



Programa Interdisciplinar de Pós-Graduação em  
**Computação Aplicada**  
Mestrado Acadêmico

Fábio Pittoli

**ChronicPrediction: Um Modelo Para Prognóstico Ubíquo de Fatores  
de Risco de Doenças Crônicas Não Transmissíveis**

São Leopoldo, 2015



Fábio Pittoli

CHRONICPREDICTION: UM MODELO PARA PROGNÓSTICO UBÍQUO DE FATORES  
DE RISCO DE DOENÇAS CRÔNICAS NÃO TRANSMISSÍVEIS

Dissertação apresentada como requisito parcial  
para a obtenção do título de Mestre pelo  
Programa de Pós-Graduação em Computação  
Aplicada da Universidade do Vale do Rio dos  
Sinos — UNISINOS

Orientador:  
Prof. Dr. Jorge Luis Victória Barbosa

São Leopoldo  
2015

P691c

Pittoli, Fábio.

ChronicPrediction : um modelo para prognóstico ubíquo de fatores de risco de doenças crônicas não transmissíveis / Fábio Pittoli. – 2015.

146 f. : il. ; 30 cm.

Dissertação (mestrado) – Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Computação Aplicada, 2015.

"Orientador: Prof. Dr. Jorge Luis Victória Barbosa."

1. Computação ubíqua. 2. Computação móvel. 3. Teoria bayesiana de decisão estatística. 4. Doenças crônicas. 5. Informática na medicina. I. Título.

CDU 004.9

Dados Internacionais de Catalogação na Publicação (CIP)  
(Bibliotecário: Flávio Nunes – CRB 10/1298)

Fábio Pittoli

ChronicPrediction: Um Modelo Para Prognóstico Ubíquo de Fatores de Risco de Doenças Crônicas Não Transmissíveis

Dissertação apresentada à Universidade do Vale do Rio dos Sinos – Unisinos, como requisito parcial para obtenção do título de Mestre em Computação Aplicada.

Aprovado em 27 de março de 2015

BANCA EXAMINADORA

---

Prof. Dr. João Carlos Gluz – UNISINOS

---

Prof. Dr. Leandro Krug Wives – UFRGS

Prof. Dr. Jorge Luis Victória Barbosa (Orientador)

São Leopoldo,

Prof. Dr. Cristiano André da Costa  
Coordenador PPG em Computação Aplicada



## **AGRADECIMENTOS**

Obrigado, Gabriela por todo apoio, paciência e carinho a mim dedicados ao longo de todo o mestrado. Aos meus pais, Dona Nadir e Seu Arnaldo, obrigado por todo o apoio e incentivo que sempre me deram. Agradeço em especial ao professor Jorge Barbosa por toda ajuda e apoio dados ao longo desses dois anos de convivência. Gostaria também de agradecer aos amigos os quais já conhecia e que pude reencontrar no mestrado e também aos novos amigos que fiz durante esse período. Gostaria também de agradecer a CAPES pelo apoio financeiro concedido através do Programa de Suporte à Pós-Graduação de Instituições de Ensino Particulares (PROSUP).



*“As pessoas pensam que ter foco significa dizer sim para aquilo que você está focando, mas não é assim. Significa dizer não a outra centena de ideias boas que existem”.*  
(Steve Jobs)



## RESUMO

A computação ubíqua quando na forma de sistemas ubíquos e utilizados no suporte e cuidado de Doenças Crônicas priorizam o monitoramento do paciente e a geração de diversos tipos de alerta, porém, o suporte à tomada de decisões por parte dos sistemas ubíquos existentes é ainda pouco utilizado em sistemas específicos para o gerenciamento e controle de Doenças Crônicas Não Transmissíveis. Como o cuidado de doença crônica deve ser feito de forma contínua, torna-se importante para o paciente ter um conhecimento prévio sobre o andamento do seu tratamento e se as ações por ele feitas no dia a dia estão lhe ajudando com o tratamento ou não. Como mecanismo de predição, uma das principais técnicas utilizadas atualmente são as Redes Bayesianas. Sendo assim, esta dissertação propõe um modelo computacional ubíquo de prognóstico de fatores de risco de Doenças Crônicas Não Transmissíveis, denominado ChronicPrediction. O modelo ChronicPrediction utiliza Redes Bayesianas criadas a partir do mapeamento de relações de causalidade existentes entre cada um dos fatores de risco da DCNT a qual se deseja observar. Essas relações são definidas a partir de opinião de especialistas ou geradas automaticamente através de dados históricos e com base em dados fornecidos pelos próprios pacientes sobre seus hábitos alimentares diários, rotina de exercícios físicos e a medição de suas taxas. São discutidas também características pertencentes a trabalhos relacionados, além de descrever o modelo em detalhes e apresentar os aspectos considerados no desenvolvimento e avaliação por meio de um protótipo desenvolvido. O processo de avaliação se apresenta na forma de experimentos descritos através de cenários, os quais possuem como objetivo avaliar as hipóteses relacionadas a cada um deles. O ponto inicial para a formulação de cada uma das hipóteses é o fato de que se tem uma ideia de uma causa e o efeito relacionado a ela. Cada um dos cenários visa descrever situações comuns que possam ocorrer durante o dia a dia de pacientes (causas e efeitos) com algum tipo de Doença Crônica Não Transmissível. Além disso, a diversidade entre os cenários torna-se importante para aperfeiçoar a abrangência da avaliação do modelo. Ao efetuar as avaliações conclui-se que o modelo ChronicPrediction amplia as funcionalidades do Modelo UDuctor e do assistente pessoal ChronicDuctor, passando a oferecer suporte a ao monitoramento de múltiplas DCNT simultaneamente, fornecendo *feedbacks* e recomendações ao paciente com o intuito de ajudá-lo a acompanhar seu tratamento de forma contínua e podendo readequá-lo de forma a promover seu bem-estar e aprimorando sua qualidade de vida.

**Palavras-chave:** Computação Ubíqua. Computação Móvel. Teoria bayesiana de decisão estatística. Doenças Crônicas. Informática na medicina.



## ABSTRACT

The ubiquitous computing in the form of ubiquitous systems and used in the support and care of Chronic Diseases prioritize the patient monitoring and the generation of different alert types, however, the support decision making by the existing ubiquitous systems is still little used on specific systems for the management and control of Chronic Non-Communicable Diseases. As the care of chronic disease should be done continuously, becomes important for the patient has a prior knowledge about the progress of your treatment and if the actions taken by him in his daily life are helping you with treatment or not. As a predictive mechanism one of the main techniques used nowadays are the Bayesian Networks. Thus, this thesis proposes an ubiquitous computing prognostic model of risk factors of Chronic Noncommunicable Diseases, called ChronicPrediction. The ChronicPrediction model uses Bayesian Networks created from mapping of existing causal relationships between each of the risk factors of NCDs which you wish to observe. These relationships are defined from expert opinion or automatically generated by historical data and based on data provided by patients themselves about their daily eating habits, exercise routine and the measuring of their rates. Are also discussed characteristics belonging to related work, addition to describing the model in detail and present the aspects considered in developing and evaluating through a prototype. The evaluation process is presented in the form of experiments described through scenarios, which have to evaluate hypotheses related to each. The starting point for the formulation of each of the hypotheses is the fact that we have an idea of a cause and effect related to it. Each scenario aims to describe common situations that may occur during the daily lives of patients (causes and effects) with some kind of Chronic Non-Communicable Disease. Furthermore, the diversity between the scenarios is important to improve the coverage of the model evaluation. Making the evaluations it was concluded that the ChronicPrediction model expands the functionality of UDuctor model and the ChronicDuctor personal assistant, offering support to the monitoring of multiple NCDs simultaneously, providing *feedbacks* and recommendations to the patients in order to help them to monitor their treatment continuously, to modify them in order to promote their well-being and improving their quality of life.

**Keywords:** Ubiquitous Computing. Mobile Computing. Bayesian statistical decision theory. Chronic Diseases. Informatics in Medicine.



## LISTA DE FIGURAS

Figura 1:	Exemplo de uma RB . . . . .	35
Figura 2:	RB contendo as tabelas de probabilidades condicionais . . . . .	36
Figura 3:	Modelo CICC . . . . .	45
Figura 4:	Exemplo de modelo de entidades do Continuum . . . . .	48
Figura 5:	Organização dos elementos do UDUCTOR . . . . .	48
Figura 6:	Composição do middleware ConnDUCTOR . . . . .	49
Figura 7:	Componente de Módulos Executáveis - arquitetura . . . . .	50
Figura 8:	Componente de Contexto - arquitetura . . . . .	51
Figura 9:	Processo de extração de pontos importantes a partir de logs mobile . . . . .	54
Figura 10:	Modelo de predição de localização com uma Rede Bayesiana Dinâmica . . . . .	55
Figura 11:	Rede Bayesiana Dinâmica com dependências entre as diferentes fatias de tempo . . . . .	56
Figura 12:	Arquitetura do sistema U-Base . . . . .	58
Figura 13:	RB para predição da diabetes tipo-2 . . . . .	60
Figura 14:	Rede de predição para Doença Pulmonar Obstrutiva Crônica . . . . .	61
Figura 15:	Uma aplicação que utiliza o modelo de diagnóstico proposto . . . . .	63
Figura 16:	Arquitetura do módulo executável de predição dentro do modelo UDUCTOR . . . . .	69
Figura 17:	Modelo ontológico de recursos . . . . .	70
Figura 18:	Exemplo de uma relação de causa e efeito em uma RB . . . . .	72
Figura 19:	Exemplo de um modelo de RB . . . . .	73
Figura 20:	Visão geral da arquitetura do modelo ChronicPrediction . . . . .	74
Figura 21:	Arquitetura do modelo ChronicPrediction expandida em módulos . . . . .	75
Figura 22:	ChronicDUCTOR - Modelo Ontológico de Recursos . . . . .	76
Figura 23:	ChronicDUCTOR - Modelo Ontológico de Planos . . . . .	78
Figura 24:	Modelo Ontológico ConnDUCTOR . . . . .	80
Figura 25:	Rede Bayesiana para Doença Arterial Coronariana . . . . .	89
Figura 26:	Plano de Cuidados para os cenários de avaliação . . . . .	93
Figura 27:	Perfil do Paciente 1 no ChronicDUCTOR com as informações preenchidas . . . . .	95
Figura 28:	Comportamento da RB com os dados do perfil do Paciente 1 . . . . .	96
Figura 29:	Atividades do Plano de Cuidados . . . . .	97
Figura 30:	Atividade física . . . . .	97
Figura 31:	Recomendação após a atividade física realizada . . . . .	97
Figura 32:	RB de DAC com a informação de atividade física para o Paciente 1 . . . . .	98
Figura 33:	Peso informado pelo Paciente 1 . . . . .	99
Figura 34:	Recomendação após as informações de peso e atividade física . . . . .	99
Figura 35:	RB de DAC com a informação de atividade física e de peso do Paciente 1 . . . . .	99
Figura 36:	Comportamento da RB com os dados do perfil do Paciente 2 . . . . .	100
Figura 37:	Pressão arterial do Paciente 2 . . . . .	102
Figura 38:	Recomendação efetuada a partir da pressão arterial . . . . .	102
Figura 39:	Novos níveis de pressão arterial do Paciente 2 . . . . .	102
Figura 40:	<i>Feedback</i> dado pelo protótipo . . . . .	102
Figura 41:	RB de DAC sem o consumo de tabaco e com os novos níveis de pressão arterial do Paciente 2 . . . . .	103
Figura 42:	Comportamento da RB com os dados do perfil do Paciente 3 . . . . .	104

Figura 43:	RB após o Paciente 3 passar a ser fumante . . . . .	104
Figura 44:	Perfil do Paciente 3 cadastrado no protótipo . . . . .	105
Figura 45:	Peso informado pelo Paciente 3 . . . . .	105
Figura 46:	Recomendação após as informações de peso e consumo de cigarro . . . . .	105
Figura 47:	Comportamento da RB contendo os dados do perfil do Paciente 4 . . . . .	107
Figura 48:	Perfil do Paciente 4 cadastrado . . . . .	108
Figura 49:	Taxa de glicose informada pelo Paciente 4 . . . . .	108
Figura 50:	Recomendação após o novo valor para glicose . . . . .	108
Figura 51:	Comportamento da RB após a alteração no nível de glicose do Paciente 4 . . . . .	109
Figura 52:	Taxa de colesterol informada pelo Paciente 4 . . . . .	110
Figura 53:	Recomendação após a informação de colesterol . . . . .	110
Figura 54:	RB com os novos valores para as taxas de colesterol e glicose . . . . .	110
Figura 55:	RB para diabetes treinada com o conjunto de dados Pima Indians Diabetes Data Set . . . . .	111
Figura 56:	Informações do perfil do Paciente 5 . . . . .	113
Figura 57:	Informações sobre pressão arterial do Paciente 5 . . . . .	113
Figura 58:	<i>Feedback</i> p/ hipertensão em paciente diabético . . . . .	113
Figura 59:	<i>Feedback</i> p/ hipertensão em paciente com DAC . . . . .	113
Figura 60:	RB para diabetes com as informações sobre pressão arterial . . . . .	114
Figura 61:	RB para DAC com as informações sobre pressão arterial . . . . .	114
Figura 62:	Protótipo com a informação de Peso preenchida . . . . .	115
Figura 63:	<i>Feedback</i> p/ peso em paciente diabético . . . . .	115
Figura 64:	<i>Feedback</i> p/ peso em paciente com DAC . . . . .	115
Figura 65:	RB para diabetes com as informações sobre peso . . . . .	116
Figura 66:	RB para DAC com as informações sobre peso . . . . .	116

## LISTA DE TABELAS

Tabela 1:	Probabilidades condicionais do problema . . . . .	35
Tabela 2:	Resultados obtidos . . . . .	38
Tabela 3:	Comparativo entre os trabalhos relacionados . . . . .	65
Tabela 4:	Fatores de risco para DAC e seus respectivos intervalos de valores . . . . .	89
Tabela 5:	Mapeamento entre variáveis da base de dados e fatores de risco . . . . .	92
Tabela 6:	Atividades do Plano de Cuidados relativas aos fatores de risco modificáveis .	94
Tabela 7:	Fatores de risco não-modificáveis e demais informações . . . . .	94
Tabela 8:	Dados do Paciente 1 . . . . .	95
Tabela 9:	Dados do Paciente 2 . . . . .	100
Tabela 10:	Dados do Paciente 3 . . . . .	103
Tabela 11:	Dados do Paciente 4 . . . . .	106
Tabela 12:	Dados do Paciente 5 . . . . .	111
Tabela 13:	Comparativo dos modelos estudados com o ChronicPrediction . . . . .	124



## LISTA DE SIGLAS

API	Application Programming Interface
CCM	Chronic Care Model
CICC	Cuidados Inovadores para Condições Crônicas
DCNT	Doenças Crônicas Não Transmissíveis
GeNIe	Graphical Network Interface
JSON	JavaScript Object Notation
NL	Nodo Local
NP	Nodo Pessoal
OMS	Organização Mundial de Saúde
PC	Computador Pessoal
RB	Rede Bayesiana
RFID	Radio-Frequency IDentification
REST	Representational State Transfer
SMILE	Structural Modeling, Inference, and Learning Engine
SQL	Structured Query Language
UML	Unified Modeling Language



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>21</b>
1.1	Motivação	21
1.2	Definição do Problema e Questão de Pesquisa	23
1.3	Objetivos	25
1.4	Metodologia	26
1.5	Organização do Texto	26
<b>2</b>	<b>U-HEALTH E DOENÇAS CRÔNICAS</b>	<b>29</b>
2.1	Computação Ubíqua	29
2.2	Sensibilidade ao Contexto	31
2.3	Histórico de Contextos	32
2.4	Redes Bayesianas	33
2.4.1	Tabelas de Probabilidades Condicionais	37
2.4.2	Inferência em Redes Bayesianas	37
2.5	Saúde Ubíqua – u-Health	39
2.5.1	Monitoramento de Pacientes	39
2.5.2	Gerenciamento de Rotinas Hospitalares	40
2.5.3	Suporte ao Bem-Estar	41
2.6	Modelos de Cuidados para Doenças Crônicas	42
2.6.1	Modelo CCM – <i>Chronic Care Model</i>	43
2.6.2	Modelo CICC – Cuidados Inovadores para Condições Crônicas	44
2.6.3	Considerações entre as características dos modelos	45
2.7	Fatores de Risco	45
2.8	Modelo UDUCTOR	47
2.8.1	Organização dos Elementos	47
2.8.2	Middleware ConnDuctor	48
2.8.3	ChronicDuctor	50
2.9	Considerações sobre o capítulo	51
<b>3</b>	<b>TRABALHOS RELACIONADOS</b>	<b>53</b>
3.1	Método de análise de <i>logs</i> móveis utilizando um modelo modular de RB	53
3.2	Predição de contextos em ambientes ubíquos utilizando RB Dinâmica	54
3.3	Predição de localização em ambientes fechados utilizando RBs	55
3.4	Integração de RB em um sistema ubíquo de apoio a tomada de decisões para oferecer predição de contexto	57
3.5	Utilizando RBs para a predição de diabetes tipo-2	59
3.6	Predição de Doença Pulmonar Obstrutiva Crônica em pacientes com asma utilizando registros médicos eletrônicos	60
3.7	Ordenação de atributos em RBs para a predição de síndrome metabólica	62
3.8	Comparativo entre os trabalhos relacionados	63
3.9	Considerações sobre o capítulo	68
<b>4</b>	<b>MODELO CHRONICPREDICTION</b>	<b>69</b>
4.1	O ChronicPrediction e o Modelo UDUCTOR	69
4.2	Arquitetura do ChronicPrediction	69
4.3	Modularização dos componentes do modelo ChronicPrediction	75
4.3.1	Etapa de aquisição de contexto	76

4.3.2	Etapa de seleção e processamento dos dados . . . . .	80
4.3.3	Etapa de inferência e predição . . . . .	82
<b>4.4</b>	<b>Considerações finais sobre o capítulo . . . . .</b>	<b>83</b>
<b>5</b>	<b>AVALIAÇÃO DO MODELO . . . . .</b>	<b>85</b>
<b>5.1</b>	<b>Aspectos de Implementação . . . . .</b>	<b>85</b>
<b>5.2</b>	<b>Metodologia de Avaliação . . . . .</b>	<b>86</b>
<b>5.3</b>	<b>Primeira Avaliação . . . . .</b>	<b>87</b>
5.3.1	Dados de Pacientes Portadores de Doenças Cardiovasculares . . . . .	87
5.3.2	Local do Estudo e Descrição dos Dados . . . . .	90
5.3.3	Seleção das Variáveis para Treinamento da Rede Bayesiana . . . . .	92
5.3.4	Cenários de utilização do ChronicPrediction com uma Rede Bayesiana para DAC . . . . .	92
5.3.5	Plano de Cuidados Aplicado aos Cenários Propostos . . . . .	93
5.3.6	Cenário 1 . . . . .	94
5.3.7	Cenário 2 . . . . .	98
5.3.8	Cenário 3 . . . . .	101
5.3.9	Cenário 4 . . . . .	106
<b>5.4</b>	<b>Segunda Avaliação . . . . .</b>	<b>109</b>
<b>5.5</b>	<b>Terceira Avaliação . . . . .</b>	<b>112</b>
<b>6</b>	<b>CONSIDERAÇÕES FINAIS . . . . .</b>	<b>121</b>
<b>6.1</b>	<b>Conclusões . . . . .</b>	<b>122</b>
<b>6.2</b>	<b>Contribuições . . . . .</b>	<b>122</b>
<b>6.3</b>	<b>Trabalhos Futuros . . . . .</b>	<b>125</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>127</b>
	<b>APÊNDICE A QUESTIONÁRIO PARA PESSOAS COM DCNTS . . . . .</b>	<b>135</b>
	<b>ANEXO A DADOS BASAIS DO USUÁRIO (GAEDKE, 2013) . . . . .</b>	<b>137</b>
	<b>ANEXO B MEDICAMENTOS PRESCRITOS (GAEDKE, 2013) . . . . .</b>	<b>143</b>

# 1 INTRODUÇÃO

## 1.1 Motivação

Doenças Crônicas Não Transmissíveis (DCNTs) são as que mais contribuem para o aumento da incidência de doenças em países desenvolvidos, e estão aumentando rapidamente nos países em desenvolvimento. Isso ocorre principalmente devido a transição demográfica e as mudanças no estilo de vida da população associada a urbanização (PUOANE et al., 2008).

