



Virtual Caregiver: a System for Supporting Collaboration in Elderly Monitoring

Virtual Caregiver: um Sistema para Apoiar a Colaboração no Acompanhamento de Idosos

Wallace Ugulino
Depto de Informática
PUC-Rio
Rio de Janeiro, Brazil
wugulino@inf.puc-rio.br

Márcio Ferreira
Depto de Informática
CEFET-RJ
Rio de Janeiro, Brazil
marcio@cefet-rj.br

Eduardo Velloso
School of Computing
and Communications
Lancaster University, UK
e.veloso@lancaster.ac.uk

Hugo Fuks
Depto de Informática
PUC-Rio
Rio de Janeiro, Brazil
hugo@inf.puc-rio.br

Abstract — This paper presents the Virtual Caregiver system, a collaborative ubiquitous computing application. The application scenario is the monitoring of an 86 years old patient diagnosed with Alzheimer's disease and cardiac arrhythmia. The system consolidates data obtained from sensors in a wearable device to enable collaborative monitoring of elderly patients by relatives and health professionals using smartphones and social networks. From the classifier developed for this study, it was found 99.4% overall accuracy in a 10-fold cross validation test. We also obtained feedback from patients and relatives that have been useful to guide the development of a new version of the wearable, unobtrusive and adapted to the patient needs.

Wearable Computing, Human Activity Recognition, e-Health

I. INTRODUÇÃO

Com o aumento da expectativa de vida e o envelhecimento da população, tem se tornado um desafio o desenvolvimento de tecnologias que possibilitem uma vida mais independente e segura para idosos e doentes crônicos [1][2][3]. Em pesquisas recentes busca-se investigar tecnologias para apoiar o acompanhamento de idosos e doentes crônicos em suas casas, de modo a evitar o impacto social, os riscos e os custos de uma internação [3]. Sistemas de e-health são alternativas tecnológicas frequentemente propostas nessas pesquisas pois possibilitam a colaboração dos parentes e profissionais no acompanhamento de idosos e doentes crônicos fora do ambiente hospitalar.

Sistemas e-health possibilitam o registro de dados para posterior avaliação médica, como a rotina de atividades e a frequência de batimentos cardíacos. Esse registro é um dado valioso para o médico que faz um tratamento continuado do paciente. Sistemas de e-health também são potencialmente úteis para possibilitar a identificação de situações na rotina que desencadeiam crises ou riscos para o paciente monitorado.

Wearable computers são usados em alguns sistemas de e-health para o monitoramento dos sinais vitais, temperatura corporal, frequência cardíaca, nível glicêmico, atividades físicas, entre outras medidas importantes para o acompanhamento de um paciente [4][5]. Os dados obtidos a partir de wearables possibilitam também a emissão de alertas em casos de emergência, como quedas ou a mudança da frequência cardíaca para valores de atenção estipulados pelo

médico [6]. Uma abordagem alternativa ao uso de wearables é sensoriar o ambiente. Na Seção 2 são discutidos os pontos fortes e fracos das duas abordagens de sensoriamento possuem, bem como são listadas pesquisas realizadas com cada abordagem.

Um desafio para o desenvolvimento de wearables de suporte a e-health é a interpretação dos dados primários obtidos dos sensores. Essa interpretação pode ser feita por meio de regras definidas numa especificação formal ou por meio de técnicas de aprendizado de máquina e mineração de dados. O objetivo é desenvolver classificadores para alimentar sistemas de e-health com informações tratadas, obtidas a partir de dados primários dos sensores. Uma revisão da literatura sobre classificadores para atividades humanas a partir de dados de acelerômetros é apresentada na Seção 3. Com as orientações obtidas na revisão de literatura foi construído um wearable e desenvolvido um classificador para os dados obtidos dos sensores no Wearable. O wearable e o classificador também são apresentados na Seção 3.

