



Evismar Almeida de Andrade

Proposta de métodos para identificação do passo utilizando sensores de dispositivos móveis

Recife

2015

Evismar Almeida de Andrade

Proposta de métodos para identificação do passo utilizando sensores de dispositivos móveis

Monografia apresentada ao Curso de Bacharelado em Sistemas de Informação da Universidade Federal Rural de Pernambuco, como requisito parcial para obtenção do título de Bacharel em Sistemas de Informação.

Universidade Federal Rural de Pernambuco – UFRPE

Departamento de Estatística e Informática

Curso de Bacharelado em Sistemas de Informação

Orientador: Victor Medeiros

Coorientador: Gabriel Alves

Recife

2015

Agradecimentos

Agradeço primeiramente a Deus por ter guiado meus passos até este momento. Onde todos veem uma sequência de coincidências, sortes e frutos apenas do meu esforço pessoal, eu vejo Sua graça em minha vida.

Agradeço a meus pais, Evimar e Iara, à minha irmã Isla pelo suporte emocional e apoio incondicional. Em especial eu agradeço à minha mãe por ter me incentivado a prestar vestibular em um momento em que eu tinha outras pretensões em minha vida. Prestar vestibular e entrar no curso de BSI da UFRPE acabou sendo a melhor decisão que eu poderia ter tomado.

Agradeço à minha melhor amiga, Gabriela Santos, por ouvir minhas lamentações e estar presente nos momentos de alegria, sempre me apoiando e dando forças em todos os momentos, mesmo quando estivemos separados fisicamente, estivemos juntos a todo momento, dando suporte um ao outro.

Agradeço aos meus orientadores Victor Medeiros e Gabriel Alves que mesmo em meio a tantas responsabilidades dedicaram seu tempo, conhecimento e experiência me ajudando a fazer este trabalho de forma mais profissional. Também agradeço ao professor Glauco Golçalves pelas dicas essenciais.

Agradeço aos professores do BSI cuja meta principal é fazer um curso de alto nível, não só em Pernambuco, não só no Brasil, mas no mundo, formando profissionais capazes de resolver os problemas mundiais. Professores que, diferentemente do que vemos em outros cursos, não buscaram apenas uma estabilidade financeira, pelo contrário, têm sede de fazer a diferença, remando contra a maré muitas vezes.

Por último, agradeço aos cidadãos brasileiros que pagam diariamente uma carga absurda de impostos que, entre outras coisas, me possibilitou fazer parte deste curso fantástico que é o BSI da UFRPE.

Resumo

Com o aumento crescente de potencial tecnológico presente nos *smartphones* e *wearables*, associado à redução de seus custos, a sua utilização para fins de análise dos movimentos do corpo humano se torna cada vez mais viável. Diante deste contexto, este trabalho visa descrever o processo de desenvolvimento de métodos de identificação do ciclo da marcha, mais especificamente do momento do passo, utilizando para isso dados dos sensores acelerômetro e giroscópio acoplados a dispositivos móveis. No decorrer deste trabalho, foi desenvolvido um aplicativo para coletar, durante a marcha, as medições dos sensores (acelerômetro e giroscópio) de um *smartphone* com sistema operacional Android. Foram também implementados filtros para o tratamento dos dados de medição e desenvolvidos métodos de identificação do momento do passo através dos dados filtrados do acelerômetro e do giroscópio. Ao final, os métodos desenvolvidos são comparados em termos de melhor desempenho. Como resultado deste trabalho, obtivemos algoritmos que podem ser utilizados por outros grupos de pesquisa que pretendam identificar algumas patologias através da análise da marcha.

Palavras-chave: Ciclo da marcha, acelerômetro, giroscópio, identificação de passos, dispositivos móveis.

Abstract

With the increasing technological potential present in the smartphone and wearables, associated with the reduction of its costs, its use for analysis of the human body movements becomes increasingly feasible. In this context, this paper aims to describe the process of the development of gait cycle identification methods, specifically the moment of the step, through the use of data from the accelerometer and gyroscope sensors coupled to mobile devices. In the course of this project, an application was developed to collect data from the sensors of an Android smartphone during the walk. Filters were implemented for the processing of data, it was also developed algorithms of step moment identification using the filtered data from the accelerometer and gyroscope. Finally, the developed algorithms are compared in terms of better performance and accuracy. As a result of this study, we obtained algorithms that may be used by other research groups who wish to identify some pathologies by gait analysis.

Keywords: Gait cycle, accelerometer, gyroscope, step identification, mobile devices.

Lista de ilustrações

Figura 1 – Eixos do dispositivo	13
Figura 2 – Screenshot da tela de preenchimento dos dados	16
Figura 3 – Posicionamento do dispositivo para a coleta de dados	17
Figura 4 – Telas 2, 3 e 4 do aplicativo de coleta de dados.	17
Figura 5 – Telas 5, 6 e 7 do aplicativo de coleta de dados.	18
Figura 6 – Medições do giroscópio no eixo z e registro do detector de passos do Android, com simulação de caminhada normal	18
Figura 7 – Medições do giroscópio no eixo z e registro do detector de passos do Android, com simulação de caminhada debilitada	19
Figura 8 – Ciclo da marcha.	20
Figura 9 – Resultado da análise de parâmetros temporais da marcha.	22
Figura 10 – Módulo da aceleração (SVM) bruto e filtrado com momento do passo.	23
Figura 11 – Identificação do momento do passo na aceleração vertical e velocidade angular do eixo z do dispositivo.	24
Figura 12 – Relação entre as fases da marcha e os registros do acelerômetro e giroscópio.	24
Figura 13 – Comparação do antes de depois da aplicação da matriz de rotação.	27
Figura 14 – Comparação do antes de depois da suavização utilizando o filtro de média móvel.	29
Figura 15 – Comparação do antes de depois da suavização utilizando o filtro de Savitzky–Golay com polinômio de grau 3.	30
Figura 16 – Comparação do antes de depois da suavização utilizando o filtro de Savitzky–Golay com polinômio de grau 4.	30
Figura 17 – Comparação do antes de depois da suavização utilizando o filtro de Savitzky–Golay com polinômio de grau 10.	31
Figura 18 – Comparação do antes de depois da suavização utilizando o filtro baseado em regressão linear.	32
Figura 19 – Comparação do antes de depois da suavização baseada em regressão linear melhorada.	33

Lista de tabelas

Tabela 1 – Biotipo e idade dos participantes	37
Tabela 2 – Resultados das coletas	38

Sumário

	Lista de ilustrações	5
1	INTRODUÇÃO	9
1.1	Visão geral	9
1.2	Justificativa e motivação	10
1.3	Objetivos	11
1.4	Organização do trabalho	11
2	APLICATIVO DE COLETA	12
2.1	Sensores e Recursos do Android	12
2.1.1	Frequência das Medições	12
2.1.2	Acelerômetro (<i>Sensor.TYPE_ACCELEROMETER</i>)	12
2.1.3	Giroscópio (<i>Sensor.TYPE_GYROSCOPE</i>)	13
2.1.4	Vetor de Rotação (<i>Sensor.TYPE_ROTATION_VECTOR</i>)	13
2.1.5	Detector de Passos Nativo da API Android (<i>Sensor.TYPE_STEP_DETECTOR</i>)	14
2.1.6	Método de Retorno da Angulação do Dispositivo (<i>Sensor.TYPE_ORIENTATION</i>)	15
2.2	Aplicativo de Coleta de Dados	15
2.2.1	Preenchimento das Informações do Indivíduo	15
2.2.2	Posicionamento do Dispositivo	16
2.2.3	Coleta de Medições dos Sensores	16
2.2.4	Envio das Medições	17
2.2.5	Algoritmo de Contagem dos Passos	18
2.2.5.1	Giroscópio	18
2.2.5.2	Detector de Passos do Android	19
3	SOLUÇÕES ALGORÍTMICAS PARA IDENTIFICAÇÃO DE PA- DRÕES DE MARCHA	20
3.1	Momento do Passo	20
3.1.1	Identificação do Momento do Passo	22
3.1.1.1	Aceleração Vertical	23
3.1.1.2	Velocidade angular	25
3.2	Análise da Aceleração Vertical	26
3.2.1	Atitude do Dispositivo Durante Caminhada	26
3.2.2	Redução de Ruídos na Medição	28

3.2.2.1	Filtro de Média Móvel	28
3.2.2.2	Filtro de Savitzky–Golay	29
3.2.2.3	Filtro Baseado em Regressão Linear	31
4	RESULTADOS OBTIDOS	34
4.1	Coleta de Dados	34
4.2	Configuração dos Filtros e Métodos de Identificação de Passos	34
4.3	Análise dos Algoritmos	35
4.3.1	Percentual de Contagem de Passos	35
4.3.2	Média de Erro por Passo Dado	35
4.3.3	Maior Erro Geral	36
4.4	Participantes da Coleta de Dados	36
4.5	Resultados relacionados à acurácia e precisão dos métodos propostos para identificação do passo	37
4.5.1	Resultados Relativos ao Percentual de Contagem de Passos	37
4.5.2	Resultados Relativos à Média de Erro por Passo Dado	38
4.5.3	Resultados Relativos ao Maior Erro Geral	38
4.5.4	Considerações a Respeito do Uso da Aceleração Vertical	39
4.5.5	Considerações a Respeito do Uso da Velocidade Angular	39
5	CONCLUSÕES	40
	REFERÊNCIAS	42

1 Introdução

Este Capítulo busca trazer uma ideia da importância da análise da movimentação do corpo humano, em especial da marcha, demonstrando como os *smartphones* podem ser uma ferramenta valiosa para este tipo de análise. Neste Capítulo também vamos apresentar a motivação e os objetivos do trabalho, assim como as principais atividades realizadas.

