

# Monitoramento Inteligente e Sensível ao Contexto na Assistência Domiciliar Telemonitorada

Alessandro Copetti<sup>1</sup>, J. C. B. Leite<sup>1</sup>, Orlando Loques<sup>1</sup>,  
Thais de Paola Chequer Barbosa<sup>2</sup>, Antonio Claudio Lucas da Nóbrega<sup>2</sup>

<sup>1</sup>Instituto de Computação – Universidade Federal Fluminense (UFF)  
Niterói, RJ – Brasil

<sup>2</sup>Instituto Biomédico – Universidade Federal Fluminense (UFF)  
Niterói, RJ – Brasil

{acopetti, julius, loques}@ic.uff.br

chequerthais@hotmail.com, anobrega@vm.uff.br

**Abstract.** *We propose a framework for ubiquitous and intelligent health monitoring of a person at home (remote assisted living). In this context, ubiquitous computing has an important role, because new classes of variables can be treated. The proposed solution integrates medical knowledge, environmental conditions, and physiological and behavioral data of the patient. The relevant modules of the framework are intended for managing context, reasoning, and learning. A fuzzy logic model with rules based on medical recommendations allows to analyse and identify critical situations of the patient. A prototype for monitoring blood pressure illustrates the use of the proposed model.*

**Resumo.** *Neste trabalho propomos um arcabouço para monitoramento ubíquo e inteligente da saúde de uma pessoa em casa (remote assisted living). Nesse contexto, a computação ubíqua tem papel relevante, pois novas classes de variáveis podem ser tratadas. A solução proposta integra conhecimentos médicos, condições ambientais, dados fisiológicos e comportamentais do paciente. O arcabouço tem como elementos relevantes módulos de gerenciamento de contexto, raciocínio e aprendizagem. Um modelo em lógica difusa e regras baseadas em recomendações médicas permitem analisar e identificar situações críticas do paciente. Um protótipo de monitoramento da pressão arterial ilustra a utilização do modelo proposto.*

## 1. Introdução

No Brasil, é estimado que a população idosa dobre no período de 2000-2025, chegando a 30 milhões de pessoas com mais do que 60 anos [1]. Além disso, haverá seis idosos para cada cinco crianças com menos de cinco anos de idade e possivelmente uma deficiência no número de médicos geriatras para atender a essa população [2]. A assistência domiciliar telemonitorada representa uma solução interessante tanto para evitar um colapso no sistema hospitalar quanto para promover a saúde em casa. No entanto, os ganhos potenciais com a assistência domiciliar exigem infra-estruturas de hardware e software nas residências para atender a essa demanda e melhorar a qualidade no gerenciamento das informações produzidas.

Uma questão importante é investigar o impacto que a computação pervasiva, caracterizada pela utilização de sensores e outros dispositivos computacionais impregnados no ambiente e nas pessoas (computação vestível - *wearable computing*), tem sobre a assistência domiciliar telemonitorada a idosos. Isso claramente contribui para o avanço das investigações no âmbito do 5º grande desafio da Sociedade Brasileira de Computação [3] (Desenvolvimento Tecnológico de Qualidade), por buscar soluções para o projeto e o desenvolvimento de sistemas ubíquos e corretos.

Com a computação ubíqua, o monitoramento do paciente sofre uma revolução: os dados fisiológicos são obtidos em momentos variados do dia, ao mesmo tempo que outras variáveis podem ser coletadas e interpretadas, como o seu comportamento (idas ao banheiro, se está dormindo, comendo, etc.) e as condições do ambiente (umidade, temperatura, vento, dentre outras). No entanto, para viabilizar o monitoramento domiciliar são necessários sistemas com características específicas em inteligência e flexibilidade, para raciocinar usando tanto o conhecimento médico quanto os dados históricos do paciente.

Enquanto muitos estudos têm sido feitos em torno de técnicas para reconhecimento de atividades das pessoas [6] [11] [16], pouco avanço foi feito na fusão dessas variáveis com os dados fisiológicos dos pacientes. Por exemplo, enquanto a pessoa está comendo ou caminhando, naturalmente aumenta a sua pressão arterial [15], ou, a temperatura do ambiente tem influência sobre a frequência cardíaca do paciente. Nós argumentamos que sistemas sensíveis ao contexto que considerem as informações ambientais e comportamentais no monitoramento de pacientes melhoram a qualidade da tomada de decisão médica.

Neste trabalho, nós propomos um arcabouço para o monitoramento inteligente da saúde de um paciente em casa. A solução proposta integra recomendações médicas, condições ambientais, dados fisiológicos e o comportamento do paciente. O arcabouço tem como elementos relevantes módulos de gerenciamento de contexto, raciocínio e aprendizagem. O raciocínio tem papel fundamental, uma vez que permite identificar situações críticas, onde analisamos valores anormais de dados fisiológicos. Para definir o componente de decisão do módulo de raciocínio está sendo desenvolvido um protótipo. Os demais módulos são interligados para cooperarem nas atividades de tomada de decisão em aplicações pervasivas na assistência domiciliar.

Uma arquitetura típica de telemonitoramento envolve dispositivos sensores que coletam dados do paciente e enviam esses dados para um centro de supervisão (uma clínica, um posto de atendimento, um médico ou um hospital). Nossa proposta avança essa arquitetura por incorporar inteligência local no domicílio: os sensores espalhados pela casa e no corpo da pessoa geram dados constantemente e os seus valores são monitorados por um sistema computacional que interpreta-os usando conhecimento médico. A situação do paciente pode determinar a atuação num sensor, uma interação com a pessoa ou lançar um alerta para o centro de supervisão. Partindo dessa visão, no final do trabalho são discutidos desafios de pesquisa nessa área.

## **2. Assistência Domiciliar Telemonitorada em Ambientes Pervasivos**

Entendemos que no estudo do papel da computação pervasiva na assistência domiciliar as principais questões alvo são a saúde do paciente (monitorando seus sinais vitais), o seu comportamento (monitorando suas atividades e movimentos), o conforto (automatizando

tarefas e dando apoio em atividades da vida diária) e a educação em saúde (informações chegam ao paciente por meio de diversos dispositivos). Nós nos concentraremos sobre as duas primeiras questões, as quais envolvem o monitoramento.

