

UNIVERSIDADE FEDERAL DE MINAS GERAIS
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**Desenvolvimento de um Sistema de Localização e
Reconstrução de Trajetórias para um Veículo Terrestre**

Belo Horizonte, 25 de setembro de 2009

UNIVERSIDADE FEDERAL DE MINAS GERAIS
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**Desenvolvimento de um Sistema de Localização e
Reconstrução de Trajetórias para um Veículo Terrestre**

Michelle Mendes Santos

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Minas Gerais como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica.

Orientadores: Prof. Dr. Leonardo Antônio Borges Tôrres e Prof. Dr. Guilherme Augusto Silva Pereira

Belo Horizonte, 25 de setembro de 2009

Dedicatória

À minha família e ao Paulo, meu
companheiro vinte e cinco horas
por dia.

Agradecimentos

Agradeço primeiramente a Deus pela oportunidade de viver essa experiência intensa que é a pós-graduação e por ter me dado forças para concluir mais essa etapa de minha vida. Agradeço ao meu noivo, Paulo, pela paciência, pelos conselhos, pelo companheirismo, enfim, por existir em minha vida. Agradeço aos meus pais pela compreensão de minha ausência em diversos momentos importantes da família.

Agradeço aos meus orientadores, Professor Leonardo Tôrres e Professor Guilherme Pereira, pelos ensinamentos, pela paciência e pelo apoio e ao Programa de Pós-Graduação em Engenharia Elétrica da UFMG. Agradeço ao Professor Paulo Iscold do Departamento de Engenharia Mecânica da UFMG, membro do grupo PDVA que participou do desenvolvimento deste trabalho. Agradeço aos colegas do laboratório CORO, que me auxiliaram academicamente em diversos momentos, pelas conversas de descontração, pelos “cafés”, especialmente ao Elias, ao Matheus Vinti e ao Guilherme Castro que participaram diretamente do desenvolvimento deste trabalho; aos colegas do PPGEE pelo companheirismo na realização de trabalhos e estudos em grupo. Agradeço aos alunos para os quais tive oportunidade de lecionar, que contribuíram para minha experiência docente.

Agradeço aos demais professores do Departamento de Engenharia Mecânica que disponibilizaram o automóvel utilizado neste trabalho, ao Professor Marcos Timbó do Instituto de Geociências e agradeço ao Departamento de Planejamento Físico e Obras da UFMG pelo fornecimento da planta do Campus.

Epígrafe

“A resposta certa, não importa nada: o essencial é que as perguntas estejam certas.”

Mário Quintana

Resumo

A tarefa de localização de um robô móvel constitui-se como uma das etapas fundamentais para se atingir o objetivo de locomoção autônoma do mesmo, tendo em vista que um veículo deve conhecer sua posição geográfica, em relação a um determinado referencial, para conseguir se desviar de obstáculos conhecidos e alcançar lugares desejados. O cumprimento desta tarefa demanda a utilização de informações ruidosas provenientes de diversos tipos de sensores. Neste trabalho tem-se como objetivo o estudo de técnicas de fusão sensorial aplicadas ao desenvolvimento de um sistema de localização para um automóvel de passeio, o qual será futuramente usado como plataforma robótica móvel. O sistema desenvolvido provê não apenas informações acerca da posição geográfica do veículo, mas também fornece estimativas de velocidade e orientação ao longo do trajeto, graças à utilização de sensores de posição, velocidade e aceleração, adequadamente instalados e calibrados, cujas medições são processadas por algoritmos de estimação baseados no filtro de Kalman. Como exemplo de aplicação do sistema de localização proposto neste trabalho, foi desenvolvido um guia eletrônico embarcado que, em conjunto com mapas fornecidos previamente, pode apresentar informações ao motorista que trafega com o veículo em um dado instante.

Abstract

The localization task of a mobile robot is one of the most important steps towards its autonomous locomotion, since a vehicle must know its geographic position, must be able to avoid known obstacles and to arrive at desired places. The fulfillment of this task requires the use of noisy information provided by many types of sensors. In this work the objective is the study of sensor fusion techniques applied to the development of a localization system for an automobile, which will be used later as a mobile robotic platform in UFMG. The developed system not only provides information concerning the geographic position of the vehicle, but also estimates its speed and orientation. This is accomplished by the use of position, speed and acceleration sensors, which are adequately installed and calibrated. The sensors measurements are processed using estimation algorithms based on the Kalman filter. As an example of application of the localization system proposed in this work, an onboard electronic guide was developed, which, based on maps previously stored on a computer, can continuously display geographical information to the vehicle driver.

Conteúdo

Lista de Figuras	xvi
Lista de Tabelas	xxi
1 Introdução	23
1.1 Motivação	23
1.2 Objetivos	25
1.3 Justificativas	26
1.4 Metodologia	28
1.5 Resultados Alcançados	30
1.6 Organização do Texto	30
2 Revisão Bibliográfica	33
2.1 O Problema da Localização	33
2.1.1 Localização Relativa (<i>Dead-Reckoning</i>)	34
2.1.2 Localização Absoluta	36
2.2 Métodos de Fusão Sensorial	39
2.2.1 Filtro de Kalman	40
2.2.2 Filtro de Kalman Estendido	43
2.3 Trabalhos Relacionados	44
2.4 Considerações Finais	52
3 Metodologia	53
3.1 Modelagem Matemática do Problema	53
3.2 Descrição da Plataforma	57
3.2.1 Sensores	57

4	Fusão Sensorial e Resultados Experimentais	69
4.1	Configurações	69
4.1.1	Configuração 1	69
4.1.2	Configuração 2	71
4.1.3	Configuração 3	72
4.1.4	Configuração 4	73
4.2	Ajuste das Matrizes de Covariância	75
4.2.1	Estimativa do Ruído de Processo Associado aos Sinais de Entrada e aos Erros de Modelagem	75
4.2.2	Estimativa do Ruído de Medição	78
4.2.3	Critérios de Avaliação	79
4.3	Reconstrução de Trajetórias – Resultados Experimentais	82
4.4	Considerações Finais	91
5	Localização <i>Online</i>	93
5.1	Fusão Sensorial	94
5.1.1	Comunicação Entre Programas	95
5.1.2	Inicialização do Algoritmo	95
5.1.3	Estimação da Trajetória	96
5.2	Interface Homem-Máquina (IHM)	97
5.2.1	Ferramentas Utilizadas	97
5.2.2	Construção da Interface de Exibição do Mapa	99
5.3	Resultados	102
5.4	Considerações Finais	105
6	Discussão e Conclusões	109
6.1	Visão Geral do Trabalho Desenvolvido	109
6.2	Principais Resultados Alcançados	109
6.3	Trabalhos Futuros	110
A	Sistema de Posicionamento Global (GPS) - Funcionamento	121
A.1	Cálculo da Posição do Receptor - Triangulação dos Satélites	121
A.2	Diluição da Precisão	124

B	Especificações Técnicas de Alguns Instrumentos	127
B.1	GPS	127
B.2	Sistema de Medições Inerciais	128
C	Janelamento de Segmentos	131

Lista de Figuras

1.1	Gráfico de dados coletados com GPS embarcado em um veículo. . . .	27
1.2	Dados coletados com GPS (*) fixo no ponto indicado pelo triângulo. .	28
1.3	Dados com perda do sinal GPS em alguns pontos. O pontos expres- sados com (*) representam os pontos coletados sem perda do sinal de satélite; os pontos representados pelo círculo representam os pontos em que há perda do sinal.	29
2.1	Órbitas dos Satélites de GPS [Pak, 2007].	39
2.2	Etapas do algoritmo do filtro de Kalman.	42
3.1	Sistema de coordenadas preso ao veículo.	54
3.2	Sistema de coordenadas na Terra.	55
3.3	Modelo de Ackerman.	56
3.4	Representação da configuração física dos instrumentos no veículo. . .	58
3.5	Receptor Garmin modelo GPS18.	59
3.6	Zonas UTM [Dana, 1994]	60
3.7	Sensor Microstrain Modelo 3DM-GX1	61
3.8	Bússola Profissional Utilizada no Experimento.	62
3.9	Medida do Sistema Inercial <i>versus</i> Medida da Bússola - Dados Co- letados em um Mesmo Local. A reta tracejada possui inclinação de 45 graus, para efeito comparativo (idealmente, as medidas obtidas deveriam estar sobre a reta)	63
3.10	Medida do Sistema Inercial <i>versus</i> Medida da Bússola - Dados Co- letados em Locais Distintos. A reta tracejada possui inclinação de 45 graus, para efeito comparativo (idealmente, as medidas obtidas deveriam estar sobre a reta)	64

3.11	Sistema de Atuação do Volante.	64
3.12	Controlador de Posição EPOS 24/5.	65
3.13	Curva de Calibração - Leitura do Encoder e Ângulo das Rodas.	65
3.14	Diagrama elétrico do circuito de condicionamento de sinal dos sensores de velocidade das rodas	67
3.15	Curva de calibração do sensor de velocidade da roda direita	67
3.16	Curva de calibração do sensor de velocidade da roda esquerda	68
4.1	Aceleração no eixo x - sinal medido pelo SMI (azul) e sinal filtrado (vermelho).	76
4.2	Velocidade angular em torno do eixo z - sinal medido pelo SMI (azul) e sinal filtrado (vermelho).	77
4.3	Comparação da inovação com o limite de confiança $\pm 3\sqrt{P_{yy}}$ para os estados (a) p_x e (b) p_y utilizando a Configuração 1. As linhas contínuas correspondem à inovação e as linhas tracejadas representam os limites de confiança	80
4.4	Comparação da inovação com o limite de confiança $\pm 3\sqrt{P_{yy}}$ para os estados (a) p_x e (b) p_y utilizando a Configuração 2. As linhas contínuas correspondem à inovação e as linhas tracejadas representam os limites de confiança	80
4.5	Comparação da inovação com o limite de confiança $\pm 3\sqrt{P_{yy}}$ para os estados (a) p_x e (b) p_y utilizando a Configuração 3. As linhas contínuas correspondem à inovação e as linhas tracejadas representam os limites de confiança	81
4.6	Comparação da inovação com o limite de confiança $\pm 3\sqrt{P_{yy}}$ para os estados (a) p_x e (b) p_y utilizando a Configuração 4. As linhas contínuas correspondem à inovação e as linhas tracejadas representam os limites de confiança	81
4.7	Gráfico de reconstrução da trajetória utilizando a Configuração 1.	83
4.8	Gráfico de reconstrução da trajetória utilizando a Configuração 2.	84
4.9	Gráfico de reconstrução da trajetória utilizando a Configuração 3.	84
4.10	Gráfico de reconstrução da trajetória utilizando a Configuração 4.	85

4.11	Gráfico do traço da matriz de covariância da estimação da posição utilizando a Configuração 1.	87
4.12	Gráfico do traço da matriz de covariância da estimação da posição utilizando a Configuração 2.	87
4.13	Gráfico do traço da matriz de covariância da estimação da posição utilizando a Configuração 3.	88
4.14	Gráfico do traço da matriz de covariância da estimação da posição utilizando a Configuração 4.	88
4.15	Gráfico das velocidades estimadas nas Configurações 1, 2 e 4 e da velocidade medida na Configuração 3.	91
5.1	Arquitetura de softwares desenvolvidos para a localização.	94
5.2	Exemplo da busca de segmentos que estão contidos ou interceptam uma janela.	99
5.3	Segmentos originais e espelhados - a operação de espelhamento possibilita o uso da CGAL.	101
5.4	Janela para inicialização do sistema de localização.	102
5.5	Janela de exibição da localização ao longo do trajeto.	103
5.6	Trajatória Exibida sobre o Mapa.	104
5.7	Trajatória Estimada Durante a Execução do Experimento.	104
A.1	Localização do receptor - infinitas possibilidades.	122
A.2	Localização do receptor - uma circunferência de possibilidades.	122
A.3	Localização do receptor - triangulação.	123
A.4	Fontes de Erro na Localização por GPS. Adaptado de [Ronnback, 2000]	124
A.5	Incerteza no posicionamento fornecido pelo receptor GPS de acordo com a geometria da configuração dos satélites.	125
B.1	Mensagem do tipo GPGGA do Protocolo NMEA.	128
B.2	Estrutura de processamento do sistema inercial Microstrain [MicroStrain, 2006].	129

C.1	Busca de segmentos pelo mínimo retângulo envolvente - retângulos são traçados em torno dos segmentos de orientação arbitrária e então, a verificação de interseção é feita entre os lados dos retângulos e a janela de busca.	132
C.2	Busca de segmentos pelo mínimo retângulo envolvente (Pior Caso). Nesse caso, a busca seria efetuada em todos os retângulos, porém, nenhum dos segmentos interceptam a janela de busca.	132
C.3	Intervalos Elementares.	133
C.4	Interseção dos segmentos com um dos limites verticais da janela de busca.	134
C.5	Esqueleto da <i>Segment Tree</i>	134
C.6	Subconjuntos Pertencentes a um Nó.	135

Lista de Tabelas

4.1	Resumo das características de cada configuração.	74
4.2	Valor médio do traço da matriz de covariância da estimativa de posição e do GPS.	89
4.3	Tempo total de processamento em segundos para uma trajetória de 377 segundos, o equivalente a 11500 pontos.	90
B.1	Características físicas do sistema de medidas inerciais Microstrain. . .	129

Capítulo 1

Introdução

1.1 Motivação

A tarefa de localização consiste na determinação da posição geográfica de um determinado objeto em relação a um dado referencial. Para se localizar em um ambiente, animais e seres humanos utilizam seus sentidos. A observação do ambiente por meio dos órgãos responsáveis pela visão, tato, audição e olfato, combinada com conhecimentos prévios de possíveis ambientes, leva o cérebro a processar as informações observadas e chegar a uma conclusão da posição do observador no mundo. Em sistemas robóticos móveis, os órgãos responsáveis pelos sentidos são substituídos por sensores utilizados para observar o ambiente. Essas observações são processadas em computadores que fazem o trabalho do “cérebro”, manipulando as observações para encontrar a localização.

Este trabalho aborda a localização automática de um veículo terrestre baseado em um carro de passeio ou automóvel, isto é, a determinação em tempo real da posição e orientação do veículo em um determinado ambiente por meio de diversos sensores que fornecem informações a uma unidade de processamento responsável por combiná-las a fim de se obter a melhor estimativa de posição geográfica.

A tarefa de localização é uma das mais importantes no desenvolvimento de veículos autônomos terrestres [Thrun et al., 2005]. Esses veículos são dotados de sensores e computação embarcada, capacitando-os a se locomoverem para atingir um objetivo pré-especificado sem a intervenção humana. Para se locomover de forma autônoma, é necessário que, de forma automática, sejam obtidas respostas a

três questões fundamentais [Borenstein et al., 1996a]:

- *Onde estou?* O veículo deve saber sua posição e orientação a fim de tomar decisões quanto aos movimentos seguintes. Essa é a tarefa de Localização.
- *Para onde devo ir?* Para efetuar uma tarefa, o veículo deve saber para onde ele deve ir. Ele deve, portanto, ter o conhecimento do Objetivo.
- *De que forma eu vou?* Uma vez conhecida a localização e determinado o objetivo do movimento, o veículo deve decidir a maneira de realizar o movimento para atingir esse objetivo. Essa tarefa é chamada Planejamento de Movimento.

A tarefa de localização é a base da solução da locomoção autônoma e deve ser tão precisa quanto possível. Porém, para responder a questão de localização o robô deve se basear em informações que tipicamente são ruidosas e incompletas provenientes de sensores, tais como GPS (*Global Positioning System*), acelerômetros, giroscópios, bússolas, inclinômetros, câmeras, entre outros. Para ampliar a confiabilidade da localização, é necessário combinar as medições desses diversos sensores, extraíndo de cada uma delas suas melhores características. Este trabalho visa a instalação de alguns desses sensores no veículo e o aumento da confiabilidade na informação de localização utilizando técnicas de processamento de sinais e fusão sensorial.

Além de viabilizar a locomoção autônoma do veículo, a localização automática em um automóvel agrega ao mesmo algumas funcionalidades, ampliando o conforto do motorista e conferindo a ele maior segurança. A instalação de sensores inteligentes, que informam ao usuário sua localização dentro de um espaço, facilita a condução do veículo em ambientes desconhecidos, por meio da exibição em um mapa da sua localização, podendo, assim, guiá-lo até seu objetivo. Do ponto de vista da segurança, esses sensores inteligentes podem ajudar o condutor trazendo informações que auxiliam a tomada de decisões, ou mesmo limitam determinadas operações não permitidas para uma via, como estacionar em local proibido, parar sobre uma faixa de pedestres, realizar ultrapassagem em trechos de faixa contínua, trafegar em velocidade superior ao limite permitido pela via, etc., além de informar a existência de redutores de velocidade ou curvas perigosas iminentes.

A combinação da localização com informações do ambiente no qual se trafega pode ser aplicada ao desenvolvimento de um guia turístico eletrônico, o qual informa aos ocupantes do veículo os pontos turísticos importantes ao longo do percurso, dizendo qual a atração que está à direita ou à esquerda do veículo, e trazendo informações a respeito dessa atração.

1.2 Objetivos

Este trabalho tem como objetivo geral o desenvolvimento e implementação de um sistema de localização e reconstrução de trajetórias para um automóvel autônomo, cuja confiabilidade na informação de posição e orientação do veículo, bem como a frequência com que essa informação é disponibilizada, sejam superiores àquelas obtidas usando somente um sensor GPS. Esse sistema deve contar, ainda, com tolerância a falhas relativas à perda do sinal GPS. Para isso, outros sensores de posição, velocidade, aceleração e inclinação do veículo são combinados às medidas do GPS por meio de algoritmos de filtragem estocástica. As informações combinadas são utilizadas para a reconstrução posterior da trajetória, após a execução do movimento, ou para, em conjunto com o mapa da área percorrida, informar ao usuário do veículo, durante o movimento, sobre a proximidade de alguns pontos de interesse, tais como curvas, prédios, redutores de velocidade, etc. Além da posição e orientação do veículo, outros estados, que sejam de interesse para o desenvolvimento de sistemas para um veículo autônomo, como sua velocidade, por exemplo, são estimados.

Os objetivos específicos deste trabalho são:

- Definição da relação entre entradas e saídas envolvidas no processo, a fim de se determinar que grandezas devem ser medidas e quais os sensores mais apropriados para a medição dessas grandezas.
- Desenvolvimento de instrumentação embarcada: calibração e condicionamento eletrônico dos sensores absolutos e relativos, instalação dos sensores no veículo, integração dos sensores à unidade de processamento.
- Estudo dos algoritmos estocásticos de fusão sensorial mais apropriados para a combinação de sensores absolutos e relativos com taxas de aquisição diferentes.

- Implementação e análise de algoritmos para filtragem estocástica de fusão sensorial na reconstrução de trajetórias, visando uma avaliação de seu desempenho nos aspectos de robustez a incertezas, robustez a falhas, custo e confiabilidade.
- Combinação das informações de sensores com um mapa, e exibição da localização do veículo em uma interface gráfica à medida em que ele se locomove dentro do Campus da UFMG com incerteza inferior e maior robustez que aquelas providas por um receptor GPS.
- Avaliação do sistema desenvolvido, determinando suas características em termos de robustez e precisão, buscando respostas para as seguintes questões: as informações dos sensores são confiáveis (qual a incerteza associada às suas medidas)? Como combiná-las a fim de se obter uma informação que corresponda mais fielmente à realidade? Em que situação pode ser melhor utilizar um ou outro sensor? Por quanto tempo o sistema continua confiável em caso de perda do sinal GPS?

Posto o que foi expresso acima, espera-se que o sistema composto pela instrumentação e processamento das informações para estimação de estados, desenvolvido neste trabalho, contribua para o desenvolvimento de um carro autônomo.

1.3 Justificativas

O desenvolvimento de um sistema de localização cuja confiabilidade e frequência da informação sejam compatíveis com os requisitos de um sistema de controle se justifica pela necessidade de atenção a esses requisitos no desenvolvimento de veículos autônomos. Os sistemas de localização utilizados atualmente, inclusive em produtos comerciais, são baseados apenas em dados de GPS, o qual fornece a informação de localização no plano com uma incerteza de até 30 metros [Brown & Hwang, 1997]. Além disso, a frequência de envio das informações é baixa (entre 1Hz e 5Hz [Garmin, 2005]).

A Figura 1.1 mostra um gráfico traçado com os dados coletados com um GPS Garmin, modelo 18 USB, durante alguns segundos, embarcado em um carro. É possível observar que entre dois pontos do gráfico o veículo percorreu aproximadamente




Figura 1.1: Gráfico de dados coletados com GPS embarcado em um veículo.

18 metros do trajeto e, nesse intervalo, não existe informação desse movimento. Além disso, a posição informada por um receptor GPS pode variar para um mesmo ponto, como mostra a Figura 1.2, que exhibe um gráfico de um experimento onde o receptor GPS se manteve fixo em um ponto de coordenadas conhecidas¹, representado no gráfico pelo triângulo. É possível observar que, apesar do receptor permanecer imóvel, foram obtidas informações variadas de localização.

Outra característica do receptor GPS é a perda de sinal em caso de obstáculos como túneis, construções ou vegetação muito densa. A Figura 1.3 mostra dados obtidos em um experimento realizado com o mesmo receptor, onde, em alguns pontos, o número de satélites vistos pelo receptor foi insuficiente para se obter a estimativa de sua posição, e, nesse caso, o receptor indicou uma informação incorreta de localização. Os pontos incorretos estão representados na figura pelos círculos.

Apesar das características negativas mencionadas, o receptor GPS é bastante utilizado em localização por ser um instrumento que fornece posição absoluta em

¹Coordenadas obtidas utilizando um GPS do tipo diferencial com incerteza de $\pm 0,006$ m no eixo x e $\pm 0,007$ m no eixo y . Dados fornecidos pelo professor Marcos Antônio Timbó Elmiro, do Instituto de Geociências da UFMG




Figura 1.2: Dados coletados com GPS (*) fixo no ponto indicado pelo triângulo.

relação à Terra. Assim, a combinação desse instrumento com outros sensores que possam melhorar a qualidade da informação. Uma das soluções mais adotadas é a combinação entre GPS e Sistemas de Navegação Inercial (*Inertial Navigation Systems* - INS). Isso ocorre porque os sensores encontrados nesses sistemas apresentam características complementares às do GPS [Grewal et al., 2007]. Os sensores de sistemas inerciais fornecem informação a uma alta taxa de amostragem. Porém, essa informação é degradada ao longo do tempo devido ao acúmulo de erros. A estimação de estados utilizando a combinação desses sensores é realizada neste trabalho por meio de algoritmos recursivos de filtragem estocástica.

1.4 Metodologia

A realização deste trabalho foi possível utilizando a metodologia descrita a seguir:

- Para os testes e experimentos foi utilizado como veículo experimental um automóvel modelo Astra Chevrolet, ano 2003 ²;

²doado à Escola de Engenharia da Universidade Federal de Minas Gerais pela montadora como




Figura 1.3: Dados com perda do sinal GPS em alguns pontos. O pontos expressos com (*) representam os pontos coletados sem perda do sinal de satélite; os pontos representados pelo círculo representam os pontos em que há perda do sinal.

- Após a definição dos sensores utilizados no veículo para a localização, estes foram instalados no veículo. Foram utilizados neste trabalho sensores de posição, velocidade e aceleração, conforme apresenta o Capítulo 3;
- A coleta de dados foi realizada em experimentos de movimentação do automóvel dentro do Campus da UFMG, cujo mapa de ruas e prédios foi fornecido pelo Departamento de Planejamento Físico e Obras (DPFO/UFMG);
- De posse dos dados coletados, foi realizada a fusão sensorial das informações para a reconstrução da trajetória efetuada, utilizando diversas configurações de sensores e algoritmos, a fim de compará-las.
- Após a avaliação do desempenho das configurações de sensores e algoritmos, a

forma de premiação pelo trabalho intitulado “Desenvolvimento de um motor multicomcombustível sobrealimentado, visando ganhos de potência e torque, sem prejuízo na eficiência energética original”, vencedor 1^o Encontro Científico em Prol da Mobilidade (ENEMOBI) no ano de 2006 em Indaiatuba, São Paulo

configuração selecionada foi adaptada para aquisição e processamento *online* das informações, a fim de se estimar a localização do veículo em tempo real;

- Utilizando o mapa do Campus da UFMG, foi possível construir uma interface gráfica que exibe na tela de um computador portátil a posição do veículo ao longo do trajeto.

1.5 Resultados Alcançados

A investigação das técnicas e modelos para fusão sensorial realizada neste trabalho bem como a realização de testes em situações reais possibilitou avaliar configurações adequadas à tarefa de localização do carro e determinar as limitações do sistema desenvolvido.

Um dos principais produtos deste trabalho é um sistema de localização em tempo real constituído por diversos programas que realizam a coleta dos dados dos sensores, um programa responsável pela fusão sensorial e um programa que exibe graficamente os resultados obtidos em um mapa. Esse sistema pode ser utilizado como um guia para auxiliar o motorista na sua orientação em um ambiente. Além disso, as informações obtidas como resultado da fusão podem ser utilizadas futuramente como dados de retroalimentação necessários ao sistema de controle automático do veículo. Este trabalho resultou, também, em duas publicações em congressos que estão listadas nas referências [Santos et al., 2008] e [Freitas et al., 2009].

1.6 Organização do Texto

Este texto está organizado em seis capítulos que abordam os seguintes assuntos: o Capítulo 2 traz uma revisão de trabalhos similares que inspiraram este trabalho ou que auxiliaram no seu desenvolvimento, contendo o estado da arte do desenvolvimento de veículos autônomos.

No Capítulo 3, apresenta-se os modelos matemáticos utilizados para a propagação dos estados estimados, além de uma descrição construtiva da plataforma utilizada, composta pelo veículo, sensores e computador embarcados. São abordadas as características físicas e princípios de medição dos instrumentos utilizados.

No Capítulo 4, apresenta-se o procedimento utilizado na fusão sensorial *offline*. A análise dos algoritmos experimentados na reconstrução de trajetória é discutida nesse capítulo.

