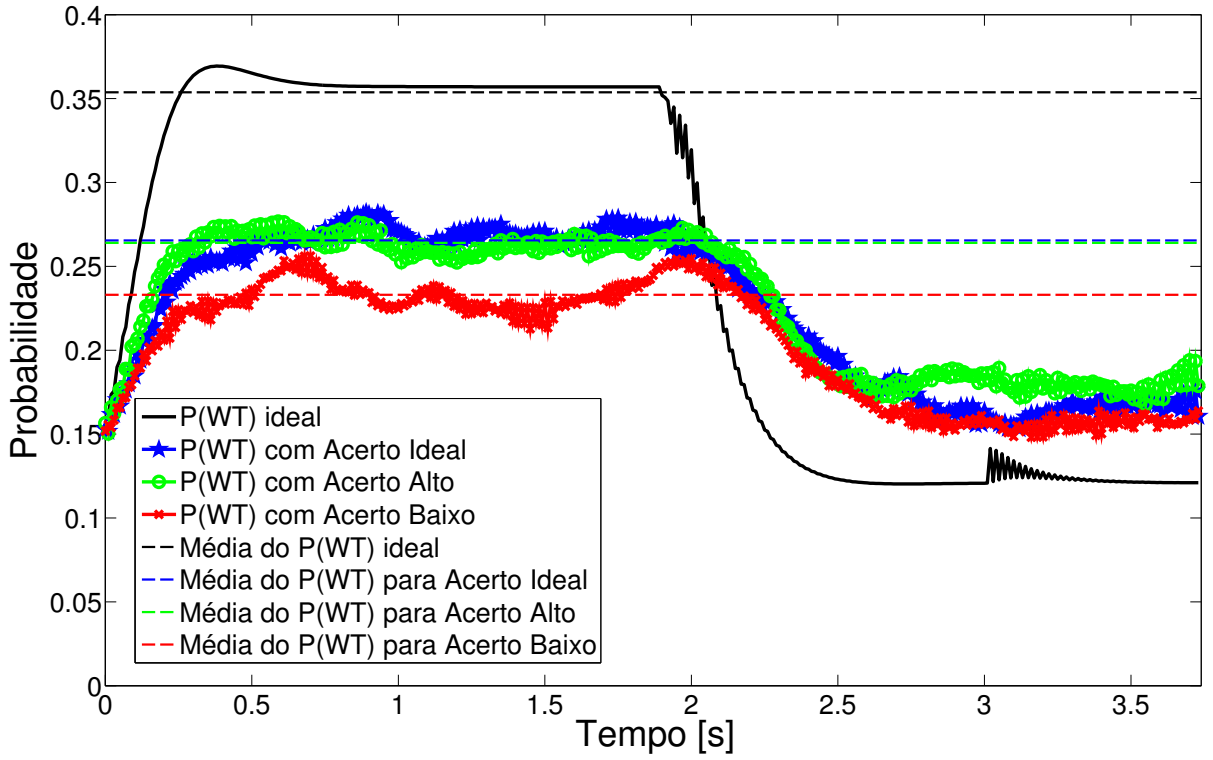

Figura 6.8: Gráfico resultante dos testes de desempenho médio para os níveis de ruído Acerto Ideal, Acerto Alto e Acerto Baixo. A comparação foi realizada com o comportamento WT (*Espere sua Vez*) e as médias calculadas quando esse comportamento foi selecionado pelo teste $F_\Phi F_\Phi F_\Phi F_\Phi \Phi\Phi$.

Na figura 6.8, encontram-se as probabilidades do desempenho médio das redes para o comportamento WT. Vê-se que a probabilidade do teste $F_\Phi F_\Phi F_\Phi F_\Phi \Phi\Phi$, considerado o caso ideal, tem valores de crença maiores que as probabilidades dos outros 3 testes (Acerto Ideal, Acerto Alto e Acerto Baixo) entre $0,3$ a $1,8$ segundos aproximadamente. Uma análise qualitativa foi feita considerando apenas o tempo em que o estado WT foi escolhido pelo teste $F_\Phi F_\Phi F_\Phi F_\Phi \Phi\Phi$.

Obteve-se as médias das probabilidades da resposta ideal, da rede de Acerto Ideal, da rede de Acerto Alto e da rede de Acerto Baixo. São, respectivamente, $0,354 \pm 0,017$, $0,265 \pm 0,010$, $0,264 \pm 0,006$ e $0,233 \pm 0,011$. Por essa análise, vê-se que a introdução de ruídos na rede é suficiente para diminuir a crença no estado WT e que uma pequena interferência de ruído na classificação do cenário não muda significativamente o nível da crença no estado atual, quando comparada ao caso desta classificação não ter interferência de ruídos. Esse fenômeno ocorre devido às transições definidas no filtro de segunda ordem, visto que há uma pequena variação das probabilidades na entrada do filtro como apresentado pela Tabela 6.4. Observa-se, também, que uma influência de ruídos ou sequências de más classificações devido a condições externas não previstas que induzem uma taxa de acerto do classificador tão baixa quanto 58% são capazes de

reduzir o nível médio de crença no comportamento deixando o sistema mais suscetível a erros de classificação como previsto pela Tabela 6.4.

As figuras 6.9 e 6.10 mostram o comportamento médio do veículo induzido pelas redes de Acerto Ideal, Acerto Alto e Acerto Baixo.

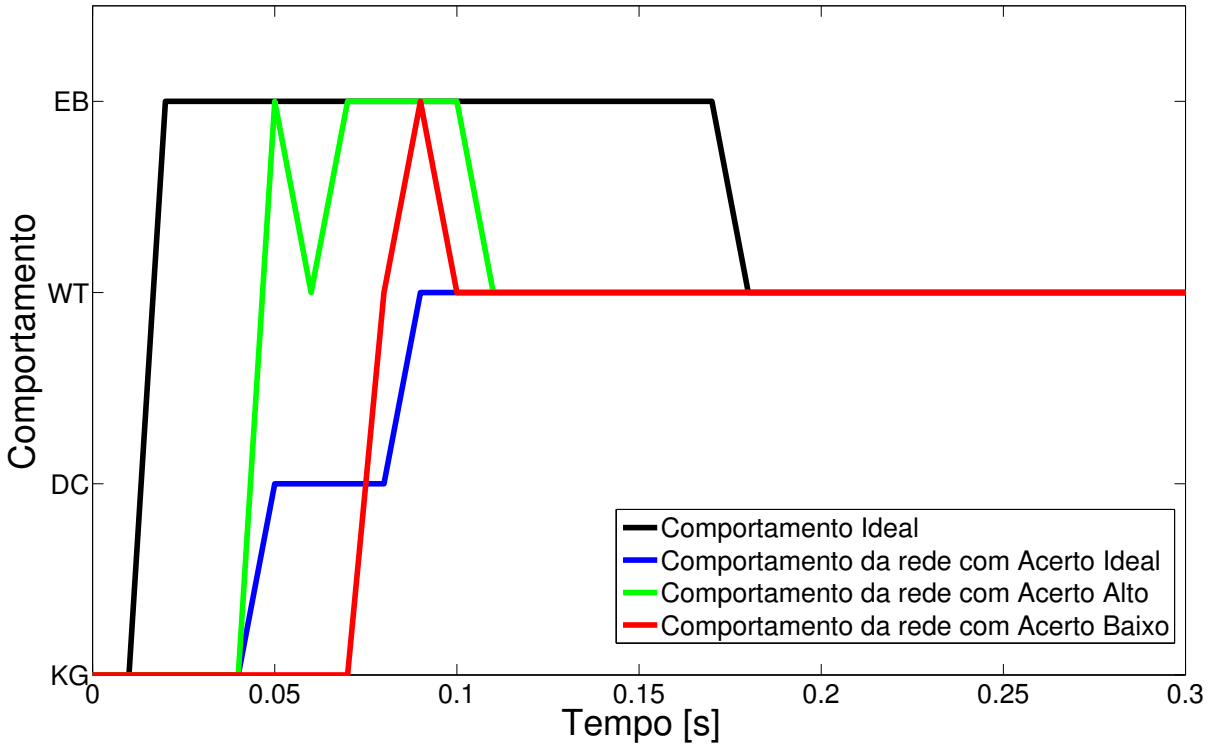

Figura 6.9: Gráfico resultante dos testes com as redes de Acerto Ideal, Acerto Alto e Acerto Baixo.

Observa-se que a decisão de começar algum tipo de frenagem (DC, WT ou EB), no início do experimento, apresentou um atraso de 30 milissegundos para a média das redes de Acerto Baixo se comparada com as outras redes com taxas melhores nos classificadores. Esse atraso pode ser explicado devido à diferença na crença da probabilidade da rede de Acerto Baixo se comparada às outras, pois um valor menor de probabilidade produz passos menores na saída do filtro de segunda ordem levando, assim, mais tempo para a torca de comportamentos ocorrer.

Tanto a rede com Acerto Ideal quanto a rede com Acerto Alto tiveram 30 ms de atraso se comparado com o teste $F_\Phi F_\Phi F_\Phi F_\Phi \Phi\Phi$. Se, agora, for analisada a média de colisões detectadas para cada rede, tem-se que a de Acerto Ideal, no teste em questão, teve uma amostra de $62,5\%$ de colisões contrariamente a $70,8\%$ de amostras para a rede de Acerto Alto. Pelo padrão observado na Tabela 6.4, um nível maior de colisões favorece os comportamentos de frenagem e, portanto, favorecendo comportamentos resultantes mais ligados a frenagem como mostra a figura 6.9.

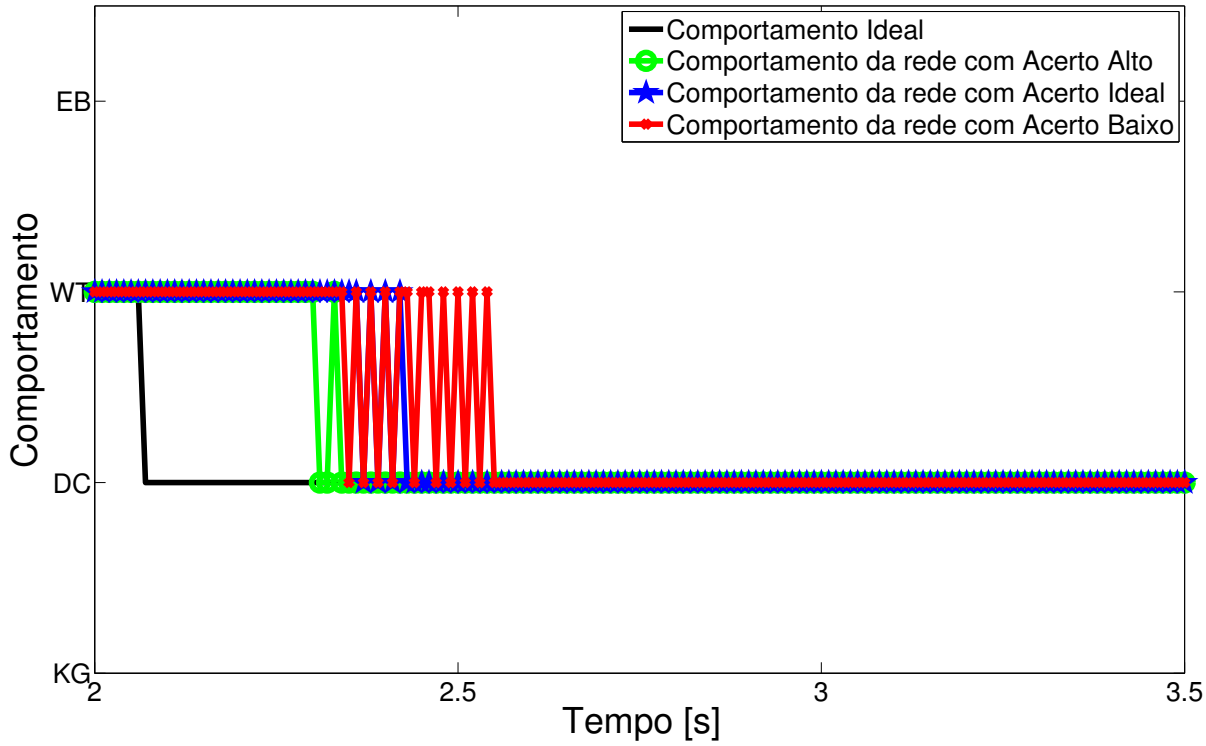

Figura 6.10: Gráfico resultante dos testes com as redes de Acerto Ideal, Acerto Alto e Acerto Baixo.

Vê-se, também, na figura 6.10 que os 3 comportamentos apresentaram oscilações no comportamento decidido, essas podem ser entendidas como as oscilações nas probabilidades dos estados em questão (DC e WT) durante a transição e devido a um nível mais baixo de crença comparado com $F_\Phi F_\Phi F_\Phi F_\Phi \Phi\Phi$, os testes feitos se mostram mais suscetíveis aos ruídos no classificador de colisões.

Faz-se, agora, a análise do efeito do tipo do classificador nas probabilidades e como medida de comparação fez-se a média de desempenho das redes cujos classificadores dos nós V e I são, respectivamente, fraco f e forte F (rfF), a média das redes com classificadores F e f (rFf), com classificadores f e f (rff) e, por fim, as redes com classificadores F e F (rFF). Como feito no caso dos ruídos, analisou-se previamente os valores das probabilidades dessas redes antes das mesmas entrarem no filtro de segunda ordem. A tabela 6.5 mostra as probabilidades condicionais $P(DC|colisão)$, $P(WT|colisão)$, $P(EB|colisão)$ e $P(DC|via\ livre)$ para cada tipo de classificador com duas classes de acerto, Φ (100%) e Gd $(0,58\%)$.

Como esperado, sem erros de classificação, quanto mais confiante for o classificador, ou seja, quanto maior for a sua força, maior será o nível de probabilidade, como o caso de $P(EB|colisão)$ e $P(DC|via\ livre)$. Quando o comportamento compete com algum que é favorecido na situ-

Tabela 6.5: Probabilidades preliminares dos comportamentos das redes rfF, rFf, rff e rFF

Redes	$P(DC\|colisão)$		$P(WT\|colisão)$		$P(EB\|colisão)$		$P(DC\|via\ livre)$	
	Φ	Gd	Φ	Gd	Φ	Gd	Φ	Gd
rfF	$0,019$	$0,033$	$0,247$	$0,258$	$0,649$	$0,577$	$0,782$	$0,572$
rFf	$0,020$	$0,034$	$0,248$	$0,259$	$0,648$	$0,570$	$0,779$	$0,550$
rff	$0,023$	$0,036$	$0,251$	$0,261$	$0,627$	$0,558$	$0,746$	$0,518$
rFF	$0,019$	$0,033$	$0,247$	$0,258$	$0,654$	$0,575$	$0,795$	$0,566$

ação, este tem sua crença reduzida com o aumento da força do classificador, como mostra $P(DC|colisão)$ e $P(WT|colisão)$, ambas menores que $P(EB|colisão)$.

Entretanto, a introdução de erros na classificação diminui a confiança nas crenças e, agora, há a combinação da partição com as classificações corretas com a partição que tem pelo menos uma resposta equivocada. Isto posto, percebe-se que, apesar de bem confiantes, dois classificadores fortes (rFF) não lidam bem com ruídos, pois, por projeto, a probabilidade para a partição com classificações errôneas é baixa e, ao final do processo, a confiança na crença correta é insuficiente para manter a resposta como sem a interferência do ruído.

Além disso, dois classificadores fracos (rff) não conseguem aumentar o nível de sua crença devido à dispersão das probabilidades nas classes, proposta pela definição deste tipo de classificador. Resta então, a opção mista entre os tipos de classificadores (rfF e rFf). Por definição desta dissertação, o módulo do cenário via GPS (nó I) apresenta certa vantagem sobre a visão devido à distinção em suas classes da *junção* em *junção de saída* e *junção de entrada*, em que tanto este último e a classe *via reta* apresentam o padrão procurado *via reta*. Devido a esse fato da modelagem, a rede com visão fraca e o GPS forte (rfF) apresenta níveis maiores de crença, como visto por $P(DC|via\ livre)$. A figura 6.11 mostra o desempenho médio das redes simulados separadas nas 4 categorias dos tipos de classificadores disponíveis.

Com a mesma análise qualitativa feita para a figura 6.8, podem-se encontrar as médias para as redes rfF, rFf, rff e rFF. Estas são, respectivamente, $0,261 \pm 0,008$, $0,252 \pm 0,009$, $0,254 \pm 0,010$ e $0,250 \pm 0,009$. Como esperado, da análise preliminar, a rede rfF apresentou um nível de crença maior que as outras comparadas. As figuras 6.12 e 6.13 ilustram os comportamentos médios decididos no início e no final do experimento, respectivamente.

Vê-se, pela figura 6.12, que a rede rfF teve uma resposta 30 ms mais rápida se comparada as outras três redes, isso devido a uma probabilidade média maior na entrada do filtro de segunda ordem, culminando em passos maiores na transição e, portanto, em uma troca de comportamentos mais rápida.

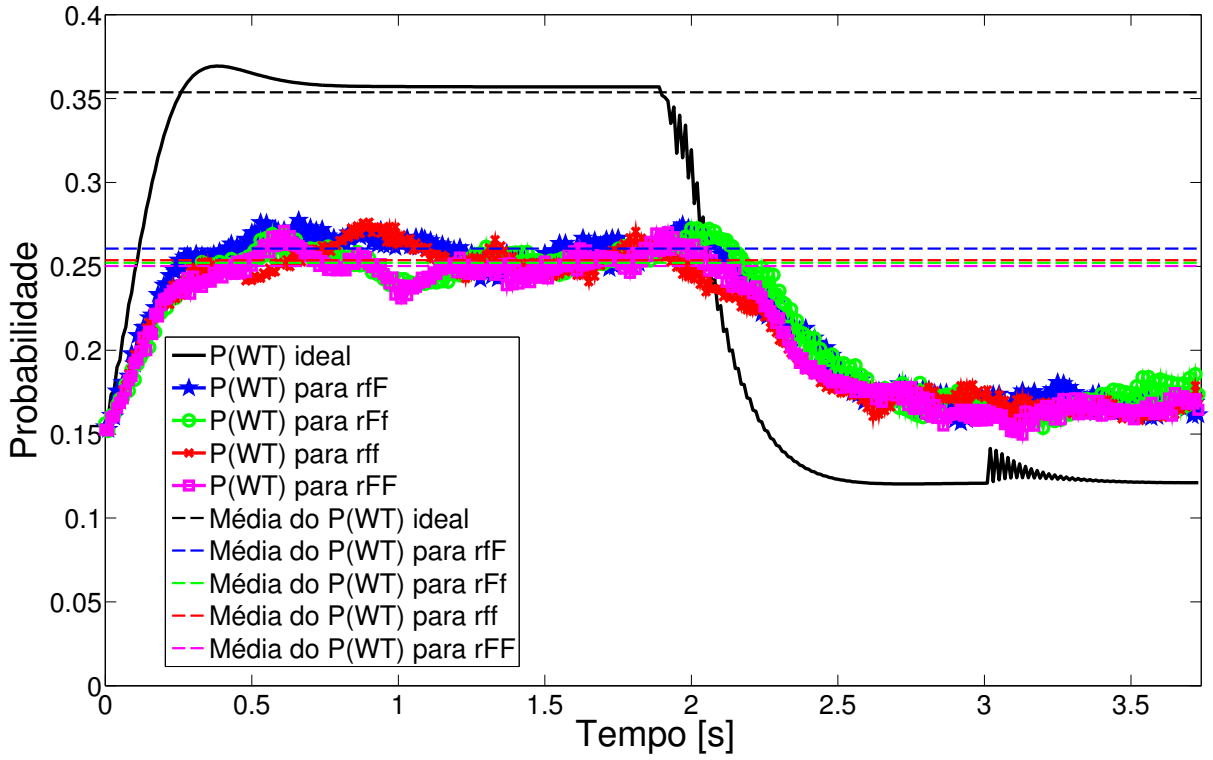

Figura 6.11: Gráfico resultante dos testes com as redes rfF, rFf, rff e rFF.

Para as redes rFf, rff e rFF, cujas médias, no experimento, ficaram próximas, pode-se explicar a variação nos comportamentos pela média de colisões apresentadas no início dos testes. Estas foram $62,5\%$, $77,1\%$ e $66,7\%$, respectivamente. Neste caso, o mesmo efeito observado na tabela 6.4 e na figura 6.9 ocorre, em que a porcentagem de colisão amostrada interfere no tipo de resposta. No caso em questão, quanto maior a amostragem, mais os comportamentos de segurança são favorecidos.

Quanto à mudança de WT para DC, vê-se para a rede rFF que não há oscilações em sua resposta, em detrimento de pequenas oscilações de rfF e das altas oscilações para rFf e rff. Ressalta-se, aqui, que apesar de no início a rede rff ter apresentado uma resposta mais semelhante ao ideal, a sua instabilidade para as baixas taxas no classificador se mostra no pico isolado presente na figura 6.13(b) por volta dos $2,9$ s.

Por fim, apenas com a finalidade de validar os experimentos feitos pela tabela 2.2 do capítulo 2, apresenta-se na figura 6.14 as distâncias do veículo autônomo ao carro frontal para cada teste.

Como pode ser observado na figura 6.14, nenhum dos testes entrou na região rosa, considerada como distância de segurança, e portanto, não houve colisão em nenhum dos testes realizados.

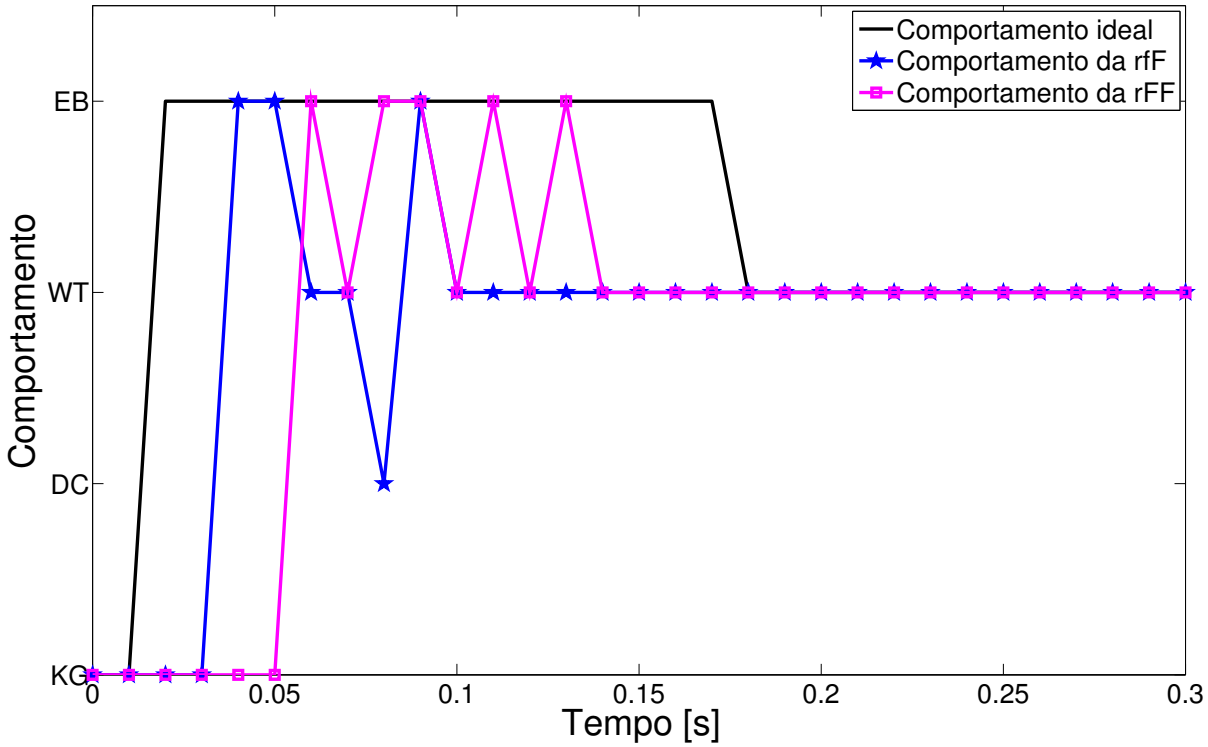

(a)

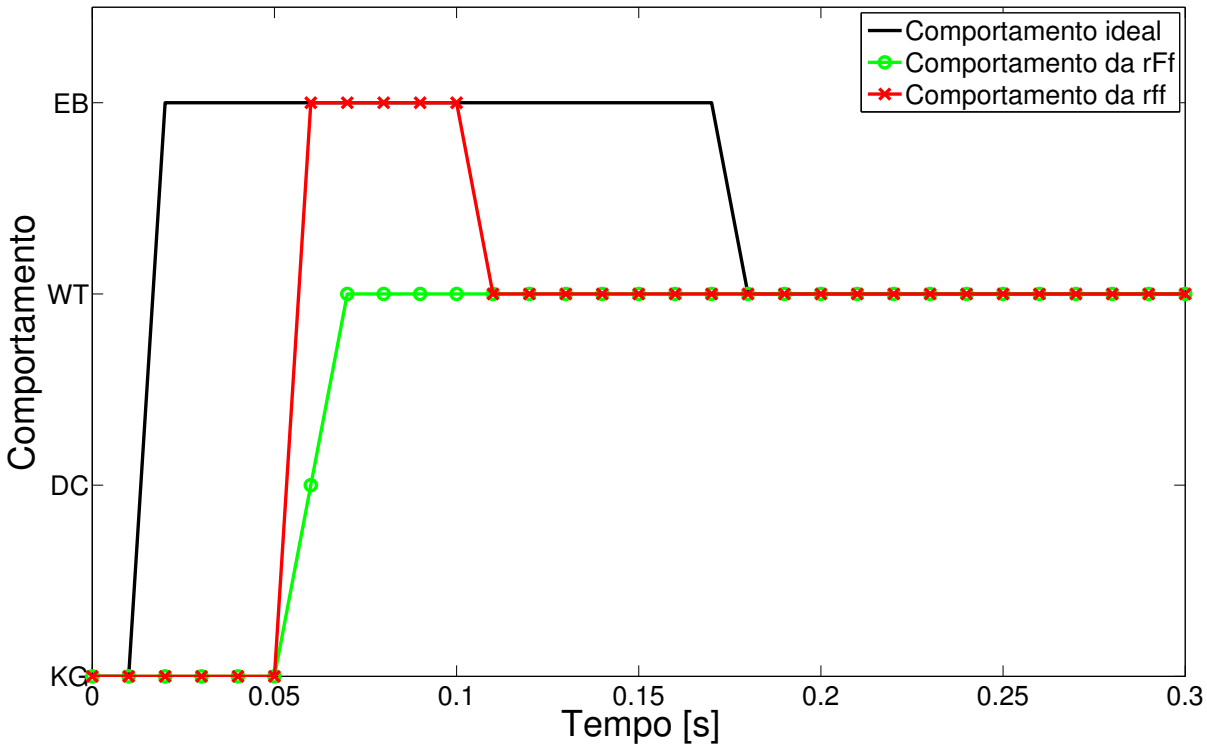

(b)

Figura 6.12: Comportamentos gerados pelas médias das redes. (a) redes rfF e rFF.(b) redes rFf e rff.