O contexto para o desenvolvimento dessa pesquisa é o projeto de pesquisa Ubilife (FAPERJ), no qual são investigadas tecnologias para auxiliar parentes, amigos ou profissionais da área médica responsáveis pela assistência a idosos fora do ambiente hospitalar. O sistema Virtual Caregiver foi desenvolvido para apoiar o acompanhamento de uma paciente de 86 anos, diagnosticada com Alzheimer e arritmia cardíaca. O sistema tem 3 módulos: aplicativo web para a rede social Facebook, aplicativo para smartphone com sistema operacional Android e wearable, usado para coleta de dados do paciente. O sistema é contextualizado no projeto de pesquisa e apresentado na Seção 4. Conclusão e trabalhos futuros dessa pesquisa são discutidos na Seção 5.

II. SENSORIAMENTO NO AMBIENTE E NO CORPO

O reconhecimento de atividades tem sido usado em diversas aplicações como esportiva, entretenimento e saúde. A coleta dos dados necessários para o reconhecimento é feita por meio de duas abordagens principais: o sensoriamento do ambiente e o sensoriamento do corpo humano. Cada abordagem tem pontos fortes e fracos e a decisão sobre o uso de uma das abordagens está relacionada com a aplicação pretendida do reconhecimento de atividades. Para esportes e atividades realizadas em ambiente controlado as duas abordagens são viáveis. Para ambientes não controlados, como o tráfego de pedestres em via pública, a abordagem de

sensoriamento do corpo apresenta consideráveis vantagens em relação ao sensoriamento do ambiente.

A. Sensoriamento do ambiente

Quando se usa o monitoramento do ambiente é preciso equipar o local com uma infra-estrutura que possibilite a coleta de dados. O monitoramento dos indivíduos é geralmente realizado por meio de técnicas de visão computacional, embora também seja realizado por meio de outras abordagens, como triangulação e trilateração em sistemas emissores / receptores.

Para o monitoramento de atletas em atividades esportivas, uma abordagem comum aplicada por treinadores é filmar os movimentos do atleta com uma câmera 2D e usar um sistema de digitalização do vídeo para realizar a anotação offline quadro a quadro das atividades. Essa abordagem de registro e anotação de vídeos possibilita a geração de datasets para métodos de aprendizagem supervisionada por meio de processamento de imagens.

Uma alternativa é equipar o ambiente com sistemas de rastreamento de indivíduos baseados em marcadores, com os quais são obtidos dados sobre diferentes partes do esqueleto (por exemplo, posição das articulações em 3 eixos – x, y e z). O sensor Microsoft Kinect tem sido usado recentemente para rastreamento tridimensional de 26 articulações do corpo humano [7]. No trabalho de Beetz, Kirchlechner e Lames [8] um sistema baseado em threshold é usado para analisar partidas de futebol com rastreamento dos jogadores por meio de um receptor que triangula informações de emissores de micro ondas posicionados nas caneleiras e na bola. Sobre o uso conjugado de câmeras e marcadores, há o trabalho de Hey e Carter [9] no qual uma mesa de tênis é usada para registrar os pontos de impacto e a bola é rastreada por meio de câmera de vídeo e sensores de vibração.

A principal vantagem de usar sensores no ambiente é não fixar qualquer equipamento no corpo do indivíduo. Em alguns casos pode ser necessário marcar o indivíduo visualmente, mas esses marcadores visuais são quase imperceptíveis (geralmente uma cor diferente na roupa) como no caso de [8]. Uma desvantagem no sensoriamento do ambiente é a necessidade de uma área coberta pelo sistema de rastreamento, o que torna essa abordagem difícil de ser aplicada em ambientes externos como avenidas, sendo mais indicada para ambientes internos e controlados, como sala de hospital, quadra de tênis e campo de futebol.

B. Sensoriamento do corpo

Na abordagem de sensoriamento do corpo, as unidades de medição de força inercial (IMU – Inertial Measurement Units) são os sensores mais usados. As IMUs são geralmente equipadas com 6 ou 9 graus de liberdade, o que significa 6 ou 9 medidas (acelerômetro, giroscópio e magnetômetro triaxiais) coletadas simultaneamente, mas é também muito comum o uso de acelerômetros triaxiais isoladamente.

