



Universidade Federal de Pernambuco
Centro de Informática

Graduação em Engenharia da Computação

**Localização Interior Utilizando Bluetooth
Low Energy e Unidade de Medição
Inercial**

Marcus Felipe Raelle Rios

Trabalho de Graduação

Recife
6 de julho de 2017

Universidade Federal de Pernambuco
Centro de Informática

Marcus Felipe Raelle Rios

Localização Interior Utilizando Bluetooth Low Energy e Unidade de Medição Inercial

Trabalho apresentado ao Programa de Graduação em Engenharia da Computação do Centro de Informática da Universidade Federal de Pernambuco como requisito parcial para obtenção do grau de Bacharel em Engenharia da Computação.

Orientador: *Abel Guilhermino da Silva Filho*

Recife
6 de julho de 2017

*A todos aqueles que de alguma forma estiveram e estão
próximos de mim, fazendo esta vida valer a pena.*

Agradecimentos

Gostaria de agradecer primeiramente aos meus genitores, pelo apoio que me deram durante toda minha vida. Agradeço aos meus colegas do LIVE pelos debates acerca deste trabalho. E aos meus amigos da UFPE pelos momentos de descontração que tivemos ao longo de toda graduação.

*Para conhecermos os amigos é necessário passar pelo sucesso e pela
desgraça. No sucesso, verificamos a quantidade e, na desgraça, a
qualidade.*

—CONFÚCIO

Resumo

O BLE (Bluetooth Low Energy) é uma tecnologia sem fio utilizada para transmissão de dados entre dispositivos como computadores, *smartphones* e tablets. Comparando com o Bluetooth clássico o BLE tenta reduzir ainda mais o custo e o consumo de energia mas mantendo uma região de conexão similar. A maioria dos *smartphones* hoje possuem BLE, para dispositivos Android o padrão passou a ser suportado pela versão 4.3. Existem vários tipos de aplicações que podem ser desenvolvida utilizando o BLE. Destas possíveis aplicações aplicações pode-se destacar as seguintes: healthcare (monitoramento cardíaco), localização (beacon) e *smarthwatches*. Em aplicações de beacon, os dispositivos beacon, fazem transmissões de dados periodicamente. Esses dados carregam informações de RSSI (*Received Signal Strength Indication*) que são capturados por outros dispositivos que os utilizam para realizar a estimativa de posicionamento dos beacons. O exemplo mais conhecido de aplicações de beacon é o iBeacon da Apple Inc, que utiliza BLE para estimar a localização do dispositivo. Unidade de Medição Inercial também conhecida como IMU (*Inertial Measurement Unit*) eletrônicas, dispositivos capazes de medir orientação, estão cada vez mais comuns em dispositivos *wearable* e *smartphones* devido ao seu custo reduzido e sua miniaturização através de tecnologia MEMS (*Microelectromechanical Systems*), desta forma avaliar a junção de informação de orientação do dispositivo com RSSI é um ponto a ser estudado. Neste trabalho será avaliado a adição de informação de orientação de dispositivos *wearables* a potência de sinal recebida (RSSI) de pacotes BLE no cálculo de localização. Neste trabalho foi proposto um cenário para avaliar a adição de orientação de dispositivos *wearables* a potência de sinal, e verificou-se que existe uma melhoria substancial no desempenho do sistema no cenário proposto.

Palavras-chave: Localização, Aprendizagem de Máquina, IMU

Sumário

1	Introdução	1
1.1	Motivação	1
1.2	Objetivo	2
1.3	Organização do texto	2
2	Fundamentação Teórica	3
2.1	Bluetooth Low Energy	3
2.2	Técnicas de localização baseadas em rádio	4
2.2.1	Técnica de triangulação	4
2.2.2	Técnica de proximidade	6
2.2.3	Técnica de <i>fingerprinting</i>	6
2.3	Giroscópios	7
2.4	Acelerômetros	7
2.5	Magnetômetros	8
2.5.1	Calibração	9
2.5.1.1	Distorção Hard-Iron	10
2.5.1.2	Distorção Soft-Iron	11
2.5.2	Campo Magnético Terrestre	11
2.6	Problemas de Classificação	12
2.7	Álgebra de Quaterniões	12
3	Sistema Desenvolvido	15
3.1	Visão geral do sistema	15
3.1.1	Ajuste (calibração)	16
3.2	Protótipos Desenvolvidos	17
3.2.1	Protótipo: Wearable	17
3.2.2	Protótipo: Dongle	19
3.2.3	Comunicação	19
4	Experimentos	21
5	Considerações Finais	26
A	Matrizes de Confusão de todos os classificadores	27
B	Intensidade, Declinação e Inclinação do campo magnético da terra	32

Lista de Figuras

- 2.1 Canais BLE. Os canais de *advertising* (37,38 e 39) não chocam com os canais mais comuns de serem utilizados pelo Wi-Fi. Fonte: "<http://www.argenox.com/a-ble-advertising-primer/>", acessado em 06/07/2017. 3
- 2.2 Processo de *scab* feito pelo central. Fonte: "<https://devzone.nordicsemi.com/tutorials/21/>", acessado em 06/07/2017. 4
- 2.3 Lateração para 2 dimensões. Fonte: J. Hightower and G. Borriello, "Location sensing techniques". 5
- 2.4 Angulação para 2 dimensões. Fonte: J. Hightower and G. Borriello, "Location sensing techniques". 6
- 2.5 Objetos X, Y, e Z são localizados monitorando suas regiões de conexão. Fonte: J. Hightower and G. Borriello, "Location sensing techniques". 6
- 2.6 MPU6050 (circulado em vermelho), circuito integrado que possui giroscópio e acelerômetro fabricado com tecnologia MEMS. 7
- 2.7 Modelo Acelerômetro. Fonte: "<http://www.instructables.com/id/Accelerometer-Gyro-Tutorial/>", acessado em 06/07/2017. 8
- 2.8 Força sendo aplicada na direção X+. Fonte: "<http://www.instructables.com/id/Accelerometer-Gyro-Tutorial/>", acessado em 06/07/2017. 8
- 2.9 HMC5883L (circulado em vermelho), magnetômetro capaz de medir a intensidade do campo magnético nos 3 eixos. 9
- 2.10 Campo magnético terrestre na ausência de distorções. Fonte: "<http://www.sensorsmag.com/components/compensating-for-tilt-hard-iron-and-soft-iron-effects>", acessado em 06/07/2017. 10
- 2.11 Campo magnético terrestre sobre efeito de distorção Hard-Iron. Fonte: "<http://www.sensorsmag.com/components/compensating-for-tilt-hard-iron-and-soft-iron-effects>", acessado em 06/07/2017. 10
- 2.12 Campo magnético terrestre sobre efeito de distorção Soft-Iron. Fonte: "<http://www.sensorsmag.com/components/compensating-for-tilt-hard-iron-and-soft-iron-effects>", acessado em 06/07/2017. 11
- 2.13 Declinação, Inclinação e intensidade do campo magnético terrestre. Fonte: "https://upload.wikimedia.org/wikipedia/commons/1/16/XYZ-DIS_magnetic_field_coordinates.svg", acessado em 06/07/2017. 12
- 2.14 Orientação B adquirida a partir do sistema de de coordenadas A. 13

3.1	Esquemático do sistema desenvolvido que utiliza a orientação do dispositivo. Dentro da região azul a parte que executa no wearable e dentro da região em vermelho a parte que executa no dongle. A região pontilhada em vermelho representa uma parte que poderia executar no dongle mas foi executada no computador.	15
3.2	Esquemático do sistema desenvolvido que utiliza que utiliza somente a potência do sinal. Dentro da região em vermelho temos a parte que executa no dongle. A região pontilhada em vermelho representa uma parte que poderia executar no dongle mas foi executada no computador.	16
3.3	Placa pca10040 com SoC BLE nRF52, circulado em vermelho.	17
3.4	Diagrama do Wearable.	17
3.5	Placa GY-87 com CIs MPU6050 (giroscópio, acelerômetro) e HMC5883L (magnetômetro).	18
3.6	Máquina de estados para o cálculo de orientação.	19
3.7	Esquema de comunicação entre o dongle e o wearable.	19
3.8	Diagrama de sequência para comunicação entre dongle, wearable e o computador.	20
3.9	Pacote enviado ao computador via UART. Os números representam os <i>offset</i> em bytes.	20
4.1	Cenário de teste.	21
4.2	Dongle posicionado na origem.	21
4.3	Posições de coleta do wearable.	22
4.4	Variação da média do RSSI para um filtro com janela de $N = 7$ ao longo da distância e das posições.	23
4.5	Matriz de confusão de todos os 10 <i>folds</i> somados para 3NN CNN. Os valores em cada posição da matriz representa a fração do conjunto de teste que foi classificado como coluna dado linha.	25
4.6	Matriz de confusão de todos os 10 <i>folds</i> somados para Árvore de decisão. Os valores em cada posição da matriz representa a fração do conjunto de teste que foi classificado como coluna dado linha.	25
A.1	Matriz de confusão de todos os 10 folds somados para 1NN. Os valores em cada posição da matriz representa a fração do conjunto de teste que foi classificado como coluna dado linha.	27
A.2	Matriz de confusão de todos os 10 folds somados para 1NN CNN. Os valores em cada posição da matriz representa a fração do conjunto de teste que foi classificado como coluna dado linha.	28
A.3	Matriz de confusão de todos os 10 folds somados para 3NN. Os valores em cada posição da matriz representa a fração do conjunto de teste que foi classificado como coluna dado linha.	28
A.4	Matriz de confusão de todos os 10 folds somados para 3NN CNN. Os valores em cada posição da matriz representa a fração do conjunto de teste que foi classificado como coluna dado linha.	29

A.5	Matriz de confusão de todos os 10 folds somados para MLP com 20 nos na camada escondida. Os valores em cada posição da matriz representa a fração do conjunto de teste que foi classificado como coluna dado linha.	29
A.6	Matriz de confusão de todos os 10 folds somados para MLP com 25 nos na camada escondida. Os valores em cada posição da matriz representa a fração do conjunto de teste que foi classificado como coluna dado linha.	30
A.7	Matriz de confusão de todos os 10 folds somados para MLP com 30 nos na camada escondida. Os valores em cada posição da matriz representa a fração do conjunto de teste que foi classificado como coluna dado linha.	30
A.8	Matriz de confusão de todos os 10 folds somados para Árvore de decisão. Os valores em cada posição da matriz representa a fração do conjunto de teste que foi classificado como coluna dado linha.	31
B.1	Intensidade do campo magnético terrestre ao longo do globo.	32
B.2	Declinação do campo magnético terrestre ao longo do globo.	33
B.3	Inclinação do campo magnético terrestre ao longo do globo.	34

Lista de Tabelas

4.1	Resultados dos experimentos para um filtro com janela de $N = 7$.	24
-----	--	----

Introdução

1.1 Motivação

O conhecimento da posição individual durante atividades diárias tanto interiores quanto exteriores é essencial em diversas aplicações como por exemplo navegação de veículos, rastreamento de cargas, sistemas de recomendação baseados em localização interior [Lin13] e guias de museu. O GPS (*Global Positioning System*) é uma tecnologia muito efetiva para localização exterior, entretanto para localização interior (dentro de ambientes fechados como casas e prédios) esse sistema não tem um desempenho satisfatório [HH14] para a maioria das aplicações que necessitam de informação de localização interior.