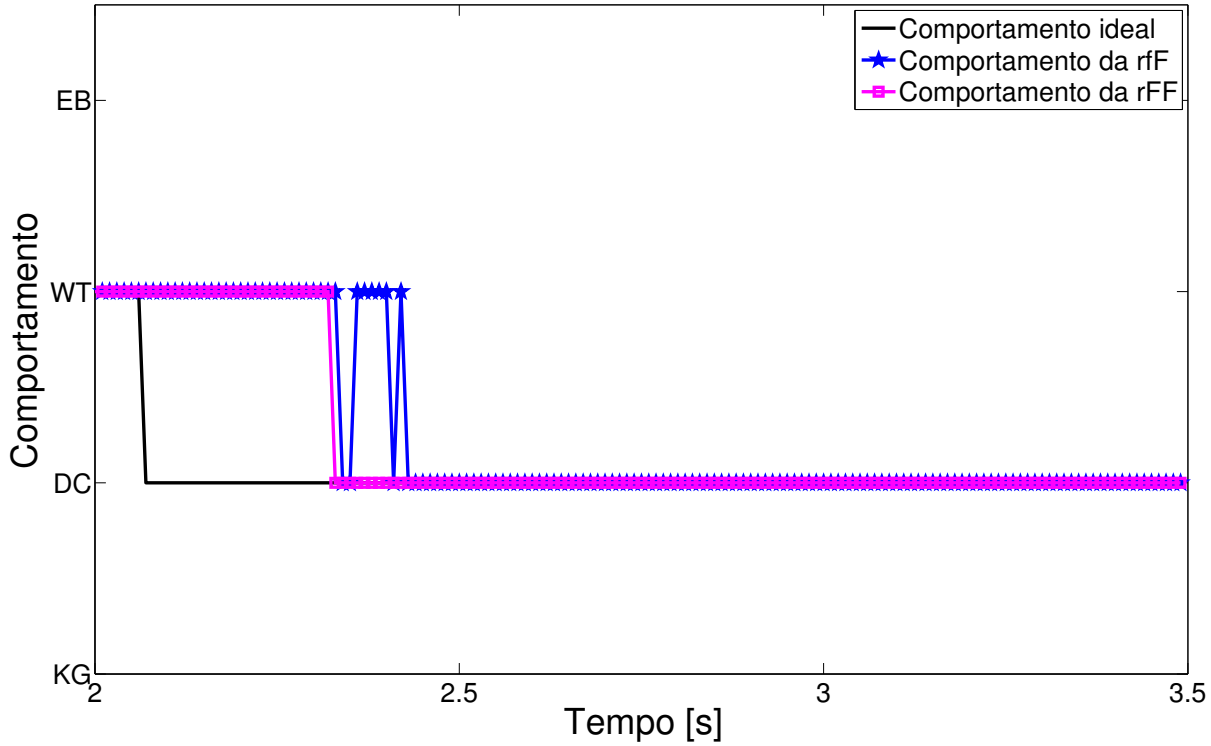

(a)

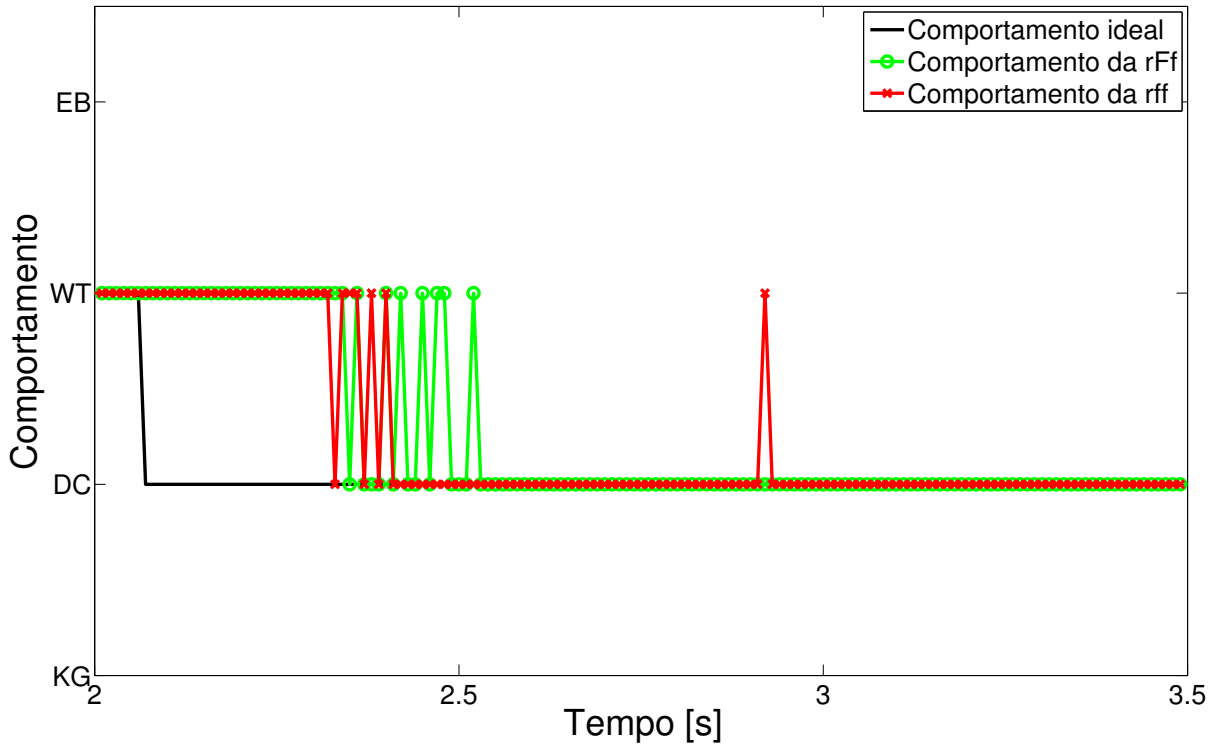

(b)

Figura 6.13: Comportamentos gerados pelas médias das redes. (a) redes rfF e rFF.(b) redes rFf e rff. Detalhe ao pico próximo ao tempo $t = 3$ s

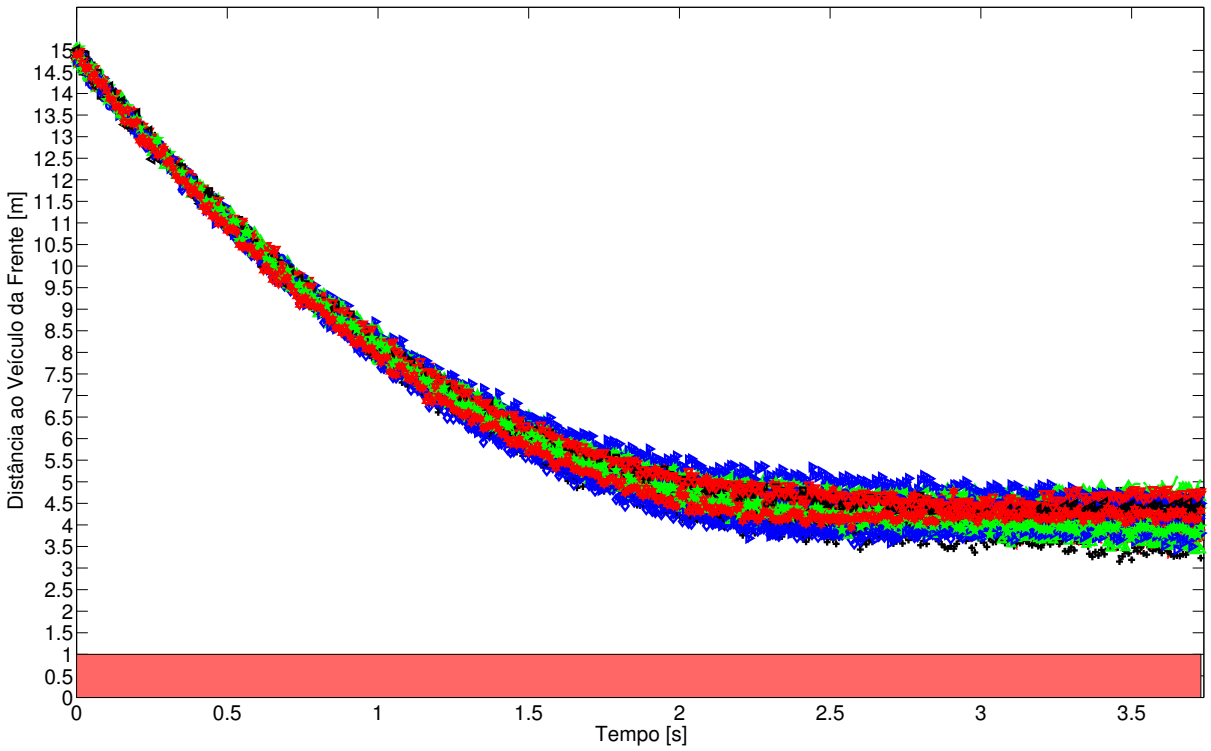

Figura 6.14: Gráfico resultante da distância ao veículo B para os 24 testes realizados

6.3 Caso - Cruzamento em T com dois veículos na via principal

O segundo caso estudado aborda o cenário em que o carro está em uma junção em T e tem a necessidade de fazer uma conversão à esquerda e detectar a presença de dois carros na via principal. Este teste busca testar os limites dos erros nos estimadores de velocidade e posição do veículo autônomo e dos outros participantes do tráfego.

Como citado no capítulo 2, para esse cenário serão testados 4 casos e para cado caso, 4 sub-casos serão postos à prova. Os casos diferenciam-se entre si pelo tempo que cada carro observado leva para chegar à intersecção. Repete-se aqui a tabela 2.3 contendo os tempos de cada veículo por conveniência. Ressalta-se que o veículo, doravante chamado de A, é o carro cujo movimento é da esquerda para à direita, enquanto que o veículo, doravante chamado de B, é o carro cujo movimento é da direita para à esquerda. Na sequência, a tabela 6.7 mostra os estimadores utilizados para cada sub-caso. Os estimadores com o subscrito $SENA$ referem-se ao protótipo GISA.

A figura 6.15 ilustra os parâmetros envolvidos na configuração dos experimentos e a tabela 6.8 contém os parâmetros iniciais usados para garantir a repetibilidade dos testes.

Observa-se, na figura 6.15, que há a consideração de possíveis prédios ou construções no

Tabela 6.6: Repetição da Tabela 2.3 com os testes da rede para o caso apresentado na figura 2.6(b)

ID	***Gap* do veículo A [s]**	***Gap* do veículo B [s]**
casoI	0	1
casoII	0	6
casoIII	5	0
casoIV	4	5

Tabela 6.7: Lista dos parâmetros utilizados nos Casos estudados e a distinção entre os sub-casos *erro baixo*, *erro na localização*, *erro no Acompanhamento* e *erro em ambos*

Estimador	**Unidade**	**Desvio Padrão**			
		erro baixo	*erro na localização*	*erro no Acompanhamento*	*erro em ambos*
$\hat{V}_{SENA}$	m/s	$0,25$	$2,00$	$0,25$	$1,50$
$\hat{P}_{xSENA}$	m	$0,06$	$4,00$	$0,06$	$3,00$
$\hat{P}_{ySENA}$	m	$0,06$	$4,00$	$0,06$	$3,00$
$\hat{\theta}_{SENA}$	rad	$0,02$	$0,36$	$0,02$	$0,18$
$\hat{V}_{xA}$	m/s	$0,25$	$0,25$	$1,50$	$1,50$
$\hat{V}_{yA}$	m/s	$0,25$	$0,25$	$1,50$	$1,50$
$\hat{P}_{xA}$	m	$0,10$	$0,10$	$3,00$	$3,00$
$\hat{P}_{yA}$	m	$0,10$	$0,10$	$3,00$	$3,00$
$\hat{V}_{xB}$	m/s	$0,25$	$0,25$	$1,50$	$1,50$
$\hat{V}_{yB}$	m/s	$0,25$	$0,25$	$1,50$	$1,50$
$\hat{P}_{xB}$	m	$0,10$	$0,10$	$3,00$	$3,00$
$\hat{P}_{yB}$	m	$0,10$	$0,10$	$3,00$	$3,00$

bloqueio da percepção dos sensores LIDAR. Para tanto, considerou-se calçadas de 2 m de largura (CREA-BA). Assim, apenas quando os veículos estão no campo de visão do sensores, os mesmos são informados ao carro autônomo. Entretanto, esse campo é diminuto se for considerado que o veículo ainda não se encontra na intersecção. Faz-se a seguir um exemplo numérico para o entendimento do problema:

Considere o centro do carro autônomo à 10 metros da intersecção, segundo o modelo do protótipo adotado, essa é a posição do sensor LIDAR 3D, considere as distâncias das calçadas como 2 metros e pistas de largura suficiente para comportar 2 carros lado a lado com segurança. Nessa situação, o carro consegue observar $39,1°$ à sua esquerda e apenas $23,6°$ à sua direita. Tais ângulos representam $9,3$ m e $6,3$ m, respectivamente, de distância efetiva em que se observa os obstáculos na via à frente (Números esses considerados baixos para a detecção de veículos). Se, agora, o carro estiver na intersecção, o campo de visão do sensor 3D passa a ser aproximadamente $180°$ e, assim, se é possível detectar todos os obstáculos em um raio de 100 metros, que é o range

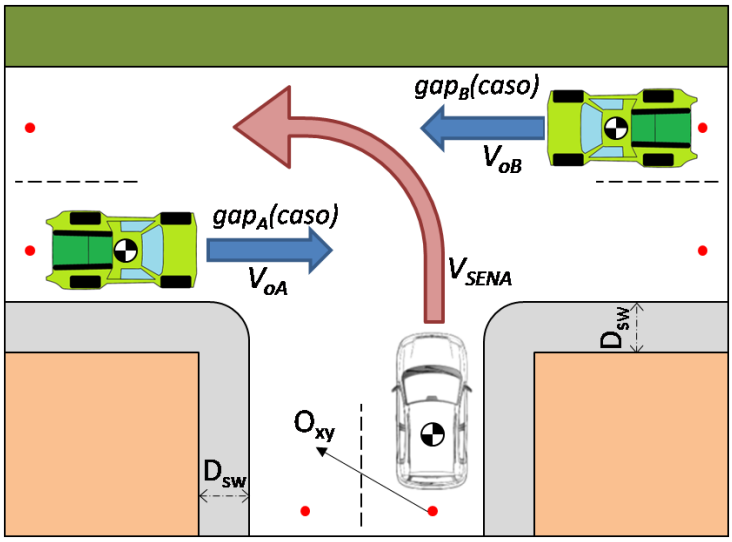

Figura 6.15: Parâmetros usados no teste do caso de tomada de decisão em um entroncamento em T.

Tabela 6.8: Lista dos parâmetros utilizados no Caso - Cruzamento em T com dois veículos na via principal

Símbolo	**Breve Descrição**	**Valor**	**Unidade**
V_{SENA}	Velocidade inicial do carro autônomo	4	m/s
V_{oA}	Velocidade inicial do veículo A	10	m/s
V_{oB}	Velocidade inicial do veículo B	10	m/s
D_{SW}	Largura da calçada	2	m
O_{xy}	Ponto de GPS da pista da direita há 10 m da intersecção	$[0\ 0]^T$	m
P_{SENA}	Posição inicial do carro autônomo	O_{xy}	m
P_{oA}	Posição inicial do veículo A	$\begin{bmatrix} 11,5 \\ 4,5 + gap_A(caso) \end{bmatrix}$	m
P_{oB}	Posição inicial do veículo B	$\begin{bmatrix} 14,5 \\ -1,5 - gap_B(caso) \end{bmatrix}$	m

máximo do sensor utilizado. Porém, não há mais espaço hábil para uma frenagem se o veículo estiver em velocidade e o sensor detectar obstáculos que antes estavam escondidos.

Devido a essa oclusão de obstáculos no cruzamento, define-se uma área considerada área de risco de colisão e, assim, o veículo deve diminuir sua velocidade a fim de possibilitar uma frenagem quando seu campo de visão for maior e uma colisão for detectada. Essa foi considerada com a largura da pista e de comprimento dos 7 m a $3,5$ m, medidos à partir da intersecção.

Como, por hipótese, tem-se o mapa métrico, pode-se modelar o grafo de colisão como apresentado na seção 4.1.4 e ilustrado na figura 6.16.

Vê-se na figura 6.16 que os pontos de encontro P_{MA} e P_{MB} foram definidos como o encontro

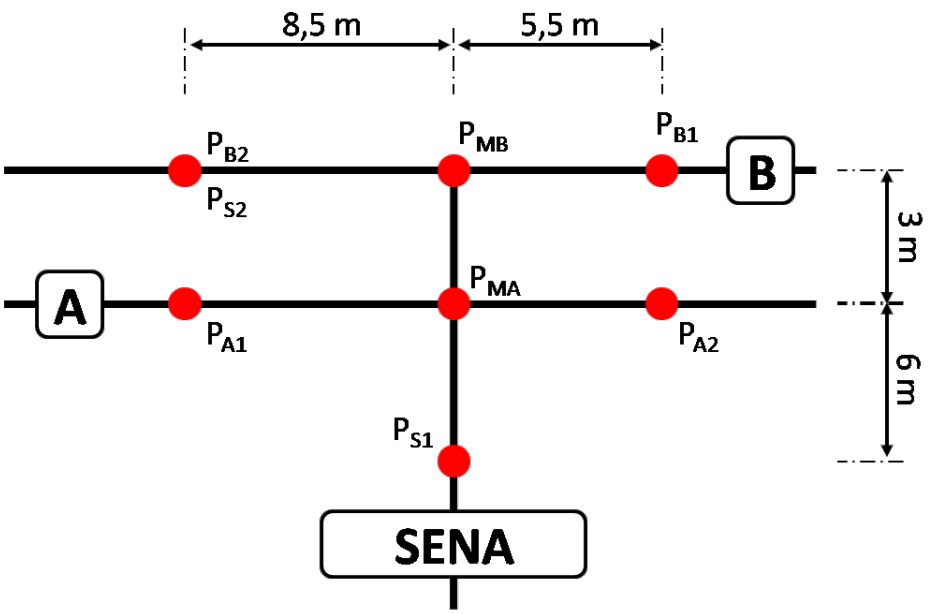

Figura 6.16: Modelo adotado de colisão para o caso estudado.

entre o centro da pista do carro SENA(Protótipo GISA) com o centro do carro da pista do carro A e com o centro da pista do carro B, respectivamente. A partir dos pontos de encontro, mapeiam-se os pontos de segurança P_{A1} e P_{A2} para o veículo A, P_{B1} e P_{B2} para o veículo B, por fim, P_{S1} e P_{S2} os pontos para o carro autônomo.

Segundo WERLING et al. (2008), para cada obstáculo, os seguintes critérios precisam ser cumpridos para classificar como *via livre*:

1. O tempo que SENA leva para chegar ao ponto de encontro P_{MA} ou P_{MB} deve ser maior que o tempo que A ou B leva para chegar ao mesmo ponto mais um tempo de segurança ΔT_{SA} ou ΔT_{SB}.

2. SENA deve percorrer uma distância até, no máximo, a distância a P_{S1}, enquanto A ou B chega em P_{A2} ou P_{B2}, respectivamente.

Como visto na seção 6.2, o cumprimento dessas exigências permite a passagem após o veículo na via principal. Entretanto, pode-se determinar se o veículo pode atravessar antes do carro na pista principal, para isso, outros dois critérios precisam ser cumpridos:

1. O tempo que SENA leva para chegar ao ponto de encontro P_{MA} ou P_{MB} deve ser menor que o tempo que A ou B leva para chegar ao mesmo ponto menos um tempo de segurança ΔT_{AS} ou ΔT_{BS}.

2. SENA deve percorrer a distância até P_{S2}, enquanto A ou B chegam em P_{A1} ou P_{B1}, respectivamente.

De maneira semelhante à seção 6.2 extrai-se as equações para os requisitos citados. Primeiramente para os requisitos que permitem o carro passar depois que o veículo atravessou a intersecção na via principal, como mostra as equações 6.6 a 6.10.

$$t_{S \to P_{MA}||P_{MB}} > t_{A||B \to P_{MA}||P_{MB}} + \Delta T_{SA||SB} \tag{6.6}$$

$$\hat{V}_{SENA} \cdot t_{A||B \to P_{A2}||P_{B2}} + t^2_{A||B \to P_{A2}||P_{B2}} < \hat{D}_{S \to P_{S1}} \tag{6.7}$$

$$t_{S \to P_{MA}||P_{MB}} = \frac{-\hat{V}^2_{SENA} + \sqrt{\hat{V}^2_{SENA} + 4\hat{D}_{S \to P_{MA}||P_{MB}}}}{2} \tag{6.8}$$

$$t_{A||B \to P_{MA}||P_{MB}} = \frac{\hat{D}_{A||B \to P_{MA}||P_{MB}}}{\sqrt{\hat{V}^2_{xA||B} + \hat{V}^2_{yA||B}}} \tag{6.9}$$

$$t_{A||B \to P_{A2}||P_{B2}} = \frac{\hat{D}_{A||B \to P_{A2}||P_{B2}}}{\sqrt{\hat{V}^2_{xA||B} + \hat{V}^2_{yA||B}}} \tag{6.10}$$

Onde $\Delta T_{SA||SB}$ são constantes de tempo definidos empiricamente e medidas em segundos, $\hat{D}_{A||B \to P_{MA}||P_{MB}}$ são os estimadores das distâncias dos carros A ou B até seus respectivos pontos de encontro em metros, $\hat{D}_{S \to P_{S1}}$ é o estimador da distância do SENA ao ponto P_{S1} em metros, $\hat{D}_{S \to P_{MA}||P_{MB}}$ é o estimador da distância do SENA ao ponto de encontro em metros e $\hat{D}_{A||B \to P_{A2}||P_{B2}}$ são os estimadores da distância dos veículos A ou B até seus respectivos pontos P_{A2} ou P_{B2} em metros.