DCNTs incluem doenças cardíacas, doenças vasculares, câncer, doenças respiratórias crônicas e diabetes. Deficiência visual e cegueira, deficiência auditiva e surdez, doenças bucais e desordem genéticas são outras condições crônicas igualmente classificadas como DCNTs e que compõem uma porção substancial da quantidade de doenças (ORGANIZATION et al., 2005).

De uma forma geral, mortes causadas por doenças crônicas têm projeção de crescimento entre 2005 e 2015, enquanto que ao mesmo tempo mortes provenientes de doenças transmissíveis e deficiências nutricionais possuem projeção de queda (ORGANIZATION et al., 2005). Para 2015, projeta-se que haverá um total de 64 milhões de mortes, sendo 41 milhões de mortes decorrentes em função de doenças crônicas. Doenças cardiovasculares irão permanecer como sendo a causa principal de morte, com uma estimativa de morte de 20 milhões de pessoas, principalmente devido a doenças cardíacas e problemas cardiovasculares. Além disso, mortes causadas por doenças crônicas tendem a aumentar em torno de 17% entre os anos de 2005 e 2015, passando de 35 milhões para 41 milhões.

As DCNTs possuem um forte impacto econômico nos indivíduos, familiares, sistemas de saúde e sociedade em geral. Uma vez que as doenças crônicas afetam os jovens e pessoas em seus anos produtivos, elas reduzem a produtividade no trabalho e a capacidade de ganho a nível doméstico. O tratamento de doenças crônicas coloca muito esforço sobre o já sobrecarregado sistema de saúde na grande maioria dos países do mundo, devido aos recursos adicionais requeridos (PUOANE et al., 2008).

Os sistemas de saúde foram organizados historicamente para responder rapidamente e efetivamente a qualquer doença aguda ou lesão que aparecer. O foco era o problema imediato, sua rápida definição e exclusão de diagnósticos alternativos mais sérios e o início do tratamento profissional. O papel do paciente foi em grande parte passivo. Uma vez que o curso clínico completo, muitas vezes se desenrola ao longo de dias ou semanas, houve pouca urgência em se desenvolver funcionalidades de autogerenciamento de pacientes ou programas de treinamentos (WAGNER et al., 2001).

Muitas pessoas com doenças crônicas lutam com demandas físicas, psicológicas e sociais de suas doenças sem muita ajuda ou apoio proveniente de cuidados médicos. Mais frequentemente, a ajuda recebida, enquanto bem intencionada, não consegue proporcionar atendimento clínico ideal ou atender as necessidades das pessoas para o efetivo autogerenciamento das suas doenças. Isso agrava-se ainda mais se considerarmos ainda o fato de que as DCNTs exigem

um tratamento contínuo e ininterrupto (WAGNER et al., 2001; BODENHEIMER; WAGNER; GRUMBACH, 2002). Sendo assim, se faz importante que o paciente portador de alguma DCNT possa ter acesso rápido e direto sobre a situação atual do seu tratamento independentemente do local onde ele esteja e do período do dia. Nesse sentido, a ascensão de dispositivos móveis com acesso à internet, tais como *smartphones*, oferece características importantes e com grande potencial para facilitar o controle e acompanhamento contínuo dos doentes, afinal, a grande maioria das pessoas carrega seus *smartphones* a todos lugares que frequentam diariamente e, além disso, dispendo de acesso à internet de forma ininterrupta, podem obter auxílio especializado sempre que necessário.

De acordo com o relatório anual *Our Mobile Planet* (GOOGLE, 2014), no Brasil, a difusão dos *smartphones* atinge 26% da população e elas dependem cada vez mais de seus dispositivos. 46% acessam a internet todos os dias no *smartphone* e 73% afirmam que nunca saem de casa sem seus dispositivos. Além disso, os locais onde os *smartphones* são comumente mais utilizados são em casa (96%), trabalho (87%) e em restaurantes (83%). Outro aspecto a se destacar é o fato de que o acesso à internet feito através de dispositivos móveis vem ocupando o espaço que até então era ocupado quase que exclusivamente por PCs e *laptops*.

Quando articulada, em 1991, a visão de Weiser (WEISER, 1991) em relação à computação do futuro estava ainda distante da realidade do seu tempo, pois a tecnologia de hardware necessária para atingir tais objetivos não existia até então. Na ideia de Weiser, a interação com os computadores não seria mais feita de forma direta, pois os dispositivos computacionais passariam a atuar de forma transparente e integrada ao ambiente. Além disso, computadores seriam cada vez menores e móveis, além de estarem espalhados por todos os ambientes, compondo o conceito denominado por ele como Computação Ubíqua (WEISER, 1991; SATYANARAYANAN, 2001). Atualmente, dados os grandes avanços tecnológicos ocorridos, alguns dos conceitos por ele idealizados começam aos poucos a se tornar realidade, principalmente no que diz respeito a miniaturização de componentes e, sobretudo, em relação aos dispositivos móveis (com destaque para os *smartphones* e *tablets*) cada vez mais presentes no dia a dia e de forma cada vez mais integrada.

Dentre as diferentes áreas que já utilizam os conceitos estabelecidos pela computação ubíqua estão o comércio (FRANCO et al., 2011) e a educação (BARBOSA et al., 2011). Além disso, entre as áreas de aplicações desenvolvidas para a computação ubíqua, uma das mais promissoras é a computação ubíqua aplicada ao cuidado e monitoramento da saúde em seus diferentes aspectos (YOO et al., 2007), onde recebe o nome de u-Health.

U-Health pode ser definida como sendo serviços de saúde entregues através de tecnologias ubíquas, tais como RFID, dispositivos biométricos, e redes de sensores ubíquos (SONG; RYU; LEE, 2011; YOO et al., 2007). Em particular, u-Health está direcionada a monitorar e gerenciar a saúde das pessoas, incluindo aquelas pessoas com alguma DCNT.

Monitorar a saúde em condições fora do hospital tem sido de interesse dos pesquisadores e médicos há bastante tempo. Registros de variáveis fisiológicas e psicológicas em condições

reais podem ser especialmente úteis no gerenciamento de desordens crônicas ou problemas de saúde; por exemplo: para pressão arterial alta, diabetes, anorexia nervosa, dor crônica ou obesidade grave (KORHONEN; PARKKA; VAN GILS, 2003).

O modelo UDoctor (VIANNA, 2013; DAMASCENO VIANNA; BARBOSA, 2014), desenvolvido no Laboratório de Computação Móvel e Ubíqua (MobiLab) vinculado à Universidade do Vale do Rio dos Sinos (Unisinos) é um exemplo de modelo para cuidados ubíquos que tem como um de seus objetivos facilitar a integração entre pacientes, recursos da comunidade e organizações de saúde. Um aspecto a se salientar é que no cuidado de doenças crônicas o indivíduo é participante ativo no processo de gerenciamento. Por exemplo, um paciente diabético pode monitorar seus valores de taxas de glicose no sangue, armazenar esses resultados em uma base de dados e receber *feedbacks*; por exemplo: sobre o sucesso de uma dieta para melhorar os níveis das taxas de açúcar no sangue. Além disso, como forma de agregar valor ao modelo, aplicações para dispositivos móveis poderiam utilizar-se desses dados em conjunto com técnicas de inteligência artificial para efetuar previsões em relação a condição de saúde futura do paciente, podendo, inclusive, efetuar diagnósticos prévios e tendências baseando-se nessas informações armazenadas e fazer recomendações sobre novas formas e possibilidades de melhor conduzir o tratamento.

## 1.2 Definição do Problema e Questão de Pesquisa

O número de pessoas com DCNTs está crescendo a taxas surpreendentes devido ao rápido envelhecimento da população e a maior longevidade das pessoas com muitas condições crônicas. Além disso, tanto em países desenvolvidos quanto naqueles em desenvolvimento, estas doenças ocupam as primeiras posições nas estatísticas de mortalidade mundiais (OLIVEIRA-CAMPOS et al., 2013). É frequente assumir que mortes causadas por doenças crônicas estão restritas a pessoas idosas, mas não é o que acontece na prática. Aproximadamente 16 milhões de mortes causadas por doenças crônicas ocorrem a cada ano em pessoas abaixo dos 70 anos de idade. Contudo, mortes causadas por doenças crônicas ocorrem mais em idades mais jovens e em países de renda baixa e média do que em países de alta renda (ORGANIZATION et al., 2005). Apesar das diferenças clínicas entre cada uma das condições crônicas, cada doença confronta pacientes e seus familiares com as mesmas necessidades: alterar seu comportamento para lidar com os impactos sociais e emocionais dos sintomas, deficiências e aproximação da morte; tomar medicamentos e interagir com cuidados médicos todo o tempo. Em troca, a assistência médica deve garantir que os pacientes recebam os tratamentos para controlar doenças e minimizar os sintomas, bem como a informação e o apoio necessários para o auto gerenciamento de sua saúde (WAGNER; GROVES, 2002).

As causas das principais doenças crônicas são, na grande maioria dos casos, bem estabelecidas e bem conhecidas. Dentre os mais importantes fatores de risco, destacam-se dietas pouco saudáveis, incluindo a ingestão excessiva de calorias, falta de atividade física e o taba-

gismo (ORGANIZATION et al., 2005). Os sistemas ubíquos utilizados no suporte e cuidado de DCNTs priorizam o monitoramento do paciente e a geração de diversos tipos de alerta. O suporte a treinamento do paciente e a integração entre os diversos agentes que podem auxiliar no tratamento contínuo dessas doenças é ainda muito escasso e insipiente. Além disso, pouco foco é dado ao controle dos fatores de risco dessas doenças (DAMASCENO VIANNA; BARBOSA, 2014). Outro aspecto importante a ser salientado diz respeito ao suporte a tomada de decisões e recomendações por parte dos sistemas ubíquos existentes, ainda pouco utilizado na área de u-Health, sobretudo, em sistemas específicos para o gerenciamento e controle de DCNTs.

Como o cuidado de doença crônica deve ser feito de forma contínua, torna-se importante para o paciente ter um conhecimento prévio sobre o andamento do seu tratamento e se as ações por ele feitas no dia a dia estão lhe ajudando com o tratamento ou não. Por exemplo, se os alimentos por ele ingeridos irão colaborar para a diminuição dos níveis glicêmicos ou se a quantidade de exercícios físicos feita por ele serão suficientes para o controle correto das suas taxas de colesterol.

Tal abordagem, com o intuito de efetuar predições, começa a ser analisada por alguns pesquisadores, porém, normalmente os estudos são voltados para uma doença específica e não necessariamente uma DCNT ou com o objetivo de fazer recomendações de ações com o intuito de aprimorar o tratamento do paciente (HIMES et al., 2009; GUO; BAI; HU, 2012; PARK; CHO, 2012).

Como mecanismo de predição, uma das principais técnicas utilizadas são as Redes Bayesianas (RBs) (CHARNIAK, 1991), que conseguem efetuar predições mesmo quando se tem disponível apenas uma pequena quantidade de dados. Além disso, as RBs tratam-se de modelos para resolver problemas que envolvem incerteza oferecendo um formulismo transparente e robusto para modelagem probabilística, sendo assim elas têm sido utilizadas como método para modelos de diagnósticos ou prognósticos em domínios médicos (PARK; CHO, 2012).

A capacidade de efetuar recomendações e predizer alguma tendência ou incidência de algum dos fatores de risco relacionados a alguma DCNT que o paciente possua antes que estes efetivamente se agravem torna-se bastante importante dentro de um modelo desenvolvido para cuidados ubíquos. Além disso, considerando-se ainda a possibilidade de se prognosticar o agravamento dos fatores de risco de forma ubíqua, constante e em todo o lugar, observando o contexto em que o paciente se encontra é importante, uma vez que no gerenciamento de doenças crônicas o indivíduo é participante ativo no processo de gerenciamento. Por exemplo, um paciente com diabetes pode informar a periodicidade com a qual faz exercícios físicos, alimentos que consumiu e, a partir disso, ser informado a respeito da probabilidade das suas taxas de glicose no sangue estarem altas (KORHONEN; PARKKA; VAN GILS, 2003). Tal abordagem tem tido cada vez mais atenção por parte dos pesquisadores dentro da computação ubíqua, onde começam a surgir trabalhos voltados para a área da u-Health (CHARITOS et al., 2009; THOMSEN et al., 2013; WANG et al., 1999; PARK; CHO, 2012; HIMES et al., 2009; GUO; BAI; HU, 2012), porém, nenhum deles foca exclusivamente no monitoramento de fatores de risco de

múltiplas DCNTs utilizando-se de dados históricos de contexto, ou trilhas (SILVA et al., 2010; KÖNIG; KLEIN; DAVID, 2013), que são registros de valores de contextos passados, e considerando informações do contexto atual do paciente. Explorar a utilização de dados históricos de contextos para monitorar fatores de risco abre inúmeras possibilidades, uma vez que torna-se possível a partir desses dados históricos verificar a evolução ou involução de certos aspectos que influenciam em determinados fatores de risco, pois através destes dados se tem a rotina do paciente monitorada ao longo de um determinado período de tempo. Além disso, torna-se possível fornecer recomendações e dicas para o paciente com o intuito de auxiliá-lo na melhora do seu estado de saúde. Torna-se possível também cruzar as informações de trilhas de um determinado paciente com as de outros pacientes que sofrem de doenças semelhantes, possibilitando, inclusive, identificar tendências.

Tomando como base os conceitos acima mencionados, abre-se a seguinte questão de pesquisa: *como seria um modelo para o prognóstico ubíquo de fatores de risco de DCNTs que utilizasse RBs a fim de efetuar recomendações e auxiliar no controle das condições de saúde em situações fora do ambiente hospitalar?*

### 1.3 Objetivos

Este trabalho tem como objetivo principal a criação do ChronicPrediction, um modelo de prognóstico ubíquo de fatores de risco de DCNTs cuja função é verificar a evolução ou involução de certos aspectos que influenciam nesses fatores, além de fornecer recomendações e dicas para o paciente com o intuito de auxiliá-lo na melhora do seu estado de saúde. Tal modelo utiliza RBs criadas a partir do mapeamento de relações de causalidade provenientes de opinião de especialistas ou criadas a partir de dados históricos de contexto.

Desta forma, o presente trabalho possui os seguintes objetivos específicos:

- propor o ChronicPrediction, um modelo para efetuar prognósticos de fatores de risco para DCNTs através do uso de RBs e dados históricos de contextos, além de fornecer recomendações e dicas para o paciente com o intuito de auxiliá-lo na melhora da sua saúde;
- desenvolver um protótipo que implemente os elementos do modelo proposto e integrá-lo a um modelo para cuidado ubíquo de DCNTs chamado UDUCTOR (DAMASCENO VI-ANNA; BARBOSA, 2014);
- descrever cenários de aplicação do modelo proposto;
- efetuar a validação do modelo utilizando-se do protótipo implementado e da metodologia de avaliação proposta.

## 1.4 Metodologia

Como ponto fundamental para o início desta pesquisa, buscou-se identificar os principais tópicos e quais eram os principais conceitos, tecnologias e modelos que propiciassem a fundamentação teórica relevante para a definição de um modelo de predição que satisfizesse os objetivos definidos. Foram realizadas diversas pesquisas, tanto nas áreas que possuem conexão direta com o tema proposto quanto em outras áreas que poderiam contribuir de forma direta ou indireta com a resolução do problema estudado. Tais pesquisas prévias foram importantes à medida que contribuíram para a elaboração de uma dissertação contendo os conhecimentos obtidos a partir das linhas de pesquisas analisadas.

Em um segundo momento, iniciou-se o desenvolvimento de uma especificação, que teve como objetivo descrever as características principais do modelo ChronicPrediction, bem como seus requisitos funcionais e não funcionais. Tomando como ponto de partida o embasamento teórico e a definição inicial do modelo, procurou-se analisar trabalhos semelhantes, objetivando analisar as abordagens adotadas, características e resultados obtidos por eles.