1.1 Visão geral

Nos últimos anos, os *smartphones* têm se tornado cada vez mais acessíveis, [Smith \(2013\)](#) afirma que no ano de 2013, nos EUA, o uso de *smartphones* superou o uso dos aparelhos celulares convencionais e a tendência é que não só o uso de *smartphones*, mas também *wearables* como *smartwatches*, se intensifique com o passar do tempo devido aos avanços tecnológicos e redução dos preços. Grande parte destes dispositivos possuem sensores capazes de medir a movimentação humana e isto abre um leque de oportunidades relacionadas a análise destes movimentos para diversos fins como uso esportivo, estudo comportamental, uso hospitalar etc. ([WONG; WONG; LO, 2007](#); [WU et al., 2012](#); [SHOAIB et al., 2014](#))

A medição da postura e movimento humano é uma importante área de pesquisa na bioengenharia e campos de reabilitação. Essa importância se dá pelo fato de que é possível encontrar correlações entre determinados padrões na movimentação do corpo humano e certas patologias, como pode ser observado em [Hausdorff, Rios e Edelberg \(2001\)](#), [Allet et al. \(2015\)](#). A partir das informações coletadas pode-se comparar movimentos normais com movimentos de indivíduos doentes, realizar planejamento e avaliação de protocolos de tratamento e avaliar projetos de órteses e próteses ([WONG; WONG; LO, 2007](#)). Neste contexto, a captura da movimentação do corpo humano através de sensores como acelerômetro e giroscópio (presentes em vários dispositivos móveis) pode ser de grande valor.

A análise da marcha tem um papel importante no reconhecimento de padrões do indivíduo além do prognóstico e diagnóstico de doenças. Diversos artigos se propõem a apresentar uma relação entre padrões da marcha e características do indivíduo como [Hausdorff, Rios e Edelberg \(2001\)](#) que associa a frequência da marcha à probabilidade de queda de pacientes idosos, [Allet et al. \(2015\)](#) demonstra que existe uma diferença significativa entre o padrão de marcha de pessoas saudáveis e pessoas acometidas de diabetes, já [Sun, Wang e Banda \(2014\)](#) demonstra que é possível identificar um indivíduo a partir da forma como caminha. Estes e outros artigos consideram a identificação

do momento do passo como um dos pilares da análise da marcha, pois ela, por si só, já traz informações determinantes para diversas análises. Entretanto, identificar o momento do passo com precisão, utilizando dados de sensores de dispositivos móveis pode ser uma tarefa não trivial devido a variação entre padrões de marcha, ruído dos sinais medidos e orientação do dispositivo durante a caminhada. Neste trabalho, buscamos propor, implementar e testar algoritmos capazes de identificar o momento do passo da forma mais precisa possível, analisando dados provindos de acelerômetros e giroscópios embutidos em dispositivos móveis. Tais algoritmos podem ser bastante úteis em estudos que visam a busca de correlações entre a marcha e determinadas doenças, utilizando recursos acessíveis como *smartphones* e computadores. Estes algoritmos também podem ser aperfeiçoados para uso em ambiente hospitalar para realizar prognósticos e auxiliar a adoção de medidas de prevenção.

1.2 Justificativa e motivação

Identificar o momento exato do passo é essencial em análises da marcha, pois com esta informação é possível encontrar, por exemplo, a frequência de passo, a qual é fundamental em estudos como vistos em [Hausdorff, Rios e Edelberg \(2001\)](#), [Allet et al. \(2015\)](#) e [Sun, Wang e Banda \(2014\)](#). Já existem atualmente aplicativos disponíveis para realizar a contagem de passos disponíveis, inclusive na própria API (*Application Programming Interface*) do Android, porém tais algoritmos simplesmente se propõem a contar passos e não a encontrar o exato momento em que o pé toca o solo. No caso da API do Android, esta falha vai ser demonstrada na Subseção [2.2.5.2](#) e na Seção [4.5](#) deste trabalho. Outros algoritmos baseados na acelerometria se mostram precisos quando testados em jovens saudáveis, porém imprecisos quando se tratam de idosos ou pessoas com debilidades como demonstrado em [Marschollek Mehmet Goevercin e Steinhagen-Thiessen \(2008\)](#). [Jayalath, Abhayasinghe e Murray \(2013\)](#) vai atestar que quase todos os algoritmos de contagem e identificação de passos utilizam dados do acelerômetro, porém eles se mostram imprecisos em caminhadas lentas.

O diferencial deste trabalho está em estudar o ciclo da marcha e suas características representadas na aceleração e na velocidade angular registradas pelos sensores do dispositivo móvel. Primeiramente, filtrando e analisando os dados do acelerômetro levando em conta diferentes tipos de caminhada. Posteriormente filtrando e analisando os dados do giroscópio, o qual raramente é considerado quanto a captura de passos, contudo apresenta um padrão claro da marcha quando acoplado ao tornozelo, isto devido ao movimento pendular da caminhada.

1.3 Objetivos

Como objetivo geral pretende-se implementar e avaliar algoritmos capazes de identificar o exato momento do passo através de dados coletados do acelerômetro e giroscópio, presentes em *smartphones*. Como objetivos específicos pretende-se:

- Desenvolver um aplicativo compatível com o sistema operacional Android, capaz de coletar informações básicas do indivíduo e medições dos sensores embutidos no dispositivo;
- Implementar os filtros de média móvel e Savitsky-Golay, e desenvolver um filtro baseado em regressão linear. Estes filtros serão aplicados na redução de ruído dos dados do acelerômetro e giroscópio;
- Desenvolver um algoritmo capaz de identificar o momento do passo analisando dados tratados do acelerômetro;
- Desenvolver um algoritmo capaz de identificar o momento do passo analisando dados tratados do giroscópio;
- Testar e comparar os métodos de identificação de passo desenvolvidos identificando seus prós e contras.

1.4 Organização do trabalho

O trabalho está organizado em 5 capítulos, os quais são descritos a seguir:

O Capítulo 1 apresenta a introdução do presente trabalho. No Capítulo 2 descrevemos o funcionamento do aplicativo desenvolvido para realizar a coleta de dados. No Capítulo 3 vamos abordar as implementações das soluções desenvolvidas. No Capítulo 4 discutimos os resultados obtidos a partir de testes realizados utilizando um grupo variado de pessoas. Por último, no Capítulo 5 são descritas as conclusões do trabalho.

2 Aplicativo de Coleta

Devido a inexistência de um aplicativo para Android que fornecesse todos os dados necessários para a pesquisa, foi necessário desenvolver um aplicativo que coletasse os dados do acelerômetro, do giroscópio, da orientação do dispositivo, do quaternio e do identificador de passos disponível na própria API do Android (para efeito de comparação).

Após a coleta de dados, o aplicativo possibilita o envio dos dados por e-mail, para que se possa realizar a observação das medições obtidas e a análise dos dados com o objetivo de desenvolver os algoritmos de detecção do instante do passo.

2.1 Sensores e Recursos do Android

Nesta aplicação, procuramos capturar o maior número possível de medições diferentes que pudessem auxiliar em uma melhor análise dos dados coletados. Os recursos da API do Android utilizados foram: acelerômetro, giroscópio, vetor de rotação, detector de passos do Android e método de retorno da angulação do dispositivo. Tais recursos serão detalhados nas subseções seguintes.

2.1.1 Frequência das Medições

No Android não é possível escolher a taxa de frequência da captura dos sensores. Existem opções pré-definidas do *delay* entre registros como: `SENSOR_DELAY_FASTEST`, `SENSOR_DELAY_GAME`, `SENSOR_DELAY_NORMAL`. Entretanto, a quantidade de medições por segundo pode variar a depender do tempo de resposta de cada sensor e do *hardware*.

Devido à inconstância da frequência em que cada sensor é capaz de capturar dados, foi decidido utilizar o `SENSOR_DELAY_FASTEST`, no qual o sensor captura dados na velocidade máxima. Em todos os testes e capturas que foram realizados utilizando um Galaxy S4, a frequência registrada foi de aproximadamente 100 Hz.

2.1.2 Acelerômetro (*Sensor.TYPE_ACCELEROMETER*)

O acelerômetro fornece as acelerações nos três eixos $A_i = (a_x^i, a_y^i, a_z^i)^T$ em m/s^2 , incluindo a aceleração da gravidade ($9.81 m/s^2$). O retorno deste sensor corresponde respectivamente às acelerações nos eixos x, y, z que podem ser observados na Figura 1.




Figura 1 – Eixos do dispositivo
(SENSORS..., 2015)

A API do Android fornece, para os sistemas mais recentes, o sensor de aceleração linear (`Sensor.TYPE_LINEAR_ACCELERATION`) que corresponde à aceleração nos 3 eixos $L_i = (l_x^i, l_y^i, l_z^i)^T$ excluindo a aceleração gravitacional (SENSORS..., 2015).

Para este trabalho, a aceleração gravitacional é descartável, por esta razão, decidimos utilizar a aceleração linear do Android, contudo vale salientar que é possível chegar aos mesmos resultados utilizando a aceleração com gravidade, como demonstrado na Subseção 3.2.1.

2.1.3 Giroscópio (`Sensor.TYPE_GYROSCOPE`)

Todos os valores estão em radianos por segundo e através deste sensor podemos obter a velocidade do giro nos três eixos $G_i = (g_x^i, g_y^i, g_z^i)^T$. O sistema de coordenadas é o mesmo utilizado para o sensor de aceleração. A rotação é positiva no sentido anti-horário (SENSORS..., 2015).

2.1.4 Vetor de Rotação (`Sensor.TYPE_ROTATION_VECTOR`)

A API do Android também fornece o Vetor de Rotação de onde podemos extrair o quatérnio. Quatérnios fornecem uma representação matemática da rotação de objetos em três dimensões e são vastamente utilizados em computação gráfica, robótica, navegação e jogos. Neste trabalho, utilizamos o quatérnio para compor a matriz de rotação a ser utilizada na decomposição dos vetores das acelerações, que inicialmente estão relacionados aos eixos x, y, z do aparelho, para encontrarmos a aceleração vertical real (tomando como referência o centro da terra). O quatérnio é uma

forma de um número imaginário que pode ser representado por $(w + x_i + y_j + z_k)$ onde w é a parte real e x, y e z as partes imaginárias. Através do método `SensorManager.getQuaternionFromVector()`, passando como parâmetro o valores do vetor de rotação, é possível obter o quatérnio $Q_i = [w_i, x_i, y_i, z_i]^T$ cujo os valores correspondem :

- $w_i : \cos(\theta/2)$;
- $x_i : x * \text{seno}(\theta/2)$;
- $y_i : y * \text{seno}(\theta/2)$;
- $z_i : z * \text{seno}(\theta/2)$.

Onde θ corresponde ao ângulo de rotação ao redor dos eixos do quatérnio. Com estes valores é possível montar a matriz de rotação descrita na Subseção 3.2.1 ([SENSORS...](#), 2015).