Existem várias técnicas para localização interior que podem ser divididas em dois principais tipos, baseadas em rádio e não baseadas em rádio. Como exemplo de técnicas não baseadas em rádio temos baseada em sensores inerciais como giroscópios e acelerômetros [Fox05] (dispositivos presentes em uma unidade de medição inercial) e baseada em visão [KHM⁺00], onde a localização é determinada por um conjunto de câmeras e/ou marcadores são espalhados por um ou mais ambientes. Para técnicas baseadas em rádio temos técnica de triangulação [Ha01], técnica de *fingerprinting* [LLN⁺16] e técnica de proximidade [GLN09].

As técnicas baseadas em rádio utilizam qualquer tipo de tecnologia que seja sem fio. Para localização interior a ideia é tirar vantagem da infraestrutura da rede sem fio para determinar a localização, a desvantagem clara é a necessidade de uma infraestrutura de rede para determinar a localização. Tecnologias como Wi-Fi e Bluetooth low energy (BLE) são exemplos de tecnologias de rádio utilizadas para determinar localização [LLS⁺16][BCD⁺16]. Algumas aplicações de localização necessitam de uma localização mais precisa, ou seja, necessitam de coordenada em que o dispositivo está, outras apenas da região.

A área de estudo de localização utilizando redes sem fio vem cada vez mais se tornando popular devido ao crescimento no número de dispositivos *wearable*, pontos de acesso e barateamento de receptores de rádio móvel. Dispositivos móveis como *smartphones* estão cada vez mais comuns, e com os avanços na tecnologia de sensores MEMS (*Microelectromechanical*) é cada vez mais comum *smartphones* possuírem giroscópios e acelerômetros. Adicionado informação de uma bússola digital (magnetômetro) com a informação de giroscópios e acelerômetros, é possível calcular a orientação do dispositivo em relação ao planeta [Mad10][RLBV05].

O BLE é uma tecnologia promissora para localização interior devido ao seu baixo custo e eficiência energética. O BLE também teve uma grande disseminação nos últimos anos, versões mais recentes de *smartphones* já possuem suporte ao BLE 4.0. Um exemplo de serviços de localização bastante popular que utiliza BLE é o iBeacon da Apple Inc. Outras tecnologias de rádio podem ser utilizadas para localização como por exemplo o WI-Fi mas a eficiência

energética do BLE é superior e o Wi-Fi também possui um custo maior.

1.2 Objetivo

Este trabalho tem como objetivo avaliar o impacto da adição da informação de orientação de um dispositivo *wearable* a informação de potência de sinal (RSSI - Received Signal Strength Indicator) de pacotes BLE, no cálculo de localização baseada na técnica de *fingerprinting*.

1.3 Organização do texto

Para atingir os objetivos apresentados, este trabalho está organizado da seguinte forma: o capítulo 2 aborda a fundamentação teórica do trabalho, abordando alguns assuntos de relevância para o entendimento trabalho. O capítulo 3 apresenta o sistema desenvolvido. No capítulo 4 é apresentando os experimentos e resultados obtidos. Por fim o capítulo 5 apresenta as considerações finais e trabalhos futuro.

Fundamentação Teórica

Neste capítulo serão revisados de forma breve alguns assuntos de importância para o entendimento deste trabalho.

2.1 Bluetooth Low Energy

O bluetooth low energy (BLE) foi introduzido em 2010 como parte da especificação do bluetooth 4.0, desenvolvida e mantida pelo grupo Bluetooth Special Interest Group (SIG). O bluetooth foi desenvolvido com o objetivo de ser utilizado em aplicações de necessitem de baixo tráfego de dados e a distâncias pequenas. Diferentemente da sua especificação anterior o bluetooth low energy, apresenta baixo consumo e baixo custo.

Os dispositivos BLE operam na faixa de frequência de $2.4GHz$ ($2.402GHz - 2.480GHz$), são 40 canais de rádio frequência com largura de $2MHz$. Existem dois tipos de canais, canais de *advertising* e canais de dados. Os canais de *advertising* são apenas 3 canais (37,38 e 39) do total de 40 canais, são utilizados para descobrir outros dispositivos, estabelecer conexões e transmitir mensagens do tipo broadcast. O segundo tipo de canal, os canais de dados, são utilizados para comunicação bi-direcional entre os dispositivos.

Os dispositivos BLE quando estão operando em modo de *advertising*, transmitem de forma periódica informações de broadcasting nos seus canais dedicados para diminuir o número de colisões com os canais do Wi-Fi mais utilizados. A Figura 2.1 ilustra a divisão dos canais BLE ao longo da sua faixa de frequência.




Figura 2.1 Canais BLE. Os canais de *advertising* (37,38 e 39) não chocam com os canais mais comuns de serem utilizados pelo Wi-Fi. Fonte: "<http://www.argenox.com/a-ble-advertising-primer/>", acessado em 06/07/2017.

No BLE os dispositivos podem desempenhar duas funções. A função de periférico e a de central. O central é aquele que inicializa uma conexão, e também responsável por decidir parâmetros da conexão como por exemplo o intervalo de conexão. O periférico começa seu ciclo de vida fazendo *advertising* de algum serviço, e então respondendo a requisições de conexão feitas por algum central.

O dispositivo periférico faz broadcast do serviço que oferece por meio dos canais de *advertising*. O dispositivo central escaneia os canais de *advertising* e analisa os dados encontrados. Baseado nos dados adquiridos o central decide se inicia ou não um processo de conexão com o periférico. O processo de *scan* pode ser visto na Figura 2.2.

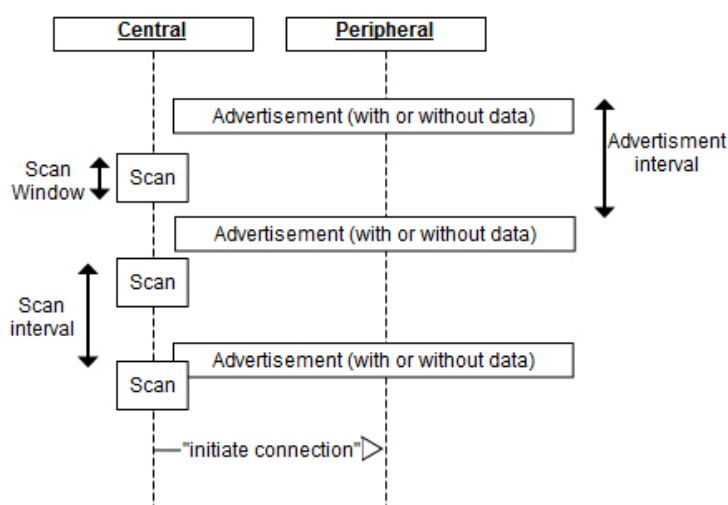


Figura 2.2 Processo de *scan* feito pelo central. Fonte: "<https://devzone.nordicsemi.com/tutorials/21/>", acessado em 06/07/2017.

2.2 Técnicas de localização baseadas em rádio

Técnicas de localização baseadas em rádio são técnicas que utilizam alguma informação proveniente do rádio do sistema como por exemplo potência de sinal ou se baseiam na forma de comunicação em si (ondas eletromagnéticas).

2.2.1 Técnica de triangulação

A técnica de triangulação pode se dividir em duas subtécnicas, lateração e angulação.

Lateração computa a posição de um objeto através da distância deste objeto a múltiplos pontos de referência. Para 2 dimensões são necessários pelo menos 3 pontos de referência não colineares. Para o cálculo da distância entre os pontos de referência e o ponto que se quer localizar existem duas técnicas bastante usadas, ToA (Time of Arrival) e por atenuação do sinal.

- ToA: Também conhecido como time of flight (ToF), consiste em calcular a distância ao

ponto de referência sabendo o tempo que levou para o sinal chegar e a velocidade de deslocamento do sinal.

- Atenuação: A Potência de um sinal emitido descrese a medida que a distância a um receptor aumenta. Dada um função que correlacione distância e potência de sinal é possível medir a distancia ao ponto de referência.

Em posse da informação da distância do objeto que se deseja localizar aos N pontos de referência, é possível de se determinar sua localização, na Figura 2.3 pode-se ver o caso para 2 dimensões.

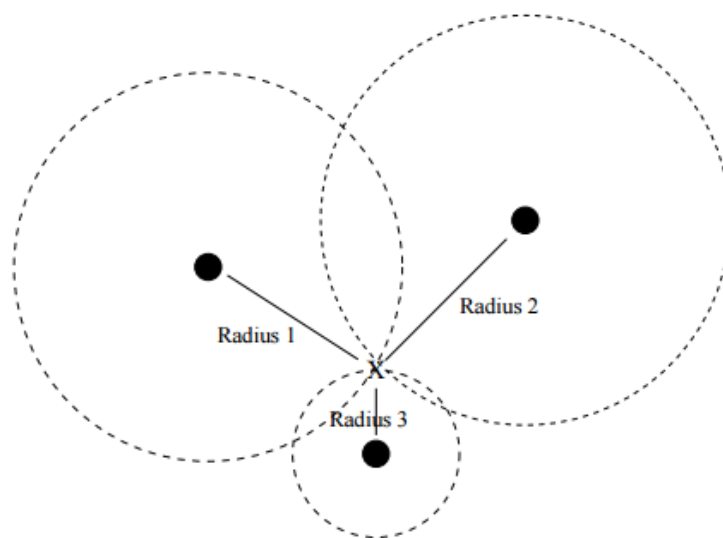


Figura 2.3 Lateração para 2 dimensões. Fonte: J. Hightower and G. Borriello, "Location sensing techniques".