Atualmente é possível encontrar à venda pulseiras e relógios com funcionalidades para sensoriamento, mas os sensores são geralmente restritos a monitores de frequência cardíaca e pedômetros. Uma abordagem recente na indústria são pulseiras que inferem o nível de atividade do indivíduo

por meio das leituras de um acelerômetro. Os dados obtidos dos sensores são geralmente classificados como “em atividade” ou “em repouso” e as inferências são feitas por regras préestabelecidas (threshold-based decision). O objetivo, em geral, é motivar o indivíduo à prática de atividades físicas. Um produto disponível na indústria é o Nike +iPod no qual são combinados dados de sensores com as músicas tocadas no iPod do indivíduo. Como resultado de pesquisas, o MPTrain é um sistema que compila uma lista de músicas por meio do mapeamento de características das músicas, nível de atividade e resposta fisiológica do atleta [10]. Outro exemplo é o MOPET, um sistema que usa GPS (Global Positioning System), acelerômetros e medidores de frequência cardíaca para prover motivação e avisos para o indivíduo por meio de um agente 3D em um dispositivo móvel [11].

Na área de saúde, o reconhecimento de atividades com wearables tem sido aplicado para acompanhar o consumo de energia na realização de atividades físicas, como é o exemplo do wearable “SensVest” de Knight et al. [12]. Outro trabalho na área de saúde é o de Jovanov et al., [13], no qual uma rede ZigBee de sensores sem fio é implementada para possibilitar análise em tempo real dos dados dos sensores e prover feedback para o usuário. O sistema dispara alertas conforme o nível de atividade, estado geral do usuário e condições ambientais. Todas as informações geradas pelo sistema são armazenadas em servidores junto com o registro do paciente.

Na área de atividades esportivas, um exemplo é o dispositivo wearable para esqui, desenvolvido por Michahelles and B. Schiele [14], no qual são usados resistores de força, um acelerômetro e um giroscópio para medir respectivamente a pressão nos pés, movimento e rotação do esquiador. Por fim, no domínio de levantamento de peso, Chang et al. [15] propõem o uso de sensores na luva e na cintura do indivíduo para identificar e contar os exercícios realizados.

A principal vantagem da abordagem wearable é não pressupor a existência de infraestrutura no ambiente, o que possibilita ao indivíduo realizar suas atividades em qualquer ambiente. Com relação aos dispositivos computacionais tradicionais (computadores, tablets e smartphones), a vantagem do wearable é não exigir a atenção do usuário, uma vez que o uso do computador não é necessariamente a atividade primária de um indivíduo. As principais desvantagens são a necessidade de vestir equipamentos, o que exige um bom projeto do wearable, a possibilidade de descalibragem dos sensores, o que demanda a atuação do usuário para reconhecer a descalibragem e disparar uma recalibragem, e consumo de bateria – que ainda é objeto de estudos de otimização.

III. CLASSIFICADORES PARA DADOS DE ACELERÔMETROS

Nessa seção são apresentados resultados parciais de uma revisão sistemática da literatura sobre o reconhecimento de atividades, que foram usados para apoiar a construção do dispositivo wearable e o desenvolvimento do classificador, também apresentados nessa seção. Outros dados dessa revisão são apresentados em [16].

Nessa revisão, foram coletados os seguintes metadados para possibilitar análises quantitativa e qualitativa dos trabalhos: título da pesquisa, ano, quantidade de acelerômetros, uso de outros sensores, posição dos acelerômetros, lista de atividades para classificação, técnica de aprendizado de máquina usada (ou classificação baseada em threshold), número de indivíduos (sujeitos) e tamanho do dataset, modo de teste (conjunto de treino vs. conjunto de teste ou validação cruzada nos modos k-fold, leave-one-example-out ou leave-one-subject-out), e percentual de acerto na classificação. Em relação ao ano de publicação, conforme ilustrado na Figura 1, foi observado um crescente número de publicações de HAR (Human Activity Recognition) com acelerômetros, o que dá indícios da relevância da abordagem de wearables para a área de HAR.