2.1.5 Detector de Passos Nativo da API Android (`Sensor.TYPE_STEP_DETECTOR`)

O Android fornece uma API de detecção de passos que, a princípio, pode ser uma forma fácil e rápida de capturar os eventos dos passos, porém durante o estudo percebemos algumas incompatibilidades do uso do detector de passos do Android e ambientes hospitalares, ou testes que requerem máxima precisão na marcação dos passos. As incompatibilidades são as seguintes:

- O algoritmo de detecção de passos tenta encontrar o momento dos passos de ambas as pernas, o problema disso é que a maioria dos estudos relacionados a análise da marcha busca analisar o chamado *stride*, ou seja, intervalo de tempo entre dois passos dados com a mesma perna;
- Esta API ([SENSORS...](#), 2015) também retorna apenas o momento de cada passo, o que impossibilita saber se o passo foi dado com a perna direita ou esquerda;
- Em testes percebemos que o detector de passos apresenta um excelente resultado quando o indivíduo caminha com velocidade aproximada de 1 Hz entre passadas, levando aproximadamente 5 segundos para identificar o padrão de marcha e a partir daí registrar os passos. Contudo, quando simulamos uma caminhada lenta, o detector de passos se mostrou ineficiente, onde em uma caminhada de 150 passos foi capaz de registrar apenas 9, isto pode ser observado na Subseção 2.2.5.2.

2.1.6 Método de Retorno da Angulação do Dispositivo (*Sensor.TYPE_ORIENTATION*)

Esta API ([SENSORS...](#), 2015) retorna a orientação em graus do dispositivo nos três eixos $O_i = (o_x^i, o_y^i, o_z^i)^T$. A notação destes valores é dada em relação ao *azimuth*, *pitch* e *roll* que correspondem aos eixos de rotação z , x e y do dispositivo, respectivamente.

- o_x^i : Retorna o *azimuth*, corresponde ao ângulo entre a direcção do norte magnético e do eixo y , em torno do eixo z (0° a 359°). 0° = Norte, 90° = Leste, 180° = Sul, 270° = Oeste;
- o_y^i : Retorna o *pitch*, rotação em torno do eixo x (-180° a 180°), com valores positivos quando o eixo z se move na direcção do eixo y ;
- o_z^i : Retorna o *roll*, rotação em torno do eixo y (-90° a 90°) aumentando à medida que o dispositivo se move no sentido horário.

A princípio, o uso deste método seria de grande uso, pois bastaria identificar os momentos em que o dispositivo está em determinada posição para identificar se a perna estava levantada ou apoiada por exemplo, porém ao analisar os dados coletados observamos que os valores obtidos através deste método não são confiáveis e não correspondem ao esperado.

2.2 Aplicativo de Coleta de Dados

O aplicativo de coleta de dados é constituído basicamente de 4 partes: preenchimento das informações do indivíduo, posicionamento do dispositivo e coleta das medições dos sensores.

2.2.1 Preenchimento das Informações do Indivíduo

A tela de preenchimento de dados possui um formulário de informações básicas do indivíduo do qual será feita a coleta. Este formulário busca registrar características físicas que tracem um perfil para o indivíduo. Isto possibilita que se possa registrar as medições de uma pessoa que possua determinada patologia e comparar com as medições de uma pessoa normal de mesmo perfil físico e assim procurar padrões relacionados à doença.

Esta tela é composta dos seguintes campos:

- Nome/Código (nome ou código do indivíduo);

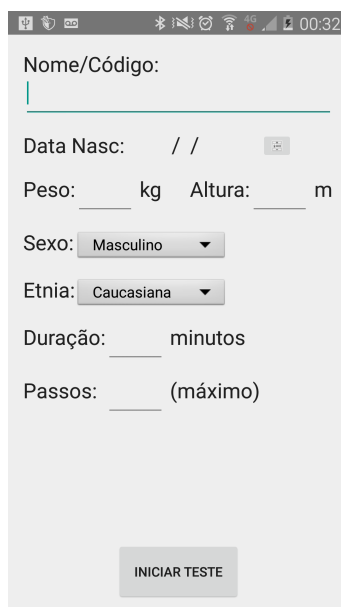


Figura 2 – Screenshot da tela de preenchimento dos dados

- Data de nascimento (dd/mm/aaaa);
- Altura (em metros);
- Peso (em quilogramas);
- Sexo;
- Etnia (parda, caucasiana ou negra);
- Duração (em minutos, corresponde ao tempo máximo da duração do teste);
- Passos (corresponde à quantidade máxima de passos desejada).

2.2.2 Posicionamento do Dispositivo

Após o preenchimento do formulário, a pessoa responsável por realizar a coleta deve posicionar o dispositivo conforme a Figura 3, na perna direita ou esquerda. Quando o dispositivo estiver posicionado da maneira correta, deverá pressionar o botão iniciar (Figura 4a) e instruir o indivíduo a caminhar buscando manter a frequência de passos até que lhe seja solicitado parar.

2.2.3 Coleta de Medições dos Sensores

O aplicativo iniciará a contagem do tempo exibindo-o no visor (Figura 4b), porém só iniciará o registro das medições após os 10 segundos iniciais, os últimos 10 segundos de coleta também são removidos. O descarte de parte inicial e final da coleta minimiza os efeitos de início e finalização da caminhada (HAUSDORFF; RIOS;



Figura 3 – Posicionamento do dispositivo para a coleta de dados

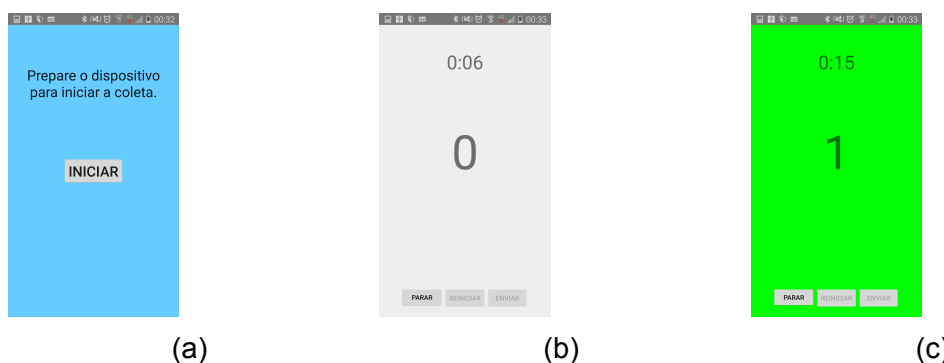


Figura 4 – Telas 2, 3 e 4 do aplicativo de coleta de dados.

EDELBERG, 2001). Quando o aplicativo atingir o tempo máximo de duração prevista para a coleta, a aplicação finaliza a coleta e habilita o botão de envio dos dados.

Após os 10 segundos iniciais o fundo da tela do aplicativo mudará da cor cinza para a cor verde, assim como, quando o tempo limite de de coleta for alcançado, o fundo da tela assumirá a coloração vermelha. O intuito da mudança de cores, visíveis na Figuras 4a,4b,4c e 5a, é proporcionar ao responsável por aplicar a coleta uma identificação visual do *status* da coleta. Desta forma, mesmo à uma certa distância, é possível visualizar que o aplicativo encerrou a coleta.

2.2.4 Envio das Medições

Caso o responsável pela coleta deseje encerrá-la antes do tempo previsto, é possível fazê-lo pressionando o botão parar e enviar em sequência (Figuras 4c e 5a). Após isso, o usuário poderá escolher por qual meio deseja enviar os dados da coleta, dando preferência ao envio por e-mail.

Ao selecionar o envio por e-mail, o sistema cria o corpo do e-mail com os dados preenchidos na tela e algumas informações adicionais a respeito da contagem dos passos. O sistema também anexa um arquivo `dados_medicao.csv` que conterà os registros de medição.

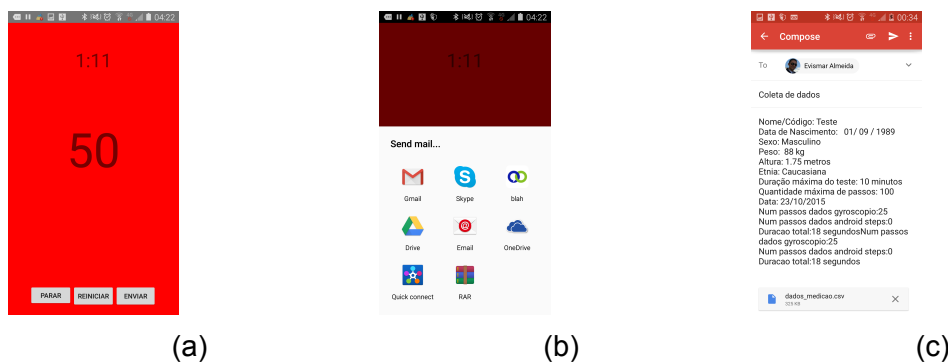


Figura 5 – Telas 5, 6 e 7 do aplicativo de coleta de dados.

2.2.5 Algoritmo de Contagem dos Passos

Como pode ser observado nas Figuras 4c e 5a o aplicativo já conta os passos durante a caminhada, porém esta contagem serve apenas para o responsável pela coleta ter uma noção de quantos passos foram dados durante a caminhada. Esta contagem é imprecisa pois utiliza um algoritmo simples que verifica apenas limiares. Diante disto, o motivo pelo qual este algoritmo de contagem é utilizado é unicamente pelo seu baixo custo computacional. Um algoritmo mais elaborado resultaria em uma maior necessidade de processamento por parte do dispositivo, o que poderia acarretar em redução na taxa de amostragem dos sensores.

Comparando a utilização do giroscópio e do detector de passos do Android, optamos por utilizar o giroscópio, pois mesmo sendo impreciso, igualmente ao detector de passos do Android, ele registra apenas os passos dados com a perna de interesse, como apresentado nas próximas seções.

2.2.5.1 Giroscópio




Figura 6 – Medições do giroscópio no eixo z e registro do detector de passos do Android, com simulação de caminhada normal

A contagem é feita a partir da velocidade angular registrada a partir do eixo z do dispositivo. Como pode-se observar, na Figura 6, a amplitude da velocidade an-

gular varia entre aproximadamente 6 rad/s e -4 rad/s e segue um padrão durante a marcha. O que o algoritmo de contagem faz é identificar (durante a caminhada) os momentos em que a velocidade está em decréscimo entre os valores 3 rad/s e 2 rad/s . Estes limiares são fixos e se adequam bem para passadas com uma frequência de aproximadamente 1 Hz.

Simulações de caminhada muito lentas com frequência de passadas menor que 0.3 Hz demonstraram que este algoritmo não se adequa a todos os tipos e é não confiável, pois não foi capaz de reconhecer todos os passos (Figura 7). Isto se dá pois como a frequência da passada é mais lenta, a velocidade angular também se torna mais lenta e sua amplitude é reduzida.