Angulação é similar a lateração mas ao invés de utilizar distâncias a pontos de referência utiliza-se ângulos. Para o caso de 2 dimensões é necessário pelo menos 2 ângulos e 1 distância conhecida por exemplo a distancia entre os 2 pontos de referência, como pode ser visto na Figura 2.4. Os ângulos precisam ser calculados de acordo com um vetor de referência, normalmente o norte para ser o 0° .




Figura 2.4 Angulação para 2 dimensões. Fonte: J. Hightower and G. Borriello, "Location sensing techniques".

2.2.2 Técnica de proximidade

A técnica de proximidade consiste em detectar se um objeto está próximo de alguma região conhecida. A exemplo de implementação desta técnica temos monitoração de pontos de acesso, se um dispositivo está ou não dentro do range de um ou mais pontos de acesso, pode-se identificar em que região ele está localizado, a Figura 2.5 ilustra esta situação.




Figura 2.5 Objetos X,Y, e Z são localizados monitorando suas regiões de conexão. Fonte: J. Hightower and G. Borriello, "Location sensing techniques".

2.2.3 Técnica de *fingerprinting*

A técnica de *fingerprinting* é uma técnica simples que não necessita técnicas avançadas para cálculo de ToA (Time of Arrival) ou AoA (Angle of Arrival) para inferir a localização. Ao contrário disso, ela utiliza valores dependentes do local para inferir a localização, como por exemplo RSSI (Received Signal Strength Indicator).

A técnica de *fingerprinting* possui duas etapas uma offline e uma online. A etapa offline consiste na construção da base de dados do *fingerprinting*, e a online no cálculo da localização em si. Na etapa offline são coletadas características do sinal (por exemplo o RSSI) em diversos pontos da região em que se deseja realizar a localização, e a partir destes dados é gerado um mapa para o *fingerprinting* que será utilizado futuramente na etapa online. Na etapa online dados do sinal são coletados (por exemplo o RSSI), e então é feito um cálculo de semelhança com os pontos dentro do meu mapa. O ponto que tiver maior semelhança com o dado coletado será inferido como sua localização, um exemplo bem simples de cálculo de semelhança é a distância euclidiana, o ponto mais próximo é o ponto mais provável de ser sua localização.

2.3 Giroscópios

Giroscópios são dispositivos usados principalmente para navegação e cálculo de velocidade angular. Giroscópios são capazes de medir a velocidade angular em 1, 2 ou 3 eixos. Existe mais de um princípio de funcionamento para giroscópios, os principais são o rotatório, ótico e o de estruturas vibrantes. O giroscópio de estruturas vibrantes tem se tornado cada vez mais comum em dispositivos eletrônicos devido ao avanços das estruturas MEMS (Microelectromechanical systems), dispositivos microscópicos com partes capazes de se moverem. A exemplo de um chip com esta tecnologia é a MPU6050 (Figura 2.6).



Figura 2.6 MPU6050 (circulado em vermelho), circuito integrado que possui giroscópio e acelerômetro fabricado com tecnologia MEMS.

2.4 Acelerômetros

Acelerômetros são dispositivos capazes de medir a aceleração inercial em 1, 2 ou 3 eixos. Acelerômetros são utilizados tipicamente em três modos, como sensor capaz de medir velocidade e posição [HSZ17], sensor de inclinação medindo a aceleração da gravidade [HBCW17] e como detectores de queda [LRS13]. Existe mais de um princípio de funcionamento para acelerômetros os mais comuns são baseados em sensores capacitivos e baseados em efeito piezoelétrico. Independente do princípio todos se baseiam pelo movimento de uma massa de prova, e através

da força exercida por essa massa de prova calcula-se a aceleração.

Para entendimento será considerado o seguinte modelo, um cubo com uma pequena esfera dentro deste cubo conforme Figura 2.7.




Figura 2.7 Modelo Acelerômetro. Fonte: "<http://www.instructables.com/id/Accelerometer-Gyro-Tutorial/>", acessado em 06/07/2017.

Quando uma força F com aceleração de magnitude $1g$ ($1g = 9.8m/s^2$) é aplicada na direção $X+$, uma força é feita na parede $X-$, e a partir desta força que é calculada a aceleração de F (Figura 2.8).




Figura 2.8 Força sendo aplicada na direção $X+$. Fonte: "<http://www.instructables.com/id/Accelerometer-Gyro-Tutorial/>", acessado em 06/07/2017.

2.5 Magnetômetros

Magnetômetros são dispositivos capazes medir a intensidade do campo magnético em cada um dos seus eixos. Atualmente magnetômetros são encontrados em diversos dispositivos eletrônicos e são bastante utilizados como bússolas digitais. Na Figura 2.9 podemos ver HMC5883L, magnetômetro capaz de medir a intensidade do campo magnético nos 3 eixos. Magnetômetros junto com acelerômetros e giroscópios são capazes de efetuar cálculos de orientação. Este tipo de dispositivo que combina magnetômetro, acelerômetro e giroscópio é chamado de unidade

de medição inercial ou do inglês IMU (Inertial Measurement Unit).

Para utilizar magnetômetro como bússola digital ou para o cálculo de orientação, o objetivo é de definir a direção e sentido do campo magnético terrestre.




Figura 2.9 HMC5883L (circulado em vermelho), magnetômetro capaz de medir a intensidade do campo magnético nos 3 eixos.

2.5.1 Calibração

Para o uso eficaz de magnetômetros, os efeitos magnéticos gerados pelos componentes a sua volta devem ser considerados, por isso os mesmos devem ser calibrados. Existem dois tipos mais comuns de distorções que afetam as leituras de magnetômetros, distorções Hard-Iron e Soft-Iron. A leitura de um magnetômetro na ausência dessas distorções deveria ser somente o campo gerado pelo campo magnético terrestre, por exemplo a leitura de um magnetômetro em relação aos eixos x e y deveria ser um circunferência perfeita de mesmo raio onde o raio é igual a magnitude do campo terrestre (Figura 2.10).




Figura 2.10 Campo magnético terrestre na ausência de distorções. Fonte: "<http://www.sensormag.com/components/compensating-for-tilt-hard-iron-and-soft-iron-effects>", acessado em 06/07/2017.

2.5.1.1 Distorção Hard-Iron

Distorções Hard-Iron são distorções geradas por materiais que geram constantes aditivas ao campo magnético terrestre. Por exemplo uma fonte de tensão e fios energizados irão gerar uma constante aditiva ao campo magnético terrestre. Desde que esse materiais tenham suas posições fixas esse tipo de distorção pode ser compensada. Esse tipo de distorção pode ser vista como um offset na circunferência (Figura 2.11).




Figura 2.11 Campo magnético terrestre sobre efeito de distorção Hard-Iron. Fonte: "<http://www.sensormag.com/components/compensating-for-tilt-hard-iron-and-soft-iron-effects>", acessado em 06/07/2017.

Para corrigir este tipo de distorção se faz necessário apenas uma constante aditiva na leitura do sensor para centralizar a circunferência.

2.5.1.2 Distorção Soft-Iron

Distorções Soft-Iron diferente de distorções Hard-Iron são geradas por materiais que influenciam ou distorcem o campo magnético mas não necessariamente geram um campo, portanto não são efeitos aditivos. Níquel e ferro geram distorções do tipo Soft-Iron. Enquanto distorções Hard-Iron são indiferentes quanto a orientação Soft-Iron não são, portanto para compensar este efeito uma técnica mais complicada se faz necessária. Este tipo de perturbação tende a transformar a circunferência numa elipse (Figura 2.12).




Figura 2.12 Campo magnético terrestre sobre efeito de distorção Soft-Iron. Fonte: "<http://www.sensormag.com/components/compensating-for-tilt-hard-iron-and-soft-iron-effects>", acessado em 06/07/2017.

2.5.2 Campo Magnético Terrestre

Quando magnetômetros são utilizados como bússolas digitais, ou seja, com o objetivo de se determinar o norte geográfico existem três pontos que devem ser levados em conta, a declinação, inclinação e intensidade do campo magnético terrestre ao longo do globo (Figura 2.13).




Figura 2.13 Declinação, Inclinação e intensidade do campo magnético terrestre. Fonte: "https://upload.wikimedia.org/wikipedia/commons/1/16/XYZ-DIS_magnetic_field_coordinates.svg", acessado em 06/07/2017.

Pode-se definir a intensidade, a declinação e a inclinação da seguinte forma:

- intensidade: representa a variação da magnitude do campo magnético terrestre ao longo do globo, e é normalmente medida em gauss (G), $1 G = 100000$ nanoteslas (nT). A magnitude varia entre 25000 e $65000 nT$ ($0.25 - 0.65 G$) ao longo do globo, como pode ser visto na Figura B.1.
- declinação: é o ângulo formado entre o norte geográfico e o norte magnético. A variação da declinação ao longo do globo pode ser vista na Figura B.2.
- inclinação: pode variar de 90° a -90° , -90° no polo norte e 90° no polo sul. A variação da declinação ao longo do globo pode ser vista na Figura B.3.

2.6 Problemas de Classificação

Um problema de classificação consiste em descobrir a qual categoria dentro de um conjunto de categorias uma nova observação pertence. Um exemplo simples seria dado uma fotografia dizer se nessa fotografia existe ou não uma pessoa. No contexto de aprendizagem de máquina, uma máquina (algoritmo) capaz de resolver um problema de classificação é dita ser um classificador.

Para este tipo de tarefa faz-se necessário uma quantidade prévia de dados sobre o problema, para treinar o classificador, este processo é conhecido como aprendizado supervisionado. No exemplo de detectar se possui uma pessoa ou não na fotografia, os dados seriam diversas fotografias com pessoas e sem pessoas. A exemplo de classificadores tem-se KNN (*K-Nearest Neighbors*) [Mit97], Árvore de decisão [Mit97] e MLP (*MultiLayer Perceptron*) [Mit97].

2.7 Álgebra de Quaterniões

Quaterniões são números complexos de quatro dimensões que podem ser utilizados para armazenar orientações ou rotações num espaço tridimensional. Uma orientação B relativa a um

sistema de coordenadas A pode ser alcançado através de uma rotação de um ângulo θ em torno de um vetor $A_{\hat{r}}$ definido no sistema de coordenadas A . Isso é representado na Figura 2.14.




Figura 2.14 Orientação B adquirida a partir do sistema de de coordenadas A.