O telemonitoramento e o tele-tratamento são serviços que permitem aos profissionais especializados monitorar as condições de saúde de um paciente para atuar sob indicações de um estado anormal [7]. Esse acompanhamento pode identificar antecipadamente a necessidade de alteração na medicação ou mesmo o diagnóstico de uma doença na fase inicial. Segundo Scanaill et al [18], o telemonitoramento de longa duração proporciona dados úteis clinicamente, que podem permitir aos médicos tomarem decisões com maior conhecimento, para monitorar deteriorações nas condições crônicas ou para avaliar a resposta de um paciente a um tratamento.

## 2.1. Classes de Variáveis para Monitoramento

Na nossa visão, um sistema de telemonitoramento deve controlar três grandes classes de variáveis: ambientais, fisiológicas e comportamentais; especificamente:

- Ambientais. No ambiente podem ser encontrados diversos sensores, dentre eles, para detecção de luz, som, fumaça, humidade, fogo, temperatura, pressão no piso e, em geral, para monitoramento de fogão ou aparelhos eletro-domésticos que ofereçam algum risco. Neste contexto, dependendo da doença, alguns tipos de sensores são mais importantes que outros como, por exemplo, detectar se o piso está molhado para diminuir a possibilidade de quedas. O investimento em sensores desse tipo pode ser motivado no caso de pacientes com Esclerose Lateral Amiotrófica que estão mais sujeitos a quedas. Ou, simplesmente, medir a intensidade do som ou a luminosidade do ambiente, são maneiras de acompanhar a situação do paciente idoso quando suas capacidades fisiológicas e/ou motoras se reduzem com o passar dos anos.
- Fisiológicas do Paciente. Envolve o uso de equipamentos, sensores e dispositivos adicionados ao corpo do usuário (*wearable devices*), formando uma *Wireless Body Area Network*. É interessante notar que a tecnologia médica está tornando acessível certos equipamentos e sensores para uso em casa e que podem transmitir seus dados eletronicamente. Dois exemplos citados em [12] são a análise da concentração de hemoglobina e a tendência de coagulação do sangue (através do oxímetro de pulso), e a capacidade pulmonar (através do espirômetro). Outros exemplos são pressão arterial, nível de glicose, temperatura corporal, peso, frequência cardíaca e eletrocardiograma.
- Comportamentais. Nesse aspecto, a rede de sensores coleta os dados que registram as atividades realizadas em casa. Os dados são analisados e usam-se técnicas de inteligência artificial para tomada de decisão e produção de informações em mais alto nível. A preocupação com a independência recai sobre as Atividades da Vida Diária (AVD): banhar-se, vestir-se, usar o banheiro, locomover-se, ter continência e alimentar-se. Outras ainda podem ser interessantes como dormir, sair e retornar à casa e realizar atividades domésticas. Sensores em portas, RFIDs em objetos e acelerômetros são os principais sensores utilizados.

## 2.2. Problemas no Monitoramento de um Paciente em Casa

Os sistemas atuais de tratamento de saúde em casa exigem que a pessoa informe emergências através do acionamento de alarmes. Ou então, os sistemas reagem quando

limites pré-fixados de dados fisiológicos são ultrapassados. Há então a necessidade de identificar situações críticas com maior eficiência, tendo um compromisso entre não ser omissos e não ter um comportamento paranóico. Diante desse objetivo, o monitoramento envolve uma série de questões para serem resolvidas. Os principais problemas são:

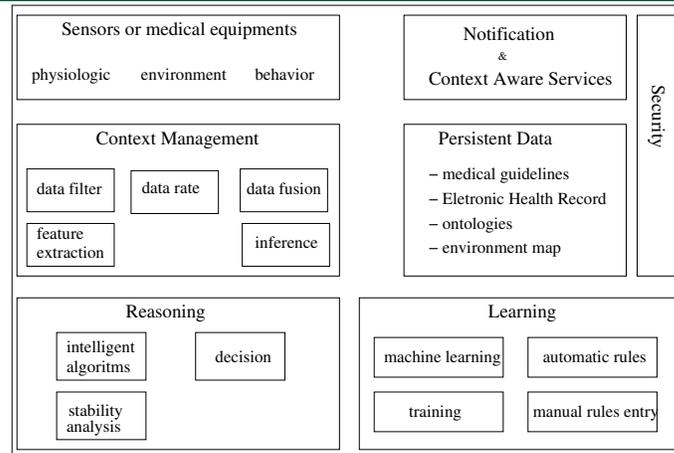
- a) correlação entre variáveis. A piora num dado fisiológico pode ser acompanhada de uma piora num outro tipo de dado - em algumas circunstâncias o aumento da frequência cardíaca pode vir seguido de uma queda ou aumento na pressão arterial.
- b) individualização no tratamento do paciente. Os dados fisiológicos variam muito para cada paciente. Uma solução possível para esse problema é a definição de regras que estabeleçam os limites individuais, ou então que o histórico seja considerado nas decisões. Assim, uma pessoa que já possui valores altos de pressão não terá alarmes constantemente sendo disparados sobre sua situação.
- c) influência do comportamento e do ambiente. Um exemplo é a temperatura ambiente interferir na frequência cardíaca do paciente, ou, a pessoa quando estiver realizando uma atividade doméstica ter um aumento na sua pressão arterial. Deve-se ter consciência dessas circunstâncias para considerá-las nos limites do paciente e também auxiliar na detecção de causas.
- d) relaxação (ou afrouxamento) dos limites de cada variável. Os valores rígidos que tentam expressar um conceito ou situação não são adequados nas diversas variáveis, principalmente as fisiológicas. Por exemplo, se a pessoa está comendo, sua pressão arterial pode aumentar até  $8,8mmHg$  em relação a sua média de PA ([14], p. 84). Somente se o limite definido for ultrapassado, acontecerá uma mudança para uma situação fora do normal.
- e) incerteza na leitura dos sensores devido a ruídos e condições do ambiente. A simples definição de regras genéricas que restringem os valores possíveis de obter para cada exame não são suficientes para resolver a complexidade desse problema. Nesse item deve-se considerar a posição dos sensores, os movimentos da pessoa e também os problemas inerentes a transmissão de dados em redes sem fio.