No Capítulo 5, a aplicação dos algoritmos para estimação dos estados de interesse em tempo real é detalhada. O desenvolvimento da interface de usuário, responsável por integrar a estimação de localização em tempo real a um mapa na tela de um computador portátil, também é apresentado.

Discussões e conclusões são relatadas no Capítulo 6, o qual apresenta ainda algumas propostas de continuidade do trabalho.

O Apêndice A apresenta o princípio de funcionamento de um receptor GPS. O Apêndice B lista especificações técnicas de alguns dos instrumentos utilizados neste trabalho. No Apêndice C, a técnica utilizada para a elaboração de uma interface gráfica é detalhada.

Capítulo 2

Revisão Bibliográfica

2.1 O Problema da Localização

O problema da Localização consiste em responder a questão “Onde estou?” do ponto de vista do veículo, ou seja, encontrar sua posição no ambiente de trabalho. No caso de um veículo terrestre, localizar significa encontrar sua posição e orientação em relação a um sistema de coordenadas global fixo no ambiente.

A localização é a base para a locomoção autônoma. Se o veículo não tem informação sobre sua localização, decidir o que ele deve fazer se torna uma tarefa muito difícil. Alguns autores consideram a localização como sendo o problema fundamental para prover a um robô móvel a habilidade de se locomover de forma autônoma [Cox, 1990].

A percepção do ambiente pelo veículo é viabilizada pelo uso de sensores, que podem prover ao sistema de processamento medidas de localização absolutas ou relativas. As observações absolutas são aquelas capazes de fornecer informação da localização do robô móvel em relação ao ambiente a qualquer momento sem a necessidade do conhecimento de medidas anteriores. Elas são realizadas, geralmente, por meio de sensores exteroceptivos absolutos, que medem valores externos ao robô, como, por exemplo, a distância do robô a um objeto. As medidas relativas, por outro lado, necessitam do conhecimento do estado anterior do robô para gerar informação de sua posição atual. Elas são obtidas pelo uso de sensores proprioceptivos, que informam valores internos do veículo, como, por exemplo, velocidade das rodas ou ângulo do volante, no caso de um automóvel.

2.1.1 Localização Relativa (*Dead-Reckoning*)

As técnicas de localização relativa, ou *dead-reckoning*, referem-se a uma forma de navegação baseada na medida de velocidade e direção de movimento de um corpo e o tempo decorrido desde sua última posição conhecida [Bowditch, 1995]. Essa é uma forma de navegação bastante primitiva, utilizada tanto para localização quanto para previsão de hora de chegada ao destino em viagens de avião ou navio. O termo *dead-reckoning* data do século XVII e sua origem é polêmica; alguns dicionários de etimologia afirmam que *dead-reckoning* é uma abreviação para *deduced-reckoning*, outros dizem que o termo *dead* nada tem a ver com *deduced*, mas sim com o sentido de “exato, absoluto”, outros ainda, defendem que o termo “*live*” era utilizado para a navegação baseada nas estrelas e no movimento dos planetas, e portanto, “*dead*” seria utilizado para a localização sem a utilização dessa informação [Adams, 2002]. Essa técnica tem sido bastante utilizada até os dias atuais, porém, sua fragilidade consiste no acúmulo de erros ao longo do tempo, tendo em vista que o cálculo da posição atual é baseado nas posições estimadas anteriormente, os quais tipicamente contêm erros.

Em robótica móvel, os principais modelos e medidas utilizados para a localização relativa são o modelo de velocidades, a odometria e a navegação inercial, explicados a seguir.

Modelo de Velocidades

O modelo de velocidades é utilizado quando a velocidade das rodas não é disponibilizada para o cálculo da posição. Ele é baseado na medição das velocidades translacional e rotacional do robô, em sua posição anterior, e no tempo decorrido desde a última estimativa de posição para o cálculo das posições posteriores. A partir da medida das velocidades e do conhecimento do tempo, é possível estimar o deslocamento nesse período que, somado à posição inicial, fornece uma estimativa da posição atual. Porém, não há garantias de que as velocidades coletadas em um determinado instante correspondam às velocidades de todo o período de amostragem. Isso pode gerar erros a cada estimativa e, ao longo do tempo, esses erros se acumulam, fazendo com que a estimativa da posição seja muito distante do movimento

real.

Esse modelo é pouco utilizado como única ferramenta para a localização de veículos, mas pode ser utilizado como subsistema redundante, no caso de falha de outros métodos de localização, ou mesmo na fusão com outros métodos.

Odometria

A odometria é a técnica de se obter a localização por meio da integração ao longo do tempo da velocidade das rodas do robô móvel obtida por *encoders*. É uma das técnicas mais utilizadas, devido à sua simplicidade e baixo custo de implementação. A distância percorrida pelo robô é calculada a partir do número de revoluções de suas rodas em um determinado espaço de tempo. O ângulo de orientação pode ser obtido por meio da comparação dos valores medidos em cada uma das rodas.

Para a localização utilizando a odometria, é necessário um prévio conhecimento da posição inicial do robô. Com a utilização dessa técnica, obtém-se boa precisão para pequenos períodos e altas taxas de amostragem, porém, por ser uma técnica que integra as medidas ao longo do tempo, ela integra também os erros, que se acumulam no cálculo e crescem indefinidamente. Além do acúmulo de erros, a técnica é vulnerável a derrapagens, que não são contabilizadas pelos *encoders* e a precisão da medição é fortemente dependente da resolução desses sensores. Outra desvantagem desse método é a sensibilidade ao terreno, que deve ser suave para um bom resultado, e a sensibilidade à variação ou diferença no diâmetro das rodas. Esses aspectos negativos causam grandes erros ao longo do tempo, principalmente na orientação [Negenborn, 2003].

Apesar das fragilidades do método, a odometria é amplamente utilizada, principalmente em conjunto com outros métodos, por meio de fusão e integração sensorial [Borenstein et al., 1997].

Sistemas de Navegação Inercial

Sistemas de Navegação Inercial (*Inertial Navigation Systems - INS*) são compostos por girômetros e acelerômetros para medir velocidade angular e aceleração linear, respectivamente. Girômetros, ou giroscópios, são capazes de detectar pequenas variações na orientação do robô. Essa informação é, então, integrada uma vez a fim de

se obter o deslocamento angular. Acelerômetros são sensores que medem aceleração linear nos três eixos (x , y e z). A aceleração deve ser integrada duas vezes para a obtenção do deslocamento linear em cada um dos eixos. Acelerômetros não são apropriados para terrenos de superfície irregular, pois devido à inclinação do terreno (e conseqüente inclinação do sensor), uma componente da aceleração gravitacional estará presente nos outros eixos além do vertical [Borenstein et al., 1997].

O INS, assim como a odometria, também sofrem com o problema de acúmulo de erros de integração (*drift*), portanto não são apropriados para a estimação de posição por um longo período. Porém, o INS é mais preciso e pode fornecer informação a uma taxa de amostragem tão alta quanto a odometria [Borenstein et al., 1996b]. Atualmente, esses sistemas são utilizados em conjunto com outros sensores absolutos, que podem ajudar a diminuir o acúmulo de erros de integração [Barshan & Durrant-Whyte, 1995]. Uma configuração bastante utilizada é a combinação desses sensores com magnetômetros, que corrigem erros na orientação, um dos mais significantes parâmetros da localização [Borenstein et al., 1997].

2.1.2 Localização Absoluta

A medição absoluta da posição consiste na obtenção da posição do robô independente da informação de posição em instantes anteriores, ou seja, sem a necessidade de se integrar uma sequência de medições para se chegar à posição atual. Para se obter a posição com um sensor absoluto, basta considerar sua medida naquele instante. A principal vantagem dos sensores absolutos é que seus erros não crescem indefinidamente, pois não há integração das medições realizadas.

Um sensor absoluto pode fornecer a localização completa do robô ou apenas um de seus parâmetros (como o magnetômetro, por exemplo, que fornece apenas o ângulo de orientação em relação ao campo magnético da Terra). Os sensores absolutos podem ser baseados em mapas ou em marcadores (*landmarks*).

A localização baseada em mapas (também conhecida como *model matching*) utiliza características geográficas do ambiente que podem ter sido extraídas de um mapeamento prévio, para identificar a posição do veículo. Nessa técnica o ambiente é representado por características como linhas que compõem as paredes, corredores,

obstáculos, etc. Essa representação é armazenada no veículo e, à medida em que ele realiza o trajeto planejado, um novo mapeamento da região em que ele se encontra é feito e comparado ao mapa armazenado. Nessa comparação é possível obter a localização do padrão observado no mapa global e, assim, a localização do veículo. O uso dessa técnica é adequado a ambientes onde o cenário não sofre grandes mudanças ao longo do tempo. Essa é uma técnica bastante utilizada em ambientes internos em conjunto com sensores relativos, na correção de estimativas, por exemplo, obtida pelo cálculo da odometria [Fang et al., 2006].

Marcadores ou *landmarks* são objetos cuja posição é conhecida e fixa. Existem dois tipos de *landmarks*: os ativos e os passivos. Um sensor de *landmarks* ativos recebe sinais de seus marcadores indicando a posição relativa entre o sensor e cada *landmark*.

Os *landmarks* passivos não enviam sinais ao seus sensores; são os sensores que efetivamente detectam a presença de um *landmark* em seu “campo de visão” e calculam sua distância em relação a eles. Os *landmarks* passivos podem ser naturais ou artificiais.

Os *landmarks* naturais são objetos que fazem parte de um determinado cenário, como por exemplo, árvores, portas, janelas, sinais de trânsito. Os sensores mais utilizados para detectar esse tipo de marco são as câmeras de vídeo. Os *landmarks* artificiais são aqueles inseridos no cenário especificamente para servir de referência para o sistema de localização, como figuras geométricas, placas coloridas, dispositivos RFID's (*Radio-Frequency IDentification*), etc.

Os principais métodos de localização por *landmarks* ativos são a trilateração e a triangulação [Borenstein et al., 1997] [Singhal, 1997]. A técnica da trilateração consiste em utilizar a informação de distância do sensor a três ou mais *landmarks* para calcular sua posição e orientação. A triangulação utiliza, além das distâncias, os ângulos entre os sistemas de coordenadas do sensor e dos *landmarks* para esse cálculo. O sensor absoluto mais utilizado atualmente é o *Global Positioning System (GPS)*, que é um sensor de *landmarks* ativos que utiliza o método da triangulação para o cálculo da posição e orientação do receptor. A seguir, uma descrição desse sensor é apresentada.

Global Positioning System

O Sistema de Posicionamento Global, mais conhecido como GPS (*Global Positioning System*), é um sistema de navegação baseado em satélites desenvolvido pela Força Aérea e pelo Departamento de Defesa dos Estados Unidos da América. Esse sistema foi colocado em operação na década de 90, mas seu desenvolvimento teve início no final da década de 70 [Stuck & Kuga, 2005].

A utilização desse sistema de posicionamento por civis é parcialmente aberta. Usuários do mundo todo têm acesso à informação de posição, velocidade e tempo com certa precisão, dependendo do receptor, condições climáticas, localização geográfica, etc. Os satélites que compõem o sistema de navegação transmitem sinais de radiofrequência contendo informações suficientes para que o receptor compute sua posição e velocidade. Para que esse cálculo seja possível, é necessário que o receptor capte o sinal de, pelo menos, três satélites. O receptor utiliza a técnica de triangulação para calcular sua latitude, longitude e altitude. Mais informações sobre essa técnica encontram-se no Apêndice A.

Atualmente o sistema é composto de 24 satélites (e mais 4 sobressalentes) distribuídos de forma aproximadamente uniforme em seis órbitas ao redor da Terra. Cada órbita possui 4 satélites. Cada satélite gasta 12 horas para completar uma volta ao redor da Terra. Isso faz com que um usuário localizado em qualquer ponto da Terra tenha visibilidade a pelo menos quatro satélites todo o tempo, desde que não haja obstáculos entre o satélite e o receptor (Figura 2.1). A geometria dos satélites visíveis no céu muda ao longo do tempo, pois os satélites não são geostacionários [Brown & Hwang, 1997]. O receptor é capaz de identificar qual satélite envia um sinal a cada momento por meio de uma sequência pseudo-aleatória que é transmitida pelo satélite. Sua localização ao redor da Terra é monitorada e atualizada periodicamente por estações terrestres que verificam também o status da atividade dos satélites.

A transmissão de mensagens por ondas de rádio traz ao sistema certa fragilidade a variações geográficas e atmosféricas. Perturbações como reflexão e refração do sinal podem acarretar erros na informação. A obstrução da visada entre satélite e receptor impede que eles se comuniquem, fazendo com que haja perda da




Figura 2.1: Órbitas dos Satélites de GPS [Pak, 2007].

informação. Além disso, um ruído do tipo *random walk* [Papoulis & Pillai, 2001] é inserido no sinal enviado pelos satélites, o que faz com que o receptor pareça estar em movimento, mesmo quando está parado. Para corrigir esses problemas, a combinação desse sistema com outros sensores é uma saída comumente utilizada [Grewal et al., 2007]. Maiores detalhes sobre o funcionamento do GPS utilizado neste trabalho estão descritos na Seção 3.1.1.

2.2 Métodos de Fusão Sensorial

Na Seção 2.1 foram apresentados alguns tipos de sensores que podem ser utilizados na solução do problema de localização. Porém, para que seja possível aproveitar as características de cada sensor, é necessário combinar a informação de diversos sensores. Esse é o objetivo dos métodos de fusão sensorial: combinar a informação proveniente de sensores diferentes, com diferentes características e frequências de amostragem, valendo-se do conhecimento do modelo matemático que determina a evolução temporal das variáveis de estado do sistema, a fim de se obter uma boa estimativa das variáveis em questão. As técnicas de fusão sensorial tratam de balancear as características de cada sensor, para que a estimativa obtida seja mais confiável do que cada medição obtida separadamente.

A fusão da informação sensorial pode ocorrer entre sensores que observam uma mesma variável de um processo, o que é chamado de interação redundante, entre sensores complementares, que observam variáveis diferentes do processo e em conjunto fornecem informação sobre todas as variáveis de interesse desse processo, ou ainda entre sensores cooperativos, cuja variável observada por um dos sensores

serve de base para as observações do outro sensor [Luo & Kay, 1989].

São duas as principais abordagens utilizadas nas técnicas de fusão sensorial: métodos de fusão estatística e métodos de fusão probabilística [Singhal, 1997]. As técnicas de fusão estatística são aquelas baseadas no método de aproximação por mínimos quadrados, utilizado para prever valores de variáveis contaminadas por sinais aleatórios. São exemplos dessa técnica o ajuste por mínimos quadrados e os algoritmos baseados na filtragem de Kalman. Essas técnicas são mais utilizadas na fusão no nível do sinal, onde a informação filtrada possui características semelhantes às informações fornecidas pelos sensores. As técnicas de fusão probabilística são aquelas baseadas nos conceitos de incerteza e confiança inerentes à Teoria da Probabilidade, como as redes Bayesianas e a lógica fuzzy, e são comumente utilizadas para a fusão sensorial de informações com um nível de abstração elevado, como a fusão ao nível da característica, ou ao nível do símbolo [Fonseca, 1999].

Os sensores envolvidos neste trabalho fornecem informações de posição, velocidade angular do veículo, aceleração linear, velocidade angular das rodas e ângulo de giro do volante. Todos os sinais fornecidos por esses sensores são digitais e amostrados a diferentes taxas. Considerando os objetivos deste trabalho, são utilizados algoritmos de fusão sensorial baseados no Filtro de Kalman. As Seções 2.2.1 e 2.2.2 apresentam o funcionamento desses algoritmos.

2.2.1 Filtro de Kalman

O Filtro de Kalman (KF, do inglês *Kalman Filter*), descrito pela primeira vez em 1960 por Rudolf Emil Kalman [Kalman, 1960], é uma solução recursiva para o problema da estimação de estados de sistemas lineares e Gaussianos. É um algoritmo não polarizado e de variância mínima para a estimação de estados de um sistema dinâmico a partir de medições ruidosas e de um modelo do sistema. Usualmente, na utilização do KF assume-se um modelo linear discreto para o sistema em questão representado em espaço de estados:

$$x(k) = A(k-1)x(k-1) + B(k-1)u(k-1) + w(k-1), \quad (2.1)$$

$$y(k) = C(k)x(k) + v(k), \quad (2.2)$$

sendo $x \in \mathbb{R}^n$ o vetor de estados, $u \in \mathbb{R}^m$ o vetor de entradas, $A(k-1) \in \mathbb{R}^{n \times n}$, $B(k-1) \in \mathbb{R}^{n \times m}$ e $C \in \mathbb{R}^{p \times n}$ as matrizes do modelo, w e v são variáveis aleatórias que representam os ruídos de processo e de medição, respectivamente. Assuma-se que w e v são variáveis aleatórias Gaussianas, mutuamente independentes, de média zero e cujas matrizes de covariância são $Q(k-1)$ e $R(k)$. É importante notar que as matrizes do modelo podem variar ao longo do tempo. O filtro de Kalman não é restrito a esse tipo de sistema, podendo ser utilizado em sistemas variantes no tempo e, com algumas modificações, pode ser aplicado a sistemas não-lineares [Teixeira, 2008].

De posse do modelo, o objetivo do algoritmo é minimizar o valor esperado para o erro quadrático de estimação associado ao vetor de estados $x(k)$. Isso é equivalente a minimizar o traço da matriz de covariância dos erros de estimação [Welch & Bishop, 2006], [Rios Neto & Hemerly, 2007].

O algoritmo de estimação do KF é, basicamente, constituído de duas etapas: *predição ou propagação* e *atualização ou correção*. Na etapa de predição os estados são calculados a partir do modelo discreto, utilizando-se a estimação obtida na iteração anterior $\hat{x}(k-1|k-1)$ para estimar os estados da iteração atual $\hat{x}(k|k-1)$, ou seja, o modelo é propagado para se encontrar uma estimativa do estado atual, tal que

$$\hat{x}(k|k-1) = A\hat{x}(k-1|k-1) + Bu(k-1|k-1), \quad (2.3)$$

$$\hat{y}(k) = C\hat{x}(k|k-1). \quad (2.4)$$

Essa estimação obtida na predição – $\hat{x}(k|k-1)$ e $\hat{y}(k)$ – é chamada de estimativa *a priori*. Em seguida, calculam-se as matrizes de covariância da estimação e o ganho de Kalman:

$$P(k|k-1) = AP(k-1|k-1)A^T + Q(k), \quad (2.5)$$

$$P_{yy}(k|k-1) = CP(k|k-1)C^T + R(k-1), \quad (2.6)$$

$$P_{xy}(k|k-1) = P(k|k-1)C^T, \quad (2.7)$$

$$K(k) = P_{xy}(k|k-1)P_{yy}^{-1}(k|k-1). \quad (2.8)$$

Os cálculos realizados até este ponto são feitos com base nas informações obtidas no instante anterior e no modelo do sistema. Esses cálculos serão utilizados

para corrigir a estimativa do estado com base na medição $y(k)$ do instante atual. A etapa de correção leva em consideração a diferença entre o vetor de medições $y(k)$ e a estimativa *a priori* das saídas $\hat{y}(k)$, conhecida com inovação para obter uma nova estimativa, a estimativa *a posteriori* dos estados, dada por:

$$\hat{x}(k|k) = \hat{x}(k|k-1) + K(k)[y(k) - \hat{y}(k)]. \quad (2.9)$$

A partir do ganho de Kalman e das matrizes de covariância *a priori*, é possível calcular a matriz de covariância da estimativa *a posteriori* para se avaliar a incerteza associada à estimação resultante:

$$P(k|k) = P(k|k-1) - K(k)P_{yy}(k|k-1)K^T(k). \quad (2.10)$$

A Figura 2.2 ilustra as etapas do algoritmo do filtro de Kalman. O filtro de Kalman é um algoritmo capaz de incorporar à sua estimativa toda a informação que possa ser fornecida a ele, desde que obedecidas suas restrições de linearidade do modelo, ruído Gaussiano e de média nula, fornecendo ainda a incerteza da estimação obtida ao final de cada iteração [Maybeck, 1979]. Porém, o sistema estudado neste trabalho apresenta uma relação não-linear entre as entradas e os estados. Nesse caso, outras versões do Filtro de Kalman são utilizadas, como por exemplo, o EKF (*Extended Kalman Filter*), apresentado a seguir.

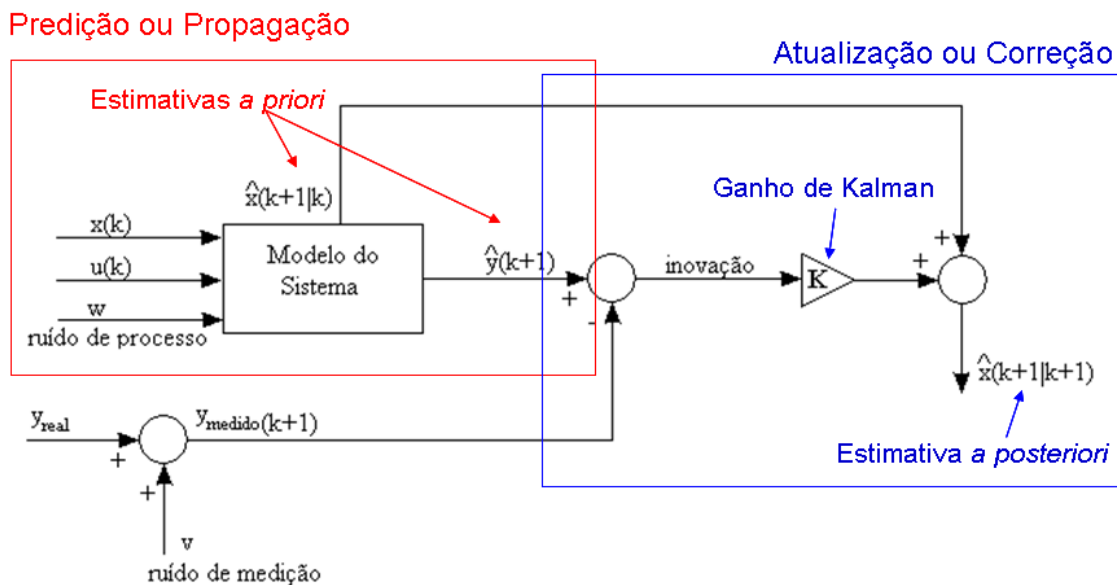


Figura 2.2: Etapas do algoritmo do filtro de Kalman.

2.2.2 Filtro de Kalman Estendido

O Filtro de Kalman Estendido (EKF) é uma adaptação do KF para sistemas não-lineares. Nesse algoritmo, o sistema é linearizado em torno da última estimativa a cada iteração. Essa linearização é realizada utilizando derivadas parciais das equações do processo [Jazwinski, 1970], [Aguirre, 2007].

No cálculo dos estados utilizando o EKF, assume-se que a equação que descreve a dinâmica do sistema é uma equação de diferenças não-linear com função de saída também não-linear:

$$x(k) = f(x(k-1), u(k-1)) + w(k-1), \quad (2.11)$$

$$y(k) = h(x(k)) + \nu(k). \quad (2.12)$$

No algoritmo do EKF, calcula-se a estimativa *a priori* dos estados a partir do modelo não-linear do sistema. Em seguida, calcula-se as matrizes Jacobianas do modelo ($F(k)$) e das medidas ($H(k)$). A partir dessas matrizes, a covariância dos erros associada à estimação a priori ($P(k|k-1)$) é aproximada, conforme a seguinte equação:

$$P(k|k-1) = F(k-1)P(k-1|k-1)F^T(k-1) + Q(k-1). \quad (2.13)$$

O ganho de Kalman é obtido como:

$$K(k) = (P(k|k-1)H^T(k))(H(k)P(k|k-1)H(k)^T + R(k-1))^{-1}. \quad (2.14)$$

A estimativa a posteriori é dada por:

$$\hat{x}(k|k) = \hat{x}(k|k-1) + K(k)[y(k) - H\hat{x}(k|k-1)]. \quad (2.15)$$

Pode-se dizer que os passos para implementação do algoritmo do Filtro de Kalman Estendido são os mesmo do Filtro de Kalman, desde que substituídas as matrizes do modelo por suas matrizes Jacobianas avaliadas a cada iteração no ponto de operação correspondente ao instante atual no cálculo das matrizes de covariância. Para a utilização desses algoritmos de fusão sensorial é necessário conhecer o modelo do sistema em questão. Os modelos utilizados para a implementação dos algoritmos de fusão neste trabalho estão descritos na Seção 3.1.

2.3 Trabalhos Relacionados

A localização é necessária em grande parte dos métodos de planejamento de movimento e controle encontrados na literatura. A localização pode ser vista como uma transformação entre sistemas de coordenadas. Assumindo-se que os sensores instalados no robô são capazes de fornecer sua posição local, ou seja, em relação a um sistema de coordenadas afixado na origem do movimento, é necessário, então, definir sua posição em relação a um sistema de coordenadas global.

Na localização global são utilizados sensores absolutos, tais como: sistemas de visão computacional, GPS ou informações de mapas. Porém, sensores absolutos são, em geral, muito lentos ou não têm taxa de amostragem bem definida (como sensores que utilizam marcos no ambiente para se localizar), fazendo com que a taxa de atualização da estimação seja baixa, o que não é suficiente para o controle. Nesse caso, utilizam-se sensores relativos como complemento para suprir o controle com informações nesse intervalo [Bonnifait et al., 2003]. Em ambientes externos, uma combinação bastante utilizada é a integração entre GPS e unidades de medidas inerciais (IMU). Os trabalhos desenvolvidos por Caron e outros (2006) e Zhou e outros (2007) são exemplos de sistemas com essa configuração de sensores.

Outra forma de se ampliar a precisão na localização é a utilização de técnicas de visão computacional para encontrar e identificar marcos visuais no ambiente. Com a utilização de uma câmera presa ao veículo, é possível saber, por exemplo, a posição relativa entre o veículo e um marco visual e, então, conhecendo a localização do marco, determinar a localização do veículo. Essa técnica é utilizada, por exemplo, em [Moreira et al., 2007].