A orientação B relativa a A pode ser representada por um quaternião segundo a equação 2.1

$${}^A_B\hat{q} = [q_1, q_2, q_3, q_4] = \left[\cos\left(\frac{\theta}{2}\right), -r_x \sin\left(\frac{\theta}{2}\right), -r_y \sin\left(\frac{\theta}{2}\right), -r_z \sin\left(\frac{\theta}{2}\right) \right] \quad (2.1)$$

onde θ representa o ângulo de rotação e r_x , r_y e r_z são as coordenadas do vetor pelo qual ocorrerá a rotação θ . Para os cálculos de rotações o quaternião ${}^A_B\hat{q}$ precisa ser normalizado.

O conjugado do quaternião denotado por $*$ pode ser utilizado para inverter as rotações, passar de um sistema de coordenadas B para uma orientação A referente ao sistema de coordenadas B , por exemplo ${}^B_A\hat{q}$ é o conjugado de ${}^A_B\hat{q}$. O conjugado de um quaternião é definido pela equação 2.2

$${}^A_B\hat{q}^* = {}^B_A\hat{q} = [q_1, -q_2, -q_3, -q_4] \quad (2.2)$$

O produto de quaterniões denotado por \otimes pode ser utilizado para compor rotações. Por exemplo duas rotações ${}^A_B\hat{q}$ e ${}^B_C\hat{q}$ podem ser compostas em uma única rotação ${}^A_C\hat{q}$. A orientação ${}^A_C\hat{q}$ é definida segundo a equação 2.3

$${}^A_C\hat{q} = {}^B_C\hat{q} \otimes {}^A_B\hat{q} \quad (2.3)$$

Para dois quaterniões a e b , o produto $a \otimes b$ é definido pela equação 2.4. O produto de quaterniões não é comutativo, $a \otimes b \neq b \otimes a$

$$\begin{aligned} a &= [a_1, a_2, a_3, a_4] \\ b &= [b_1, b_2, b_3, b_4] \\ a \otimes b &= \begin{bmatrix} a_1 b_1 - a_2 b_2 - a_3 b_3 - a_4 b_4 \\ a_1 b_2 + a_2 b_1 + a_3 b_4 - a_4 b_3 \\ a_1 b_3 - a_2 b_4 + a_3 b_1 + a_4 b_2 \\ a_1 b_4 + a_2 b_3 - a_3 b_2 + a_4 b_1 \end{bmatrix}^T \end{aligned} \quad (2.4)$$

Um vetor tridimensional ${}^A v$ no sistema de coordenadas A pode ser rotacionado para uma orientação B gerando o vetor ${}^B v$ a partir de um quaternião ${}^A_B \hat{q}$. A rotação de ${}^A v$ é definida pela equação 2.5,

$${}^B v = {}^A_B \hat{q} \otimes {}^A v \otimes {}^A_B \hat{q}^* \quad (2.5)$$

onde um vetor tridimensional $v = [x, y, z]$ deve ser expresso como $[0, x, y, z]$.

Sistema Desenvolvido

3.1 Visão geral do sistema

Um sistema de localização para dispositivos wearable baseado na técnica de fingerprinting foi proposto. Duas versões foram desenvolvidas uma baseada apenas na potência do sinal recebido (RSSI) e outra baseada em orientação do dispositivo e RSSI. Ambas versões utilizaram a tecnologia BLE (*Bluetooth Low Energy*) para a localização.

Um esquemático do sistema desenvolvido que utiliza a orientação do dispositivo pode ser visto na Figura 3.1.

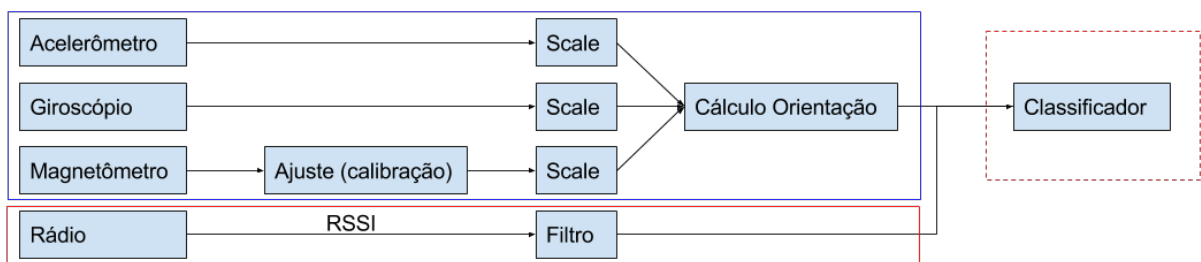


Figura 3.1 Esquemático do sistema desenvolvido que utiliza a orientação do dispositivo. Dentro da região azul a parte que executa no wearable e dentro da região em vermelho a parte que executa no dongle. A região pontilhada em vermelho representa uma parte que poderia executar no dongle mas foi executada no computador.

A entrada do sistema consiste na leitura dos três sensores, acelerômetro, giroscópio e magnetômetro e da leitura do RSSI em dBm do pacote BLE recebido. Após a leitura dos sensores é efetuada a *scale* que consiste em converter a saída dos sensores em dado útil para o algoritmo de cálculo da orientação, para o giroscópio a conversão é feita de raw data para rad/s , para o acelerômetro de raw data para g ($1g = 9.8m/s^2$) e para o magnetômetro de raw data para $Gauss$. O magnetômetro tem que ser calibrado antes do *scale*, para remover as distorções Hard-Iron e Soft-Iron.

Para o cálculo da orientação foi utilizado o algoritmo de Madgwick [Mad10] que tem como saída um quaternião que representa a orientação do dispositivo. O algoritmo de Madgwick é uma boa opção para o sistema uma vez que ele necessita de pouco processamento, 277 operações escalares (51 adições, 57 subtrações, 155 multiplicações, 14 divisões e 5 raízes quadradas). As leituras de RSSI passam por um filtro de média para eliminar variações bruscas no RSSI. O

filtro é implementado através de uma janela deslizante de tamanho N onde a cada nova leitura a mais antiga e substituída pela mais recente. A saída da janela corresponde a média aritmética das leituras que estão armazenadas na janela.

Para definir em que região o dispositivo se encontra é utilizada uma máquina de aprendizagem com função de classificador, que possui como entradas as informações de orientação do dispositivo e do valor de RSSI médio. Os classificadores utilizados foram KNN (*K-Nearest Neighbors*), Árvore de decisão e MLP (*MultiLayer Perceptron*) que são classificadores que podem ser embarcados facilmente.

A versão baseada apenas na potência de sinal tem um funcionamento semelhante a versão que utiliza orientação, mas sem a parte do cálculo de orientação como pode ser visto na Figura 3.2. A entrada do classificador é apenas o resultado de um filtro de média de janela deslizante igual a versão baseada na orientação e RSSI.




Figura 3.2 Esquemático do sistema desenvolvido que utiliza que utiliza somente a potência do sinal. Dentro da região em vermelho temos a parte que executa no dongle. A região pontilhada em vermelho representa uma parte que poderia executar no dongle mas foi executada no computador.

3.1.1 Ajuste (calibração)

Para corrigir as distorções Hard-Iron e Soft-Iron utilizou-se o modelo descrito na equação 3.1.

$$\begin{bmatrix} X_c \\ Y_c \\ Z_c \end{bmatrix} = \begin{bmatrix} M_{11} & M_{12} & M_{13} \\ M_{21} & M_{22} & M_{23} \\ M_{31} & M_{32} & M_{33} \end{bmatrix} \times \left(\begin{bmatrix} X_{nc} \\ Y_{nc} \\ Z_{nc} \end{bmatrix} - \begin{bmatrix} B_x \\ B_y \\ B_z \end{bmatrix} \right) \quad (3.1)$$

Na equação 3.1 X_{nc} , Y_{nc} , Z_{nc} representam os dados lidos direto do magnetômetro. A correção das distorções Hard-Iron são corrigidas pelas constantes B_x , B_y , B_z , e as distorções Soft-Iron pelas constantes M_{11} , M_{12} , M_{13} , M_{21} , M_{22} , M_{23} , M_{31} , M_{32} , M_{33} . Ao final do processo tem-se X_c , Y_c , Z_c que são os novos valores do magnetômetro calibrados. Os valores para as constantes B e M foram calculadas a partir do software MagMaster [Yur].

3.2 Protótipos Desenvolvidos

Dois tipos de protótipos foram desenvolvidos para verificar o desempenho do sistemas proposto. Ambos utilizam como base a plataforma de prototipação da Nordic pca10040 que possui o SoC BLE nRF52, a placa de prototipação pode ser vista na Figura 3.3.




Figura 3.3 Placa pca10040 com SoC BLE nRF52, circulado em vermelho.

3.2.1 Protótipo: Wearable

O wearable funciona como o periférico no protocolo BLE, e tem como responsabilidade calcular sua orientação e fazer o broadcasting da mesma via *advertising*.

Para o calculo da orientação foi utilizada a placa GY-87 (Figura 3.5) que possui os CIs MPU6050 (giroscópio, acelerômetro) e HMC5883L (magnetômetro) conectados a placa PCA10040 (Figura 3.3). Através de um barramento I2C os CIs que estão na placa GY-87 podem se comunicar com o SoC nRF52 (a comunicação entre GY-87 e a PCA10040 está ilustrada na Figura 3.4), que é responsável por fazer o cálculo de orientação e por fazer o broadcasting via *advertising*.




Figura 3.4 Diagrama do Wearable.



Figura 3.5 Placa GY-87 com CIs MPU6050 (giroscópio, acelerômetro) e HMC5883L (magnetômetro).

Os sensores da placa GY-87 são configurados ao inicializar o sistema através do barramento I2C. Algumas características dos sensores e suas configurações durante a inicialização são descritas abaixo:

- **Giroscópio:** possui conversor AD de 16 bits, frequência de amostragem de 1 KHz , funcionando no intervalo de $\pm 1000\text{ graus/s}$.
- **Acelerômetro:** possui conversor AD de 16 bits, frequência de amostragem de 1 KHz , funcionando no intervalo de $\pm 4\text{ g}$.
- **Magnetômetro:** possui conversor AD de 12 bits, frequência de amostragem de 12 Hz , 0.92 mG por contagem o que leva a um intervalo de $\pm 1.8\text{ G}$.