Figura 7 – Medições do giroscópio no eixo z e registro do detector de passos do Android, com simulação de caminhada debilitada

2.2.5.2 Detector de Passos do Android

Através da Figura 6, se observarmos a linha vermelha, notaremos que os valores registrados são binários, ou seja, 1 para passo e 0 para não passo. É possível observar também que o intervalo entre os passos se mantém constantes durante o trecho exibido. Cada registro de valor 1 vai indicar um passo independentemente se este será da perna esquerda ou direita. Como pudemos observar em artigos como [Hausdorff, Rios e Edelberg \(2001\)](#), é fundamental identificar o momento da passada de cada perna específica, pois boa parte dos estudos são feitos relacionados à frequência dos passos da mesma perna e não de ambas.

Outro fator que impossibilita a utilização do detector de passos do Android é a sua imprecisão, dado o fato que ele busca, em tempo de execução, reconhecer o padrão de marcha independentemente de onde esteja posicionado (ex. bolso, perna, calcanhar). Esta falha pode ser demonstrada na Figura 7 onde ele não pode identificar os passos simulados de uma pessoa debilitada.

3 Soluções Algorítmicas para Identificação de Padrões de Marcha

Como pode-se observar em [Wong, Wong e Lo \(2007\)](#), [Sun, Wang e Banda \(2014\)](#), [Hausdorff, Rios e Edelberg \(2001\)](#) muito esforço tem sido despendido no intuito de encontrar padrões de marcha, cada um com seu objetivo em particular. Neste trabalho, o foco principal é encontrar o momento exato de cada passada, ou seja, o instante em que o pé toca o solo. Embora seja aparentemente algo trivial de ser feito, a grande variedade de padrões de caminhada, que variam de acordo com a idade, gênero e condições físicas, trazem uma complexidade a mais. Neste capítulo, vamos apresentar as possíveis implementações da análise dos dados coletados desenvolvidas durante este trabalho.

3.1 Momento do Passo

Antes de começar a desenvolver as soluções de identificação do passo, é necessário entender o ciclo da marcha e suas fases, após isso correlacioná-lo aos dados da aceleração e giro coletados através do aplicativo.

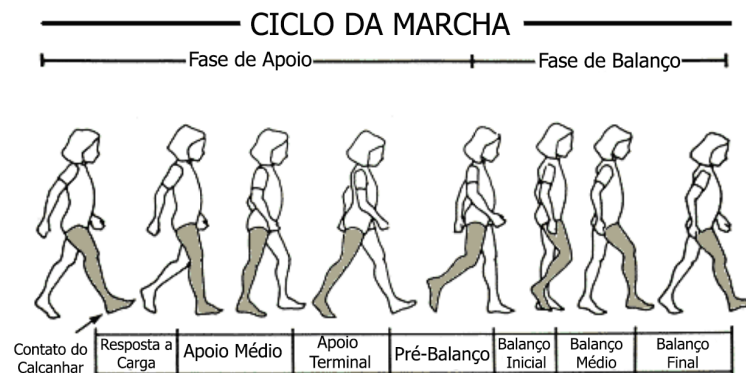


Figura 8 – Ciclo da marcha.

([RAFAJLOVIĆ](#); [GAVRILOVIĆ](#); [MIJAILOVIĆ](#), 2009)

A Figura 8 divide as fases da marcha em duas principais; fase de apoio e fase de balanço. Estas fases estão relacionadas, no processo de caminhada, a cada uma das pernas individualmente. A fase de apoio compreende todo o tempo em que a perna em questão está em contato com o solo. Começa com um contato do calcanhar e continua com as subfases: resposta à carga, apoio médio, apoio terminal e pré-balanço. A separação dos dedos do pé do chão marca o início da fase de balanço que envolve as seguintes subfases: balanço inicial, balanço médio e balanço Final, iniciando assim a

fase de apoio novamente. Neste trabalho buscamos identificar a primeira subfase da fase de apoio, o contato do calcanhar com o solo.

Lee et al. (2010) desenvolveu uma análise utilizando dois acelerômetros de três eixos, cada um posicionado na parte lateral de cada tornozelo de forma similar à Figura 3. Também foram colocados sensores nas palmilhas de cada calçado, um sensor na região do calcanhar e outro na região da ponta do pé, para identificar os exatos momentos de início das fases de apoio e balanço e compará-los à aceleração capturada. Através deste experimento pode-se obter o seguinte resultado:

Em Lee et al. (2010) a aceleração tri-dimensional é transformada em um *Signal Vector Magnitude (SVM)* onde $SVM = \sqrt[2]{a_y^2 + a_x^2 + a_z^2}$.

Os módulos da aceleração do pés esquerdo e direito foram plotados juntamente com o status dos sensores da palmilha ao longo de três passos para a comparação. Os dois gráficos superiores indicam sinais brutos dos acelerômetros e os dois gráficos inferiores representam os sinais filtrados. Como pode ser observado, o sensor do calcanhar é pressionado após a crista maior nos três casos, aproximadamente entre a crista e a sua base.

Para validar se o mesmo padrão se repetia quando utilizando o acelerômetro do celular, modificamos o aplicativo descrito no Capítulo 2 para capturar o evento do clique do botão do fone de ouvido e posicionamos o botão do fone de ouvido do aparelho celular no calçado, abaixo do calcanhar. Deste modo, a pressão exercida pelo peso da pessoa sobre o botão de fone de ouvido aciona-o, marcando o momento do passo. Para efeito de comparação, também utilizamos o módulo da aceleração (SVM) descrito em Lee et al. (2010).

É possível observar nas Figuras 10a e 10b que o momento do passo registrado pelo pressionar do botão do fone de ouvido coincide com o mesmo momento da Figura 9. Para a filtragem do dado bruto nos utilizamos o filtro de Savitzky–Golay demonstrado na Subseção 3.2.2.3. Diferentemente de Lee et al. (2010), nós decidimos utilizar a aceleração vertical para fazer as análises e não o módulo das acelerações, a razão para isto se dá pelo fato da aceleração vertical ser bem mais expressiva que as demais durante a marcha, pois corresponde ao levantar a abaixar da perna, fase que corresponde ao balanço.

Na Figura 11a observamos que quando utilizamos apenas a aceleração vertical, o momento do toque do calcanhar no solo se aproxima mais do vale posterior à crista maior, em alguns casos estando exatamente em seu centro. Similarmente, o mesmo ocorre no caso da velocidade angular representada na Figura 11b, onde o momento do passo é corresponde ao vale posterior a crista maior, porém de maneira mais precisa que na aceleração vertical. De posse destas informações podemos montar agora ciclo

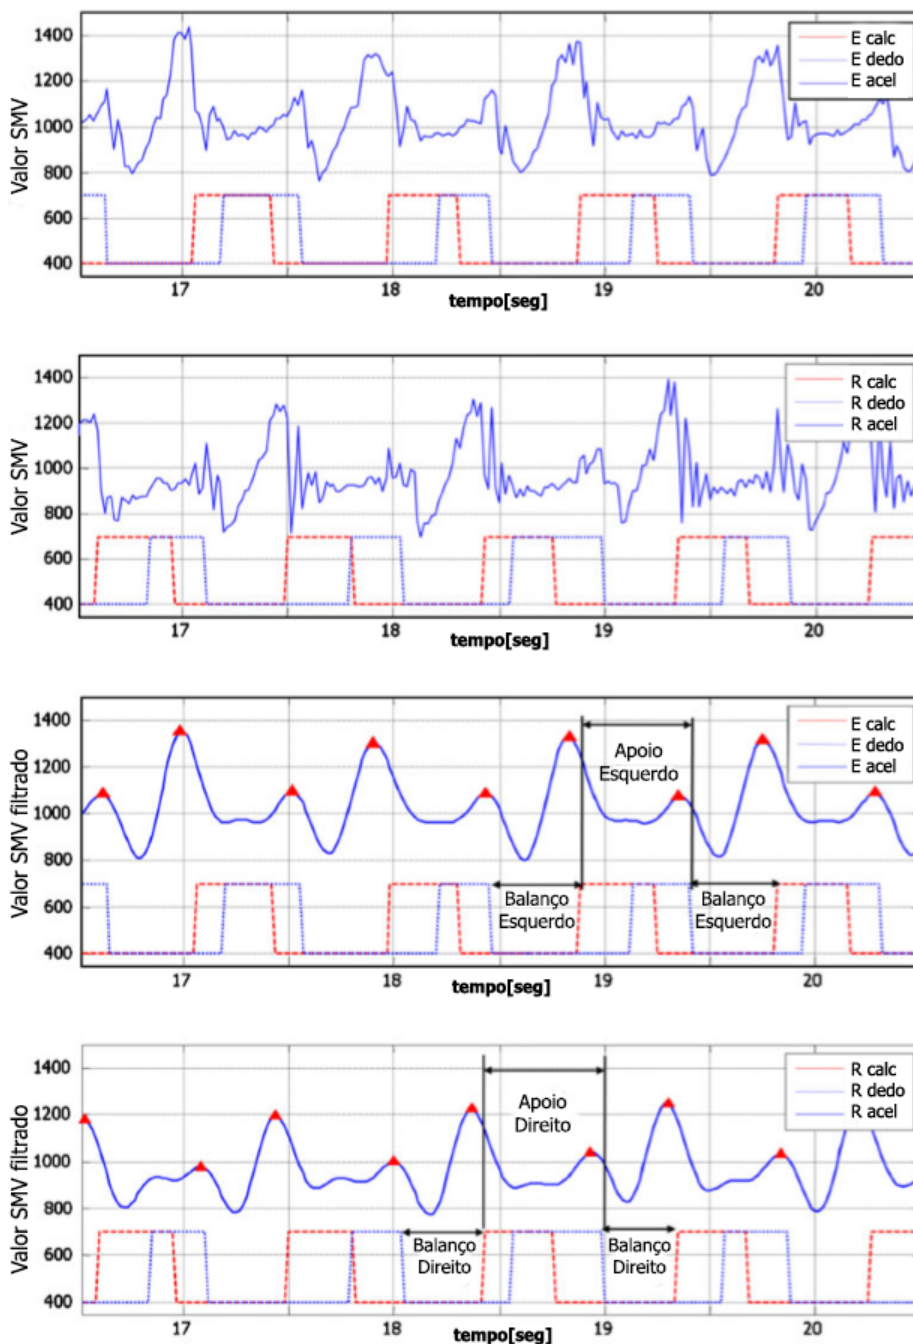


Figura 9 – Resultado da análise de parâmetros temporais da marcha. (LEE et al., 2010)

de marcha adequado à aceleração vertical e à velocidade angular, como pode ser observado nas Figuras 12a e 12b respectivamente .