O trabalho de Roumeliotis e Bekey (1997) descreve uma implementação que combina a informação de sensores relativos, como potenciômetros que medem o ângulo das rodas, girômetros e encoders com a informação de um sensor global que provê a orientação do veículo baseada na posição do Sol. A fusão sensorial foi realizada por meio do algoritmo do EKF de uma forma sequencial, suprindo o sistema de localização com informações baseadas nos encoders quando o robô não tinha visada para o Sol.

Diversos trabalhos na literatura discorrem sobre estimativa recursiva de esta-

dos em robótica móvel utilizando métodos estatísticos e a maioria deles utiliza como algoritmo de estimação de estados o filtro de Kalman e suas variações. O uso do KF como método de fusão sensorial é bastante difundido, principalmente em trabalhos em que se deseja combinar informações de sensores absolutos com informações de sensores relativos, como em [Caron et al., 2006], cujo objetivo é o desenvolvimento de um algoritmo de integração de sensores levando em consideração o contexto. Para tal, o trabalho utiliza KF e lógica *fuzzy*, agregando informação à estimação e avaliando a validade dos valores medidos.

Com o objetivo de reduzir e eliminar o erro de posição produzido pelas incertezas nas restrições existentes entre as rodas do robô e o solo, em Lin e outros (2004) utiliza-se o filtro de Kalman para fusão sensorial dos dados provenientes de sensores ultrassônicos, giroscópio e encoders. Os encoders foram posicionados nas rodas e medem a posição dos motores de passo para calcular a orientação do robô. Essa informação é fundida com a informação do giroscópio para se obter uma estimativa do ângulo de orientação. Segundo os autores, o erro máximo de posição encontrado com o estimador implementado foi de 50mm e o erro máximo de orientação foi de 2,5°.

O trabalho descrito em [Ivanjko et al., 2005] apresenta a implementação dos dois estimadores mais comumente utilizados em fusão sensorial para sistemas não-lineares, o EKF e o UKF e a comparação de desempenho entre eles e com o posicionamento baseado em odometria. A partir dos resultados apresentados nesse trabalho, é possível notar que a fusão sensorial melhora significativamente o desempenho da localização em relação aos sensores separadamente. A porcentagem de erro observada nesse trabalho para o algoritmo EKF é, em média, ligeiramente menor que no UKF, porém, pode-se notar pelos gráficos, que o UKF apresenta uma filtragem mais suave, ou seja, o erro cometido na estimativa em cada iteração é menor que o observado para o EKF.

Uma versão modificada do EKF, o *Interlaced Extended Kalman Filter* é apresentada no trabalho de Panzieri e outros (2005). O princípio básico desse estimador é a divisão do sistema em partes que são processadas paralelamente, a fim de reduzir o custo computacional do processo de estimação. A estimação de parâmetros utilizando o *Interlaced EKF* reduz o custo computacional, porém não garante uma

estimação ótima. Assim, ela é adequada para o uso em sistemas de tempo real, onde o baixo custo computacional é um requisito do sistema.

O SPKF (*sigma-point Kalman filter*), ou UKF é comparado ao EKF em um trabalho que visa integrar GPS e INS utilizando sensores de baixo custo. Na comparação, os autores concluem que o SPKF é um algoritmo de fácil implementação e de mais rápida convergência que o EKF [Li et al., 2006]. O UKF, que é um filtro de Kalman para sistemas não-lineares também baseado no cálculo de pontos sigma, é utilizado em comparação com o EKF no trabalho de Zhang e outros (2005). Os resultados obtidos mostram que a incerteza na estimação obtida com o UKF é menor que a com o EKF para a configuração de sensores utilizada. Foram utilizados um GPS, uma IMU e uma bússola digital para a localização de um veículo terrestre.

As pesquisas sobre veículos autônomos terrestres, que incluem fusão sensorial para localização, receberam um grande incentivo com a iniciativa da DARPA (*Defense Advanced Research Projects Agency*) de promover desafios nessa área. A DARPA é uma agência de defesa americana responsável pelo desenvolvimento de novas tecnologias para uso militar. Os desafios da DARPA trouxeram avanços e ampliaram a divulgação das pesquisas. O primeiro desafio foi promovido em 2004, o *DARPA Grand Challenge*, uma corrida na qual os veículos deveriam percorrer uma rota especificada em um deserto do estado da Califórnia, nos Estados Unidos. Nesse primeiro desafio, nenhum dos veículos conseguiu completar a prova [DARPA, 2004]. Muitas equipes que participaram do desafio de 2004 concorreram também na segunda versão do *DARPA Grand Challenge* em 2005 e dentre elas, algumas se classificaram para a etapa final do desafio, como a Axion Racing, a Insight Racing, o Red Team, o Sci Autonics II, o Team Caltech, o Team ENSCO, a Terra Max e o The Golem Group.

A equipe *Axion Racing* em 2004 utilizou como sensores para a localização um GPS - o *Coremicro UNCUN1*, da *America GNC* - integrado a um sistema INS/IMU. O sistema *Coremicro AHRS/INS/GPS Integration Unit* produz informação de localização baseada em um receptor GPS de 12 canais (isso significa que o receptor pode se comunicar com até 12 satélites ao mesmo tempo). No momento em que o sinal GPS não está disponível, o sistema integra no tempo a informação de velocidade e aceleração obtidas por meio das medidas da INS/IMU e soma à última posição

medida pelo GPS para encontrar sua posição atual. Para isso, o sistema utiliza um algoritmo proprietário do sistema da *Coremicro* [Kehaly et al., 2004]. No desafio de 2005 a equipe decidiu utilizar outro modelo de sensor inercial, o *Northrop Grumman LN270 Inertial Navigation System*. Esse sistema aceita entradas de um receptor GPS e calcula a posição baseado nos sensores inerciais quando o GPS tem o sinal obstruído ou de má qualidade. Como receptores GPS a equipe utilizou dois equipamentos modelo *NavCom SF2050*, que são compatíveis com o sistema INS. Nesse veículo, os sistemas de localização e detecção de obstáculos funcionam de forma independente, ou seja, o sistema de desvio de obstáculos não utiliza informações de localização para identificar barreiras [Kehaly et al., 2005].

A equipe *Insight Racing*, no desafio de 2004, também optou por utilizar GPS e INS como principal sistema de localização. Com esses sensores é possível obter posição, direção e velocidade do veículo. Ambos os sensores estão em um mesmo equipamento, o *POS LV*, da *Applanix Corporation*, que possui como principal fonte de informação os sensores INS. Essa informação é atualizada sempre que a informação de GPS está disponível. Se o sistema deixar de receber informações de GPS, apenas o INS é utilizado na localização. A equipe afirma que se a informação do GPS não estiver disponível por dois minutos, ainda assim a precisão da localização é de 0,60 metros. O veículo conta também com um encoder óptico que determina a posição do volante. Essa informação pode ser utilizada em conjunto com o sistema *POS LV* para melhorar a localização em caso de perda do GPS [Randall, 2004]. No ano de 2005 a equipe *Insight Racing* também alterou seu sistema de localização. Nesse ano, o veículo foi equipado com dois receptores GPS com características complementares. Ambos são capazes de utilizar o sistema WAAS e, no modo diferencial, podem chegar a uma precisão de aproximadamente 0,1 metros. O sistema WAAS (*Wide Area Augmentation System*) é composto por 25 estações terrestres, localizadas nos Estados Unidos, que enviam informações ao receptor do GPS com correções para diminuir os erros de sua medida. Os modelos utilizados são o *Novatel Propak LB plusGPS* e o *Garmin GPS 16A*. O sistema de navegação inercial utilizado é o modelo *Crossbow AHR5 400*. O algoritmo de localização realiza a estimação dos estados baseado nas medidas de aceleração fornecidas pelo INS (*dead reckoning*), que são atualizadas pelo GPS sempre que essa informação é disponibi-

lizada [Randall et al., 2005].

O veículo desenvolvido pelo *Red Team* em 2004 era equipado com Sistema de Posição e Orientação baseado em GPS/INS chamado *POS*, da *Applanix Corporation*. Esse sistema é parecido com o utilizado pela equipe *Insight Racing*, porém conta também com um indicador de distância percorrida (DMI - *Distance Measurement Indicator*). Ele integra as medidas inerciais e do DMI para obter a estimativa de posição e orientação entre uma medida de GPS e outra, utilizando o algoritmo do filtro de Kalman [Whittaker, 2004]. Em 2005 a equipe acrescentou o cálculo da odometria ao sistema utilizando o filtro de Kalman e um receptor GPS diferencial (modelo *Trimble AG132* com correção Omnistar VBS, além de substituírem o sistema *POS* pelo sistema *POS LV*, o mesmo utilizado em 2004 pela equipe *Insight Racing* que, segundo a equipe, fornece estimativa de posição e orientação com precisão de meio metro [Whittaker, 2005].

A equipe *Sci Autonics II* utilizou em 2004 um receptor GPS diferencial, modelo *Navcom Starfire SF-2050G*, uma IMU, modelo *Rockwell Collins GMC-10*, e um odômetro incremental que fornece a distância percorrida por meio de um sensor de Efeito Hall, assumindo-se que não haja derrapagem no movimento. Em longas distâncias, o sistema GPS/IMU é utilizado. Um acelerômetro destinado a medir a rugosidade do terreno foi instalado para reduzir os erros de integração da aceleração. O ângulo do volante é medido na coluna de atuação do mesmo. Na ausência de sinal GPS, é utilizado também um magnetômetro 3D além da odometria e a fusão entre todos esses instrumentos também é realizada por meio do algoritmo do Filtro de Kalman [Gunthner, 2004]. Em 2005 a equipe não modificou os sensores utilizados, refinando apenas o algoritmo de fusão, que agora recebe uma configuração diferente para a matriz de covariância no filtro de Kalman dependendo da informação que está disponível naquele momento. Caso o GPS não esteja disponível no modo diferencial ou no modo normal, a localização é realizada com a integração dos outros sensores [Porter et al., 2005].

O *Team Caltech* também utiliza em seu veículo um receptor de GPS diferencial. Em casos de perda do sinal do GPS o veículo conta com informações de uma IMU e um magnetômetro para se localizar. A fim de tentar eliminar o *bias* ou polarização encontrada nas medidas da IMU, esse valor é atualizado toda vez

que o veículo se encontra com velocidade zero, atualizando também a informação de posição fornecida pelo GPS quando disponível [van Gogh et al., 2004]. O veículo utilizado no desafio de 2005 contou com os mesmos instrumentos de 2004, um GPS diferencial e uma IMU, que foram combinados por meio do algoritmo do filtro de Kalman para a obtenção da estimação dos estados. Essa estimação era enviada por uma rede a todos os outros módulos presentes no veículo, como o módulo de planejamento, por exemplo. O veículo recebeu também a funcionalidade de armazenamento de informações relativas aos terrenos já visitados para utilização posterior [Cremean et al., 2006].

O *Team ENSCO* utilizou, no primeiro desafio, uma combinação da posição absoluta fornecida por um GPS dotado de correções Omnistar, WASS e função diferencial dentro de uma área de cobertura determinada, com um INS em que o algoritmo de fusão utilizado também é o filtro de Kalman. Para aumentar a precisão da posição e orientação do veículo, o conjunto GPS+INS foi combinado com um radar 3D e um magnetômetro, obtendo precisão sub-métrica. Os testes realizados mostraram que quando a informação do GPS fica indisponível por 30 segundos, o sistema é capaz de manter a estimação de posição 2D com precisão inferior a 1 metro [Carr, 2004]. O veículo que participou do desafio de 2005 também utilizou a combinação GPS e INS, porém a combinação é realizada por um sistema *Novatel SPAN (Synchronized Position Attitude Navigation)*, que fornece a posição com grande precisão (10 cm) a uma taxa de 20 Hz. A equipe notou que a falta do sinal de GPS por um longo período causava um grande acúmulo de erros no cálculo da orientação. Para solucionar esse problema, foram instalados dois receptores GPS no veículo. Com o veículo parado, era calculado o vetor entre um receptor e outro, bem como a distância entre eles. Caso a diferença entre a distância calculada e a real, que era conhecida, estivesse dentro do limite testado pela equipe, então o ângulo do vetor obtido poderia ser considerado como correto, com alguns graus de erro. Além disso, o segundo receptor GPS funcionaria como uma medida redundante que poderia fornecer a posição em caso de indisponibilidade de sinal no primeiro receptor [Carr & Mee, 2005].

A equipe *TerraMax* utilizou no veículo que participou do desafio de 2004 duas antenas receptoras de GPS do modelo *Novatel Propack -LB Dual freq*, que possui

correções Omnistar HP e função diferencial. Esse modelo foi bastante utilizado nos veículos desse desafio. Para a obtenção dos ângulos de orientação nos três eixos foi utilizada uma bússola 3D. As acelerações e velocidades angulares foram medidas utilizando uma IMU. A velocidade das rodas foi obtida pelo barramento de controle do veículo. Nos instantes em que as medidas do GPS estão disponíveis, a localização é realizada a partir dessas medidas. Nos intervalos entre uma medida de GPS e outra, é feito o *dead reckoning* das medidas da IMU. Essa informação é combinada com as medições da bússola para obter a localização [Fravert, 2004]. Em 2005, a equipe optou por utilizar duas unidades de um sensor que faz a combinação *onboard* de GPS e IMU (modelo *RT3100s*, da *Oxford Technical Solutions*). Esse sensor fornece a posição do veículo em tempo real a uma taxa de 100 Hz mesmo que não haja informação do GPS. Um dos sensores foi configurado para utilizar o GPS no modo diferencial e o outro para utilizar as correções WAAS. No caso de perda do sinal GPS, o sensor mantém a localização utilizando apenas a IMU. Para auxiliar a IMU, a velocidade das rodas é fornecida como entrada para o *RT3100*. Em caso de perda de todo o sistema *RT3100*, outro sistema baseado em odometria entra em operação a partir da medida das velocidades e ângulo das rodas [Braid et al., 2006].

A equipe *The Golem Group* participou do desafio de 2004 com um veículo equipado com um INS e um magnetômetro de três eixos, ambos da *Rotomotion*, um potenciômetro que media a posição da coluna de direção do veículo e um sensor de Efeito Hall (encoder) para medir a rotação do eixo traseiro, além de dois receptores GPS, o primeiro, modelo *Trimble AgGPS 114*, foi montado no teto do veículo e o segundo, modelo *Garmin GPS V*, é utilizado como *backup* do sistema. Ambos têm a capacidade de realizar correções diferenciais. As informações dos GPS diferenciais são combinadas com a IMU e o encoder com a utilização de um algoritmo de estimação chamado *Interacting Multiple Model* (IMM), que utiliza diferentes modelos selecionados para cada situação. Nos momentos de perda do sinal GPS, o *dead reckoning* é realizado com as informações da IMU e da odometria [Mason, 2004]. Em 2005, a equipe modificou tanto o hardware quanto o algoritmo de fusão utilizado. O GPS foi substituído por um *NovAtel Propak-LBPlus* com correção Omnistar HP e o INS foi substituído por um *C-MIGITS III*. O ângulo e a velocidade das rodas também foram utilizados. O algoritmo utilizado na fusão foi o filtro de Kalman. A

equipe afirma que em condições típicas a estimação apresenta erros de localização inferiores a 30 cm [Mason et al., 2006].

A equipe vencedora do desafio de 2005 foi a *Stanford Racing Team*, com seu veículo *Stanley*, que não havia participado do desafio de 2004. A localização teve como principal fonte de informação um receptor GPS, e uma IMU, como nas outras equipes, porém o algoritmo de estimação de estados utilizado na fusão sensorial foi o *unscented Kalman filter* (UKF) [Thrun et al., 2005] [Julier & Uhlmann, 2004]. O UKF é utilizado para integrar de forma assíncrona os dados do GPS, dados da IMU e informações provenientes do barramento CAN do veículo a uma taxa máxima de 100 Hz. O modelo utilizado no algoritmo para a predição dos estados é o modelo de *Ackerman* [Thrun et al., 2006].

No ano de 2007, a DARPA promoveu um terceiro desafio de veículos autônomos terrestres, mas dessa vez em área urbana. O *DARPA Urban Challenge* reuniu 89 equipes em um circuito onde as regras para o trânsito em vias urbanas deveriam ser respeitadas [Buehler et al., 2008]. A equipe vencedora desse desafio foi a *Tartan Racing*, da Universidade Carnegie Mellon, com seu carro *Boss*. Essa equipe utilizou a solução comercial POSLV, da Applannix como principal fonte de informação para a localização. Esse sistema fornece informação de posição a uma taxa de 100Hz baseado em um GPS diferencial, sensores inerciais e encoders nas rodas. Além do sistema de localização, a equipe utilizou vários mecanismos de detecção de obstáculos e detecção de bordas da pista. Outras informações quanto à geometria e o relevo da pista são utilizadas para filtrar e melhorar o sistema de localização [Urmson et al., 2008].

A equipe da Universidade de Stanford, vencedora do desafio de 2005, ficou em segundo lugar no desafio de 2007, com seu carro *Júnior*. Esse veículo realiza a estimação da localização em relação a um mapa fornecido previamente com o uso do sistema de localização da Applannix (o mesmo utilizado na maioria dos veículos participantes dos desafios DARPA). O veículo verifica o alinhamento entre o sensor de localização e o mapa, ou seja, ele se localiza em relação a esse mapa para definir seus movimentos [Montemerlo et al., 2008].

A maior parte dos veículos do desafio DARPA utilizou o GPS como medida padrão confiável sempre que essa informação estava disponível. Isso acontece por-

que o sistema GPS no hemisfério norte apresenta erros inferiores aos verificados no hemisfério sul, devido ao uso do sistema WAAS. Além disso, a grande maioria dos veículos utilizou GPS diferencial, que apresenta erros bem inferiores a 1 metro, sendo necessário utilizar outra fonte de dados para a localização apenas quando essa informação não está disponível.

2.4 Considerações Finais

Para a realização do trabalho de localização desenvolvido, a escolha da configuração de sensores e algoritmos foi baseada em informações obtidas a partir da leitura de referências como as citadas neste capítulo, além da verificação experimental do comportamento dos sensores. Os sensores e algoritmos experimentados neste trabalho formam um conjunto capaz de fornecer posição e orientação do veículo a uma taxa de amostragem constante e superior, com precisão e robustez maiores que aquelas verificadas na utilização apenas de um receptor GPS comum. Optou-se pelo uso de sensores de baixo custo, fácil instalação e pequena intervenção física no ambiente do veículo.

As variáveis medidas neste trabalho e que serão utilizadas na estimação da localização e reconstrução da trajetória do automóvel são a aceleração no eixo x_v , a velocidade angular em torno do eixo z_v , a posição nos eixos x_v e y_v , a velocidade linear do veículo, o ângulo de giro do volante e a velocidade das rodas. Os sensores utilizados para medir essas variáveis estão detalhados no Capítulo 3.

Capítulo 3

Metodologia

Para realizar a reconstrução da trajetória do veículo utilizado neste trabalho, foi adotado o algoritmo do filtro de Kalman estendido (Seção 2.2.2) como método de fusão sensorial. Os algoritmos baseados no filtro de Kalman necessitam da definição de um modelo matemático para realizar a propagação dos estados a serem estimados. Para a reconstrução da trajetória do veículo, foram estimados, principalmente, os seguintes estados: posição do veículo em duas dimensões, velocidade e orientação em relação a um sistema de coordenadas preso na superfície terrestre. Neste capítulo, são apresentados os modelos matemáticos utilizados para a fusão sensorial, bem como os sensores adotados como fonte de informação para a localização.

3.1 Modelagem Matemática do Problema

A modelagem matemática de um sistema é a representação da evolução temporal de determinadas características desse sistema por meio de equações matemáticas. É importante observar que um modelo matemático é uma aproximação. Assim, não existe apenas um modelo para um sistema, mas sim uma família de modelos com características e desempenho diferentes. É possível modelar um sistema por suas características físicas; processo conhecido como modelagem caixa branca; ou por meio de experimentos, sem o conhecimento das relações físicas envolvidas, o que é conhecido por modelagem caixa preta ou modelagem empírica [Aguirre, 2007].

A escolha do modelo a ser utilizado para representar o sistema não é trivial. As diferenças de desempenho causadas pela escolha do modelo de movimento de um robô móvel podem superar as diferenças causadas pelo algoritmo de estimação

de estados [Dahlkamp et al., 2004]. Neste trabalho são testados dois modelos cinemáticos do veículo, ou seja, sua dinâmica associada à aceleração adquirida pelo veículo devido a uma força aplicada e ponderada por sua massa não é levada em consideração. Esses modelos foram elaborados com base no sistema de coordenadas descrito na Figura 3.1. Esse sistema de coordenadas obedece ao modelo de eixos de rolamento, arfagem e guinada, RPY (*roll-pitch-yaw*), onde o eixo x é fixado no sentido de movimento do veículo, o eixo y aponta para sua direita e o eixo z , pela regra da mão direita, aponta para baixo. O sistema RPY é utilizado para definir o sistema de coordenadas de referência local tanto em veículos terrestres, como aéreos e aquáticos. A rotação em torno dos eixos RPY fornece os ângulos de Euler (ϕ , θ e ψ , respectivamente).




Figura 3.1: Sistema de coordenadas preso ao veículo.

O sistema de coordenadas utilizado para representar o referencial do mundo é um sistema de coordenadas fixo à Terra do tipo Plano Tangente Local - LTP (*Local Tangent Plane*), em que a Terra é representada por um plano tangente à sua superfície. As direções de cada eixo foram definidas de acordo com o subsistema Leste-Norte-Para Cima - ENU (*East-North-Up*), conforme Figura 3.2. Neste trabalho o movimento do veículo será avaliado em duas dimensões, ou seja, não será

avaliado o movimento no eixo z do veículo. Assim, para representar o referencial do mundo, foi selecionada a projeção Universal Transversa de Mercator UTM (*Universal Transverse Mercator*), em que a origem do sistema de coordenadas está na interseção do Meridiano Central (de Greenwich) com a Linha do Equador, o eixo y aponta para o Norte e o eixo x aponta para o Leste.




Figura 3.2: Sistema de coordenadas na Terra.

Os modelos apresentados neste trabalho são modelos discretos e estão descritos de acordo com as equações de diferenças (2.1) e (2.2).

O primeiro modelo testado utiliza equações cinemáticas para representar o movimento do veículo como se ele fosse um corpo rígido em que toda a massa se encontra em seu centro de massa, também conhecido como modelo do unicycle (*unicycle model*) [Jiang & Nijmeijer, 1997]. Os estados estimados são a posição (P_x e P_y), a velocidade linear (V) e a orientação do veículo (ψ) em relação ao eixo z . A aceleração no eixo x (A_x) e a velocidade angular ω são utilizadas como entrada do modelo. Assim, as matrizes de estados para esse modelo, considerando o movimento em duas dimensões (apenas nos eixos x e y), podem ser descritas como:

$$x(k) = \begin{bmatrix} p_x(k) \\ p_y(k) \\ v(k) \\ \psi(k) \end{bmatrix} = \begin{bmatrix} p_x(k-1) + v(k-1)\cos(\psi(k-1)) \Delta t \\ p_y(k-1) + v(k-1)\text{sen}(\psi(k-1)) \Delta t \\ v(k-1) + a_x(k-1) \Delta t \\ \psi(k-1) + \omega(k-1) \Delta t \end{bmatrix}, \quad (3.1)$$

$$u(k) = \begin{bmatrix} a_x(k) \\ \omega(k) \\ 0 \\ 0 \end{bmatrix}. \quad (3.2)$$

O segundo modelo utilizado neste trabalho é o modelo de Ackerman para um automóvel [Choset et al., 2005]. Nesse modelo, o veículo é representado por um volume retangular sobre quatro rodas, onde as rodas traseiras são fixas e as rodas dianteiras são atuadas por meio do volante (Figura 3.3).




Figura 3.3: Modelo de Ackerman.

No modelo de Ackerman, o ângulo da roda (α) é representado por uma roda “virtual” localizada entre as duas rodas dianteiras e o ângulo dessa roda virtual é dado pela média dos ângulos das duas rodas (que são diferentes entre si). A velocidade dessa roda virtual (v_r) também é dada pela média das velocidades das duas rodas. A distância entre os eixos (L) deve ser considerada na estimação da orientação do veículo¹.

Os estados estimados são os mesmos do primeiro modelo, porém, as equações do modelo e as entradas são diferentes:

¹No veículo utilizado nos experimentos, a distância entre eixos é de 2,61 m.

$$x(k) = \begin{bmatrix} p_x(k) \\ p_y(k) \\ v(k) \\ \psi(k) \end{bmatrix} = \begin{bmatrix} p_x(k-1) + v_r(k-1)\cos(\alpha(k-1))\cos(\psi(k-1)) \Delta t \\ p_y(k-1) + v_r(k-1)\cos(\alpha(k-1))\sin(\psi(k-1)) \Delta t \\ v(k-1) + a_x(k-1) \Delta t \\ \psi(k-1) + \frac{v_r(k-1)}{L}\tan(\alpha) \Delta t \end{bmatrix}, \quad (3.3)$$

$$u(k) = \begin{bmatrix} \alpha(k) \\ a_x(k) \\ 0 \\ 0 \end{bmatrix}. \quad (3.4)$$

3.2 Descrição da Plataforma

Como plataforma robótica para a instalação dos sensores e realização dos experimentos foi utilizado um automóvel Chevrolet Astra 2003/2004 equipado com direção hidráulica, câmbio automático, acelerador eletrônico e freios ABS controlados por uma Unidade Central de Controle (*Electronic Control Unit* - ECU). O sistema *drive-by-wire* do veículo permite que alguns sinais de comando sejam enviados diretamente à unidade de controle. O veículo possui diversos sensores instalados, como por exemplo o sensor de velocidade das rodas incluído no sistema de freios ABS. A presença desses sensores torna possível sua utilização como informação complementar no sistema de fusão sensorial. Além desse sensor, foram instalados um receptor GPS, um Sistema de Medições Inerciais e um encoder para medir o ângulo do volante no veículo. A Figura 3.4 apresenta um diagrama da configuração física da plataforma, ilustrando como esses sensores foram instalados no veículo. Os sensores utilizados são descritos na Seção 3.2.1.