O cálculo de orientação é efetuado segundo o Algoritmo 1, as linhas 2 a 4 representam as leituras dos sensores via barramento I2C, a linha 5 representa a correção de distorções no magnetômetro, as linhas 6 a 8 representam o *scale* dos dados, e finalmente na linha 9 temos o cálculo da orientação utilizando o algoritmo de Madgwick. A função descrita no Algoritmo 1 foi implementada através de um *timer* com frequência de 100 Hz . Na Figura 3.6 podemos ver a máquina de estados que representa o cálculo de orientação com o *timer* de 100 ms (equivalente a frequência de 100 Hz). A orientação mais recente fica salva na memória do dispositivo por meio de variáveis globais.

Algoritmo 1 Cálculo Orientação

```

1: function CALCULO_ORIENTACAO(void)
2:    $ax, ay, az \leftarrow \text{leitura\_acelerômetro}()$ 
3:    $gx, gy, gz \leftarrow \text{leitura\_giroscópio}()$ 
4:    $mx, my, mz \leftarrow \text{leitura\_magnetômetro}()$ 
5:    $mx, my, mz \leftarrow \text{correção\_distorções\_hard\_e\_soft\_iron}(mx, my, mz)$ 
6:    $ax, ay, az \leftarrow \text{scale\_acelerômetro}(ax, ay, az)$ 
7:    $gx, gy, gz \leftarrow \text{scale\_giroscópio}(gx, gy, gz)$ 
8:    $mx, my, mz \leftarrow \text{scale\_magnetômetro}(mx, my, mz)$ 
9:    $quaternion \leftarrow \text{algoritmo\_madgwick}(gx, gy, gz, ax, ay, az, mx, my, mz)$ 
10:  return quaternion
11: end function

```




Figura 3.6 Máquina de estados para o cálculo de orientação.

Em paralelo a pilha do protocolo BLE implementada pelo nRF52 fica responsável por fazer *advertising* da informação de orientação mais recente a cada 20ms. A comunicação entre a pilha BLE e o cálculo de orientação é feito através de variáveis globais compartilhadas em memória.

3.2.2 Protótipo: Dongle

O dongle funciona como o central no protocolo BLE, e tem como responsabilidade fazer *scan* nos canais de *advertising* a procura do wearable. O wearable faz *broadcasting* da sua orientação periodicamente. O dongle fica escutando os canais de *advertising* filtrando por endereço MAC para descobrir qual *advertising* pertence ao wearable. Uma vez que um pacote de *advertising* do wearable é descoberto a informação de RSSI do pacote é lida e passada ao filtro, depois ambas informações, saída do filtro e orientação são enviadas ao classificador via UART, que está executando no computador. O processo por completo pode ser visto na Figura 3.7.




Figura 3.7 Esquema de comunicação entre o dongle e o wearable.

3.2.3 Comunicação

A comunicação entre o dongle, wearable e o computador pode ser vista na Figura 3.8 por meio de um diagrama de sequência. Primeiro o wearable envia o quaterniônio que representa a orientação para o dongle por meio de *advertising* o quaterniônio e armazenado por meio de 4 pontos flutuantes de 32 bits o que totaliza 16 bytes, que cabem em 1 pacote de *advertising*.

O dongle ao receber o quaterniãõ anexa a informação de RSSI, 1 byte, recebida no pacote de *advertising* e envia via UART para o computador que ao receber armazena o dado para processamento posterior. O pacote enviado pela UART pode ser visto na Figura 3.9, contem 1 byte para determinar o início (0xFF), 17 bytes de dados e 1 byte de CRC para verificar erros. O CRC implementado é apenas o xor bit a bit de todos os outro campos do pacote (dados e início).

O computador ao receber um pacote verifica se o xor bit a bit de todos os campos do pacote é igual a zero, caso seja igual a zero nenhum erro foi detectado e então o dado é armazenado para ser processado futuramente, caso não seja igual a zero o pacote é descartado.

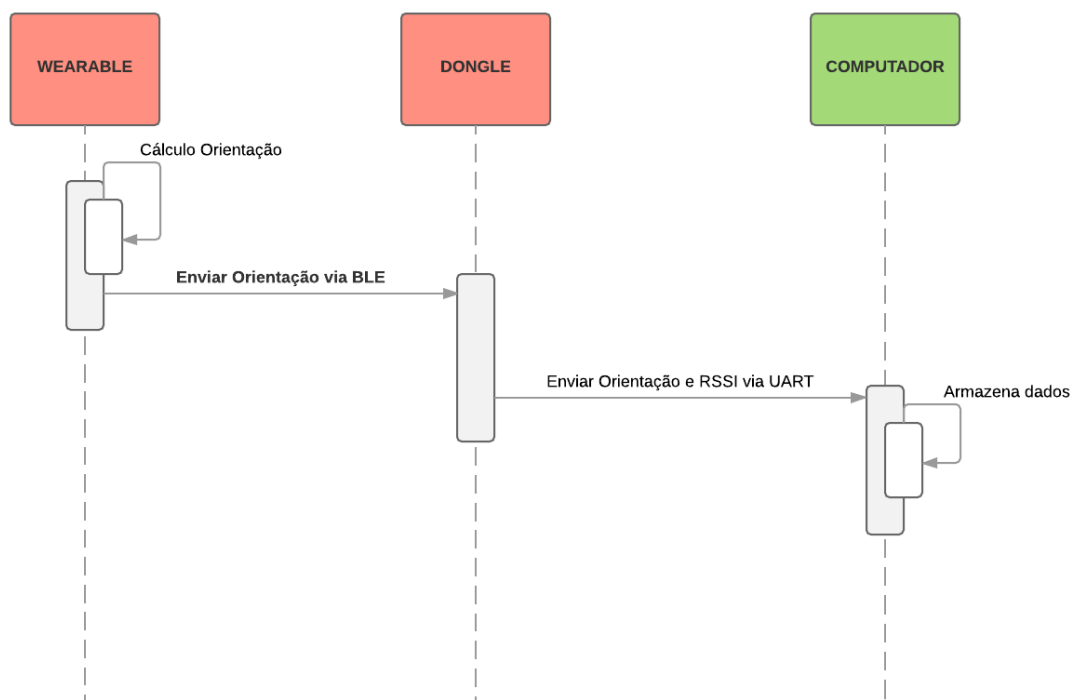


Figura 3.8 Diagrama de sequência para comunicação entre dongle, wearable e o computador.




Figura 3.9 Pacote enviado ao computador via UART. Os números representam os *offset* em bytes.

CAPÍTULO 4

Experimentos

Para avaliar o sistema proposto no capítulo 3 um cenário de teste foi elaborado. O cenário é composto por 6 pontos um como origem a $0m$ e os outros 5 a respectivamente $1m$, $2m$, $3m$, $4m$ e $5m$ do ponto de origem, conforme Figura 4.1. No ponto $0m$ foi fixado o dongle (Figura 4.2), os demais pontos foram pontos de coleta do wearable.





Figura 4.1 Cenário de teste.



Figura 4.2 Dongle posicionado na origem.

Nos pontos de coleta o wearable foi rotacionado ao longo do eixo Z a 0° , 90° , 180° e 270° , as posições de coleta podem ser vistas na Figura 4.3.




(a) 0°



(b) 90°



(c) 180°



(d) 270°

Figura 4.3 Posições de coleta do wearable.

Durante os experimentos o canal de advertesing do wearable foi fixado no canal 37 e foram coletados 1000 pontos em cada posição, o intervalo de advertesing foi fixado em $20ms$. Na Figura 4.4 pode-se ver a variação da média do RSSI para um filtro com janela de $N = 7$ ao longo da distância e das posições. Percebe-se que para a distância de $1m$ a orientação não tem muita influência na média do RSSI, mas para distâncias maiores tem uma influência significativa.




Figura 4.4 Variação da média do RSSI para um filtro com janela de $N = 7$ ao longo da distância e das posições.

Foram utilizados como possíveis classificadores o KNN, MLP e Árvore de decisão. Todos os classificadores foram implementados utilizando a biblioteca de machine learning scikit-learn [Cou17] do Python 2.7. Para o KNN foram avaliadas as seguintes variações 1NN, 3NN, 1NN com CNN (*Condensed Nearest Neighbor*) [Har68] e 3NN com CNN. Em todas as variações a medida de distância utilizada foi a distância euclidiana. Para MLP foram avaliadas as seguintes configurações, 1 camada escondida com 20, 25 e 30 nós na camada escondida com função de ativação a função logística e algoritmo de treinamento Adam [KB14].

Para a árvore de decisão foi avaliada a seguinte configuração, o critério de divisão foi a entropia e a profundidade máxima da árvore foi igual a 10. Para avaliar os classificadores foi utilizada a técnica do *10-Fold*, onde a base de dados é dividida em 10 partes iguais mantendo as mesmas proporções de classes da base nas partes. São efetuados 10 testes onde em cada teste 9 partes são para treino e 1 para teste. Cada parte é utilizada 1 vez como teste e 9 vezes como treino.

A métrica utilizada para avaliar os classificadores foi apenas a acurácia média dos *folds*. Na tabela 4.1 pode-se ver os resultados obtidos para os classificadores avaliados, acurácia média que representa a média aritmética do acerto de cada *fold* (número de padrões classificados corretamente dividido pelo total de padrões classificados) e desvio padrão da acurácia dos *folds*. Na tabela 4.1 para o caso do KNN com CNN temos uma coluna informando de quanto foi a redução no tamanho da base armazenada pelo KNN. Percebe-se um aumento substancial na acurácia média dos classificadores quando a informação de orientação é adicionada ao sistema. Em todos os casos (com e sem orientação) a Árvore de decisão obteve o melhor resultado, seguida do KNN e depois da MLP.

Classificador	Acurácia média <i>10-Fold</i>	Desvio padrão <i>10-Fold</i>	Redução da base em	Informação de orientação
1NN	57.47%	2.28%	#	Não
1NN com CNN	54.72%	1.99%	55%	Não
3NN	59.09%	1.90%	#	Não
3NN com CNN	57.65%	2.67%	55%	Não
MLP com 20 nós	50.48%	1.45%	#	Não
MLP com 25 nós	50.22%	1.98%	#	Não
MLP com 30 nós	50.60%	1.89%	#	Não
Árvore de decisão	68.00%	0.45%	#	Não
1NN	99.89%	0.06%	#	Sim
1NN com CNN	99.86%	0.09%	99%	Sim
3NN	99.91%	0.07%	#	Sim
3NN com CNN	99.77%	0.18%	99%	Sim
MLP com 20 nós	95.20%	1.34%	#	Sim
MLP com 25 nós	95.67%	0.83%	#	Sim
MLP com 30 nós	95.11%	1.09%	#	Sim
Árvore de decisão	99.98%	0.02%	#	Sim

Tabela 4.1 Resultados dos experimentos para um filtro com janela de $N = 7$.