3.1.1 Identificação do Momento do Passo

Nesta Subsecção vamos abordar as duas formas encontradas de realizar a identificação do momento do passo utilizando os sensores dos dispositivos móveis. Utilizando a aceleração vertical, proveniente da aceleração no eixo y do dispositivo, e da

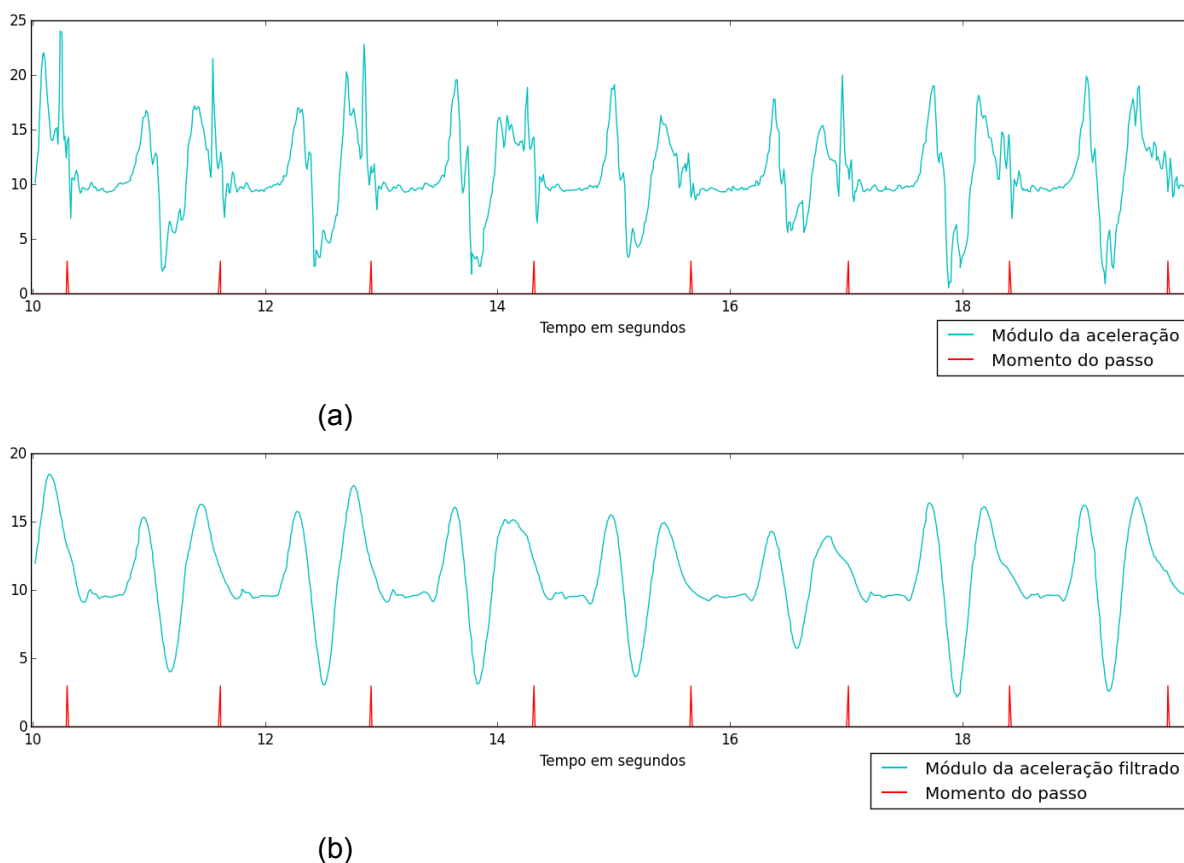



Figura 10 – Módulo da aceleração (SVM) bruto e filtrado com momento do passo.

velocidade angular, proveniente do eixo z do giroscópio do dispositivo.


3.1.1.1 Aceleração Vertical

Ao observar as Figuras 12a e 11a, é possível notar um padrão característico da marcha. Na fase de balanço, a aceleração realiza um movimento ondulatório em forma de V , isto se dá pelo movimento vertical que o pé faz nesta fase. Partindo do princípio que este movimento é obrigatório para a marcha, mesmo para marchas de velocidade mais lenta, desenvolvemos um algoritmo de reconhecimento de passos que funciona da seguinte forma:

- Define-se um valor mínimo (l') de amplitude que uma crista tem que ter para ser considerada uma das cristas que formam o V da fase de balanço;
- Define-se um valor mínimo (l'') que um vale tem que ter para ser considerado o vale que forma o V da fase de balanço;
- Valores booleanos são atribuídos a $c1$, v e $c2$ que correspondem respectivamente à existência da primeira crista, do vale e da segunda crista da fase de balanço. Caso o algoritmo de identificação de passos encontre os as cristas e o vale ne-

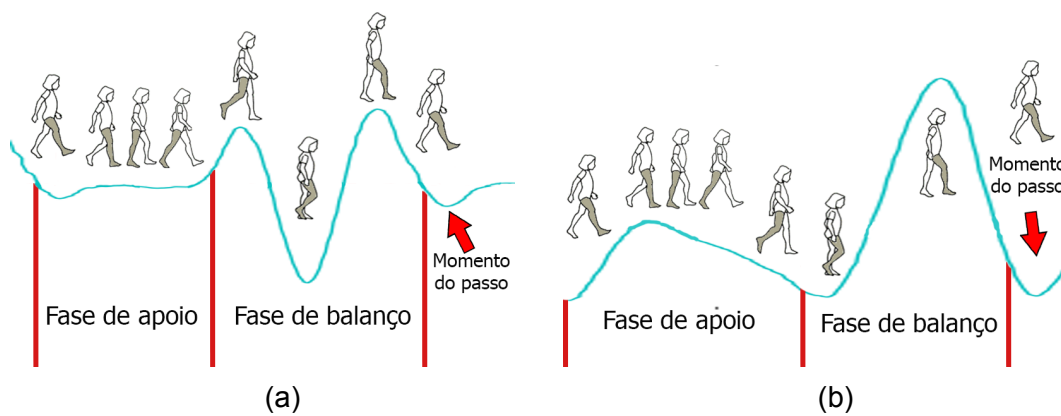


(a)



(b)

Figura 11 – Identificação do momento do passo na aceleração vertical e velocidade angular do eixo z do dispositivo.



(a)

(b)

Figura 12 – Relação entre as fases da marcha e os registros do acelerômetro e giroscópio.

cessários para compor o V correspondente a fase de balanço, estas variáveis são definidas como verdadeiras;

- Caso $c1$, v e $c2$ sejam verdadeiros, o próximo vale será considerado passo.

Como a intensidade da marcha varia de acordo com o biotipo, idade e outras características pessoais, fica inviável definir um valor fixo para l'' , logo, definimos um valor para ele baseando-se na variação das acelerações da marcha. Para isto, dividimos os valores da aceleração em 2 blocos, um só com os valores positivos e um só com os valores negativos, então encontramos o valor do desvio padrão para o bloco dos valores negativos. A partir deste valor, podemos definir as seguintes equações; $l'' = -\sigma''k$, onde σ'' e k , equivalem ao desvio padrão das acelerações negativas e variável de correção, respectivamente. No caso de l' , entendemos que qualquer valor acima de 0 pode ser considerado crista, logo, $l' = 0$. Vale ressaltar que este algoritmo, pode não ser tão eficaz caso o tipo de marcha da pessoa fuja totalmente ao padrão descrito na Figura 8 (Alguém que ande arrastando os pés por exemplo).

3.1.1.2 Velocidade angular

Nas Figuras 12b e 11b também é possível identificar um padrão na marcha, onde nitidamente o momento do passo ocorre sempre próximo ao vale posterior à crista maior, característica da fase de balanço. O algoritmo de reconhecimento de passos baseado na velocidade angular funciona da seguinte forma:

- Define-se um valor mínimo (l) de amplitude que a crista maior tem que ter para ser considerada a crista que precede o passo;
- Um valor booleano é atribuído a c que corresponde à existência da crista;
- Caso c seja verdadeiro, o próximo vale será considerado passo.

Da mesma forma que a intensidade da aceleração provocada pelo passo varia de pessoa para pessoa, a velocidade da caminhada também varia, e isto influencia diretamente na velocidade angular no eixo z . Desta forma, definimos um valor para l também baseado no desvio padrão, devido ao fato da crista ser uma velocidade positiva, utilizamos os valores positivos dos sinais para calcular o desvio padrão, definindo a equação como $l = \sigma k$, onde σ e k , equivalem ao desvio padrão das velocidade positivas e variável de correção, respectivamente.

3.2 Análise da Aceleração Vertical

As medições de aceleração no eixo y do dispositivo, vem sendo utilizada em diversos trabalhos (WONG; WONG; LO, 2007; RAFAJLOVIĆ; GAVRILOVIĆ; MIJAILOVIĆ, 2009; LEE et al., 2010) com o objetivo de encontrar o momento da passada. Esta abordagem faz bastante sentido partindo do princípio de que o levantar e baixar dos pés durante a marcha é nítido na leitura das medições devido ao efeito da aceleração e da desaceleração no respectivo eixo (WILLEMSSEN; BLOEMHOF; BOOM, 1990). Entretanto, existem duas dificuldades ao lidar com os dados da aceleração vertical do dispositivo celular: A atitude/orientação do dispositivo e o ruído na medição, que serão descritas em sequência. Para o tratamento e análise da aceleração vertical, utilizamos os dados enviados pelo aplicativo de coleta de medições, explanado na Seção 2.

3.2.1 Atitude do Dispositivo Durante Caminhada

A atitude ou orientação de um objeto corresponde ao posicionamento deste objeto no espaço tridimensional, logo a atitude do dispositivo vai influenciar fundamentalmente no registro das medições, pois as acelerações registradas pelo aplicativo correspondem às acelerações sofridas pelo aparelho nos seus eixos. Isto significa que, considerando um dispositivo em estado de repouso, a aceleração no eixo y não necessariamente corresponderá a aceleração da gravidade, pois dependerá de como o dispositivo está posicionado.