3.2.1 Sensores

Para promover a percepção do ambiente pelo veículo, é necessária a instalação de diversos sensores. Esses instrumentos possibilitam que se obtenham informações sobre todo o movimento realizado pelo veículo. Com base na revisão de literatura




Figura 3.4: Representação da configuração física dos instrumentos no veículo.

realizada no Capítulo 2, verificou-se a necessidade de se medir as seguintes variáveis do sistema: posição e orientação do veículo, aceleração e velocidade lineares, velocidade angular do veículo, ângulo de giro do volante, que pode ser convertido no ângulo das rodas do veículo. O sistema desenvolvido neste trabalho utiliza como sensor de posição absoluta um receptor GPS, e alguns sensores relativos, que estão melhor detalhados nas seções que se seguem.

GPS

O Sistema de Posicionamento Global (GPS) é um sistema de localização por satélites, conforme explicado na Seção 2.1.2. Para obter informações de posicionamento global utilizando os satélites desse sistema é necessário que uma antena receptora seja instalada no veículo. O receptor GPS é um equipamento que coleta informações provenientes de satélites cuja posição em relação à Terra é conhecida. A posição do observador na superfície da Terra pode ser obtida a partir da recepção do sinal de pelo menos três satélites. Para se obter uma maior precisão na informação de tempo, os receptores utilizam a informação de quatro satélites (ver Apêndice A).

A qualidade da informação produzida pelo receptor está diretamente relacionada com o número de satélites dos quais o receptor consegue coletar o sinal. O número de satélites dentro do campo de visão de um receptor pode variar de 0 a 12.

Assim, em locais onde a visada é dificultada por obstáculos, a medida da posição por um receptor GPS pode ser prejudicada ou até mesmo impossibilitada.

O equipamento utilizado neste trabalho é o modelo GPS 18 PC, da Garmin (Figura 3.5) [Garmin, 2005]. Esse instrumento fornece informações a uma taxa de amostragem de 1Hz, com uma incerteza de 15 metros para um intervalo de confiança de 95%, de acordo com informação fornecida pelo fabricante, mas que é variável, conforme detalhado no Apêndice A . O receptor disponibiliza as medidas por meio de uma saída serial sob o protocolo de comunicação RS-232. A essa saída serial é conectado um conversor USB/Serial que possibilita que o sensor seja conectado a uma porta USB no computador portátil.



Figura 3.5: Receptor Garmin modelo GPS18.

A informação é enviada ao computador em forma de mensagens do padrão NMEA (*National Marine Electronics Association* [Betke, 2001], [NMEA, 2009]). O protocolo NMEA é um padrão desenvolvido por uma associação de fabricantes, distribuidores, instituições de ensino e outros interessados em protocolos de comunicação entre instrumentos de navegação marítima.

A comunicação serial é realizada a uma taxa de 4800 bits/segundo, 8 bits de dados (1 caracter), sem paridade e sem controle de fluxo. As mensagens do protocolo têm um formato característico e a partir delas é possível extrair informações como latitude, longitude, hemisfério ou número de satélites.

Após a leitura das mensagens enviadas pelo receptor GPS a cada segundo pela porta serial, é realizada uma separação dos campos de interesse para a localização. A latitude e a longitude são informadas em graus, minutos e segundos, que devem ser convertidos para metros. Essa conversão é realizada com a utilização do método de projeção UTM (*Universal Transverse Mercator*) que é um sistema referencial de localização terrestre que divide a Terra em 60 zonas de 6 graus de longitude cada

uma (Figura 3.6). Esse sistema de projeção cilíndrica “retifica” o mapa da Terra de acordo com o modelo de elipsóide de referência utilizado pelo sistema GPS (o padrão para GPS é o modelo WGS84) [Hofmann-Wellenhof et al., 1997].

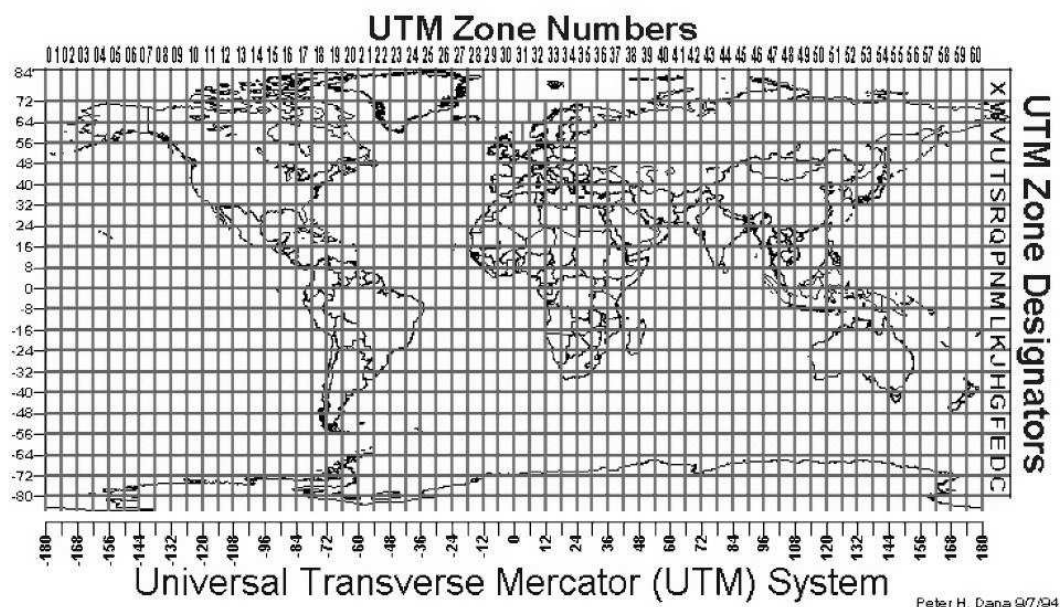


Figura 3.6: Zonas UTM [Dana, 1994]

Sistema de Medições Inerciais (SMI)

O Sistema de Medições Inerciais utilizado neste trabalho é um instrumento capaz de fornecer aceleração linear, velocidade angular e ângulos de orientação de um corpo em movimento ao qual ele esteja fixado. Esse tipo de instrumento é amplamente utilizado em navegação de robôs móveis, sejam aéreos, terrestres ou aquáticos. A partir dos dados desse sensor é possível realizar a navegação de um veículo por meio do método *dead reckoning* (ver Seção 2.1.1).

O instrumento utilizado neste trabalho é o modelo 3DM-GX1 da Microstrain (Figura 3.7). Esse modelo combina três girômetros ortogonais, três acelerômetros ortogonais, três magnetômetros ortogonais, um conversor A/D e um microprocessador embutido que fornece também a orientação. A inclusão dos magnetômetros agrega a esse instrumento a capacidade de fornecer a informação de orientação do veículo nos três eixos. O microprocessador embutido no instrumento contém um algoritmo proprietário que fornece as medidas em tempo real. Esse modelo apresenta também sensores de temperatura que são utilizados no algoritmo para fazer a

compensação dos erros causados por alterações de temperatura [MicroStrain, 2006].



Figura 3.7: Sensor Microstrain Modelo 3DM-GX1

Para avaliar o desempenho da medida do ângulo ψ fornecida pelo sensor inercial foi realizado um experimento que compara suas medidas às medida obtidas usando uma bússola profissional de uso militar (Figura 3.8). Antes de dar início ao experimento, foi realizado um procedimento de calibração recomendado pelo fabricante. Esse procedimento, chamado *Hard Iron Calibration*, tem o objetivo de calibrar o sistema de acordo com o campo magnético da Terra verificado na região onde ele será utilizado. O procedimento para a verificação da repetibilidade da informação do ângulo ψ fornecido pelo sistema inercial teve início com a instalação da bússola profissional externamente ao veículo, porém presa a ele de forma a seguir o mesmo ângulo de orientação do sistema inercial. Em seguida, o veículo foi estacionado em posições demarcadas e os valores obtidos do sistema inercial e da bússola para o ângulo de guinada do veículo foram anotados.

O experimento foi realizado em locais diferentes, próximo aos prédios e afastado dos prédios com o objetivo de avaliar a existência de interferência do meio externo no comportamento do magnetômetro presente no instrumento. A cada realização, o veículo foi posicionado em quatro orientações diferentes dentro de um mesmo espaço. O gráfico da Figura 3.9 apresenta os dados coletados em duas realizações sobre o mesmo local (afastado dos prédios). É possível observar que, nesse caso, os dados observados na primeira e na segunda realização são bastante próximos, ou seja, o comportamento do sensor de orientação dentro de um mesmo espaço

é aparentemente repetitivo. O gráfico da Figura 3.10 mostra os dados coletados em três realizações em locais diferentes. Pode-se observar nessa figura que os valores obtidos entre as realizações são bem diferentes, o que mostra que o comportamento do sensor de orientação se modifica conforme o local onde o veículo está trafegando. Isso ocorre devido a deformações no campo magnético medido pelo instrumento pela influência dos objetos e estruturas presentes no terreno. Devido a esse comportamento, optou-se por não se utilizar a informação do ângulo de guinada fornecido pelo instrumento, pois não há garantias de que ele produza uma informação confiável.



Figura 3.8: Bússola Profissional Utilizada no Experimento.

Sensor do Ângulo do Volante

O veículo utilizado como plataforma deste trabalho vem sendo preparado para a locomoção autônoma. Dessa forma, alguns atuadores foram instalados em seu interior. Um desses atuadores é o sistema de acionamento do volante. Para atuação do volante foi instalado um motor elétrico de corrente contínua modelo RE40, da MAXON Motores (Figura 3.11). Esse motor possui uma redução e um encoder incremental que fornece informação de posição do volante. Um controlador modelo EPOS 24/5 (Figura 3.12), também da MAXON, foi instalado para realizar o controle do motor. Esse controlador se comunica com o computador por meio de comunicação serial sob o protocolo RS-232 e possibilita o controle de posição, velocidade e corrente do motor e leitura do encoder a uma taxa de aproximadamente 33 Hz.

A medição do ângulo de giro do volante do veículo pela leitura do encoder instalado no sistema de atuação possibilita a estimação do ângulo das rodas do

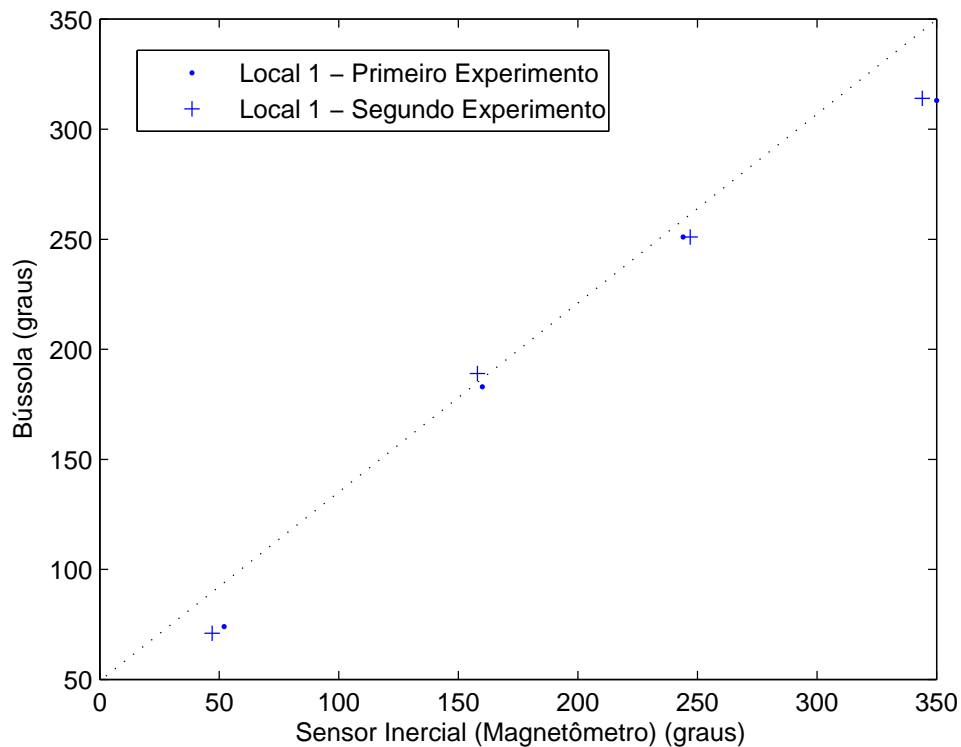


Figura 3.9: Medida do Sistema Inercial *versus* Medida da Bússola - Dados Coletados em um Mesmo Local. A reta tracejada possui inclinação de 45 graus, para efeito comparativo (idealmente, as medidas obtidas deveriam estar sobre a reta)

veículo ao longo do trajeto. Assim, um procedimento de calibração foi realizado para descobrir a relação entre a leitura do encoder e o ângulo das rodas. Foram medidos os ângulos das duas rodas por meio de um equipamento utilizado para alinhamento das rodas e registrada a leitura do encoder do volante para cada ângulo observado. No cálculo da curva de calibração a média dos ângulos foi utilizada, segundo modelo de Ackerman [Choset et al., 2005] detalhado na Seção 3.1. A Figura 3.13 apresenta os pontos correspondentes a cada roda, os pontos médios das rodas e a curva de calibração obtida a partir desse procedimento.

A equação obtida para as curvas de calibração do ângulo das rodas em função do ângulo do volante é:

$$a_{rodas} = -0,000005(a_{volante}) - 0,0016. \quad (3.5)$$

O maior desvio entre um valor medido e a reta ajustada no procedimento de calibração foi de 0,0153 radianos.




Figura 3.10: Medida do Sistema Inercial *versus* Medida da Bússola - Dados Coletados em Locais Distintos. A reta tracejada possui inclinação de 45 graus, para efeito comparativo (idealmente, as medidas obtidas deveriam estar sobre a reta)



Figura 3.11: Sistema de Atuação do Volante.



Figura 3.12: Controlador de Posição EPOS 24/5.




Figura 3.13: Curva de Calibração - Leitura do Encoder e $\hat{\text{Ângulo}}$ das Rodas.

Sensor de Velocidade das Rodas

A medida da velocidade das rodas permite o uso da odometria para o cálculo do deslocamento do veículo. Para adquirir essa medida, foi utilizado o sensor de velocidade presente no sistema de freios ABS (*Antilock Braking System*) do veículo.

No caso do automóvel Astra 2003, o sensor existente é um sensor magnético de relutância variável. Esse sensor é utilizado em conjunto com um disco dentado, chamado roda fônica. A passagem dos dentes do disco próximo ao sensor magnético provoca uma variação na intensidade do campo magnético sobre a bobina do sensor, o que provoca o surgimento de uma tensão induzida senoidal nos terminais da bobina. A frequência observada no sinal alternado é proporcional à frequência

de giro do disco, que está diretamente acoplado ao eixo da roda da qual se deseja medir a velocidade.

O circuito de processamento do sinal do sensor de velocidade é baseado em um conversor frequência/tensão que transforma o sinal em frequência do sensor em um sinal em tensão proporcional à frequência. Para tal, foi utilizado um conversor modelo LM2917 para cada roda, cujo circuito correspondente é apresentado na figura 3.14.

O sinal em tensão produzido pelo conversor frequência/tensão é lido por um conversor A/D de um microcontrolador Microchip PIC. Uma placa de comunicação via USB usada para estabelecer um enlace de dados entre o PIC e o computador foi desenvolvida no laboratório de Sistemas de Computação e Robótica (CORO) da UFMG pelo aluno de graduação Elias J. de R. Freitas [Santos et al., 2008], [Freitas et al., 2009]. Essa placa é modular e tem a finalidade de possibilitar a troca de sinais entre o computador e um circuito eletrônico acoplado a ela. Ela é constituída de um microcontrolador PIC18F2550, um barramento que disponibiliza as portas do PIC para aplicações quaisquer, o que possibilita o acoplamento de outras placas e um conector para comunicação USB.

Para se determinar a relação entre o sinal lido pelo computador e a velocidade angular das rodas, foi realizado um procedimento de calibração que consistiu em atuar o acelerador do veículo com a roda livre e realizar a leitura da velocidade angular por meio de um tacômetro óptico. O resultado desse procedimento é apresentado nas Figuras 3.15 e 3.16. Nos gráficos dessa figura, é possível observar que a relação entre a velocidade angular das rodas e o valor lido a partir do sensor de velocidade presente no sistema ABS do carro é aparentemente linear. Percebe-se, também, que há repetibilidade nessas medidas, uma vez que a massa de dados de validação obedece a curva de calibração. A obtenção da curva de calibração possibilitou estabelecer uma relação direta entre a leitura do circuito e a velocidade linear do veículo, considerando também o diâmetro das rodas.

As equações obtidas no procedimento de calibração para a roda direita e para a roda esquerda são, respectivamente:

$$v_{rpm_{dir}} = 0,9119(v_{sensor_{dir}}) - 2,6565, \quad (3.6)$$

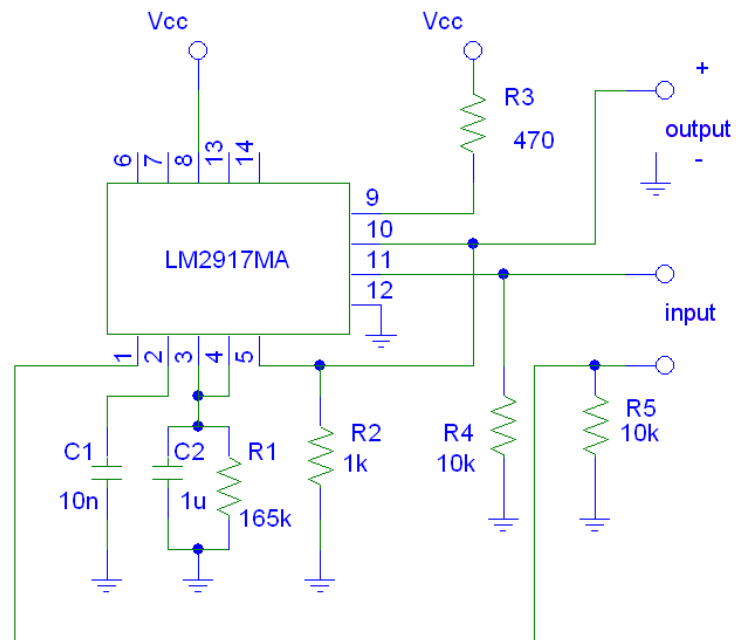


Figura 3.14: Diagrama elétrico do circuito de condicionamento de sinal dos sensores de velocidade das rodas

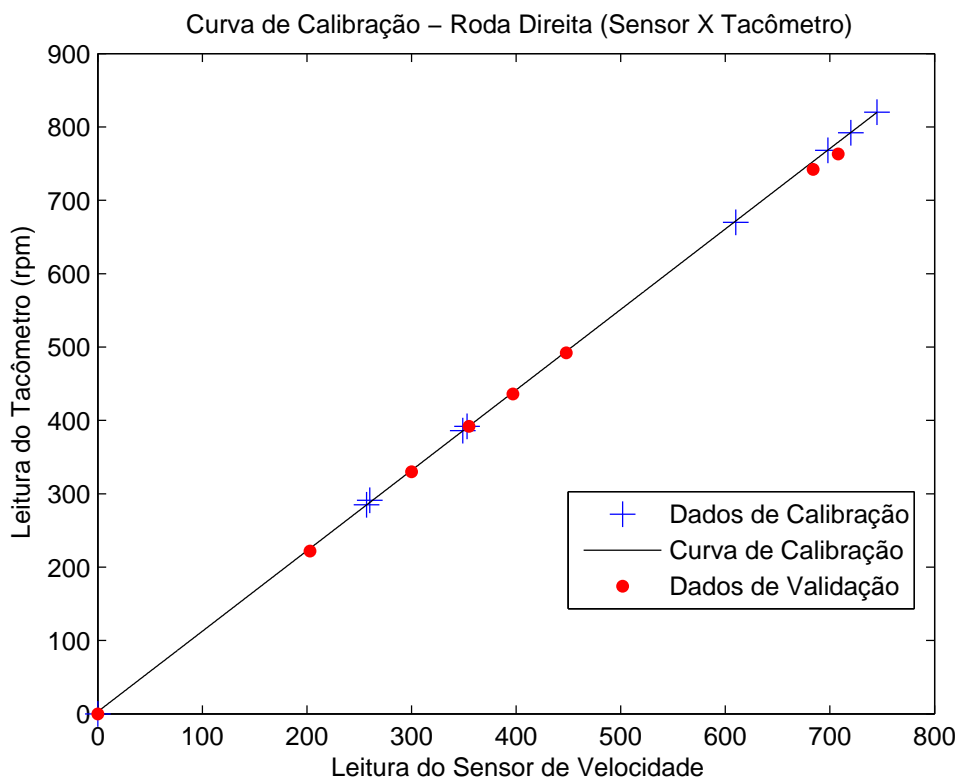


Figura 3.15: Curva de calibração do sensor de velocidade da roda direita

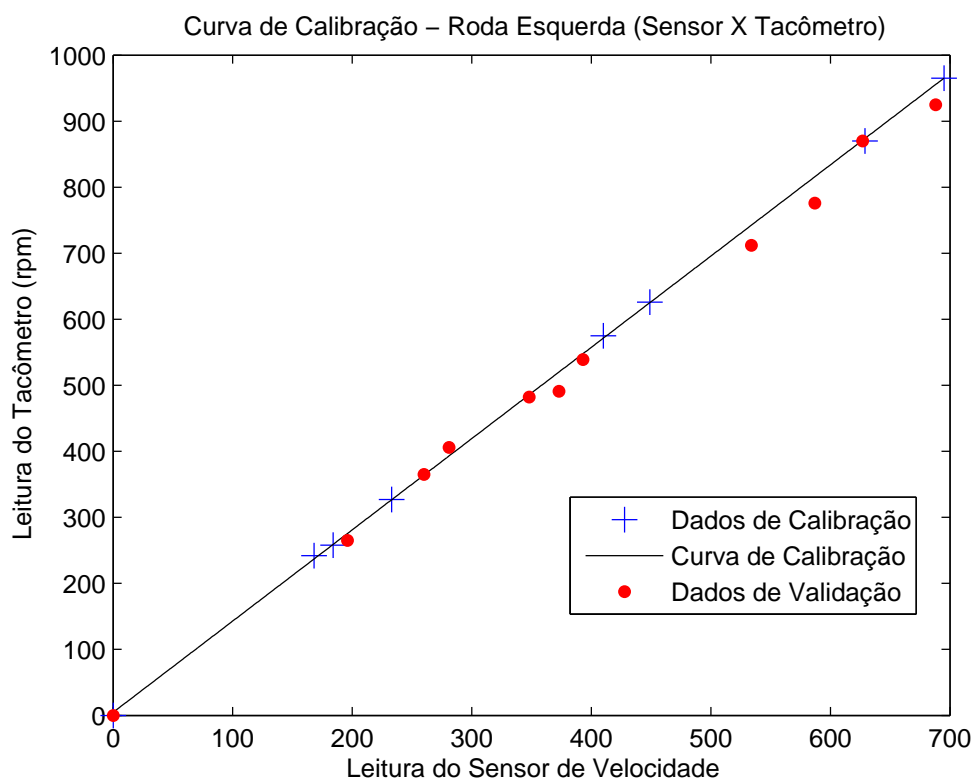


Figura 3.16: Curva de calibração do sensor de velocidade da roda esquerda

$$v_{rpm_{esq}} = 0,7236(v_{sensor_{esq}}) - 3,3891. \quad (3.7)$$

Para a roda direita, o maior desvio entre um valor medido e a reta ajustada foi de 2,103 rpm. Para a roda esquerda, esse valor foi de 3.143 rpm.

Na determinação da velocidade do veículo ao longo do movimento foi utilizada a velocidade média das duas rodas, convertida de rpm para m/s, conforme será apresentado no Capítulo 4.

Capítulo 4

Fusão Sensorial e Resultados Experimentais

Este capítulo visa descrever os experimentos realizados para a obtenção da reconstrução da trajetória do veículo. São apresentadas as configurações de sensores e modelos utilizados para a estimação dos estados de interesse. Os resultados da fusão sensorial utilizando essas configurações são base para a análise das características de cada uma delas. A análise de desempenho da estimação de estados foi é uma ferramenta de auxílio na tomada de decisão sobre qual configuração é adequada a determinadas condições de operação e qual delas é a melhor alternativa para a localização em tempo real, apresentada no Capítulo 5.

4.1 Configurações

Esta seção apresenta as combinações entre os modelos matemáticos apresentados na Seção 3.1 e os sensores apresentados na Seção 3.2.1. O desempenho de cada combinação foi avaliado por meio da análise da reconstrução de trajetórias a fim de estabelecer a configuração mais adequada ao problema de localização do automóvel utilizando as informações disponíveis.

4.1.1 Configuração 1

Na primeira configuração testada foi utilizado o modelo cinemático do veículo, conforme as Equações (3.1) e (3.2). Os sensores utilizados nesta configuração foram o receptor GPS e o Sistema de Medições Inerciais (SMI). A aceleração no eixo x e a

velocidade angular em torno do eixo z do veículo (os eixos foram fixados conforme Figura 3.1), medidas pelo SMI, foram utilizadas como sinais de entrada para o modelo. É importante salientar que a aceleração medida pelo SMI é dada no referencial do veículo. A posição nos eixos x e y , obtida pelo GPS, foi utilizada como medição, sendo agregada na etapa de correção do algoritmo de fusão sensorial.