Após, realizou-se um comparativo entre os trabalhos que foram analisados, visando identificar características positivas e negativas e melhorar as características do modelo proposto. Após este comparativo, chegou-se a uma primeira especificação completa do modelo a ser desenvolvido. O modelo proposto, posteriormente, sofreu modificações devido à evolução na pesquisa como um todo, chegando, por fim, a definição arquitetural sobre a qual a solução proposta foi desenvolvida.

Posteriormente, após a especificação do modelo proposto, foi implementado um protótipo funcional do modelo que possuísse as funcionalidades requeridas para que os experimentos utilizados para avaliação fossem executados e sua integração com o protótipo do modelo UDuctor consumada. A avaliação efetuada se apresenta na forma de experimentos, que são descritos e representados através de cenários, os quais possuem como objetivo principal avaliar as hipóteses relacionadas a cada um desses experimentos. Cada uma das hipóteses formuladas tem como ponto inicial para a sua formulação o fato de que se tem uma ideia de uma causa envolvida com o respectivo efeito dela. Os cenários elaborados buscam descrever situações comuns que ocorrem constantemente no dia a dia de pacientes portadores de algum tipo de DCNT. A diversidade buscada em cada um dos cenários elaborados se torna importante para aperfeiçoar a amplitude da avaliação proposta.

## 1.5 Organização do Texto

A presente dissertação está organizada da seguinte maneira: O capítulo 2 descreve os conceitos principais aos quais o modelo está relacionado. Esses conceitos abrangem a computação ubíqua, saúde ubíqua, Redes Bayesianas e modelos de cuidados ubíquos. Além disso, o capítulo descreve o modelo UDuctor e seus componentes, bem como apresenta o assistente pessoal Ch-

ronicDuctor, que são utilizados para compor o modelo de predição proposto. No capítulo 3 são apresentados e comparados os trabalhos relacionados ao tema de predição utilizando-se de dados históricos de contextos e predição na área de doenças crônicas. No capítulo 4 é apresentado o modelo de monitoramento de fatores de risco para DCNTs ChronicPrediction, sua integração com o modelo UDuctor e sua arquitetura. O capítulo 5 apresenta aspectos de implementação e avaliação que foram aplicados no estudo realizado. A dissertação é encerrada no capítulo 6, onde são apresentadas as conclusões a respeito do trabalho, quais foram as contribuições pretendidas pelo modelo proposto quando comparado aos demais trabalhos apresentados, além de abrir espaço para futuros trabalhos.



## 2 U-HEALTH E DOENÇAS CRÔNICAS

Avanços nas tecnologias de sensores, comunicação *wireless* e da tecnologia da informação em geral oferecem oportunidades para novos modelos de assistência médica e bem estar ou ferramentas para o gerenciamento de doenças, as quais possibilitam ampliar a independência de vida em casa e melhorar a qualidade de vida dos indivíduos.

U-health pode ser definida como sendo serviços de saúde entregues através de tecnologias ubíquas, tais como identificação por rádio frequência (RFID), dispositivos biométricos, e redes de sensores ubíquos (SONG; RYU; LEE, 2011; YOO et al., 2007). Em particular, u-health está direcionada a monitorar e gerenciar a saúde das pessoas, incluindo aquelas pessoas com doenças crônicas.

Monitorar a saúde em condições fora do hospital tem sido de interesse dos pesquisadores e médicos há bastante tempo. Registros de variáveis fisiológicas e psicológicas em condições reais podem ser especialmente úteis no gerenciamento de desordens crônicas ou problemas de saúde; por exemplo: para pressão arterial alta, diabetes, anorexia nervosa, dor crônica ou obesidade grave (KORHONEN; PARKKA; VAN GILS, 2003).

No gerenciamento de doenças crônicas o indivíduo é participante ativo no processo de gerenciamento. Por exemplo, um paciente diabético pode monitorar seus valores de taxas de glicose no sangue, armazenar esses resultados em uma base de dados e receber textitfeedback ou recomendações para melhorar o andamento do seu tratamento; por exemplo: sobre o sucesso de uma dieta para melhorar os níveis das taxas de açúcar no sangue. Além disso, em um ambiente de computação ubíqua, outros fatores podem ser levados em consideração no gerenciamento de uma DCNT, tais como como a localização atual do paciente, a temperatura do local em que se encontra, o período do dia, bem como ações por ele tomadas anteriormente e dados armazenados referentes as suas condições de saúde anteriores (dados históricos de contexto).

O presente capítulo aborda o tema da computação ubíqua, dados históricos de contexto, bem como a aplicabilidade da computação ubíqua na área da saúde e das DCNTs. Além disso, se propõe a apresentar os principais conceitos relacionados a RBs, além de exemplos práticos de utilização desta técnica para se efetuar predições e diagnósticos. Na parte final do capítulo é descrito o modelo para cuidados ubíquos UDuctor e seus componentes principais, incluindo o assistente pessoal ChronicDuctor. Ambos são utilizados para compor o modelo de predição proposto.

### 2.1 Computação Ubíqua

O conceito fundamental de computação ubíqua definida por Weiser (1991) trabalha de forma totalmente integrada com a definição de sistemas distribuídos, pois fazendo parte do ambiente em que se encontra, atuará de forma distribuída e multiplataforma através da integração de dispositivos móveis, tais como *smartphones* com sensores e sistemas inteligentes, podendo con-

tatar um servidor central, que pode estar localizado no mesmo ambiente ou em qualquer outro lugar e é responsável por processar as informações. Dentro da computação ubíqua o computador ou entidade inteligente passa a participar ativamente e de forma autônoma auxiliando na tomada de decisões e, ao contrário da computação convencional, na computação ubíqua a presença das entidades computacionais é transparente a quem as utiliza, sendo totalmente integrada ao ambiente em que se encontra e agindo sobre o contexto.

Quando articulada, a visão de Weiser estava ainda distante da realidade do seu tempo, pois a tecnologia de hardware necessária para atingir tais objetivos não existia até então (SATYANARAYANAN, 2001). Em 2001, após uma década de progressos em hardware, muitos elementos citados como críticos na computação pervasiva e que eram considerados exóticos em 1991 passaram a ser produtos viáveis, tais como *smartphones*, redes *wireless* e computadores vestíveis. A visão de Weiser passou então a ser enquadrada dentro do novo quadro tecnológico existente, onde, para Satyanarayanan (2001), a computação móvel torna-se o ponto de partida para a computação ubíqua, o qual é precedida pelos conceitos que norteiam os sistemas distribuídos e a computação móvel, além de adicionar alguns novos conceitos próprios que, segundo Satyanarayanan, poderiam ser classificados entre: espaços inteligentes, invisibilidade, escalabilidade localizada e mascaramento das condições desiguais.

Define-se como sendo **espaços inteligentes** a eficiente utilização da infraestrutura computacional já existente em um ambiente a fim de melhorar a qualidade da utilização desse mesmo ambiente por alguém. Um exemplo simples de utilização deste conceito seria a automática adaptação dos níveis de resfriamento, aquecimento e luminosidade em uma sala baseando-se no perfil de quem a estivesse ocupando naquele determinado momento.

A **invisibilidade** diz respeito a capacidade de um determinado sistema ubíquo não ser percebido mesmo durante a sua utilização, onde o usuário efetua a interação com o sistema quase que de forma inconsciente e totalmente transparente. Como exemplo, pode-se citar um determinado sistema de navegação veicular autônomo que guia o motorista de forma adequada até o destino requisitado.

**Escalabilidade localizada** diz respeito ao fato de que, conforme um espaço inteligente cresce em sofisticação, a intensidade das interações entre o espaço computacional pessoal de um usuário e seu ambiente aumenta. Isso traz grande consumo de largura de banda de conexão, energia e implicações para um usuário mobile. Normalmente, em um ambiente ubíquo, a demanda por recursos localizados mais próximos fisicamente é maior do que a demanda por recursos localizados mais distantes. Sendo assim, sistemas ubíquos devem ser projetados para atender, preferencialmente, as requisições das entidades computacionais localizadas mais próximas. Como exemplo, pode-se mencionar uma scanner localizado em um determinado setor de uma companhia e que sistematicamente prioriza trabalhar com arquivos requisitados por aquele setor em que ele está localizado.

A taxa de penetração da tecnologia de computação pervasiva dentro de uma determinada infraestrutura irá variar consideravelmente dependendo de muitos fatores não necessariamente

técnicos, tais como a estrutura organizacional, econômica e o modelo de negócio empregado. O **maskamento das condições desiguais** é incentivado pela possibilidade de existirem, efetivamente, ambientes com menos capacidade e riqueza de recursos em relação a outros. Nessas situações, fica na responsabilidade do ambiente pessoal do usuário suprir esta carência de alguma forma. Como exemplo, pode-se mencionar uma reunião em que não se tenha um projetor disponível para apresentação, sendo assim as telas dos notebooks ou smartphones dos participantes poderiam estar sincronizadas com a tela do interlocutor em questão a fim de acompanharem a apresentação normalmente.

Além dessas características mencionadas por Satyanarayanan, Kindberg e Fox (2002), foram analisadas outras duas características que foram consideradas importantes para compor a definição da área, onde tomou-se como premissa a ideia de que todo sistema ubíquo é orientado, fundamentalmente, por duas características principais: a integração física e a interoperação espontânea. O conceito de integração física diz que, similarmente ao conceito de espaços inteligentes, objetos integrados a dispositivos computacionais tendem a potencializar a utilização e a experiência de uso do espaço físico. Nesse ponto surge o que foi chamado de fronteira (KINDBERG; FOX, 2002), que diz que sistema ubíquos devem claramente indicar os limites de início e fim entre esses espaços.

Já na **interoperação espontânea** os dispositivos se comunicam uns com os outros em um ambiente dinâmico, onde os dispositivos participantes da comunicação mantêm associações de forma passageira, o que determina que uma vez que os dispositivos participantes dos sistemas ubíquos são dinâmicos e imprevisíveis (sem comportamento definido) deverá haver um tipo de regra que dirija a execução do sistema.

De uma forma geral, pode-se concluir então que a computação ubíqua pode ser conceituada como sendo um ambiente repleto de dispositivos que se comunicam entre si e que possuem capacidade de mudar de ambiente dinamicamente e de forma transparente, objetivando melhorar a experiência dos usuários oferecendo algum tipo de aplicação e/ou serviço de forma transparente.

## 2.2 Sensibilidade ao Contexto

O termo sensibilidade ao contexto surgiu como sendo uma das etapas do processo evolutivo que objetiva culminar com as ideias e conceitos propostos por Weiser (1991) quando cunhou o termo Computação Ubíqua. Para um melhor entendimento naquilo que se refere a contexto dentro do modelo de computação ubíqua, se faz necessário, antes de tudo, definir o que é contexto. Na literatura, a expressão sensível ao contexto apareceu, primeiramente, em Schilit e Theimer (1994) onde os autores descrevem contexto como sendo a localização e identificam as pessoas próximas, objetos e mudanças para esses objetos.

Tais exemplos de contextos eram frequentemente utilizados no início da história dos sistemas sensíveis ao contexto. Em Nick, Pascoe e Morse (1997) contexto é referido como a

localização do usuário, o ambiente, a identidade e o tempo. Uma outra forma comum de definir contexto foi a utilização de sinônimos. Hull, Neaves e Bedford-Roberts (1997) descrevem contexto como sendo os aspectos da situação atual. Uma das definições mais conhecidas e amplamente aceitas, dado seu generalismo em relação ao termo, pertence a Dey, Abowd e Salber (2001), que diz que um contexto pode ser definido como sendo qualquer informação que pode ser utilizada para caracterizar a situação das entidades (pessoa lugar ou objeto, por exemplo) que são consideradas relevantes para a interação entre um usuário e uma aplicação, incluindo o usuário e a própria aplicação. Se pode dizer também que, normalmente, contexto é tipicamente a localização, a identidade, e o estado das pessoas, grupos, e objetos físicos e computacionais.

Computação sensível ao contexto (*Context-Aware Computing*) se refere, basicamente, a ideia de que dispositivos computacionais podem perceber e reagir ao ambiente físico onde estão implantados (HOAREAU; SATOH, 2009). Um dos objetivos tidos como sendo fundamentais da computação sensível ao contexto é adquirir e utilizar informações pertencentes ao mundo físico e então selecionar, configurar e oferecer uma variedade de serviços de forma adequada. Sistemas sensíveis ao contexto estão, fundamentalmente, interessados em adquirir informações de contextos (através de sensores, por exemplo) e no entendimento do contexto (combinando a percepção de estímulos sensoriais para um determinado contexto). Esse tipo de sistema é apto a adaptar suas operações para o contexto corrente sem a intervenção explícita do usuário e, assim, visando aumentar a usabilidade e a efetividade levando em conta o contexto do ambiente (BALDAUF; DUSTDAR; ROSENBERG, 2007). Sistemas sensíveis ao contexto podem ser implementados de muitas formas. A abordagem depende de requisitos especiais e condições de uso, tais como a localização dos sensores (locais ou remotos), a porção de usuários possíveis (um usuário ou muitos), a disponibilidade de recursos dos dispositivos utilizados (PCs top de linha ou pequenos dispositivos móveis) ou a possibilidade de uma funcionalidade nova do sistema.

Dey, Abowd e Salber (2001) elenca também algumas das principais funcionalidades que uma aplicação sensível ao contexto pode implementar:

- **Apresentar informação e serviços:** mostrar a localização dos usuários ou de seus veículos no mapa e possivelmente indicar lugares próximos de interesse;
- **Execução automática de um serviço:** descreve aplicações que disparam comandos ou reconfigura o sistema ou interesse do usuário de acordo com as mudanças no contexto. Anexar informações de contexto para posterior recuperação.

### 2.3 Histórico de Contextos

Histórico de contexto ou trilhas (SILVA et al., 2010; FRANCO et al., 2011) tem sido reconhecido como simplesmente a coleção de contextos passados e ações dos usuários nesses contextos. Existem inúmeras possibilidades de aperfeiçoar os serviços oferecidos através desta

abordagem. Se o histórico de contexto pode ser utilizado, os serviços personalizados inteligentes podem oferecer aos usuários inúmeras possibilidades através da extração de padrões extraídos a partir dos dados históricos de contextos (HONG et al., 2009). Históricos de contextos, especialmente quando gravados por um longo período, oferecem um amplo conjunto de possibilidades para reforçar os serviços oferecidos por alguns sistemas de computador. Essas possibilidades incluem inferência das atuais e das ações passadas dos usuários, seleções dos dispositivos, etc. Contudo, a predição de contextos futuros baseados nos contextos anteriormente armazenados é frequentemente concebida como sendo o desafio definitivo na exploração de históricos de contextos (MAYRHOFER, 2005). Segundo Ciaramella et al. (2010), histórico de contexto foi identificado como uma importante peça de informação para reconhecer a situação do usuário e é estritamente relacionado a atividade que os usuários estão desempenhando e os recursos os quais eles podem estar interessados.

Comparar predição de contextos com contextos já conhecidos ajuda a detectar irregularidades e, portanto, auxilia a lidar com falhas no sistema. Por outro lado, proatividade permite oferecer interações de usuários que melhor atendam às suas expectativas. Em combinação com sensibilidade ao contexto, a proatividade abre inúmeras possibilidades para melhorar as informações sobre serviços disponíveis ou construir novos, atualmente indisponíveis.

Mayrhofer (2004) propôs utilizar histórico de contexto para prever a situação atual. Aqui, dados de sensores são classificados em níveis mais altos de identificadores de contextos e então o próximo contexto possível é predito utilizando um algoritmo baseado em modelos de Markov.

Byun e Cheverst (2003) têm explorado históricos de contextos para induzir regras a fim de adaptar o sistema ao comportamento do usuário. Yap, Tan e Pang (2005) propôs escolher dinamicamente o conjunto de informações contextuais nas quais a recomendação de recursos pode se basear. Técnicas de Máquinas de Vetores de Suporte são aplicadas no histórico de contexto a fim de aprender um coeficiente de relevância de cada informação contextual. Hong et al. (2009) tem sugerido a utilização de históricos de contexto para automaticamente extrair as preferências dos usuários sobre os serviços. Em particular, através de árvores de decisão e regras de associação, o sistema está apto a associar contextos de usuários com serviços e ainda prever o próximo serviço que o usuário poderá necessitar.

Predição de contexto é um tópico ainda recente, no ramo das pesquisas (VOIGTMANN et al., 2013; KÖNIG; KLEIN; DAVID, 2013). Além disso, ela pode ser uma poderosa ferramenta para usuários em suas atividades diárias e promover uma ampla disponibilidade de serviços computacionais para o grande público.

## 2.4 Redes Bayesianas

Redes Bayesianas (RBs) foram desenvolvidas no início dos anos 80 para facilitar a tarefa de predição e diagnóstico em sistemas de Inteligência Artificial (IA) (CHARNIAK, 1991). O nome Redes Bayesianas deriva da utilização da fórmula matemática para o cálculo de probabilidades

estabelecido por Thomas Bayes em 1763.

RBs podem ser consideradas como sendo diagramas que organizam o conhecimento numa dada área através de um mapeamento entre causas e efeitos (CHARNIAK, 1991).

Para Fenton e Neil (1999), "as Redes Bayesianas nos permitem expressar relações complexas dentro de um modelo a um nível de incerteza com base no problema".

As RBs são grafos acíclicos dirigidos, ou seja, os arcos são unidirecionais de tal forma que, quando uma relação sai de um nodo ela não pode retornar para o mesmo nodo, em respeito à direção especificada pelas setas. A representação gráfica de uma rede Bayesiana é composta por nodos que representam variáveis aleatórias, que assumem valores discretos ou contínuos. Os arcos são responsáveis por relacionar estes nodos, que representam as conexões ou as dependências diretas. A ideia é representar as relações de causalidade entre os nodos (FIRMINO P. R. A.; DROGUETT, 2004).