Figura 1. Número de publicações na área de reconhecimento de atividades com acelerômetros (base IEEE)

Na maior parte dos trabalhos revisados observou-se o uso de até 4 acelerômetros para a coleta de dados. Os autores recomendam o posicionamento dos sensores na cintura ou peito se for construído um dispositivo vestível com apenas 1 sensor [17]. Para abordagens com mais de 1 sensor as posições recomendadas são cintura ou peito, coxa e tornozelo [18][19][20][21][22]. Num survey da literatura específico sobre o reconhecimento de atividades com acelerômetros [23], Yang e Csu apontam essas mesmas áreas do corpo como as mais importantes para o reconhecimento de posturas como “sentado” e em “pé”, movimentos como “andar” e “subir escadas” e transições como “levantar” e “sentar”. Esses resultados da literatura foram considerados na construção do wearable para essa pesquisa.

Sobre os classificadores desenvolvidos, o modo de teste mais usado é a validação cruzada (k-fold); entretanto, testes menos confiáveis e testes não padronizados também são usados. Outro importante dado identificado na revisão da literatura é que boa parte dos trabalhos apresentam taxa de acerto maior ou igual a 90% na classificação das atividades. A pesquisa com maior percentual de acerto é a de Jun-Ki e Sung-Bae [24], com 99.4% de desempenho geral. Entretanto, é impossível comparar o desempenho desses classificadores em função da ausência de datasets públicos. Também é impossível replicar os wearables da maior parte das pesquisas encontradas nessa revisão por causa da ausência de informação sobre o posicionamento, modelo e orientação dos sensores.

O crescente número de publicações dá indícios da relevância da área de pesquisa, enquanto a impossibilidade de replicar os classificadores e dispositivos e a aplicação de testes pouco confiáveis indicam a necessidade de amadurecimento dessa área de pesquisa. Como resposta à essa demanda de amadurecimento, nesta pesquisa são disponibilizados os datasets e todas as informações necessárias para a replicação do dispositivo wearable construído para a coleta de dados, conforme disponível no website do projeto de pesquisa.

A. Construção do dispositivo wearable

No dispositivo wearable foram usados 4 acelerômetros triaxiais, modelo ADXL335, conectados a um microcontrolador ATmega328V. Todos os módulos são da família “LilyPad Arduino”, apropriados para costura em tecido. Na Figura 2 são ilustrados o Wearable, o posicionamento e a orientação dos sensores.



Figura 2. Wearable construído para a coleta de dados

Os acelerômetros foram posicionados, respectivamente, na cintura (1), coxa esquerda (2), tornozelo direito (3), e braço direito (4) e calibrados antes da coleta de dados. Foi usado um modo simples de calibragem que consiste em manter os acelerômetros imóveis em uma superfície plana, efetuar leituras durante um tempo e considerar o valor médio como ponto zero. O valor médio de cada eixo é descontado das leituras durante a coleta de dados.

B. Coleta de dados

Foram coletados dados durante 8 horas de atividades, sendo aproximadamente 2 horas com cada um dos 4 participantes: 2 homens e 2 mulheres, todos adultos, saudáveis e sem restrições de movimentos. O protocolo estipulado para cada participante foi executar cada atividade separadamente (ambiente laboratorial). O participante mais velho realizou as atividades por menos tempo em função de um desconforto muscular relatado. O perfil de cada participante é listado na Tabela 1.

TABELA I. PERFIL DOS PARTICIPANTES

Participante	Sexo	Idade	Altura	Peso	Instâncias
A	Feminino	46 anos	1.62m	67kg	51,577
B	Feminino	28 anos	1.58m	53kg	49,797
C	Masculino	31 anos	1.71m	83kg	51,098
D	Masculino	75 anos	1.67m	67kg	13,161

No total foram coletadas 165.633 instâncias. A distribuição das instâncias entre as atividades é ilustrada na Figura 3.




Figura 3. Frequencia das instâncias

Após a coleta dos dados, os arquivos foram concatenados e pré-processados para diferentes formatos, conforme a orientação de [24]. O objetivo é possibilitar a investigação de vários modelos, como SVM, redes neurais, árvores de decisão. Para alguns modelos foi preciso normalizar os dados e converter features nominais para numéricas.

C. Extração de features

Os dados foram lidos a uma frequência de 10Hz (aprox. 10 leituras por segundo). Para cada um dos 4 acelerômetros as medidas de aceleração nos eixos x, y e z foram as features primárias estabelecidas. A partir desses valores, foram calculadas features derivadas, como a rotação sobre os eixos (roll e pitch) e o módulo do vetor de aceleração.