Ao observar o sinal coletado pelo SMI, foi possível notar que esse instrumento sofre influência de *bias*, ou seja, há um erro sistemático contaminando a medição, o que o torna um instrumento tendencioso. No algoritmo do Filtro de Kalman pressupõe-se que o ruído presente nas informações utilizadas seja um ruído de média nula (vide Seção 2.2.1). Devido à polarização observada no SMI, foi necessário incluir na equação de propagação dois pseudo-estados que representam o *bias* do acelerômetro e o *bias* do girômetro, minimizando os efeitos da média diferente de zero presente no ruído. Assumiu-se que os valores dos *bias*es são variantes no tempo e para modelá-los utilizou-se um modelo de primeira ordem, conforme se observa nas matrizes de predição dos estados (Eq. 4.1).

O modelo de predição ou propagação de estados, o vetor de entradas e o vetor de medidas utilizados para a estimação da trajetória nesta configuração são, respectivamente:

$$x(k) = \begin{bmatrix} p_x(k) \\ p_y(k) \\ v(k) \\ \psi(k) \\ b_{a_x}(k) \\ b_{\omega}(k) \end{bmatrix} = \begin{bmatrix} p_x(k-1) + v(k-1)\cos(\psi(k-1)) \Delta t \\ p_y(k-1) + v(k-1)\text{sen}(\psi(k-1)) \Delta t \\ v(k-1) + (u_1(k-1) - b_{a_x}(k-1)) \Delta t \\ \psi(k-1) + (u_2(k-1) - b_{\omega}(k-1)) \Delta t \\ (1 - \Delta t/\tau_{b_{a_x}})b_{a_x}(k-1) \\ (1 - \Delta t/\tau_{b_{\omega}})b_{\omega}(k-1) \end{bmatrix}, \quad (4.1)$$

$$u(k-1) = \begin{bmatrix} a_x(k-1) \\ \omega(k-1) \end{bmatrix} = \begin{bmatrix} u_1(k-1) \\ u_2(k-1) \end{bmatrix}, \quad (4.2)$$

$$y(k) = \begin{bmatrix} p_{xgps}(k) \\ p_{ygps}(k) \end{bmatrix}, \quad (4.3)$$

onde p_x e p_y são a posição do veículo nos eixos x e y , respectivamente, v é a velocidade linear, ψ é o ângulo de guinada do veículo, ω é a velocidade angular medida pelo

sistema inercial, b_{a_x} é a polarização do acelerômetro no eixo x e b_ω é a polarização da velocidade angular.

Observa-se na equação que representa o vetor de medições, que foram utilizadas informações fornecidas pelo receptor GPS convertidas para a posição em metros por meio da transformação entre Latitude/Longitude e a projeção UTM. Conforme descrito no Capítulo 3, a taxa de amostragem desse sensor é de 1Hz, enquanto a taxa de amostragem dos demais sensores foi ajustada para 33Hz. Como a informação proveniente do receptor GPS é utilizada apenas na etapa de atualização, a solução encontrada foi realizar essa etapa apenas nos momentos em que uma nova informação de GPS é disponibilizada. O vetor de medições tem relação direta com os dois primeiros estados estimados. A etapa de predição deve manter a estimação dos estados a partir das equações do modelo entre as amostras de posição obtidas a partir do receptor GPS.

Os ruídos de processo e de medição para cada configuração são representados, respectivamente pelas matrizes Q e R . Esses ruídos estão detalhados mais adiante, nas Seções 4.2.1 e 4.2.2.

4.1.2 Configuração 2

Na segunda configuração testada foi adicionada a informação de ângulo de giro do volante - $u_2(k)$ - para estimar a orientação do veículo. Na estimação desse estado foi utilizado o modelo de Ackerman apresentado na Seção 3.1. Os demais estados foram estimados como na configuração anterior. As equações de transição de estados utilizadas na etapa de predição (modelo) são:

$$x(k) = \begin{bmatrix} p_x(k) \\ p_y(k) \\ v(k) \\ \psi(k) \\ b_{a_x}(k) \end{bmatrix} = \begin{bmatrix} p_x(k-1) + v(k-1)\cos(\psi(k-1)) \Delta t \\ p_y(k-1) + v(k-1)\text{sen}(\psi(k-1)) \Delta t \\ v(k-1) + (u_1(k-1) - b_{a_x}(k-1)) \Delta t \\ \psi(k-1) + \frac{v(k-1)}{L\cos(u_2(k-1))}\tan(u_2(k-1)) \Delta t \\ (1 - \Delta t/\tau_{b_{a_x}})b_{a_x}(k-1) \end{bmatrix}, \quad (4.4)$$

onde L é a distância entre eixos do veículo.

Além dos estados referentes a posição, velocidade e orientação do veículo, foi estimado, também, o *bias* do acelerômetro.

O vetor de entradas:

$$u(k-1) = \begin{bmatrix} a_x(k-1) \\ \alpha(k-1) \end{bmatrix}, \quad (4.5)$$

possui informação de aceleração no eixo x e ângulo de orientação do sistema de direção. Esse ângulo foi obtido a partir do ângulo do volante, conforme curva de calibração apresentada na Seção 3.2.1.

O vetor de medições:

$$y(k) = \begin{bmatrix} p_{xgps}(k) \\ p_{ygps}(k) \end{bmatrix}, \quad (4.6)$$

utilizado na etapa de atualização da estimação é o mesmo utilizado na configuração 1 (Equação (4.3)), que contém as medidas de posição obtidas pelo GPS nos eixos x e y .

4.1.3 Configuração 3

Nas configurações 1 e 2, o estado estimado $v(k)$ correspondente à velocidade do veículo é obtido a partir da integração no tempo da aceleração fornecida pelo SMI. A terceira configuração foi desenvolvida com o intuito de testar outra fonte de informação para a estimação da velocidade do carro. Nela, foi utilizada a velocidade das rodas obtida pelos sensores acoplados ao sistema de freios ABS do veículo. O modelo utilizado foi o modelo de Ackerman e a predição dos estados é realizada usando as equações:

$$x(k) = \begin{bmatrix} p_x(k) \\ p_y(k) \\ \psi(k) \end{bmatrix} = \begin{bmatrix} p_x(k-1) + u_1(k-1)\cos(u_2(k-1))\cos(\psi(k-1)) \Delta t \\ p_y(k-1) + u_1(k-1)\cos(u_2(k-1))\sen(\psi(k-1)) \Delta t \\ \psi(k-1) + \frac{u_1(k-1)}{L}\tan(u_2(k-1)) \Delta t \end{bmatrix}, \quad (4.7)$$

$$u(k-1) = \begin{bmatrix} \frac{v_{esq}(k-1) + v_{dir}(k-1)}{2} \\ \alpha(k-1) \end{bmatrix}. \quad (4.8)$$

Pode-se observar nessa equação que, ao invés de se utilizar a aceleração para estimar a velocidade, utiliza-se a média da velocidade das rodas dianteiras. O ângulo de orientação do veículo (ψ) foi calculado por meio do ângulo da direção (α), assim como na configuração anterior. Para o cálculo desse ângulo poderia ser utilizada a integração no tempo da diferença de velocidade das rodas, porém essa opção se mostrou inviável, uma vez que a relação sinal-ruído para pequenas amplitudes da diferença de velocidade é muito pequena. Sendo assim, a diferença de velocidade das rodas pode não expressar corretamente o ângulo das rodas.

O vetor de entradas, nesse caso, é composto pela medida de ângulo de direção (α) obtido a partir do ângulo do volante e pelas velocidades das rodas dianteiras do veículo, conforme apresentado na Equação (4.8). O vetor de medições utilizado na atualização contém a posição medida pelo receptor GPS nos eixos x e y , assim como nas configurações 1 e 2.

4.1.4 Configuração 4

A partir da observação do comportamento da reconstrução de trajetória nas configurações anteriores, foi implementada uma quarta configuração que combina a informação de todos os sensores descritos anteriormente. Nessa configuração a predição é realizada utilizando o modelo de Ackerman para a orientação do veículo e o modelo do uniciclo para os demais estados, assim como na Configuração 2:

$$x(k) = \begin{bmatrix} p_x(k) \\ p_y(k) \\ v(k) \\ \psi(k) \\ b_{ax}(k) \end{bmatrix} = \begin{bmatrix} p_x(k-1) + v(k-1)\cos(\psi(k-1)) \Delta t \\ p_y(k-1) + v(k-1)\sen(\psi(k-1)) \Delta t \\ v(k-1) + (u_1(k-1) - b_{ax}(k-1)) \Delta t \\ \psi(k-1) + \frac{v(k-1)}{L\cos(u_2(k-1))}\tan(u_2(k-1)) \Delta t \\ (1 - \Delta t/\tau_{b_{ax}})b_{ax}(k-1) \end{bmatrix}, \quad (4.9)$$

$$u(k-1) = \begin{bmatrix} a_x(k-1) \\ \alpha(k-1) \end{bmatrix}. \quad (4.10)$$

A diferença dessa configuração em relação à configuração 2 está na etapa de atualização, que passa a ser dividida em duas partes. Caso exista uma nova informação de posição fornecida pelo receptor GPS (situação que ocorre de 1 em 1 segundo), a atualização é realizada com o vetor de medições apresentado na Equação (4.3); caso contrário, a informação atualizada é a velocidade, utilizando-se os sensores de velocidade das rodas, isto é:

$$y(k) = \left[\frac{v_{esq}(k) + v_{dir}(k)}{2} \right]. \quad (4.11)$$

Dessa maneira, a informação de aceleração é combinada com a medida de velocidade das rodas para se obter uma estimativa mais confiável da velocidade, grandeza que interfere diretamente no cálculo da posição e da orientação. Esta configuração agrega um maior número de informações ao algoritmo de fusão sensorial. Portanto, desde que as características estocásticas dos ruídos de processo e de medição sejam apropriadamente representadas através da escolha adequada das matrizes de covariância correspondentes, essa configuração resulta em uma estimativa mais confiável dos estados em questão.

A tabela 4.1 apresenta um sumário das características de cada configuração com relação ao modelo adotado na predição dos estados e os sensores utilizados como entrada do modelo e como medida.

Tabela 4.1: Resumo das características de cada configuração.

Configuração	Modelo	Sensores
1	Uniciclo	GPS e SMI
2	Uniciclo para posição e velocidade e Ackerman para orientação	GPS, SMI e ângulo do volante
3	Ackerman	GPS, ângulo do volante e velocidade das rodas
4	Uniciclo para posição e velocidade e Ackerman para orientação	GPS, SMI, ângulo do volante e velocidade das rodas

4.2 Ajuste das Matrizes de Covariância

Em todas as configurações apresentadas foi utilizado o algoritmo do filtro de Kalman Estendido na estimação dos estados. O programa computacional de cálculo numérico Matlab foi utilizado na implementação do algoritmo.

Um dos aspectos mais importantes para o funcionamento do Filtro de Kalman Estendido é o ajuste das matrizes de covariância que devem ser fornecidas como parâmetros de entrada do algoritmo. A matriz denominada Q é referente ao ruído de processo, ou seja, erros associados à imperfeição do modelo e ao ruído nas entradas, e a matriz denominada R é referente ao ruído presente nas medidas. O ajuste dessas matrizes foi realizado levando em consideração descrições fornecidas pelos fabricantes e a experiência na utilização dos instrumentos.

4.2.1 Estimativa do Ruído de Processo Associado aos Sinais de Entrada e aos Erros de Modelagem

As entradas utilizadas na reconstrução da trajetória neste trabalho foram a aceleração no eixo x medida pelo SMI, a velocidade angular em torno do eixo z do veículo, o ângulo de giro do volante e a velocidade das rodas. Para definir a matriz de covariância de ruído de processo, foram estimados erros em cada variável. Os valores encontrados nesse cálculo foram o ponto de partida para o ajuste dessa matriz.

O erro de aceleração (e_{a_x}) foi estimado com base no ruído da medida feita pelo SMI. Para calcular esse valor, um filtro digital do tipo *Butterworth* de quarta ordem e não causal foi projetado e aplicado sobre os dados coletados (Fig. 4.1). A diferença entre o sinal coletado e o sinal filtrado foi usada para o cálculo do desvio padrão dessa diferença. O valor do desvio padrão foi atribuído inicialmente como intensidade do sinal de ruído associada à medição da aceleração. Esse valor foi amplificado após a verificação de que ele era um valor subestimado para o erro. Por isso, esse valor foi ajustado por tentativa e erro até que se chegasse a uma estimativa de posição dentro dos limites aceitáveis, conforme critérios de avaliação explicados na Seção 4.2.3. O valor utilizado para e_{a_x} foi de 3,13 m/s².

Para calcular o erro da velocidade angular (e_{ω}), também fornecida pelo SMI, o mesmo procedimento foi adotado (Fig. 4.2). Os dados coletados foram subtraídos

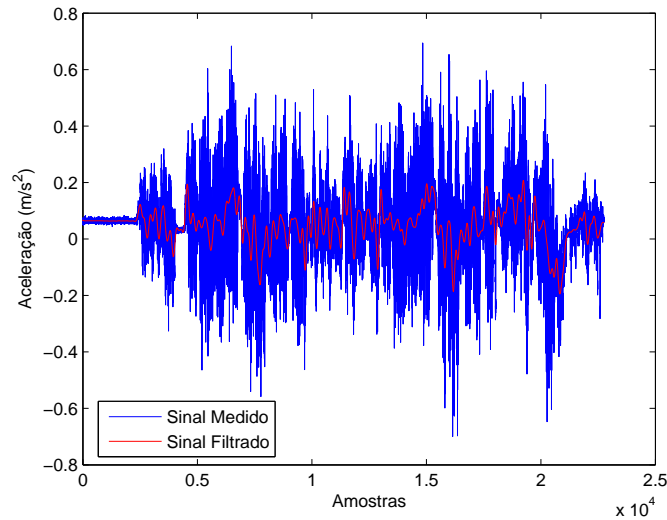


Figura 4.1: Aceleração no eixo x - sinal medido pelo SMI (azul) e sinal filtrado (vermelho).

dos dados filtrados e o desvio padrão dessa diferença foi adotado como intensidade do sinal de ruído de processo associado a essa variável. Como mencionado na seção anterior, os elementos sensores presentes no SMI sofrem influência de *bias*, porém, o erro correspondente a essa influência não foi considerado neste cálculo, uma vez que um pseudo-estado correspondente à estimação do *bias* foi acrescentado na predição, minimizando seus efeitos. O valor utilizado para e_ω foi de 0,028 rad/s.

A estimação da intensidade do ruído de processo associado ao ângulo de giro do eixo das rodas do veículo (e_{vol}) foi feita com base nos dados de calibração. O valor do desvio padrão observado na curva de calibração mostrada na Seção 3.2.1 em relação aos dados que geraram essa curva foi utilizado como erro relativo à calibração. A esse valor foi somado um erro correspondente às folgas mecânicas e imprecisão do instrumento de calibração, totalizando o valor do erro de medição do ângulo de giro. O valor utilizado para o erro do ângulo de giro do volante foi de 0,174 rad.

O erro de velocidade linear presente na medição das velocidades das rodas (e_{V_r}) foi calculado a partir de uma comparação da velocidade medida pelos sensores das rodas e a velocidade medida pelo receptor GPS. Essa segunda velocidade é dada em metros por segundo com apenas uma casa decimal, porém nos momentos em que o número de satélites vistos pelo receptor é grande, ela é uma medida confiável.




Figura 4.2: Velocidade angular em torno do eixo z - sinal medido pelo SMI (azul) e sinal filtrado (vermelho).

Portanto, essa medida foi utilizada como padrão de comparação na obtenção do erro de velocidade das rodas. Esse erro foi obtido com o cálculo do desvio padrão da diferença amostral da velocidade medida usando o receptor GPS e a velocidade obtida a partir dos sensores de velocidade angular das rodas. O valor correspondente ao erro na medição das velocidades das rodas foi de 2 m/s.

Os erros de aproximação do modelo também são representados na matriz Q utilizada em cada configuração, e levam em consideração os erros envolvidos no cálculo de cada estado devidos à aproximação por diferença finita, para um dado tempo de amostragem (T_s), das equações diferenciais correspondentes ao movimento do veículo. As matrizes Q_1 , Q_2 e Q_3 referentes às configurações testadas são:

$$Q_1 = \begin{bmatrix} (e_{v_x} T_s)^2 & 0 & 0 & 0 & 0 & 0 \\ 0 & (e_{v_y} T_s)^2 & 0 & 0 & 0 & 0 \\ 0 & 0 & (e_{a_x} T_s)^2 & 0 & 0 & 0 \\ 0 & 0 & 0 & (e_{\omega} T_s)^2 & 0 & 0 \\ 0 & 0 & 0 & 0 & (e_{b_{ax}} T_s / \tau_{b_{ax}})^2 & 0 \\ 0 & 0 & 0 & 0 & 0 & (e_{b_{\omega}} T_s / \tau_{b_{\omega}})^2 \end{bmatrix}, \quad (4.12)$$

$$Q_2 = \begin{bmatrix} (e_{vx}T_s)^2 & 0 & 0 & 0 & 0 \\ 0 & (e_{vy}T_s)^2 & 0 & 0 & 0 \\ 0 & 0 & (e_{ax}T_s)^2 & 0 & 0 \\ 0 & 0 & 0 & (e_{vol}(sqrt(e_{vx}^2 + e_{vy}^2))T_s)^2 & 0 \\ 0 & 0 & 0 & 0 & (e_{bax}T_s/\tau_{bax})^2 \end{bmatrix}, \quad (4.13)$$

$$Q_3 = \begin{bmatrix} \frac{(e_{vr}^2 T_s^2)}{2} & 0 & 0 \\ 0 & \frac{(e_{vr}^2 T_s^2)}{2} & 0 \\ 0 & 0 & (e_{vol}e_{vr}T_s)^2 \end{bmatrix}, \quad (4.14)$$

$$Q_4 = Q_2. \quad (4.15)$$

4.2.2 Estimativa do Ruído de Medição

As variáveis utilizadas como medidas na atualização das estimativas são a posição nos eixos x e y fornecida pelo receptor GPS, e a velocidade das rodas do veículo. O erro da medida do receptor GPS foi calculado com base na informação fornecida pelo fabricante e na qualidade da informação recebida a cada instante. Segundo o fabricante Garmin [Garmin, 2005], o receptor utilizado apresenta uma incerteza de 15 metros com um intervalo de confiança de 95%. Assim, considerando que esse valor de incerteza corresponde a duas vezes o desvio padrão de uma variável aleatória com distribuição de probabilidade Gaussiana, o desvio padrão do instrumento, de 7,5 metros, ($e_{Pxgps} = e_{Pygps} = 7,5$ metros) foi utilizado como um dos parâmetros para o cálculo do erro dessa medida. A qualidade da medida depende também do número de satélites e da geometria/posição dos satélites vistos pelo receptor em cada instante. O número de satélites em visada é fornecido pelo receptor e a qualidade da medição é diretamente proporcional a esse número. A geometria da constelação de satélites vistos pelo receptor é quantificada pela diluição horizontal da precisão - HDOP (*Horizontal Dilution of Precision*) da informação coletada (ver Apêndice A para mais detalhes). O HDOP ideal é igual a 1 e seu valor é inversamente proporcional à qualidade da medição.

Utilizando essas informações, a matriz de covariância para a medida de posição fornecida pelo receptor GPS pode ser calculada como:

$$R(k) = \begin{bmatrix} \left(\frac{e_{Pxgps}(k)HDOP(k)}{NumSat(k)/7}\right)^2 & 0 \\ 0 & \left(\frac{e_{Pygps}(k)HDOP(k)}{NumSat(k)/7}\right)^2 \end{bmatrix}, \quad (4.16)$$

onde $NumSat$ expressa o número de satélites vistos pelo receptor GPS em um dado instante e $HDOP$ é o valor da diluição horizontal da precisão nesse mesmo instante. O valor que divide a variável $NumSat$ foi inserido para realizar uma normalização no cálculo. Verificou-se experimentalmente, o valor de $NumSat/HDOP$ era 7. Assim, dividindo $NumSat$ por esse valor, em média, o erro das medidas do receptor GPS é igual a e_{Pxgps} ou e_{Pygps} .

Na configuração 4 existem duas possibilidades para a matriz de covariância do ruído de medição. A primeira é a matriz apresentada na Equação (4.16), relativa ao receptor GPS. A segunda é a matriz relativa ao erro de velocidade do veículo devido aos erros dos sensores de velocidade das rodas. Nesse caso, a matriz de covariância adotada foi:

$$R = \begin{bmatrix} e_{Vr}^2 \end{bmatrix}. \quad (4.17)$$

Para determinar se o ajuste das matrizes de covariância Q e R correspondem a valores adequados, foi utilizado o valor da inovação observada para os estados $p_x(k)$ e $p_y(k)$ a cada atualização. O procedimento adotado foi a comparação da inovação com o limite de confiança dado pela Matriz de covariância da inovação como $\pm 3\sqrt{P_{yy}}$. Foi estabelecido que, se o valor da inovação permanece dentro dos limites desse intervalo de confiança, então o algoritmo do filtro possui suas matrizes de covariância bem sintonizadas. Os gráficos das figuras 4.3, 4.4, 4.5 e 4.6 mostram que os valores observados para a inovação ao longo da estimação dos estados permaneceu dentro dos limites dados pela matriz P_{yy} .

4.2.3 Critérios de Avaliação

Para comparar o desempenho obtido nos resultados da fusão sensorial, foi necessário definir uma métrica de comparação entre as configurações analisadas. Por não haver padrão de comparação mais preciso (e exato) que o receptor GPS utilizado




Figura 4.3: Comparação da inovação com o limite de confiança $\pm 3\sqrt{P_{yy}}$ para os estados (a) p_x e (b) p_y utilizando a Configuração 1. As linhas contínuas correspondem à inovação e as linhas tracejadas representam os limites de confiança




Figura 4.4: Comparação da inovação com o limite de confiança $\pm 3\sqrt{P_{yy}}$ para os estados (a) p_x e (b) p_y utilizando a Configuração 2. As linhas contínuas correspondem à inovação e as linhas tracejadas representam os limites de confiança

no experimento, foram estabelecidos três critérios principais para a avaliação: (i) a comparação do traço da sub-matriz de covariância da estimativa da posição; (ii) a comparação da trajetória estimada com a trajetória medida pelo GPS com elipses de confiança dessas medidas; e (iii) a robustez da estimativa à perda do sinal de GPS avaliada pelo tempo durante o qual a estimativa apresenta incerteza menor do que aquela da medição GPS.

O traço de uma matriz é definido como a soma dos elementos de sua diagonal principal. As matrizes de covariância em um filtro de Kalman expressam a incerteza associada ao parâmetro representado por ela. O traço da matriz de covariância pode ser utilizado como critério de comparação, uma vez que reduz um




Figura 4.5: Comparação da inovação com o limite de confiança $\pm 3\sqrt{P_{yy}}$ para os estados (a) p_x e (b) p_y utilizando a Configuração 3. As linhas contínuas correspondem à inovação e as linhas tracejadas representam os limites de confiança




Figura 4.6: Comparação da inovação com o limite de confiança $\pm 3\sqrt{P_{yy}}$ para os estados (a) p_x e (b) p_y utilizando a Configuração 4. As linhas contínuas correspondem à inovação e as linhas tracejadas representam os limites de confiança

conjunto de números a um valor que expressa as características desse conjunto. No algoritmo de um Filtro de Kalman, o ganho de Kalman é calculado de forma a minimizar o traço da matriz de covariância do erro da estimação dos estados. Esse critério também é utilizado na avaliação da consistência e da informação contida na estimativa [Teixeira, 2008]. Quanto menor o traço da matriz de covariância, mais consistente e mais informativa é a estimativa obtida. Dessa forma, como se deseja avaliar a estimativa da posição nos eixos x e y , a submatriz de covariância correspondente à estimação desses dois estados é utilizada em comparação com a matriz de covariância do erro da medida do GPS. Considera-se que, se o traço da submatriz de covariância da estimativa da posição é menor do que o traço da matriz de

covariância do ruído de medição associado às medidas do receptor GPS, então, a estimativa é mais confiável que a medida fornecida pelo receptor GPS.

Outro critério de avaliação utilizado é obtido por meio do desenho de elipses de confiança que levam em consideração a incerteza da medida do receptor GPS. Ao longo do trajeto são traçadas elipses que representam a matriz de covariância dos estados estimados, ou seja, a incerteza de localização no espaço bidimensional. A partir da decomposição da matriz P de covariância dos estados estimados, ou da matriz R de covariância do ruído de medição, em valores singulares e da especificação da probabilidade de que aquele valor de posição pode ser encontrado dentro da elipse (probabilidade associada à incerteza), é possível determinar a dimensão e posicionamento dos semi-eixos principais da elipse. Cada um dos semi-eixos estará associado à incerteza da estimativa em uma dimensão, e a elipse está centrada no valor da estimativa. No caso deste trabalho, a probabilidade associada utilizada é de 95%, isto é, as elipses delimitam regiões tais que os valores verdadeiros das posições estão em seus interiores com 95% de chance.

A análise do desempenho das configurações deve levar em consideração, também, a robustez da estimativa à perda do sinal GPS. Uma vez que o sistema de fusão sensorial é muito dependente do sensor receptor GPS, cujo sinal de satélite pode ser obscurecido por barreiras físicas presentes no ambiente, é necessário que o sistema possa manter uma estimativa aceitável em caso de perda do sinal. Para testar esse quesito, foram simuladas situações em que o número de satélites vistos pelo receptor é igual a zero, e foi contabilizado o tempo em que o sistema manteve a estimativa com incerteza inferior à incerteza utilizando-se apenas o receptor GPS.

4.3 Reconstrução de Trajetórias – Resultados Experimentais

Para realizar a reconstrução de trajetória com os dados adquiridos pelos sensores, foram implementados códigos em linguagem MATLAB referentes a cada configuração. Os experimentos para coleta dos dados foram realizados no campus da UFMG. A posição (x,y) foi calculada em todas as configurações mencionadas a fim de se comparar sua eficiência associada a cada configuração. A primeira medida de posição é

considerada como sendo a origem, isto é, posição (0,0).