Avaliando os erros dos classificadores (através de suas matrizes de confusão) os dois melhores classificadores foram a Árvore de decisão e o 3NN CNN (o 3NN CNN foi escolhido mesmo com uma acurácia inferior a sua versão sem redução de base porque o objetivo é um sistema voltado para dispositivos wearable em que restrições de memória são muito fortes) pode-se ver nas figuras 4.5 e 4.6 que o erro se concentra nas regiões acima de $1m$. As matrizes de confusão para os demais classificadores podem ser vistas no apêndice A e também possuem um erro maior em regiões acima de $1m$.




Figura 4.5 Matriz de confusão de todos os 10 *folds* somados para 3NN CNN. Os valores em cada posição da matriz representa a fração do conjunto de teste que foi classificado como coluna dado linha.




Figura 4.6 Matriz de confusão de todos os 10 *folds* somados para Árvore de decisão. Os valores em cada posição da matriz representa a fração do conjunto de teste que foi classificado como coluna dado linha.

Considerações Finais

Neste trabalho foi realizado um estudo sobre o impacto da adição de informação de orientação de um dispositivo wearable a informação de RSSI (Received Signal Strength Indication) de pacotes BLE (Bluetooth Low Energy) para o cálculo de localização. Este trabalho tem grande importância devido ao grande número de dispositivos wearable com possibilidades de possuir IMU (Inertial measurement unit), devido ao baixo custo, e ao padrão BLE possuir baixo consumo de energia.

Inicialmente foram apresentados conceitos básicos sobre BLE e sobre acelerômetros, giroscópios e magnetômetros (dispositivos presentes numa IMU). Logo depois um cenário foi proposto para avaliar o impacto da adição de informação de orientação. Os resultados mostraram que no cenário proposto a adição de informação de orientação aumenta substancialmente a acurácia do sistema baseado em fingerprint, que utiliza aprendizagem de máquina para efetuar a localização.

Para trabalhos futuros pretende-se avaliar cenários mais complexos, com mais variações de posições e também com uma quantidade maior de dongles, não somente com um como foi verificado no cenário proposto neste trabalho. Avaliar também o desempenho do sistema com conexão além de advertesing e avaliar o advertesing utilizando todos os canais. Verificar o desempenho do sistema em tempo real fora de uma ambiente controlado também é um ponto a ser verificado. Avaliar o consumo deste sistema também é ponto que deve ser estudado, uma vez que o cálculo de orientação causa um overhead a mais para o wearable.

APÊNDICE A

Matrizes de Confusão de todos os classificadores

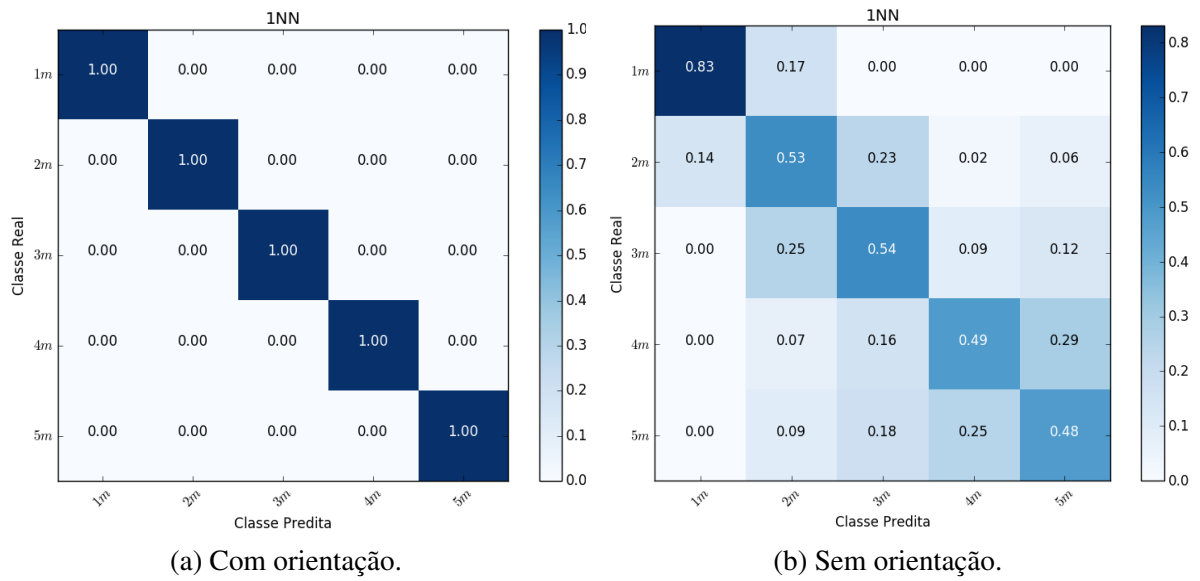


Figura A.1 Matriz de confusão de todos os 10 folds somados para 1NN. Os valores em cada posição da matriz representa a fração do conjunto de teste que foi classificado como coluna dado linha.

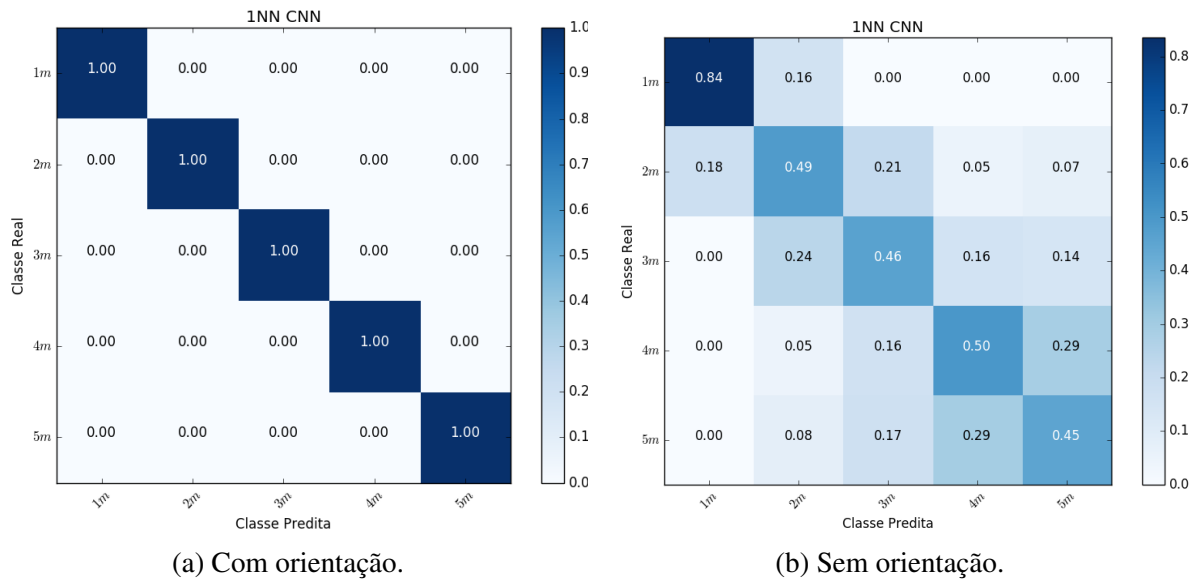


Figura A.2 Matriz de confusão de todos os 10 folds somados para 1NN CNN. Os valores em cada posição da matriz representa a fração do conjunto de teste que foi classificado como coluna dado linha.

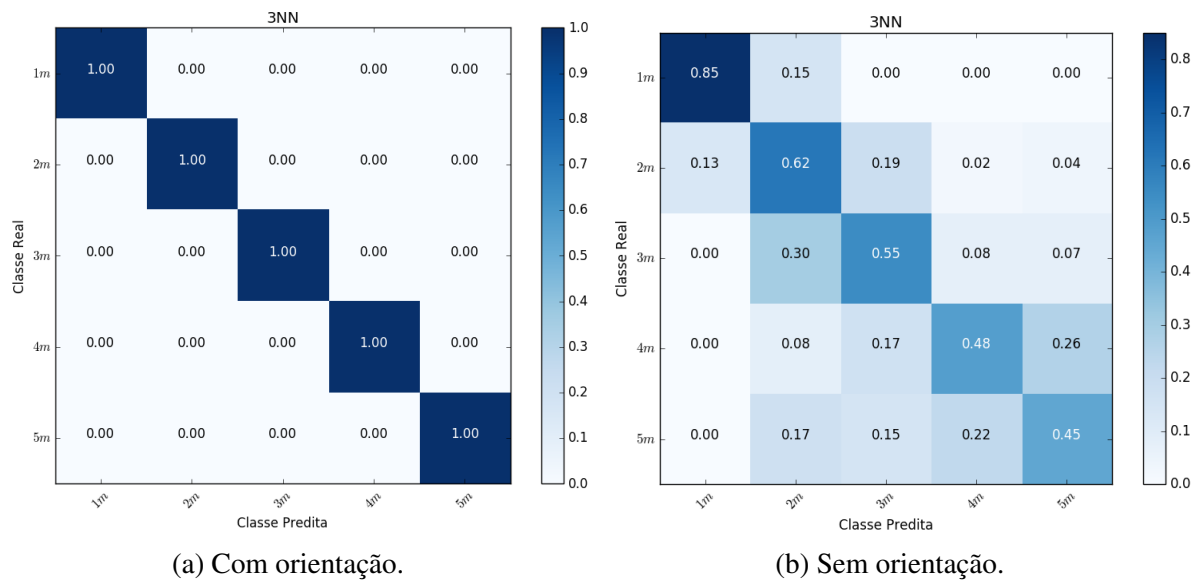


Figura A.3 Matriz de confusão de todos os 10 folds somados para 3NN. Os valores em cada posição da matriz representa a fração do conjunto de teste que foi classificado como coluna dado linha.

