

INCA: Um sistema *healthcare* flexível baseado no paradigma *fog computing* e *publish/subscribe*

José R. Torres Neto, Geraldo P. R. Filho, Leandro Y. Mano, Jó Ueyama

¹Instituto de Ciências Matemáticas e de Computação – ICMC
Universidade de São Paulo - USP
CEP: 13566-590 – São Carlos – SP – Brazil

jrtorresneto@usp.br, geraldop@icmc.usp.br
leandroyukiomano@usp.br e joueyama@icmc.usp.br

Abstract. *The growth of the population in need of health care and reduced mobility in many countries highlights the need to develop assistive technologies appropriate to this public. To this end, interactive applications on mobile devices are usually integrated into intelligent environments. This article proposes the INCA (IN-home healthCAre), a flexible system that combines the fog computing and publish/subscribe paradigm to individually monitor and manage individuals with reduced mobility. INCA allows you to connect new devices and applications in a scalable way to your infrastructure in real time, as well as a better use of the resources of the devices through the fog. Two interactive applications of individualized monitoring were evaluated: i) recognition of people by the image and; ii) detection of fall by means of the sensors (accelerometer and gyroscope) of a smartwatch. In addition, an evaluation of the performance of the infrastructure based on data offloading was carried out and showed promising results, being notable: i) high accuracy to identify the individuals as well as to detect their mobility; and ii) efficiency when deployed in devices with scarce resources.*

Resumo. *O crescimento da população com necessidade de cuidados de saúde e com mobilidade reduzida em muitos países destaca a necessidade de desenvolver tecnologias assistivas adequadas a esse público. Para esta finalidade, aplicações interativas em dispositivos móveis geralmente são integradas em ambientes inteligentes. Este artigo propõe o INCA (IN-home healthCAre), um sistema flexível que combina o paradigma fog computing e publish/subscribe para monitorar e gerenciar de maneira individualizada indivíduos com mobilidade reduzida. O INCA permite conectar novos dispositivos e aplicações de forma escalável a sua infraestrutura em tempo real, bem como um melhor aproveitamento dos recursos dos dispositivos por meio do fog. Foram avaliadas duas aplicações interativas de monitoramento individualizado: i) reconhecimento de pessoas pela imagem e; ii) detecção de queda por meio dos sensores (acelerômetro e giroscópio) de um smartwatch. Além disso, uma avaliação de desempenho da infraestrutura, baseada no descarregamento de dados, foi realizada e mostrou resultados promissores, sendo notáveis: i) alta acurácia para identificar os indivíduos, bem como detectar sua mobilidade; e ii) eficiência ao ser implantada em dispositivos com recursos escassos.*

1. Introdução

Nos últimos anos, o número de pessoas com necessidades de cuidados de saúde, e.g. idosos, deficientes e pacientes com mobilidade reduzida, aumentou consideravelmente tanto em países desenvolvidos quanto em países em desenvolvimento [Gonçalves et al. 2013]. Esse aumento gerou uma tendência nas pesquisas dessas pessoas quando recebem alta dos hospitais e precisam ser cuidadas em casa. O conceito de *Health Smart Homes* (HSH), também conhecida como ambiente doméstico assistivo, vêm surgindo como uma opção promissora para melhorar a qualidade de vida das pessoas em tratamento domiciliar. Tipicamente, o tratamento de pessoas com mobilidade reduzida, dentro do contexto de HSH, utiliza inteligência computacional para monitorá-las enquanto se recuperam em suas residências [Romero et al. 2009]. Vale frisar que a utilização da inteligência computacional nesse contexto de monitoramento é viável e de extrema relevância, principalmente em países em que o número de pessoas com mobilidade reduzida é alta [Romero et al. 2009, Taleb et al. 2010].

O uso da Internet das Coisas (do inglês *Internet of Things* (IoT)) em cuidados de saúde têm proporcionado um conforto para pessoas com alguma deficiência, mobilidade reduzida e/ou idosos. Na IoT, seja qual for o sensor físico (dispositivos de variados tamanhos e capacidades) ou virtual (modelos computacionais capazes de fornecer uma informação lógica), este é considerado uma “coisa” que pode ser conectado com a Internet [Gubbi et al. 2013]. Com isso, a HSH pode ser definido como uma *smart home* munida com dispositivos e/ou “coisas” especializadas para cuidados de saúde remotamente. Tais “coisas”, podem ser sensores ou atuadores que irão agir/atuar quando uma situação crítica for detectada. Neste cenário, as informações precisam ser agregadas de múltiplas fontes e distribuídas para consumidores que não têm conexões diretas com os produtores de informações, e.g., dados de monitoramento de um paciente em tratamento domiciliar compartilhados com um sistema de hospital [Eugster et al. 2003]. Assim, o uso do paradigma *publish/subscribe* para a distribuição de tais informações entre os dispositivos IoT é uma abordagem promissora no contexto de HSH. Assim, a HSH pode auxiliar no diagnóstico de doenças, influenciar na interação social, intervir em alguma tarefa cotidiana ou tomar decisões de persuasão em prol do usuário [Taleb et al. 2010].