Nesse trabalho nós nos concentraremos em tratar os problemas dos itens “b”, “c” e “d” (individualização, influência do ambiente ou do comportamento e relaxação dos limites). A correlação entre variáveis (item “a”) é tratada num nível mais básico, mas pode ser uma extensão dessa proposta. Para o item “e” assumimos que os sensores disponíveis são confiáveis.

### 3. Arcabouço de Monitoramento Inteligente

O arcabouço proposto neste trabalho chama-se H-SAUDE: “*Health Support in Aware and Ubiquitous Domestic Environments*” e tem como objetivo o suporte ao monitoramento inteligente e sensível ao contexto. O arcabouço possibilita um melhor projeto de aplicações de telemonitoramento por estabelecer inter-relações entre componentes que privilegiam o raciocínio sobre os dados de sensores.

O arcabouço (figura 1) tem como elementos relevantes módulos de Gerenciamento de Contexto, Raciocínio e Aprendizagem, respectivamente, *Context Management*, *Reasoning* e *Learning*. Os módulos são constituídos de componentes que usam internamente regras. Quando descrevemos situações normais ou anormais de saúde com base



**Figura 1. Módulos e seus componentes no arcabouço H-SAUDE**

na descrição das variáveis de contexto, e determinamos ações a serem executadas, estamos definindo regras para acompanhar e tomar decisões no monitoramento. Por exemplo, uma regra pode declarar que se a pessoa estiver em repouso e a frequência cardíaca estiver acima de  $140bpm$  é uma situação de alerta ou emergência.

A importância de gerar alertas confiáveis em sistemas de telemonitoramento fazem do Raciocínio o núcleo do arcabouço. O componente de decisão do módulo de Raciocínio (descrito na seção 4) recebe como entrada dados pré-processados de sensores, realiza uma análise para determinar situações críticas e identifica em quais circunstâncias estão ocorrendo as situações de alerta. Uma outra contribuição do módulo é servir como base para o desenvolvimento de aplicações de monitoramento que trabalhem com as variáveis ambientais, fisiológicas e comportamentais do paciente em casa. Técnicas de análise de estabilidade, como filtros de Kalman, podem ser acopladas para detectar desvios nas diversas classes de variáveis.

O módulo de Gerenciamento de Contexto enfatiza mecanismos primários de tratamento e refinamento dos dados. Inicialmente, podem ser realizadas a filtragem de dados e a extração de características relevantes. A fusão de dados (agregação) e inferência geram uma nova informação. O módulo pode atuar no ambiente da casa, alterando a taxa amostral de um sensor. Esse módulo pode ainda contar com Serviços Sensíveis ao Contexto, comuns a diversas propostas nesta área [8] [19], como: seleção, descoberta, representação, armazenamento e disseminação.

A fusão de dados e a inferência geram informações em um nível mais alto para o módulo de Raciocínio. Uma regra pode definir, por exemplo, que se a pessoa está no quarto e se a pessoa não apresenta movimentos então ela está dormindo. No entanto, para uma decisão, podem ser utilizados algoritmos inteligentes (do módulo de Raciocínio), como modelos de Markov ocultos e redes neurais.

O módulo de Aprendizado objetiva atender ao requisito de individualização de sistemas de assistência domiciliar pervasivos. A base de treinamento pode ser constituída por exames realizados previamente pelo paciente. Exemplos disso são os dados de MAPA (Monitorização Ambulatorial da Pressão Arterial), coletados durante 24 horas, e os dados de teste de estresse mental.

Uma base de treinamento pode também ser formada por um processo de calibração, que constitui em demonstrar para o sistema uma atividade ou situação na casa envolvendo o usuário. Por exemplo, a variação na frequência cardíaca e a aproximação da pessoa junto a equipamentos de ginástica, pode representar uma sessão de exercícios físicos. Muitos trabalhos fazem essa demonstração real para que o sistema reconheça atividades da pessoa [16] [21]. No entanto, não realizam a associação com os sinais fisiológicos.

Na entrada manual de regras (*manual rules entry*) podem, por exemplo, ser colocadas regras para tratar as automatizações do ambiente que objetivam conforto ao ocupante. Por exemplo: aumentar o volume do telefone se a pessoa está distante; avisar o paciente na hora de tomar um remédio.

A interoperabilidade com os sistemas externos é intermediada pelo armazenamento de recomendações médicas (ou *guidelines*, os quais podem vir a gerar regras no futuro), o prontuário do paciente e ontologias da área de saúde, segundo padrões internacionais. Esses recursos e o acesso externo são controlados pelo módulo de Segurança do sistema.

A interação entre os componentes ocorre de diversas formas. Por exemplo: o Gerenciamento de Contexto infere se ocorreu um movimento de transição (por exemplo, de deitado para em pé) e então dispara uma regra no módulo de Raciocínio para realizar uma medição; o Raciocínio atualiza no Gerenciamento de Contexto a situação do usuário (basicamente, se está normal, em alerta ou emergência) e pode utilizar o serviço de Notificação no caso de uma emergência; o Raciocínio detecta uma situação de alerta e determina que o componente de taxa amostral aumente a frequência de monitoramento dos sinais vitais da pessoa.

#### 4. Componente de Decisão do Módulo de Raciocínio

Esta seção apresenta o módulo de Raciocínio do arcabouço H-SAUDE, mais especificamente, o seu componente chamado de Decisão. O módulo foi definido a partir de um estudo de caso de telemonitoramento da pressão arterial (PA). Nós consideramos o dia a dia de uma pessoa idosa vivendo sozinha em uma casa e com recursos de computação pervasiva. Nesta seção é apresentado o projeto desse estudo de caso para, então, propor o modelo do componente de Decisão e, na seção 5, descrever a implementação do protótipo. Inicialmente, são definidas as regras contendo o conhecimento médico necessário para o monitoramento, as entradas e saídas do módulo e a definição de variáveis. Ao final, o modelo do módulo de Raciocínio é descrito.