A análise dos resultados da reconstrução permite escolher a configuração mais adequada à estimação em tempo real, além de responder duas questões: os algoritmos podem prover ao sistema informação de qualidade entre duas amostras do receptor GPS? Por quantos segundos os algoritmos conseguem estimar a trajetória do veículo com incerteza inferior à incerteza associada às medidas do GPS, em caso de perda de sinal?

As Figuras 4.7, 4.8, 4.9 e 4.10 apresentam as trajetórias reconstruídas para cada uma das configurações. Nelas, os pontos representam a posição estimada, e as cruces representam as amostras de posição do GPS. Em todos os gráficos foram incluídas elipses tracejadas que indicam a covariância das medidas de posição do GPS para um nível de confiança de 95%. Se a trajetória calculada encontra-se dentro dos limites das elipses, pode-se argumentar que a estimação não pode ser descartada ou considerada como sendo falsa.




Figura 4.7: Gráfico de reconstrução da trajetória utilizando a Configuração 1.

A reconstrução da trajetória na Configuração 1 (Fig. 4.7) mostrou uma trajetória aceitável, uma vez que em todo o percurso a estimativa não ultrapassou os




Figura 4.8: Gráfico de reconstrução da trajetória utilizando a Configuração 2.




Figura 4.9: Gráfico de reconstrução da trajetória utilizando a Configuração 3.




Figura 4.10: Gráfico de reconstrução da trajetória utilizando a Configuração 4.

limites das elipses de covariância do sinal medido pelo receptor GPS. Porém, em alguns trechos, a etapa de atualização do filtro faz com que a estimativa mude bruscamente seu valor, criando descontinuidades na trajetória estimada. Essa situação indica que a confiança na medida GPS é grande em relação ao estado predito, ou seja, a matriz Q apresenta valores altos para o erro de posição, em relação aos valores correspondentes da matriz R . Esses valores, no entanto, devem ser altos, pois, caso contrário, a estimação da posição atingiria valores fora da faixa de confiança estabelecida pelo GPS, o que a caracterizaria como inaceitável.

O gráfico de reconstrução para a Configuração 2 (Fig. 4.8) também apresentou valores dentro da faixa coberta pelas elipses de covariância do GPS. É possível observar que os valores obtidos foram bem próximos aos pontos medidos pelo GPS. Nesta configuração a estimação apresentou uma curva mais suave, com mudanças de valor menos abruptas nos momentos em que há atualização, ou correção. Isso se deve à substituição da utilização da velocidade angular pelo ângulo do volante no cálculo da orientação do veículo.

As configurações 3 e 4 apresentaram um resultado muito semelhante entre

si. Os valores de posição estimada estão dentro do limite das elipses de confiança. A trajetória reconstruída apresenta curvas mais abertas que aquelas observadas a partir das medidas GPS somente, o que pode ser efeito da informação de velocidade proveniente do sensor de velocidade das rodas.

Por não haver um padrão de comparação mais preciso que o próprio GPS, não é possível tirar conclusões de qual a melhor configuração apenas analisando as curvas de reconstrução. Para tornar essa avaliação mais conclusiva, foi calculado o traço (soma dos elementos da diagonal principal) da submatriz de covariância da estimação de posição para cada iteração da simulação, nas quatro configurações testadas, resultando nos gráficos apresentados nas Figuras 4.11, 4.12, 4.13 e 4.14. O traçado contínuo nos gráficos representa o traço da submatriz de covariância relativa à estimação da posição e o traçado pontilhado representa o traço da matriz de covariância R associada à medida GPS. Durante o experimento, o sinal GPS estava disponível a uma taxa de 1Hz e foi utilizado na correção da predição. É possível observar nos gráficos das Figuras 4.11 e 4.12, referentes às Configurações 1 e 2, que os valores do traço da submatriz de covariância da estimativa da posição são muito próximos aos valores do traço da matriz de covariância associada ao receptor GPS. Já as Configurações 3 e 4 (Figuras 4.13 e 4.14) resultaram em valores de traço da submatriz de covariância da estimativa de posição bastante inferiores ao traço da matriz de covariância associada ao erro do receptor GPS.

A Tabela 4.2 apresenta o valor médio do traço da matriz de covariância do GPS e do traço das submatrizes de covariância da posição estimada nas quatro configurações. É possível verificar nessa tabela que, apesar de em alguns pontos as Configurações 1 e 2 apresentarem covariância superior àquela da medida GPS, na média esse valor é bastante inferior em todas as configurações.

A partir da inspeção dos gráficos das Figuras 4.11, 4.12, 4.13 e 4.14 e do valor médio do traço da matriz de covariância para cada configuração, apresentados na Tabela 4.2, é possível afirmar que, na situação de disponibilidade do sinal GPS a cada 1 segundo, a configuração que apresentou menor incerteza é a Configuração 4, sendo, portanto, a mais confiável. Esse resultado é coerente com a expectativa, uma vez que essa é a configuração que agrega mais informação ao filtro.

Além de avaliar a estimativa considerando a disponibilidade do sinal do GPS




Figura 4.11: Gráfico do traço da matriz de covariância da estimação da posição utilizando a Configuração 1.




Figura 4.12: Gráfico do traço da matriz de covariância da estimação da posição utilizando a Configuração 2.




Figura 4.13: Gráfico do traço da matriz de covariância da estimação da posição utilizando a Configuração 3.




Figura 4.14: Gráfico do traço da matriz de covariância da estimação da posição utilizando a Configuração 4.

Tabela 4.2: Valor médio do traço da matriz de covariância da estimativa de posição e do GPS.

	Traço Médio
GPS	106,50
Configuração 1	45,16
Configuração 2	31,27
Configuração 3	27,73
Configuração 4	14,24

a cada segundo, avaliou-se o desempenho dos algoritmos em situações de perda do sinal, a fim de verificar por quanto tempo cada algoritmo pode manter uma incerteza inferior à do receptor GPS no caso de perda de sinal GPS. Para realizar esse teste, a informação GPS foi suprimida por um tempo cada vez maior até que o traço da matriz de covariância da estimação da posição superasse o traço da matriz de covariância das medidas GPS. Essa informação foi suprimida em diferentes pontos do trajeto e, para avaliar a robustez da configuração, foi considerado o pior caso.

Nas Configurações 1 e 2 a covariância da estimativa apresentou um valor superior ao GPS mesmo em situação de disponibilidade do sinal em todo o trajeto. Isso ocorreu porque nesses pontos o número de satélites era pequeno e o HDOP apresentava um valor alto. Pode-se afirmar que o pior caso para essas duas configurações ocorre mesmo sem perda de sinal do receptor GPS. A Configuração 3 sustentou a incerteza abaixo do valor de covariância do GPS por 5 segundos, superando-o apenas no sexto segundo quando a perda de sinal ocorreu no meio da trajetória. A Configuração 4 apresentou, neste teste, o mesmo desempenho da Configuração 3, sustentando a estimativa por 5 segundos no pior caso.

Outro aspecto importante, que deve ser levado em consideração é o tempo de processamento de cada uma das configurações. Esse tempo foi medido durante a simulação e a configuração que consumiu maior tempo de processamento para a mesma trajetória foi a Configuração 4. No entanto, esse tempo de processamento para 11500 pontos ainda é muito pequeno, conforme apresenta a Tabela 4.3, tornando esse critério não decisivo na escolha da configuração mais adequada.

A velocidade do veículo foi estimada nas configurações 1, 2 e 4, onde se utilizou

Tabela 4.3: Tempo total de processamento em segundos para uma trajetória de 377 segundos, o equivalente a 11500 pontos.

	Tempo Total de Processamento (s)
Configuração 1	0,813
Configuração 2	0,734
Configuração 3	0,703
Configuração 4	1,360

o modelo do uniciclo para realizar a predição dos estados. Na configuração 3, a velocidade das rodas foi utilizada como entrada do modelo de Ackerman. O gráfico da Figura 4.15 exibe a velocidade estimada ao longo do trajeto (curvas azul, vermelha e preta) e a velocidade das rodas utilizada na Configuração 3, convertida para a velocidade do veículo, a título de comparação. Pode-se observar no gráfico que a curva correspondente à Configuração 4 apresentou valores intermediários. Os valores de velocidade nessa configuração estão entre os valores da Configuração 2, que utiliza apenas a aceleração para estimar a velocidade e os valores da Configuração 3, que utiliza apenas os sensores de velocidades das rodas. Esse fato não é surpreendente, uma vez que a Configuração 4 combina os dois sensores. A curva da Configuração 1 apresentou mudanças mais bruscas na velocidade, principalmente nos instantes em que ocorreu a etapa de atualização, o que pode ser observado nas oscilações que ocorrem nessa curva.

Uma consideração com relação à não utilização das medições de orientação fornecida pelo sistema inercial deve ser feita aqui. Devido ao comportamento não repetitivo do sistema para um mesmo experimento em locais diferentes, conforme apresentado no Capítulo 3, optou-se por não se utilizar suas medidas diretamente no algoritmo de fusão. Foi realizado um experimento em que essa medida era utilizada na etapa de atualização do filtro, porém, devido ao grande erro inserido nessa medida, a matriz de covariância correspondente utilizada foi ajustada com valores altos para que a trajetória estimada fosse coerente com a realizada, de acordo com o critério de se obter uma trajetória coberta pelas elipses de confiança. Assim, a contribuição para a redução na covariância da estimação foi mínima. Por isso, como o custo computacional para processar essa informação é maior que sua contribuição,

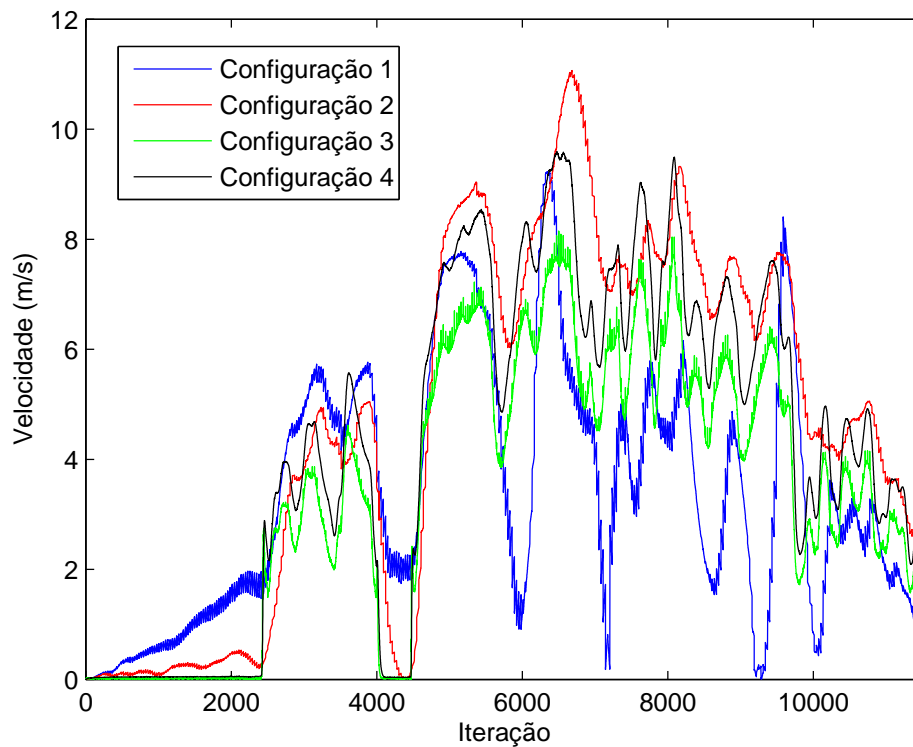


Figura 4.15: Gráfico das velocidades estimadas nas Configurações 1, 2 e 4 e da velocidade medida na Configuração 3.

concluiu-se que sua utilização não era viável.

4.4 Considerações Finais

Este capítulo apresentou algumas possibilidades de combinação de modelos e sensores testadas no desenvolvimento deste trabalho. Essa avaliação teve o objetivo de avaliar quais os sensores mais adequados para a tarefa de localização e qual a melhor combinação para se obter uma estimativa mais confiável da posição do veículo, mesmo em casos de perda do sinal GPS.

De acordo com o exposto até aqui, com relação ao critério “robustez à perda de GPS”, as configurações que apresentaram melhores resultados foram a terceira e a quarta configurações. Porém, a Configuração 4 resultou em um menor valor para o traço da matriz de covariância nos experimentos realizados. Assim, concluiu-se que a configuração mais adequada para a localização em tempo real é a quarta configuração, que utiliza o modelo de Ackerman, tendo a aceleração no eixo x do

veículo e o ângulo de direção como entradas, a posição medida pelo receptor GPS e a velocidade das rodas como medições usadas na etapa de correção do filtro. É importante salientar que os testes das configurações foram realizados com dados reais e não com dados simulados, tornando a análise dos resultados mais aplicável à localização em tempo real.

Os resultados da estimação da trajetória em tempo real utilizando a quarta configuração são apresentados no capítulo seguinte.

Capítulo 5

Localização *Online*

No capítulo anterior, foram apresentados os resultados obtidos para a reconstrução de trajetória utilizando diferentes algoritmos para fusão sensorial. Nele, os dados foram adquiridos e armazenados durante o experimento e processados posteriormente. Neste capítulo são descritos os procedimentos utilizados para a localização do veículo em tempo real, ou seja, durante a realização do trajeto. Para a visualização dos resultados de localização *online*, foi desenvolvida uma interface gráfica que exibe a posição do veículo em um mapa durante o seu movimento. O desenvolvimento dessa interface também é discutido neste capítulo.

Os programas utilizados nesta etapa do trabalho foram desenvolvidos na plataforma Microsoft Visual Studio. Inicialmente, foi definida uma arquitetura de desenvolvimento dos softwares de forma que o sistema de localização fosse modular, facilitando a alteração da configuração e inclusão de novas informações. Para cada instrumento foi desenvolvido um programa de coleta de dados que é responsável por se comunicar com o dispositivo, adquirir os dados e enviá-los a outro programa, responsável pela fusão sensorial. Este, então, centraliza as informações coletadas e as combina de forma a obter a estimação dos estados de interesse. De posse da estimação dos estados, ele repassa a localização a uma interface gráfica que representa em um mapa o ponto correspondente à posição do veículo. A Figura 5.1 representa essa arquitetura.

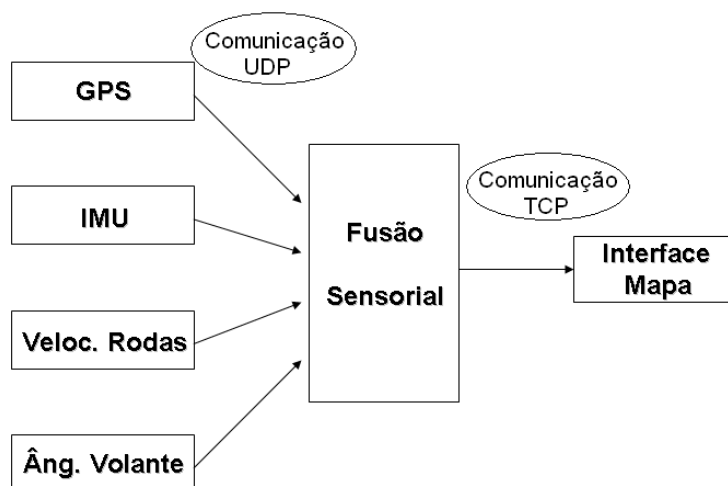


Figura 5.1: Arquitetura de softwares desenvolvidos para a localização.

5.1 Fusão Sensorial

Conforme visto no Capítulo 4, a configuração que resultou em uma localização com menor covariância associada à posição foi a configuração que utiliza o modelo de Ackerman para a predição dos estados, as informações do acelerômetro e do volante na etapa de predição e do GPS e velocidade das rodas na etapa de atualização (Configuração 4). Devido aos resultados obtidos, essa foi a configuração selecionada para ser implementada na localização *online*, mas o sistema não se limita a ela. A escolha da configuração utilizada na fusão sensorial é feita de acordo com as medidas disponíveis no momento da inicialização. Caso todos os instrumentos estejam disponíveis, a configuração de fusão utilizada é a Configuração 4, que apresentou melhor desempenho na reconstrução de trajetória. Se apenas a medida de velocidade das rodas está indisponível, a Configuração 2 é utilizada, sendo realizada a predição da orientação pelo Modelo de Ackerman e a atualização da posição apenas com o GPS; caso a medida de ângulo do volante esteja indisponível, a configuração utilizada é a Configuração 1. Portanto, para que seja possível a localização por fusão sensorial, é necessário que existam, no mínimo, as medidas do receptor GPS e do sensor inercial.

Para a realização da fusão das informações dos sensores à medida em que eles realizam as medições, foi utilizada a plataforma de programação Visual C++. A coleta dos dados dos instrumentos, mesmo para a reconstrução *offline* da trajetória, foi realizada em um programa desenvolvido nessa plataforma, porém, os dados foram

apenas armazenados em arquivo para utilização posterior. A comunicação entre os programas que compõem o sistema é explicada a seguir. O estado inicial para inicialização do algoritmo de fusão é definido em um procedimento de inicialização, detalhado na Seção 5.1.2.

5.1.1 Comunicação Entre Programas

Para utilizar os dados em tempo real, cada programa de leitura de um instrumento foi adaptado para enviar as informações a um servidor via Socket. O programa servidor, por sua vez, é responsável por coletar as informações enviadas pelo cliente e realizar a fusão sensorial. Os principais protocolos para envio de informação via Socket são o UDP (*User Datagram Protocol*) e o TCP (*Transmission Control Protocol*). No protocolo TCP há controle do fluxo de dados e garantia de entrega dos pacotes. Para isso, sempre que uma mensagem é enviada, o sistema fica aguardando uma mensagem de retorno (*Ack*), que é a confirmação de recebimento do pacote. Caso essa confirmação não seja recebida, há reenvio do pacote até que a confirmação de entrega seja recebida. Essa característica torna a troca de mensagens lenta, fazendo com que o servidor possa receber pacotes com atraso, ou seja, informação antiga, o que é inviável para a fusão sensorial em tempo real. No protocolo UDP não há controle de fluxo e garantia de entrega dos pacotes de dados, porém, é o protocolo mais adequado para essa tarefa, uma vez que a velocidade de transmissão da informação é mais alta que no protocolo TCP. É menos oneroso para o sistema que se percam algumas mensagens, do que se recebam todas as mensagens, porém com atraso, pois informações antigas não contribuem adequadamente para uma localização correta. Por isso, o envio de mensagens dos sensores para o sistema de fusão sensorial é feito por meio do protocolo UDP.

No programa que implementa o servidor é realizada a fusão dos dados utilizando as configurações, de acordo com a disponibilidade das informações.

5.1.2 Inicialização do Algoritmo

A inicialização do algoritmo de fusão sensorial é realizada com a coleta das medidas fornecidas pelos instrumentos por aproximadamente 40 segundos. Durante o período

de inicialização o veículo deve estar parado em local plano. A posição inicial do veículo é calculada utilizando a média das posições coletadas pelo receptor GPS durante aproximadamente 40 segundos. As medidas de posição obtidas pelo GPS após a inicialização são subtraídas da posição inicial média calculada para que a posição inicial seja considerada como $(0, 0)$. Nesse tempo de inicialização do sistema são coletadas também a aceleração e a orientação fornecidas pelo sensor inercial *Microstrain* 3DM-GX1. Assim, a média da aceleração é utilizada como estimativa para o *bias* inicial do acelerômetro, pois, nessa situação a aceleração no eixo x deve ser zero, e qualquer valor médio diferente de zero será atribuído ao *bias* do acelerômetro. A média da orientação é utilizada como valor inicial para a orientação do veículo.

5.1.3 Estimação da Trajetória

Após a inicialização do algoritmo, as medidas recebidas no servidor UDP são utilizadas para a fusão sensorial. A utilização da média das leituras do receptor GPS na posição inicial minimiza o erro de *offset* que o uso de apenas uma medida poderia gerar (ver Figura 1.2).

A variável de tempo é dada pelo *time stamp* de envio dos dados do sensor inercial, que marca, portanto, o tempo entre as amostras. Sempre que o servidor recebe uma informação nova de aceleração, ele utiliza a última mensagem recebida pelos outros instrumentos para realizar a predição. Dessa forma, em um cenário onde todas as informações coletadas por cada sensor são recebidas pelo servidor sem atrasos, e como a taxa de amostragem dos instrumentos é a mesma (30Hz, exceto no caso do GPS, que é de 1Hz), o erro de tempo na predição será de uma amostra no pior caso, ou seja, 0,033 segundos. Porém, como esse seria um cenário ideal, deve-se acrescentar à Matriz Q (covariância do modelo) um fator correspondente ao erro de tempo.

A etapa de atualização é realizada de acordo com a informação disponível. Caso haja uma nova informação de posição fornecida pelo GPS, o que, idealmente, ocorre a cada 1 segundo, a atualização da posição é realizada no algoritmo. Caso essa informação não esteja disponível e o sensor de velocidade das rodas esteja ativado, a informação atualizada é a de velocidade, conforme mostrado na configuração 4.

O ganho de Kalman e a nova matriz de covariância da estimação é calculada e o algoritmo retorna ao início, como mostra o Algoritmo 1.

Após a obtenção da estimativa de posição, entre outros estados, a localização do veículo deve ser exibida em um mapa na tela do computador. Dessa forma, um programa que implementa a interface de exibição do mapa foi desenvolvido. O envio da informação de posição para a interface também é feito utilizando um Socket de comunicação.

A cada iteração do algoritmo de fusão é calculada uma nova posição para o veículo. Se não houver perda de nenhum pacote de dados, tem-se 30 valores de posição a cada segundo. Não é necessário que a posição do veículo na interface gráfica seja atualizada a essa taxa, portanto, a posição estimada é enviada pelo servidor à interface a cada 30 iterações, ou seja, aproximadamente a cada segundo. A interface é um cliente desse servidor. Ela recebe a posição do veículo nos eixos x e y e exibe em um mapa. As técnicas utilizadas no desenvolvimento da interface são apresentadas na seção seguinte.

5.2 Interface Homem-Máquina (IHM)

Nesta seção são apresentadas as técnicas utilizadas para a implementação da interface gráfica. O objetivo da interface gráfica neste trabalho é a exibição da localização do veículo durante o trajeto dentro do Campus da UFMG. Para isso, um mapa do Campus UFMG foi obtido junto ao Departamento de Planejamento Físico e Obras. A interface gráfica foi construída no ambiente Visual C++ utilizando a API OpenGL e técnicas de geometria computacional implementadas na biblioteca CGAL. Os detalhes da implementação serão apresentados a seguir.

5.2.1 Ferramentas Utilizadas

Em robótica móvel é comum que se deseje utilizar e visualizar informações de mapas da região onde o robô se locomove. Porém, a visualização da localização do robô no mapa se torna difícil se a região exibida for a representação de uma grande área. Assim, torna-se necessário selecionar a região do mapa que corresponda à área em torno da localização do robô. Nesta seção, é apresentada a descrição das ferramentas

utilizadas para a implementação de um algoritmo que armazena as informações do mapa em uma estrutura de dados e seleciona os segmentos que estão dentro de uma área em torno da localização do veículo.

O mapa utilizado neste trabalho consiste em uma planta baixa das ruas e prédios do Campus da UFMG referenciado em coordenadas UTM. O armazenamento do mapa no computador foi feito por meio dos segmentos de reta presentes nesse mapa, que formam as ruas e prédios do Campus. O mapa foi originalmente obtido no formato “.dwg”, extensão de um arquivo produzido pelo programa AutoCad. Nesse programa é possível desenhar segmentos, círculos, arcos, retângulos, ou seja, diversas formas geométricas. Para a confecção da interface, um requisito era que todo o mapa fosse representado apenas por segmentos. Assim, foi necessário encontrar uma ferramenta que fizesse essa conversão.

A conversão do arquivo “.dwg” em segmentos foi feita utilizando o software FEMM 4.0, que permite importar arquivos do tipo “.dxf” (outra extensão padrão do AutoCad) e converter as formas em segmentos. Esse software é geralmente utilizado para se construir malhas de elementos finitos e uma etapa intermediária da construção dessas malhas é a criação de um arquivo “.poly”, que contém a descrição de todos os segmentos que compõem o desenho. A vantagem desse método é que o formato de dados do arquivo “.poly”¹ é de simples compreensão e extração da informação. Além disso, o software FEMM é capaz de converter todas as formas geométricas do arquivo DXF em segmentos de reta (os círculos e arcos, por exemplos, são decompostos em pequenos segmentos). A desvantagem dessa ferramenta é que ela não suporta arquivos DXF muito grandes, com muita informação, como é o caso dos mapas, e, por isso, foi necessário dividir o mapa em vários arquivos e reuní-los apenas na etapa da leitura dos arquivos.

Após a definição do formato da informação, foi necessário determinar os segmentos que estão dentro ou interceptam uma sub-janela ao redor da localização do veículo no mapa (Figura 5.2). Uma alternativa para a seleção desses segmentos seria percorrer todos os segmentos que compõem o mapa e buscar, dentre eles, aqueles que obedecerem à condição. Porém, esse método seria ineficiente, pois gastaria muito tempo para ser executado. Dessa forma, foi necessário utilizar uma estrutura de da-

¹Maiores informações sobre este formato de arquivos podem ser obtidas em [Shewchuk, 2008]

dos que pudesse armazenar os segmentos de forma a facilitar a busca. Existem alguns métodos eficientes para lidar com o janelamento de segmentos [de Berg et al., 2000]. Esses métodos são apresentados no Apêndice C, onde pode-se encontrar, também, detalhes sobre o algoritmo selecionado para este trabalho - a Árvore de Segmentos (*Segment Tree*).




Figura 5.2: Exemplo da busca de segmentos que estão contidos ou interceptam uma janela.

5.2.2 Construção da Interface de Exibição do Mapa

Conforme mencionado na seção anterior, o algoritmo da *Segment Tree* foi selecionado para o armazenamento e busca dos segmentos do mapa. Com esse algoritmo é possível construir uma árvore binária com os limites dos segmentos do mapa e obter uma busca dos segmentos que estão contidos em uma janela retangular a um baixo custo computacional (ver Apêndice C).