Se o dispositivo estiver posicionado de maneira tal que o visor esteja perpendicular à superfície, como observado na Figura 1, o acelerômetro tende a registrar 1g no eixo y . Caso o visor esteja voltado para cima, em posição paralela à superfície da terra, o acelerômetro tende a registrar 1g no eixo z . Na hipótese do dispositivo estar com o visor na posição perpendicular em relação à superfície, tendo a lateral como apoio, o acelerômetro tende a registrar 1g no eixo x .

Como pode ser observado na Figura 8, durante a caminhada a perna realiza uma movimentação pendular. Este tipo de movimento é principalmente notado na região compreendida entre o joelho e o pé. Levando em consideração que o dispositivo estará fixado à perna, como demonstrado na Figura 3, o dispositivo também sofrerá este efeito de pêndulo, logo, parte da aceleração da gravidade, que a princípio deveria ser totalmente destinado ao eixo y , será somada aos eixos x e y . Da mesma maneira, a aceleração vertical provocada pela suspensão e apoio do pé no chão, durante a caminhada, será distribuída entre os eixos x , y e z , dependendo da atitude do dispositivo durante o registro, conseqüentemente as acelerações horizontais e laterais também serão distribuídas entre os eixos x , y e z do dispositivo.

Para solucionar os problemas relacionados à atitude do dispositivo, foi utilizada

uma matriz de rotação (SUN; WANG; BANDA, 2014) que utiliza quatérnios para encontrar a aceleração vertical real. Esta matriz de rotação visa identificar a aceleração vertical real sofrida pelo dispositivo de medição, tomando como referência o centro da terra e não mais o eixo y do dispositivo, independente da atitude do dispositivo.

Para encontrar a matriz de transformação T_{om}^i para $t = i$, de acordo com o quatérnio em tempo real $Q_i = [w_i, x_i, y_i, z_i]^T$. A matriz de transformação (HENDERSON, 1977) é

$$T_{om}^i = \begin{bmatrix} 1 - 2(y_i^2 + z_i^2) & 2(x_i y_i - w_i z_i) & 2(x_i z_i + w_i y_i) \\ 2(x_i y_i + w_i z_i) & 1 - 2(x_i^2 + z_i^2) & 2(y_i z_i - w_i x_i) \\ 2(x_i z_i - w_i y_i) & 2(y_i z_i + w_i x_i) & 1 - 2(x_i^2 + y_i^2) \end{bmatrix}$$

Como a API Android já fornece a aceleração linear, basta utilizar a matriz de transformação para achar a aceleração real $R_i = (r_x^i, r_y^i, r_z^i)^T$ sem a necessidade de subtrair a aceleração vertical.

$$\begin{bmatrix} r_x^i \\ r_y^i \\ r_z^i \end{bmatrix} = T_{om}^i \begin{bmatrix} a_x^i \\ a_y^i \\ a_z^i \end{bmatrix}$$

Onde r_x^i e r_y^i são as acelerações horizontais e r_z^i é a aceleração vertical.

Aplicando a matriz de rotação, pode-se observar o seguinte resultado:




Figura 13 – Comparação do antes de depois da aplicação da matriz de rotação.

Pode-se observar na Figura 13 que os picos de aceleração tendem a ser maiores após a transformação. Isto ocorre pois na fase de balanço, ou seja, fase em que o pé é suspenso e antecede o passo, existe uma inclinação do dispositivo, logo, parte da aceleração vertical era destinada ao eixo x no dispositivo. Após a conversão da aceleração vertical do dispositivo em aceleração vertical real, os ruídos dos dados se intensificaram significativamente.

3.2.2 Redução de Ruídos na Medição

Mesmo após acharmos a aceleração vertical real do dispositivo, ainda temos o problema do ruído dos dados. Os ruídos podem ser causados por diversas razões como: mal posicionamento do dispositivo, falha dos sensores, aparato de fixação do dispositivo à perna com folga etc. Aparentemente, os ruídos observados na coleta dos dados realizada para este trabalho são provenientes da vibração do dispositivo após uma mudança de aceleração brusca, como o passo. Para resolver ou mitigar a questão do ruído nos dados, foram implementados três algoritmos, o filtro de Média Móvel, o filtro passa baixa de Savitzky–Golay e um algoritmo baseado em regressão linear, proposto neste trabalho.

3.2.2.1 Filtro de Média Móvel

Segundo [Cerqueira et al. \(2000\)](#) o filtro de média móvel tornou-se, nos últimos anos, uma ferramenta de uso comum para a suavização de ruído em sinais analíticos. O motivo para tal popularidade deve-se à sua simplicidade teórica e à sua incorporação a diversos *softwares* comerciais. A ideia do algoritmo é basicamente substituir o valor intermediário de uma série de intervalos pelo valor da média do intervalo, repetindo o processo por toda a série de dados sempre com um intervalo de mesmo tamanho de ponto a ponto, o processo é o seguinte:

1. Define-se o número total de pontos dos dados (n_1);
2. Define-se o número de pontos do intervalo (n_2), onde n_2 é um número ímpar;
3. Define-se a origem do sinal (x_i), $i = INT(n_2/2) + 1$;
4. Obtém-se a média dos pontos do intervalo;
5. Obtém-se o valor do dado filtrado como sendo a média do intervalo;
6. Incrementa-se o valor de i e repete-se as etapas 4 e 5;
7. Finaliza-se o processo quando $i = n_1 - INT(n_2/2)$.

Como n_2 tem que ser um número ímpar, para que o elemento do meio seja substituído, utilizamos o filtro de média móvel, com a largura do intervalo igual a 51 (equivalente a aproximadamente 0,5 segundos). Pudemos obter então o resultado apresentado na Figura 14:

Pode-se notar uma redução considerável do ruído nos dados, porém também é perceptível uma redução na amplitude dos valores da aceleração no momento do passo. Variando o valor do tamanho do intervalo pôde-se perceber que quanto menor




Figura 14 – Comparação do antes de depois da suavização utilizando o filtro de média móvel.

o tamanho do intervalo, mais próximo o valor da aceleração filtrada se aproxima da aceleração real no momento do passo, porém o ruído também se aproxima do ruído original. Quando testamos um intervalo maior, podemos observar que tanto o ruído quanto a aceleração no momento do passo eram reduzidos.

3.2.2.2 Filtro de Savitzky–Golay

O filtro de Savitzky–Golay é um dos filtros passa baixa mais utilizados e referenciados na suavização de sinais analíticos e é incorporado em boa parte dos *softwares* de tratamentos de dados. A vantagem do filtro de Savitzky–Golay é que a suavização dos dados é feita através do ajuste dos pontos do intervalo (janela) por um polinômio e não pela simples média dos pontos vizinhos. A ideia básica do método de Savitzky–Golay é a seguinte (CERQUEIRA et al., 2000):

1. Define-se a origem do sinal;
2. Define-se a largura do intervalo;
3. Define-se o ponto central do intervalo;
4. Remove-se o ponto central do conjunto de pontos do intervalo;
5. Ajusta-se através do método de mínimos quadrados, um polinômio de grau variável aos pontos restantes;
6. Utiliza-se o polinômio para estimar o valor do ponto removido;
7. Desloca-se o intervalo para o ponto seguinte do sinal original e repete-se o processo anterior.

Utilizando o filtro de Savitzky–Golay, com os parâmetros de largura do intervalo igual a 11 e grau do polinômio igual a 3. A escolha de um intervalo de tamanho 11 se

dá pelo fato de que este algoritmo tem uma maior capacidade de representar curvas, logo, utilizando um intervalo de tempo menor (aproximadamente 0,1 segundo) temos uma maior proximidade com características do passo. O polinômio de ordem 3 seria o menor valor possível para obtermos as curvas desejadas na filtragem, neste caso as curvas tendem a ter um comprimento de onda maior. O resultado obtido é apresentado na Figura 15.




Figura 15 – Comparação do antes de depois da suavização utilizando o filtro de Savitzky–Golay com polinômio de grau 3.

Como pode ser observado, os ruídos, por terem uma alta frequência, são praticamente eliminados. Podemos notar também que a amplitude da aceleração vertical é reduzida, contudo já é possível ter uma visão muito mais clara da curva de aceleração que constitui o passo.

Já com um intervalo de 51 medições e um polinômio de grau 4 obtivemos o resultado apresentado na Figura 16.




Figura 16 – Comparação do antes de depois da suavização utilizando o filtro de Savitzky–Golay com polinômio de grau 4.

Utilizando um polinômio de grau 4 podemos perceber que o novo gráfico alcança aproximadamente a mesma amplitude no momento do passo, também é possível observar uma quantidade maior ondas nos instantes que correspondem ao ruído.

Caso utilizemos um polinômio de ordem 10 obteremos o resultado apresentado na Figura 17.




Figura 17 – Comparação do antes de depois da suavização utilizando o filtro de Savitzky–Golay com polinômio de grau 10.

Quanto maior a ordem do polinômio, maior o efeito de ondulação do gráfico após a filtragem. Podemos notar na Figura 17 que a filtragem passa a se comportar de forma mais parecida à medição inicial, inclusive nos ruídos. Portanto há de se observar qual intervalo de medições e qual grau do polinômio melhor atende cada situação.

3.2.2.3 Filtro Baseado em Regressão Linear

Como dito anteriormente, o ruído no registro da aceleração vertical corresponde a uma mudança brusca na aceleração em um curto intervalo de tempo. Partindo deste princípio, encontrando a linha de tendência entre estes registros é possível anular a variação brusca na aceleração. A definição de linhas de tendência a partir de registros não ruidosos no entanto, não descaracteriza a medição, pois estes registros tendem a manter um padrão de subida ou descida. Levando isto em consideração, a proposta inicial de do filtro baseado em regressão linear seria dividir todo período a ser analisado em intervalos T_i de tamanho n e, posteriormente, para cada intervalo definir uma linha de tendência baseada na equação $r_i = b_0 + b_1 t_i$. Onde:

- r_i : novo valor da aceleração filtrada;
- x_i : b_0 e b_1 : variáveis a serem definidas a partir dos valores no intervalo T_i ;
- t_i : tempo no intervalo T_i .

Utilizando um intervalo T_i de $n = 10$ (equivalente a aproximadamente 100 milissegundos), pôde-se obter o resultado apresentado na Figura 18:

Como pode-se observar, os vales maiores correspondentes ao passo tendem a se manter e boa parte do ruído é eliminado, contudo a característica curvilínea das medições é totalmente descaracterizada e com isso muita informação pode ser perdida.




Figura 18 – Comparação do antes de depois da suavização utilizando o filtro baseado em regressão linear.