Nesse contexto, aplicações interativas em dispositivos móveis são utilizadas no sensoriamento e monitoramento individualizado com a utilização de câmeras e outros sensores de dispositivos móveis. Por exemplo, uma aplicação de detecção de queda por meio dos sensores acelerômetro e giroscópio de um *smartwatch* podem emitir alertas às equipes de profissionais de saúde e/ou familiares sempre que detectar a ocorrência de uma queda. Os sensores acelerômetro e giroscópio fornecem dados de forma precisa de movimento capturados e possuem um caráter não intrusivo. Outra aplicação bem difundida em ambientes inteligentes é o reconhecimento de indivíduos pela face por meio de visão computacional. Visão computacional tem sido usada em muitos sistemas, pois permite a aquisição de enormes quantidades de dados multidimensionais relacionados ao ambiente monitorado. Por exemplo, ele pode ser usado para aprender as atividades da vida diária de idosos no sentido de analisar problemas de saúde ou distúrbios cognitivos [Banerjee et al. 2015].

A IoT funciona por meio de uma computação onipresente e invisível capaz de coletar e disseminar dados para análise e representação das

informações [Stojkoska and Trivodaliev 2017, Gubbi et al. 2013]. Vale frisar, entretanto, que os dispositivos integrados na HSH possuem recursos escassos. Nesse contexto, o paradigma de *fog computing*, também conhecido como computação em névoa, surge como um tripé para auxiliar tais dispositivos. No *fog*, após o sensoriamento e detecção, os dados podem ser pré-processados em dispositivos com maior poder de processamento nas bordas da rede, também conhecidos com nó *fog* (nesta pesquisa, *Raspberry PI*). Assim, o processo de extração de conhecimento começa tão cedo quanto o momento em que os dados são detectados, i.e. nas bordas da rede. Uma das razões mais proeminentes para empregar este paradigma é a economia de energia, redução de volume de dados e latência. Em relação aos sensores, a computação local é menos custosa que a comunicação, uma vez que tais sensores podem consumir uma enorme quantidade de energia caso sua comunicação não seja otimizada [Stojkoska et al. 2012, Stojkoska and Trivodaliev 2017]. Desta forma, abre espaço para investigação de algoritmos leves para o processamento de dados locais. Com esse paradigma é possível diminuir a quantidade de transmissões envolvendo dados brutos, e consequentemente, somente metadados são enviados. A redução de transmissões entre os dispositivos e a IoT é relevante, uma vez que evita problemas de latência e saturação da rede sem fio [Stojkoska et al. 2012, Viani et al. 2013, Stojkoska and Trivodaliev 2017].

Este artigo apresenta o INCA (**IN**-home health**CA**re), um sistema baseado nos paradigmas de *Fog Computing* e *publish/subscribe*, os quais visam o uso da IoT para o monitoramento individualizado de usuários com mobilidade reduzida. Por meio dos sensores de imagem e movimento (acelerômetro e giroscópio) é possível identificar o usuário de maneira individualizada e, em seguida, detectar se este está sentado, deitado ou se ocorreu uma queda. Como o processamento de tais aplicações são computacionalmente custosas, o *fog* utiliza dispositivos mais robustos para processar o conteúdo, antes de repassá-los a nuvem. Já o *publish/subscribe* permite conectar novos dispositivos e aplicações de forma escalável na infraestrutura do INCA em tempo real. Os resultados mostram que a combinação de *fog computing* e descarregamento (*offloading*) de dados é viável e aumenta o desempenho da infraestrutura em ambientes inteligentes.

O restante deste artigo está organizado da seguinte maneira. A Seção 2 apresenta os trabalhos relacionados. A Seção 3 apresenta o INCA, enquanto a Seção 4 apresenta os resultados da solução proposta. Por fim, a Seção 5 apresenta as considerações finais e trabalhos futuros para este estudo.

2. Trabalhos relacionados

Esta seção apresenta os avanços alcançados nos HSHs, destacando os principais desafios desta pesquisa. Salienta-se que os avanços em *in-home healthcare* são devidos à aplicação de ambientes inteligentes aliados com inteligência artificial [Rialle et al. 2002, Filho et al. 2015, Filho et al. 2014]. Por isso, a combinação de equipamentos modernos de detecção, com técnicas avançadas de processamento de dados e redes sem fio, resulta na criação de ambientes digitais que melhoram a vida diária dos moradores.

Em [Romero et al. 2009], é proposto uma arquitetura sem fio WPAN (do Inglês, *Personal Area Network*) para tirar proveito das características oferecidas pelo ambiente inteligente. O intuito é garantir segurança e fornecer serviços aos usuários mediante técnicas de monitoramento. Para tanto, o sistema é baseado em processamento de imagem para

prover soluções que é integrada com outros dispositivos de controle. Tais informações, servem como entrada para a rede de atuador com inteligência distribuída que adapta ao ambiente, tornando as tarefas diárias mais fáceis para os utilizadores. Entretanto, a solução pode ser custosa computacionalmente em dispositivos com recursos escassos, situação presente nesta pesquisa.

Outro grupo de pesquisa [Corchado et al. 2010] realiza pesquisas em HSHs, especificamente em telemonitoramento de usuários. Nesse caso, os autores [Corchado et al. 2010] propõem um sistema de telemonitoramento distribuído para a melhorar a qualidade de vida dos usuários que dependem de assistências, por exemplo, médicas em casas. Para isso, o sistema implementa uma plataforma baseada em arquitetura orientada a serviços. Com isso, a plataforma permite que as redes heterogêneas de sensores sem fio comuniquem-se de maneira distribuída, independentemente das restrições de tempo e localização. Dessa forma, tal abordagem fornece ao sistema uma maior capacidade de recuperação de erros e uma melhor flexibilidade para alterar seu comportamento em tempo de execução. Salienta-se, contudo, que não há uma preocupação em melhorar computacionalmente os recursos da infraestrutura mediante o paradigma de *fog computing*.