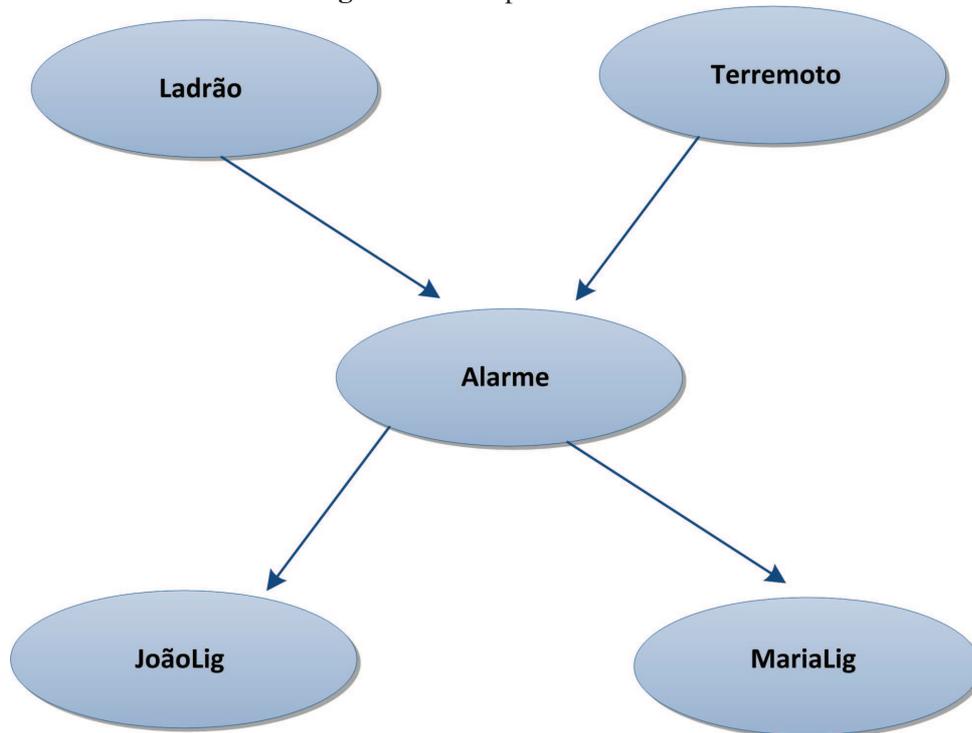
Marques e Dutra (2000) afirmam que toda RB é composta pelas seguintes características:

- um conjunto determinado de variáveis e um conjunto de arcos ligando essas variáveis;
- cada uma das variáveis possui um conjunto limitado de estados mutuamente exclusivos;
- as variáveis e arcos formam um grafo dirigido e sem ciclos;
- para cada variável  $A$  que tem como pais  $B_1, \dots, B_n$  existirá uma tabela de probabilidades  $P(A|B_1, \dots, B_n)$ .

É importante observar que, caso a variável  $A$  não possua pais, a tabela de probabilidades é reduzida para uma probabilidade incondicional  $P(A)$ . Estando definida a topologia da rede, basta especificar as probabilidades dos nós que participam com dependências diretas e utilizar estas probabilidades para computar as demais probabilidades que se deseje.

Para ilustrar o funcionamento de uma RB, considere um novo alarme contra ladrões. Tal alarme é muito confiável na detecção de ladrões, porém, ele também pode disparar caso ocorra um terremoto. Dois vizinhos, João e Maria, comprometeram em telefonar caso o alarme dispare. João sempre liga quando ouve o alarme, porém, algumas vezes confunde o alarme com o telefone e também liga nesses casos. Maria, por outro lado, gosta de ouvir música alta e, às vezes, não escuta o alarme. Tal domínio poderia ser representado da seguinte forma (Figura 1).

Conforme se pode observar a rede não possui nenhum nó que indique que Maria esteja ouvindo música, ou que o telefone esteja tocando e atrapalhando o entendimento de João. Estes fatos são implícitos e estão associados à incerteza relacionada pelos arcos Alarme  $\rightarrow$  JoãoLig e MariaLig, pois seria necessário um tempo muito grande para se obter tais probabilidades e tais informações poderiam ser irrelevantes. Desta forma, as probabilidades devem resumir as condições nas quais o alarme pode falhar (falta de bateria, campainha estragada, etc) e ainda, as condições em que João e Maria podem falhar (não estava presente, não ouviu o alarme, estava de mau-humor, etc). Após definida a topologia da rede, torna-se necessário definir a tabela de probabilidades condicionais para cada um dos nós. Cada uma das linhas na tabela

**Figura 1:** Exemplo de uma RB

Fonte: (RUSSELL; NORVIG, 1995)

contém a probabilidade condicional para cada caso condicional dos nós pais. Entende-se por caso condicional uma possível combinação dos valores para os nós pais (ver Tabela 1). Por exemplo, para a variável aleatória Alarmes se tem:

**Tabela 1:** Probabilidades condicionais do problema

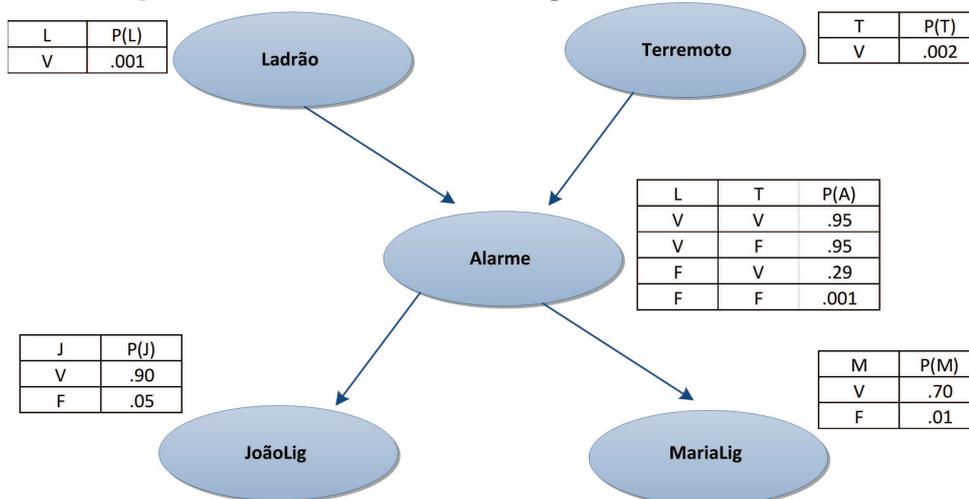
Ladrão	Terremoto	P(Alarme   Ladrão, Terremoto)	
		Verdadeiro	Falso
Verdadeiro	Verdadeiro	0.95	0.050
Verdadeiro	Falso	0.95	0.050
Falso	Verdadeiro	0.29	0.71
Falso	Falso	0.001	0.999

Fonte: (RUSSELL; NORVIG, 1995)

A imagem a seguir demonstra a RB para o exemplo citado, onde são mostradas as probabilidades condicionais (Figura 2).

Conforme mostrado na Figura 2, as distribuições de probabilidades são exibidas na forma de uma Tabela de Probabilidade Condicional, ou TPC, onde tal forma de representação pode ser utilizada tanto para representar variáveis discretas como para representar variáveis contínuas. Cada uma das linhas contém a probabilidade condicional para cada caso condicional dos nós pais. Um caso condicional (também chamado de caso de condicionamento) representa uma possível combinação dos valores para os nós pais (MARQUES; DUTRA, 2000).

Para variáveis booleanas, onde se sabe que a probabilidade de um valor verdadeiro é  $p$ ,

**Figura 2:** RB contendo as tabelas de probabilidades condicionais

Fonte: (RUSSELL; NORVIG, 1995)

então a probabilidade de um valor falso deve ser  $1-p$ , desta frequentemente omite-se o segundo número. Normalmente, uma tabela para uma determinada variável booleana com  $k$  pais booleanos contém  $2^k$  probabilidades que podem ser especificadas independentemente. Um nó que não possua pais tem apenas uma linha na tabela de probabilidades, representando as probabilidades a priori de cada valor possível da variável. (RUSSELL; NORVIG, 1995).

Após os cálculos das probabilidades condicionais terem sido efetuados e o grafo já estando totalmente estruturado é possível calcular as inferências através dos conceitos do cálculo das probabilidades, tais como a regra da cadeia e o Teorema de Bayes são demonstrados (DE OLIVEIRA, 2007):

- a) Regra de cadeia: seja  $C$  um subconjunto de eventos de  $E$ , onde:  $C = C_1, C_2, \dots, C_n$ , então:

$$P(C_1 \cap C_2 \cap \dots \cap C_n) = P(C_1)P(C_2|C_1) \dots P(C_n|C_1, C_2, \dots, C_{n-1})$$

- b) Teorema de Bayes: sejam dois eventos  $A$  e  $E$  tais que  $P(A) > 0$  e  $P(E) > 0$ , então:  
 $P(A|E) = (P(E|A)P(A))/P(E)$  onde:  $P(A)$  é a probabilidade a priori do evento  $A$ .  
 $P(E|A)P(E)$  é a verossimilhança relativa da evidência  $E$ , assumindo a ocorrência do evento  $A$ .

De acordo com essas informações, pode-se concluir que uma rede Bayesiana possui distribuições condicionadas, ou seja, as probabilidades serão medidas dado que o evento que influencie o evento atual ocorra ou não. Sendo assim, nota-se uma relação de dependência nas ocorrências de eventos entre si. Porém, existe uma situação que é de suma importância, a qual é denominada condição Markoviana e que é também uma característica de RBs.

De acordo com Ross (2006), um processo possui a propriedade Markoviana desde que:  $PX_{n+1} = j | X_1 = i_1, X_2 = i_2, \dots, X_n = i_n = PX_{n+1} = j | X_n = i_n$ , ou seja, a probabilidade da variável  $X$  assumir um valor  $j$  no momento futuro não depende do passado, visto que se tenha um conhecimento do comportamento da variável no presente.

#### 2.4.1 Tabelas de Probabilidades Condicionais

As tabelas de probabilidades condicionais tendem a ter, normalmente, uma quantidade grande de entradas, mesmo em casos de nós que possuem um número reduzido de pais. Preencher tais valores pode ser algo que necessite de certa experiência, caso a relação entre nós pais e filhos seja arbitrária. Porém, na maioria dos casos, esta relação pode ser adaptada a algum padrão, facilitando o restante do trabalho. Tais casos são chamados de Distribuições Canônicas (MARQUES; DUTRA, 2000).

Um caso bastante conhecido e simples é aquele representado por nós determinísticos. Tais nós têm o seu valor determinado de forma explícita a partir dos valores dos seus pais. Por exemplo: uma relação estabelecida entre os nós pais *Italiano*, *Alemão* e *Grego* e o nó filho *Europeu* é determinado especificamente pela disjunção dos pais.

Relações onde exista incerteza podem ser chamadas de Relações com Ruídos. Dentro da lógica proposicional pode-se dizer que o estado *Febre*, é verdadeiro se e somente se *Gripe*, *Resfriado* ou *Malária* é verdadeiro. A relação *ruído* acrescenta um nível de incerteza à relação (OU), levando em conta três suposições:

- a) cada uma das causas possui uma chance independente de causar o efeito;
- b) todas as possibilidades estão listadas;
- c) o fato de uma das causas ser inibida é independente da inibição das demais. Considerando o exemplo,  $P(\text{Febre}|\text{Gripe}) = 0,4$ ,  $P(\text{Febre}|\text{Resfriado}) = 0,8$  e  $P(\text{Febre}|\text{Malária}) = 0,9$ , para tais valores, os parâmetros de ruídos serão, respectivamente, 0,6, 0,2, 0,1.

Em ocasiões em que nenhum nó pai é verdadeiro, o nó filho é falso com 100% de certeza. Se apenas 1 pai é verdadeiro, então a probabilidade do nó filho ser falso será sempre igual ao valor do ruído daquele pai que for verdadeiro. No caso de existir mais de um pai verdadeiro, a probabilidade será o valor resultante do produto do ruído dos pais (MARQUES; DUTRA, 2000).

A Tabela 2 mostra o resultado obtido para o exemplo apresentado.

#### 2.4.2 Inferência em Redes Bayesianas

Inferência em RBs diz respeito à tarefa de computar a distribuição de probabilidades a posteriori para um conjunto de variáveis de consulta. É utilizado, basicamente, quando se precisa

**Tabela 2:** Resultados obtidos

Gripe	Resfriado	Malária	P(Febre)	P( $\neg$ Febre)
F	F	F	0.0	1.0
F	F	V	0.9	0.1
F	V	F	0.98	0.2
F	V	V	0.98	$0.02 = 0.2 \times 0.1$
V	F	F	0.4	0.6
V	F	V	0.94	$0.06 = 0.6 \times 0.1$
V	V	F	0.88	$0.12 = 0.6 \times 0.2$
F	F	F	0.0	1.0

Fonte: (MARQUES; DUTRA, 2000)

atualizar ou inferir uma probabilidade de determinado evento. O processo de inferência utiliza-se de informações já existentes na própria rede, porém, para se calcular as probabilidades, é requerida a avaliação de todos os nós pertencentes a rede. Sendo assim, um dos principais problemas observados quando fala-se em inferência em RBs reside no tempo elevado necessário para se realizar uma busca exata.

Basicamente, podem ser encontrados três diferentes tipos de algoritmos voltados para a inferência de RBs (CASTILLO; GUTIERREZ; HADI, 1997):

- a) Exatos: Inferir Redes Bayesianas de forma exata consiste em um problema intratável (alta complexidade) para redes formadas por uma grande quantidade de nodos. São citados como exemplo de algoritmo que utilizam essa abordagem: Eliminação de Variáveis, Enumeração, Árvore de Junção (*Junction Tree*).
- b) Aproximados: Visando reduzir o tempo de execução em comparação com o algoritmos de inferência exata, os algoritmos de inferência aproximada fazem uma aproximação das distribuições conjuntas de algumas variáveis da rede (KOLLER; FRIEDMAN, 2009). Tais instâncias são denominadas amostras, que representam parte das probabilidades do problema. Esses algoritmos são também chamados de algoritmos de Monte Carlo, pois fornecem respostas aproximadas, cuja exatidão dependerá do número de amostras geradas.
- c) Simbólicos: Os algoritmos de inferência anteriormente descritos necessitam que a função de probabilidade conjunta do modelo seja especificada numericamente, atribuindo-se valores numéricos a todos os parâmetros (CASTILLO; GUTIERREZ; HADI, 1997). Porém, nem sempre a especificação numérica desses parâmetros é possível. Sendo assim, substitui-se os métodos numéricos por métodos simbólicos, capazes de lidar com os parâmetros sem precisar lhes atribuir valor. Normalmente, os métodos de inferência simbólica levam a soluções que se expressam como funções dos parâmetros. As respostas para as questões gerais podem ser dadas na forma simbólica em função dos parâmetros e as perguntas específicas podem ser obtidas substituindo-se os valores dos parâmetros na solução simbólica, não necessitando refazer a propagação.

## 2.5 Saúde Ubíqua – u-Health

U-Health, chamado também de telehealth ou e-Health, é considerado um método útil para gerenciar problemas relacionados a saúde. Métodos de u-Health para gerenciar ou monitorar doenças crônicas são considerados úteis para melhorar a condição de saúde e diminuir as despesas médicas (SONG; RYU; LEE, 2011). Um serviço u-Health pode ser considerado como sendo o entendimento de como construir tecnologias que melhor suportem as pessoas e mantêm sua saúde (SOHN; LEE, 2007).

As categorias de dispositivos u-Health incluem produtos ou tecnologias as quais capturam dados de contexto relacionados a saúde, armazenam dados intermediários e se comunicam com outros dispositivos. Serviços u-Health se referem a várias intervenções tecnológicas projetadas para exibir conteúdo de saúde ou orientações úteis (SOHN; LEE, 2007).

Em se tratando de aplicações, comumente, as aplicações de u-health estão distribuídas dentre as seguintes áreas: monitoramento de pacientes, gerenciamento das rotinas hospitalares e suporte ao bem-estar. A seguir são apresentados alguns trabalhos relacionados classificados entre essas áreas.

### 2.5.1 Monitoramento de Pacientes

A *Alzheimer's Disease International* estima que mais de 35 milhões de pessoas ao redor do mundo estão convivendo com Alzheimer ou algum tipo de demência relacionada, e existe a expectativa de que este número dobre nos próximos 20 anos. Aperfeiçoar e coordenar os cuidados tanto em casa quanto na comunidade é algo crítico para minimizar os efeitos do Alzheimer em indivíduos e familiares e para reduzir os custos com despesas médicas (TUNG et al., 2013).

Pacientes com Alzheimer frequentemente exibem comportamento problemático que são altamente estressantes para seus cuidadores, tais como andar sem rumo e questionamentos repetitivos. Rodríguez et al. (2012) desenvolveram auxiliares de memória externa para melhorar a consciência situacional e diminuir o estresse tanto dos cuidadores quanto dos idosos. Inicialmente focado no problema de andar sem rumo, os pesquisadores coletaram dados de campo utilizando GPS, Wi-Fi, um acelerômetro, e *tags* NFC (*Near-Field-Communication*) para capturar dados sobre localização e atividades. Dados a partir do campo de estudos foram utilizados para desenvolver um algoritmo de reconhecimento de atividade que mostra informações situacionais e fornece lembretes ou sugestões para o paciente através de um *smartphone*, computador ou tablet.

A pesquisa desenvolvida por Thoyib, Lee e Park (2011) calcula a distância dos movimentos e a velocidade utilizando dados recebidos via GPS e estabelece um sistema andador inteligente, refletindo os passos e a intensidade dos movimentos utilizando um sensor de aceleração para ajudar a manter e promover práticas saudáveis.

O exercício de andar não necessita habilidades especiais ou instalações. Possui a vantagem

de poder ser feito em todas as idades sem o perigo das lesões e dos efeitos de uma caminhada. Os benefícios incluem mudanças na forma do corpo, melhora na capacidade aeróbica e do sistema cardiovascular, flexibilidade, elasticidade muscular e aumento da densidade óssea. É também conhecido por ajudar a melhorar as habilidades cognitivas, depressão, dentre outros sintomas psicológicos.

O objetivo fundamental da pesquisa foi tratar ativamente as diversas mudanças na indústria esportiva e na área de cuidados ubíquos através da inclusão de funções as quais tornam possível o monitoramento da quantidade de exercícios durante a caminhada, usando GPS e giroscópio, sensor de aceleração e também tomar medidas adequadas para as tendências de mercado, tais como a elaboração de produtos de avaliação e a inclusão de função para satisfazer as necessidades dos usuários.