Além disso, ruídos com vales ou cristas com comprimento de onda maiores que 100 milissegundos tendem a se manter, visivelmente representados próximos ao segundo 26 da Figura 18.

Após observar o funcionamento do filtro de Savitzky–Golay, pôde-se perceber que muitos problemas relacionados acima poderiam ser reduzidos se fossem implementadas as seguintes mudanças:

- Trabalhar com um intervalo de tempo maior para definição da equação linear. Desta forma a linha de tendência definida pela regressão linear no intervalo tende a ser menos susceptível a ruídos;
- Ao invés de substituir todos os valores no intervalo pelos valores obtidos através equação resultante, apenas o valor intermediário será substituído e o intervalo andar­á mais uma posição repetindo o processo. Por esta razão o tamanho do intervalo tem que ser ímpar.

Aplicando as modificações supracitadas e utilizando uma intervalo de tamanho 51 (aproximadamente 500 milissegundos) pôde-se obter o resultado demonstrado na Figura 19.

Após a utilização deste filtro pôde-se perceber uma nítida melhora na suavização do ruído, sem perda dos picos de aceleração. Uma desvantagem deste algoritmo está no custo computacional, considerando que para cada ponto de medição um cálculo de regressão linear deve ser feito, envolvendo uma quantidade razoável de pontos. Outra desvantagem é que este algoritmo gera um deslocamento no tempo à esquerda no gráfico, sendo necessário deslocá-lo novamente para a direita após o filtro. Neste exemplo, o *offset* foi de aproximadamente 12 milissegundos. Entretanto, como o fim principal das aplicações de análise da frequência da marcha é conside-




Figura 19 – Comparação do antes de depois da suavização baseada em regressão linear melhorada.

rar os intervalos de tempo entre cada passada, este problema é irrelevante, pois os intervalos entre passos se mantém.

4 Resultados Obtidos

Neste capítulo vamos demonstrar as soluções algorítmicas desenvolvidas no Capítulo 3 postas em prática, coletando dados de indivíduos diferentes e analisando estes dados com os diferentes algoritmos. Ao fim, as soluções algorítmicas desenvolvidas serão comparadas em termos de melhor desempenho.

4.1 Coleta de Dados

Procuramos manter um padrão na duração de cada coleta, o tempo foi fixado em 5 minutos de caminhada para todos os participantes, os quais foram orientados a manter a frequência da marcha normal durante todo o tempo, sem pausas.

O mesmo dispositivo foi utilizado em todas as coletas de dados para evitar discrepâncias relacionadas às diferenças de hardware e software de outro dispositivo. Faz-se necessário um estudo comparativo posterior para descobrir até onde dispositivos móveis diferentes podem variar em relação à captura de dados dos sensores. Este estudo estava fora do escopo deste trabalho e pode ser considerado em trabalhos futuros. O dispositivo utilizado foi um Samsung Galaxy S4, registrando as medições a uma velocidade aproximada de 100 Hz.

Para medir a precisão dos métodos de identificação do passo, definidos nos capítulos anteriores, utilizamos o botão do microfone preso ao calcanhar, como descrito na Seção 3.1. Os registros dos momentos dos passos capturados pelo botão do microfone foram utilizados como parâmetro de comparação para os demais métodos de captura. No texto a seguir este método de captura do momento exato do passo será definido como método de referência.

4.2 Configuração dos Filtros e Métodos de Identificação de Passos

Após diversos testes, identificamos quais seriam os melhores parâmetros para os filtros e métodos de identificação do passo, porém estas escolhas foram feitas de forma subjetiva, como base nos testes mencionados.

Para os Métodos de identificação temos os seguintes valores:

- Aceleração vertical: $k = 0.5$;
- Velocidade angular: $k = 1.5$.

A descrição do que correspondem estes valores estão nas Subseções [3.1.1.1](#) e [3.1.1.2](#) respectivamente.

Para os Filtros temos os seguintes valores:

- Média Móvel: janela de tamanho 11 para aceleração vertical e velocidade angular;
- Savitzky-Golay: janela de tamanho 31 e polinômio de ordem 4 para aceleração vertical e janela de tamanho 51 e polinômio de ordem 4 para velocidade angular;
- Regressão Linear: janela de tamanho 31 para aceleração vertical e janela de tamanho 51 para velocidade angular.

A descrição do que correspondem estes valores estão nas Subseções [3.2.2.1](#), [3.2.2.2](#) e [3.2.2.3](#) respectivamente.

Estes foram os valores utilizados para realização dos testes a serem apresentados. Vale salientar que a alteração destes parâmetros podem resultar em resultados melhores ou piores.

4.3 Análise dos Algoritmos

O algoritmos foram analisados de acordo com os seguintes critérios:

4.3.1 Percentual de Contagem de Passos

Neste critério, os algoritmos serão comparados segundo sua capacidade em identificar a quantidade de passos, onde serão comparados a quantidade de passos identificados pelo algoritmo com a quantidade de passos real registradas no momento da coleta.

4.3.2 Média de Erro por Passo Dado

Para cada passo dado registrado pelo sensor adaptado no calçado, o método de referência, o algoritmo de identificação de passos deve registrar um passo no momento correspondente.

A média do erro por passo dado é dada pela Equação [4.1](#) onde: n equivale ao número total de passos identificados pelo método de referência;

x_i equivale ao momento em milissegundos do passo i no método de referência;
 y_i equivale ao momento em milissegundos do passo i indicado pelo método avaliado.

$$\sum_{i=1}^n \frac{|x_i - y_i|}{n} \quad (4.1)$$

Foi necessário definir um valor limite l para o erro. Caso $|x_i - y_i| > l$, aquele passo não será computado, nem adicionado a n por entendermos que o algoritmo não foi capaz de identifica-lo. Tendo em mente que o ciclo da marcha de uma pessoa normal é, em média, aproximadamente 1 Hz, entendemos que 700 milissegundos é um valor adequado para l .

4.3.3 Maior Erro Geral

Este critério mostra o valor de maior discrepância entre o momento real do passo e o momento previsto pelo algoritmo, vale salientar que este valor também deve ser inferior a 700 milissegundos.

4.4 Participantes da Coleta de Dados

Para validar os métodos de identificação de passos desenvolvidos neste trabalho, foram realizados testes utilizando dados de 4 de pessoas de idades e biotipos diferentes, com o intuito de identificar se os algoritmos eram capazes de reconhecer o exato momento do passo em pessoas com padrão de caminhada diferentes. A Tabela 1 descreve as características dos participantes da coleta.

Para um melhor posicionamento do texto nas tabelas, utilizamos as seguintes abreviações:

- M e F, correspondem a Masculino e Feminino;
- P e C, correspondem a Parda e Caucasiana;
- S e N, correspondem a Sim e Não;
- D.L. corresponde à Dificuldade de Locomoção;
- Q.P. corresponde à Quantidade de passos dados;
- A.V. corresponde ao uso da Aceleração Vertical;
- V.A. corresponde ao uso da Velocidade Angular no eixo z ;
- M.M. corresponde ao uso do filtro de Média Móvel;

Tabela 1 – Biotipo e idade dos participantes

<i>Pessoa</i>	<i>Sexo</i>	<i>Idade</i>	<i>Peso(Kg)</i>	<i>Altura(m)</i>	<i>Etnia</i>	<i>D.L</i>	<i>Q.P</i>
<i>P1</i>	<i>M</i>	26	86	1,75	<i>P</i>	<i>N</i>	246
<i>P2</i>	<i>F</i>	78	61	1,47	<i>P</i>	<i>N</i>	242
<i>P3</i>	<i>F</i>	49	63	1,53	<i>C</i>	<i>S</i>	255
<i>P4</i>	<i>F</i>	26	55	1,62	<i>C</i>	<i>N</i>	262

- S.G. corresponde ao uso do filtro de Savitsky Golay;
- R.L. corresponde ao uso do filtro baseado em Regressão Linear;
- D.P.A. corresponde ao Detector de Passos do Android;
- P.C.P. corresponde ao Percentual obtido na Contagem de Passos;
- M.E.P. corresponde à Média de Erro que o algoritmo apresentou por Passo dado (em milissegundos);
- M.E.G. corresponde ao Maior Erro Geral do momento da identificação do momento do passo.

4.5 Resultados relacionados à acurácia e precisão dos métodos propostos para identificação do passo

A Tabela 2 apresenta um comparativo dos resultados dos diferentes algoritmos desenvolvidos ao longo deste trabalho a partir da análise da marcha dos participantes descritos na Tabela 1.

Além dos testes realizados com os participantes P1, P2, P3 e P4, foi incluída para testes uma simulação, onde o participante P1 simulou passos aleatórios de pessoas com caminhada muito lenta, com variação de tempo no ciclo da marcha e tropeços. Esta simulação tem o objetivo de testar uma situação que foge aos padrões convencionais de caminhada para ver como os algoritmos se comportam. Para melhor visualização, os melhores resultados em cada critério estão destacados em cinza.

4.5.1 Resultados Relativos ao Percentual de Contagem de Passos

De acordo com os resultados, pode-se dizer que os algoritmos desenvolvidos obtiveram, na maioria dos casos, resultados similares, identificando todos ou quase todos os passos, exceto o detector de passos do Android na simulação PS que só identificou 36% dos passos. Isto se explica pela dificuldade que este método tem em identificar marchas muito lentas, além de precisar de um tempo para identificar uma

Tabela 2 – Resultados das coletas

		A.V+ M.M	V.A+ M.M	A.V+ S.G	V.A+ S.G	A.V+ R.L	V.A+ R.L	D.P.A
P1	P.C.P	99,6%	100%	99,2%	100%	99,6%	100%	100%
	M.E.P	62ms	32ms	70ms	21ms	29ms	34ms	444ms
	M.E.G	252ms	252ms	268ms	240ms	217m	258ms	699ms
P2	P.C.P	95,0%	100%	99,5%	99,4%	97,1%	100%	96,2%
	M.E.P	67ms	41ms	79ms	38ms	61ms	17ms	406ms
	M.E.G	221ms	143ms	247ms	222ms	275ms	100ms	699ms
P3	P.C.P	93,3%	100%	100%	100%	94,1%	100%	98,8%
	M.E.P	53ms	23ms	70ms	11ms	67ms	10ms	572ms
	M.E.G	161ms	128ms	156ms	61ms	271ms	52ms	699ms
P4	P.C.P	99,6%	100%	100%	100%	99,6%	100%	99,6%
	M.E.P	107ms	18ms	96ms	9ms	67ms	10ms	594ms
	M.E.G	179ms	118ms	160ms	39ms	167ms	50ms	699ms
PS	P.C.P	99,4%	99,4%	100%	99,4%	98,8%	99,4%	36,0%
	M.E.P	144ms	54ms	157ms	38ms	108ms	65ms	430ms
	M.E.G	672ms	181ms	672ms	222ms	513ms	243ms	699ms

mudança no padrão da marcha, o que ocorreu diversas vezes na simulação. De forma geral, V.A + MM (velocidade angular tratada pelo filtro de média móvel) teve um melhor resultado neste critério, entretanto A.V + S.G (velocidade angular tratada pelo filtro de Savitzky-Golay foi o único método capaz de identificar todos os passos em PS).