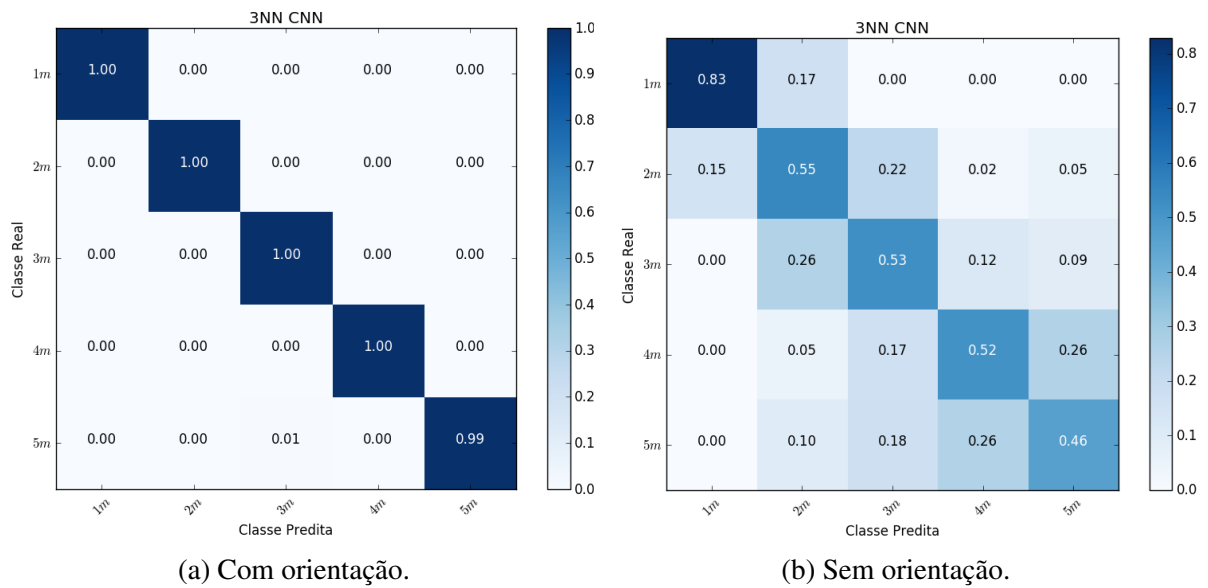


Figura A.4 Matriz de confusão de todos os 10 folds somados para 3NN CNN. Os valores em cada posição da matriz representa a fração do conjunto de teste que foi classificado como coluna dado linha.

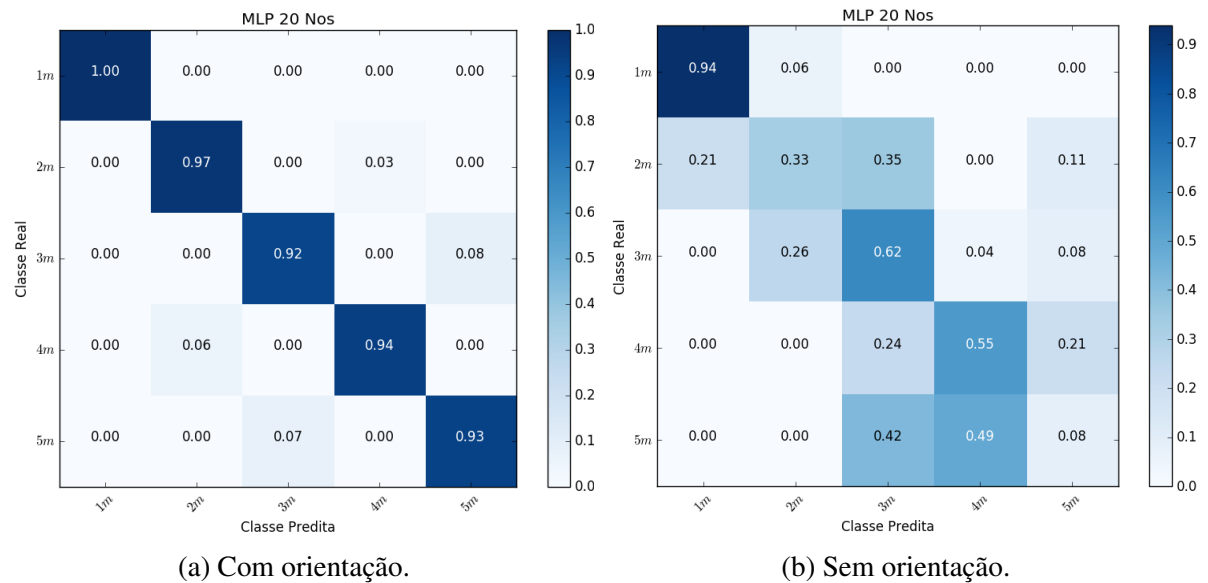


Figura A.5 Matriz de confusão de todos os 10 folds somados para MLP com 20 nos na camada escondida. Os valores em cada posição da matriz representa a fração do conjunto de teste que foi classificado como coluna dado linha.



Figura A.6 Matriz de confusão de todos os 10 folds somados para MLP com 25 nos na camada escondida. Os valores em cada posição da matriz representa a fração do conjunto de teste que foi classificado como coluna dado linha.




Figura A.7 Matriz de confusão de todos os 10 folds somados para MLP com 30 nos na camada escondida. Os valores em cada posição da matriz representa a fração do conjunto de teste que foi classificado como coluna dado linha.




Figura A.8 Matriz de confusão de todos os 10 folds somados para *Árvore de decisão*. Os valores em cada posição da matriz representa a fração do conjunto de teste que foi classificado como coluna dado linha.

APÊNDICE B

Intensidade, Declinação e Inclinação do campo magnético da terra

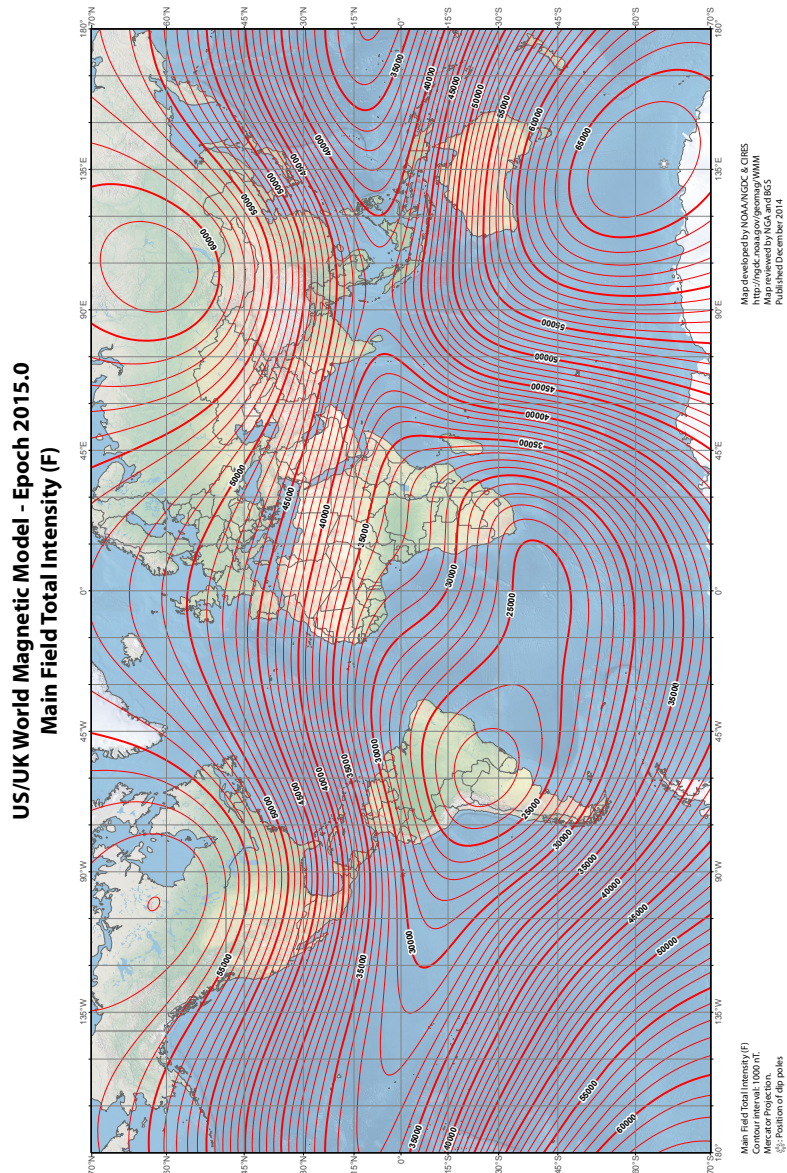


Figura B.1 Intensidade do campo magnético terrestre ao longo do globo.