Sobre a lista de features primárias e derivadas foi gerada uma janela de tempo de 1s a partir da qual várias features foram calculadas, todas resultantes de medidas de estatística descritiva sobre os dados da janela de tempo. Cada janela é sobreposta com um deslocamento de 150ms em relação à anterior. As features geradas são listadas a seguir:

- Para cada acelerômetro: as leituras da aceleração nos eixos x, y, e z; a rotação sobre os ângulos x e y e o módulo do vetor de aceleração;
- Variância de roll, pitch e do módulo do vetor para todas as instâncias da janela de tempo de 1s;
- Uma coluna com a discretização do módulo do vetor de aceleração de cada sensor. As faixas para a discretização foram definidas após análise estatística comparando os dados das 5 classes;

D. Seleção de features

Para diminuir o uso de features redundantes e selecionar as features mais informativas em relação às classes, foi usado o algoritmo de seleção de Mark Hall [26], baseado em correlação. O algoritmo foi configurado para adotar o método BestFirst, que tem uma estratégia gulosa baseada em backtracking. O resultado da seleção é o menor conjunto de features que traz o maior ganho de informação.

As 12 features selecionadas por meio desse procedimento foram: (1) sensor da cintura: discretização do módulo do vetor de aceleração, variância do pitch e variância do roll; (2) Sensor posicionado na coxa direita: módulo do vetor de

aceleração, discretização e a variância do pitch; (3) Sensor no tornozelo direito: variância do pitch e variância do roll; (4) Sensor no braço direito: discretização do módulo de aceleração. De todos os sensores: a média aritmética do módulo do vetor entre as leituras da janela de tempo.

E. Classificador para atividades humanas

Com o dataset gerado foram realizados diversos testes de validação cruzada (67 no total) envolvendo os algoritmos de aprendizagem supervisionada: Support Vector Machine (SVM), Voted Perceptron (estratégia one-against-all), MultiLayer Perceptron (Back Propagation) e Árvore de Decisão C4.5. O melhor resultado obtido foi de 98.1% de acerto com a árvore de decisão C4.5, de Ross Quilan [27], configurada com fator de confiança de 0.15 e mínimo de 100 instâncias por folha. A árvore C4.5 é uma evolução proposta por Quilan ao algoritmo ID3 (Iterative Dichotomiser 3) e sua principal vantagem sobre o ID3 é a poda mais eficiente.

Para obter maior percentual de acerto foi criado um comitê AdaBoost [28] com 10 árvores C4.5. Segundo o autor, o método AdaBoost “*gera distribuições concentradas nos exemplos mais difíceis para possibilitar a um algoritmo fraco obter melhor desempenho nas partes mais difíceis do espaço amostral*” (tradução nossa). De maneira simplificada, com o uso de AdaBoost, o algoritmo C4.5 foi executado com diferentes distribuições a cada iteração, privilegiando as instâncias mais difíceis de prever.

O desempenho geral obtido com o comitê AdaBoost foi de 99.4% de acerto (media ponderada) no modo de teste de validação cruzada (10-fold). A precisão obtida por classe foi: “sitting” 100%, “sitting down” 96.9%, “standing” 99.8%, “standing up” 96.9%, e “walking” 99.8%.

IV. VIRTUAL CAREGIVER: COLABORAÇÃO PARA ASSISTÊNCIA FORA DO HOSPITAL

O sistema Virtual Caregiver foi proposto no contexto do projeto de pesquisa Ubilife. No Ubilife são investigadas tecnologias para auxiliar parentes, amigos ou profissionais da área médica responsáveis pela assistência a idosos fora do ambiente hospitalar. Um dos sistemas no contexto do Ubilife é um AAL (Ambient Assisted Living) colaborativo que usa o mundo virtual OpenSIM como plataforma para apoiar para o monitoramento constante de um idoso, além de dispor de serviços de lembretes e alarmes [29]. Nesse AAL, coletam-se dados por meio do sensoriamento do ambiente para correlacionar os objetos e o indivíduo, e obter dados como a localização do usuário e os objetos com os quais interage.