##### 4.1. Conhecimento Médico para o Estudo de Caso

A primeira questão a tratar é como o sistema pode expressar o conhecimento médico considerando a complexidade do monitoramento que pretendemos. Uma forma simples para essa representação, que possa ser bem entendida por médicos, são as regras se-então. A seguir, são mostrados alguns exemplos de regras utilizando variáveis ambientais, fisiológicas e comportamentais (atividade da pessoa), que poderiam ser definidas. Elas são produto da investigação de publicações e de experiência de especialistas em saúde:

- Se a média da pressão sistólica for maior que  $135mmHg$  e a da diastólica for maior que  $85mmHg$  então o paciente é considerado hipertenso [10]

- Se está comendo, a pressão sistólica deve subir no máximo a  $8,8mmHg$  da média e a diastólica a  $9,6mmHg$  ([14], p. 84)
- Se está realizando tarefas/atividades domésticas, a pressão sistólica deve subir no máximo a  $10,7mmHg$  da média e a diastólica a  $6,7mmHg$  ([14], p. 84)
- Se está dormindo, a pressão sistólica deve ficar no máximo a  $-10mmHg$  da média e a diastólica a  $-7,6mmHg$  [10]
- É sempre admissível que a frequência cardíaca esteja entre 61 e 99bpm em repouso
- Se a temperatura ambiente está alta e a frequência cardíaca é alta então notifica “temperatura ambiente alta”

#### 4.2. Entradas e Saídas no Componente de Decisão

A base de dados inicial da aplicação de monitoramento da PA é formada pelos dados de MAPA. O MAPA realiza a medição automática do paciente em intervalos pré-programados. Os dados de MAPA são os seguintes: pressão arterial sistólica (PAS), pressão arterial diastólica (PAD), frequência cardíaca (FC), tipo de atividade e hora. A atividade é anotada pelo paciente.

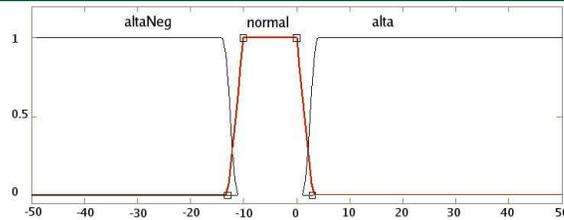
As variáveis fisiológicas a serem monitoradas são: PAS, PAD e FC. A escolha dessas variáveis deve-se a simplicidade, a disponibilidade e a resposta rápida que sofrem diante de uma mudança no quadro clínico do paciente. Quanto aos fatores ambientais que têm influência sobre a saúde do paciente, como luminosidade, temperatura, ruído, umidade e fumaça, dentre outros, para fins de simplificação, optamos inicialmente por usar somente a temperatura ambiente. No comportamento do paciente, a atividade atual assumirá as situações de dormindo, repouso, comendo, caminhando ou atividade doméstica. A tabela 1 mostra as variáveis monitoradas.

**Tabela 1. Variáveis e sensores utilizados no estudo de caso**

Variáveis	Sensores necessários
<b>Fisiológicas</b>	
- PAD e PAS	⇒ monitor de PA
- FC	⇒ monitor de frequência cardíaca
<b>Comportamentais</b>	
- atividade	⇒ acelerômetro e detector de presença
<b>Ambientais</b>	
- temperatura	⇒ sensor de temperatura

Enquanto o acelerômetro e os monitores de dados fisiológicos são vestíveis, o sensor de temperatura e o de detector de presença encontram-se nos principais locais onde a pessoa permanece na casa (por exemplo, banheiro, quarto, cozinha e sala). Uma consulta solicitando a temperatura retorna o valor conforme o cômodo onde se encontra o paciente. Todos os valores medidos são transmitidos pela rede sem fio para o computador da casa. Nele são executados os processos de raciocínio sobre os dados. O que ficará para futuras investigações é a possibilidade de pré-processar as regras no próprio dispositivo sensor, evitando que a maior parte dos dados seja transmitida pela rede.

A atividade que o paciente está realizando é obtida por um sub-sistema que infere essa informação de alto nível usando dados de sensores, e a fornece para nosso sistema. Por exemplo, em [11], a acurácia do modelo para afirmar que a atividade é “comendo” é de 76.3%. Essa informação será usada pela nossa aplicação de monitoramento. Isso



**Figura 2. Variação da PAS em relação a média quando está dormindo (variação da PAS em  $mmHg$  versus grau de pertinência)**

porque estamos preocupados não em reconhecer as atividades, mas em utilizar a variável atividade no raciocínio do monitoramento.

Nós assumimos que existe um ambiente pervasivo com disponibilidade de sensores, tanto no corpo da pessoa como no ambiente, conforme a relação de sensores da tabela 1. Estes sensores têm comunicação com o computador da casa através de *links* confiáveis, seguros e sem interferência. Isto é, a comunicação é confiável: as mensagens chegam e tem integridade. Há também um detector de falhas nos sensores, o que faz com que o sistema seja informado imediatamente quando um sensor apresenta falha. Nosso protótipo é direcionado para atender uma única pessoa, pois a sua identificação não é uma entrada do sistema. No entanto, ele pode ser estendido para mais pessoas através da adoção de tecnologias de identificação.

Já no resultado do sistema, pretendemos inferir situações de “alerta” que indiquem um desvio do esperado pelas recomendações médicas e, ainda, identificar situações de “emergência” que necessitem de busca por um atendimento. No primeiro caso, o alerta servirá para a melhora da qualidade da decisão médica, já que identifica contextos específicos onde ocorrem anormalidades; no segundo caso, as emergências servem para notificar alguém sobre a necessidade de atendimento urgente.

### 4.3. Definição das Variáveis

A dinâmica do comportamento humano, as variações apresentadas pelos sinais vitais, as incertezas dos dados que caracterizam ambientes pervasivos dotados de sensores e a forma como o conhecimento humano, mesmo o especializado, expressa suas idéias não possibilitam a aplicação de técnicas exatas. Apesar das regras produzidas na subseção 4.1 apresentarem dados quantitativos para cada variável, elas estão sujeitas a oscilações e exigem uma lógica apropriada para manipulação e tomada de decisão. A lógica difusa (*fuzzy*) [17] apresenta propriedades que facilitam representar as classes de variáveis que estamos trabalhando e a elaboração de regras que permitem um raciocínio eficiente. O componente de Decisão utiliza lógica *fuzzy*, sendo para nosso estudo de caso definidas algumas variáveis.