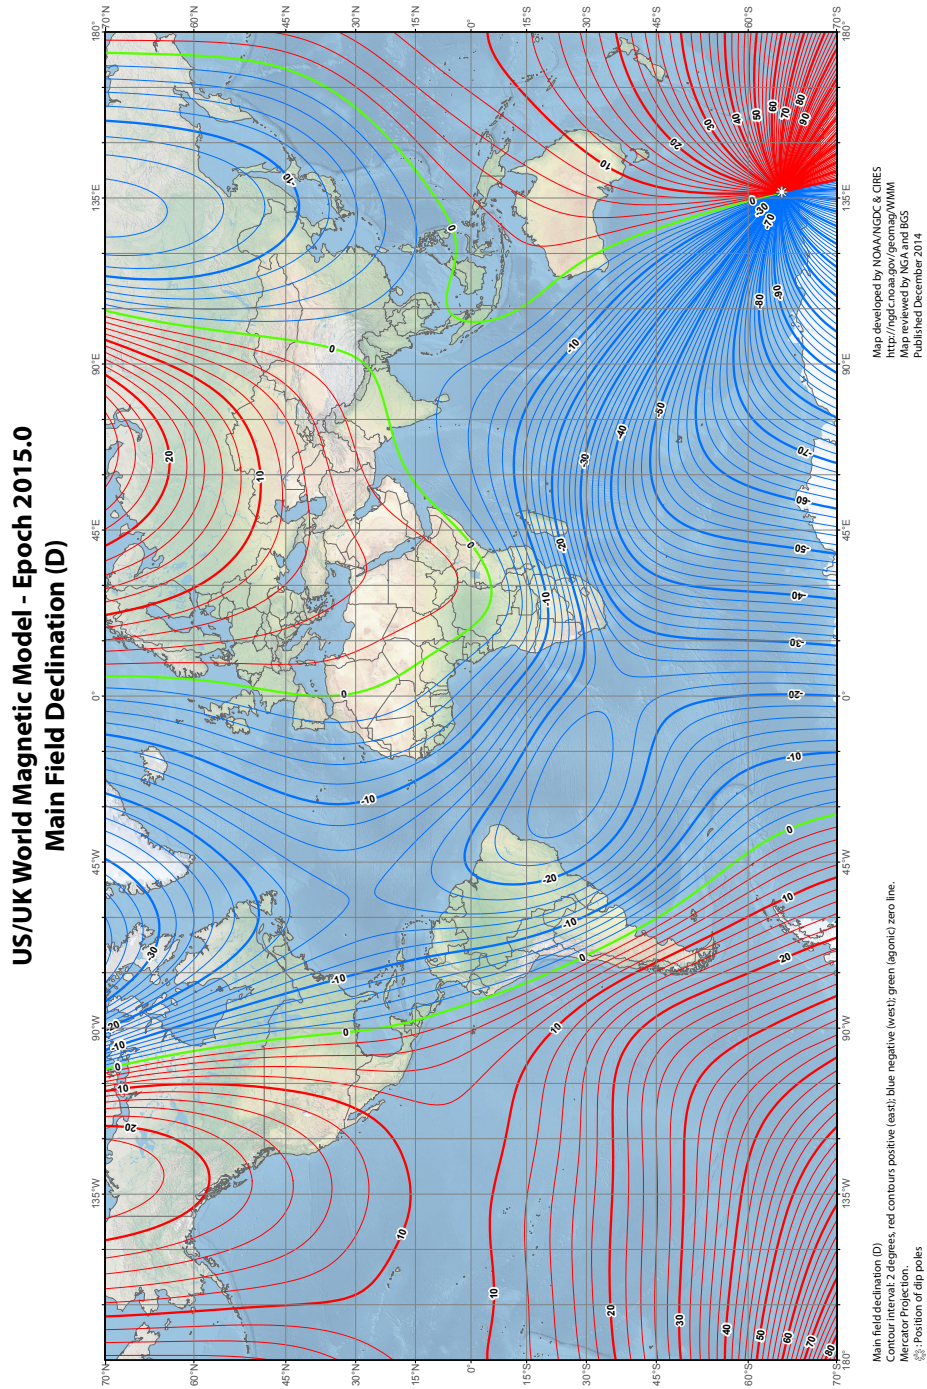


Figura B.2 Declinação do campo magnético terrestre ao longo do globo.

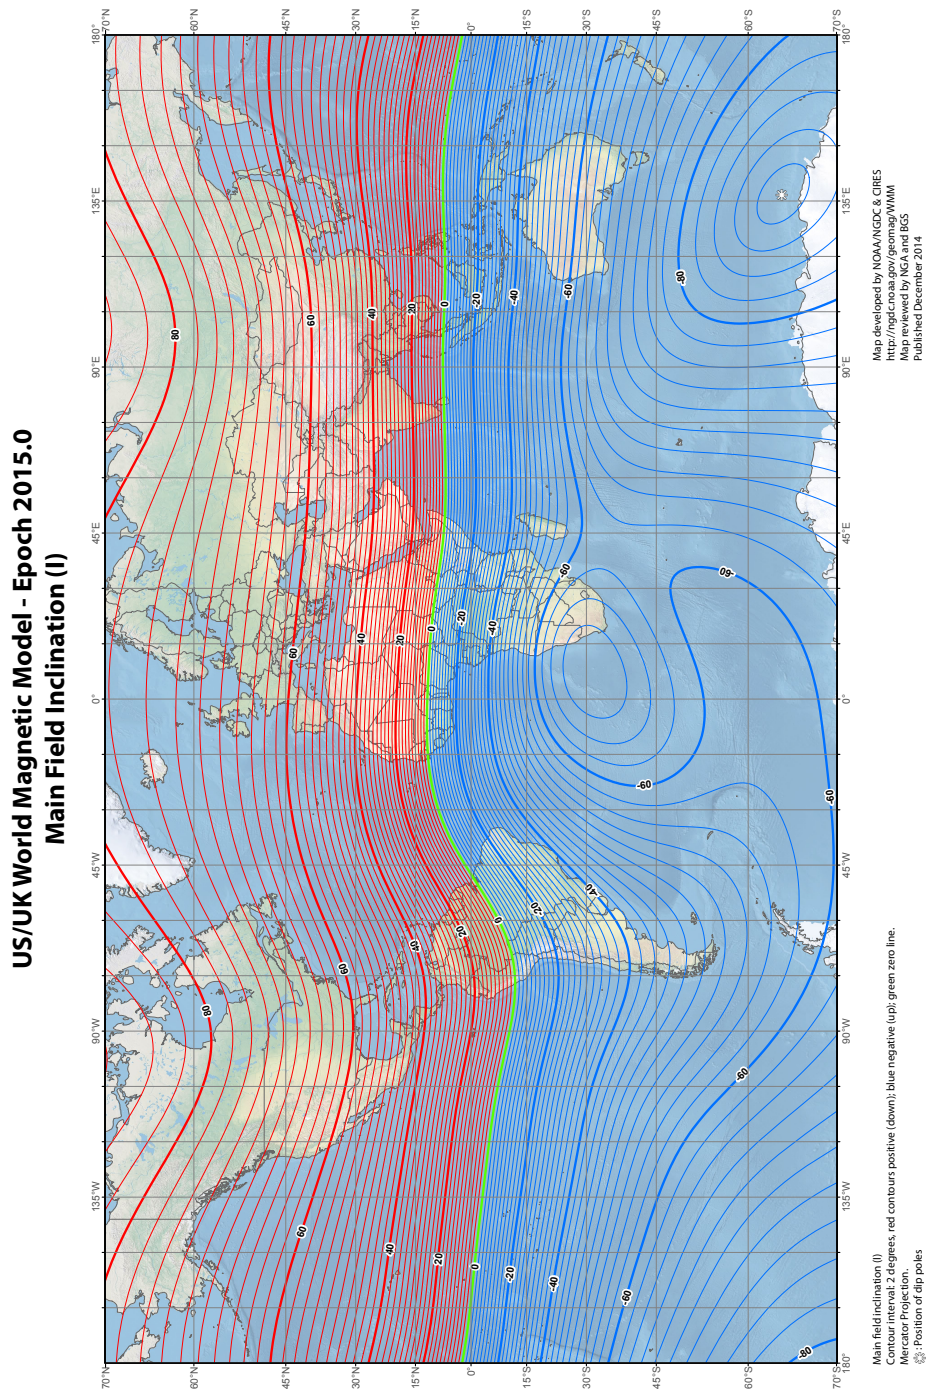


Figura B.3 Inclinação do campo magnético terrestre ao longo do globo.

Referências Bibliográficas

- [BCD⁺16] S. Bertuletti, A. Cereatti, U. Della, M. Caldara, and M. Galizzi. Indoor distance estimated from bluetooth low energy signal strength: Comparison of regression models. In *2016 IEEE Sensors Applications Symposium (SAS)*, pages 1–5, April 2016.
- [Cou17] David Cournapeau. scikit-learn. <http://scikit-learn.org/stable/documentation.html>, 2017. Acessado: 29/06/2017.
- [Fox05] E. Foxlin. Pedestrian tracking with shoe-mounted inertial sensors. *IEEE Computer Graphics and Applications*, 25(6):38–46, Nov 2005.
- [GLN09] Y. Gu, A. Lo, and I. Niemegeers. A survey of indoor positioning systems for wireless personal networks. *IEEE Communications Surveys Tutorials*, 11(1):13–32, First 2009.
- [Ha01] Jeffrey Hightower and Gaetano Borriello and. Location sensing techniques. Technical report, University of Washington, Computer Science and Engineering, 2001.
- [Har68] P. Hart. The condensed nearest neighbor rule (corresp.). *IEEE Transactions on Information Theory*, 14(3):515–516, May 1968.
- [HBCW17] Chi-Huang Hung, Ying-Wen Bai, Ching-Hsiang Chiang, and Hsu-Yao Wu. An improved design of an automatic detection balance tray with an accelerometer, four servo motors, four force-sensitive resistors and an mcu expansion board. In *2017 IEEE International Conference on Consumer Electronics (ICCE)*, pages 49–50, Jan 2017.
- [HH14] Zoltan Horvath and Hanna Horvath. The measurement preciseness of the gps built in smartphones and tablets. *International Journal of Electronics & Communication Technology*, 2014.
- [HSZ17] J. Hua, Z. Shen, and S. Zhong. We can track you if you take the metro: Tracking metro riders using accelerometers on smartphones. *IEEE Transactions on Information Forensics and Security*, 12(2):286–297, Feb 2017.
- [KB14] D. P. Kingma and J. Ba. Adam: A Method for Stochastic Optimization. *ArXiv e-prints*, December 2014.

- [KHM⁺00] J. Krumm, S. Harris, B. Meyers, B. Brumitt, M. Hale, and S. Shafer. Multi-camera multi-person tracking for easy living. In *Proceedings Third IEEE International Workshop on Visual Surveillance*, pages 3–10, 2000.
- [Lin13] Zhongduo Lin. Indoor location-based recommender system. Master’s thesis, Department of Electrical and Computer Engineering, University of Toronto, 2013.
- [LLN⁺16] X. Liu, B. Lu, J. Niu, L. Shu, and Y. Chen. Hmf: Heatmap and wifi fingerprint-based indoor localization with building layout consideration. In *2016 IEEE 22nd International Conference on Parallel and Distributed Systems (ICPADS)*, pages 324–331, Dec 2016.
- [LLS⁺16] Q. Li, W. Li, W. Sun, J. Li, and Z. Liu. Fingerprint and assistant nodes based wi-fi localization in complex indoor environment. *IEEE Access*, 4:2993–3004, 2016.
- [LRS13] A. Leone, G. Rescio, and P. Siciliano. Supervised machine learning scheme for tri-axial accelerometer-based fall detector. In *2013 IEEE SENSORS*, pages 1–4, Nov 2013.
- [Mad10] Sebastian O.H. Madgwick. An efficient orientation filter for inertial and inertial/magnetic sensor arrays. Technical report, x-io Technologies, April 2010.
- [Mit97] Tom M. Mitchell. *Machine Learning*. MCGRAW-HILL UK, 1997.
- [RLBV05] D. Roetenberg, H. J. Luinge, C. T. M. Baten, and P. H. Veltink. Compensation of magnetic disturbances improves inertial and magnetic sensing of human body segment orientation. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 13(3):395–405, Sept 2005.
- [Yur] YuriMat. Magmaster. <https://github.com/YuriMat/MagMaster>. Acessado: 14/06/2017.