O Virtual Caregiver foi implementado para possibilitar o uso de dispositivos móveis, como smartphones e tablets, e também a rede social Facebook, dada a sua popularidade recente. O trabalho de [30] é o principal trabalho relacionado. O cenário de aplicação é com a família de uma paciente de 86 anos, diagnosticada com Alzheimer e arritmia cardíaca. Um dos parentes comentou seu interesse na tecnologia de monitoramento: “(...) me interessei pois a minha avó é uma senhora idosa de 86 anos com Alzheimer e cardíaca [sic] e uma vez ela se perdeu em Botafogo, sem ter como se comunicar, sem lembrar onde estava e quem eram seus parentes.”

Os agentes originalmente implementados na arquitetura multiagentes xAgente [29] não contemplam o monitoramento em ambientes externos e a interface foi desenvolvida apenas para o espelhamento do ambiente em mundos virtuais. A plataforma, contudo, possibilita extensões, que foram desenvolvidas para viabilizar o compartilhamento dos dados do sistema em redes sociais e smartphones. A tela do aplicativo para Facebook é ilustrada na Figura 4.

Na Figura 4, o aplicativo para Facebook contém um histórico dos batimentos cardíacos recentes da paciente. O histórico é associado à atividade ou postura do paciente. Dados da localização (GPS) também são apresentados graficamente. A interface do Facebook foi imitada para possibilitar a inclusão de comentários, fotos e arquivos relacionados à rotina do paciente.



Figura 4. Aplicativo para Facebook

A interface para Android, ilustrada na Figura 5, contém os mesmos elementos da interface para Facebook e possui também atalhos para fazer ligações de emergência e enviar SMS para um dos colaboradores.



Figura 5. Aplicativo para Android

Para coletar os dados de batimentos cardíacos foi usado um sensor de batimentos conhecido como Polar. O Wearable com as IMUs (Inertial Measurement Unit) foi adaptado para as medidas físicas da paciente, para coletar os dados de batimentos cardíacos e para enviar os dados por Bluetooth para um smartphone. A paciente usa o wearable por baixo da blusa e os parentes já solicitaram uma adaptação do protótipo wearable para viabilizar o uso prolongado. O wearable construído é ilustrado na Figura 6.



Figura 6. Wearable usado para monitoramento

No projeto Virtual Caregiver, a colaboração é entendida pelo Modelo 3C de colaboração [31]: as notificações de atividades e batimentos cardíacos da paciente e o grupo no Facebook compreendem o espaço compartilhado no qual parentes e médicos cooperam. Com a observação de médicos e parentes espera-se que padrões de comportamento e sintomas sejam percebidos e o médico possa atuar de forma preventiva. A vantagem de usar a colaboração, em detrimento do uso de uma análise estatística em um grande banco de dados, é a possibilidade de observar padrões com dados de apenas uma paciente.

V. CONCLUSÃO E TRABALHOS FUTUROS

Nesse artigo foram discutidas abordagens para o reconhecimento de atividades humanas e foi feita uma revisão dos principais trabalhos na área. Foi realizada uma revisão da literatura sobre classificadores de dados de acelerômetros para o

reconhecimento de atividades e foram desenvolvidos um classificador para reconhecimento de atividades, um wearable usado na coleta de dados, e o sistema Virtual Caregiver.

O bom resultado obtido no desenvolvimento do classificador motivou a continuidade da pesquisa e o desenvolvimento da nova versão do wearable, que foi adaptado às necessidades da paciente. A nova versão do wearable é mais discreta e possibilita também coletar a frequência de batimentos cardíacos, não previsto na primeira versão. Como trabalhos futuros, será feita a liberação dos aplicativos do Facebook e Android para uso pelos parentes. Espera-se avaliar a usabilidade dos mecanismos de interface e se a colaboração dos parentes e médicos é útil para o acompanhamento da paciente.

ACKNOWLEDGMENTS

Wallace Ugulino recebe bolsa do CNPq (142916/2010-2). Hugo Fuks recebe bolsa do CNPq (302230/2008-4) e UBILIFE FAPERJ/ADT1-190.116/2010. Este trabalho foi parcialmente financiado pela FAPERJ/INC&T (E-26/170028/2008).