A sociedade moderna está mudando de um ambiente de bem-estar passivo baseado na prevenção para manter e promover o tratamento de saúde baseado em cuidados médicos com base no tratamento de doenças. Sendo assim, a necessidade para manter e promover sistemas para a saúde individual em um ambiente ubíquo está crescendo. Por esse motivo, esse sistema insere tecnologia ubíqua á função do passometro, o qual é frequentemente utilizado no monitoramento de caminhadas. Divergindo do passometro existente, o qual simplesmente conta os passos para calcular a quantidade exata de exercícios adequados para o exercício de caminhada, ele pode precisamente calcular a quantidade de exercícios do usuário. O sistema desenvolvido para essa pesquisa pode ser utilizado como um modelo nacional de serviços de promoção da saúde para o desenvolvimento futuro de um sistema de u-Health, empresa de serviços e serviços ubíquos para o bem-estar.

## 2.5.2 Gerenciamento de Rotinas Hospitalares

As aplicações voltadas a hospitais buscam melhorar as rotinas de médicos e enfermeiros, a colaboração que eles exercem uns com os outros, a prescrição de medicamentos e as cirurgias e emergências do dia-a-dia. O trabalho de uma equipe de profissionais de um hospital é um desafio para a pesquisa na área de computação pervasiva em diferentes formas. Médicos precisam controlar um grande volume de dados compartilhados, tais como registros de pacientes e raios-x. Seu ambiente é agitado, sendo assim eles precisam memorizar algumas atividades paralelas pendentes e necessitam acessar rapidamente dados relevantes para alternar dentre as diferentes situações de trabalho enquanto mantêm sigilosos os dados médicos sensíveis (BARDRAM; CHRISTENSEN, 2007).

Em resposta a esses desafios, Bardram (2005) desenvolveram uma pesquisa sobre computação baseada em atividades, as quais permitem aos usuários organizar seu controle sobre os serviços dos dispositivos, e dados em termos de atividades computacionais que facilitem recriar, compartilhar e rapidamente alterar o contexto computacional do dispositivo que se tiver a mão de acordo com a demanda. Tal abordagem se mostra interessante e adequada, à me-

dida que, normalmente, o trabalho dos profissionais da área de saúde não é tão convencional e a busca por dados e outras informações relativas a pacientes e a utilização de aplicações de software convencionais demanda tempo excessivo e sobrecarrega o profissional.

Um outro exemplo bastante pertinente refere-se ao estudo de caso Orwat et al. (2010), que consiste de um PDA conectado a um leitor de cartões do paciente que se comunica com um celular. O sistema apoia o diagnóstico de doença cardiovascular através de um *checklist* estruturado. Os paramédicos verificam e informam vários indicadores de problemas neurológicos, tais como atraso na fala ou nos movimentos, de forma guiada através do sistema. Baseando-se nesses dados, o sistema calcula a probabilidade de uma doença cardiovascular.

Se uma doença cardiovascular é indicada, o sistema inicia um alerta e recomenda a admissão imediata do paciente para um hospital especializado e envia todos os dados relevantes incluindo o protocolo de emergência para o hospital via tecnologias de rede *wireless*. Quando os dados do novo paciente chegam no hospital, o servidor Stroke Angel dispara um alerta, o qual permite que os médicos se preparem para o tratamento de doenças cardiovasculares enquanto o paciente ainda está a caminho. O sistema automaticamente gera um novo registro eletrônico para o paciente no sistema do hospital com base nos dados do paciente do Stroke Angel e após a confirmação pela recepção.

### 2.5.3 Suporte ao Bem-Estar

Aplicações voltadas ao bem-estar dizem respeito àquelas que têm como objetivo o gerenciamento pessoal de saúde de uma forma geral (controle de medicamentos, atividades físicas, monitoramento das taxas sanguíneas, etc).

A aplicação COACH (*Cognitive Orthosis for Assisting with aCtivities in the Home*) desenvolvida por Mihailidis et al. (2008) é uma aplicação destinada a ajudar usuários com suas atividades diárias. O sistema ajuda pessoas que sofrem de demência desempenhando certas tarefas, tais como lavar as mãos. O sistema utiliza uma câmera de vídeo para identificar a posição das mãos e os objetos da tarefa – tais como sabão ou toalha – para inferir o estado da atividade e oferecer alertas apropriados.

Seppala, Nykanen e Ruotsalainen (2012) desenvolveram uma pesquisa para o suporte ao bem-estar cujo objetivo era criar uma ontologia confiável sensível ao contexto para o gerenciamento pessoal de saúde ao longo da vida e um modelo de arquitetura para o uso confiável de informações de múltiplas fontes distintas. Como resultado dessa pesquisa, foi desenvolvido um modelo de informação de alto nível que descreve os principais conceitos e alguns relacionamentos relacionados ao bem estar pessoal. O modelo descreve o domínio do bem estar pessoal em mais detalhes que outros modelos que foram desenvolvidos em clínicas e centros de aconselhamento psicológico. Tais modelos anteriores permanecem generalistas, enquanto fomos mais fundo no domínio do bem estar pessoal através de definição de mais conceitos, relacionamentos e propriedades. A intenção é apoiar o desenvolvimento de uma ontologia pessoal de

gerenciamento do bem estar e um modelo de arquitetura para o uso confiável de informações heterogêneas de múltiplas fontes.

## 2.6 Modelos de Cuidados para Doenças Crônicas

Consideradas como epidemia na atualidade, as DCNTs constituem sério problema de saúde pública, tanto nos países ricos quanto nos de média e baixa renda. Não obstante, é certo que estes últimos sofrem de forma tanto mais acentuada quanto menor suas possibilidades de garantir políticas públicas que alterem positivamente os determinantes sociais de saúde (SAÚDE, 2008). Além disso, o número de pessoas com doenças crônicas está crescendo a taxas surpreendentes devido ao rápido envelhecimento da população e a maior longevidade das pessoas com muitas condições crônicas (WAGNER et al., 2001).

Segundo a OMS (ORGANIZATION et al., 2005) referem-se a conjuntos de doenças que têm fatores de risco em comum aquelas que exigem cuidado integral para doenças cardiovasculares, doenças respiratórias crônicas, neoplasias e a diabetes mellitus e, portanto, podem contar com uma abordagem comum para sua prevenção. Apesar das diferenças clínicas entre essas condições crônicas, cada doença confronta pacientes e seus familiares com as mesmas necessidades: alterar seu comportamento para lidar com os impactos sociais e emocionais dos sintomas, deficiências e aproximação da morte; tomar medicamentos e interagir com cuidados médicos todo o tempo. Em troca, a assistência médica deve garantir que os pacientes recebam os tratamentos para controlar doenças e minimizar os sintomas, bem como a informação e o apoio necessários para o auto gerenciamento de sua saúde e, em muitas instâncias, sua morte (WAGNER; GROVES, 2002).

A incidência de DCNTs tem se expandido devido em grande parte a fatores de risco modificáveis, tais como altos níveis de colesterol, alta pressão arterial, obesidade, falta de atividade física, alimentação pouco saudável, tabagismo e o consumo inapropriado de álcool. Esses fatores resultam em várias doenças a longo prazo, culminando em altas taxas de mortalidade atribuídas a acidente vascular cerebral, ataque cardíaco, tabagismo, doença pulmonar obstrutiva e muitas outras (PUOANE et al., 2008). Partindo do princípio de que tais doenças não podem ser tratadas da mesma forma que quadros agudos, onde não há a necessidade de cuidados de longo prazo e o paciente se envolve pouco com a sua própria doença, foram propostos alguns modelos de cuidados e gerenciamento de condições crônicas que possuem o intuito de padronizar e elencar as ideias e ações de sucesso no controle de tais doenças.

Os modelos de cuidados para doenças crônicas são sistemas lógicos que organizam o cuidado, articulando as relações entre a população e suas subpopulações estratificadas por riscos, os focos das intervenções do sistema de atenção à saúde e os diferentes tipos de intervenções sanitárias (LANDIM, 2012 apud MENDES, 2010).

Dentre os modelos de atenção à saúde aplicados às condições crônicas pode-se mencionar: o Modelo da Pirâmide de Risco (JESTER, 2008), Modelo de Atenção Crônica (WAGNER, 1997),

e o Modelo de Determinação Social da Saúde (DAHLGREN; WHITEHEAD, 1991). Destacam-se, porém, entre os modelos conhecidos atualmente, o modelo CCM – *Chronic Care Model* (WAGNER et al., 2001) e o modelo CICC – Cuidados Inovadores para Condições Crônicas (SAÚDE, 2003).

Atualmente, o modelo CCM é utilizado e aceito amplamente em diversos países do mundo. Resultados de evidências científicas internacionais mostraram que a aplicação do modelo resultou em melhorias nos cuidados e nos resultados em saúde (LANDIM, 2012), sendo parte deles publicados por pesquisadores que participaram ativamente da sua concepção (BODENHEIMER; WAGNER; GRUMBACH, 2002; DORR et al., 2006; GILMER et al., 2006; GILMER; O'CONNOR, 2003; GLASGOW et al., 2005). Já o modelo CICC, sendo uma expansão importante e reconhecida do modelo CCM em países de alta condição socioeconômica, foi estudado e avaliado por Singh e Ham (2006) na Universidade de Birmingham, Inglaterra, onde encontraram evidências de melhorias em alguns processos e resultados sanitários, porém não obtiveram fortes evidências do valor do foco nas políticas de saúde.

### 2.6.1 Modelo CCM – *Chronic Care Model*

O modelo CCM (*Chronic Care Model*) tem como objetivo descrever as melhores práticas que contribuem nas atividades de gerenciamento de doenças e, sobretudo, aquelas que têm como objetivo aprimorar a interação entre provedores de saúde e pacientes. O modelo CCM pode ser considerado um guia para melhorar os cuidados com doenças crônicas que é consistente com a literatura existente até então e útil a diversas organizações que desejam melhorar o atendimento de seus pacientes com doenças crônicas.

O CCM é uma síntese de mudanças baseadas em evidências de sistemas que tem como objetivo ser um guia para melhorar a qualidade e o gerenciamento de doenças. O CCM não é uma teoria explanatória. Isto é, como uma diretriz baseada em evidências, simplesmente uma síntese das melhores evidências disponíveis. Ele destina-se a ser flexível e sujeito a mudanças quando novas evidências surgirem. O modelo retrata o sistema de saúde como parte de uma comunidade maior e a equipe médica como parte da organização de saúde. O gerenciamento efetivo de doenças crônicas requer um sistema de entrega organizado e conectado com recursos complementares da comunidade e que estão disponíveis fora da organização. O CCM representa as melhorias para a organização e as práticas que contribuem para interações produtivas entre provedores e pacientes.

O modelo CCM é constituído fundamentalmente por cinco componentes principais:

- Comunidade: corresponde aos pontos de conexão entre os pacientes e o sistema de saúde, tendo também o papel de intervir em políticas de saúde que beneficiem a comunidade como um todo.
- Sistema de Saúde: assegura que os médicos tenham capacidade de oferecer suporte aos

pacientes. O Sistema de Saúde subdivide-se em outros três elementos do modelo CCM:

- Suporte ao autogerenciamento: provimento das condições necessárias de forma que o paciente entenda seu tratamento e fique engajado;
- Projeto de sistema de entrega: delegar as atividades entre os componentes da equipe de cuidados e definir papéis e responsabilidades entre os membros.
- Suporte a Decisão: métodos utilizados para orientar o paciente, de forma que o seu autogerenciamento obtenha sucesso.

### 2.6.2 Modelo CICC – Cuidados Inovadores para Condições Crônicas

O modelo denominado Cuidados Inovadores para Condições Crônicas (CICC) (Figura 3), insere-se em um contexto político abrangente que envolve os pacientes e suas famílias, as organizações de saúde e as comunidades. O ambiente político é responsável pela regulamentação, liderança, integração política, parcerias, financiamento e alocação de recursos humanos que permitem às comunidades e organizações de saúde ajudarem os pacientes e suas famílias no tratamento das condições crônicas. O modelo CICC divide seus componentes em três níveis de abrangência, classificados em micro, meso e macro, partindo do pressuposto que para obter sucesso o modelo de cuidado crônico deve abranger todos os níveis que envolvem desde o paciente até o nível governamental, responsável pela criação de políticas de saúde.

O modelo CICC intensifica a função dos pacientes e das famílias e os vincula à suas respectivas comunidades e a organizações de saúde. No **nível micro** temos a tríade que se encontra no centro do modelo e é formada pelo paciente e familiares, pelo grupo de apoio da comunidade e pela equipe de atenção à saúde. Essa tripla parceria é peculiar ao tratamento das condições crônicas. Enquanto é possível obter resultados favoráveis para problemas agudos com um único prestador de serviço, somente se alcançam resultados positivos para as condições crônicas quando os pacientes e suas famílias, o grupo de apoio da comunidade e as equipes de atenção à saúde são informados, motivados, capacitados e trabalham em parceria.

No **nível meso** estão organizadas as comunidades e organizações de saúde que apoiam a tríade. As organizações de saúde, por sua vez, devem coordenar o tratamento do paciente, ofertar recursos de trabalho para os profissionais de saúde. Já a comunidade deve promover campanhas de saúde e prover recursos básicos de tratamento para doenças crônicas. No que diz respeito ao **nível macro**, as políticas são meios poderosos de organizar os valores, princípios e estratégias gerais dos governos ou divisões administrativas para reduzir a carga das condições crônicas. A partir de políticas e planos formulados adequadamente, os tomadores de decisão e os planejadores podem causar um impacto significativo sobre a saúde da população. Para otimizar os cuidados para as condições crônicas, é essencial existir um ambiente político favorável.

Figura 3: Modelo CICC



Fonte: (SAÚDE, 2003)

### 2.6.3 Considerações entre as características dos modelos

Em ambos os modelos de cuidados de doenças crônicas percebe-se claramente a ênfase dada ao fato de tanto o paciente portador da doença, quanto seus familiares estarem plenamente cientes e conhecedores do tratamento requerido para a obtenção de melhores resultados e um melhor gerenciamento. Além disso, a integração entre as comunidades e as entidades de saúde cumpre papel fundamental no tratamento, a medida que novas políticas e projetos de auxílio ao controle de doenças vão sendo necessários para aprimorar os cuidados com os doentes crônicos.

## 2.7 Fatores de Risco

Um dos principais aspectos que deve ser levado em consideração quando do correto gerenciamento e controle de DCNTs diz respeito ao controle dos fatores de risco que, por sua vez, podem ser classificados em “não modificáveis” (sexo, idade e herança genética) e “comportamentais” (tabagismo, alimentação, inatividade física, consumo de álcool e outras drogas). Os fatores de risco comportamentais são potencializados pelos fatores condicionantes socioeconômicos, culturais e ambientais. Considerando-se o cenário contemporâneo, no qual a competitividade e o individualismo são privilegiados como modos de existir e de se relacionar, são potencializadas as ações dos fatores de risco associados ao sedentarismo, à alimentação com excesso de gorduras, açúcares e sal, ao consumo de tabaco, ao uso abusivo de álcool e outras drogas e às atitudes violentas na mediação de conflitos. Ao mesmo tempo, reduz-se a ação dos fatores protetores, tais como: o acesso ampliado a alimentos *in natura* e de melhor qualidade

nutricional, a existência de redes de suporte social e de espaços públicos seguros e facilitadores de interação social por meio de práticas esportivas e culturais, bem como o desenvolvimento de ferramentas não violentas para a mediação de conflitos, entre outros (SAÚDE, 2008).

A experiência de outros países mostra que o sucesso das intervenções de saúde pública, no que se refere à redução dos fatores de risco e da prevalência das DCNTs, é maior à medida que sejam realizadas de maneira integrada e abrangente as ações de promoção da saúde e de prevenção de DCNTs e seus fatores de risco. Trabalha-se, portanto, com a produção de informações e análises da situação de saúde, com o planejamento de ações vinculadas a determinado cenário e específica população, com a implementação de estratégias setoriais e intersetoriais e com a sua avaliação, operando um cuidado integral das DCNTs e seus fatores de risco.

Ao se tomar como foco o cuidado integral das DCNTs, entende-se que o eixo da promoção da saúde é fundamental para a construção de intervenções que atuem nos fatores de risco e proteção. Assim, por exemplo, considerando-se como fator de risco o sedentarismo, trata-se de prover informação qualificada à população quanto aos benefícios das práticas corporais, garantir acesso à orientação de profissionais da saúde e, ao mesmo tempo, trabalhar intersetorialmente pela existência de espaços públicos acessíveis e seguros para a prática de atividades físicas e do lazer.

O aumento da incidência de diabetes em países em desenvolvimento é particularmente preocupante. Essa condição crônica é o principal fator de risco para cardiopatia e doença cerebrovascular e, normalmente, ocorre associada à hipertensão - outro importante fator de risco para problemas crônicos. Os países em desenvolvimento contribuem com 3/4 da carga global de diabetes. Em 1995, havia 135 milhões de diabéticos; as projeções indicam que esse número irá atingir 300 milhões no ano 2025. Tudo indica que a Índia terá um aumento duas vezes maior (SAÚDE, 2003).

Fatores de risco modificáveis para outras condições crônicas, tais como cardiopatias, doença cerebrovascular, HIV/AIDS e câncer, são também bastante conhecidos. Em verdade, o estilo de vida e o comportamento são elementos determinantes para essas patologias, pois podem prevenir, iniciar, ou agravar esses problemas e as complicações decorrentes. Comportamentos e padrões de consumo não saudáveis implicam de forma predominante no surgimento das condições crônicas. Tabagismo, ingestão excessiva de alimentos não saudáveis, sedentarismo, abuso de bebidas alcoólicas, práticas sexuais de alto-risco e estresse social descontrolado são as principais causas e fatores de risco para as condições crônicas. Infelizmente, o mundo está passando por uma transformação incontestável em virtude desses comportamentos prejudiciais à saúde (SAÚDE, 2003, 2008). Outros fatores de risco de doenças crônicas incluem agentes infecciosos que são responsáveis por câncer cervical e câncer de fígado, e alguns fatores ambientais como a poluição do ar, os quais contribuem para um conjunto de doenças crônicas, incluindo asma e outras doenças respiratórias crônicas (ORGANIZATION et al., 2005).

Mudanças não saudáveis nos hábitos alimentares, sedentarismo e uso crescente de drogas ilícitas podem parecer de menor importância frente aos danos causados pelo fumo. Não obs-

tante, essas mudanças negativas no estilo de vida estão se propagando no mundo e devem ser tratadas com extrema seriedade no que concerne aos problemas crônicos de saúde. Todos esses comportamentos prejudiciais mencionados acima são reconhecidos como fatores de risco para uma variedade de problemas crônicos, incluindo doença cardiovascular, diabetes e derrame.