Maia et. al [Maia et al. 2015] desenvolveram uma plataforma de *middleware* para IoT baseada na Web para conectar médicos e pacientes utilizando sensores corporais acoplados e atuadores, denominada *EcoHealth* – Ecosistema Web de Dispositivos de *Health Care*. A solução é dividida em módulos de conexão de dispositivos, manipulação de dados, atuação, visualização, gerenciamento, armazenamento e serviços comuns. O foco principal dos autores é no monitoramento de pessoas em observação, uma vez que sugere sensores de respiração acoplados em uma máscara de oxigênio, um sensor de temperatura no braço do paciente e um sensor de eletrocardiograma. Dessa forma o médico pode avaliar o paciente em tempo real remotamente. No entanto, considerando o cenário de uma HSH, o monitoramento por tais sensores é considerado intrusivo e desconsidera a qualidade de vida e independência do usuário em seu cotidiano, além disso, os autores não consideraram o desempenho dos recursos computacionais utilizados no monitoramento.

Esta pesquisa difere dos demais trabalhos, uma vez que propõe uma arquitetura de integração de múltiplas aplicações que funcionam de forma não intrusiva. Vale ressaltar que a infraestrutura do INCA fornece uma comunicação confiável de informações pela arquitetura, baseada no paradigma *publish/subscribe*. Além disso, o INCA também faz uso do paradigma *Fog computing* para aumentar o desempenho de processamento de dados na arquitetura, uma vez que as aplicações de monitoramento em *in-home healthcare* muitas vezes são consideradas aplicações críticas, i.e. podem ocasionar perda de vidas.

3. INCA: In-home healthcare

Esta seção apresenta o INCA, um sistema flexível para monitorar e gerenciar de maneira específica indivíduos com mobilidade reduzida em um espaço inteligente. O INCA coleta, dissemina e detecta informações do ambiente mediante sensores sem fios. Para o desenvolvimento do sistema, o INCA foi baseado em dois paradigmas: i) *publish/subscribe* e; ii) *fog computing*. O paradigma *publish/subscribe* permite a difusão confiável de informações pela arquitetura do sistema proposto, por meio de uma abordagem flexível e assíncrona, entre os produtores (*publish*) e os consumidores (*subscribe*)

de informações [Eugster et al. 2003]. Já o *fog* além de auxiliar no gerenciamento do ambiente em tempo real, permite melhorar computacionalmente os dispositivos com recursos escassos (processador e memória), um vez que tais recursos estão mais próximos do utilizador final. Desta maneira, o processamento é feito localmente em nós mais robustos, antes de repassá-los para a nuvem [Stojkoska and Trivodaliev 2017]. O monitoramento é feito através da coleta de dados dos sensores dos dispositivos do cotidiano do usuário (smartwatch, smartphone ou câmeras). A infraestrutura do INCA é dividida em três módulos, como mostra a Figura 1.

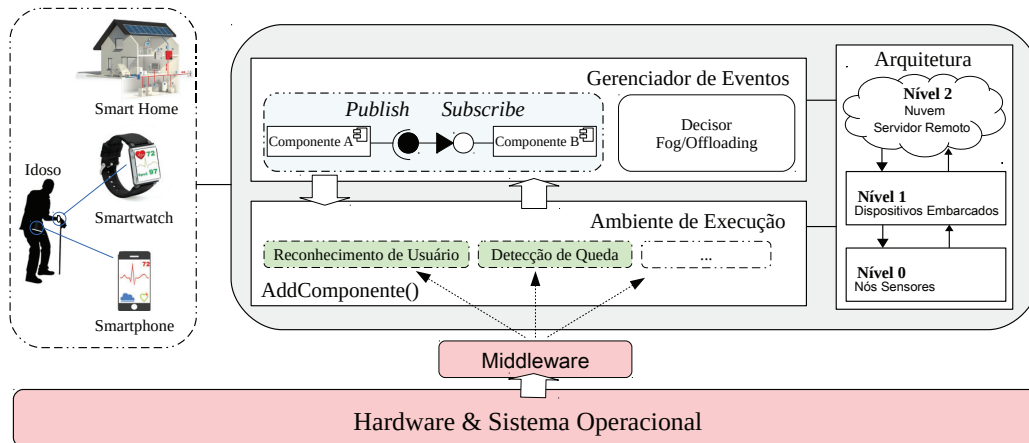


Figura 1. Arquitetura do Sistema INCA: Os dados são coletados pelos dispositivos móveis ou câmeras; O Gerenciador de eventos recebe os dados (*publish*) e decide qual abordagem utilizar (*Fog* ou *Descarregamento*); No Ambiente de execução as aplicações recebem os dados assinados (*subscribe*) e retornam o evento.

No *Gerenciador de Eventos*, os dispositivos publicam seus dados coletados (foto, acelerômetro) usando o protocolo *Message Queue Telemetry Transport* (MQTT) [Stanford-Clark and Nipper 2014]. Esse módulo é responsável pelo gerenciamento e descarregamento dos dados nos níveis da *Arquitetura* do sistema proposto. De acordo com a entrada dos dados publicados, o decisor define o nível para o processamento baseado no conceito de névoa ou descarregamento de dados. Nesse módulo, o *publish/subscribe* garante a conexão entre os dados publicados pelos dispositivos e os componentes do *Ambiente de Execução*.

O *Ambiente de Execução* é composto por componentes, que são as aplicações interativas (Reconhecimento de Usuários, Detecção de Queda) adicionadas ao ambiente de execução em tempo real por meio de um *middleware*. No INCA, *publish/subscribe* auxilia o *middleware* a garantir a interoperabilidade e confiabilidade do sistema, haja vista que os componentes apresentam características fracamente acoplados.