REFERENCES

- [1] Charmaz, K. (1983). Loss of self: a fundamental form of suffering in the chronically ill. *Sociology of Health & Illness*, 5: 168–195. doi: 10.1111/1467-9566.ep10491512
- [2] Katz, S.; Branch, L. G.; Branson, M. H.; Papsidero, J. A.; Beck, J. C.; Greer, D. S., Active Life Expectancy. *New England Journal of Medicine*, 1983. 309 (20): p. 1218-1224. DOI: 10.1056/NEJM198311173092005.
- [3] Yu-Jin, H.; Ig-Jae, K.; Sang Chul, A.; Hyoung-Gon, K. Activity Recognition Using Wearable Sensors for Elder Care. In: *Proceedings of Second International Conference on Future Generation Communication and Networking*, 2008. FGCN '08. v2. p. 302-305. DOI: 10.1109/FGCN.2008.165.
- [4] Ken, C.; Xiaoying, L. Development of Remote Monitoring Cardiac Patients System Based on GPRS. *International Conference on Biomedical Engineering and Computer Science (ICBECS)*, 2010, pp.1-4, 23-25 April 2010. DOI: 10.1109/ICBECS.2010.5462410.
- [5] Sieber, A.; Yong, X.; L'Abbate, A.; Bedini, R. Cardiac Sentinel: A smart GSM based embedded solution for continuous remote monitoring of cardiac patients. *International Workshop on Intelligent Solutions in Embedded Systems*, 2008, pp.1-11, 10-11 July 2008 doi: 10.1109/WISES.2008.4623296.
- [6] Chen, J.; Kwong, K.; Chang, D.; Luk, J.; Bajcsy, R. Wearable Sensors for Reliable Fall Detection. *27th Annual International Conference of the Engineering in Medicine and Biology Society*, 2005. *IEEE-EMBS 2005*. vol., no., pp.3551-3554, 17-18 Jan. 2006 doi: 10.1109/IEMBS.2005.1617246.
- [7] T. Dutta. Evaluation of the Kinect sensor for 3-d kinematic measurement in the workplace. *Applied Ergonomics*, 2011.
- [8] M. Beetz, B. Kirchlechner, and M. Lames. Computerized real-time analysis of football games. *IEEE Pervasive Computing*, 4(3):33–39, 2005.
- [9] J. Hey and S. Carter. Pervasive computing in sports training. *IEEE Pervasive Computing*, 4(3):54, 2005.
- [10] N. Oliver and F. Flores-Mangas. Mptrain: a mobile, music and physiology-based personal trainer. In *Proceedings of the 8th Conference on Human-computer interaction with mobile devices and services*, pages 21–28. ACM, 2006.
- [11] F. Buttussi and L. Chittaro. Mopet: A context-aware and user-adaptive wearable system for fitness training. *Artificial Intelligence in Medicine*, 42(2):153–163, 2008.
- [12] J. F. Knight, A. Schwirtz, F. Psomadellis, C. Baber, H. W. Bristow, and T. N. Arvanitis. The design of the sensvest. *Personal and Ubiquitous Computing*, 9(1):6–19, 2004.
- [13] Jovanov, E.; Milenkovic, A.; Otoo, C.; Groen, P.C. A wireless body area network of intelligent motion sensors for computer assisted physical rehabilitation. In *Journal of NeuroEngineering and Rehabilitation*. vol.2(6). DOI: 10.1186/1743-0003-2-6.
- [14] F. Michahelles and B. Schiele. Sensing and monitoring professional skiers. *IEEE Pervasive Computing*, 4(3):40–46, 2005.
- [15] K.-h. Chang, M. Y. Chen, and J. Canny. *Tracking free-weight exercises*. In *Proc. of UbiComp 2007*, volume 4717, pages 19–37. Springer, 2007.
- [16] Ugulino, W.; Cardador, D.; Vega, K.; Velloso, E.; Milidui, R.; Fuks, H. Wearable Computing: Accelerometers' Data Classification of Body Postures and Movements. *Advances in Artificial Intelligence - SBIA 2012*. In: *Lecture Notes in Computer Science*. Editors: L. N. de Barros, M. Finger, Aurora T.R. Pozo. 2012, Springer. [in press].