Para o caso do carro autônomo poder passar em primeiro lugar na intersecção, tem-se as equações 6.11, 6.12, 6.8, 6.9, 6.13.

$$t_{S \to P_{MA}||P_{MB}} < t_{A||B \to P_{MA}||P_{MB}} - \Delta T_{AS||BS} \tag{6.11}$$

$$\hat{V}_{SENA} \cdot t_{A||B \to P_{A1}||P_{B1}} + t^2_{A||B \to P_{A1}||P_{B1}} > \hat{D}_{S \to P_{S2}} \tag{6.12}$$

$$t_{A||B \to P_{A1}||P_{B1}} = \frac{\hat{D}_{A||B \to P_{A1}||P_{B1}}}{\sqrt{\hat{V}^2_{xA||B} + \hat{V}^2_{yA||B}}} \tag{6.13}$$

Onde $\Delta T_{AS||BS}$ são constantes de tempo definidos empiricamente, $\hat{D}_{S \to P_{S2}}$ é o estimador da distância do SENA ao ponto P_{S2} e $\hat{D}_{A||B \to P_{A1}||P_{B1}}$ são os estimadores da distância dos veículos A ou B até seus respectivos pontos P_{A1} ou P_{B1}. Ressalta-se que todos os pontos usados para a asserção de colisão estão nas coordenadas do mapa local do veículo autônomo.

Com o problema estruturado, pode-se realizar a análise dos testes. Primeiramente, faz-se a análise do movimento desejado e o comportamento esperado para os quatro casos usando o teste *erro baixo*. A figura 6.17 ilustra a velocidade que SENA(Protótipo GISA) assumiu, as distâncias aos veículos A e B e o comportamento decidido pela Rede Bayesiana para o primeiro caso, com os veículos próximos a intersecção.

Nota-se, na figura 6.17 o problema das construções no campo de visão do veículo. Durante aproximadamente $0,5$ s, o carro A não foi avistado e o carro B só foi reconhecido 2 s após o começo do movimento. Tempo esse necessário para o SENA parar no cruzamento em segurança. Vê-se, também, que levou aproximadamente $0,4$ s para o carro autônomo mudar seu comportamento de KG para WT e começar a frenagem, uma vez que o veículo havia sido identificado. Se uma análise for feita nesse período de tempo para as probabilidades dos comportamentos em questão, pode-se reparar que a decisão em trocar o comportamento foi rapidamente identificada, entretanto, como o comportamento WT não pertence a lista de transições de KG, a troca efetiva dos comportamentos demora a acontecer. Essa transição pode ser vista na figura 6.18(a).

Uma vez parado, o carro permanece nesta situação por $2,5$ s para retomar o movimento, esse tempo de espera foi suficiente para os dois veículos, A e B, passarem o cruzamento na via principal. Se for observada a transição do comportamento de WT para LT, sendo que este não pertence a lista de transição do primeiro, vê-se que a troca de comportamentos leva 0.3 s. A figura 6.18(b) ilustra a transição das probabilidades $P(WT)$ e $P(LT)$.

A figura 6.19 ilustra a velocidade do carro autônomo e as distâncias deste para os outros veículos no segundo caso, em que o carro A está próximo a intersecção, entretanto, o carro B está longe o suficiente para permitir que o SENA entre no cruzamento.

Nesta nova situação, vê-se que o veículo autônomo novamente foi capaz de frear a tempo e permitir a passagem do carro A. Entretanto, a distância do veículo B permitiu a passagem do SENA no cruzamento antes do outro fazê-lo. Observa-se que o problema de oclusão aqui

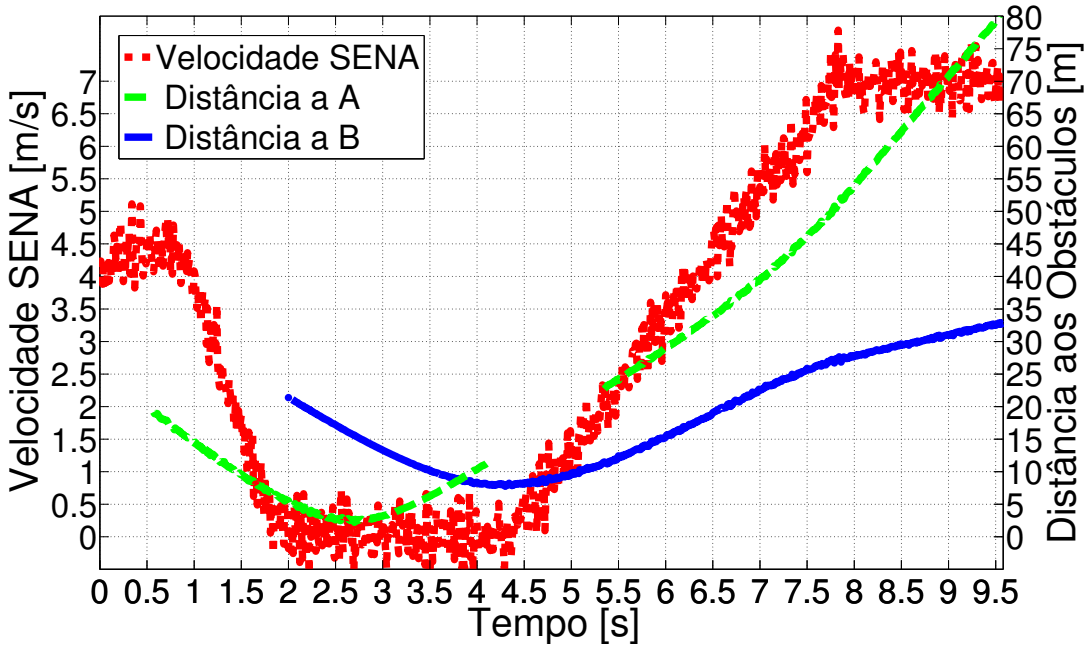

(a)

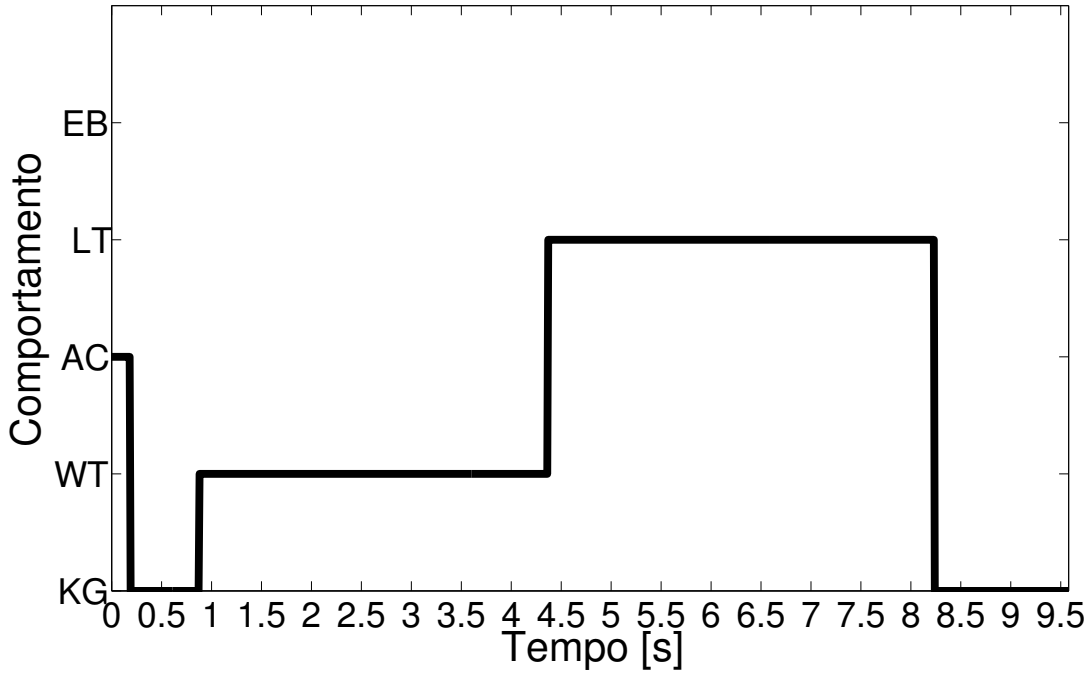

(b)

Figura 6.17: Caso 1, A e B com *gaps* 0 e 1 s, respectivamente. (a) Velocidade SENA e distância a A e B. (b) Comportamento Resultante da Rede Bayesiana.

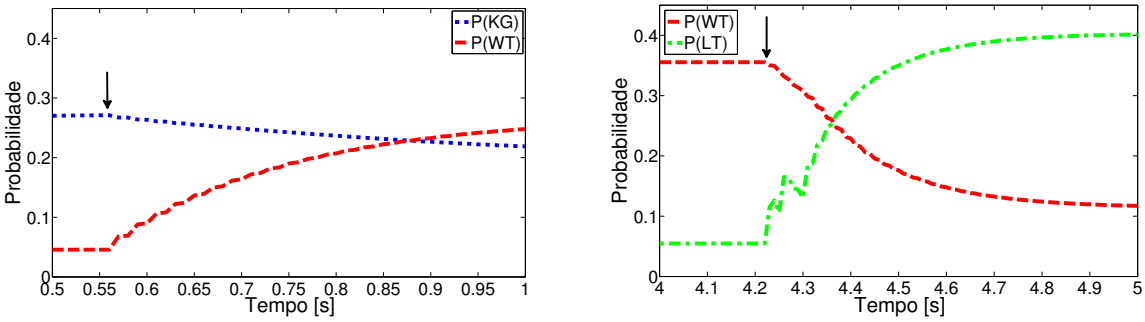

(a) (b)

Figura 6.18: Análise das probabilidades durante o caso 1 com o sub-caso *erro baixo* (a) Análise entre $0,5$ s e 1 s para as probabilidades P(KG) e P(WT). (b) Análise entre 4 s e 5 s para as probabilidades P(WT) e P(LT).

se faz presente, uma vez que levou aproximadamente 1 s com o SENA em movimento para o carro B começar a ser rastreado. A figura 6.20 traz a situação inversa onde, agora, o veículo B está próximo à intersecção e o carro A está a uma distância que permite o veículo autônomo atravessar o cruzamento primeiro.

Pela 6.20(a) observa-se que o veículo praticamente não parou na intersecção, isso pois quando o mesmo chegou a velocidade nula, o carro B havia passado o ponto de segurança, permitindo o SENA a atravessar o cruzamento, como o veículo A não estava no campo de visão, foi suposto pista livre e o veículo começou a realizar a conversão à esquerda até o momento em que o carro A começou a ser rastreado e a não-colisão confirmada pelo carro autônomo. A figura 6.20(b) comprova o fato do carro praticamente não ter parado pelo curto período em que WT ficou ativo. (≈ 1 s).

Por fim, a figura 6.21 ilustra o movimento do veículo quando tanto o carro A quanto o carro B estão longe o suficiente para permitir que o SENA seja o primeiro veículo a entrar no cruzamento. É importante notar na figura 6.21(b) que de 1 s a $2,5$ s o comportamento escolhido foi WT e se for comparada essa faixa de tempo com a figura 6.21(a), vê-se que os obstáculos não foram ainda detectados, isso se deve à região de risco de colisão proposta, obrigando o carro autônomo frear nesno que não observe os obstáculos. Além disso, próximo à $t = 6,5$ s, o veículo A se encontra bem próximo ao SENA, isto ocorre pois os carros estão lado a lado na mesma via.

Analisa-se, agora, a diferença dos comportamentos quando o erro na estimativa da localização e da velocidade do carro é alto como o apresentado pela Tabela 6.7. A figura 6.22 ilustra os 4 casos comparando o comportamento gerado pelos sub-casos *erro baixo* e o *erro na localização*, o período de tempo analisado difere de caso para caso devido a peculiaridade de cada, entretanto

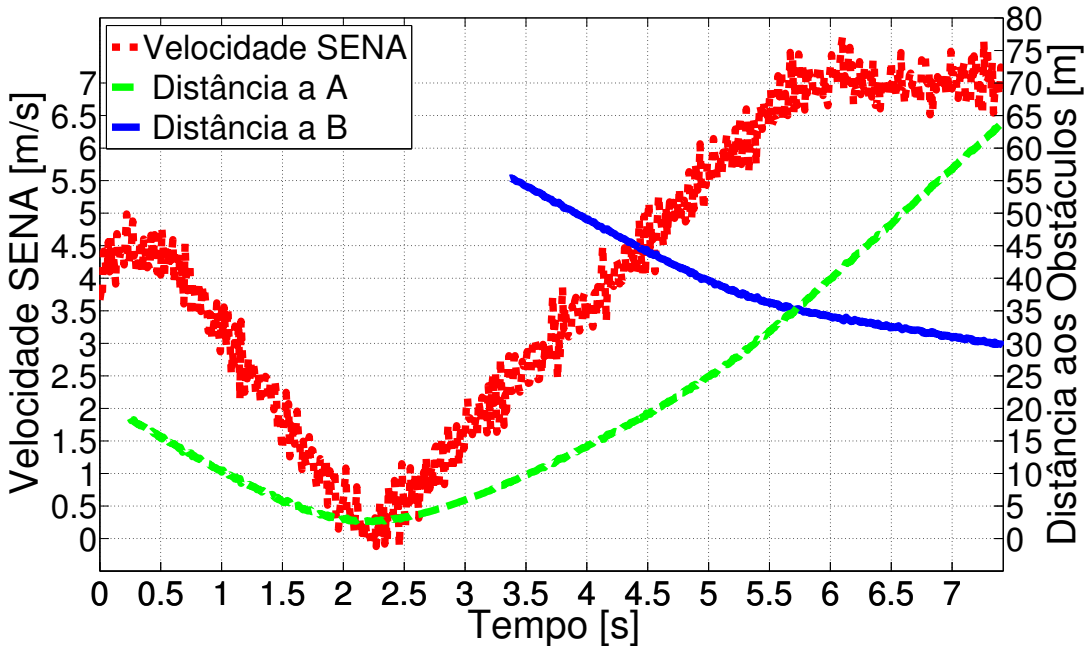

(a)

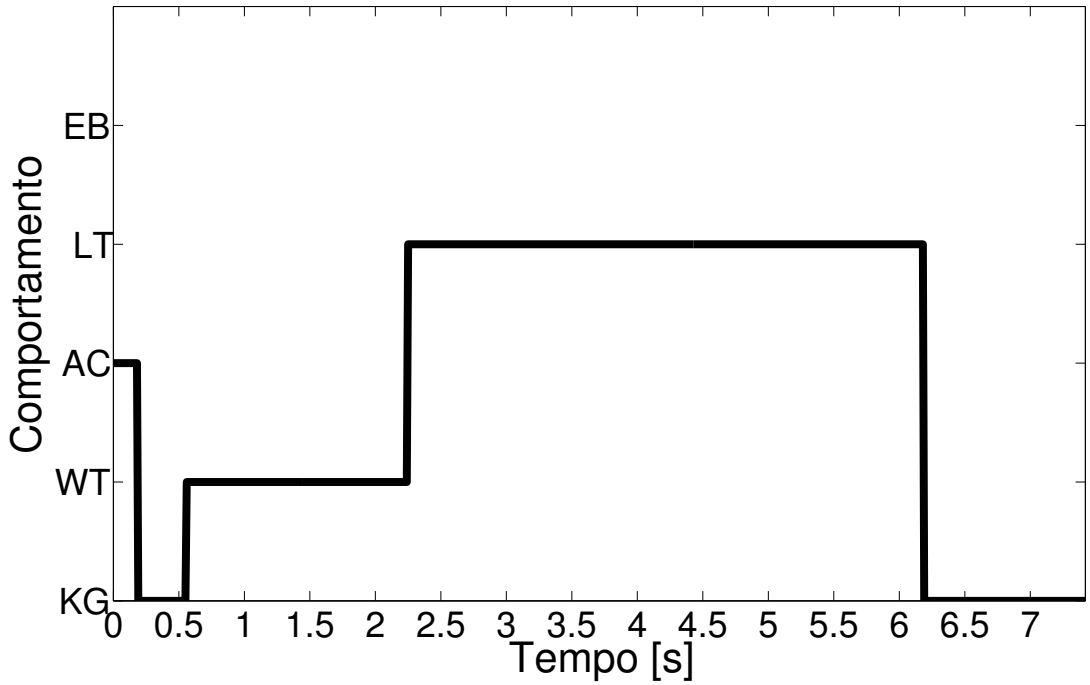

(b)

Figura 6.19: Caso 2, A e B com *gaps* 0 e 6 s, respectivamente. (a) Velocidade SENA e distância a A e B. (b) Comportamento Resultante da Rede Bayesiana.

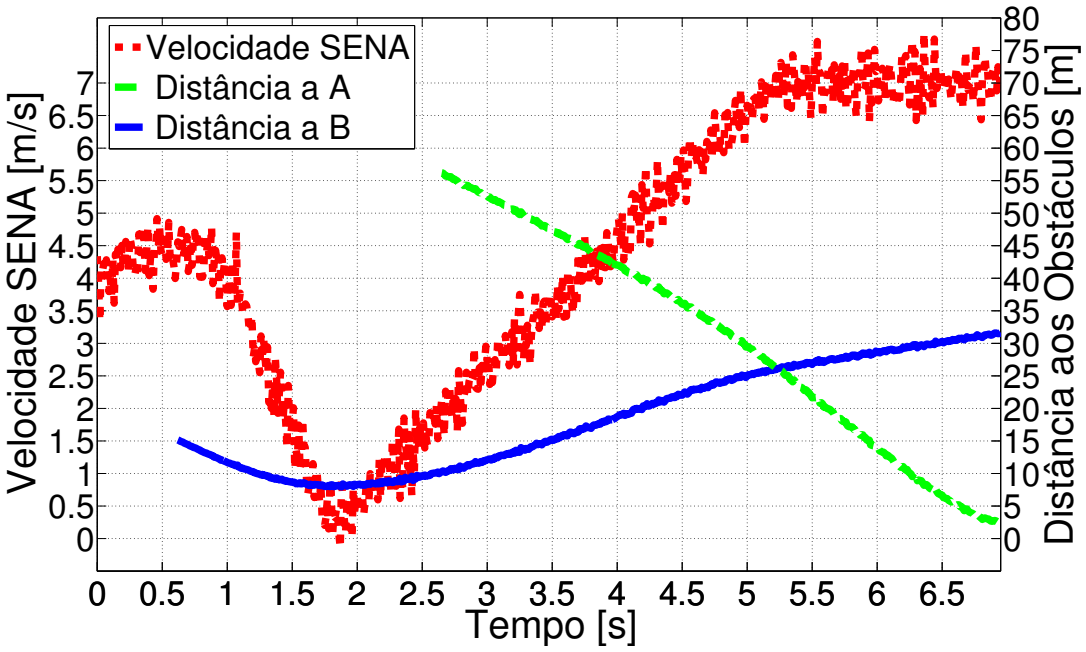

(a)

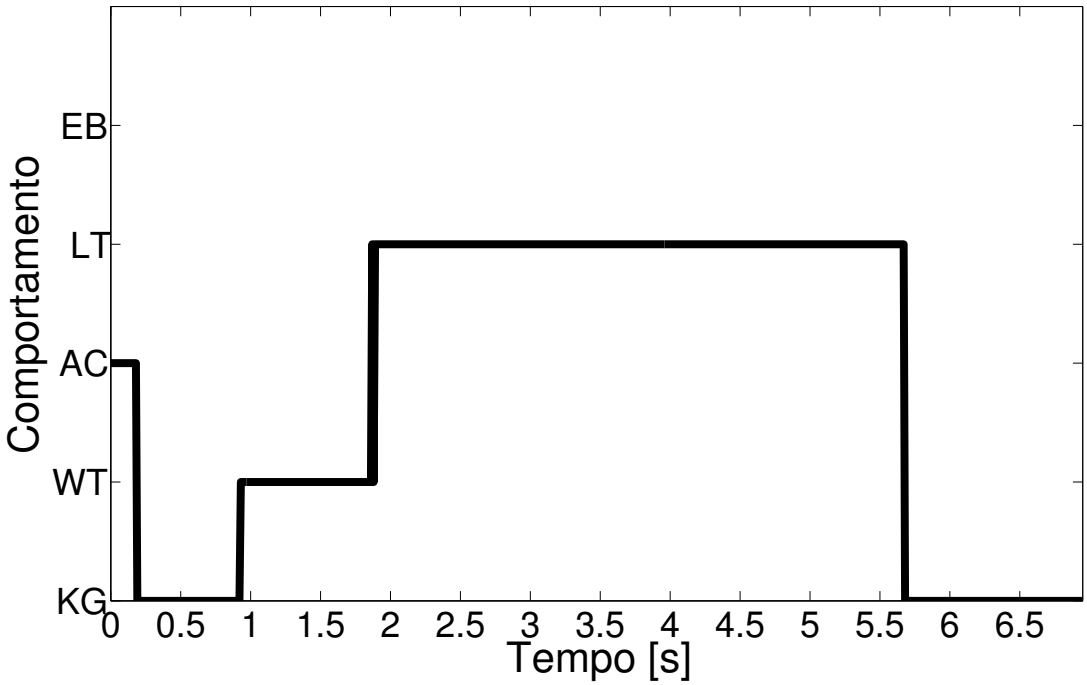

(b)

Figura 6.20: Caso 2, A e B com *gaps* 5 e 0 s, respectivamente. (a) Velocidade SENA e distância a A e B. (b) Comportamento Resultante da Rede Bayesiana.