Nas variáveis fisiológicas, modelamos a PAS, a PAD e a atividade, tanto em separado quanto em conjunto. A variável de PAS, por exemplo, é importante para definir o que é anormal de uma forma não tão rígida; mesmo que uma pessoa sinta-se bem com uma pressão alta, ela é considerada hipertensa (pessoas em casa com média da PAS maior que  $135mmHg$ ).

Se utilizarmos o caso da pessoa dormindo, quando sua variação de PAS fica entre 0 e  $-10mmHg$ , ela é considerada normal (figura 2). Valores acima são considerados

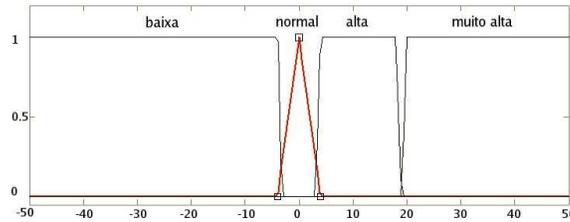


Figura 3. Variação da PAS em relação a média quando está repousando (variação da PAS em *mmHg* versus grau de pertinência)

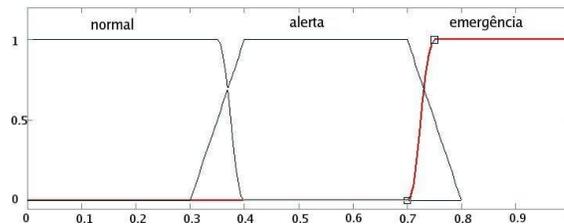


Figura 4. Situação do paciente gerada pelo componente Decisão

altos e valores abaixo são considerados alto negativos (*altaNeg*).

A figura 3 mostra a recomendação médica sobre a variação da PAS quando a pessoa está em repouso. Nesse caso, a variação da PAS e da PAD deve estar em torno da média, isto é, não deveriam ocorrer aumentos ou diminuições dos valores pressóricos. Quanto a situação do paciente, que é o resultado produzido pelo módulo, podemos ter: normal, alerta ou emergência (figura 4).

Quanto a variável “atividade” (figura 5), ela possui uma singularidade. A ordem dos estados nesta variável (suas funções de pertinência) está relacionada com o aumento da variação da PAS: dormindo (1), repousando (2), comendo (3), caminhando (4) e atividade doméstica (5). Esses estados representam situações bem específicas à assistência domiciliar, o que não exclui outros, como telefonando ou tomando remédio. No entanto, a variável “atividade” foi modelada como uma variável *fuzzy* porque é difícil afirmar com certeza sobre cada um desses estados rotineiros.

Além disso, existe uma transição de um estado para outro que pode estar em curso, por exemplo, a pessoa em repouso, mas quase dormindo. A “atividade” poderia assumir um valor percentual para o “repouso” e outro, para “dormindo”. Por exemplo: 1,7 (70% em repouso e 30% dormindo).

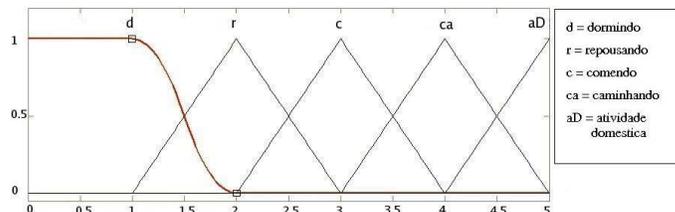


Figura 5. Atividade da pessoa em casa (estado da pessoa de 1 a 5 versus grau de pertinência)

Esse fato é importante quando numa regra combinamos a variável de variação da PAS enquanto dormindo com a atividade. Suponhamos a existência das três regras:

1. se a pessoa está dormindo e a variação da PAS e da PAD é normal enquanto dormindo então a situação é “normal”
2. se a pessoa está repousando e a variação da PAS e da PAD é normal enquanto em repouso então a situação é “normal”
3. se a pessoa está em repouso e a variação da PAS e da PAD é baixa enquanto em repouso então a situação é de “alerta”

Se a pessoa está com a pressão baixa (variação da PAS e da PAD é alta negativa) e a aplicação recebe a informação de que a pessoa está em repouso (ou com maior probabilidade de que está em repouso), a regra que mais se encaixa é a regra 3. Isto é, a máquina de raciocínio infere que a pessoa está em “alerta”. No entanto, o sistema pode resultar numa situação “normal”, se existe uma pequena probabilidade que a pessoa está dormindo (regra 1).

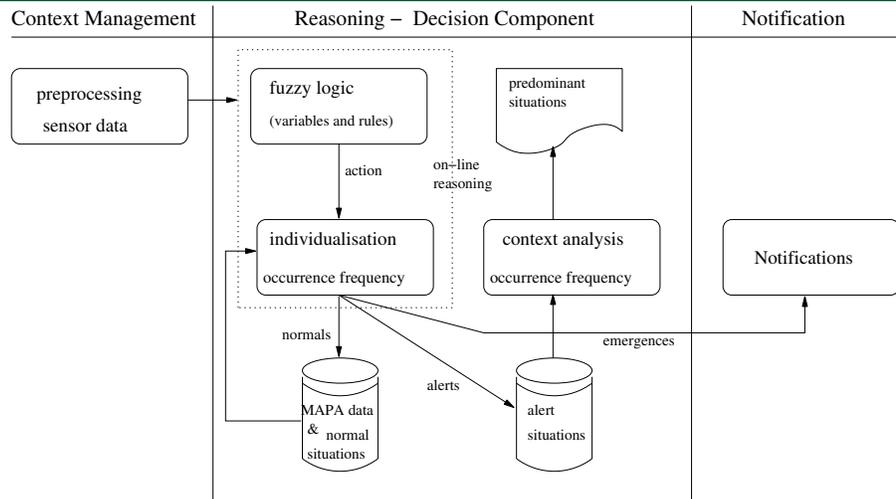
Como vimos, existe uma incerteza em definir qual o estado da pessoa, que é amenizada com a combinação de várias fontes de dados e com o uso de probabilidade. O valor da variável atividade, por exemplo, assume com total certeza que está num determinado estado somente quando lhe forem atribuídos valores inteiros (de 1 a 5 na figura 5). Essa situação representa bem a questão relacionada a incerteza em ambientes pervasivos. Junta-se a isso, que em determinados momentos temos informações mais confiáveis para caracterizar uma situação.