- [17] Feng, W.; Meiling, W.; Nan, F. *Research on Classification of Human Daily Activities Based on a Single Tri-Axial Accelerometer*. In *1st International Workshop on Complexity and Data Mining (IWCDM)*. 2011.
- [18] Kai Kunze and Paul Lukowicz. 2008. *Dealing with sensor displacement in motion-based onbody activity recognition systems*. In *Proceedings of the 10th international conference on Ubiquitous computing (UbiComp '08)*. ACM, New York, NY, USA, 20-29. DOI=10.1145/1409635.1409639 <http://doi.acm.org/10.1145/1409635.1409639>
- [19] Gjoreski, H.; Lustrek, M. Gams, M. *Accelerometer Placement for Posture Recognition and Fall Detection*. In *7th International Conference on Intelligent Environments (IE)*. 2011.
- [20] Lei, G.; Bourke, A.K.; Nelson, J. *A system for activity recognition using multi-sensor fusion*. In *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, EMBC. 2011.
- [21] Yuting, Z.; Markovic, S.; Sapir, I.; Wagenaar, R.C.; Little, T.D.C. *Continuous functional activity monitoring based on wearable tri-axial accelerometer and gyroscope*. In *5th International Conference on Pervasive Computing Technologies for Healthcare (PervasiveHealth)*. 2011.
- [22] Atallah, L.; et al. *Sensor Positioning for Activity Recognition Using Wearable Accelerometers*. *Biomedical Circuits and Systems*, *IEEE Transactions on*, 2011. 5(4): p. 320-329.
- [23] Yang C.-C., Hsu Y.-L. A Review of Accelerometry-Based Wearable Motion Detectors for Physical Activity Monitoring. *Sensors*. 2010; 10(8):7772-7788.
- [24] Jun-Ki, M.; C. Sung-Bae. *Activity recognition based on wearable sensors using selection/fusion hybrid ensemble*. In *IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. 2011.
- [25] Maziewski, P.; Kupryjanow, A.; Kaszuba, K.; Czyzewski, A. *Accelerometer signal pre-processing influence on human activity recognition*. In: *Conference Proceedings of Signal Processing Algorithms, Architectures, Arrangements, and Applications (SPA)*, 2009. p. 95-99. ISSN: 978-83-62065-06-6.
- [26] Hall, M. A. *Correlation-based Feature Subset Selection for Machine Learning*. PhD thesis, Department of Computer Science, University of Waikato, Hamilton, New Zealand, Apr. 1999
- [27] Salzberg, S.L., C4.5: *Programs for Machine Learning by J. Ross Quinlan*. Morgan Kaufmann Publishers, Inc., 1993. *Machine Learning*, 1994. 16(3): p. 235-240. ISSN: 0885-6125. DOI: 10.1007/bf00993309.
- [28] Freund, Y.; Schapire, R. E. *Experiments with a New Boosting Algorithm*. In *International Conference on Machine Learning*, pages 148–156, 1996.
- [29] Vega, K.; Cardador, D.; Fuks, H.; Lucena, C.J.P. xAgent: Arquitetura para Colaboracao em Ambientes Cross-Reality. *Anais do VIII Simpósio Brasileiro de Sistemas Colaborativos (SBSC 2011)*, pp. 62-67. Paraty, RJ: ACM, 2011. ISBN 978-85-7669-254-6.
- [30] Lara, O.D.; Pérez, A.J.; Labrador, M.A.; Posada, J. D. Centinela: A human activity recognition system based on acceleration and vital sign data, *Pervasive and Mobile Computing*, Available online 5 July 2011, ISSN 1574-1192, 10.1016/j.pmcj.2011.06.004.
- [31] Fuks, H., Raposo, A., Gerosa, M.A., Pimentel, M. & Lucena, C.J.P. The 3C Collaboration Model. *The Encyclopedia of E-Collaboration*, Ned Kock (org), ISBN 978-1-59904-000-4, pp. 637-644, 2007.