A *Arquitetura* do sistema é bem definida e distribuída em níveis, local onde ocorre o processamento dos dados. O uso de névoa foi essencial para o processamento e gerenciamento das aplicações interativas no INCA, uma vez que explora completamente a arquitetura do sistema. Os níveis são distribuídos da seguinte forma:

- *Nível 0 (Sensores):* dispositivos com nenhum poder de processamento, utilizados para coletar e disseminar os dados para o Nível 1.

- *Nível 1 (Dispositivos Embarcados)*: dispositivos utilizados para realizar o processamento dos dados, deixando os recursos computacionais (processamento, memória, dados) mais próximos do usuário final. Além disso, fornece um mecanismo de descarregamento da carga de processamento dos dados.
- *Nível 2 (Servidor)*: estação com maior poder de processamento e armazenamento.

Basicamente, um determinado sensor publica uma imagem e o componente assinante (aplicação de reconhecimento de usuário) dos dados de imagem são ativados, processando tais dados e retornando uma resposta de saída. O uso de *Publish/Subscribe* preenche uma parte importante dos requisitos para aplicações baseadas em IoT, uma vez que eles são capazes de conceder, de forma assíncrona, múltiplos eventos aos seus respectivos *subscribers* de interesse, a partir de fontes de eventos [Fersi 2015]. A combinação de névoa e descarregamento de dados permite a flexibilidade do sistema frente a uma grande quantidade de dados, de maneira que a arquitetura seja completamente explorada e os sensores de bordas fiquem menos ociosos [Bonomi et al. 2014].

3.1. Monitoramento individualizado

O sistema proposto visa o monitoramento individualizado e não intrusivo, que pode ser feito por inúmeras aplicações interativas monitorando o usuário. Desta forma, o sistema proposto deve ser capaz de permitir a integração dessas aplicações e a adição de novas aplicações em sua infraestrutura. Neste trabalho, foi utilizado duas aplicações interativas na avaliação de desempenho do sistema proposto. As aplicações utilizadas são Reconhecimento de Usuário e Detecção de Queda, que permite o monitoramento individualizado e não intrusivo.

3.1.1. Reconhecimento do Usuário

O INCA utiliza as imagens disseminadas dos sensores para a identificação do indivíduo. Por meio da imagem analisou-se a face, a qual permite determinar de maneira individualizada cada usuário. Assim, o INCA utilizou a abordagem baseada no mapeamento da face para o reconhecimento, sendo dividida em três etapas distintas, sendo elas: i) obtenção da face; ii) extração de características faciais; e iii) identificação baseada na aprendizagem automática.

Para um melhor entendimento, a Figura 2 apresenta o funcionamento de como é realizado o reconhecimento do usuário. Nesse caso, foi feito um processo de mapeamento da face considerando 33 pontos obtidos na extração de características faciais. Os pontos são partes específicas da face que quando juntas identifica de maneira única um indivíduo. Os pontos são distribuídos da seguinte maneira: i) oito para mapear a boca; ii) seis para cada um dos olhos; iii) três para cada sobrancelha; iv) três para o queixo; v) dois para as narinas; e vi) dois para demarcar as extremidades laterais da face perto dos olhos. Além disso, para modelar a forma dos olhos, da boca e das regiões da face relacionadas aos movimentos musculares, 8 áreas são mapeadas. Destaca-se que todas as combinações possíveis de pontos são obtidas por meio dos ângulos e das distâncias entre dois pontos distintos (33×33), em que cada ponto possui uma posição (33 posições), o que gera uma representação com dimensionalidade $D_1 = 33 \times 33 + 8 + 33 = 1130$ atributos.

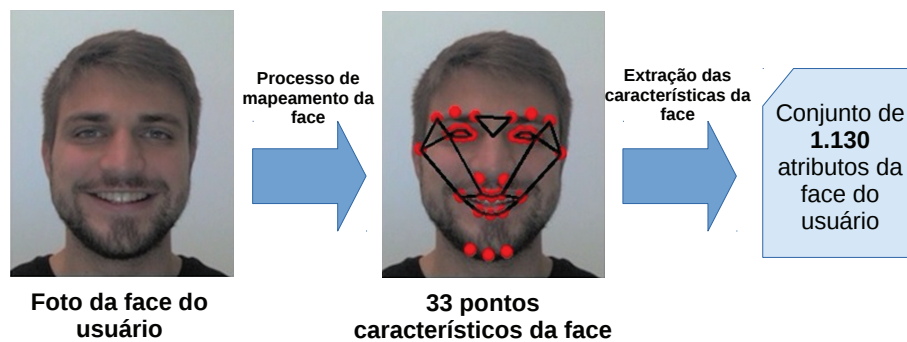


Figura 2. Processo de mapeamento da face para o reconhecimento dos usuários.

Após a obtenção da dimensionalidade da face, procurou-se alinhar os elementos da face de um usuário com os pontos de característica do modelo de referência atual para identificá-lo. Para isso, utilizou-se algoritmos de aprendizagem de máquina que tem como objetivo o aprendizado da identificação do usuário. Para saber qual era o melhor algoritmo a ser implantado no INCA, explorou-se os seguintes algoritmos: (i) Naive Bayes; (ii) Árvore de decisão; (iii) K-nearest neighbors; e (iv) Support vector machine. Tais algoritmos são melhores explicados na Seção 4.