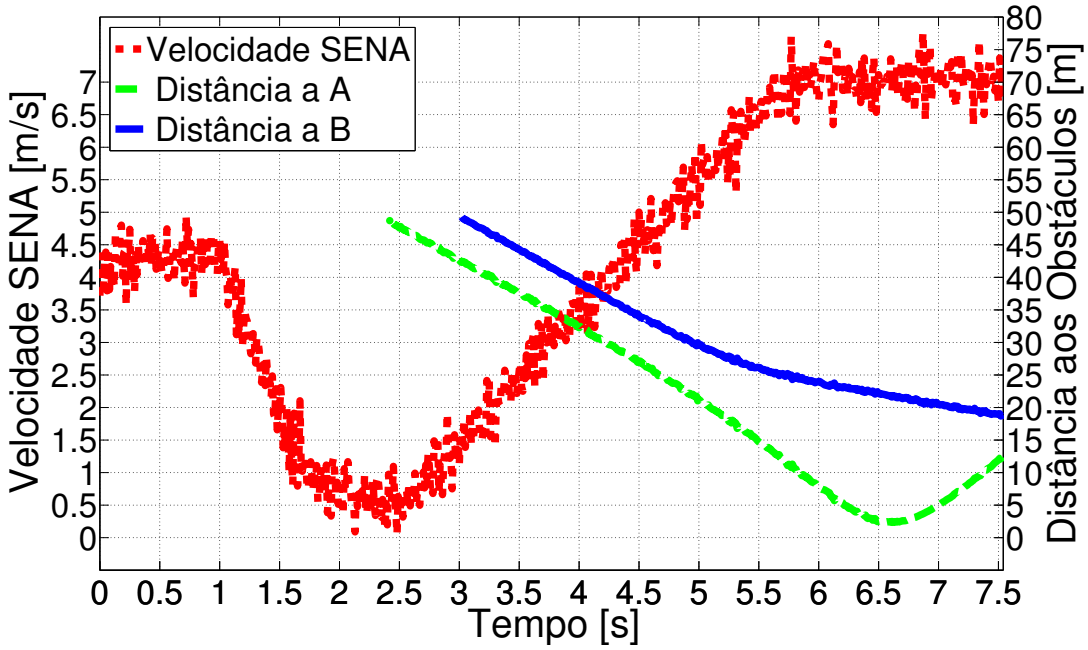

(a)

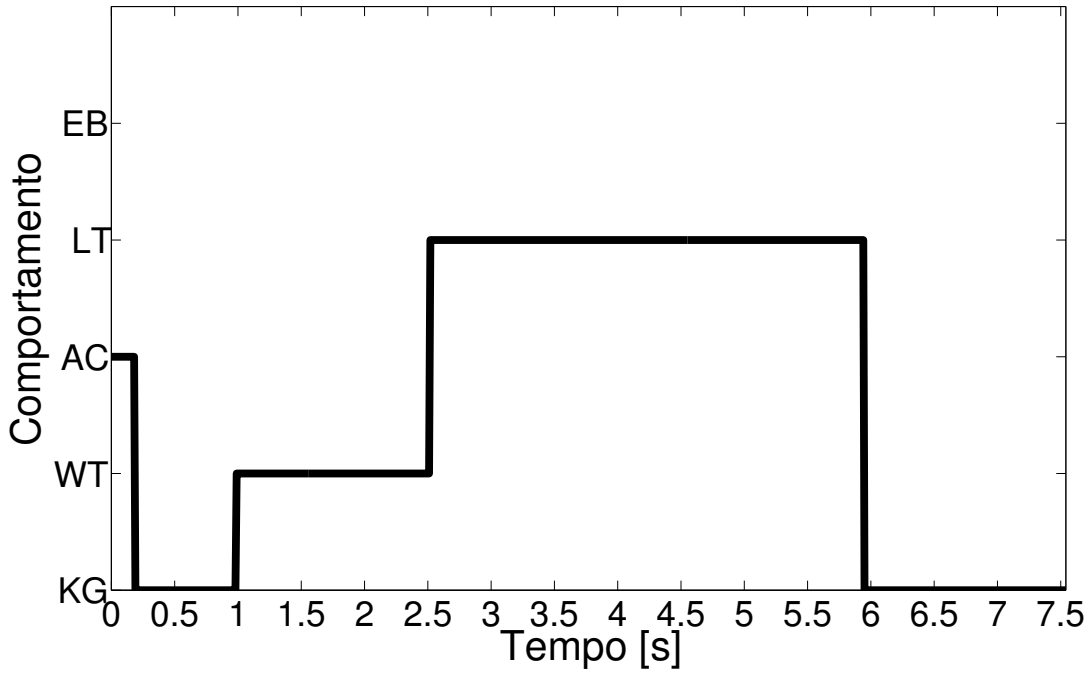

(b)

Figura 6.21: Caso 2, A e B com *gaps* 4 e 5 s, respectivamente. (a) Velocidade SENA e distância a A e B. (b) Comportamento Resultante da Rede Bayesiana.

todos fazem referência ao momento em que o carro autônomo está próximo à intersecção.

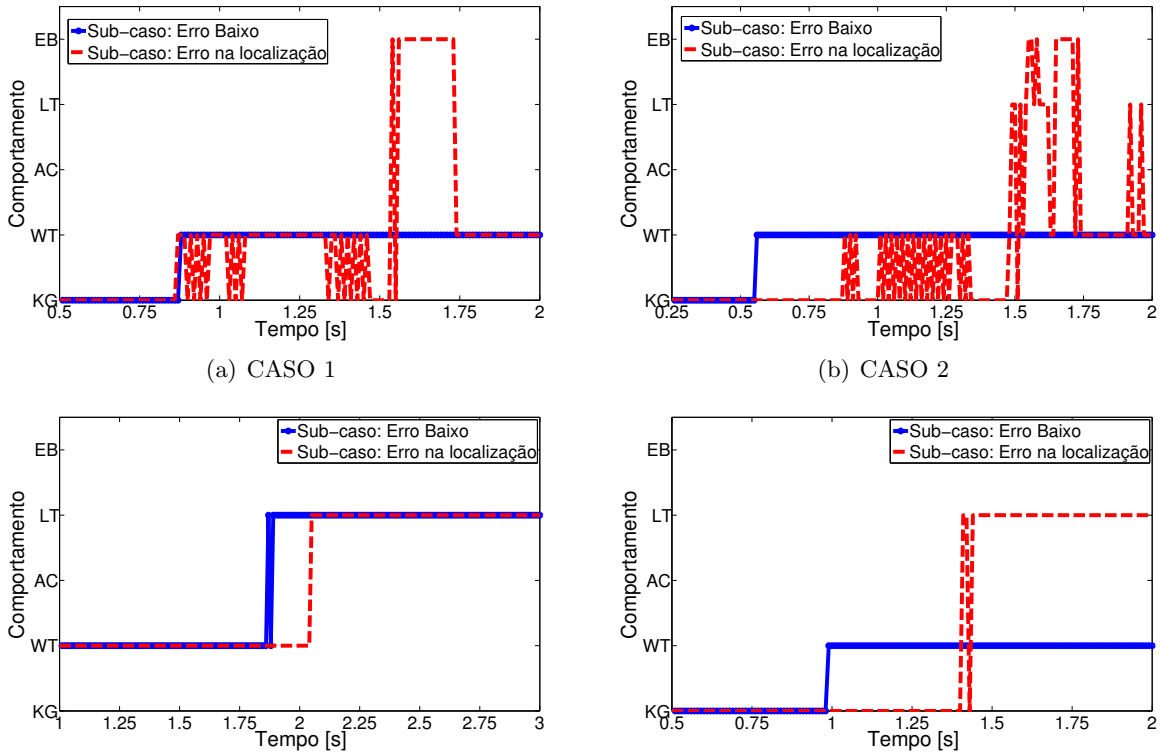

(a) CASO 1

(b) CASO 2

(c) CASO 3

(d) CASO 4

Figura 6.22: Caso - Cruzamento em T com dois veículos na via principal (a) Comportamentos do caso 1 para os sub-casos *erro baixo* e o *erro na localização* (b) Comportamentos do caso 2 para os sub-casos *erro baixo* e o *erro na localização*. (c) Comportamentos do caso 3 para os sub-casos *erro baixo* e o *erro na localização*. (d) Comportamentos do caso 4 para os sub-casos *erro baixo* e o *erro na localização*

Observa-se na figura 6.22(a) que, aproximadamente aos $0,9$ s, os dois sub-casos testados para o caso 1 trocaram seu comportamento de KG para WT e, assim, iniciaram uma manobra de frenagem. Entretanto, o erro de localização imposto pelo teste introduziu ruídos na rede através do classificador de situação dinâmica (nó D) e esta obteve a sua resposta de forma bem instável. Esse efeito pode ser observado também na figura 6.22(b).

Nos dois casos, o veículo A está a vista e a asserção sobre a colisão é feita através das equações 6.6 a 6.10. O erro das estimativas de posição e velocidade do carro autônomo afetam, não só o estimador $\hat{V}_{SENA}$ mas também a posição de P_{MA} ou P_{MB}, pois estes são transportados para o mapa local do veículo a fim da análise com os obstáculos ser feita. Com isso, pode-se dizer que os erros criam uma região de incerteza para a asserção de colisão, e quando a solução das equações 6.6 e 6.7 caem nessa região, como é o caso para o carro A próximo, a classificação das mesmas se é *via livre* ou *colisão* se torna aleatória e assim, tornando a resposta da rede instável.

A figura 6.22(c) apenas mostra que a rede apresentou um atraso no comportamento de WT de $0,2$ s. A situação do caso 3, o carro B esta na vista do veículo autônomo e este freia, mesmo com o erro de localização. Porém, esse último introduziu incertezas ao classificador dinâmico (nó D) e, por consequência, um atraso na decisão em trocar o comportamento. É importante notar que a distância ao veículo influenciou o tipo de resposta, se era ruidosa ou com atraso. Isso ocorre pois a estimativa das distâncias aos objetos está com o erro baixo.

A figura 6.22(d) ilustra o efeito que um erro na localização provoca quando se usa uma parte do mapa para mudar o comportamento do veículo. No caso em questão, com o sub-caso *erro baixo*, o carro foi capaz de perceber a área de risco de colisão e mudou seu estado para WT, já o sub-caso *erro na localização*, essa área não é reconhecida pelo veículo e, como não há obstáculos no campo de visão, apenas mantém seu curso até chegar ao ponto em que consegue observar os outros carros e devido a sua alta velocidade, consegue atravessar o cruzamento sem perigo devido aos *gaps* impostos no teste.

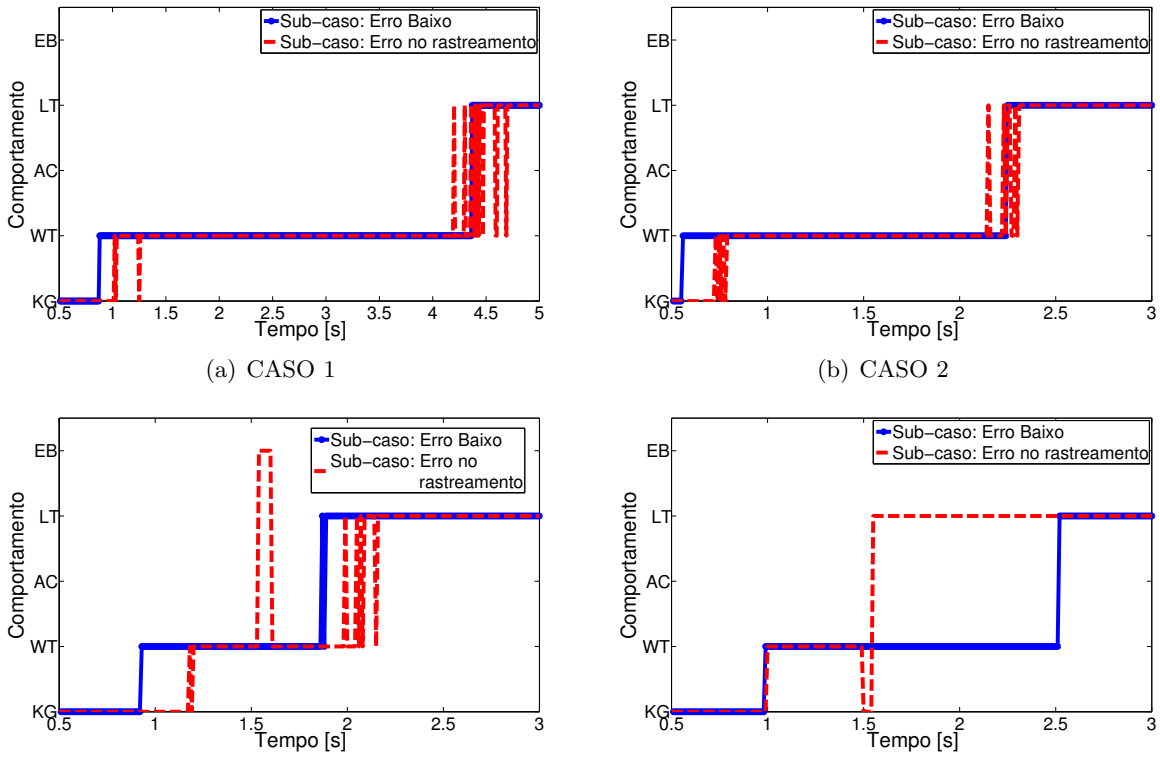

Figura 6.23: Caso - Cruzamento em T com dois veículos na via principal (a) Comportamentos do caso 1 para os sub-casos *erro baixo* e o *erro no rastreamento* (b) Comportamentos do caso 2 para os sub-casos *erro baixo* e o *erro no rastreamento*. (c) Comportamentos do caso 3 para os sub-casos *erro baixo* e o *erro no rastreamento*. (d) Comportamentos do caso 4 para os sub-casos *erro baixo* e o *erro no rastreamento*

Observa-se nas figuras 6.23(a), 6.23(b) e 6.23(c) que o erro no rastreamento atrasou a resposta da rede e a deixou instável. Isso se deve ao fato do erro na estimativa do posicionamento dos obstáculos interferir diretamente na asserção de colisão, uma vez que se o carro autônomo não reconhece ao certo onde estão os obstáculos, a sua ação também é incerta. Nota-se também, que na figura 6.23(d), a área de risco de colisão foi percebida e o comportamento foi trocado para WT, entretanto, dado a estimativa tão incerta do posicionamento dos outros carros, o comportamento LT foi rapidamente escolhido.

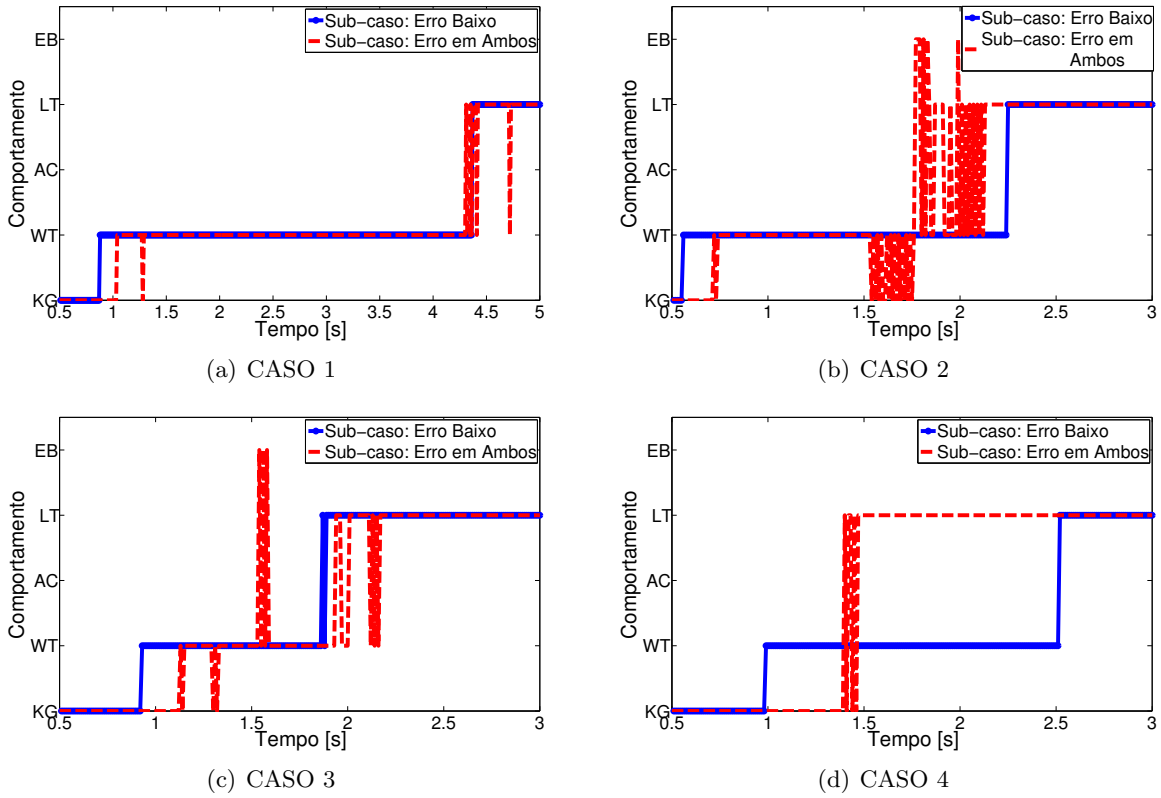

(a) CASO 1

(b) CASO 2

(c) CASO 3

(d) CASO 4

Figura 6.24: Caso - Cruzamento em T com dois veículos na via principal (a) Comportamentos do caso 1 para os sub-casos *erro baixo* e o *erro em ambos* (b) Comportamentos do caso 2 para os sub-casos *erro baixo* e o *erro em ambos*. (c) Comportamentos do caso 3 para os sub-casos *erro baixo* e o *erro em ambos*. (d) Comportamentos do caso 4 para os sub-casos *erro baixo* e o *erro em ambos*

Por fim, faz-se a análise do sub-caso *erro em ambos* ilustrados pela figura 6.24. Como esperado, com os dois ruídos, os efeitos foram somados tornando a rede mais instável. Ressalta-se, que a instabilidade indica um nível baixo nas crenças dos comportamentos. Isso pode ser comprovado pela presença do comportamento EB nas respostas em que a rede estava muito instável, uma vez que esse comportamento não foi utilizado quando os erros eram baixos. Para efeito de validação, faz-se a Tabela 6.9 contendo a resposta visual aos testes realizados, os gráficos

com as velocidades e distâncias aos outros carros de todos os testes encontram-se no Apêndice D.

Tabela 6.9: Análise visual do comportamento do carro autônomo para os casos testados

Casos	*erro baixo*	*erro na localização*	*erro no Acompanhamento*	*erro em ambos*
CASO 1	não colidiu	colisão	colisão	colisão
CASO 2	não colidiu	colisão	não colidiu	colisão
CASO 3	não colidiu	não colidiu	não colidiu	não colidiu
CASO 4	não colidiu	não colidiu	não colidiu	não colidiu

Como os gráficos presentes no apêndice D apresentam uma dispersão grande devido à natureza dos testes, usar somente as informações do gráfico não são suficientes para definir se o veículo autônomo colidiu ou não. É importante frisar que, apesar do caso 4 não ter apresentado nenhuma colisão, o fato do veículo não ter reconhecido a área de risco de colisão põe em risco a sua própria segurança caso exista *gaps* mais curtos do que 4 e 5 para os carros A e B, respectivamente.

6.4 Considerações Finais

Esse capítulo se propôs a mostrar o comportamento de uma Rede Bayesiana aplicada ao domínio de carros autônomos. Vale ressaltar que os comportamentos simulados que o carro autônomo executou interferem no modo como a rede responde ao longo do tempo, uma vez que o domínio do problema está inserido na Robótica Móvel e a cada iteração simulada, o ambiente que o veículo observa sofre modificações devido ao seu próprio movimento. Tais acionamentos foram modelados para obter a análise das probabilidades da rede ao longo de uma trajetória e os mesmos não apresentam nenhuma robustez quanto a mudança do tipo do ambiente no mundo físico. Não era o foco dessa dissertação tornar esses acionamentos robustos ou implementar um planejador de trajetórias, o qual deixaria esses comportamentos executados pelo carro mais verossímeis.

Capítulo 7

Conclusões & Trabalhos Futuros

Essa dissertação se propôs a testar uma técnica de inteligência artificial chamada de *Redes Bayesianas* no processo de decisão de um veículo autônomo e verificar quão robusta é a resposta dessa arquitetura quando há erros nas classificações dos nós observadores.

Essa arquitetura usa uma abordagem probabilística para tratar as incertezas que o cenário de tráfego possui. Pode-se pensar na inferência probabilística como a necessidade de se conhecer a probabilidade conjunta de um número n de variáveis. Por si só, esse cálculo é complexo e inviável para n grande. Entretanto, a noção de causalidade entre as mesmas permite gerenciá-las de modo a reduzir a dimensionalidade dos termos a serem calculados.

Segundo a literatura, processos de decisões usando as Redes Bayesianas encontram-se em seu estado da arte, sendo estas desenvolvidas para resolver situações específicas. Para a situação aplicada a essa dissertação, as entradas da rede foram definidas como a saída de classificadores aplicados aos sensores coletados pelo carro autônomo. Dentre os seis classificadores citados, cinco deles fazem a asserção da situação ou contexto em que o veículo está inserido. Uma análise do funcionamento de cada classificador se fez necessário, uma vez que as classes e as tabelas de probabilidades condicionais precisavam ser definidas. A modelagem dos descritores citadas e propostas foram desenvolvidas com foco na entrada dos observadores propostos por essa dissertação.

Quanto ao único classificador referente a situação dinâmica, esse foi baseado nos conceitos de cinemática pontual e na hipótese do conhecimento do mapa em que o carro estará dirigindo. Ressalta-se que os classificadores citados não são ótimos tão pouco robustos, pois cabe a outras pessoas presentes no projeto SENA realizar tal função. Dado essa divisão de tarefas unido com

o carro em processo de automação, foram simuladas apenas as saídas dos classificadores, o que possibilitou um controle maior da interferência dos ruídos nos testes realizados.

Este último parâmetro é um fator decisivo para o tipo de tabela de probabilidades condicionais que será usado na rede bayesiana, inclusive o tipo de filtro que poderá ser utilizado. Viu-se que baixas taxas de acerto nos classificadores (devido à efeitos externos não modelados ou previstos) reduzem a crença do comportamento dominante no seu nó de saída. Devido a propriedade da probabilidade que a soma de todas as partições deve somar 1, um nível menor na crença dominante significa um nível maior de crença nos comportamentos competidores e isso concede a rede uma sensibilidade alta a ruídos, o que gera oscilações nas respostas se for considerada a classe com maior probabilidade a dominante. As crenças mais baixas afetam também a velocidade de resposta da rede visto que o passo de aumento das probabilidades é menor.

Conhecer o domínio de atuação e quão bem o classificador reagirá nele ajuda no desenvolvimento dos observadores propostos, uma vez que, em ambientes cujas classificações são fáceis e as respostas chegam a níveis tão altos quanto 100%, observadores com níveis maiores de probabilidade nas classes corretas são desejosos. Entretanto, existem situações nas quais os classificadores não conseguem discernir a resposta e, desse modo, geram baixas taxas de acerto, se aproximando de classificações aleatórias (50%). Para esse caso, a modelagem dos observadores orienta a escolha do classificador cuja CPT terá o maior nível de probabilidade, sendo observadores com dimensões (número de classes) menores do que o estado observado melhor classificados com baixa confiabilidade. Isso devido o fato de ter pelo menos mais de um estado sendo observado pela mesma classe. Porém, se o observador for de maior dimensão do que o estado observado, ele é melhor classificado como de alta confiabilidade, pois um estado pode ser observado por mais de uma classe.

Observou-se também que os erros na localização do veículo autônomo e dos outros objetos no cenário afetam diretamente o comportamento da rede, pois esses interferem no classificador da situação dinâmica, que é responsável em dizer se o ambiente está seguro ou não. Dentre os erros testados, o da localização do ego-veículo é o que mais afeta o processo de decisão sendo esse um parâmetro a ser otimizado.

No âmbito de otimizações, fica como trabalhos futuros, o desenvolvimento de algoritmos e classificadores robustos o suficiente para tratar os estados investigados, tornando a entrada da rede menos ruidosa e desse modo, aumentando sua eficácia. Também devem ser implementados os comportamentos que o veículo deve executar de forma mais robusta, usando, por exemplo, o

algoritmo de *Velocity Obstacle* e o controle ativo de cruzeiro (ACC). Quanto à Rede Bayesiana em si, a maior parte das CPTs foram confeccionadas manualmente e com isso, podem existir casos em que a rede pode não se portar bem. Nessa situação, pode-se usar ferramentas de aprendizado de máquinas (*Machine Learning*) para crias as CPTs e, com isso, otimizar os parâmetros da rede em questão. Nesse ponto, usar as informações oriundas de um simulador pode não ser suficientes e com isso, os dados precisam ser coletados via a plataforma.

Entretanto, para os testes com a plataforma, a mesma precisa contar com todos os algoritmos acima citados. Além disso, a mesma precisa conter a arquitetura de software capaz de tratar todo o fluxo de informações que o domínio de carros autônomos exige. Por fim, o *hardware* utilizado deve ter um desempenho otimizado, pois os testes feitos no simulador foram mais lentos do que eles podem ser, dado as características observadas. Com o tempo de simulação em 10 ms, a rede foi capaz de mudar suas probabilidades a cada amostragem, entretanto a mesma funciona por volta de 70 ms em tempo real, diminuindo drasticamente o número de amostragens e tornando a arquitetura menos eficiente para tratar os ruídos. A otimização do hardware e a implementação do *software* voltada para o *hardware* pode reduzir drasticamente os cálculos realizados.

Referências Bibliográficas

ACKERMAN, E. Google's Autonomous Car Takes To The Streets (2010). Disponível em: <http://spectrum.ieee.org/automaton/robotics/artificial-intelligence/googles-autonomous-car-takes-to-the-streets>. Acesso em: 30 jan 2012.

ALVES, D. R. Um grito pela vida no trânsito e transporte. (2011). Disponível em: <http://www.transitobrasil.org/artigos/doutrina/um-grito-pela-vida-no-transito-e-transporte>. Acesso em: 27 jan. 2012.

ANFAVEA. Anuário da indústria automobilística Brasileira. Technical report, Associação Nacional dos Fabricantes Automotores (2011).

ARAÚJO, R. L. C.; LACERDA, V. D. M.; HERNANDES, A. C.; MENDONÇA, A. S. B.; BECKER, M. (2011). Classificação de Pedestres Usando Câmera e Sensor Lidar. In: *SBAI - Simpósio Brasileiro de Automação Inteligente*. 2011.