A pergunta inicial é como esse valor de 1 a 5 é atribuído a variável “atividade”? Nesse sentido, nós podemos incorporar o conceito de qualidade do contexto [13]: ao sensor fica associado um valor de qualidade da informação, atribuído segundo critérios que dizem respeito a confiabilidade do dado que está sendo obtido. Se combinamos resultados de diversas fontes de contexto (uso da agregação ou fusão de dados), podemos utilizar a qualidade do contexto como um peso para cada sensor. Dessa forma, um valor não inteiro, mas mais próximo da realidade será atribuído a variável “atividade”. Exemplos de teorias que não atribuem completa certeza às variáveis são as de Dempster-Shafer e de Bayes.

Caso queiramos inferir sobre a situação de dormindo e tivermos um sensor combinado de acelerômetro com dados fisiológicos do paciente teremos então uma maior certeza da resposta. Como já mencionado, esse trabalho não objetiva explorar técnicas de reconhecimento de atividade; assumimos que a informação de atividade é fornecida para o nosso sistema.

#### 4.4. Modelo do Componente de Decisão

Esta subseção apresenta o modelo do componente Decisão do módulo de Raciocínio (figura 6). Os dados brutos de sensores passam pelo pré-processamento, realizado pelo módulo de Gerenciamento de Contexto. Após isso, o raciocínio *on-line* (dentro do retângulo pontilhado) produz o resultado para a situação do paciente, isto é, normal, alerta ou emergência, constituído de duas etapas. Na primeira etapa o bloco *fuzzy* aplica as regras conforme o conhecimento médico e considerando as variáveis ambientais, fisiológicas e comportamentais. Esse resultado será utilizado na segunda etapa, quando o bloco de individualização analisa se os valores fisiológicos ocorrem com frequência.



**Figura 6. Modelo do componente Decisão**

Um novo valor para a situação do paciente é gerado pelo bloco de individualização. Nesse momento são efetuadas as seguintes ações: se a situação é normal, então os dados de entrada são armazenados no histórico do paciente; se a situação for de alerta, então os dados são armazenados numa base com somente esse tipo de situação; se a situação for de emergência, então o bloco de notificação é acionado.

Os dados de histórico, constituídos inicialmente pelos dados de MAPA, são discretizados e, em seguida, aplicado um algoritmo de regras de associação que produz uma lista com os dados fisiológicos mais frequentes. É com esta lista que o bloco chamado de “individualização” faz a verificação para determinar se o dado é frequente ou não. Se concluir que é frequente, uma situação de emergência será reduzida para um alerta, e um alerta será normal. Para determinarmos o conjunto de itens frequentes, optamos pelo algoritmo APRIORI [4], que faz a extração das regras de associação.

A atuação do sistema no ambiente também é uma possibilidade de ação. Sabemos que as situações de alerta são armazenadas e descritas por informações como horário e atividade do paciente. Então, uma técnica de mineração de dados pode atuar a fim de capturar de uma melhor forma quais as situações que predominam, isto é, que têm maior ocorrência, ou mais relevantes. Essa tarefa é realizada no bloco de Análise de Contexto. De forma similar ao bloco de individualização, essa tarefa também é desempenhada pelo algoritmo APRIORI, só que agora atuando sobre todas as variáveis de entrada do sistema. De posse do resultado, as regras existentes podem ser revistas ou novas regras serem elaboradas para atender a essas situações estressantes ou indesejáveis. Por exemplo, uma fotografia de família poderia ser projetada numa TV ou num porta-retratos digital, no final da tarde, quando o paciente está em repouso e não têm outras pessoas na casa.

## 5. Protótipo do Componente de Decisão

Encontra-se em desenvolvimento um protótipo do componente de Decisão para validação de conceitos. O protótipo funciona com a entrada de dados simulados de pacientes e também com dados reais de MAPA. Ele aplica as regras *Fuzzy* e decide se a situação é normal, alerta ou emergência. Em seguida, o bloco de individualização determina se os dados são frequentes.

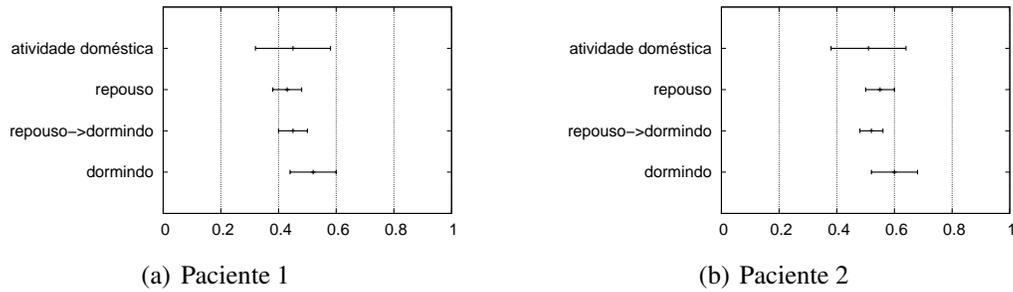


Figura 7. Média dos resultados do bloco *fuzzy* para cada atividade do paciente

O bloco de Lógica *Fuzzy* foi desenvolvido no *Fuzzy Logic Toolbox* do MATLAB, e incorporado ao ambiente Simulink. O método de inferência é o Mamdani e o método de defuzificação é o centróide. Em paralelo, é executado o algoritmo APRIORI, da ferramenta WEKA [20], para extração de regras. O APRIORI atua em dois casos, na avaliação da frequência de ocorrência (individualização do paciente) e sobre as situações de alerta (para analisar a influência do ambiente e do comportamento). No caso da individualização, após os dados serem discretizados, os resultados em forma de sentenças condicionais são recuperados pelo simulador por intermédio de uma função do MATLAB. Já no caso da análise das situações de alerta, o algoritmo APRIORI executa isoladamente utilizando a base de dados de alertas.