## 2.8 Modelo UDirector

O modelo UDirector (DAMASCENO VIANNA; BARBOSA, 2014; VIANNA, 2013) é um modelo para cuidados ubíquos de DCNTs. Fundamentalmente, o foco aqui será dado aos conceitos que compõem o modelo, tais como o *middleware* ConnDirector e o módulo executável ChronicDirector, que é um assistente pessoal que tem como foco o gerenciamento e prevenção de DCNT. Além disso, serão apresentados outros elementos que fazem parte do modelo UDirector e que foram escolhidos por se tratarem de elementos básicos que serão utilizados pelo modelo de predição. Por se tratar de um modelo ubíquo para DCNT, o UDirector oferece em conjunto com o assistente pessoal ChronicDirector, acesso a trilhas coletadas e armazenadas, além do *middleware* ConnDirector, que disponibiliza um conjunto de funcionalidades importantes ao modelo proposto, possibilitando que ele atue como sendo um módulo executável integrado diretamente ao UDirector.

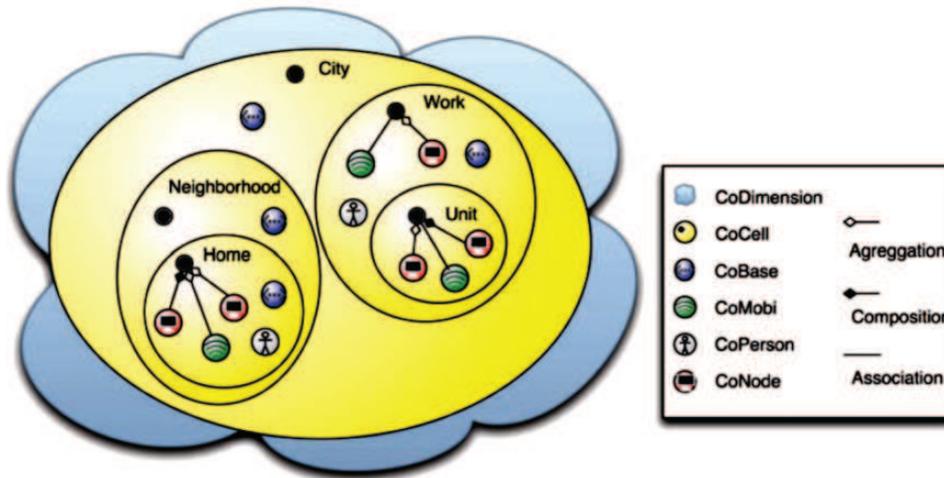
### 2.8.1 Organização dos Elementos

O modelo organizacional dos elementos do UDirector se inspira no modelo de abstração de entidades utilizados pelo Continuum (COSTA et al., 2009). O modelo Continuum é composto, basicamente, por sete entidades, CoDimension, CoCell, CoNode, CoBase, CoMobi, CoGadet e CoPerson, os quais se relacionam através de associações, composições ou agregações, podendo representar, mesmo que de forma abstrata, um modelo do mundo físico. A Figura 4 demonstra um exemplo de entidades do Continuum.

A **CoDimension** é uma super-entidade, que engloba todas as outras entidades existentes no modelo. Uma entidade **CoCell** representa uma localização física (por exemplo, uma cidade). As entidades **CoNode** e **CoMobi** representam dispositivos que executam os serviços do modelo Continuum, sendo eles distintos pois, CoNodes representam entidades fixas e CoMobis entidades móveis. A entidade **CoBase** é um dispositivo encarregado pelo gerenciamento de uma CoCell, ou um grupo de CoCells dependentes a esta CoCell, e pela interação entre as CoCells. A entidade **CoGadet** representa um dispositivo pessoal, tal como um *smartphone* ou tablet. **CoPerson** representa um usuário do sistema Continuum presente em alguma CoCell.

No modelo UDirector foram criados seis tipos de elementos: **Mundo**, **Nodo Local (NL)**, **Nodo Pessoal (NP)**, **Serviço de Resolução de Posição <-> Nodo Local (SRP-NL)**, **Contexto** e **Recursos**, onde o elemento denominado Mundo corresponde à infraestrutura de rede utilizada para efetuar a comunicação entre o SRP-NL, NLs e NPs (DAMASCENO VIANNA;

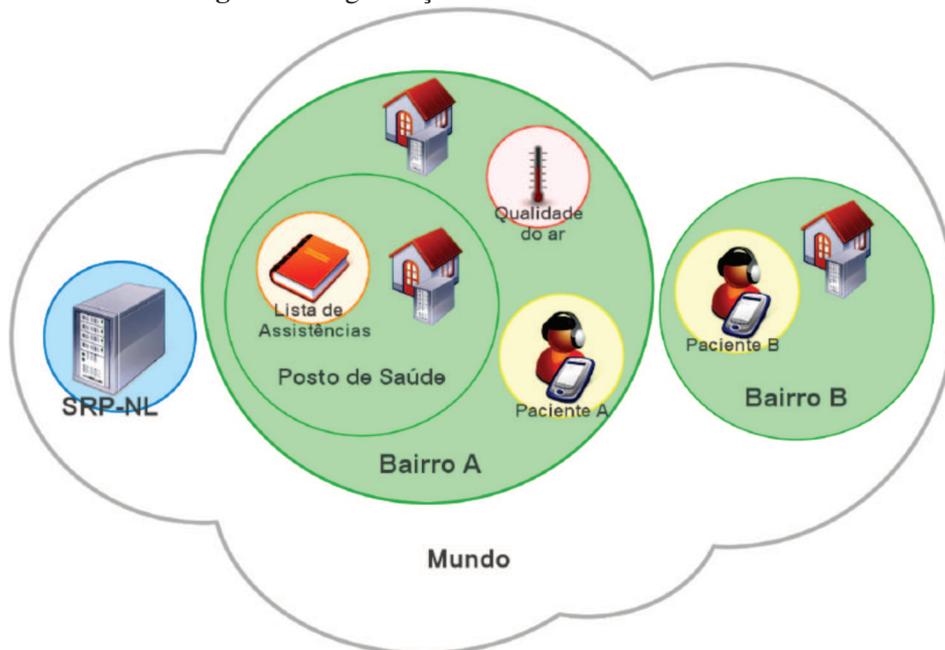
**Figura 4:** Exemplo de modelo de entidades do Continuum



Fonte: (COSTA et al., 2009)

BARBOSA, 2014). A Figura 5 mostra a organização dos elementos do UDuctor.

**Figura 5:** Organização dos elementos do UDuctor



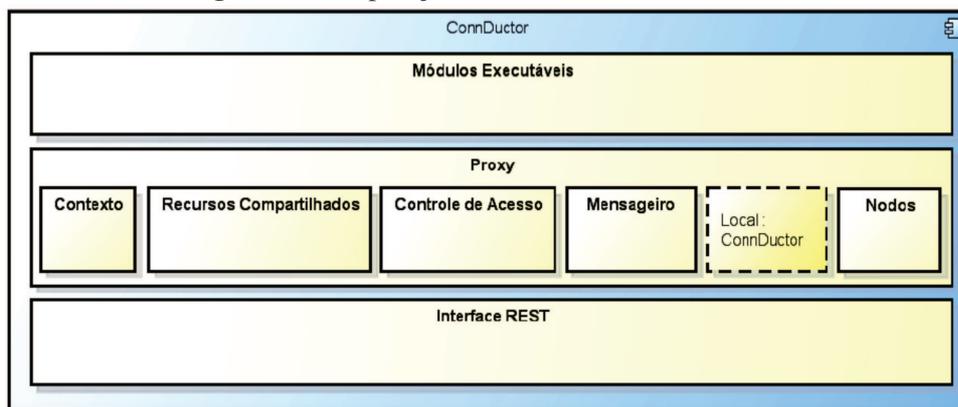
Fonte: (VIANNA, 2013)

## 2.8.2 Middleware ConnDuctor

Em conjunto com o modelo UDuctor, Damasceno Vianna e Barbosa (2014) desenvolveram um *middleware* cujo papel é disponibilizar funções de comunicação, notificações de eventos de alteração de contextos, localização de recursos disponíveis, além de mecanismos para controle de acessos a determinados recursos. O *middleware* ConnDuctor é constituído, fundamental-

mente, por nove componentes: Contexto, Módulos Executáveis, Proxy, Controle de Acesso, Recursos Compartilhados, Local, Mensageiro, Interface REST e Nodos (DAMASCENO VIANNA; BARBOSA, 2014). A Figura 6 mostra a organização dos componentes dentro do *middleware* ConnDuctor.

**Figura 6:** Composição do middleware ConnDuctor



Fonte: (VIANNA, 2013)

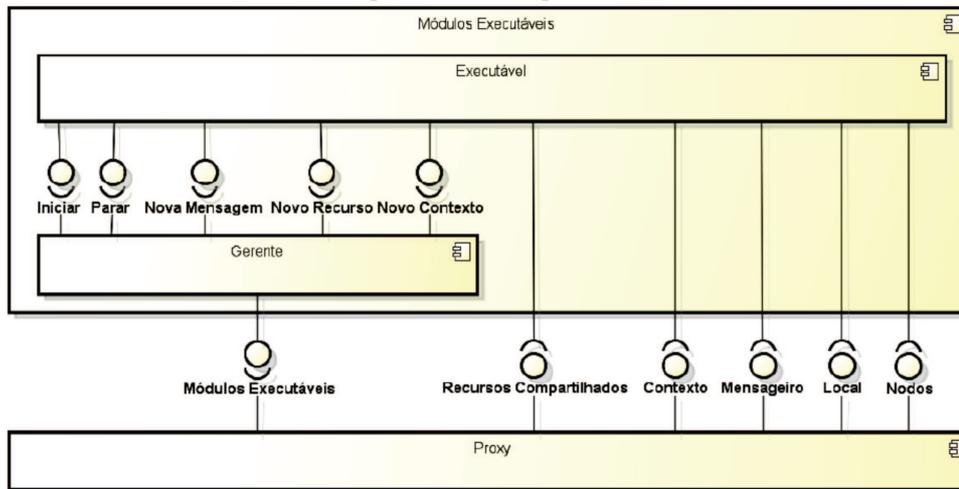
O modelo ChronicPrediction funcionará integrado ao UDUCTOR e com o *middleware* ConnDuctor. Sendo assim, serão abordados em mais detalhes os componentes do ConnDuctor que efetivamente serão utilizados pelo modelo de predição, seja de forma direta ou indireta.

- **Módulos Executáveis:** o componente de módulos executáveis permite a utilização de recursos do *middleware* ConnDuctor através de módulos criados por desenvolvedores e registrados no *middleware*. Tais módulos estão aptos a receber as notificações do *middleware*, conforme segue: mensagens recebidas pelo nodo; criação, alteração e exclusão de recursos compartilhados; e alterações de contextos. Além disso, os módulos executáveis podem acessar as funcionalidades dos Recursos Compartilhados, componentes de Contexto, Controle de Acesso, Mensageiro, Nodos e Local (DAMASCENO VIANNA; BARBOSA, 2014).

A Figura 7 mostra um diagrama de componentes que apresenta a arquitetura do componente de Módulos Executáveis, que é formado por um componente denominado **Gerente** e por instâncias do componente **Executável**. O Gerente tem por função iniciar os Executáveis e avisá-los sobre a ocorrência de novos recursos, mensagens ou contextos recebidos pelo *middleware*. Os Executáveis terão a possibilidade de acessar os Contextos, Recursos Compartilhados, Mensageiro, Local e Nodos através do componente Proxy.

- **Contexto:** o componente de Contexto possibilita aos módulos do *middleware* e clientes informarem seu interesse nos atributos / características que identificam o estado de um nodo em específico, e receberem notificações quando tais atributos forem alterados. Quando o nodo representar uma pessoa, por exemplo, tais atributos poderiam ser o índice

**Figura 7:** Componente de Módulos Executáveis - arquitetura



Fonte: (VIANNA, 2013)

glicêmico ou a taxa de colesterol, desde que esses dados sejam compartilhados pela pessoa. Outro aspecto importante em relação a este módulo é a capacidade dele armazenar informações geradas ou recebidas pelo nodo e que são referentes ao contexto. Sendo assim, o nodo guarda um histórico desses contextos, possibilitando que as aplicações pelo *middleware* executadas antecipem situações que um usuário possa enfrentar através da inferência desses dados históricos.

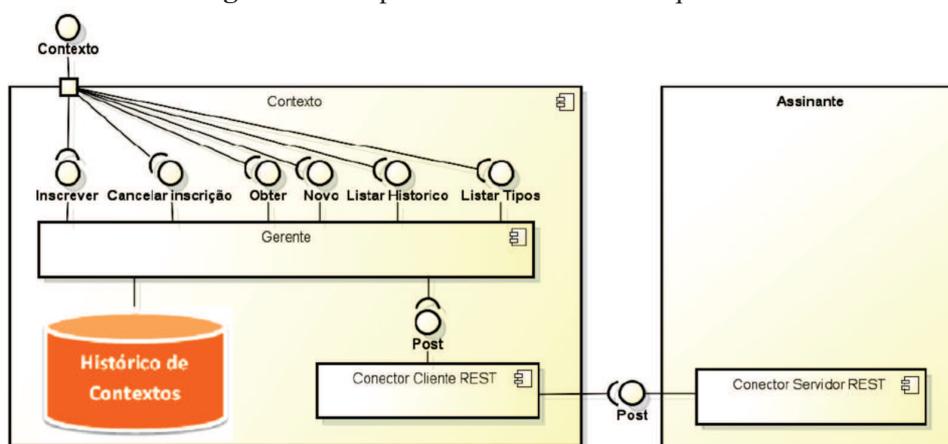
No modelo UDuctor o componente de Contexto age como um agregador, o qual tem como função principal receber novas informações de contexto que são enviadas através de *widgets*. Os componentes **Gerente** e **Conector Cliente REST** integram o componente de Contexto, conforme a Figura 8. O **Gerente** tem, dentre suas principais tarefas: gerenciar inscrições (contextos) de clientes; armazenar informações de contextos que forem recebidas através dos *widgets* de entrada de dados no repositório de Histórico de Contextos, além de enviar notificações a respeito de troca de contextos aos assinantes. O envio das notificações é feito por meio de um **Conector Cliente REST**.

### 2.8.3 ChronicDuctor

O ChronicDuctor (DAMASCENO VIANNA; BARBOSA, 2014) é um assistente de saúde pessoal que tem como objetivo principal o gerenciamento e a prevenção de DCNTs. O assistente executa a partir de um NP como sendo um módulo executável do *middleware* ConnDuctor.

O ChronicDuctor tem como objetivo atingir cinco requisitos principais: suportar a criação de planos de cuidado, notificar eventos, recomendar recursos de interesse, ler indicadores de saúde e oferecer suporte para a comunicação entre pessoas. Tais requisitos são descritos com um nível maior de detalhes conforme segue:

**Figura 8:** Componente de Contexto - arquitetura



Fonte: (VIANNA, 2013)

- **Suportar a Criação de Planos de Cuidado:** tem como função garantir que médicos, educadores corporais e nutricionistas possam criar planos que devem ser seguidos pelos pacientes, com o intuito de controlar e prevenir as DCNTs (DAMASCENO VIANNA; BARBOSA, 2014);
- **Recomendar Recursos:** consiste em apresentar oportunidades aos pacientes, de acordo com o contexto ao qual estão inseridos. Como exemplo, pode-se apresentar dois locais onde o paciente possa fazer uma refeição adequada às suas necessidades;
- **Notificar Eventos:** atua como um guia para que o paciente possa seguir o controle e o tratamento da sua doença, utilizando para isso o planejamento definido pelos educadores corporais e médicos;
- **Ler Indicadores:** permite a observação dos dados do paciente os quais são lidos através de instrumentos, tais como um glicosímetro, balanças, etc;
- **Suportar Comunicação entre Pessoas:** deve possibilitar a comunicação entre pacientes, cuidadores e médicos, como forma de ajudá-los na execução de suas atividades.

## 2.9 Considerações sobre o capítulo

O capítulo expôs os principais aspectos e conceitos que norteiam e definem a computação ubíqua, bem como a aplicação da ubiquidade em cenários da área da saúde, sobretudo, em temas relacionados às rotinas médicas e às DCNTs. Dentro da computação ubíqua os dispositivos computacionais passam a ser imperceptíveis e integrados ao contexto nos quais estão inseridos e de forma totalmente distribuída, utilizando-se, principalmente, de dispositivos móveis e computação embarcada. Conforme visto, a aplicabilidade da computação ubíqua dentro da área da

saúde recebe o nome de u-Health, que está direcionado a monitorar e gerenciar as saúde das pessoas, incluindo aquelas pessoas com doenças crônicas.

Monitorar a saúde dos pacientes em condições fora do hospital tem sido de interesse dos pesquisadores e médicos há bastante tempo e pesquisas na área de u-Health estão ganhando cada vez mais espaço, principalmente devido a franca expansão do uso de dispositivos móveis. O próximo capítulo apresenta trabalhos na área de u-Health que utilizam RBs para efetuar predições.

Além disso, é apresentado um panorama geral sobre a arquitetura e o funcionamento do modelo UDUCTOR, tendo como foco o *middleware* ConnDUCTOR e o módulo ChronicDUCTOR. A forma como é organizado o modelo UDUCTOR permite que novos módulos executáveis sejam desenvolvidos e utilizem a arquitetura já existente como base, o que faz com que o modelo ganhe em versatilidade e adaptabilidade. O bom entendimento dos conceitos básicos aqui apresentados são importantes para a apresentação do módulo ChronicPrediction, que será integrado no modelo UDUCTOR.

### 3 TRABALHOS RELACIONADOS

Dados históricos de contextos (*context history*) em conjunto com RBs têm sido utilizados para os mais diferentes fins. Na identificação de pontos importantes (*landmarks*) em *logs* gerados por dispositivos móveis (HWANG; CHO, 2009); na predição de contextos futuros, sobretudo a localização futura (LEE; LEE, 2012); na predição do tempo de permanência e a localização futura dentro de diferentes salas em um ambiente fechado (*indoor*) (PETZOLD et al., 2005), além da construção de modelos de apoio à tomada de decisão que oferecem a capacidade de predições de contextos futuros de acordo com características como período do dia e localização atual (LEE; CHO, 2012).