AUTONOMOSLABS. Pick me up! (2010). Disponível em: <http://autonomos.inf.fu-berlin.de/technology/made-germany/autonomous-taxi>. Acesso em: 08 fev. 12.

BAKER, C.; DOLAN, J. (2009). Street Smarts for Boss. *Robotics and Automation Magazine*.

BECKER, J. C.; SIMON, A. (2000). Sensor and Navigation Data Fusion for an Autonomous Vehicle. In: *Proceedings of the IEEE Intelligent Vehicles Symposium*. 2000.

BECKER, M.; HALL, R.; KOLSKI, S.; MAEK, K.; SIEGWART, R.; JENSEN, B. A. (2009). 2D laser-based probabilistic motion tracking in urban-like environments. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, v.31p.83 – 96, 06.

BERTOZZI, M.; BROGGI, A.; CARDARELLI, E.; FEDRIGA, R. I.; MAZZEI, L.; PORTA, P. P. (2011). VIAC Expedition Toward Autonomous Mobility. *Robotics and Automation Magazine*.

BUSCHKA, P.; SAFFIOTTI, A. (2004). Some Notes on the Use of Hybrid Maps. In: *Proceedings of the 8th International Conference on Intelligent Autonomous Systems*. 2004.

CHRISTENSEN, H. I.; HAGER, G. D. Sensing and Estimation. In: SICILIANO, B., KHATIB, O. (Ed.). **Springer Handbook of Robotics**. Springer, 2008. cap. 4, p. 87-107.

CONTRAN. CONSELHO NACIONAL DE TRÂNSITO. **Sinalização Vertical de Regulamentação**. Brasília, DF, 2007.

COOPER, P. J.; ZHENG, Y. (2002). Turning gap acceptance decision-making: the impact of driver distraction. *Journal of Safety Research*.

CREA-BA. CONSELHO REGIONAL DE ENGENHARIA E ARQUITETURA - BAHIA. **Guia Prático para a Construção de Calçadas**. Salvador, BA, 2009.

DARWICHE, A. (2009). *Modeling and Reasoning with Bayesian Networks*. Cambridge University Press.

LIMA, D. A. D. (2010). Navegação Segura de um carro autônomo utilizando campos vetoriais e o método da janela dinâmica. Dissertação (Mestrado), Universidade Federal de Minas Gerais.

ANDRADE, K. D. O. (2011). Sistema Neural Reativo para o Estacionamento Paralelo com uma Única manobra em Veículos de Passeio. Dissertação (Mestrado), Escola de Engenharia de São Carlos da Universidade de São Paulo.

DENATRAN. Frota de Veículos (2011). Disponível em: <www.denatran.gov.br/frota.htm>. Acesso em: 28 jan. 2012.

DIETSCH, J. (2010). 2010: When Mobile Robots Reached the Tipping Point. *Robotics and Automation Magazine*, v.17, n.4, , Dezembro.

DUDA, R. O.; HART, P. E.; STORK, D. G. (2001). *Pattern Classification*. Willey Interscience.

DUDEK, G.; JENKIN, M. Inertial Sensors, GPS, and Odometry. In: SICILIANO, B., KHATIB, O. (Ed.). **Springer Handbook of Robotics**. Springer, 2008. cap. 20, p. 477-490.

DURRANT-WHYTE, H.; HENDERSON, T. C. Multisensor Data Fusion. In: SICILIANO, B., KHATIB, O. (Ed.). **Springer Handbook of Robotics**. Springer, 2008. cap. 25, p. 585-610.

FIAT. FIAT AUTOMÓVEIS S.A. **Guia de Uso e Manutenção Fiat Stilo**. Betim, MG, 2005.

FORD. Ford Lane Keeping System Helps Fusion Drivers Stay Alert and Between the Lines (2011). Disponivel em: <http://media.ford.com/article_display.cfm?article_id=35776>. Acesso em: 28 jan 2011.

GINDELE, T.; BRECHTEL, S.; DILLMANN, R. (2010). A Probabilistic Model for Estimating Driver Behaviors and Vehicle Trajectories in Traffic Environments. In: *13th International IEEE Annual Conference on Intelligent Transportation Systems*. 2010.

GONZALEZ, R. C.; WOODS, R. E.; EDDINS, S. L. (2003). *Digital Image Processing Using MATLAB*. Prentice-Hall, Inc.

GUIZZO, E. French Self-Driving Car Takes to the Road (2012). Disponível em: <http://spectrum.ieee.org/automaton/robotics/industrial-robots/french-self-driving-car-takes-to-the-road>. Acesso em: 30 jan. 2012.

IDI. IDI Innovative Decisions, Inc. (2012). Disponível em: <www.innovativedecisions.com>. Acesso em: 14 jan. 2012.

IET. IET Information Extraction & Transport (2012). Disponível em: <www.iet.webfactional.com>. Acesso em: 14 jan. 2012.

IFR. Executive Summary of World Robotics 2011 Industrial and Service Robots (2011). International Federation of Robotics Statistical Department. Disponível em: <www.worldrobotics.org/uploads/media/2011_Executive_Summary.pdf>. Acesso em: 23 jan. 2012.

KASTNER, R.; MICHALKE, T.; ADAMY, J.; FRITSCH, J.; GOERICK, C. (2011). Task-Based Environment Interpretation and System Architecture for Next Generation ADAS. *IEEE Intelligent Transportation Systems Magazine*.

KOGGE, P. (2011). The tops in flops. *Spectrum, IEEE*, v.48, n.2, p.48–54, fevereiro.

KOWALENKO, K. (2010). Keeping Cars from Crashing. *The Institute, IEEE*, v.34, n.3, p.5.

KUMAR, V. (2010). 50 Years of Robotics. *Robotics and Automation Magazine*, v.17, n.3, , Setembro.

KURDZIEL, M. S. (2008). A monocular Color Vision System for Road Intersection Detection. Dissertação (Mestrado), Rochester Institute of Technology.

LABERGE, J. C.; CREASER, J. I.; RAKAUSKAS, M. E.; WARD, N. J. (2006). Design of an intersection decision support (IDS) interface to reduce crashes at rural stop-controlled intersections. *Transportation Research Part C*.

LAMON, P.; TRIEBEL, S. K. R.; SIEGWART, R.; BURGARD, W. The SmartTer for ELROB 2006 - a Vehicle for Autonomous Navigation and Mapping in Outdoor Environments. Technical report, EPFL - École Polytechnique Férérale de Lausanne (2006).

LAUGIER, C.; PAROMTCHICK, I. E.; PERROLLAZ, M.; YONG, M.; YODER, J.-D.; TAY, C.; MEKHNACHA, K.; NèGRE, A. (2011). Probabilistic Analysis of Dynamic Scenes and Collision Risk Assessment to Improve Driving Safety. *IEEE Intelligent Transportation Systems Magazine*.

LEFÈVRE, S.; LAUGIER, C.; IBAÑEZ-GUZMÀN, J.; BESSIÈRE, P. Modelling Dynamic Scenes at Unsignilised Road Intersections. Technical report, INRIA - Institut National de Recherche en Informatique et en Automatique (2011).

LRM. CARINA - Carro Robótico Inteligente para Navegação Autônoma (2011). Disponível em: <http://www.lrm.icmc.usp.br/carina/>. Acesso em: 30 jan. 2012.

MONTEMERLO, M.; BECKER, J.; BHAT, S.; DAHLKAMP, H.; DOLGOV, D.; ETTINGER, S.; HAEHNEL, D.; HILDEN, T.; HOFFMANN, G.; HUHNKE, B.; JOHNSTON, D.; KLUMPP, S.; LANGER, D.; LEVANDOWSKI, A.; LEVINSON, J.; MARCIL, J.; ORENSTEIN, D.; PAEFGEN, J.; PENNY, I.; PETROVSKAYA, A.; PFLUEGER, M.; STANEK, G.; STAVENS, D.; VOGT, A.; THRUN, S. (2008). Junior: The Stanford entry in the Urban Challenge. *Journal of Field Robotics*.

NORSYS. Norsys Software Corporation (2012). Disponível em: <www.norsys.com>. Acesso em: 14 jun. 2012.

OMS. Global Status Report on Road Safety: Time for Action. Technical report, Organização Mundial de Saúde (2009).

ONUBR. Década de ação pelo trânsito seguro 2011-2020 é lançada oficialmente hoje (11) em todo mundo (2011). Disponível em: <www.onu.org.br/decada-de-acao-pelo-transito-seguro-2011-2020-e-lancada-oficialmente-hoje-11-em-todo-o-mundo/>. Acesso em: 27 jan. 2012.

OXFORD. Robot car to cut jams & prangs (2011). Disponível em: <http://www.ox.ac.uk/media/news_stories/2011/111010.html>. Acesso em: 31 jan. 2012.

POLLATSCHECK, M. A.; POLUS, A.; LIVNEH, M. (2002). A decision model for gap acceptance and capacity at intersections. *Transportation Research Part B.*

REUSCHENBACH, A.; WANG, M.; GANJINEH, T.; GOHRING, D. (2011). iDriver - Human Machine Interface for Autonomous Car. In: *2011 Eighth International Conference on Information Technology: New Generations.* 2011.

REZENDE, S. O. (2003). *Sistemas inteligentes: fundamentos e aplicações.* Manole Ltda.

RODAS, Q. FIAT STILO 1.8 8V X PEUGEOT 307 1.6 16V PRESENCE PACK (2006). Disponível em: <http://quatrorodas.abril.com.br/carros/comparativos/conteudo_144105.shtml>. Acesso em: 4 jul. 2012.

RUSSEL, S.; NORVIG, P. (2010). ***Artificial Intelligence**. A modern Approach.* Prentice Hall.

SANTOS, F. B. N. (2007). Determinação em tempo real da posição e atitude de um veículo móvel aéreo com múltiplos receptores GPS de baixo custo. Dissertação (Mestrado), Universidade Técnica de Lisboa - Instituto superior Técnico.

SATO, T.; AKAMATSU, M. (2009). Analysis of drivers' preparatory behaviour before turning at intersections. *IET Intelligent Transport Systems.*

SCHUBERT, R.; WANIELIK, G. (2011). A Unified Bayesian Approach for Object and Situation Assessment. *IEEE Intelligetn Transportation Systems Magazine.*

SENA. CePOF - SENA Project (INOF) (2012). Disponível em: <http://cepof.ifsc.usp.br/int.php?mid=35>. Acesso em: 31 jan. 2012.

SIEGWART, R.; NOURBAKHSH, I. R.; SCARAMUZZA, D. (2011). *Introduction to Autonomous Mobile Robots.* The MIT Press.

STEVENSON, R. (2011). A Driver's Sixth Sense. *Spectrum, IEEE*, v.48, n.10, p.50–55.

THRUN, S.; MONTEMERLO, M.; DAHLKAMP, H.; STAVENS, D.; ARON, A.; DIEBEL, J.; FONG, P.; GALE, J.; HALPENNY, M.; HOFFMANN, G.; LAU, K.; OAKLEY, C.; PALATUCCI, M.; PRATT, V.; STANG, P.; STROHBAND, S.; DUPONT, C.; JENDROSSEK, L.-E.; KOELEN, C.; MARKEY, C.; RUMMEL, C.; VAN NIEKERK, J.; JENSEN, E.; ALESSANDRINI, P.; BRADSKI, G.; DAVIES, B.; ETTINGER, S.; KAEHLER, A.; NEFIAN, A.; MAHONEY, P. (2006). Stanley: The Robot that Won the DARPA Grand Challenge. *Journal of Field Robotics.*

TRW. Technology Information (2011). Disponível em: <www.trw.com/media_center/technology_information>. Acesso em: 28 jan . 2012.

WERLING, M.; GINDELE, T.; JAGSZENT, D.; GRÖLL, L. (2008). A robust Algorithm for Handling Moving Traffic in Urban Scenarios. In: *IEEE Intelligent Vehicles Symposium*. 2008.