As funções necessárias para se trabalhar com uma *Segment Tree* estão implementadas em uma classe na biblioteca CGAL (*Computational Geometry Algorithms Library*), uma biblioteca de classes para uso das técnicas de geometria computacional em C++. A classe `Segment_tree_map_traits_2`² possibilita armazenar os segmentos que são fornecidos pelo mapa em intervalos e os intervalos em uma árvore de segmentos. A árvore é construída através do comando `Segment_tree`

²Uma descrição mais detalhada da classe e exemplos podem ser encontrados em [CGAL, 2007a]

`_2.make_tree(InputList.begin(),InputList.end())`, onde `InputList` é uma lista de intervalos (os segmentos do mapa).

A implementação da CGAL para a *Segment Tree* apresenta algumas restrições. Para que se possa inserir um segmento na árvore, ele deve ser crescente em x e em y . Em um mapa não é possível determinar a posição e orientação dos segmentos - isso depende, obviamente, do terreno mapeado. Dessa forma, algumas adaptações no código foram necessárias. Considerando que (x_1, y_1) e (x_2, y_2) são as coordenadas das extremidades (*endpoints*) de um segmento, existem três situações em que o segmento não seria aceito pela classe:

- $x_1 > x_2$ e $y_1 > y_2$;
- $x_1 < x_2$ e $y_1 > y_2$;
- $x_1 > x_2$ e $y_1 < y_2$.

A primeira situação é simples de ser resolvida, pois tanto a coordenada x quanto a y decrescem, então, basta inverter os pontos x_1 com x_2 e y_1 com y_2 para que o intervalo seja crescente. A segunda e a terceira situações são um pouco mais complicadas, pois enquanto em um dos eixos a coordenada cresce, no outro eixo ela decresce.

Para solucionar esse problema, os segmentos identificados em uma dessas duas situações foram armazenados em uma lista separada de segmentos de entrada, tendo suas coordenadas em x espelhadas em torno de $x = 0$. Essa lista de segmentos invertidos foi armazenada em uma árvore separada.

A operação de busca dos segmentos que estão dentro ou interceptam uma determinada janela é feita utilizando o comando `Segment_tree_2.window_query(a, std::back_inserter(OutputList))`, onde “a” representa o intervalo que contém a janela de busca e `OutputList` é a lista dos segmentos que estão dentro da janela ou interceptam seus limites.

Para os segmentos que foram espelhados, a janela de busca também precisou ser espelhada em torno de $x = 0$. Assim, têm-se duas listas de segmentos de saída, e a união dessas duas listas resulta em todos os segmentos que interceptam ou estão

contidos na janela. A Figura 5.3 ilustra a utilização do espelho do segmento e da janela para torná-lo válido para a classe.




Figura 5.3: Segmentos originais e espelhados - a operação de espelhamento possibilita o uso da CGAL.

Outro problema ocorre quando há segmentos horizontais ou verticais. Para fazer com que esses segmentos sejam válidos, uma pequena perturbação em um dos pontos da coordenada inválida foi introduzida, de forma que eles ficassem ligeiramente crescentes, eliminando o problema.

A segunda etapa da implementação consistiu da escolha da forma mais adequada de se converter as informações do mapa em segmentos que pudessem ser trabalhados no programa desenvolvido. Como descrito na seção anterior, a metodologia adotada foi a conversão do arquivo DXF em arquivo “.poly”, por meio do programa FEMM 4.0.

O programa desenvolvido é responsável por ler o arquivo de entrada, construir a árvore de segmentos, buscar os segmentos dentro de uma janela de tamanho pré-definido e com centro no ponto em que se localiza o veículo e exibir essas informações graficamente em uma janela. A árvore de segmentos é construída apenas uma vez, no início da execução do programa. A busca é realizada sempre que o programa responsável pela exibição da interface recebe um valor de localização do programa responsável pela fusão sensorial. Os resultados da localização e da exibição da posição no mapa são apresentados na próxima seção.

5.3 Resultados

O sistema desenvolvido foi testado em experimentos dentro do campus da UFMG. Após a inicialização do algoritmo, as medidas recebidas no servidor UDP são utilizadas para a fusão sensorial, conforme explicado na Seção 5.1.

A configuração utilizada na fusão sensorial é feita de acordo com as medidas disponíveis no momento da inicialização. Para possibilitar o teste do sistema nas diferentes configurações, foi desenvolvida uma interface simples onde se pode selecionar quais os instrumentos serão utilizados na fusão sensorial. A Figura 5.4 apresenta essa interface, que também tem como objetivo a inicialização automática de todos os programas necessários para a utilização do sistema. Para isso, após a seleção dos instrumentos por meio das *checkboxes*, basta clicar sobre o botão “Inicia Navegação”. É possível notar na figura que os instrumentos GPS e IMU já estão previamente selecionados e bloqueados, pois eles são pré-requisitos necessários para o funcionamento do sistema.

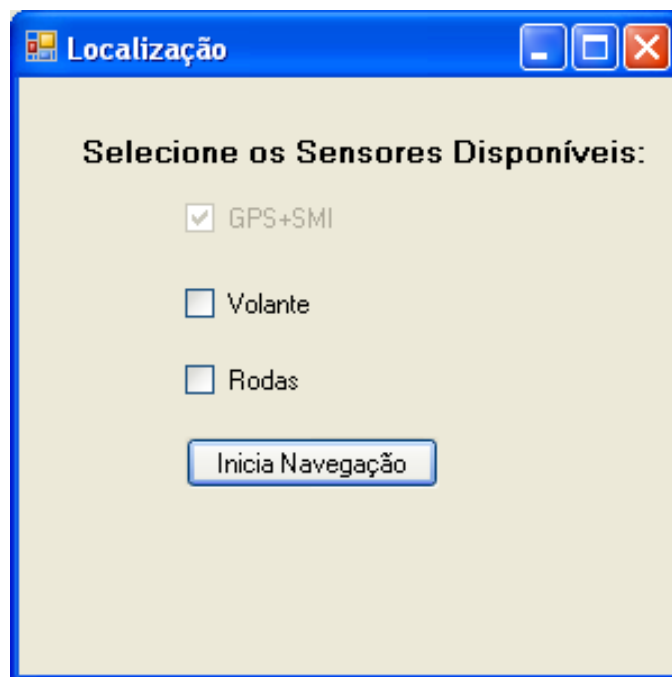


Figura 5.4: Janela para inicialização do sistema de localização.

Após realizado o cálculo da posição, da velocidade, da orientação e do *bias*, esses valores são armazenados em um arquivo para análise do desempenho do sistema e estão disponíveis para o envio para a interface de visualização do mapa ou para

o sistema de controle do veículo. Para a visualização no mapa, optou-se por enviar a posição do veículo uma vez a cada segundo. Esse envio é feito pelo programa de fusão sensorial ao programa de exibição por meio do protocolo TCP.

Ao receber a mensagem com a posição estimada, o programa responsável pela exibição da posição no mapa faz a busca dos segmentos próximos ao ponto recebido e exibe o ponto na tela. A Figura 5.5 apresenta um exemplo de exibição do ponto e da região em torno do ponto em um momento da trajetória realizada.




Figura 5.5: Janela de exibição da localização ao longo do trajeto.

Os pontos estimados, bem como os pontos recebidos pelo servidor referentes aos valores coletados pelo GPS foram armazenados em um arquivo para análise posterior. A Figura 5.6 exibe a trajetória estimada sobre o mapa em um experimento onde a localização foi feita durante o trajeto utilizando a Configuração 4. O gráfico apresentado na Figura 5.7 exibe a trajetória estimada *online*, as medições feitas pelo GPS e as elipses de confiança para essas medições.

É possível observar nas figuras apresentadas que a trajetória estimada obedeceu ao caminho realmente percorrido, porém, em alguns momentos, a posição estimada não seguiu as ruas mostradas no mapa. Diversos fatores podem influen-




Figura 5.6: Trajetória Exibida sobre o Mapa.




Figura 5.7: Trajetória Estimada Durante a Execução do Experimento.

ciar na divergência entre o mapa e a localização, tais como:

- Erro de estimação de posição e orientação inicial (fator crítico);
- Erro de conversão entre as coordenadas do mapa e o sistema de coordenadas da estimação;
- Imprecisões ou incoerência entre a representação no mapa e a realidade;
- Trechos com relevo acidentado, onde a inclinação do terreno poderia modificar a medida de aceleração e, ao longo do tempo, influenciar na estimação da posição;
- Trechos com vegetação muito densa, que podem influenciar na qualidade do sinal recebido pelo GPS, prejudicando a estimação de posição.

Apesar da divergência de alguns intervalos da trajetória com as ruas desenhadas no mapa, não é possível descartar como falsa a estimativa realizada *online*, pois, conforme apresentado na Figura 5.7, a trajetória estimada permaneceu no interior das elipses de confiança de incerteza do GPS.

5.4 Considerações Finais

A implementação da localização em tempo real mostrou que os resultados obtidos na reconstrução de trajetória *offline* são uma boa representação do comportamento do algoritmo, auxiliando na decisão da configuração mais adequada para a localização. Porém, ao trabalhar com os dados após a coleta não se pode prever a influência de eventos como pequenos atrasos no recebimento das medidas ou perda de pacotes de dados. Esses fatores fizeram com que o sistema apresentasse desempenho um pouco diferente do observado na reconstrução de trajetória, mas ainda assim, a fusão sensorial resultou em dados de posicionamento dentro dos limites de confiabilidade do sistema expressos pelas elipses de confiança em torno das medidas do GPS.

O uso de *Segment Trees* na aplicação mencionada se mostrou uma boa solução, uma vez que o algoritmo é eficiente, e realiza as buscas rapidamente. Após algumas alterações e um pré-processamento dos dados, foi possível utilizar o código da CGAL para a Segment Tree com todos os segmentos do mapa, após a separação

dos segmentos em duas sub-árvores de acordo com as coordenadas dos pontos final e inicial. A representação do mapa em segmentos permite o armazenamento do mapa utilizando pouco espaço de memória, uma vez que os segmentos são armazenados em um arquivo de texto.

Saída: Estimativa da posição, velocidade e orientação do veículo

início

```

se Há nova medida de aceleração então
  se Medida do Volante Disponível então
    Realiza predição com o modelo de Ackerman e aceleração no eixo  $x$ 
    para estimar velocidade;
    Calcula matriz de covariância da estimativa a priori;
    se Há nova medida de GPS então
      Realiza atualização da posição;
      Calcula o ganho de Kalman e a matriz de covariância da
      estimativa a posteriori;
    senão
      se Há informação de velocidade então
        Realiza atualização da velocidade;
        Calcula ganho de Kalman e matriz de covariância da
        estimativa a posteriori;
      fim
    fim
  senão
    Realiza predição com a Configuração 1;
    Calcula matriz de covariância da estimativa a priori;
    se Há nova medida de GPS então
      Realiza atualização da posição;
      Calcula ganho de Kalman e matriz de covariância da estimativa
      a posteriori;
    senão
      se Há informação de velocidade então
        Realiza atualização da velocidade;
        Calcula ganho de Kalman e matriz de covariância da
        estimativa a posteriori;
      fim
    fim
  fim
fim

```

Algoritmo 1: Algoritmo de Fusão Sensorial *Online*.

Capítulo 6

Discussão e Conclusões

6.1 Visão Geral do Trabalho Desenvolvido

Este trabalho teve como objetivo o desenvolvimento e implementação de um sistema computacional de localização e reconstrução de trajetórias de um automóvel a partir de dados ruidosos de diversos sensores. As etapas de desenvolvimento deste trabalho passaram pela escolha das grandezas utilizadas para a determinação da posição e orientação do veículo, a instalação física dos sensores necessários para se medir essas grandezas e a implementação de algoritmos para a fusão sensorial desses instrumentos.

Os sensores selecionados para a medição das variáveis foram um receptor GPS, que fornece a posição do veículo a cada segundo, uma unidade de medição inercial, que fornece orientação, aceleração linear e velocidade angular do veículo, um sensor de ângulo do volante, e dois sensores de velocidade das rodas dianteiras do veículo, conforme apresentado no Capítulo 3. O Capítulo 4 apresentou os resultados obtidos para a fusão sensorial *offline*. Esses resultados indicaram a configuração mais adequada, dentro das opções testadas, para a localização em tempo real, apresentada no Capítulo 5.

6.2 Principais Resultados Alcançados

Os resultados apresentados no Capítulo 4 a respeito da reconstrução de trajetórias realizadas pelo automóvel mostraram que é possível se estimar a localização do veículo com incerteza inferior à incerteza associada à medida de GPS e a uma taxa de

amostragem superior à do GPS. A quarta configuração de sensores e modelos utilizada (ver Tabela 4.1) apresentou um desempenho em que a incerteza da estimação permaneceu inferior à do GPS mesmo em situações em que a informação proveniente do receptor GPS estava indisponível por até cinco segundos. Foi possível verificar, a partir de experimentos, que a informação de orientação fornecida pelo sistema inercial não deveria ser utilizada nos algoritmos de fusão testados, pois essa informação é de baixa qualidade e sua contribuição para a estimação dos estados não foi significativa. A partir desses resultados foi possível definir a configuração mais adequada, dentre as analisadas, para a utilização na localização em tempo real.

A estimação da trajetória do veículo em tempo real se mostrou viável, conforme apresentado no Capítulo 5. Os algoritmos de fusão sensorial foram implementados no ambiente de programação Visual C++ para a integração das medidas dos sensores de acordo com sua disponibilidade. Os resultados mostraram que a utilização desse sistema para o controle automático, a ser implementado futuramente, é possível, pois seu desempenho mostrou-se superior àquele obtido usando apenas um dos sensores. Para facilitar a visualização dos resultados, foi implementada uma interface gráfica que representa a área percorrida em um mapa e informa a posição do veículo à medida em que ele se movimenta. Essa interface foi desenvolvida com o uso da biblioteca CGAL [CGAL, 2007b].

Alguns dos resultados deste trabalho foram publicados em dois congressos, o Workshop RoboControl'09, em Bauru-SP [Santos et al., 2008] e o IX SBAI (Simpósio Brasileiro de Automação Inteligente), em Brasília-DF [Freitas et al., 2009].

6.3 Trabalhos Futuros

Algumas melhorias podem ser incorporadas ao sistema, com a adição de novos sensores ou modificações no algoritmo de fusão. O uso do receptor GPS como único sensor que informa a posição global do veículo faz com que o sistema dependa fortemente dessa medida. Dessa maneira, a inclusão de um novo sensor de posição poderia tornar o sistema mais robusto aos erros provenientes do GPS. Para isso, poderia ser utilizado, por exemplo, o reconhecimento de marcos visuais posicionados no terreno utilizando técnicas de Visão Computacional. A partir da visualização

desses marcos por uma câmera instalada no veículo e do conhecimento da posição onde foram instalados, é possível se obter a posição e orientação do veículo (ou da câmera). A desvantagem desse método é a possibilidade de utilização apenas em ambientes onde se tenha instalado previamente esses marcos visuais.

A utilização de um sensor de orientação que não seja baseado no campo magnético da Terra poderia trazer melhorias à estimação da orientação do veículo e, por consequência, melhorar a estimação da posição. Para obter a orientação, poderia ser utilizado o mesmo sensor de marcos visuais, que pode fornecer, além da posição, a orientação da câmera em relação ao alvo preso ao ambiente. Com o uso de um sensor desse tipo seria possível minimizar erros de integração do modelo observados na predição de atitude.

O uso de um sensor de posição global mais preciso que o receptor GPS utilizado, como por exemplo um GPS diferencial, traria ao sistema maior precisão na estimativa de posição. Além disso, a análise dos resultados seria favorecida pelo uso de um padrão de comparação mais confiável.

Outros algoritmos de fusão sensorial poderiam ser utilizados para a localização do veículo, como por exemplo, o filtro de Kalman *unscented* (UKF) ou o filtro de partículas. Esse último algoritmo demanda um maior processamento pois se baseia no cálculo de diversas estimativas (as partículas) para se obter a estimativa de estados em cada iteração. Neste trabalho, o requisito inicial era que todo o processamento e visualização em uma interface gráfica fosse realizado em um mesmo computador portátil e, por isso, a alternativa do filtro de partículas não se mostrou viável para esta aplicação. Esse requisito poderia ser contornado com a distribuição das etapas de processamento em outros computadores, distribuindo cada parte do sistema (coleta de dados, fusão sensorial, interface gráfica) em um processador dedicado. O algoritmo do UKF, por outro lado, poderia conduzir os testes a melhores resultados com o custo computacional comparável ao EKF.

Por fim, outra possibilidade para a melhoria do desempenho do sistema é a utilização de mapas no algoritmo de localização, agregando informações geográficas, como o desenho das ruas e prédios, o relevo do terreno, por exemplo, à estimação de posição. Nesse caso, o mapa seria utilizado como mais um dos sensores para a fusão sensorial.

Bibliografia

- [Adams, 2002] Adams, C. (2002). Is “dead reckoning” short for “deduced reckoning”? Disponível em: <http://www.straightdope.com/columns/read/2053/is-dead-reckoning-short-for-deduced-reckoning>. Acesso em: dez/2007.
- [Aguirre, 2007] Aguirre, L. A. (2007). *Introdução à Identificação de Sistemas*. Ed. Campus, 3rd. edition.
- [Barshan & Durrant-Whyte, 1995] Barshan, B. & Durrant-Whyte, H. (1995). Inertial navigation systems for mobile robots. pages 328–342.
- [Betke, 2001] Betke, K. (2001). The nmea 0183 protocol.
- [Bonnifait et al., 2003] Bonnifait, P., Bouron, P., Meizel, D., & Crubillé, P. (2003). Dynamic localization of car-like vehicles using data fusion of redundant abs sensors. *The Journal of Navigation*, 3(56):429–441.
- [Borenstein et al., 1996a] Borenstein, J., Everett, H. R., & Feng, L. (1996a). *Where am I? Sensors and Methods for Mobile Robot Positioning*. University of Michigan.
- [Borenstein et al., 1997] Borenstein, J., Everett, H. R., Feng, L., & Wehe, D. (1997). Mobile robot positioning: Sensors and techniques. *Journal of Robotic Systems*, 14,4:231–249.
- [Borenstein et al., 1996b] Borenstein, J., Feng, L., & Borenstein, C. J. (1996b). Measurement and correction of systematic odometry errors in mobile robots. *IEEE Transactions on Robotics and Automation*, 12:869–880.
- [Bowditch, 1995] Bowditch, N. (1995). *The American Practical Navigator: An Epitome of Navigation*. National Imagery and Mapping Agency.

- [Braid et al., 2006] Braid, D., Broggi, A., & Schmiedel, G. (2006). The terramax autonomous vehicle. *Journal of Field Robotics*, 23(9):693–708.
- [Brown & Hwang, 1997] Brown, R. G. & Hwang, P. Y. C. (1997). *Introduction to random signals and applied Kalman filtering: with MATLAB exercises and solutions*. Wiley.
- [Buehler et al., 2008] Buehler, M., Iagnemma, K., & Singh, S. (2008). Editorial. *J. Field Robot.*, 25(9):567–568.
- [Caron et al., 2006] Caron, F., Duflos, E., Pomorski, D., & Vanheeghe, P. (2006). Gps/imu data fusion using multisensor kalman filtering: introduction of contextual aspects. *Information Fusion*, 7:221–230.
- [Carr, 2004] Carr, G. (2004). Technical paper for team ensco darpa grand challenge.
- [Carr & Mee, 2005] Carr, G. & Mee, B. (2005). Darpa grand challenge 2005 team ensco’s dexter.
- [CGAL, 2007a] CGAL (2007a). Chapter 46 - dd range and segment trees. Disponível em: http://www.cgal.org/Manual/3.3/doc_html/cgal_manual/SearchStructures/Chapter_main.html#Subsection_46.6.1.
- [CGAL, 2007b] CGAL (2007b). User and reference manual: All parts. Disponível em: http://www.cgal.org/Manual/3.3/doc_html/cgal_manual/title.html.
- [Choset et al., 2005] Choset, H., Lynch, K. M., Hutchinson, S., Kantor, G., Burgard, W., Kavraki, L. E., & Thrun, S. (2005). *Principles of Robot Motion*. The MIT Press.
- [Cox, 1990] Cox, I. J. (1990). Blanche: position estimation for an autonomous robot vehicle. pages 221–228.
- [Cremean et al., 2006] Cremean, L. B., Foote, T. B., Gillula, J. H., Hines, G. H., Kogan, D., Kriechbaum, K. L., Lamb, J. C., Leibs, J., Lindzey, L., Rasmussen, C. E., Stewart, A. D., Burdick, J. W., & Murray, R. M. (2006). Alice: An information-rich autonomous vehicle for high-speed desert navigation. *Journal of Field Robotics*, 23(9):777–810.

- [Dahlkamp et al., 2004] Dahlkamp, H., Pece, A. E., Ottlik, A., & Nagel, H.-H. (2004). Differential analysis of two model-based vehicle tracking approaches. *Lecture Notes in Computer Science*, 3175:71–78.
- [Dana, 1994] Dana, P. H. (1994). Utm zones. Disponível em: <http://www.colorado.edu/geography/gcraft/notes/coordsys/coordsys.bak3>.
- [DARPA, 2004] DARPA (2004). Darpa grand challenge - autonomous ground vehicles. Disponível em: <http://www.darpa.mil/grandchallenge04/index.htm>.
- [de Berg et al., 2000] de Berg, M., van Kreveld, M., Overmars, M., & Schwarzkopf, O. (2000). *Computational Geometry: Algorithms and Applications*. Springer-Verlag, 2nd. edition.
- [Fang et al., 2006] Fang, F., Ma, X., & Dai, X. (2006). Mobile robot localization based on improved model matching in hough space. In *Intelligent Robots and Systems, 2006 IEEE/RSJ International Conference on*, pages 1541–1546.
- [Fonseca, 1999] Fonseca, J. F. C. (1999). Aplicação de técnicas de fusão/integração sensorial de dados no levantamento de relevo de objectos. Tese de Doutorado. Universidade do Minho, Portugal.
- [Fravert, 2004] Fravert, J. (2004). Darpa grand challenge – technical paper for terramax.
- [Freitas et al., 2009] Freitas, E. J. R., Vinti, M. N. W., Santos, M. M., Iscoldi, P., Torres, L. A. B., & Pereira, G. A. S. (2009). Desenvolvimento de automação embarcada para um robô móvel baseado em um carro de passeio. In *Anais do IX Simpósio Brasileiro de Automação Inteligente*, volume 9, Brasília, Brasil.
- [Garmin, 2005] Garmin, I. I. (2005). Gps 18 technical specifications. Disponível em: <http://www.garmin.com>.
- [Grewal et al., 2007] Grewal, M. S., Weil, L. R., & Andrews, A. P. (2007). *Global Positioning Systems, Inertial Navigation and Integration*. Wiley, second edition.
- [Gunthner, 2004] Gunthner, P. (2004). Technical paper addendum for darpa grand challenge.

- [Hofmann-Wellenhof et al., 1997] Hofmann-Wellenhof, B., Lichtenegger, H., & J. (1997). *Global Positioning Systems: Theory and Practice*. Springer-Verlag Wien New York, 4th. edition.
- [Ivanjko et al., 2005] Ivanjko, E., Vasak, M., & Petrovic, I. (2005). Kalman filter theory based mobile robot pose tracking using occupancy grid maps. In *International Conference of Control and Automation (ICCA '05)*, volume 2, pages 869 – 874.
- [Jazwinski, 1970] Jazwinski, A. H. (1970). *Stochastic Processes and Filtering Theory*. Academic Press, Inc., New York, NY, USA.
- [Jiang & Nijmeijer, 1997] Jiang, Z. & Nijmeijer, D. H. (1997). Tracking control of mobile robots: a case study in backstepping. *Automatica*, 33(7):1393–1399.
- [Julier & Uhlmann, 2004] Julier, S. J. & Uhlmann, J. K. (2004). Unscented filtering and nonlinear estimation. In *Proceedings of the IEEE*, volume 92, pages 401–422.
- [Kalman, 1960] Kalman, R. E. (1960). A new approach to linear filtering and prediction problems. *Transactions of the ASME - Journal of Basic Engineering*, pages 35–45.
- [Kehaly et al., 2004] Kehaly, B., O'Briant, J., Dumas, M., Jones, G., Doyle, T., Kalling, R., Bickett, R., Kimmelman, P., Farrar, M., & Rini, B. (2004). Axiom racing darpa grand challenge – final technical paper.
- [Kehaly et al., 2005] Kehaly, B., O'Briant, J., Dumas, M., Jones, G., Doyle, T., Kalling, R., III, G. S., Pollock, J., Chenu, J., Phillips, W., Jones, M., Redhair, D., Kimmelman, P., Khattar, P., Idarto, A., Kehaly, T., Jones, P., Eichberger, G., Guest, C., Ehlers, B., & Kehaly, R. (2005). Darpa grand challenge 2005 technical paper.
- [Li et al., 2006] Li, Y., Wang, J., Rizos, C., Mumford, P., & Ding, W. (2006). Low-cost tightly coupled gps/ins integration based on a nonlinear kalman filtering design. *National Technical Meeting of the Institute of Navigation*, pages 958–966.

- [Lin et al., 2004] Lin, Y., Huang, Y., & Shi, E. (2004). Application of data fusion algorithm based on kalman filter in mobile robot position measuring system. *Fifth World Congress of Intelligent Control and Automation (WCICA 2004)*, 6:4956 – 4959.
- [Luo & Kay, 1989] Luo, R. & Kay, M. (1989). Multisensor integration and fusion in intelligent systems. *Systems, Man and Cybernetics, IEEE Transactions on*, 19(5):901–931.
- [Mason, 2004] Mason, R. (2004). The golem group.
- [Mason et al., 2006] Mason, R., Radford, J., Kumar, D., Walters, R., Fulkerson, B., Jones, E., Caldwell, D., Meltzer, J., Alon, Y., Shashua, A., Hattori, H., Frazzoli, E., & Soatto, S. (2006). The golem group/university of california at los angeles autonomous ground vehicle in the darpa grand challenge. *Journal of Field Robotics*, 23(8):527–553.
- [Maybeck, 1979] Maybeck, P. S. (1979). *Stochastic models, estimation, and control*, volume 141 of *Mathematics in Science and Engineering*.
- [MicroStrain, 2006] MicroStrain (2006). Technical product overview. Disponível em: <http://www.microstrain.com>.
- [Montemerlo et al., 2008] 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*, 25(9):569–597.
- [Moreira et al., 2007] Moreira, M. A. G., Machado, H. N. and de Castro Mendonça, C. F., & Pereira, G. A. (2007). Mobile robot outdoor localization using planar beacons and visual improved odometry. *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS'07)*, pages 2468–2473.