Além da sua utilização de forma generalista, as RBs são utilizadas dentro da área médica, em especial, nas atividades de prognóstico de doenças e acompanhamento de rotinas diárias, principalmente nos casos em que o paciente sofre de alguma DCNT, como por exemplo, sistema de tomada de decisão para pessoas de meia idade e idosas fazerem em sua própria casa a auto predição de diabetes tipo-2 (GUO; BAI; HU, 2012), modelos preditivos para identificar a progressão de doença pulmonar crônica em pacientes com asma (HIMES et al., 2009), métodos de construção de modelos de prognósticos para predizer síndrome metabólica (PARK; CHO, 2012).

Esta seção apresenta sete trabalhos, os quais possuem como foco a utilização de dados históricos de contextos em conjunto com RBs em ambientes ubíquos e/ou a utilização de RBs na área médica para prognóstico de doenças.

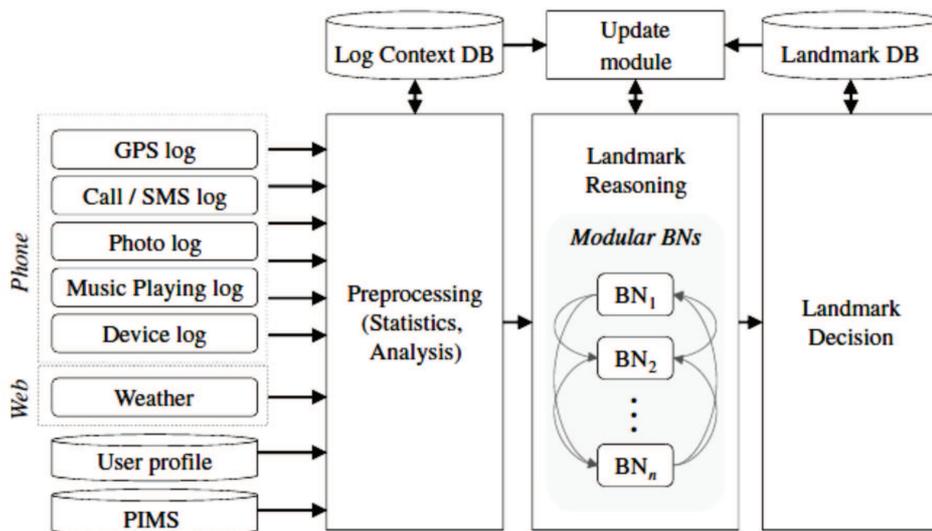
#### 3.1 Método de análise de *logs* móveis utilizando um modelo modular de RB

Ambientes móveis têm mostrado potencial em termos de oferecer serviços customizados para usuários, pois esses ambientes podem gravar informações significativas e privadas continuamente e por um longo período de tempo. Até agora, a maioria dessas informações foi geralmente ignorada devido as limitações dos dispositivos móveis em termos de potência, capacidade de memória e velocidade. Hwang e Cho (2009) propuseram um método de analisar *logs* gerados por dispositivos móveis de forma efetiva, extraindo informação semântica e dados históricos de pontos mais importantes, os quais podem ser utilizados de formas especiais para ajudar a recordar funções específicas. O modelo proposto utiliza um método cooperativo de raciocínio com uma RB modular a fim de trabalhar de forma competente em ambientes móveis.

Trabalhos relacionados mostraram que a abordagem probabilística Bayesiana foi uma boa ferramenta para controlar, raciocinar e combinar informações de incerteza. Para grandes domínios, as RBs convencionais e os métodos de aprendizado de RBs exigem computação altamente complexa. Isso é um problema crucial quando se modela situações da vida diária com dispositivos móveis. Para superar esses problemas, uma abordagem mais apropriada foi requerida para reduzir os níveis de complexidade.

Dentro do modelo proposto (Figura 9), vários logs de dados móveis são processados primeiramente, e então o módulo de raciocínio de pontos de referência detecta os pontos importantes. O módulo de pré-processamento é operado por técnicas de reconhecimento de padrões e raciocínio simples de regras. O módulo de raciocínio de Redes Bayesianas desempenha a inferência probabilística. O módulo de atualização aprende os modelos de Redes Bayesianas e adapta para o usuário e o ambiente usando os dados acumulados. O módulo desenvolvido foi aplicado em diversos experimentos usando tantos dados sintéticos quanto dados reais de logs mobile coletados via um smartphone durante o período de 1 mês.

**Figura 9:** Processo de extração de pontos importantes a partir de logs mobile



Fonte: (HWANG; CHO, 2009)

Durante a avaliação, introduziu-se o modelo modularizado de Rede Bayesiana para operações eficientes em ambientes mobile, e foi proposto o método de inferência em 2 etapas aplicando o conceito de nodo virtual, e então aprendendo as BNs modulares automaticamente a partir do conjunto de dados de treinamento. Nos resultados experimentais com dados artificiais e reais de logs, os pontos de referência pretendidos foram bem extraídos e o método proposto foi capaz de reduzir o nível de complexidade.

### 3.2 Predição de contextos em ambientes ubíquos utilizando RB Dinâmica

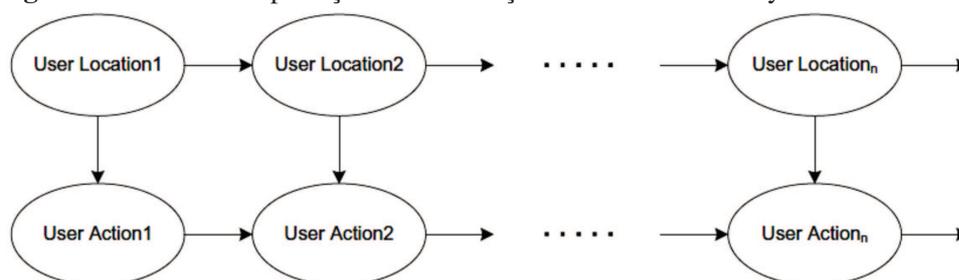
Sistemas ubíquos de apoio a tomada de decisão exigem mais mecanismos inteligentes no quais o suporte a decisões de forma mais oportuna e precisa está disponível. Contudo, sistemas convencionais sensíveis ao contexto, os quais tem se tornado populares na área de sistemas ubíquos de apoio a tomada de decisão, não podem fornecer um apoio a tomada de decisão muito ágil e proativo.

Lee e Lee (2012) propuseram um novo conceito de mecanismo de predição de contextos no qual os dispositivos ubíquos de apoio a tomada de decisão estão aptos a prever o contexto

futuro dos usuários antecipadamente. Especialmente, predição de localização é útil devido ao fato de que sistemas ubíquos de apoio a tomada de decisão podem se adaptar dinamicamente seu conteúdo de tomada de decisão para um usuário baseado na localização futura de um usuário.

O mecanismo desenvolvido apresenta uma abordagem indutiva para reconhecer a localização de um usuário através do aprendizado do modelo de uma Rede Bayesiana Dinâmica. O modelo de Rede Bayesiana Dinâmica foi avaliado com um conjunto de dados contextuais de estudantes de graduação (Figura 10).

**Figura 10:** Modelo de predição de localização com uma Rede Bayesiana Dinâmica



Fonte: (LEE; LEE, 2012)

A avaliação dos resultados sugere que um modelo de Rede Bayesiana Dinâmica oferece um poder de predição significativo na predição de localização. Além disso, descobriu-se que um modelo de Rede Bayesiana Dinâmica possui um ótimo potencial para outros tipos de sistemas ubíquos de apoio a tomada de decisão.

Predição de contextos é um problema importante nos ambientes de computação ubíqua. Predizer com precisão o contexto do usuário pode aperfeiçoar muito a qualidade de satisfação do usuário em cada aspecto da vida diária, particularmente no uso de sistemas ubíquos de apoio e suporte a decisão.

Gerando inferências sobre a localização dos usuários, sistemas ubíquos de apoio e suporte a decisão podem não apenas detectar automaticamente uma situação atual do usuário, mas também prever a localização futura do usuário. Tal sistema de predição de localização irá auxiliar os usuários a tomarem decisões rapidamente e eficientemente oferecendo serviços mais adequados.

### 3.3 Predição de localização em ambientes fechados utilizando RBs

Petzold et al. (2005) investigaram a eficiência de predição de localização em ambientes fechados comparando alguns métodos de predição (um preditor de estados e uma rede neural).

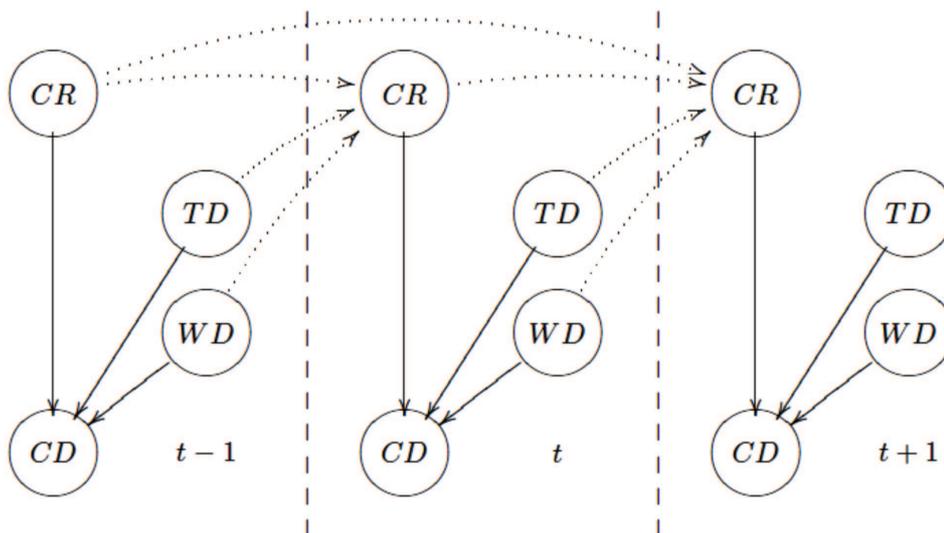
O cenário analisado diz respeito as pessoas em um edifício de escritórios visitando salas de forma regular em alguns períodos de tempo. O cenário foi modelado através de uma Rede Bayesiana Dinâmica e a precisão da predição da próxima sala e a duração da permanência foram avaliadas, bem como memória e requisitos de desempenho de um preditor que usa RBs.

O objetivo é investigar o quanto técnicas de aprendizado de máquina podem dinamicamente prever sequências de sala, hora de entrada nas salas, e tempo de permanência independente de conhecimento adicional.

Os resultados são comparados com outras abordagens de predição — um preditor de estado e um preditor de percepção multicamada utilizando exatamente o mesmo conjunto de avaliação e *benchmarks*.

A fim de prever o contexto futuro de uma pessoa, optou-se pelo uso de uma Rede Bayesiana Dinâmica. Essa rede consiste de diferentes fatias de tempo as quais todas contêm uma Rede Bayesiana Dinâmica. Os nodos entre as fatias de tempo são conectados com setas para representar dependências entre essas fatias de tempo (Figura 11).

**Figura 11:** Rede Bayesiana Dinâmica com dependências entre as diferentes fatias de tempo



Fonte: (PETZOLD et al., 2005)

Neste trabalho em específico, procurou-se prever localizações futuras de uma pessoa e adicionalmente a duração de permanência e a hora de quando a pessoa está provavelmente mudando para uma nova localização.

O mecanismo de predição que foi proposto pode ser utilizado em um grande número de aplicações em um ambiente de escritórios inteligentes, porém os autores procuraram demonstrar duas dessas aplicações:

- a) No projeto *Smart Doorplate* (TRUMLER et al., 2003), do qual o mecanismo de predição desenvolvido faz parte, um visitante é notificado sobre o provável próximo local em que um profissional de escritório que está ausente estará, dentro do edifício em questão. A predição é necessária para decidir se o visitante deve seguir a pessoa procurada até sua localização atual, ir para a localização prevista, ou apenas esperar até que o profissional procurado retorne;

- b) Uma chamada telefônica direcionada para a localização atual de um profissional dentro de um determinado escritório é uma aplicação frequentemente proposta em um escritório inteligente, porém, para onde direcionar uma chamada telefônica nos casos em que uma pessoa acabou de deixar seu escritório e ainda não chegou até o seu destino? A chamada telefônica poderia ser direcionada para a sala prevista e respondida assim que a pessoa atingir seu destino.

Os resultados mostraram que o preditor com Redes Bayesianas atinge a predição da próxima localização com precisão de 90% e a predição de precisão de duração com 87% com variações dependendo da pessoa e um conjunto de predição.

O método de predição usando RBs desempenha o mesmo range de precisão que uma rede neural e o preditor de estado.

### **3.4 Integração de RB em um sistema ubíquo de apoio a tomada de decisões para oferecer predição de contexto**

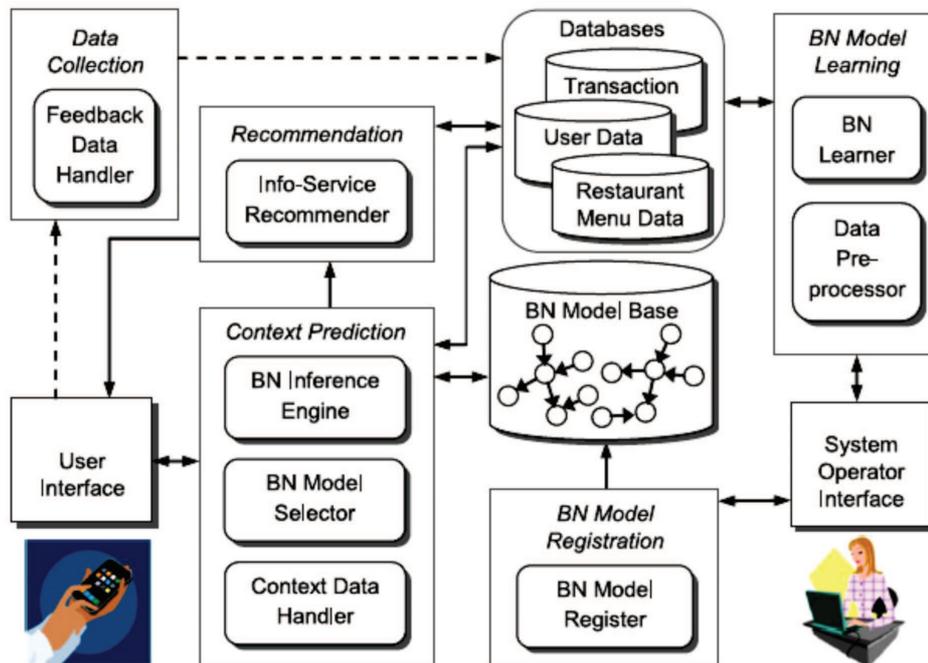
Lee e Cho (2012) propuseram um novo tipo de sistema ubíquo para apoio a tomada de decisões, o qual é potencializado por uma RB. Simples sensibilidade ao contexto não garante reduzir de forma proativa o esforço requerido pelo usuário para prever mudanças em contextos relevantes no futuro. Em outras palavras, possibilitar que os sistemas ubíquos de tomada de decisão incorporem proatividade requer informações sobre as necessidades futuras dos usuários que devem ser inferidas a partir de informações de contextos futuros. Prever contextos futuros dos usuários, chamado de *Context Prediction* (CP), requer métodos de inferência altamente sofisticados com capacidade de analisar dados contextuais e encontrar padrões de significado a partir deles para prever mudanças futuras nos contextos dos usuários.

Cada método de predição de contexto possui vantagens sobre os outros. A primeira desvantagem é que muitos métodos de predição de contextos não conseguem oferecer relacionamentos causais entre as variáveis alvo e as variáveis explicativas. Se um relacionamento causal pode ser extraído a partir de dados contextuais, então ele pode ser utilizado para fazer uma ampla variedade de análises *What-If*. Os relacionamentos causais obtidos a partir dos dados de treinamento podem ser utilizados como um mecanismo de inferência o qual pode desempenhar uma variedade de análises *What-If* dados os cenários considerados.

É proposta a utilização de *General Bayesian Networks* (GBN) na predição de contextos onde relacionamentos causais são induzidos a partir dos dados de treinamento e contextos futuros podem ser inferidos através de análise *What-If* em vários cenários.

O sistema U-Base proposto coleta dados de transações de usuários para construir modelos de BNs e prever contextos futuros dos usuários utilizando modelos de BN para oferecer recomendações sensíveis ao contexto aos usuários. O sistema U-Base consiste de 5 componentes (Figura 12):

Figura 12: Arquitetura do sistema U-Base



Fonte: (LEE; CHO, 2012)

- Componente de Predição de Contextos:** o componente chave do sistema U-Base é o componente de predição de contextos (CP). O componente de CP consiste de um controlador de dados de contexto, um seletor de modelo de BN e um mecanismo de inferência de BN. O controlador de dados de contexto passa os dados de contexto para o seletor de modelos de BN, e o seletor de modelos escolhe o modelo de BN apropriado a partir de base de modelos. O mecanismo de inferência desempenha predições de contextos baseado no modelo de BN selecionado e nos dados de contexto, e passa os resultados preditos de volta ao controlador de dados de contexto. O controlador de dados de contexto então passa os resultados para o componente de recomendação.
- Controlador de dados de contexto:** o controlador de dados de contexto recebe os dados de contextos de usuários a partir da aplicação de duas formas: ele pode receber dados de contexto os quais são deliberadamente enviados pelo usuário, ou ele pode receber dados por requisições proativas dos usuários da aplicação para os dados de contexto.
- Seletor de modelo de BN:** o seletor de modelos de BN seleciona um modelo apropriado de BN a partir da base de modelos baseando-se nos dados de contexto dos usuários, e então envia o modelo de BN selecionado e os dados de contexto do usuário para o mecanismo de inferência de BN para a predição de contexto.
- Mecanismo de inferência de BN:** o mecanismo de inferência desempenha simulações *What-If* no modelo de RN selecionado utilizando os dados de contextos dos usuários. As probabilidades a posteriori das entradas das variáveis alvo são calculadas pela instanci-

ação das variáveis explicativas; a entrada com a melhor probabilidade é retornada como resultado da predição.