3.1.2. Detecção de Quedas

Aliado ao monitoramento individualizado de usuários, o INCA realiza o monitoramento dos movimentos realizados pelos usuários em ambientes inteligentes, a fim de monitorar sua rotina à distância e detectar alguma atividade fora do normal, e.g. a ocorrência de quedas. Ainda, para que atue de forma não intrusiva, o sistema promove uma ação apenas quando detecta alterações no padrão de movimentos que um usuário normalmente efetua, portanto, a captura de movimentos precisos e de forma constante é indispensável.

Neste sentido, para uma melhor precisão no sentido de fornecer indícios para o monitoramento de atividades, o INCA explora, de forma conjunta, os dados dos sensores: (i) acelerômetro para determinar o deslocamento de um corpo em movimento e o (ii) giroscópio para determinar a rotação e a mudança de direção de um corpo em movimento. Assim, é possível oferecer atendimento/assistência médica o quanto antes e adequado sempre que o sistema detectar um acidente com o usuário monitorado (como ilustrado na Figura 3).

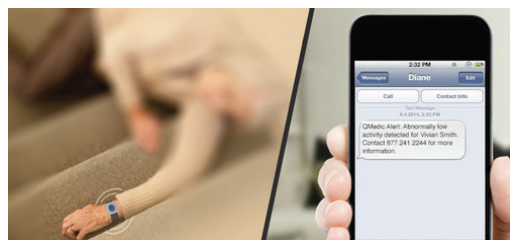


Figura 3. Exemplo de aplicação de sensor para monitoramento [System 2015].

4. Avaliação de desempenho

A metodologia e os resultados da avaliação de desempenho realizada por meio de experimentos serão mostrados nesta seção. Neste trabalho, foram realizados experimentos utilizando um dispositivo embarcado Raspberry PI 2 como dispositivo de borda da rede.

4.1. Cenários de Avaliação 1

Neste trabalho, foram utilizadas imagens de expressões faciais da base de dados Cohn-Kanade (CK+) [Lucey et al. 2010], de acesso livre, para validar a metodologia empregada para identificação de indivíduos. A base de dados CK+ mostra expressões faciais de atores adultos, 69% feminino e 31% masculino. Entre a amostra populacional, 81% são europeus ou americanos, 13% afro-americanos e 6% pertencem a outros grupos étnicos. O banco de dados tem 593 expressões faciais, de 123 atores. No entanto, apenas um subconjunto da base de dados CK+ foi utilizado para os experimentos, uma vez que existem muitas imagens quase idênticas porque o conjunto de dados CK+ é composto por uma sequência de imagens obtidas a partir de vídeos. Assim, foi utilizado o subconjunto CK+ com a remoção das imagens muito semelhantes, essa remoção também auxilia na criação de um subconjunto equilibrado de imagens relevantes que podem melhorar o desempenho de generalização dos classificadores de AM investigados. Esse subconjunto é composto por imagens frontais sozinhas.

Ainda, foram coletados dados de acelerômetro e giroscópio de três estudantes, entre 18 e 40 anos, portadores de um smartwatch (Moto 360). Essa estratégia foi desenvolvida considerando a necessidade de garantir que ambos os dados, tanto do acelerômetro quanto do giroscópio, fossem adquiridos no mesmo instante de tempo, uma vez que não foram encontrados dados de ambos os sensores em conjunto. Nesse sentido, experimentos foram realizados de modo não intrusivo para a aquisição dos dados das atividades estudadas nesse trabalho (andando, correndo, sentado, deitado, em pé e queda). Os dados coletados correspondem a 15 minutos de cada usuário realizando cada uma das atividades. Vale ressaltar que foram realizados experimentos reais em todas as atividades, inclusive na atividade queda, a qual foi coletado especificamente os dados de acelerômetro e giroscópio do movimento de queda dos indivíduos. Os movimentos coletados, foram os movimentos realizados no instante da queda considerando a aceleração e a rotação dos sensores. Após a detecção de queda, existem metodologias para confirmar se realmente houve queda ou não, por exemplo, emitir um aviso para o usuário confirmar a queda ou não, assim movimentos que parecem queda podem ser identificados pelo o usuário. Por sua vez, os dados foram coletados em um intervalo de tempo correspondente a 20 milissegundos. Assim, no final do experimento, foram adquiridos um conjunto de 135.000 dados de cada atividade, totalizando 810.000 dados. A metodologia utilizada para os experimentos foi a realização da média simples de cada 25 linhas de dados, equivalente a média dos dados de acelerômetro e giroscópio no intervalo de tempo de 1 segundo.

Para ambos os experimentos (isto é, reconhecimento do usuário e detecção de queda), o desempenho dos algoritmos foi analisado separadamente por meio de uma técnica de validação cruzada de *k-fold* onde $k = 10$, o que nos fornece uma estimativa mais precisa.

4.1.1. Impacto da precisão das aplicações implantadas

Com o intuito de garantir que a abordagem adotada seja semelhante à maneira como os seres humanos interpretam as características do rosto, várias fotos do mesmo indivíduo foram utilizadas para o modelo de reconhecimento do usuário. A Tabela 1 apresenta os resultados obtidos pelos algoritmos de classificação em função da acurácia do reconhecimento do usuário. Os resultados demonstram que o algoritmo SVM supera as outras soluções com uma taxa de precisão de 99,75% nas experiências. Outros algoritmos também tiveram altas taxas de precisão, como o kNN e *Ensemble*, com 99% e 99,70%, respectivamente. Embora a *Ensemble* tenha alcançado uma taxa de precisão muito próxima da SVM, a *Ensemble* emprega vários algoritmos que aumentam significativamente seus custos computacionais mais do que quando usados individualmente. Por esta razão, na nossa proposta de reconhecimento de usuários, escolhemos a SVM que atinge a taxa mais precisa e tem menores custos computacionais do que as outras técnicas utilizadas.