Apêndice A

Mapa conceitual de Veículos inteligentes

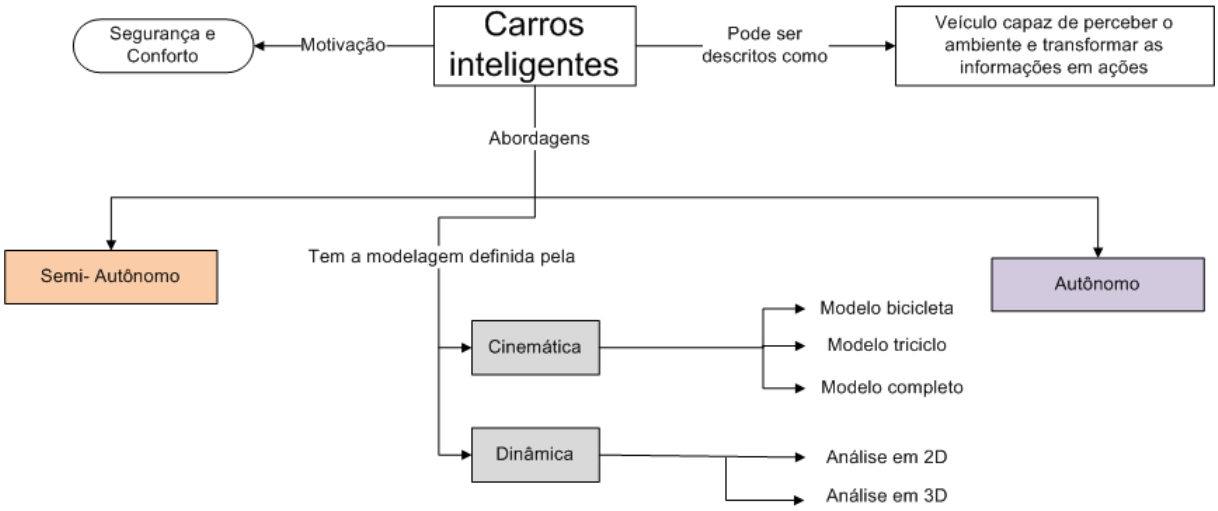

Figura A.1: Vista geral do problema

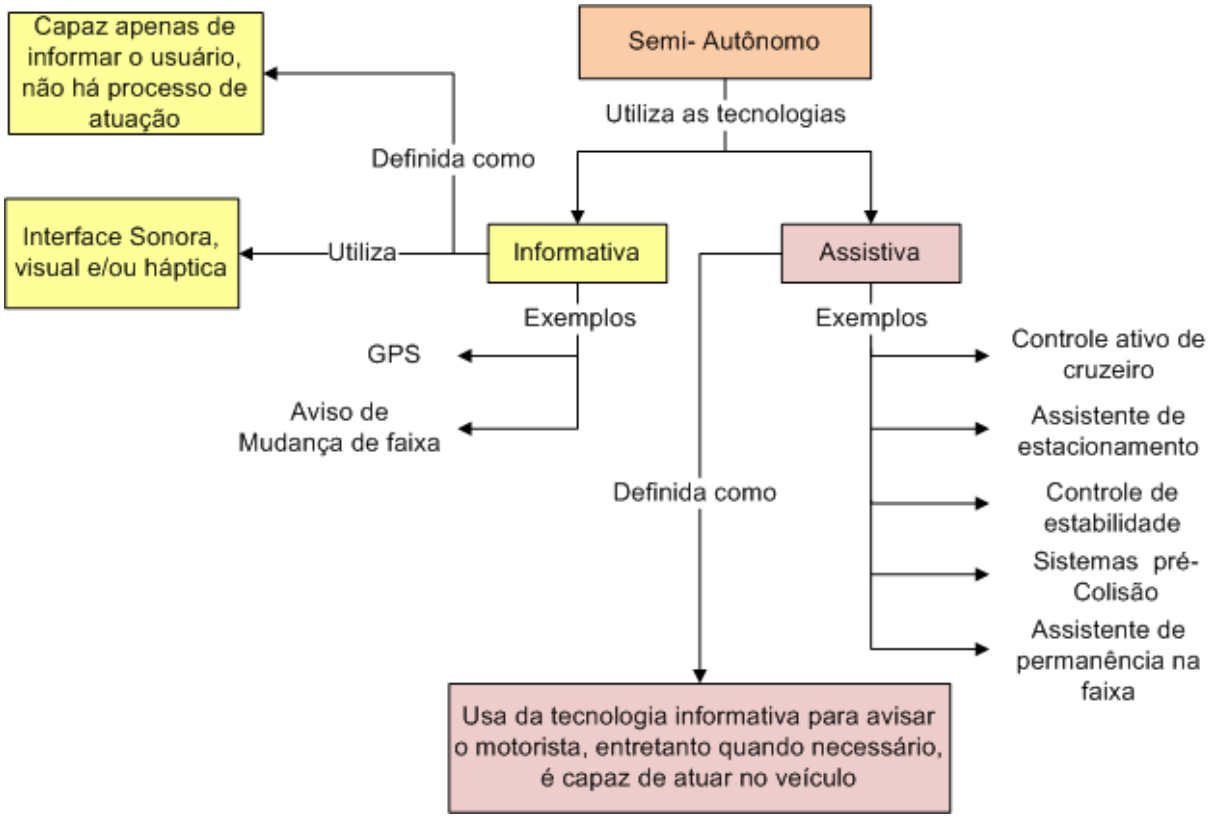

Figura A.2: Mapa para os carros com foco semi-autônomo

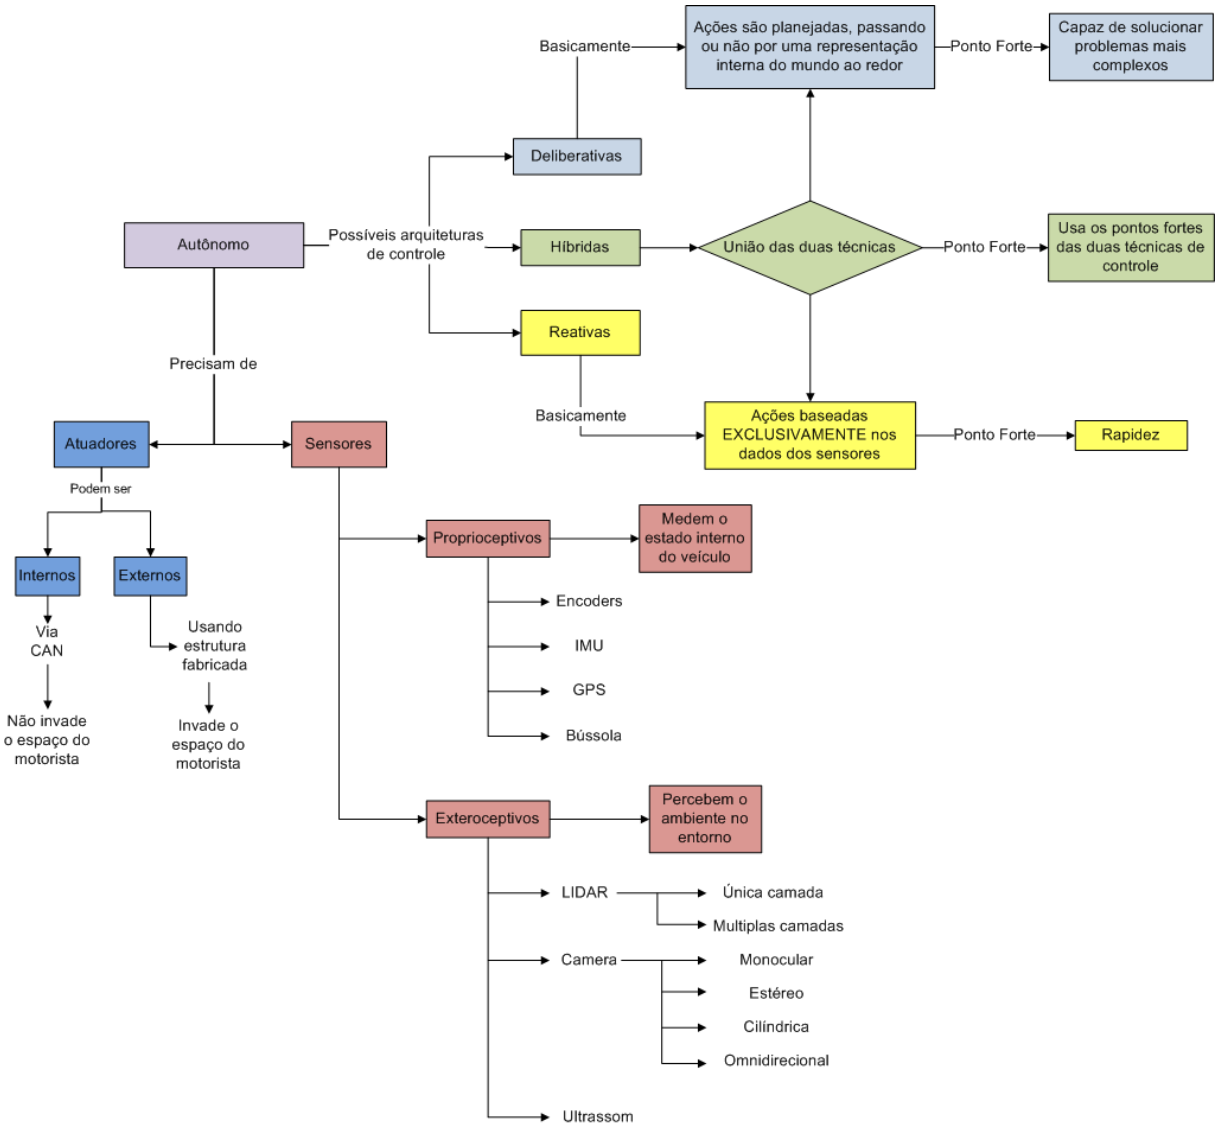

Figura A.3: Mapa para os carros com foco autônomo

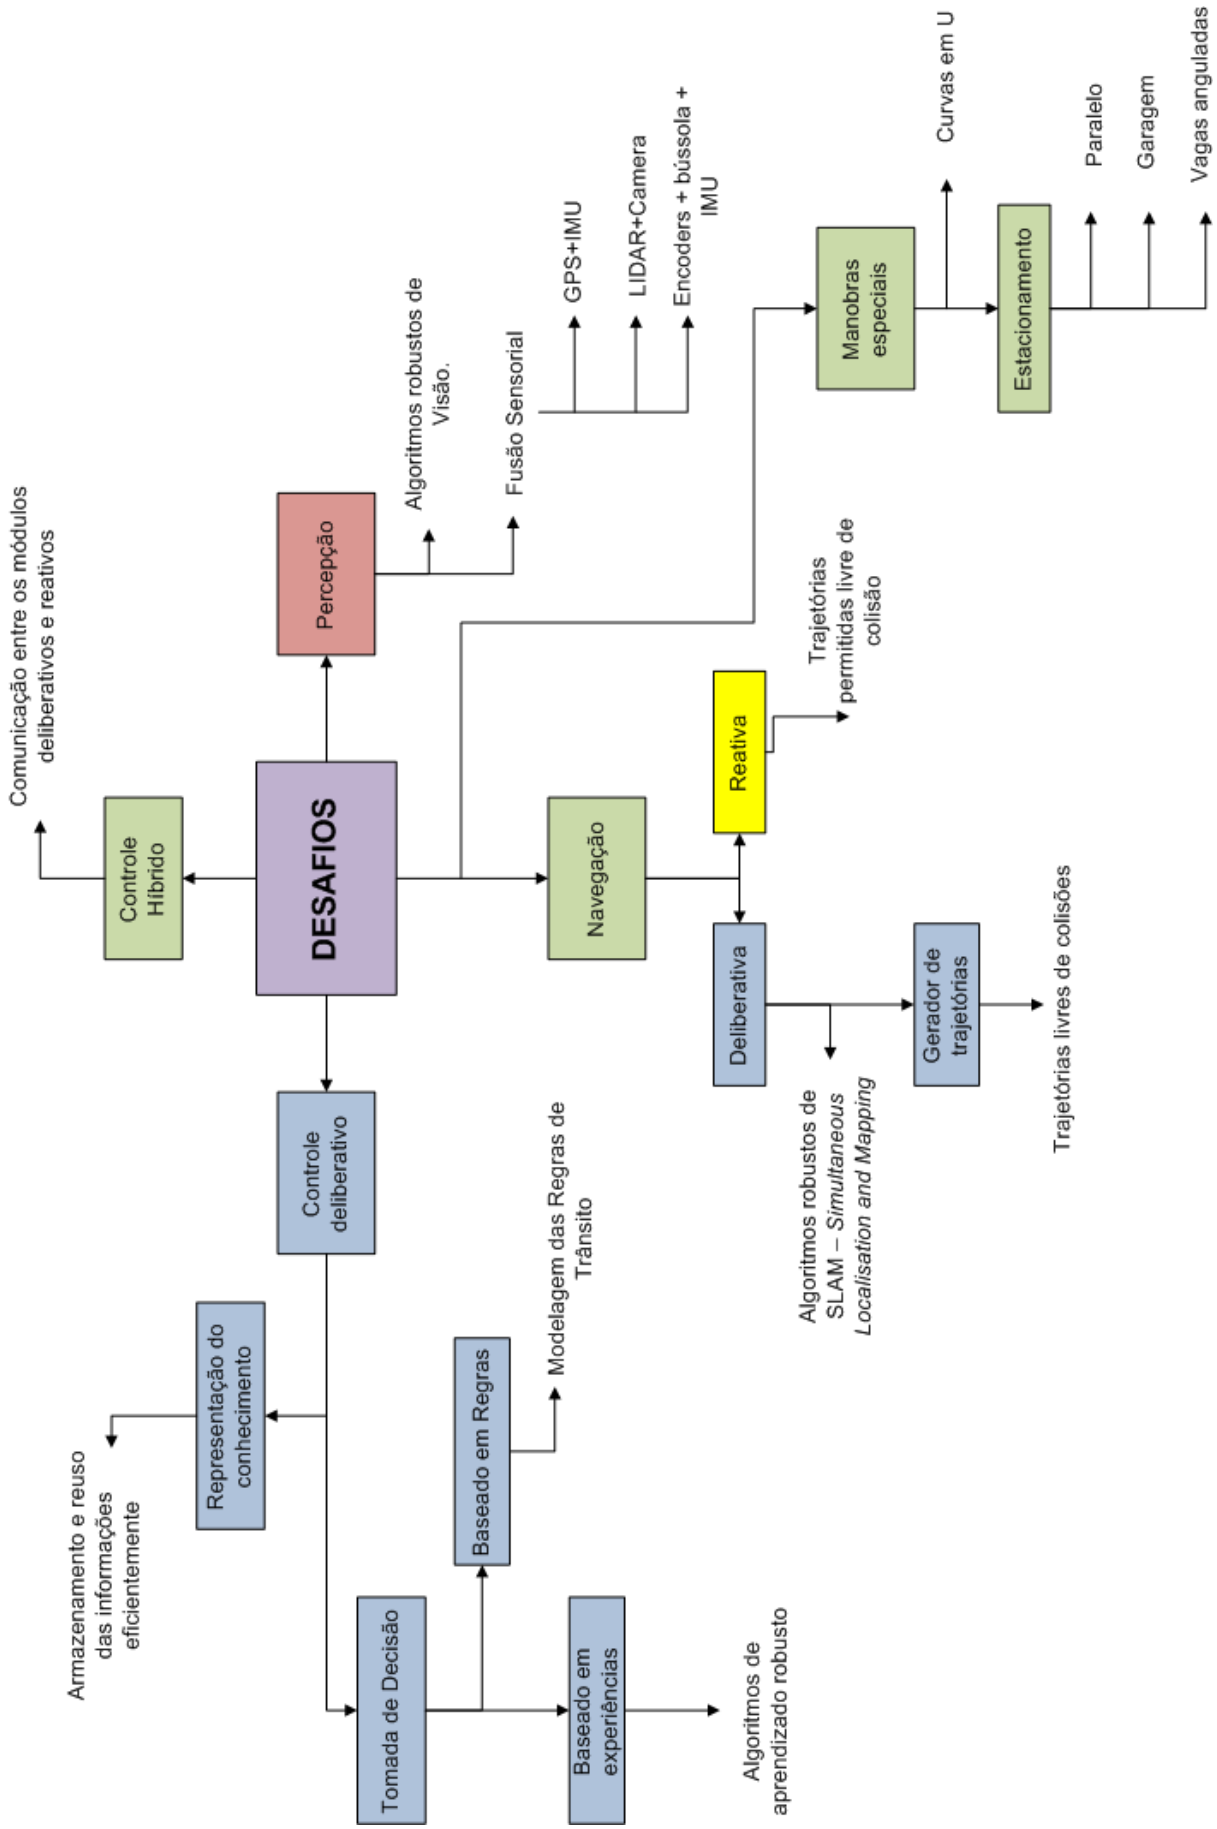

Figura A.4: Mapa dos desafios a serem cumpridos por veículos inteligentes

Apêndice B

Mapa do Campus 1 da USP São Carlos

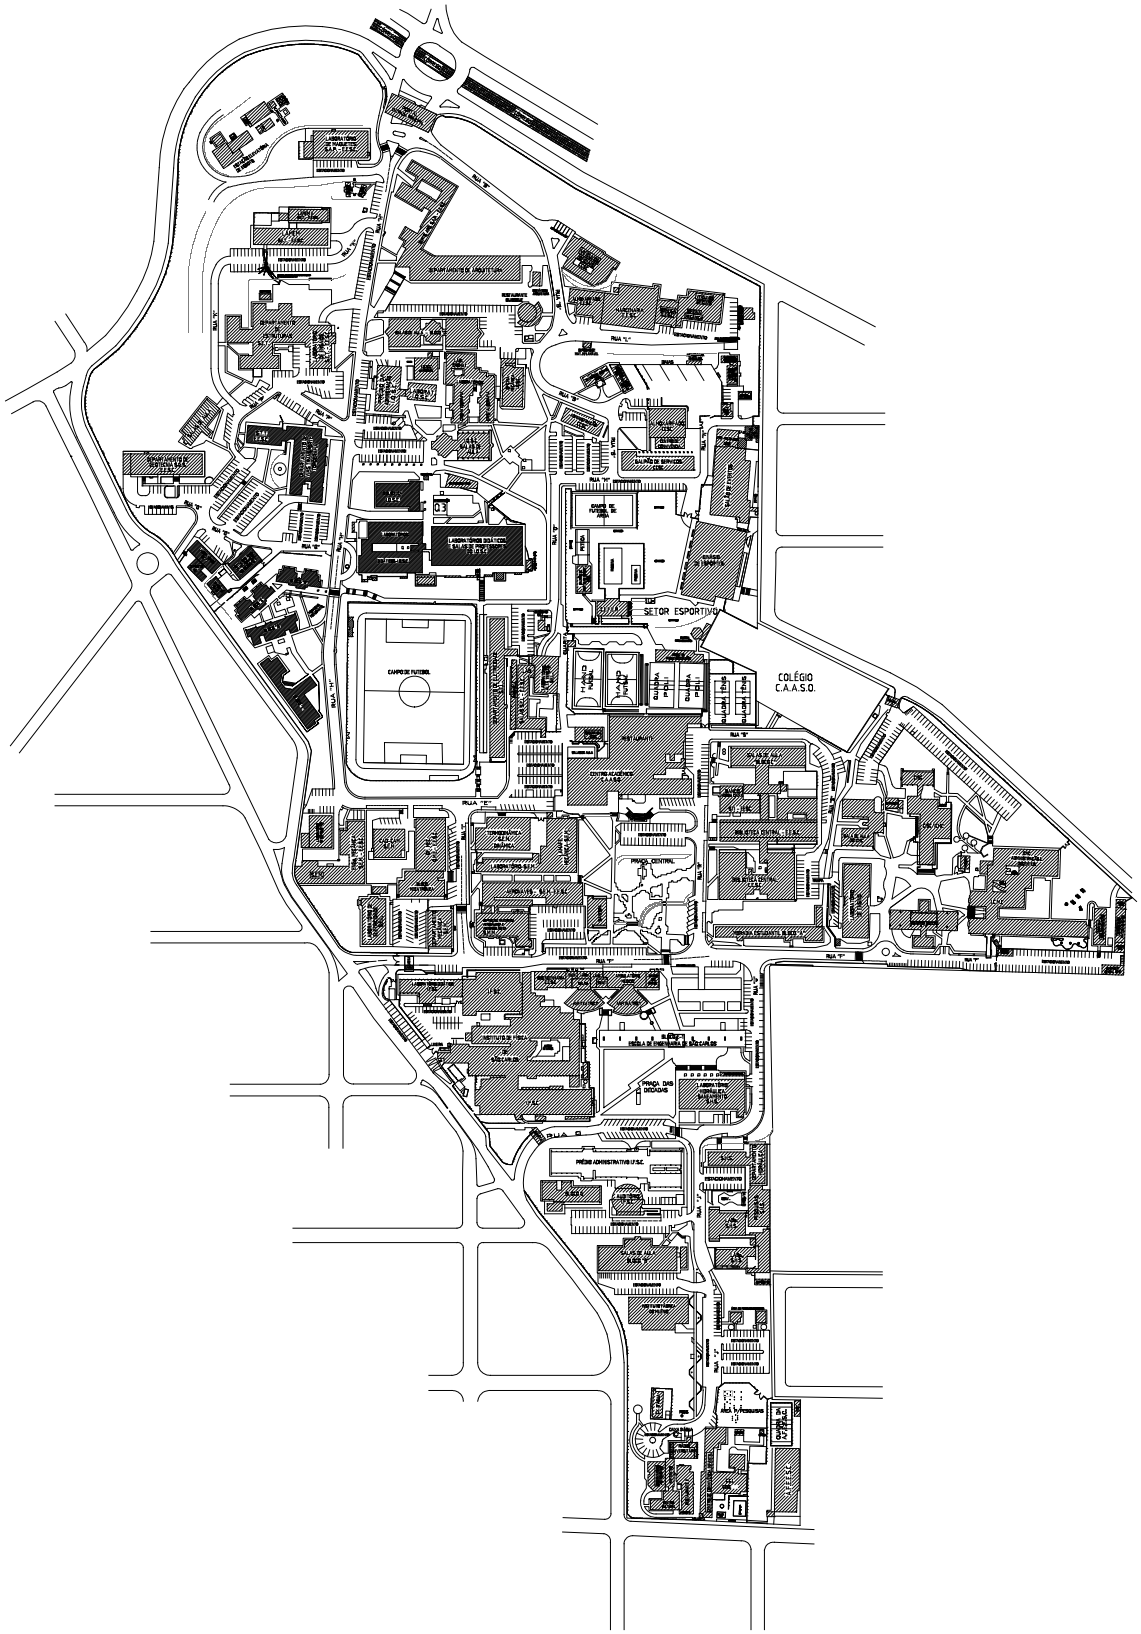

Figura B.1: Mapa Campus 1 da USP São Carlos

Apêndice C

CPT do Filtro de Segunda Ordem

Tabela C.1: CPT da variável B. Parte 1

Classes(t-2)	Classes(t-1)	Classes(t)	KG	DC	WT	AC	LT	RT	CL	EB
KG	KG	KG	93	1	1	1	1	1	1	1
		DC	70	24	1	1	1	1	1	1
		WT	93	1	1	1	1	1	1	1
		AC	93	1	1	1	1	1	1	1
		LT	70	1	1	1	24	1	1	1
		RT	70	1	1	1	1	24	1	1
		CL	80	1	1	1	1	1	14	1
		EB	80	1	1	1	1	1	1	14
	DC	KG	84	10	1	1	1	1	1	1
		DC	24	70	1	1	1	1	1	1
		WT	70	24	1	1	1	1	1	1
		AC	70	24	1	1	1	1	1	1
		LT	70	24	1	1	1	1	1	1
		RT	70	24	1	1	1	1	1	1
		CL	70	10	1	1	1	1	15	1
		EB	70	10	1	1	1	1	1	15
	WT	KG	93	1	1	1	1	1	1	1
		DC	84	10	1	1	1	1	1	1
		WT	90	4	1	1	1	1	1	1
		AC	90	4	1	1	1	1	1	1
		LT	80	5	1	1	10	1	1	1
		RT	80	5	1	1	1	10	1	1
		CL	84	1	1	1	1	1	10	1
		EB	84	1	1	1	1	1	1	10

Tabela C.2: CPT da variável B. Parte 2

Classes(t-2)	Classes(t-1)	Classes(t)	KG	DC	WT	AC	LT	RT	CL	EB
KG	AC	KG	93	1	1	1	1	1	1	1
		DC	84	10	1	1	1	1	1	1
		WT	90	4	1	1	1	1	1	1
		AC	90	4	1	1	1	1	1	1
		LT	80	5	1	1	10	1	1	1
		RT	80	5	1	1	1	10	1	1
		CL	84	1	1	1	1	1	10	1
		EB	84	1	1	1	1	1	1	10
	LT	KG	93	1	1	1	1	1	1	1
		DC	84	1	1	1	10	1	1	1
		WT	90	1	1	1	4	1	1	1
		AC	90	1	1	1	4	1	1	1
		LT	30	5	1	1	60	1	1	1
		RT	90	4	1	1	1	1	1	1
		CL	84	1	1	1	1	1	10	1
		EB	84	1	1	1	1	1	1	10
	RT	KG	93	1	1	1	1	1	1	1
		DC	84	10	1	1	1	1	1	1
		WT	90	4	1	1	1	1	1	1
		AC	90	4	1	1	1	1	1	1
		LT	90	4	1	1	1	1	1	1
		RT	30	5	1	1	1	60	1	1
		CL	84	1	1	1	1	1	10	1
		EB	84	1	1	1	1	1	1	10
	CL	KG	84	1	1	1	1	1	10	1
		DC	70	10	1	1	1	1	15	1
		WT	84	1	1	1	1	1	10	1
		AC	84	1	1	1	1	1	10	1
		LT	84	1	1	1	1	1	10	1
		RT	84	1	1	1	1	1	10	1
		CL	24	1	1	1	1	1	70	1
		EB	70	1	1	1	1	1	24	1
	EB	KG	84	1	1	1	1	1	1	10
		DC	70	10	1	1	1	1	1	15
		WT	84	1	1	1	1	1	1	10
		AC	84	1	1	1	1	1	1	10
		LT	84	1	1	1	1	1	1	10
		RT	84	1	1	1	1	1	1	10
		CL	70	1	1	1	1	1	1	24
		EB	24	1	1	1	1	1	1	70
DC	KG	KG	1	91	2	2	1	1	1	1
		DC	1	93	1	1	1	1	1	1
		WT	1	84	10	1	1	1	1	1
		AC	1	84	1	10	1	1	1	1
		LT	1	91	2	2	1	1	1	1
		RT	1	91	2	2	1	1	1	1
		CL	1	84	1	1	1	1	10	1
		EB	1	84	1	1	1	1	1	10

Tabela C.3: CPT da variável B. Parte 3

Classes(t-2)	Classes(t-1)	Classes(t)	KG	DC	WT	AC	LT	RT	CL	EB
DC	DC	KG	1	93	1	1	1	1	1	1
		DC	1	93	1	1	1	1	1	1
		WT	1	70	24	1	1	1	1	1
		AC	1	70	1	24	1	1	1	1
		LT	1	93	1	1	1	1	1	1
		RT	1	93	1	1	1	1	1	1
		CL	1	80	1	1	1	1	14	1
		EB	1	80	1	1	1	1	1	14
	WT	KG	1	70	24	1	1	1	1	1
		DC	1	84	10	1	1	1	1	1
		WT	1	24	70	1	1	1	1	1
		AC	1	25	35	35	1	1	1	1
		LT	1	84	10	1	1	1	1	1
		RT	1	84	10	1	1	1	1	1
		CL	1	70	10	1	1	1	15	1
		EB	1	70	10	1	1	1	1	15
	AC	KG	1	70	1	24	1	1	1	1
		DC	1	93	1	1	1	1	1	1
		WT	1	25	35	35	1	1	1	1
		AC	1	24	1	70	1	1	1	1
		LT	1	70	1	24	1	1	1	1
		RT	1	70	1	24	1	1	1	1
		CL	1	70	1	10	1	1	15	1
		EB	1	70	1	10	1	1	1	15
	LT	KG	1	91	2	2	1	1	1	1
		DC	1	93	1	1	1	1	1	1
		WT	1	84	10	1	1	1	1	1
		AC	1	84	1	10	1	1	1	1
		LT	1	91	2	2	1	1	1	1
		RT	1	91	2	2	1	1	1	1
		CL	1	84	1	1	1	1	10	1
		EB	1	84	1	1	1	1	1	10
	RT	KG	1	91	2	2	1	1	1	1
		DC	1	93	1	1	1	1	1	1
		WT	1	84	10	1	1	1	1	1
		AC	1	84	1	10	1	1	1	1
		LT	1	91	2	2	1	1	1	1
		RT	1	91	2	2	1	1	1	1
		CL	1	84	1	1	1	1	10	1
		EB	1	84	1	1	1	1	1	10
	CL	KG	1	84	1	1	1	1	10	1
		DC	1	84	1	1	1	1	10	1
		WT	1	70	10	1	1	1	15	1
		AC	1	70	1	10	1	1	15	1
		LT	1	84	1	1	1	1	10	1
		RT	1	84	1	1	1	1	10	1
		CL	1	24	1	1	1	1	70	1
		EB	1	70	1	1	1	1	24	1

Tabela C.4: CPT da variável B. Parte 4

Classes(t-2)	Classes(t-1)	Classes(t)	KG	DC	WT	AC	LT	RT	CL	EB
DC	EB	KG	1	84	1	1	1	1	1	10
		DC	1	84	1	1	1	1	1	10
		WT	1	70	10	1	1	1	1	15
		AC	1	70	1	10	1	1	1	15
		LT	1	84	1	1	1	1	1	10
		RT	1	84	1	1	1	1	1	10
		CL	1	70	1	1	1	1	1	24
		EB	1	24	1	1	1	1	1	70
WT	KG	KG	1	1	90	4	1	1	1	1
		DC	1	1	90	4	1	1	1	1
		WT	1	1	93	1	1	1	1	1
		AC	1	1	84	10	1	1	1	1
		LT	1	1	90	4	1	1	1	1
		RT	1	1	90	4	1	1	1	1
		CL	1	1	90	4	1	1	1	1
		EB	1	1	90	4	1	1	1	1
	DC	KG	1	1	90	4	1	1	1	1
		DC	1	1	90	4	1	1	1	1
		WT	1	1	93	2	1	1	1	1
		AC	1	1	84	10	1	1	1	1
		LT	1	1	90	4	1	1	1	1
		RT	1	1	90	4	1	1	1	1
		CL	1	1	90	4	1	1	1	1
		EB	1	1	90	4	1	1	1	1
	WT	KG	1	1	93	1	1	1	1	1
		DC	1	1	93	1	1	1	1	1
		WT	1	1	93	1	1	1	1	1
		AC	1	1	70	24	1	1	1	1
		LT	1	1	93	1	1	1	1	1
		RT	1	1	93	1	1	1	1	1
		CL	1	1	93	1	1	1	1	1
		EB	1	1	93	1	1	1	1	1
	AC	KG	1	1	70	24	1	1	1	1
		DC	1	1	70	24	1	1	1	1
		WT	1	1	84	10	1	1	1	1
		AC	1	1	24	70	1	1	1	1
		LT	1	1	70	24	1	1	1	1
		RT	1	1	70	24	1	1	1	1
		CL	1	1	70	24	1	1	1	1
		EB	1	1	70	24	1	1	1	1
	LT	KG	1	1	90	4	1	1	1	1
		DC	1	1	90	4	1	1	1	1
		WT	1	1	93	1	1	1	1	1
		AC	1	1	84	10	1	1	1	1
		LT	1	1	90	4	1	1	1	1
		RT	1	1	90	4	1	1	1	1
		CL	1	1	90	4	1	1	1	1
		EB	1	1	90	4	1	1	1	1

Tabela C.5: CPT da variável B. Parte 5

Classes(t-2)	Classes(t-1)	Classes(t)	KG	DC	WT	AC	LT	RT	CL	EB
WT	RT	KG	1	1	90	4	1	1	1	1
		DC	1	1	90	4	1	1	1	1
		WT	1	1	93	1	1	1	1	1
		AC	1	1	84	10	1	1	1	1
		LT	1	1	90	4	1	1	1	1
		RT	1	1	90	4	1	1	1	1
		CL	1	1	90	4	1	1	1	1
		EB	1	1	90	4	1	1	1	1
	CL	KG	1	1	90	4	1	1	1	1
		DC	1	1	90	4	1	1	1	1
		WT	1	1	93	1	1	1	1	1
		AC	1	1	84	10	1	1	1	1
		LT	1	1	90	4	1	1	1	1
		RT	1	1	90	4	1	1	1	1
		CL	1	1	90	4	1	1	1	1
		EB	1	1	90	4	1	1	1	1
	EB	KG	1	1	90	4	1	1	1	1
		DC	1	1	90	4	1	1	1	1
		WT	1	1	93	1	1	1	1	1
		AC	1	1	84	10	1	1	1	1
		LT	1	1	90	4	1	1	1	1
		RT	1	1	90	4	1	1	1	1
		CL	1	1	90	4	1	1	1	1
		EB	1	1	90	4	1	1	1	1
AC	KG	KG	1	1	1	91	2	2	1	1
		DC	1	1	1	91	2	2	1	1
		WT	1	1	1	91	2	2	1	1
		AC	1	1	1	93	1	1	1	1
		LT	1	1	1	84	10	1	1	1
		RT	1	1	1	84	1	10	1	1
		CL	1	1	1	91	2	2	1	1
		EB	1	1	1	84	1	1	1	10
	DC	KG	1	1	1	91	2	2	1	1
		DC	1	1	1	91	2	2	1	1
		WT	1	1	1	91	2	2	1	1
		AC	1	1	1	93	1	1	1	1
		LT	1	1	1	84	10	1	1	1
		RT	1	1	1	84	1	10	1	1
		CL	1	1	1	91	2	2	1	1
		EB	1	1	1	84	1	1	1	10
	WT	KG	1	1	1	91	2	2	1	1
		DC	1	1	1	91	2	2	1	1
		WT	1	1	1	91	2	2	1	1
		AC	1	1	1	93	1	1	1	1
		LT	1	1	1	84	10	1	1	1
		RT	1	1	1	84	1	10	1	1
		CL	1	1	1	91	2	2	1	1
		EB	1	1	1	84	1	1	1	10

Tabela C.6: CPT da variável B. Parte 6

Classes(t-2)	Classes(t-1)	Classes(t)	KG	DC	WT	AC	LT	RT	CL	EB
AC	AC	KG	1	1	1	93	1	1	1	1
		DC	1	1	1	93	1	1	1	1
		WT	1	1	1	93	1	1	1	1
		AC	1	1	1	93	1	1	1	1
		LT	1	1	1	70	24	1	1	1
		RT	1	1	1	70	1	24	1	1
		CL	1	1	1	93	1	1	1	1
		EB	1	1	1	80	1	1	1	14
	LT	KG	1	1	1	70	24	1	1	1
		DC	1	1	1	70	24	1	1	1
		WT	1	1	1	70	24	1	1	1
		AC	1	1	1	84	10	1	1	1
		LT	1	1	1	24	70	1	1	1
		RT	1	1	1	25	35	35	1	1
		CL	1	1	1	70	24	24	1	1
		EB	1	1	1	80	1	1	1	14
	RT	KG	1	1	1	70	1	24	1	1
		DC	1	1	1	70	1	24	1	1
		WT	1	1	1	70	1	24	1	1
		AC	1	1	1	84	1	10	1	1
		LT	1	1	1	25	35	35	1	1
		RT	1	1	1	24	1	70	1	1
		CL	1	1	1	70	1	24	1	1
		EB	1	1	1	80	1	1	1	14
	CL	KG	1	1	1	91	2	2	1	1
		DC	1	1	1	91	2	2	1	1
		WT	1	1	1	91	2	2	1	1
		AC	1	1	1	93	1	1	1	1
		LT	1	1	1	84	10	1	1	1
		RT	1	1	1	84	1	10	1	1
		CL	1	1	1	91	2	2	1	1
		EB	1	1	1	84	1	1	1	10
	EB	KG	1	1	1	84	1	1	1	10
		DC	1	1	1	84	1	1	1	10
		WT	1	1	1	84	1	1	1	10
		AC	1	1	1	84	1	1	1	10
		LT	1	1	1	70	10	1	1	15
		RT	1	1	1	70	1	10	1	15
		CL	1	1	1	84	1	1	1	10
		EB	1	1	1	24	1	1	1	70
LT	KG	KG	70	1	1	1	24	1	1	1
		DC	24	1	1	1	70	1	1	1
		WT	24	1	1	1	70	1	1	1
		AC	24	1	1	1	70	1	1	1
		LT	10	1	1	1	84	1	1	1
		RT	24	1	1	1	70	1	1	1
		CL	24	1	1	1	70	1	1	1
		EB	10	1	1	1	70	1	1	15