4.5.2 Resultados Relativos à Média de Erro por Passo Dado

Neste critério os resultados foram bem diferentes entre os algoritmos utilizados, porém nota-se que entre as filtragens de mesmo tipo os algoritmos que utilizaram a velocidade angular obtiveram resultados consideravelmente superiores aos que utilizaram a aceleração vertical. Sendo o filtro de Savitzky-Golay e o filtro baseado em Regressão Linear os que obtiveram os melhores resultados. O detector de passos do Android teve um atraso médio de aproximadamente meio segundo por passo, isso se dá pelo fato do algoritmo não identificar como passo no seu instante e sim na fase de balanço da marcha.

4.5.3 Resultados Relativos ao Maior Erro Geral

Os resultados relacionados à maior discrepância entre o momento real do passo e o momento previsto também variaram bastante, onde mais uma vez o filtro de Savitzky-Golay e o filtro baseado em Regressão Linear obtiveram os melhores resultados. Pode-se observar também que em todos os casos, o valor para o detector de passos do

Android foi de 699 milissegundos, isso ocorre por conta do limiar l estabelecido, correspondente a 700 milissegundos.

4.5.4 Considerações a Respeito do Uso da Aceleração Vertical

Os resultados mostram que, com um certo grau de imprecisão, a aceleração vertical pode ser usada para a identificação do passo, porém, a depender do nível de precisão requerida, pode não ser uma boa alternativa. Isto, levando em conta os algoritmos desenvolvidos neste trabalho. A falta de precisão neste caso, está mais ligada ao ruído provocado pelo momento do passo.

Após a filtragem do sinal da aceleração o ruído desaparece, ou é reduzido quase que completamente. Através das conclusões descritas na Subseção 3.1.1.1, percebemos que o momento do passo fica então entre a crista que descreve o fim da fase de balanço e o início da fase de apoio. Para padronizar, definimos este ponto como sendo o vale posterior a crista, mas os resultados mostram que nem sempre esta premissa está correta.

4.5.5 Considerações a Respeito do Uso da Velocidade Angular

Utilizando os métodos e algoritmos desenvolvidos neste trabalho, através do resultado exibido na Tabela 2, é nítido que o uso da aceleração vertical foi superior à aceleração vertical na identificação do momento dos passos, isto se dá pela fácil visualização do momento do passo descrita na Subseção 3.1.1.2, além da baixa incidência de ruídos neste tipo de sinal. Uma observação interessante é que os resultados foram ainda mais precisos nos indivíduos que deram uma maior quantidade de passos dentro do tempo estipulado, indicando um ritmo mais acelerado de passadas e um tempo menor no ciclo da marcha. É possível notar que a precisão do momento do passo é diretamente proporcional a velocidade da marcha de acordo com os resultados obtidos a partir da amostra, onde quanto maior a velocidade da marcha, maior a precisão em milissegundos. Possivelmente isto se justifique pelo fato de que o valor da discrepância entre momento real e momento previsto do passo é proporcional a duração do ciclo de marcha utilizando o mesmo método de filtragem e identificação do passo.

5 Conclusões

Neste trabalho concluímos que dispositivos móveis têm um grande potencial para realizar análises de marcha, possibilitando este tipo de análise em situações em que faltam recursos especializados. No intuito de testar a aplicabilidade de dispositivos móveis dotados de sensores como acelerômetro e giroscópio na análise da marcha, foram desenvolvidos neste trabalho um aplicativo para realizar a coleta das medições dos sensores, algoritmos de redução de ruído e de identificação do momento do passo.

Ao observar os sinais obtidos do acelerômetro e giroscópio concluímos que se faz necessário tratar os sinais obtidos. Tal necessidade se dá pelo fato dos dados brutos serem bastante ruidosos, o que na prática inviabiliza uma análise mais precisa. Com este fim, foram implementados os filtros de média móvel, Savitsky Golay e foi desenvolvido um filtro baseado em regressão linear. Foi identificado que o ciclo de marcha reproduz um padrão característico tanto na aceleração vertical, quanto na velocidade angular, o que possibilitou a implementação de algoritmos de reconhecimento. Ao identificar este padrão, e reconhecendo cada fase da marcha ali reproduzido, se torna viável a localização do momento do passo, sem a necessidade de sensores de pressão acoplados a palmilhas, por exemplo.

Após os testes realizados pudemos concluir que, no tocante a identificação do momento do passo, os sinais obtidos a partir do giroscópio tendem a ser mais nítidos que os sinais a partir do acelerômetro. Foi observado também que os sinais do giroscópio após filtragem do algoritmo de Savitzky-Golay e do filtro baseado em Regressão Linear foram mais precisos em prever o momento do passo que os demais métodos de identificação.

No desenvolver deste trabalho, percebemos que alguns estudos posteriores podem ser realizados nesta linha de pesquisa, estes estudos incluem:

- Aperfeiçoamento do método de identificação do momento do passo utilizando aceleração vertical;
- Comparação de diferentes dispositivos quanto à precisão e calibração de sensores;
- Replicação, utilizando sensores de dispositivos móveis, de estudos que utilizam acelerômetros e giroscópios acoplados ao corpo humano para análise de movimentação.

Além de estudos que podem ser realizados em parceria com áreas mais especializadas em fisiologia e saúde, estes estudos incluem:

- Identificação de patologias associadas à frequência de marcha;
- Identificação e prognóstico de doenças que possam ser identificadas a partir da análise da marcha;
- Identificação e prognóstico de doenças que possam ser identificadas a partir da análise da movimentação de outros membros.

Referências

- ALLET, L. et al. Gait alterations of diabetic patients while walking on different surfaces. v. 29, n. 3, p. 488–493, 2015. ISSN 0966-6362. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0966636208003810>>. Citado 2 vezes nas páginas 9 e 10.
- CERQUEIRA, E. O. et al. Utilization of fourier transform filter for noise minimization in analytical signals. v. 23, n. 5, p. 690–698, 2000. ISSN 0100-4042. Disponível em: <http://www.scielo.br/scielo.php?script=sci_abstract&pid=S0100-40422000000500019&lng=en&nrm=iso&tng=pt>. Citado 2 vezes nas páginas 28 e 29.
- HAUSDORFF, J. M.; RIOS, D. A.; EDELBERG, H. K. Gait variability and fall risk in community-living older adults: A 1-year prospective study. v. 82, n. 8, p. 1050–1056, 2001. ISSN 0003-9993. Disponível em: <<http://www.archives-pmr.org/article/S0003999301632155/abstract>>. Citado 5 vezes nas páginas 9, 10, 17, 19 e 20.
- HENDERSON, D. Euler angles, quaternions, and transformation matrices. *NASA JSC Report*, v. 12960, 1977. Citado na página 27.
- JAYALATH, S.; ABHAYASINGHE, N.; MURRAY, I. A gyroscope based accurate pedometer algorithm. In: *International Conference on Indoor Positioning and Indoor Navigation*. [S.l.: s.n.], 2013. v. 28, p. 31st. Citado na página 10.
- LEE, J.-A. et al. Portable activity monitoring system for temporal parameters of gait cycles. v. 34, n. 5, p. 959–966, 2010. ISSN 0148-5598. Citado 3 vezes nas páginas 21, 22 e 26.
- MARSCHOLLEK MEHMET GOEVERCIN, K.-H. W. B. S. M. G. R. H. M.; STEINHAGEN-THIESSEN, E. A performance comparison of accelerometry-based step detection algorithms on a large, non-laboratory sample of healthy and mobility-impaired persons. - PubMed - NCBI. 2008. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/19162910>>. Citado na página 10.
- RAFAJLOVIĆ, S.; GAVRILOVIĆ, M.; MIJAILOVIĆ, N. Gait phases recognition from accelerations and ground reaction forces: Application of neural networks. v. 1, n. 1, p. 34–37, 2009. ISSN 1821-3251. Disponível em: <<https://doaj.org>>. Citado 2 vezes nas páginas 20 e 26.
- SENSORS Overview | Android Developers. 2015. Disponível em: <http://developer.android.com/intl/pt-br/guide/topics/sensors/sensors_overview.html>. Citado 3 vezes nas páginas 13, 14 e 15.
- SHOAIB, M. et al. Fusion of smartphone motion sensors for physical activity recognition. v. 14, n. 6, p. 10146–10176, 2014. Disponível em: <<http://www.mdpi.com/1424-8220/14/6/10146>>. Citado na página 9.

SMITH, A. Smartphone ownership – 2013 update. Pew Research Center, 2013. Disponível em: <http://boletines.prisadigital.com/PIP_Smartphone_adoption_2013.pdf>. Citado na página 9.

SUN, B.; WANG, Y.; BANDA, J. Gait characteristic analysis and identification based on the iPhone's accelerometer and gyrometer. v. 14, n. 9, p. 17037–17054, 2014. Disponível em: <<http://www.mdpi.com/1424-8220/14/9/17037>>. Citado 4 vezes nas páginas 9, 10, 20 e 27.

WILLEMSSEN, A. T.; BLOEMHOF, F.; BOOM, H. B. Automatic stance-swing phase detection from accelerometer data for peroneal nerve stimulation. v. 37, n. 12, p. 1201–1208, 1990. ISSN 0018-9294. Citado na página 26.

WONG, W. Y.; WONG, M. S.; LO, K. H. Clinical applications of sensors for human posture and movement analysis: A review. v. 31, n. 1, p. 62–75, 2007. ISSN 0309-3646. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/03093640600983949>>. Citado 3 vezes nas páginas 9, 20 e 26.

WU, W. et al. Classification accuracies of physical activities using smartphone motion sensors. v. 14, n. 5, p. e130, 2012. Disponível em: <<http://www.jmir.org/2012/5/e130/>>. Citado na página 9.