No que diz respeito a detecção de quedas (Tabela 2), os resultados demonstram que o algoritmo *Multilayer perceptron* (MLP), para esse conjunto de dados, possibilita uma classificação mais precisa, se comparado com os outros classificadores utilizados em comparação. Os resultados obtidos com esse algoritmo apresenta uma média de acurácia com valor de 96,62%. Além disso, é possível notar uma menor dispersão dos resultados obtidos pelo MLP, o que demonstra uma maior estabilidade em suas execuções.

Tabela 1. Resultados da acurácia do reconhecimento de usuários.

	Naive Bayes	Arv. Dec	KNN	SVM	Ensemble
Teste 1	89,50	95,00	99,50	99,50	99,50
Teste 2	92,50	93,00	99,50	100,00	100,00
Teste 3	90,00	94,00	99,50	100,00	100,00
Teste 4	91,00	93,50	97,50	100,00	100,00
Teste 5	88,00	96,00	99,00	100,00	99,50
Teste 6	86,00	92,50	99,00	99,50	99,50
Teste 7	85,00	96,00	99,00	100,00	100,00
Teste 8	87,50	95,00	98,50	99,50	100,00
Teste 9	84,00	93,50	99,50	99,50	99,00
Teste 10	86,00	94,00	99,00	100,00	99,50
Média	87,95	94,25	99,00	99,80	99,70

Tabela 2. Resultados da acurácia da detecção de quedas.

	Naive Bayes	Arv. Dec	KNN	SVM	MLP
Teste 1	90,03	92,32	88,73	93,46	93,14
Teste 2	93,46	89,38	92,64	92,32	94,29
Teste 3	82,51	93,14	91,83	84,48	94,29
Teste 4	94,77	98,86	99,02	96,24	97,06
Teste 5	94,93	98,53	98,53	97,71	98,7
Teste 6	96,24	97,22	97,06	95,75	96,41
Teste 7	98,04	99,84	99,35	97,71	99,02
Teste 8	97,06	98,53	98,86	98,03	98,2
Teste 9	97,22	97,88	98,37	98,2	98,04
Teste 10	95,03	97,55	97,55	95,1	97,06
Média	93,93	96,33	96,20	94,90	96,61

4.2. Cenários de Avaliação 2

Os experimentos de avaliação foram feitos com o objetivo de realizar uma análise exploratória do desempenho da arquitetura do sistema proposto, utilizando duas aplicações interativas de monitoramento: i) Reconhecimento de Usuários e ii) Detecção de Queda. As aplicações foram executadas em ambientes diferentes, chamados de níveis: i) nível 1 (dispositivo embarcado - Raspberry PI) e ii) nível 2 (Servidor Remoto). Assim, foi possível inferir em qual nível da arquitetura, o processamento das aplicações é válido de acordo com a situação e quantidade de dados de entrada. A coleta dos dados de imagem é feita por câmeras instaladas no ambiente ou pelos smartphones e os dados de acelerômetro e giroscópio por um *smartwatch*. Vale ressaltar que os blocos de dados coletados pelas interfaces servem como entrada nas aplicações. Esses blocos de dados podem ser imagens ou coordenadas de acelerômetro e giroscópio, como mostra a figura 4.

Os cenários foram divididos com base nos blocos de dados de entrada para o dispositivo embarcado ou para o Servidor. A Tabela 3 apresenta os cenários considerados.




Figura 4. Tipos de dados de entrada

Tabela 3. Valores dos parâmetros dos experimentos

Parâmetros para o consumo de memória e processador	
Experimentos usando o servidor remoto - nível 2	E2, E3, E4, E5, E6, E7, E8, E9
Experimento usando o dispositivo embarcado - nível 1	E1
Número de blocos de dados p/ servidor remoto	1, 2, 4, 8, 16, 32, 64, 128, 256
Número de blocos de dados p/ dispositivo embarcado	1

Para a avaliação da arquitetura do INCA, foi realizado experimentos com a finalidade de avaliar o desempenho de dispositivos escassos em relação a um servidor remoto, considerando o uso de *fog computing* e descarregamento de dados. Sendo assim, a avaliação proposta visa deixar o processamento das aplicações nos dispositivos embarcados (nível 1) e realizar a transmissão dos dados para próximo nível somente se houver diferença estatística no processamento. Assim, é possível utilizar dispositivos de borda da rede tanto para coletar quanto para atuar no ambiente e os recursos dos dispositivos são aproveitados completamente, permitindo que os dados estejam mais próximos dos usuários finais por meio do paradigma *fog computing*.

As avaliações de desempenho concentraram-se na gerência dos recursos utilizando as métricas de consumo de memória e de processamento. Analisamos também o desempenho da arquitetura proposta no tempo de execução das aplicações e na distribuição do processamento na arquitetura do INCA em quatro cenários (Ver Tabela 4), por meio do descarregamento de dados (Seção 4.2.1).


Tabela 4. Valores dos parâmetros dos cenários

Parâmetros para o descarregamento de dados	
Cenário 1	1 Servidor remoto (Nível 2)
Cenário 2	1 Servidor remoto (Nível 2) e 1 Dispositivo Embarcado (Nível 1)
Cenário 3	1 Servidor remoto (Nível 2) e 3 Dispositivo Embarcado (Nível 1)
Cenário 4	1 Servidor remoto (Nível 2) e 5 Dispositivo Embarcado (Nível 1)


Foi considerado diferentes cenários reais, em que pode ter vários dispositivos embarcados distribuídos em um ambiente inteligente de monitoramento (e.g. casa de repouso). Os resultados foram obtidos considerando-se 95% de intervalo de confiança, uma vez que cada experimento foi realizado 33 vezes.