Tabela C.7: CPT da variável B. Parte 7

Classes(t-2)	Classes(t-1)	Classes(t)	KG	DC	WT	AC	LT	RT	CL	EB
LT	DC	KG	10	1	1	1	84	1	1	1
		DC	4	1	1	1	90	1	1	1
		WT	4	1	1	1	90	1	1	1
		AC	4	1	1	1	90	1	1	1
		LT	1	1	1	1	93	1	1	1
		RT	4	1	1	1	90	1	1	1
		CL	4	1	1	1	90	1	1	1
		EB	1	1	1	1	84	1	1	10
	WT	KG	10	1	1	1	84	1	1	1
		DC	4	1	1	1	90	1	1	1
		WT	4	1	1	1	90	1	1	1
		AC	4	1	1	1	90	1	1	1
		LT	1	1	1	1	93	1	1	1
		RT	4	1	1	1	90	1	1	1
		CL	4	1	1	1	90	1	1	1
		EB	1	1	1	1	84	1	1	10
	AC	KG	10	1	1	1	84	1	1	1
		DC	4	1	1	1	90	1	1	1
		WT	4	1	1	1	90	1	1	1
		AC	4	1	1	1	90	1	1	1
		LT	1	1	1	1	93	1	1	1
		RT	4	1	1	1	90	1	1	1
		CL	4	1	1	1	90	1	1	1
		EB	1	1	1	1	84	1	1	10
	LT	KG	24	1	1	1	70	1	1	1
		DC	1	1	1	1	93	1	1	1
		WT	1	1	1	1	93	1	1	1
		AC	1	1	1	1	93	1	1	1
		LT	1	1	1	1	93	1	1	1
		RT	1	1	1	1	93	1	1	1
		CL	1	1	1	1	93	1	1	1
		EB	1	1	1	1	80	1	1	14
	RT	KG	10	1	1	1	84	1	1	1
		DC	4	1	1	1	90	1	1	1
		WT	4	1	1	1	90	1	1	1
		AC	4	1	1	1	90	1	1	1
		LT	1	1	1	1	93	1	1	1
		RT	4	1	1	1	90	1	1	1
		CL	4	1	1	1	90	1	1	1
		EB	1	1	1	1	84	1	1	10
	CL	KG	10	1	1	1	84	1	1	1
		DC	4	1	1	1	90	1	1	1
		WT	4	1	1	1	90	1	1	1
		AC	4	1	1	1	90	1	1	1
		LT	1	1	1	1	93	1	1	1
		RT	4	1	1	1	90	1	1	1
		CL	4	1	1	1	90	1	1	1
		EB	1	1	1	1	84	1	1	10

Tabela C.8: CPT da variável B. Parte 8

Classes(t-2)	Classes(t-1)	Classes(t)	KG	DC	WT	AC	LT	RT	CL	EB
LT	EB	KG	10	1	1	1	70	1	1	15
		DC	1	1	1	1	84	1	1	10
		WT	1	1	1	1	84	1	1	10
		AC	1	1	1	1	84	1	1	10
		LT	1	1	1	1	84	1	1	10
		RT	1	1	1	1	84	1	1	10
		CL	1	1	1	1	84	1	1	10
		EB	1	1	1	1	24	1	1	70
RT	KG	KG	70	1	1	1	1	24	1	1
		DC	24	1	1	1	1	70	1	1
		WT	24	1	1	1	1	70	1	1
		AC	24	1	1	1	1	70	1	1
		LT	24	1	1	1	1	70	1	1
		RT	10	1	1	1	1	84	1	1
		CL	24	1	1	1	1	70	1	1
		EB	10	1	1	1	1	70	1	15
	DC	KG	10	1	1	1	1	84	1	1
		DC	4	1	1	1	1	90	1	1
		WT	4	1	1	1	1	90	1	1
		AC	4	1	1	1	1	90	1	1
		LT	4	1	1	1	1	90	1	1
		RT	1	1	1	1	1	93	1	1
		CL	4	1	1	1	1	90	1	1
		EB	1	1	1	1	1	84	1	10
	WT	KG	10	1	1	1	1	84	1	1
		DC	4	1	1	1	1	90	1	1
		WT	4	1	1	1	1	90	1	1
		AC	4	1	1	1	1	90	1	1
		LT	4	1	1	1	1	90	1	1
		RT	1	1	1	1	1	93	1	1
		CL	4	1	1	1	1	90	1	1
		EB	1	1	1	1	1	84	1	10
	AC	KG	10	1	1	1	1	84	1	1
		DC	4	1	1	1	1	90	1	1
		WT	4	1	1	1	1	90	1	1
		AC	4	1	1	1	1	90	1	1
		LT	4	1	1	1	1	90	1	1
		RT	1	1	1	1	1	93	1	1
		CL	4	1	1	1	1	90	1	1
		EB	1	1	1	1	1	84	1	10
	LT	KG	10	1	1	1	1	84	1	1
		DC	4	1	1	1	1	90	1	1
		WT	4	1	1	1	1	90	1	1
		AC	4	1	1	1	1	90	1	1
		LT	4	1	1	1	1	90	1	1
		RT	1	1	1	1	1	93	1	1
		CL	4	1	1	1	1	90	1	1
		EB	1	1	1	1	1	84	1	10

Tabela C.9: CPT da variável B. Parte 9

Classes(t-2)	Classes(t-1)	Classes(t)	KG	DC	WT	AC	LT	RT	CL	EB
RT	RT	KG	24	1	1	1	1	70	1	1
		DC	1	1	1	1	1	93	1	1
		WT	1	1	1	1	1	93	1	1
		AC	1	1	1	1	1	93	1	1
		LT	1	1	1	1	1	93	1	1
		RT	1	1	1	1	1	93	1	1
		CL	1	1	1	1	1	93	1	1
		EB	1	1	1	1	1	80	1	14
	CL	KG	10	1	1	1	1	84	1	1
		DC	4	1	1	1	1	90	1	1
		WT	4	1	1	1	1	90	1	1
		AC	4	1	1	1	1	90	1	1
		LT	4	1	1	1	1	90	1	1
		RT	1	1	1	1	1	93	1	1
		CL	4	1	1	1	1	90	1	1
		EB	1	1	1	1	1	84	1	10
	EB	KG	10	1	1	1	1	70	1	15
		DC	1	1	1	1	1	84	1	10
		WT	1	1	1	1	1	84	1	10
		AC	1	1	1	1	1	84	1	10
		LT	1	1	1	1	1	84	1	10
		RT	1	1	1	1	1	84	1	10
		CL	1	1	1	1	1	84	1	10
		EB	1	1	1	1	1	24	1	70
CL	KG	KG	70	1	1	1	1	1	24	1
		DC	35	35	1	1	1	1	25	1
		WT	24	1	1	1	1	1	70	1
		AC	24	1	1	1	1	1	70	1
		LT	24	1	1	1	1	1	70	1
		RT	24	1	1	1	1	1	70	1
		CL	10	1	1	1	1	1	84	1
		EB	24	1	1	1	1	1	70	1
	DC	KG	35	35	1	1	1	1	25	1
		DC	1	70	1	1	1	1	24	1
		WT	24	1	1	1	1	1	70	1
		AC	24	1	1	1	1	1	70	1
		LT	24	1	1	1	1	1	70	1
		RT	24	1	1	1	1	1	70	1
		CL	10	1	1	1	1	1	84	1
		EB	24	1	1	1	1	1	70	1
	WT	KG	10	1	1	1	1	1	84	1
		DC	1	10	1	1	1	1	84	1
		WT	2	2	1	1	1	1	91	1
		AC	2	2	1	1	1	1	91	1
		LT	2	2	1	1	1	1	91	1
		RT	2	2	1	1	1	1	91	1
		CL	1	1	1	1	1	1	93	1
		EB	2	2	1	1	1	1	91	1

Tabela C.10: CPT da variável B. Parte 10

Classes(t-2)	Classes(t-1)	Classes(t)	KG	DC	WT	AC	LT	RT	CL	EB
CL	AC	KG	10	1	1	1	1	1	84	1
		DC	1	10	1	1	1	1	84	1
		WT	2	2	1	1	1	1	91	1
		AC	2	2	1	1	1	1	91	1
		LT	2	2	1	1	1	1	91	1
		RT	2	2	1	1	1	1	91	1
		CL	1	1	1	1	1	1	93	1
		EB	2	2	1	1	1	1	91	1
	LT	KG	10	1	1	1	1	1	84	1
		DC	1	10	1	1	1	1	84	1
		WT	2	2	1	1	1	1	91	1
		AC	2	2	1	1	1	1	91	1
		LT	2	2	1	1	1	1	91	1
		RT	2	2	1	1	1	1	91	1
		CL	1	1	1	1	1	1	93	1
		EB	2	2	1	1	1	1	91	1
	RT	KG	10	1	1	1	1	1	84	1
		DC	1	10	1	1	1	1	84	1
		WT	2	2	1	1	1	1	91	1
		AC	2	2	1	1	1	1	91	1
		LT	2	2	1	1	1	1	91	1
		RT	2	2	1	1	1	1	91	1
		CL	1	1	1	1	1	1	93	1
		EB	2	2	1	1	1	1	91	1
	CL	KG	24	1	1	1	1	1	70	1
		DC	1	24	1	1	1	1	70	1
		WT	1	1	1	1	1	1	93	1
		AC	1	1	1	1	1	1	93	1
		LT	1	1	1	1	1	1	93	1
		RT	1	1	1	1	1	1	93	1
		CL	1	1	1	1	1	1	93	1
		EB	1	1	1	1	1	1	93	1
	EB	KG	10	1	1	1	1	1	84	1
		DC	1	10	1	1	1	1	84	1
		WT	2	2	1	1	1	1	91	1
		AC	2	2	1	1	1	1	91	1
		LT	2	2	1	1	1	1	91	1
		RT	2	2	1	1	1	1	91	1
		CL	1	1	1	1	1	1	93	1
		EB	2	2	1	1	1	1	91	1
EB	KG	KG	70	1	1	1	1	1	1	24
		DC	35	35	1	1	1	1	1	25
		WT	35	1	35	1	1	1	1	25
		AC	24	1	1	1	1	1	1	70
		LT	35	1	1	1	35	1	1	25
		RT	35	1	1	1	1	35	1	25
		CL	24	1	1	1	1	1	1	70
		EB	10	1	1	1	1	1	1	84

Tabela C.11: CPT da variável B. Parte 11

Classes(t-2)	Classes(t-1)	Classes(t)	KG	DC	WT	AC	LT	RT	CL	EB
EB	DC	KG	35	25	1	1	1	1	1	25
		DC	1	70	1	1	1	1	1	24
		WT	1	35	35	1	1	1	1	25
		AC	1	24	1	1	1	1	1	70
		LT	1	35	1	1	35	1	1	25
		RT	1	35	1	1	1	35	1	25
		CL	1	24	1	1	1	1	1	70
		EB	1	10	1	1	1	1	1	84
	WT	KG	35	1	35	1	1	1	1	25
		DC	1	35	35	1	1	1	1	25
		WT	1	1	70	1	1	1	1	24
		AC	1	1	24	1	1	1	1	70
		LT	1	1	35	1	35	1	1	25
		RT	1	1	35	1	1	35	1	25
		CL	1	1	24	1	1	1	1	70
		EB	1	1	10	1	1	1	1	84
	AC	KG	10	1	1	1	1	1	1	84
		DC	1	10	1	1	1	1	1	84
		WT	1	1	10	1	1	1	1	84
		AC	2	2	2	1	2	2	1	88
		LT	1	1	1	1	10	1	1	84
		RT	1	1	1	1	1	10	1	84
		CL	2	2	2	1	2	2	1	88
		EB	1	1	1	1	1	1	1	93
	LT	KG	35	1	1	1	35	1	1	25
		DC	1	35	1	1	35	1	1	25
		WT	1	1	35	1	35	1	1	25
		AC	1	1	1	1	24	1	1	70
		LT	1	1	1	1	70	1	1	24
		RT	1	1	1	1	35	35	1	25
		CL	1	1	1	1	24	1	1	70
		EB	1	1	1	1	10	1	1	84
	RT	KG	35	1	1	1	1	35	1	25
		DC	1	35	1	1	1	35	1	25
		WT	1	1	35	1	1	35	1	25
		AC	1	1	1	1	1	24	1	70
		LT	1	1	1	1	35	35	1	25
		RT	1	1	1	1	1	70	1	24
		CL	1	1	1	1	1	24	1	70
		EB	1	1	1	1	1	10	1	84
	CL	KG	10	1	1	1	1	1	1	84
		DC	1	10	1	1	1	1	1	84
		WT	1	1	10	1	1	1	1	84
		AC	2	2	2	1	2	2	1	88
		LT	1	1	1	1	10	1	1	84
		RT	1	1	1	1	1	10	1	84
		CL	2	2	2	1	2	2	1	88
		EB	1	1	1	1	1	1	1	93

Tabela C.12: CPT da variável B. Parte 12

Classes(t-2)	**Classes(t-1)**	**Classes(t)**	**KG**	**DC**	**WT**	**AC**	**LT**	**RT**	**CL**	**EB**
EB	**EB**	**KG**	24	1	1	1	1	1	1	70
		DC	1	24	1	1	1	1	1	70
		WT	1	1	24	1	1	1	1	70
		AC	1	1	1	1	1	1	1	93
		LT	1	1	1	1	24	1	1	70
		RT	1	1	1	1	1	24	1	70
		CL	1	1	1	1	1	1	1	93
		EB	1	1	1	1	1	1	1	93

Apêndice D

Comportamentos do Carro Autônomo para o Caso - Cruzamento em T com dois veículos na via principal

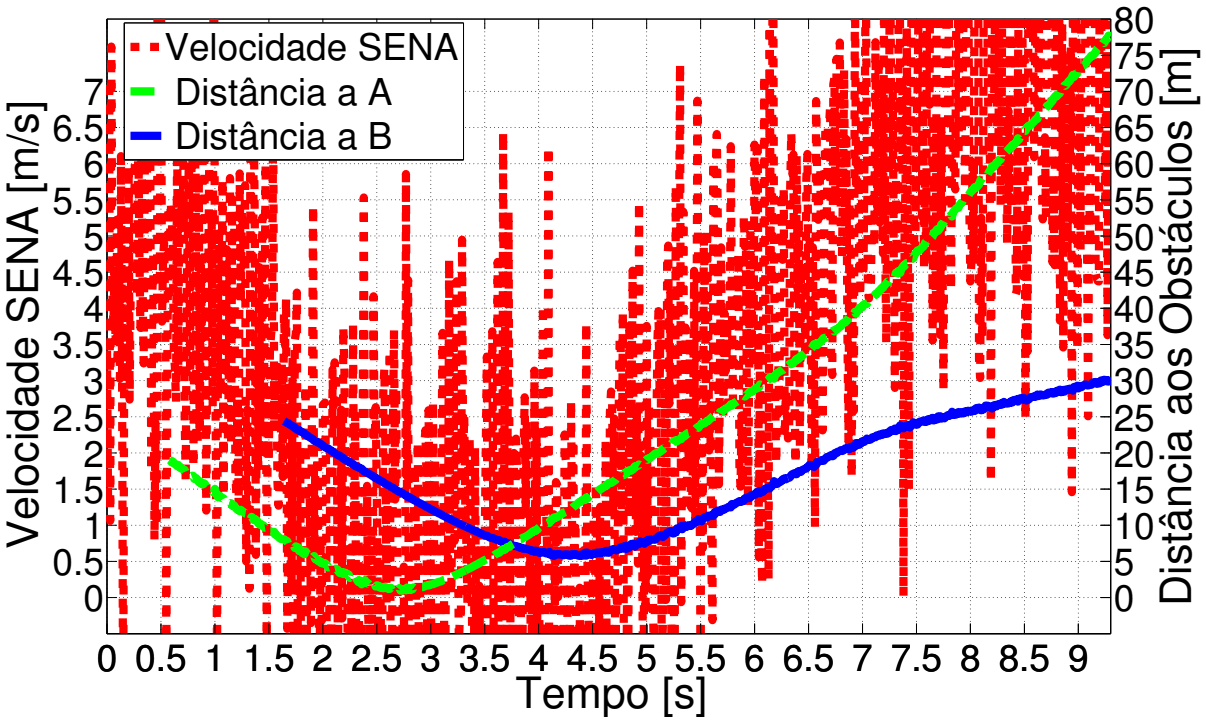

Figura D.1: Velocidade do Veículo Autônomo e distância aos outros carros para o caso 1 e sub-caso *erro na localização*.

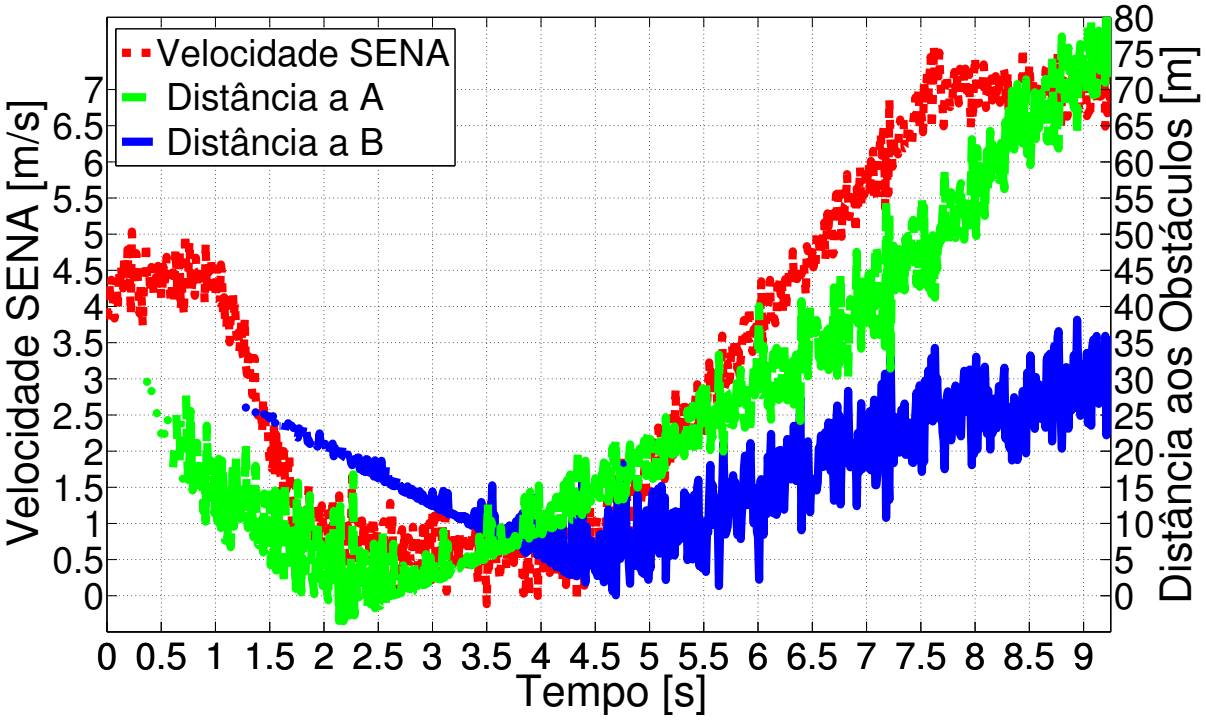

Figura D.2: Velocidade do Veículo Autônomo e distância aos outros carros para o caso 1 e sub-caso *erro no rastreamento*.

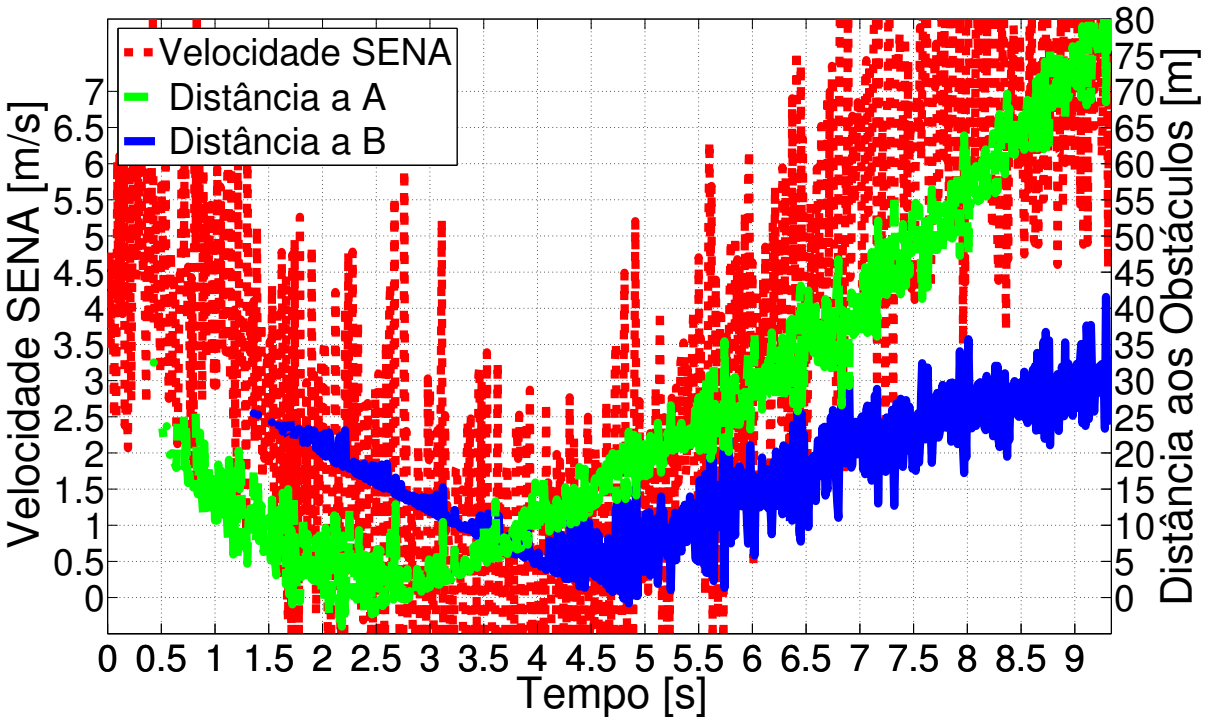

Figura D.3: Velocidade do Veículo Autônomo e distância aos outros carros para o caso 1 e sub-caso *erro em ambos*.

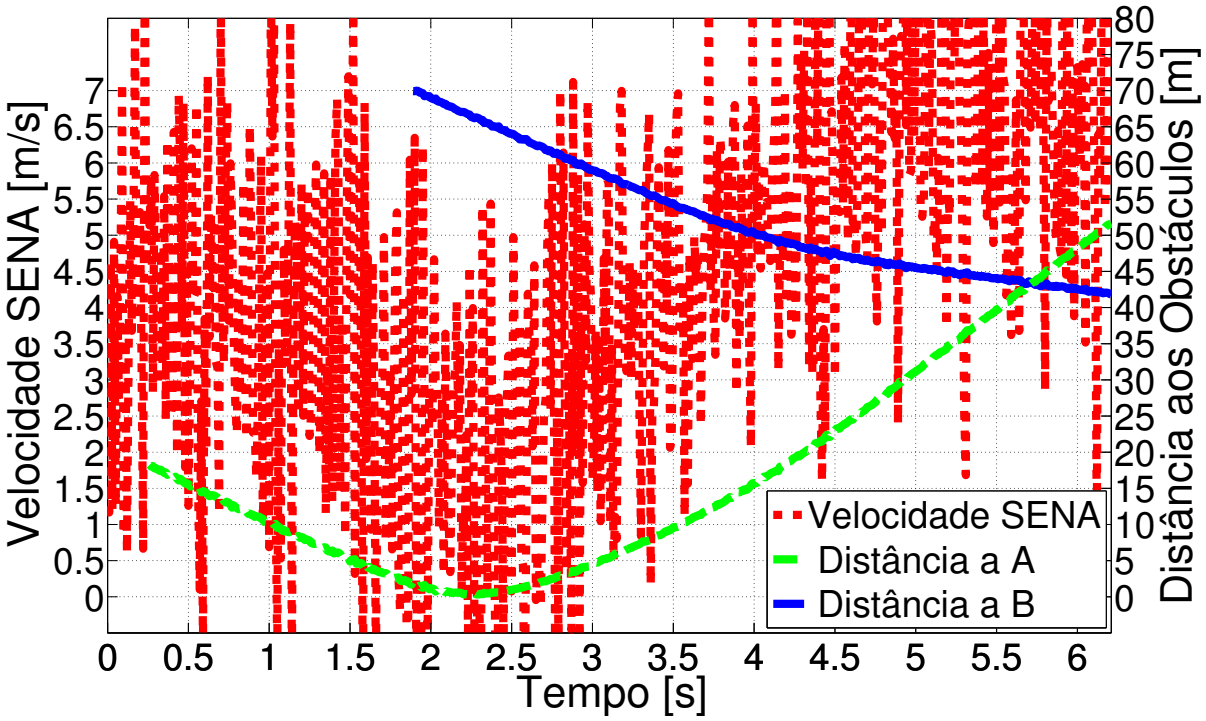

Figura D.4: Velocidade do Veículo Autônomo e distância aos outros carros para o caso 2 e sub-caso *erro na localização*.