Um teste importante é verificar o resultado do bloco *fuzzy* após submeter dados reais de MAPA. Mesmo em hipertensos, o sistema não deve necessariamente indicar a predominância de situações de emergência. As variáveis de entrada na simulação foram a PAS e a atividade. Os dados foram separados em vigília (v) e sono (s). A atividade foi avaliada nos modos de atividade doméstica (5), repouso (2), repouso para dormindo (1,5) e dormindo (1). O valor entre parênteses foi atribuído à variável atividade. Somente na atividade de dormindo utilizamos os dados do período de sono, portanto, nas atividades domésticas, repouso e repouso para dormindo utilizamos dados de vigília.

Para o teste foram usados dados de dois pacientes hipertensos (tabela 2) nas 4 atividades. A média do resultado *fuzzy* é mostrada na figura 7, com intervalo de confiança de 95%. Sabendo que a região de pertinência máxima de alerta está na faixa de 0,4 a 0,7, vemos que os resultados predominam nesta situação. No entanto, a atividade doméstica, por tolerar uma variação maior de pressão, possui valores de média próximos da situação normal.

Tabela 2. Dados de MAPA da PAS dos pacientes

	idade	média (v)	desv.pad. (v)	média (s)	desv.pad. (s)	instâncias
Paciente 1	57	135	8,8	126	11,2	80
Paciente 2	80	161	15,6	144	19,6	79

Assumindo, para cada paciente, que sua atividade permanece constante durante todo o período da vigília ou do sono, os resultados médios não têm diferença significativa entre os cenários, mesmo com um conjunto de dados específicos para o período de sono (com média e desvio padrão menores que a da vigília). À primeira vista, o sistema consegue manter coerência na identificação da situação nos diferentes cenários. No entanto, mais testes são necessários e com mais pacientes.

Cabe ressaltar que os resultados obtidos não foram passados para o bloco de individualização, o que provavelmente resultará numa redução de situação, como descrito na subseção 4.4. Ainda na individualização, ao aplicar o algoritmo APRIORI, uma regra pode envolver mais de uma variável. Com essa correlação é possível detectar situações normais em que há um aumento em uma variável e a diminuição em uma outra, como nos mecanismos compensatórios do corpo humano.

## 6. Novas Perspectivas e Desafios à Assistência Domiciliar Telemonitorada

Em uma perspectiva de médio prazo, nós vislumbramos sensores com autonomia para tomarem decisões. Eles estarão espalhados pelo ambiente e pelo corpo da pessoa. Essas decisões envolvem desde a extração de características relevantes dos dados brutos até o lançamento de alarmes avisando de um agravamento de estado. Os sensores poderão também colaborar entre si, compartilhando decisões e entrando em consenso, por exemplo, sobre qual horário atuarão ou quando serão desativados. Para tanto, são necessárias novas arquiteturas que permitam a atuação mais próxima possível do sensor, como as *Wireless Sensor and Actor Networks* (WSAN) [5]. O conhecimento do domínio do problema, isto é, o conhecimento médico, é essencial nessa tomada de decisão.

A interoperabilidade entre biosensores, atuadores e agregadores de dados de sensores será um tópico de pesquisa permanente. Os sensores de fabricantes diferentes entrarão no ambiente e serão reconhecidos pelo sistema pervasivo. Mesmo que tenham a mesma funcionalidade, os sensores terão acurácias específicas, atuando em contextos diferentes. Assim, o sistema deve saber de onde veio a informação, como e quando. Todas essas informações devem ser consideradas na interpretação do contexto.

Os desafios de pesquisa na área de ubiqüidade vão além das preocupações com as restrições da computação móvel. Em sistemas que envolvem vidas humanas, uma característica indispensável é a fidedignidade. Dentre outras questões, o sistema não pode prejudicar ou afetar o paciente, por exemplo, fazendo algo errado como deixar de gerar um alarme. Para garantir corretude, o papel essencial das técnicas de tolerância a falhas presume que elas ponderem as variações de dados fisiológicos. Por exemplo, qual o mínimo de confiança em afirmar que houve um desmaio e não, simplesmente, que a pessoa deitou num sofá, considerando falhas nos sensores?

Outro desafio a longo prazo, é o tratamento do fluxo e persistência de dados, os quais exigem mecanismos que preservem sua privacidade. Novas técnicas de autenticação, criptografia e políticas de acesso devem prover segurança no processo de comunicação dos dados aos envolvidos no tratamento de saúde. Além disso, duas iniciativas contribuirão na obtenção da escalabilidade do sistema para atender grande parte da população: o tratamento local dos dados gerados na residência e a interoperação com os sistemas externos, conforme foi contemplado no arcabouço proposto (seção 3). Como consequência, poderá ocorrer uma transparência no local do processamento.

Por fim, acreditamos que a investigação de mecanismos de raciocínio integrados aos sistemas ubíquos será essencial para o desenvolvimento tecnológico de qualidade. Na assistência domiciliar, o raciocínio com o suporte de técnicas de aprendizagem e de fusão de dados construirão perfis dinâmicos de sinais vitais associados ao comportamento. Esse tópico de pesquisa buscará soluções para um dos principais requisitos em sistemas de tratamento de saúde, a individualização do paciente.

## 7. Conclusões e Trabalhos Futuros

A aplicação da computação pervasiva no domínio da assistência domiciliar telemonitorada é um complemento ao tratamento tradicional. Essa união pode auxiliar na detecção de situações de alerta, evitando que se recorra a um atendimento somente quando a situação já é crítica. Da mesma forma, a notificação de emergências é outro recurso importante, principalmente no caso de idosos. Quanto ao aspecto médico, pode-se aperfeiçoar a forma de interpretação dos dados, com relatórios contendo informações mais detalhadas do dia a dia do paciente.