4.2.1. Impacto das aplicações na infraestrutura

A figura 5 mostra o consumo de memória e processador das aplicações de reconhecimento de usuários pela face e de detecção de queda pelos sensores acelerômetro e giroscópio do *smartwatch* em ambos os níveis.



(a) Reconhecimento de Indivíduos: Desempenho do consumo de memória. (b) Detecção de Queda: Desempenho do consumo de memória.



(c) Reconhecimento de Indivíduos: Desempenho de processamento. (d) Detecção de Queda: Desempenho de processamento.

Figura 5. Desempenho de memória e de processamento das aplicações

As figuras 5(a) e 5(b) mostram o consumo da memória de ambos os ambientes para as duas aplicações interativas de monitoramento. Enquanto que as figuras 5(c) e 5(d) mostram o consumo do processamento. Apesar do alto consumo de processador e memória no dispositivo embarcado em relação ao servidor, os resultados mostram que os dispositivos embarcados suportam tais aplicações. Por outro lado, abre espaço para investigação de algoritmos com alto desempenho para esses dispositivos, de forma que exija menos recursos e deixe o máximo possível de processamento nos sensores de borda, assim pode economizar energia com menos transmissões para a nuvem.

A Figura 6 mostra a avaliação de desempenho dos níveis 1 e 2 em relação ao tempo de processamento das aplicações interativas. A Figura 6 mostra o tempo que a aplicação de reconhecimento de usuários levou para executar nos níveis, de acordo com a quantidade de blocos de dados como entrada. É possível notar que com 1 bloco de dados, o processamento da extração de características e classificação no nível 1 leva em torno de 5s enquanto que no nível 1 o tempo é 5 vezes menor. Porém, conforme a quantidade de

blocos de dados aumenta, o tempo de processamento do nível 2 se aproxima do tempo de processamento de 1 bloco de dados no nível 1. Isso nos permite verificar que em uma grande rajada de dados é possível usar o nível 1 para o processamento, deixando-o menos ocioso enquanto o nível 2 processa uma grande quantidade de dados.

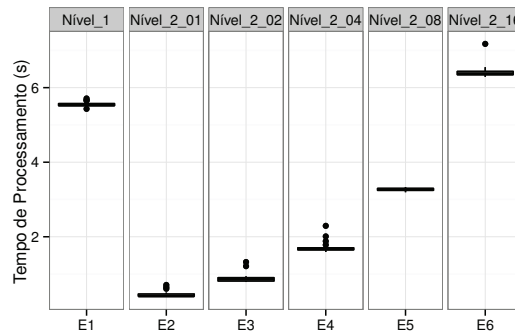


Figura 6. Reconhecimento de Indivíduos: Tempo de execução.

Da mesma forma, a Figura 7 mostra o tempo de processamento da aplicação de detecção de queda. Neste cenário, o dispositivo embarcado leva 2.2 segundos para detectar uma queda com 1 bloco de dados. Neste cenário, o tempo de resposta do nível 2 é 7 vezes menor, porém também se aproxima do tempo de resposta do dispositivo embarcado em um determinado instante. Diante disso, é viável empregar a abordagem de descarregamento de dados para paralelizar o processamento de uma grande quantidade de dados, uma vez que além de tornar o processamento do dispositivo no nível 1 oportunístico também aproxima os dados do utilizador final, principal conceito de *fog computing*.


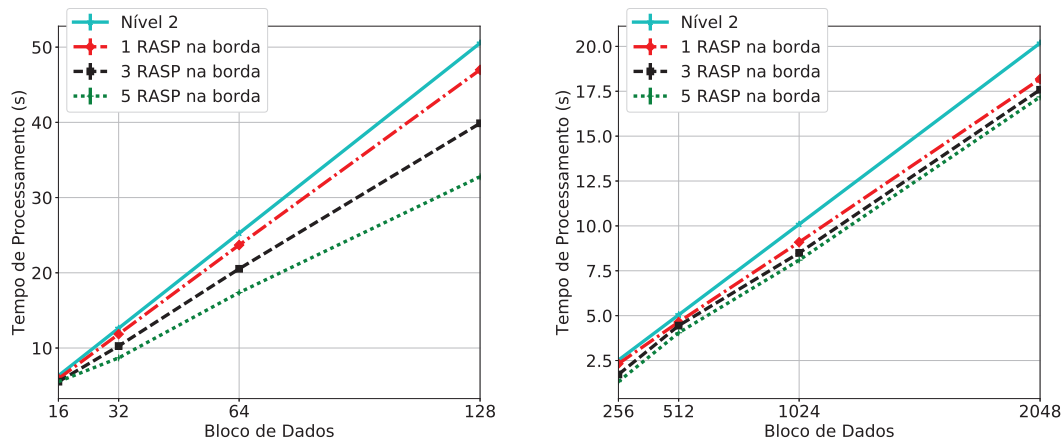


Figura 7. Detecção de Queda: Tempo de execução.

O uso da técnica de descarregamento de dados também foi proposto a fim de distribuir o processamento entre os níveis 1 e 2 da arquitetura do INCA, considerando os cenários apresentados na Tabela 4 (ver Figura 8). A partir de um determinado ponto, o tempo de processamento diminui para ambas as aplicações interativas. Na Figura 8(a), percebemos que o tempo de processamento do nível 2 é 1,27 maior do que o ambiente com 3 dispositivos embarcados e 1,54 maior com 5 dispositivos. Na Figura 8(b), o tempo de processamento foi menor em até 1,15 com 5 dispositivos embarcados em relação ao nível 2. É possível notar que em dados de entrada mais robustos (imagem), o uso do descarregamento de dados e o de *fog computing* tiveram maior impacto no desempenho do sistema proposto.