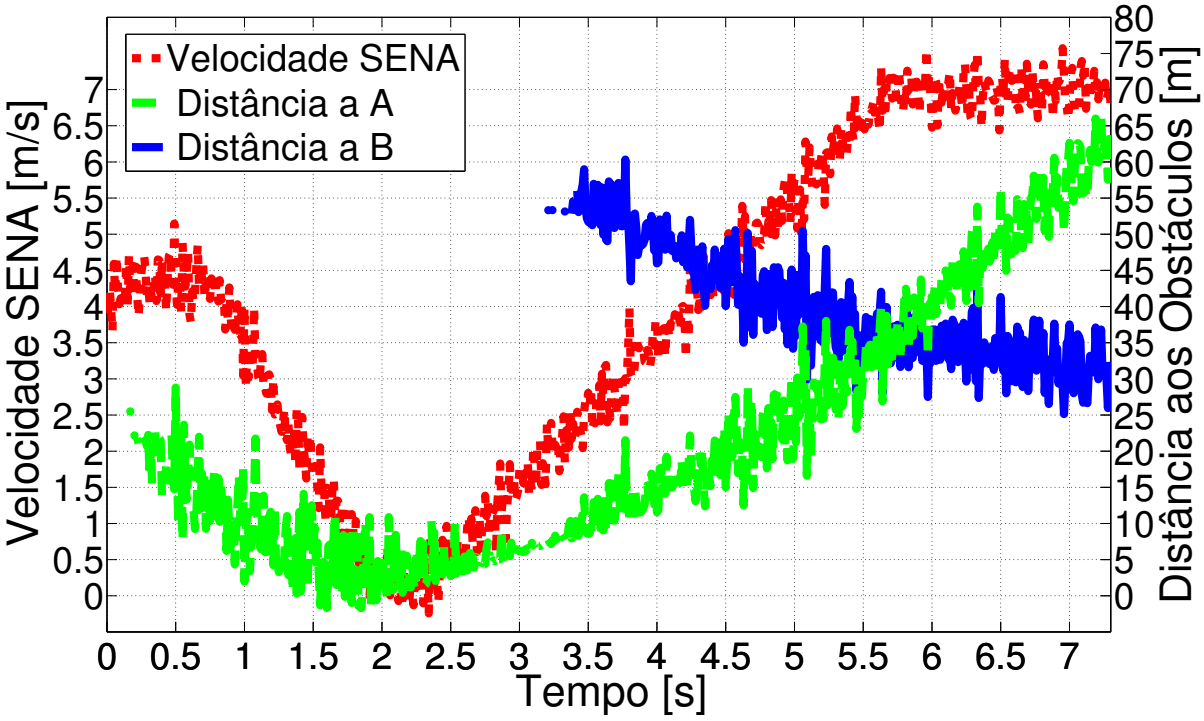

Figura D.5: Velocidade do Veículo Autônomo e distância aos outros carros para o caso 2 e sub-caso *erro no rastreamento*.

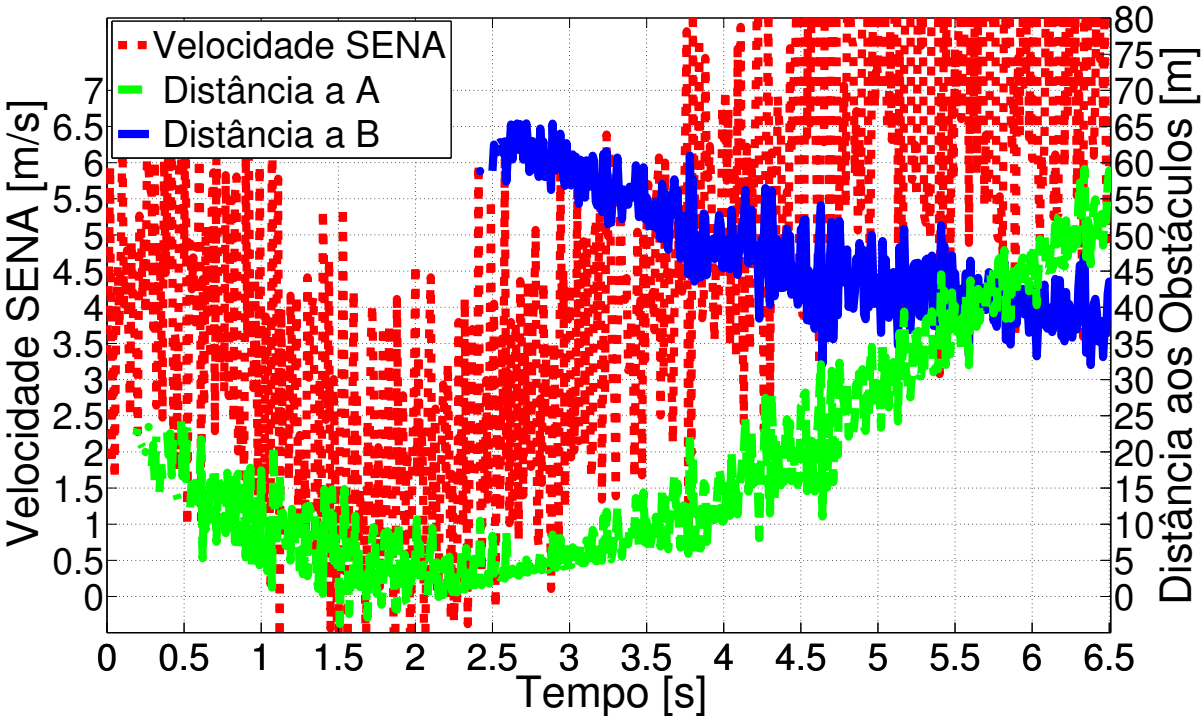

Figura D.6: Velocidade do Veículo Autônomo e distância aos outros carros para o caso 2 e sub-caso *erro em ambos*.

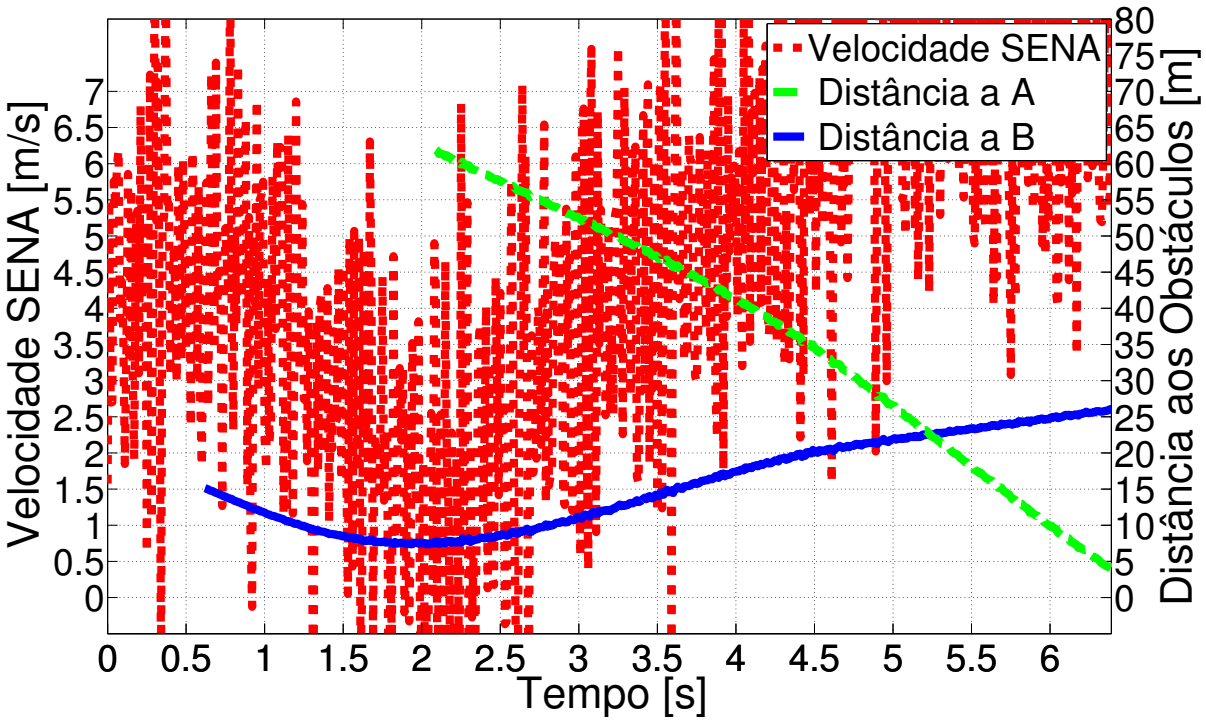

Figura D.7: Velocidade do Veículo Autônomo e distância aos outros carros para o caso 3 e sub-caso *erro na localização*.

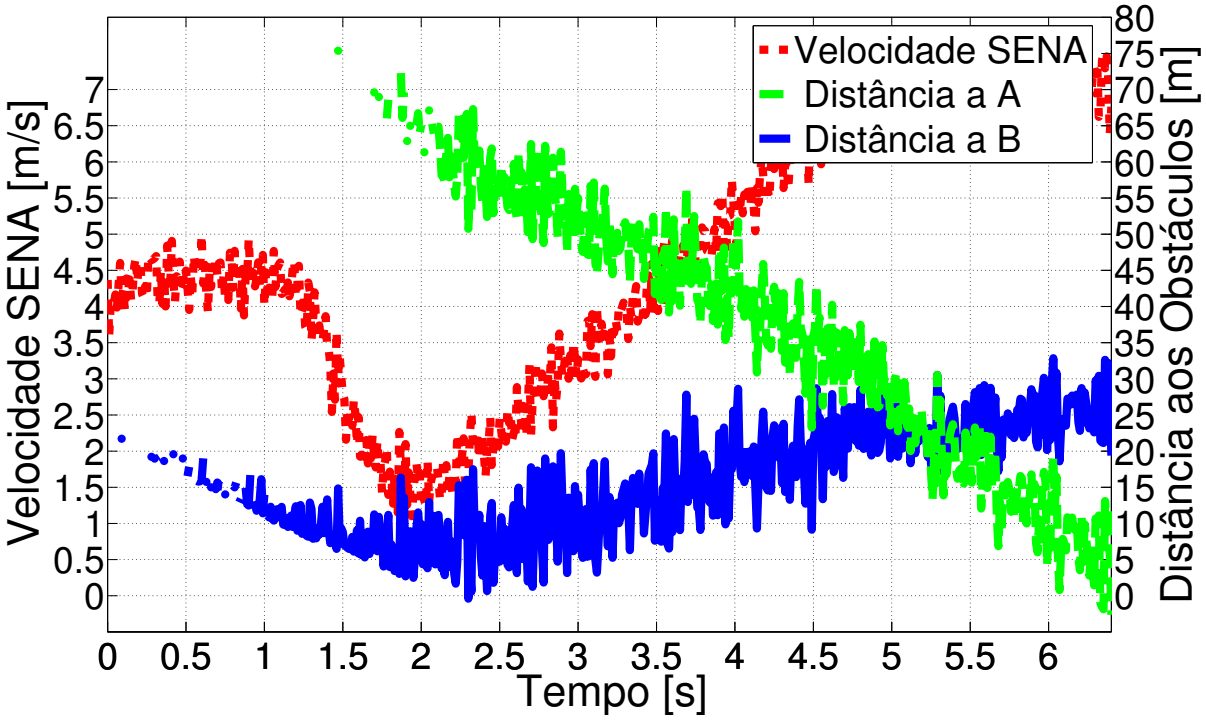

Figura D.8: Velocidade do Veículo Autônomo e distância aos outros carros para o caso 3 e sub-caso *erro no rastreamento*.

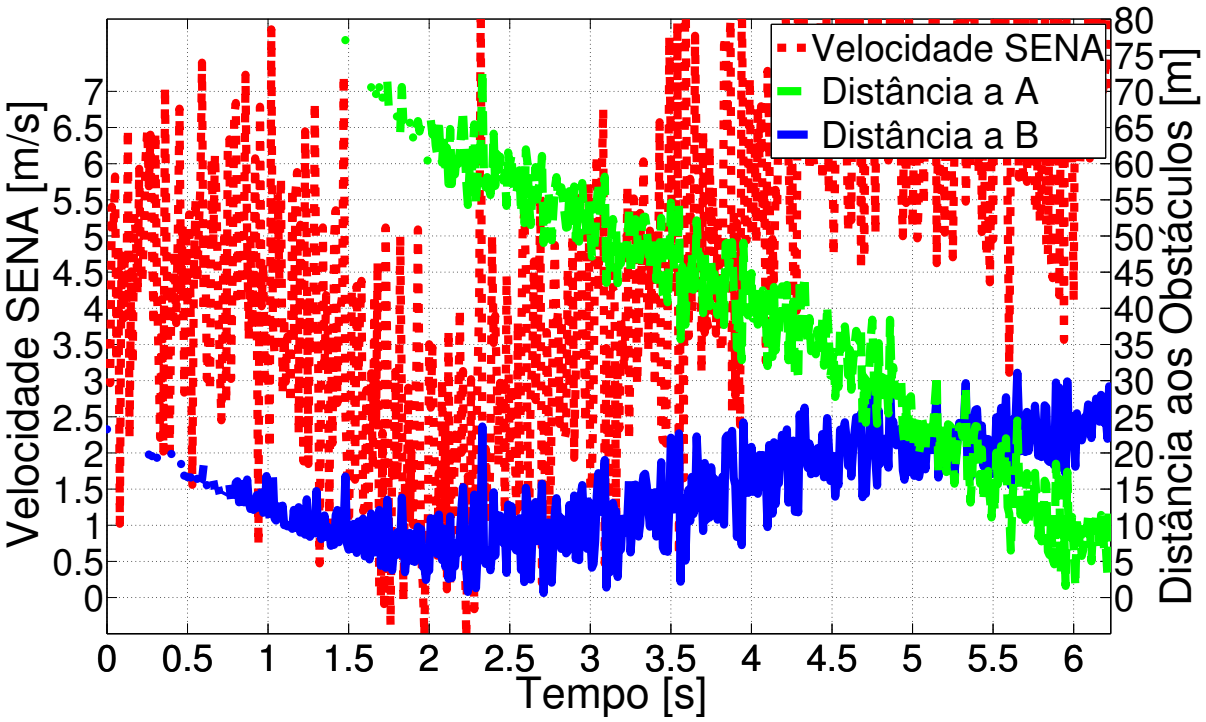

Figura D.9: Velocidade do Veículo Autônomo e distância aos outros carros para o caso 3 e sub-caso *erro em ambos*.

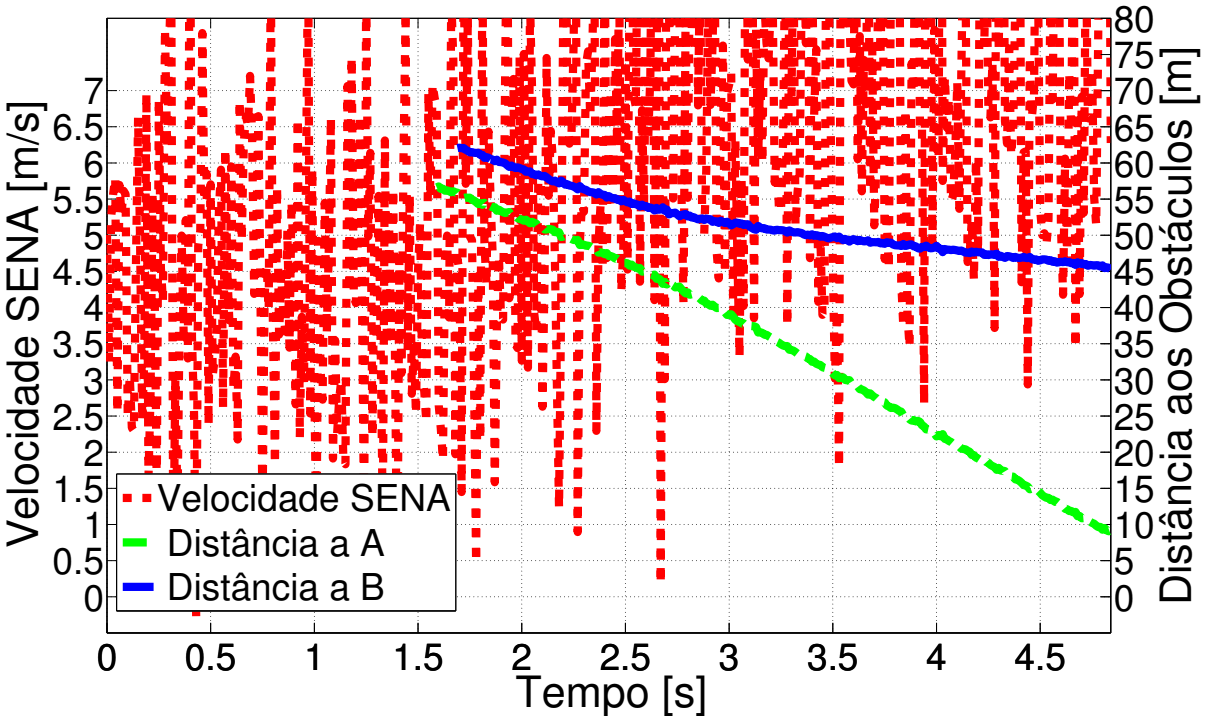

Figura D.10: Velocidade do Veículo Autônomo e distância aos outros carros para o caso 4 e sub-caso *erro na localização*.

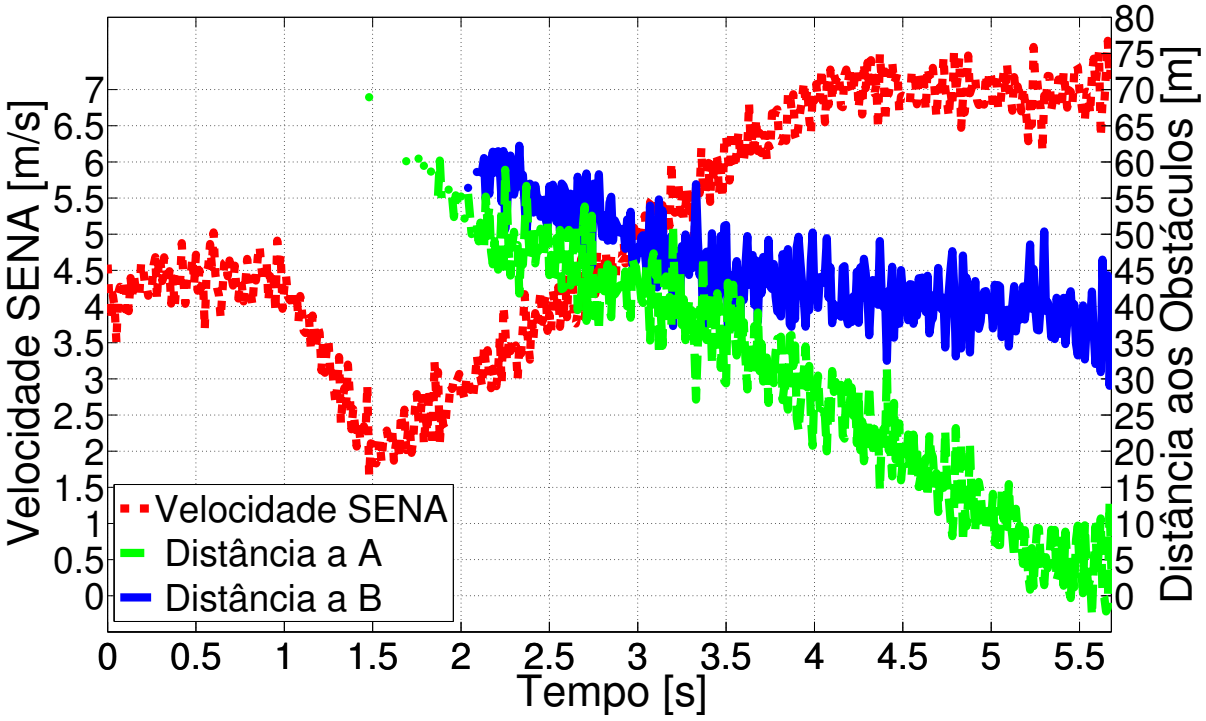

Figura D.11: Velocidade do Veículo Autônomo e distância aos outros carros para o caso 4 e sub-caso *erro no rastreamento*.

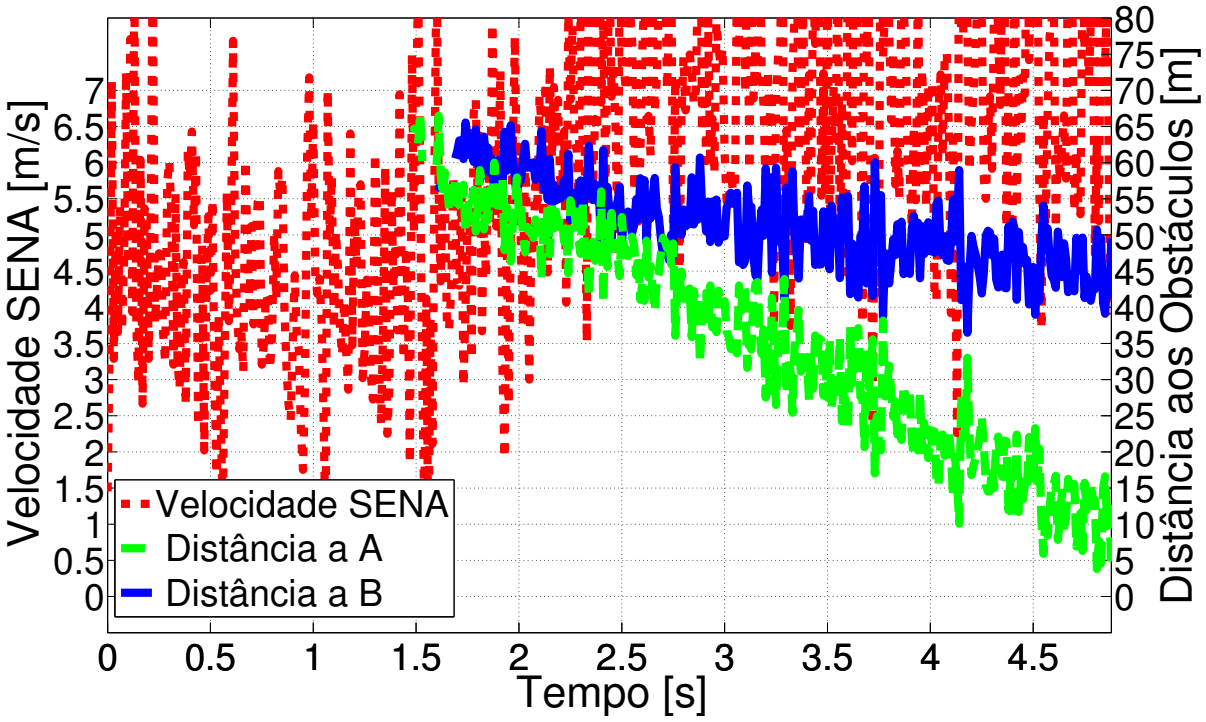

Figura D.12: Velocidade do Veículo Autônomo e distância aos outros carros para o caso 4 e sub-caso *erro em ambos*.