O arcabouço apresentado contribui para uma visão holística do tratamento de saúde, priorizando a fusão dos dados fisiológicos, comportamentais e de ambiente. Com isso, os alarmes tornam-se mais confiáveis, justamente por estarmos cientes dessas novas classes de variáveis. Essas são contribuições importantes para avançar o conhecimento no âmbito do 5º grande desafio da SBC. Da mesma forma, a proposta é original por definir um arcabouço de suporte ao desenvolvimento de aplicações de assistência domiciliar pervasivas para monitoramento de pacientes. O raciocínio proposto sobre os dados complementa a atividade de monitoramento, considerando a individualização, a relaxação dos limites de exames e a influência do comportamento e do ambiente.

Além de refinar e desenvolver os aspectos relevantes do arcabouço, pretendemos executar experimentos para uma grande quantidade de pacientes para validar nossas conclusões iniciais. Além disso, incorporaremos as variáveis PAD, FC e temperatura do ambiente no protótipo sendo desenvolvido. Num contexto de um projeto interdisciplinar [9], envolvendo equipes médicas da UERJ e UFF, faremos um estudo de campo utilizando sensores, os quais servirão de plataforma para fornecer dados *on-line* via rede sem fio ao sistema de monitoramento.

O telemonitoramento contínuo da saúde reúne aplicações como, detecção de quedas e de situações críticas, avaliação do sono, acompanhamento de dietas e de exercícios, dentre outros, que exigem uma computação onivalente [3] - ubiquidade associada à segurança, fidedignidade e evolução de sistemas computacionais. Devido ao fato que somente recentemente verificamos a potencialidade dessas aplicações, novas arquiteturas devem ser propostas para o projeto e o desenvolvimento de qualidade.

## Agradecimentos

Os autores agradecem aos apoios recebidos da FAPERJ e do CNPq para a realização desta pesquisa.

## Referências

- [1] Instituto Brasileiro de Geografia e Estatística, 2002. <http://www.ibge.gov.br/home/presidencia/noticias/25072002pidoso.shtm>.
- [2] Instituto Brasileiro de Geografia e Estatística - Pesquisa Nacional por Amostra de Domicílios, 2004. <http://www.ibge.gov.br>.
- [3] Grandes Desafios da Pesquisa em Computação no Brasil 2006–2016, 2006. <http://www.sbc.org.br>.
- [4] Rakesh Agrawal e Ramakrishnan Srikant. Fast algorithms for mining association rules in large databases. In *20th International Conference on Very Large Data Bases*, pp. 487–499, San Francisco, CA, EUA, 1994.

- [5] I. Akyildiz e I. Kasimoglu. Wireless sensor and actor networks: research challenges. *Ad Hoc Networks*, 2(4):351–367, 2004.
- [6] T. S. Barger, D. E. Brown e M. Alwan. Health-status monitoring through analysis of behavioral patterns. *IEEE Transactions on Systems, Man and Cybernetics*, pp. 22–27, 2005.
- [7] T. Broens, A. van Halteren, M. van Sinderen e K. Wac. Towards an application framework for context-aware m-health applications. *International Journal of Internet Protocol Technology*, 2(2):109–116, 2007.
- [8] Leonardo Cardoso, Alexandre Sztajnberg e Orlando Loques. Self-adaptive applications using ADL contracts. In *2nd IEEE International Workshop in Self-Managed Networks, Systems, and Services*, volume 3996, pp. 87–101, Dublin, Irlanda, 2006.
- [9] Orlando Loques (coordenador). Aplicando técnicas de computação ubíqua e pervasiva a aplicações de tele-saúde, Dezembro 2007. Projeto do Programa PrioridadeRio, FAPERJ.
- [10] Sociedade Brasileira de Cardiologia. IV Diretriz para uso da Monitorização Ambulatorial da Pressão Arterial. II Diretriz para uso da Monitorização Residencial da Pressão Arterial. *Arquivos Brasileiros de Cardiologia*, 85(Supl II):1–18, 2005.
- [11] Michael Marschollek et al. Multimodal home monitoring of elderly people—first results from the lass study. In *21st International Conference on Advanced Information Networking and Applications Workshops*, pp. 815–819, Washington, DC, EUA, 2007.
- [12] M. Hebert, B. Korabek e R. Scott. Moving research into practice: a decision framework for integrating home telehealth into chronic illness care. *International Journal of Medical Informatics*, pp. 786–794, 2006.
- [13] Markus C. Huebscher e Julie A. McCann. Adaptive middleware for context-aware applications in smart-homes. In *2nd Workshop on Middleware for Pervasive and Ad-Hoc Computing*, pp. 111–116, New York, NY, EUA, 2004.
- [14] Décio Mion Jr., Wille Oigman e Fernando Nobre. *MAPA: Monitorização Ambulatorial da Pressão Arterial*. Atheneu RJ, 3a. edição, 2004.
- [15] Antonio Claudio Lucas Nobrega. The subacute effects of exercise: concept, characteristics, and clinical implications. *Exercise and Sport Sciences Reviews*, 33(2):84–87, 2005.
- [16] W. Pentney, A.-M. Popescu, S. Wang, H. Kautz e M. Philipose. Sensor-based understanding of daily life via large-scale use of common sense. In *Proceedings of American Association for Artificial Intelligence*, Boston, EUA, 2006.
- [17] T.J. Ross. *Fuzzy Logic with Engineering Applications*. McGraw-Hill, New York, 1995.
- [18] C. Scanail, S. Carew, P. Barralon, N. Noury, D. Lyons e G. Lyons. A review of approaches to mobility telemonitoring of the elderly in their living environment. *Annals Biomedical Engineering*, 34(4):547–563, 2006.
- [19] V. Vieira, P. Tedesco, A. Salgado e P. Brézillon. Investigating the Specifics of Contextual Elements Management: The CEManTIKA Approach. In B. Kokinov et alli, editor, *6th International and Interdisciplinary Conference on Modeling and Using Context*, volume 4635, pp. 493–506, Roskilde, Dinamarca, Agosto 2007.
- [20] Ian H. Witten e Eibe Frank. *Data Mining: Practical Machine Learning Tools and Techniques*. Morgan Kaufmann, San Francisco, CA, EUA, 2a. edição, Junho 2005.
- [21] B. Ziebart, D. Roth, R. Campbell e A. Dey. Learning automation policies for pervasive computing environments. *2nd Conference on Autonomic Computing*, pp. 193–203, Junho 2005.