- [Negenborn, 2003] Negenborn, R. (2003). Robot localization and kalman filters: On finding your position in a noisy world. Master's project, Utrecht University, Institute of Information and Computing Sciences.
- [NMEA, 2009] NMEA (2009). National marine electronics association homepage. Disponível em: <http://www.nmea.org>.
- [Pak, 2007] Pak, E. (2007). Gps constellation. Disponível em: <http://en.wikipedia.org/wiki/File:ConstellationGPS.gif>.
- [Panzieri et al., 2005] Panzieri, S., Pascucci, F., & Setola, R. (2005). Interlaced extended kalman filter for real time navigation. *International Conference of Intelligent Robots and Systems (IROS 2005)*, pages 2780 – 2785.
- [Papoulis & Pillai, 2001] Papoulis & Pillai (2001). *Probability, Random Variables and Stochastic Processes*. Boston: McGraw-Hill Science/Engineering/Math, 4th. edition.
- [Porter et al., 2005] Porter, J., Behringer, R., Elsley, R., Guthmiller, W., Bostrup, G., Jr., R. A., Knoedler, K., Khoshnevisan, M., Bevly, D., Daily, R., Travis, W., Kubinger, W., & Dilley, R. (2005). The autonomous ground vehicle rascal: Team sciautronics/auburn engineering in the darpa grand challenge 2005.
- [Randall, 2004] Randall, G. (2004). Insight racing darpa grand challenge – final technical paper.
- [Randall et al., 2005] Randall, G., Caldwell, K., Dean, B., Kuekes, S., Randall, M., Rhinehart, M., Shanley, B., Sliva, W., & Bhatia, A. (2005). Insight racing technical paper darpa grand challenge 2005.
- [Rios Neto & Hemerly, 2007] Rios Neto, A. & Hemerly, E. M. (2007). *Observadores de Estado e Filtro de Kalman*, volume 3, pages 158–181. EDITORA BLUCHER.
- [Ronback, 2000] Ronback, S. (2000). Developmento of a ins/gps navigation loop. Master's project, Lulea Tekniska Universitet, Institutionen for Systemteknik Avdelningen for Robotik och automation.

- [Roumeliotis & Bekey, 1997] Roumeliotis, S. & Bekey, G. (1997). An extended kalman filter for frequent local and infrequent global sensor data fusion. *International Symposium on Intelligent Systems (SPIE)*.
- [Santos et al., 2008] Santos, M. M., Freitas, E. J. R., Vinti, M. N. W., Iscoldi, P., Torres, L. A. B., & Pereira, G. A. S. (2008). Automation and localization of a robotic car. In *Proc. Workshop Robocontrol'08 - 3rd. Applied Robotics and Collaborative Systems Engineering*, Bauru, Brasil.
- [Shewchuk, 2008] Shewchuk, J. R. (2008). .poly files. Disponível em: <http://www-2.cs.cmu.edu/quake/triangle.poly.html>.
- [Singhal, 1997] Singhal, A. (1997). Issues in autonomous mobile robot navigation. Technical report, University of Rochester.
- [Stuck & Kuga, 2005] Stuck, B. M. & Kuga, H. K. (2005). Medindo distâncias através de um único receptor gps. *Instituto Nacional de Pesquisas Espaciais - INPE-12331-NTC/321*.
- [Teixeira, 2008] Teixeira, B. O. S. (2008). Estimaco de estados com restrioes para sistemas dinâmicos lineares e não-lineares. Tese de Doutorado PPGEE/UFMG.
- [Thrun et al., 2005] Thrun, S., Burgard, W., & Fox, D. (2005). *Probabilistic Robotics*. The MIT Press.
- [Thrun et al., 2006] 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 Niekerc, 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*, 23(9):661–692.
- [Urmson et al., 2008] Urmson, C., Anhalt, J., Bagnell, D., Baker, C., Bittner, R., Clark, M. N., Dolan, J., Duggins, D., Galatali, T., Geyer, C., Gittleman, M., Harbaugh, S., Hebert, M., Howard, T. M., Kolski, S., Kelly, A., Likhachev, M.,

- McNaughton, M., Miller, N., Peterson, K., Pilnick, B., Rajkumar, R., Rybski, P., Salesky, B., Seo, Y.-W., Singh, S., Snider, J., Stentz, A., Whittaker, W. R., Wolkowicki, Z., Ziglar, J., Bae, H., Brown, T., Demitrish, D., Litkouhi, B., Nickolaou, J., Sadekar, V., Zhang, W., Struble, J., Taylor, M., Darms, M., & Ferguson, D. (2008). Autonomous driving in urban environments: Boss and the urban challenge. *J. Field Robot.*, 25(8):425–466.
- [van Gogh et al., 2004] van Gogh, D. A., Craig, A., Fischer, K., Somers, A., Klima, K., Bansal, A., Rogers, L., Liu, C. J., Breuer, L., Chrystal, C., Pacey, M., West, G., Crowley, M., Ristroph, G., Thielman, M., Huang, H. H., Cram, P., Gremmer, I., White, R., Salazar, J., Velez, R., Wilbur, J., Fleming, S., Raycroft, J., Berardi, S., Sue, J. C., Hong, A., Cox, J., Consort, T., Lamb, J., Vanderslice, T., Gillula, J., Coulter, W., Cohen, J., Heltsley, W., Koehler, J., & Mousavi, Z. (2004). Darpa grand challenge – final technical paper.
- [Welch & Bishop, 2006] Welch, G. & Bishop, G. (2006). An introduction to the kalman filter. Technical report, University of North Carolina at Chapel Hill.
- [Whittaker, 2004] Whittaker, W. R. L. (2004). Read team darpa grand challenge – final technical paper.
- [Whittaker, 2005] Whittaker, W. R. L. (2005). Darpa grand challenge 2005 technical paper.
- [Zhang et al., 2005] Zhang, P., Gu, J., Milios, E. E., & Huynh, P. (2005). Navigation with imu/gps/digital compass with unscented kalman filter. *Proceedings of IEEE International Conference on Mechatronics and Automation, Niagara Falls, Canada*, pages 1497–1502.
- [Zhou & Bolandhemmat, 2007] Zhou, J. & Bolandhemmat, H. (2007). Integrated ins/gps system for an autonomous mobile vehicle. *International Conference on Mechatronics and Automation (ICMA 2007)*, pages 694–699.

Apêndice A

Sistema de Posicionamento Global (GPS) - Funcionamento

Este apêndice visa abordar alguns aspectos do funcionamento de um sistema GPS (*Global Positioning System*). O funcionamento desse sistema é baseado no tempo gasto para que um sinal emitido por um determinado satélite chegue ao receptor. A partir do conhecimento desse tempo e utilizando a técnica de triangulação, o receptor pode calcular a sua posição.

A.1 Cálculo da Posição do Receptor - Triangulação dos Satélites

Para calcular sua posição, o receptor GPS recebe sinais de rádio de diversos satélites. Cada satélite envia informações a respeito de sua posição ao redor da Terra e do tempo de emissão daquele sinal por meio de uma sequência de bits pseudo-aleatória. O receptor, então, pode calcular a diferença entre o tempo em que um sinal foi transmitido (t_T) e o tempo em que o sinal foi recebido (t_R). Os sinais de rádio são ondas eletromagnéticas e, portanto, trafegam à velocidade da luz (c_0). De posse desses valores, é possível calcular a distância entre o satélite e o receptor ($d = c_0(t_R - t_T)$). O conhecimento dessa distância possibilita saber que o receptor está em uma esfera centrada no satélite e com raio igual a essa distância. Tem-se, portanto, infinitas soluções para a posição do receptor (Figura A.1).

O conhecimento da distância do receptor a dois satélites reduz o número de possibilidades para a posição do receptor para uma circunferência resultante da

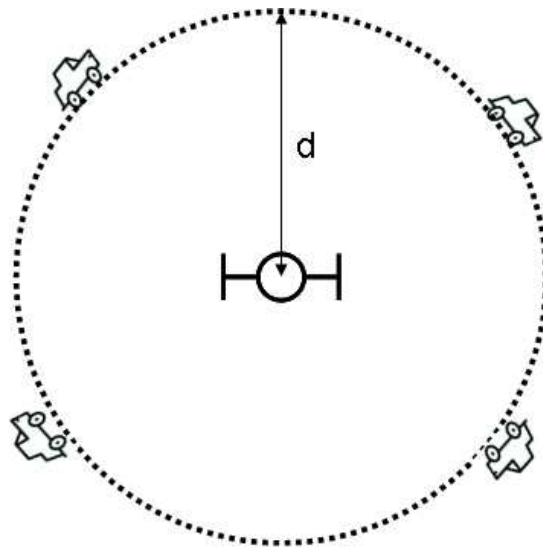


Figura A.1: Localização do receptor - infinitas possibilidades.

interseção de duas esferas, porém, ainda se tem infinitas possibilidades para a posição do receptor (Figura A.2).




Figura A.2: Localização do receptor - uma circunferência de possibilidades.

Ao obter a informação de distância do receptor a mais um satélite, totalizando três distâncias, é possível reduzir esse número de possibilidades para um, pois a esfera resultante da distância do terceiro satélite deve, necessariamente, tangenciar a circunferência formada pela interseção das outras duas esferas (Figura A.3).

Dessa forma, o cálculo da posição do receptor a partir do conhecimento de sua distância a, pelo menos, três satélites é chamado triangulação de satélites. É im-




Figura A.3: Localização do receptor - triangulação.

portante ressaltar que essa seria uma situação ideal. Na realidade, devido aos ruídos existentes nesse sistema, nem sempre a interseção entre as três circunferências ocorre em um ponto. A ocorrência desses ruídos ocasiona em erros no posicionamento. Os erros na informação de localização por satélite podem ter origem em diversas fontes, como:

- Multicaminhamento;
- Atrasos na ionosfera;
- Atrasos na troposfera;
- Atenuação do sinal;
- Erro no relógio do satélite;
- Erro no relógio do receptor.

A Figura A.4 ilustra esses erros. Uma forma de se obter uma medida da dispersão do erro em torno da posição informada pelo receptor é o cálculo da Diluição da Precisão, que é apresentado na seção seguinte.




Figura A.4: Fontes de Erro na Localização por GPS. Adaptado de [Ronnback, 2000]

Para corrigir esses problemas, deve-se lançar mão de outras técnicas que visam determinar apenas um ponto de localização do receptor. Os erros relativos à diferença dos relógios é normalmente corrigido com a utilização do sinal de mais um satélite, totalizando quatro satélites para uma medida mais precisa da posição do receptor. O sinal desse quarto satélite é utilizado para estimar a correção do *bias* do relógio (Cbr). Dessa forma, tem-se quatro incógnitas (P_x , P_y , P_z e Cbr) e informação de distância de quatro satélites ao receptor. [Grewal et al., 2007]

A.2 Diluição da Precisão

A precisão da posição determinada por um receptor GPS está relacionada com dois fatores: (i) a qualidade da medida de distância entre o satélite e o receptor; (ii) geometria da configuração dos satélites no momento da observação. A Figura A.5 sugere que quanto mais próximos estiverem os satélites observados pelo receptor, maior será a área de incerteza do posicionamento.

A Diluição da Precisão (*Dilution Of Precision* - DOP) em um sistema GPS é




Figura A.5: Incerteza no posicionamento fornecido pelo receptor GPS de acordo com a geometria da configuração dos satélites.

um valor escalar que quantifica a influência da configuração geométrica da constelação de satélites visto pelo receptor em um dado instante na precisão da informação de posição fornecida por esse sensor. A Diluição da Precisão pode ser calculada em função de parâmetros geométricos e do tempo. Os tipos de Diluição da Precisão mais comuns são:

- VDOP - Diluição da Precisão Vertical (altura);
- HDOP - Diluição da Precisão Horizontal (plano 2D);
- PDOP - Diluição da Precisão da Posição (3D);
- TDOP - Diluição da Precisão do Tempo;
- GDOP - Diluição da Precisão Geométrica (Posição 3D e Tempo);

Os valores da Diluição da Precisão podem ser obtidos, de forma geral, a partir da raiz quadrada da soma dos quadrados dos semi-eixos das elipses de confiança correspondentes aos parâmetros envolvidos no DOP calculado (por exemplo, para calcular o HDOP é necessário obter a distância ao centro da elipse de confiança ao longo dos dois eixos do plano 2D que compõem a direção horizontal). Assim, o valor de um DOP pode ser considerado como uma medida da região de confiança de um parâmetro. A expressão que relaciona os DOPs é dada por:

$$GDOP^2 = PDOP^2 + TDOP^2 = HDOP^2 + VDOP^2 + TDOP^2. \quad (A.1)$$

O valor da Diluição da Precisão é uma estimativa da qualidade da medição fornecida pelo receptor relacionada com a geometria da configuração dos satélites a cada instante. O valor do DOP varia com o tempo, uma vez que os satélites vistos pelo receptor mudam ao longo do tempo. Para que a precisão seja a melhor possível, o valor de DOP deve ser o menor possível e ele deve ser multiplicado à incerteza da medida para se obter a incerteza total da posição.

Apêndice B

Especificações Técnicas de Alguns Instrumentos

Este apêndice tem o objetivo de trazer informações complementares, consideradas relevantes no desenvolvimento deste trabalho, sobre dois dos instrumentos utilizados – o receptor GPS e o Sistema de Medições Inerciais. Para informação mais detalhada sobre esses sensores, deve-se consultar os manuais dos produtos: [Garmin, 2005] e [MicroStrain, 2006].

B.1 GPS

O receptor utilizado nos experimentos deste trabalho foi o modelo 18PC da Garmin [Garmin, 2005]. Esse modelo de receptor GPS conta com uma saída serial (RS232, 4800 bps) que pode ser conectada a um computador para aquisição dos dados. As informações são transmitidas ao computador em forma de mensagens no protocolo NMEA. [NMEA, 2009] As mensagens desse protocolo têm um formato característico: toda mensagem se inicia com o símbolo \$; os cinco caracteres seguintes identificam o tipo de mensagem; os demais caracteres são a informação, que varia de acordo com o tipo de mensagem - os valores da informação são separados por vírgulas. A Figura B.1 mostra uma mensagem muito utilizada para navegação, que contém informação de latitude, longitude, número de satélites, entre outras.

Além dessas informações, o receptor GPS pode fornecer mensagens com o índice de cada satélite que está dentro de sua visada, velocidade do receptor (apenas os modelos Garmin, pois a mensagem que contém essa informação é proprietária),

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16

\$GPGGA,hhmmss,IIII.II,a,yyyyy.yy,a,x,xx,x.x,x.x,M,x.x,M,x.x,xxxx*hh

- 1) Tipo da mensagem
- 2) Hora, minutos e segundos (UTC)
- 3) Latitude
- 4) N ou S (Norte ou Sul)
- 5) Longitude
- 6) E or W (Leste ou Oeste)
- 7) Indicador de Qualidade do GPS:
 - 0 – fix não disponível,
 - 1 – GPS fix,
 - 2 – Differential GPS fix
- 8) Numero de satélites em visada: 00 – 12
- 9) Diluição da Precisão Horizontal (HDOP)
- 10) Altitude da antena – abaixo ou acima do nível do mar
- 11) Unidade da altitude da antena: metros
- 12) Separação geoidal
- 13) Unidade da separação geoidal: metros
- 14) Campo utilizado apenas para GPS diferencial
- 15) Estação de referência para GPS diferencial: 0000–1023
- 16) Checksum

Figura B.1: Mensagem do tipo GPGGA do Protocolo NMEA.

diluição da precisão, elevação do receptor, etc.

A alimentação desse receptor é feita pela própria bateria do automóvel. O instrumento é dotado de um conector para isqueiro veicular e pode ser alimentado com valores de tensão entre 8 e 15 Volts.

A precisão da posição no modo padrão de utilização desse receptor é de 15 metros. O receptor utilizado também pode operar no modo WAAS (*Wide-Area Augmentation System*), em que a precisão na posição é de 3 metros, porém, esse modo só está disponível para utilização nos países localizados no hemisfério norte da Terra.

B.2 Sistema de Medições Inerciais

O Sistema de Medições Inerciais utilizado foi o modelo 3DM-GX1 da Microstrain [MicroStrain, 2006]. Esse sensor conta, além dos acelerômetros e girômetros, com magnetômetros que possibilitam o fornecimento de informação de orientação, além das acelerações e velocidades angulares. Os dados fornecidos por esse instrumento são pré-processados por meio de filtros digitais e compensação de temperatura. A

Figura B.2 apresenta a estrutura desse sistema.

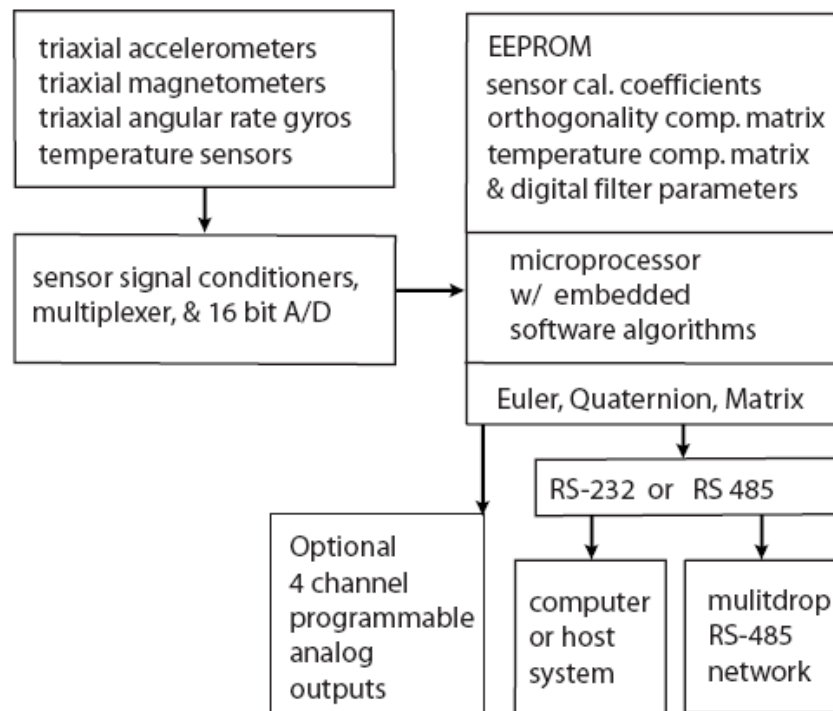


Figura B.2: Estrutura de processamento do sistema inercial Microstrain [MicroStrain, 2006].

As informações referentes às características físicas dos instrumentos são apresentadas na Tabela B.1.

Tabela B.1: Características físicas do sistema de medidas inerciais Microstrain.

Tensão de alimentação	5,2 VDC (mínimo), 12 VDC (máximo)
Corrente de alimentação	65 mA
Temperatura de operação	-40 to +70°C com invólucro -40 to +85°C sem invólucro
Dimensões	64 mm x 90 mm x 25 mm
Peso	75 grams
Range da orientação (pitch, roll, yaw)	$\pm 90^\circ$, $\pm 180^\circ$, $\pm 1800^\circ$
Range dos sensores	gyros: $\pm 300^\circ/sec$ acelerômetros: $\pm 5g$ magnetômetros: $\pm 1,2 Gauss$

Apêndice C

Janelamento de Segmentos

O janelamento de segmentos consiste na determinação de quais segmentos estão contidos ou interceptam uma determinada janela retangular. Existem alguns métodos eficientes para lidar com o janelamento de segmentos. Dentre eles, pode-se citar [de Berg et al., 2000]:

- *Interval Tree*, que armazena os segmentos em uma árvore de intervalos e busca segmentos que interceptam ou estão dentro de uma janela, porém encontra apenas segmentos paralelos aos limites da janela;
- *Priority Tree*, que, assim como na *Interval Tree*, é adequada para segmentos paralelos aos limites da janela, porém o tempo de busca é $O(1 + k)$, enquanto na *Interval Tree* é $O(\log(n) + k)$, onde n é número total de segmentos e k é o número de segmentos encontrados;
- *Segment Tree*, que pode ser utilizada para segmentos com orientação arbitrária e busca os segmentos com custo computacional de $O(\log(n) + k)$ no pior caso.

Mapas possuem segmentos com orientações arbitrárias e, por isso, o uso de *Interval Tree* ou *Priority Tree* para armazená-los não pode ser aplicado diretamente, pois essas estruturas são adequadas a segmentos paralelos aos limites da janela de busca. Para buscar segmentos com orientação arbitrária utilizando um desses algoritmos, pode-se pensar em verificar a interseção da janela de busca com o mínimo retângulo envolvente de cada segmento, em vez do próprio segmento e, em caso de interseção, verificar se o segmento realmente intercepta a janela (Figura C.1).

Porém, no pior caso, seria necessário verificar a interseção em todos os segmentos (Figura C.2).




Figura C.1: Busca de segmentos pelo mínimo retângulo envolvente - retângulos são traçados em torno dos segmentos de orientação arbitrária e então, a verificação de interseção é feita entre os lados dos retângulos e a janela de busca.




Figura C.2: Busca de segmentos pelo mínimo retângulo envolvente (Pior Caso). Nesse caso, a busca seria efetuada em todos os retângulos, porém, nenhum dos segmentos interceptam a janela de busca.

Observando todas essas características, foi possível verificar que o algoritmo mais adequado a um mapa, que possui segmentos em orientações diversas, é a *Segment Tree*, que é detalhada a seguir.

Segment Tree

A *Árvore de Segmentos* (*Segment Tree*) é uma estrutura de dados que armazena os segmentos em uma árvore binária de forma a facilitar a busca dos segmentos que

interceptam a janela de busca. O algoritmo de construção dessa árvore é explicado aqui para a interseção entre os segmentos e um dos limites verticais da janela. Para a interseção com os limites horizontais pode-se proceder de forma análoga.

Seja $S = s_1, s_2, s_3, \dots, s_n$ um conjunto de segmentos que não se interceptam, mas podem possuir uma das extremidades (*endpoint*) em comum. Então, pode-se definir um conjunto de intervalos elementares (conjunto E) formado pelas abscissas dos *endpoints* dos segmentos do conjunto S (Figura C.3), conforme:

$$E = \{(-\infty : p_1), [p_1 : p_1], (p_1 : p_2), [p_2 : p_2], \dots, (p_{m-1} : p_m), [p_m : p_m], (p_m : +\infty)\}. \quad (C.1)$$




Figura C.3: Intervalos Elementares.

Seja q um dos segmentos limites verticais da janela de busca e q_x a abscissa desse segmento (Figura C.4). Para encontrar os intervalos que contém q_x , deve-se construir uma árvore de busca binária T , cujas folhas correspondam aos intervalos elementares. O esqueleto de uma Segment Tree é uma árvore binária balanceada. As folhas de T correspondem aos intervalos elementares ordenados (Figura C.5). Os nós internos de T correspondem aos intervalos que são a união de intervalos elementares (um nó pai é a união de seus nós filhos). Dessa forma, se ν é um nó interno de T , um segmento está no subconjunto canônico de ν se ele cruza completamente os intervalos pertencentes a ν e não cruza todos os intervalos do seu nó pai, como mostra a Figura C.6. Na Figura C.5 pode-se observar, também, que um intervalo qualquer é armazenado no conjunto de intervalos, no máximo, em dois nós no mesmo nível de uma árvore (ver exemplo do segmento s_1).

O algoritmo de construção de uma Segment Tree pode ser descrito como apresentado no Algoritmo 2.




Figura C.4: Interseção dos segmentos com um dos limites verticais da janela de busca.




Figura C.5: Esqueleto da *Segment Tree*.

Utilizando a estrutura da *Segment Tree*, um intervalo aparece, no máximo, duas vezes em cada nível da árvore, então, o total de armazenamentos na árvore é $O(n \log(n))$, bem como o tempo de construção da árvore.

O algoritmo de busca em uma *Segment Tree* tem custo computacional $O(\log(n) +$




Figura C.6: Subconjuntos Pertencentes a um Nó.

Entrada: A raiz de uma árvore (ou sub-árvore) de segmentos e um intervalo

Saída: O intervalo será inserido na sub-árvore

início

se $Int(\nu) \subseteq [x : x']$ então

| armazena $[x : x']$ em ν

senão

se $Int(lc(\nu)) \cap [x : x'] \neq 0$ então

| INSERE_SEGMENT_TREE($lc(\nu), [x : x']$)

fim

se $Int(rc(\nu)) \cap [x : x'] \neq 0$ então

| INSERE_SEGMENT_TREE($rc(\nu), [x : x']$)

fim

fim

fim

Algoritmo 2: INSERE_SEGMENT_TREE ($\nu, [x : x']$)

k), onde n é número total de segmentos e k é o número de segmentos reportados pelo algoritmo. Esse algoritmo pode ser descrito como mostra o Algoritmo 3.

Entrada: A raiz de uma árvore (ou sub-árvore) de segmentos e um ponto de busca q_x

Saída: Todos os intervalos que contêm q_x

início

```

| Reportar todos os intervalos em  $I(v)$ ; se  $v$  não é uma folha então
|   | se  $q_x \in Int(lc(v))$  então
|   | | BUSCA_SEGMENT_TREE ( $lc(v), q_x$ )
|   | senão
|   | | BUSCA_SEGMENT_TREE ( $rc(v), q_x$ )
|   | fim
| fim
fim

```

Algoritmo 3: BUSCA_SEGMENT_TREE (v, q_x).