(a) Reconhecimento de Indivíduos: Descarrega- (b) Identificação de Queda: Descarregamento de da-
mento de dados. dos.

Figura 8. Resultados obtidos para o descarregamento de dados

5. Conclusão

Este artigo apresentou um sistema flexível capaz de monitorar e gerenciar indivíduos com mobilidade reduzida, de maneira individualizada. Aplicações de monitoramento interativas (reconhecimento de usuário e detecção de queda) foram desenvolvidas e avaliadas na infraestrutura do sistema. Os resultados mostraram que o uso de *fog computing* e descarregamento de dados aumenta o desempenho de sistemas para casas e/ou ambientes inteligentes.

Agradecimentos: Os autores gostariam de agradecer o apoio financeiro da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) processos 2014/06330-5, 2015/21642-6, 2016/14267-7 e 2016/25865-2.

Referências

- Banerjee, T., Keller, J. M., Popescu, M., and Skubic, M. (2015). Recognizing complex instrumental activities of daily living using scene information and fuzzy logic. *Computer Vision and Image Understanding*.
- Bonomi, F., Milito, R., Natarajan, P., and Zhu, J. (2014). *Fog Computing: A Platform for Internet of Things and Analytics*, pages 169–186. Springer International Publishing, Cham.
- Corchado, J. M., Bajo, J., Tapia, D. I., and Abraham, A. (2010). Using heterogeneous wireless sensor networks in a telemonitoring system for healthcare. *IEEE Transactions on Information Technology in Biomedicine*, 14(2):234–240.
- Eugster, P. T., Felber, P. A., Guerraoui, R., and Kermarrec, A.-M. (2003). The many faces of publish/subscribe. *ACM Comput. Surv.*, 35(2):114–131.
- Fersi, G. (2015). Middleware for internet of things: A study. In *2015 International Conference on Distributed Computing in Sensor Systems*, pages 230–235.

- Filho, G., Ueyama, J., Faical, B., Guidoni, D., and Villas, L. (2015). Residi: An intelligent decision platform for residential infrastructure using wireless sensors and actuators. In *Computer Networks and Distributed Systems (SBRC), 2015 XXXIII Brazilian Symposium on*, pages 237–245.
- Filho, G. P. R., Ueyama, J., Villas, L. A., Pinto, A. R., Goncalves, V. P., Pessin, G., Pazzi, R. W., and Braun, T. (2014). Nodepm: A remote monitoring alert system for energy consumption using probabilistic techniques. *Sensors*, 14(1):848–867.
- Gonçalves, V. P., Neris, V. P., Ueyama, J., Seraphini, S., Dias, T. C., and Rocha Filho, G. (2013). Senior citizens in interaction with mobile phones: A flexible middleware approach to support the diversity. *Proc. of the SERP 2013*, 1:56–62.
- Gubbi, J., Buyya, R., Marusic, S., and Palaniswami, M. (2013). Internet of things (iot): A vision, architectural elements, and future directions. *Future Generation Computer Systems*, 29(7):1645 – 1660.
- Lucey, P., Cohn, J. F., et al. (2010). The extended cohn-kanade dataset (ck+): A complete dataset for action unit and emotion-specified expression. In *Computer Vision and Pattern Recognition Workshops, IEEE Computer Society Conf. on*.
- Maia, P., Baffa, A., Cavalcante, E., Delicato, F. C., Batista, T., and Pires, P. F. (2015). A middleware platform for integrating devices and developing applications in e-health. In *Computer Networks and Distributed Systems (SBRC), 2015 XXXIII Brazilian Symposium on*, pages 10–18.
- Rialle, V., Duchene, F., Noury, N., Bajolle, L., and Demongeot, J. (2002). Health "Smart"home: information technology for patients at home. *Telemedicine journal and e-health : the official journal of the American Telemedicine Association*, 8(4):395–409.
- Romero, E., Araujo, A., Moya, J. M., de Goyeneche, J.-M., Vallejo, J. C., Malagon, P., Villanueva, D., and Fraga, D. (2009). Image processing based services for ambient assistant scenarios. In *Distributed Computing, Artificial Intelligence, Bioinformatics, Soft Computing, and Ambient Assisted Living*, volume 5518 of *Lecture Notes in Computer Science*, pages 800–807. Springer Berlin Heidelberg.
- Stanford-Clark, A. and Nipper, A. (2014). Mq telemetry transport.
- Stojkoska, B. L. R. and Trivodaliev, K. V. (2017). A review of internet of things for smart home: Challenges and solutions. *Journal of Cleaner Production*, 140, Part 3:1454 – 1464.
- Stojkoska, B. R., Solev, D., and Davcev, D. (2012). Variable step size lms algorithm for data prediction in wireless sensor networks. *Sensors & Transducers*, 14(2):111.
- System, M. A. (2015). QMedic - medical alert system - full review.
- Taleb, T., Bottazzi, D., and Nasser, N. (2010). A novel middleware solution to improve ubiquitous healthcare systems aided by affective information. *IEEE Transactions on Information Technology in Biomedicine*, 14(2):335–349.
- Viani, F., Robol, F., Polo, A., Rocca, P., Oliveri, G., and Massa, A. (2013). Wireless architectures for heterogeneous sensing in smart home applications: Concepts and real implementation. *Proceedings of the IEEE*, 101(11):2381–2396.