- e) **Componente de recomendação:** o serviço de recomendação utiliza dados de contexto, os resultados preditos e dados de fatos relevantes obtidos a partir de base de dados para gerar informações sensíveis ao contexto úteis para o usuários.

A base de modelos de BN mantém múltiplos modelos de BN para diferentes predições de contexto baseadas em serviços. Esses modelos de BN predizem contextos futuros, tais como a próxima localização, próxima atividade, próximo objetivo e assim por diante. Foi utilizado o WEKA, uma ferramenta de mineração de dados de código aberto com capacidade de aprendizado de RBs e inferências, para construir as RBs e efetuar experimentos. Os dados das 12 atividades desempenhadas no campus de uma universidade foram utilizados para o aprendizado das RBs com nodo alvo sendo o “Location Arrived”. A estrutura da BN foi aprendida usando o algoritmo K2 com um número máximo de nodos pais limitados a 2.

### 3.5 Utilizando RBs para a predição de diabetes tipo-2

A diabetes mellitus tem se tornado o principal problema da saúde pública nos últimos tempos. De acordo com a Federação Internacional da Diabetes, existem atualmente 246 milhões de pessoas diabéticas no mundo todo, e esse número é esperado que cresça a 380 milhões em 2025. Diabetes é uma doença crônica na qual o corpo não produz insulina suficiente para ser utilizada de forma adequada.

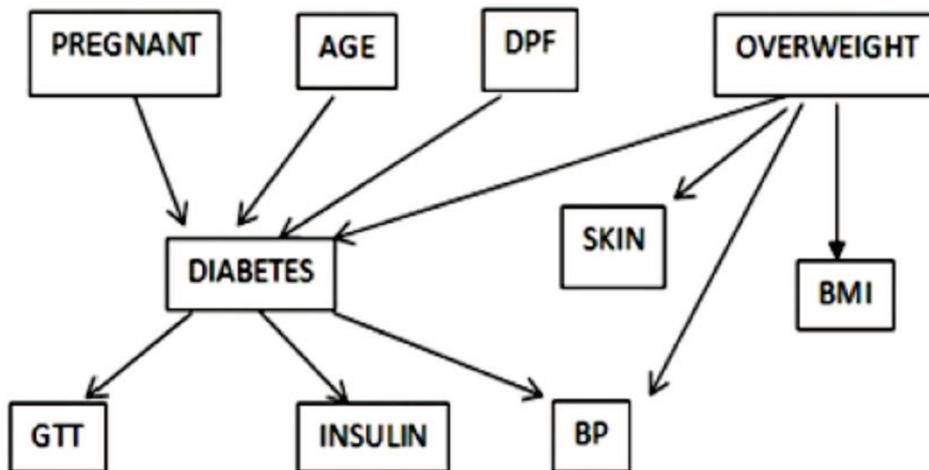
Um estudo feito por Guo, Bai e Hu (2012) teve como objetivo a elaboração de uma rede Bayesiana para o diagnóstico de diabetes do tipo 2. O conjunto de dados utilizado na pesquisa foi extraído a partir do Repositório de Aprendizado de Máquina UCI. O proprietário original dos dados é o Instituto Nacional de Diabetes, Doenças Digestivas e Doenças de Kidney, localizado na Suécia. A seleção dessas instâncias é conforme segue: todos os pacientes são femininos com pelo menos 21 anos de idade e originárias de uma comunidade indígena. Muitos pesquisadores têm conduzido pesquisas na área de predições de diabetes do tipo-2. Nesse estudo utilizou-se uma rede Naive Bayes para construir um sistema de tomada de decisões para pessoas de meia idade até idosas fazerem a auto predição da diabetes do tipo-2 em casa. O conjunto de dados utilizado nesse estudo foi o “*The Pima Indians Diabetes Dataset*”, onde existem 768 instâncias e todas elas possuem 8 atributos de entrada e 1 de saída.

Baseando-se na investigação do conhecimento da diabetes, pode-se criar a estrutura da rede Bayesiana. Primeiro, é certo que diabetes pode ser causada por GRAVIDEZ (número de vezes em que a mulher engravidou), IDADE, e DPF (diabete hereditária). Uma parte interessante do conjunto de dados é que existem duas medidas relativas ao excesso de peso SKIN (dobras cutâneas triceptais) e BMI (Índice de massa corporal). Essas medidas não causam sobrepeso, ao invés disso, o excesso de peso faz com que essas medidas sejam altas. Sendo assim, podemos

assumir “sobrepeso” como sendo uma variável escondida na rede. Após uma análise mais aprofundada, a espessura das dobras cutâneas pareceu ser uma evidencia muito pobre para diabetes, sendo assim utilizou-se o índice de massa corporal como valor de sobrepeso. As medidas de GTT (concentração de glicose no plasma) e de INSULINA são ambas testadas para diabetes, o que significa que diabetes os causa.

O método *leave-one-out* foi utilizado para avaliar a rede Bayesiana proposta (Figura 13). Pré-processamento foi utilizado para melhorar a qualidade dos dados. As técnicas de pré-processamento aplicadas foram a identificação dos atributos e seleção, normalização dos dados e discretização numérica. Em seguida, um classificador foi aplicado para o conjunto de dados modificado para construir o modelo de rede Bayesiana. Ao se comparar os resultados obtidos pela Rede Bayesiana proposta em relação aos resultados obtidos por uma rede Naive Bayes, verificou-se que a Rede Bayesiana obtve uma precisão de 72,3% contra 71,5% da rede Naive Bayes.

Figura 13: RB para predição da diabetes tipo-2



Fonte: (GUO; BAI; HU, 2012)

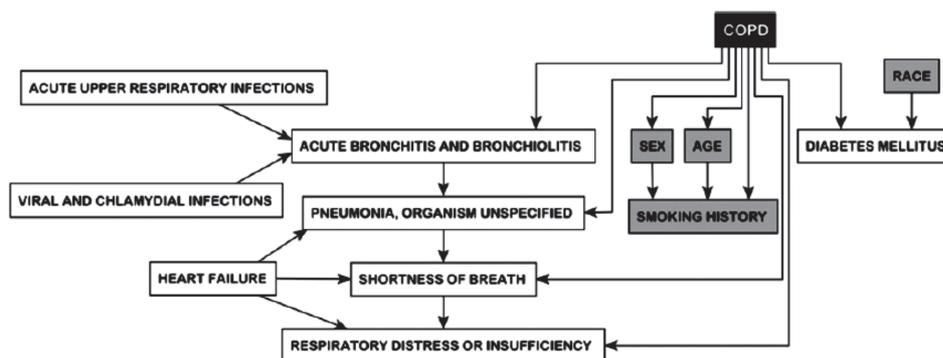
### 3.6 Predição de Doença Pulmonar Obstrutiva Crônica em pacientes com asma utilizando registros médicos eletrônicos

Doença Pulmonar Obstrutiva Crônica (COPD), é uma doença de progressão lenta caracterizada pelo aumento não reversível da limitação do fluxo de ar, e é uma das principais causas de morbidade e mortalidade no mundo todo.

Himes et al. (2009) criaram um modelo de predição do COPD em pacientes com asma utilizando dados demográficos e dados de comorbidade a partir de informações extraídas do The Partners Healthcare Research Patient Data Registry (RPDR) nos Estados Unidos, o qual contém dados sobre mais de três milhões de pacientes que foram tratados em hospitais-afiliados, e é uma das maiores coleções de registros médicos eletrônicos a partir de centros médicos acadêmicos.

O modelo preditivo foi criado utilizando Redes Bayesianas, modelos multivariados que estão aptos a contar associações simultâneas entre variáveis para criar previsões de COPD. RBs foram utilizadas com sucesso em uma ampla variedade de aplicações médicas, a partir de sistemas públicos de vigilância da saúde (Figura 14).

**Figura 14:** Rede de predição para Doença Pulmonar Obstrutiva Crônica



Fonte: (HIMES et al., 2009)

Pacientes foram divididos em dois grupos de acordo com a data inicial de observação. Um grupo de 9349 pacientes, que foram inicialmente observados entre 1988 e 1998, foram selecionados para criar o modelo preditivo de COPD. Um conjunto posterior independente de 992 pacientes teve as observações iniciais entre os anos de 1999 e 2002. O grupo independente foi utilizado para testar o modelo preditivo. O conjunto de 9349 pacientes e 109 variáveis clínicas foram utilizadas em conjunto com o algoritmo K2 para construir a Rede Bayesiana. Para encontrar tal rede, um conjunto de diferentes modelos de redes foi explorado e cada uma foi pontuada para seus dados de probabilidade a posteriori para os dados recebidos. O modelo com o máximo de probabilidades a posteriori é retornado. A RB encontrada com 109 variáveis continua muitos relacionamentos entre variáveis e alguns desses relacionamentos não influenciavam diretamente o COPD. Devido ao fato dos autores estarem interessados em prever a doença de COPD, especificamente, eles focaram nas variáveis da rede que foram moduladas diretamente: idade, sexo, raça, histórico de consumo de cigarro e 8 comorbidades.

Um posterior conjunto independente de pacientes foi utilizado para a validação do modelo preditivo desenvolvido. A doença de COPS foi predita em cada paciente do conjunto independente e a predição foi comparada com pacientes que já possuem a doença de COPD.

Resultados mostram que é possível utilizar dados extraídos a partir de registros médicos para criar modelos preditivos. O modelo proposto obteve um acerto de 83% nas previsões de COPD. Com o aperfeiçoamento na extração de dados e a inclusão de mais variáveis, tais modelos podem ser úteis clinicamente e servirem para o melhor entendimento das tendências de doenças.

### 3.7 Ordenação de atributos em RBs para a predição de síndrome metabólica

Síndrome metabólica é um conjunto de fatores de risco que incluem obesidade abdominal, resistência à insulina, dislipidemia e hipertensão. Ela tem afetado 25% de adultos nos EUA e se tornou um sério problema nos países asiáticos recentemente devido as mudanças nos hábitos de dieta e estilo de vida. Por outro lado, RBs são modelos para resolver problemas que envolvem incerteza oferecendo um formulismo transparente e robusto para modelagem probabilística, sendo assim elas têm sido utilizadas como método para modelos de diagnósticos ou prognósticos em domínios médicos.

Park e Cho (2012) estudaram um método de otimização dos atributos de uma RB. A pesquisa desenvolvida utilizou um algoritmo genético para resolver um problema de otimização na modelagem de prognósticos médicos. Especificamente, lida com o problema de prever a síndrome metabólica com um conjunto de dados obtidos no Youchon County, na Coreia. Foi construído um modelo de prognóstico utilizando RBs, e foi utilizado o algoritmo K2 a fim de aprender a estrutura da rede. Uma vez que o resultado do algoritmo K2 é influenciado pela entrada de atributos, uma otimização para esse fim foi também estudada.

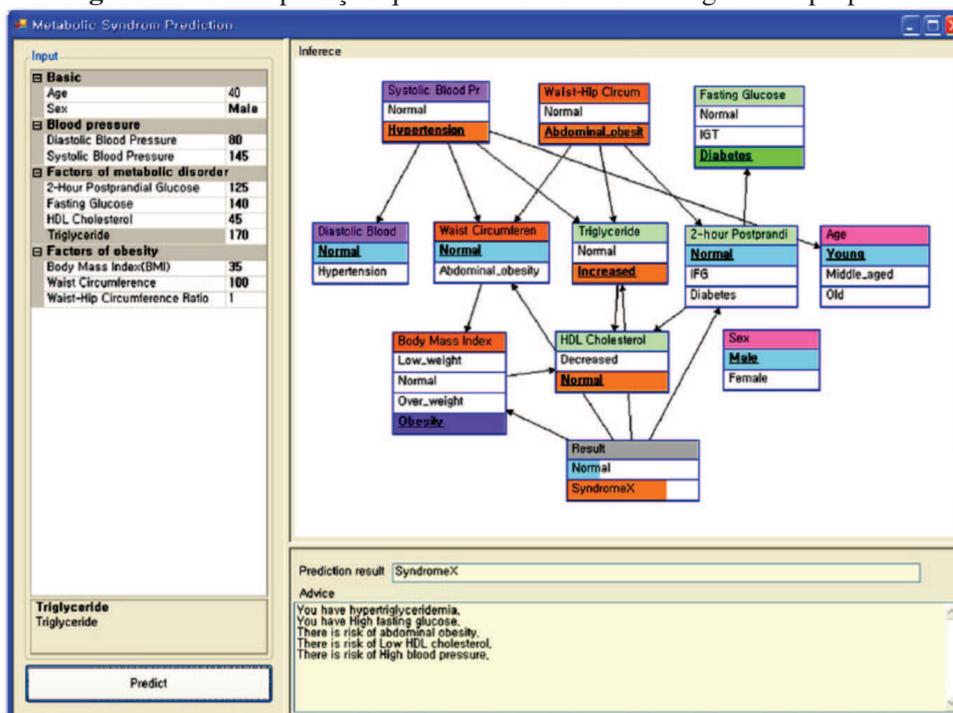
Foi proposto um modelo de RB utilizando 11 atributos, os quais contêm oito atributos básicos e três atributos informativos adicionais para o modelo de prognóstico da síndrome metabólica. Nesse processo de concepção do modelo, aplicou-se conhecimento de especialistas no domínio médico para fazer com que o modelo se tornasse mais confiável.

Após a ordenação dos atributos analisados, é efetuado o processo de aprendizagem da Rede Bayesiana utilizando o algoritmo K2 que reduz o espaço de busca fixando a ordem dos atributos. As probabilidades dos nodos são calculadas a partir da frequência dos dados de aprendizagem. O conjunto de dados foi examinado por pesquisas epidemiológicas na comunidade local. Os *surveys* foram conduzidos entre 1993 e 1995. 2293 participaram do primeiro *survey* e 1193 participaram do segundo *survey*. Foram utilizados dados de 1135 que não tinham dados faltantes e 18 atributos que poderiam influenciar a predição da síndrome metabólica.

Após decidiu-se se cada uma das amostras deveria pertencer a síndrome metabólica ou não, de acordo com a definição de síndrome metabólica. Para confirmar a eficiência do modelo de prognóstico idealizado, foi desenvolvido um aplicativo que utiliza o modelo com o objetivo de prever a síndrome metabólica. A aplicação compreende três partes (Figura 15): um painel do lado esquerdo para obter informações de entrada, um painel no topo para exibir o modelo de inferência e um painel na parte inferior para oferecer os resultados das predições e alertas baseados em conhecimentos de especialistas. Usuários podem não apenas obterem o resultado do prognóstico oferecido pelo modelo, mas também informações úteis a fim de diminuir o risco de se contrair síndrome metabólica.

Após experimentos, confirmou-se que o método proposto oferece melhor desempenho se comparando com outros modelos, tais como, Redes Neurais e *k-nearest neighbor*.

Figura 15: Uma aplicação que utiliza o modelo de diagnóstico proposto



Fonte: (PARK; CHO, 2012)

### 3.8 Comparativo entre os trabalhos relacionados

De uma forma geral, diversos aspectos são desejáveis quando se trata de modelos de predição; sobretudo, modelos de predição que utilizam-se de RBs, tais como a possibilidade de se utilizar mais de um modelo de RB e a capacidade de utilização de dados históricos para melhorar a eficiência das predições efetuadas. Além disso, quando se trabalha com modelos de predição aplicados a ambientes ubíquos cujo objetivo é oferecer suporte à saúde, deve-se considerar características que visem melhorar a qualidade de vida dos pacientes, e que se tenha como objetivo fazer predições que sejam relevantes ao tratamento do paciente e que sejam contínuas, de forma que desvios no tratamento ou tendências possam ser identificados em tempo hábil.

A Tabela 3 apresenta um comparativo entre os trabalhos analisados, levando em consideração o suporte aos seguintes itens:

- **suporte à saúde / bem estar:** indica se o trabalho oferece algum tipo de apoio ou assistência à saúde dos usuários, visando melhorar sua qualidade de vida e o autogerenciamento de suas rotinas;
- **análise de fatores de risco:** no apoio e suporte à saúde, um aspecto importante diz respeito aos fatores de risco, sobretudo quando trata-se de suporte e monitoramento de algum tipo de DCNT, onde o bom gerenciamento e acompanhamento dos fatores de risco é aspecto fundamental para o bom andamento do tratamento do paciente. Esse critério de comparação identifica se o trabalho analisado considera características que influenciam

direta ou indiretamente no agravamento de uma determinada DCNT;

- **suporte a múltiplos modelos de RBs:** para todo modelo de predição que se propõe a utilizar RBs, um aspecto importante diz respeito a capacidade de efetuar análises preditivas baseando-se em diferentes aspectos. Dentro de um ambiente ubíquo, esses diferentes aspectos poderiam ser a localização ou o período do dia, por exemplo. Já quando se tem como objetivo efetuar predições para identificar e monitorar algum tipo de DCNT, a possibilidade de se poder efetuar análises preditivas utilizando RBs para diferentes tipos de doenças se torna bastante importante, a medida que flexibiliza e compreende casos em que um mesmo usuário / paciente sofre de mais de um tipo de DCNT em que cada uma delas possui diferentes fatores de risco;
- **tipo de aplicação:** identifica qual o objetivo macro em relação aquilo que é apresentado. Se trata-se da apresentação de uma nova **metodologia** (etapas tratadas e definidas para serem seguidas no processo que está sendo definindo); o desenvolvimento de uma nova **ferramenta** (dispositivo ou mecanismo desenvolvido para realizar algum tipo de experimento preditivo ou decisório) ou se trata-se do desenvolvimento de um **modelo** (representa de forma conceitual e visual o processo o qual se propõe a predizer);
- **acompanhamento das atividades diárias:** para mecanismos de predição cujo propósito é predizer o agravamento de uma determinada DCNT ou sua existência, é fundamental que, dado o fato de se tratarem de doenças que exijam cuidado e atenção contínua, esses mecanismos possam acompanhar o dia-a-dia do usuário de forma a monitorar seus índices e seu hábitos;
- **sensibilidade ao contexto:** busca identificar se é utilizado algum tipo de informação sobre contextos. Um exemplo prático poderia ser, através da identificação do local em que o usuário se encontra, poder efetuar algum tipo de sugestão ou oferecer alguma possibilidade de interação extra em virtude do local. No caso de um paciente, se poderia sugerir um local próximo a sua localização onde ele poderia receber um tratamento mais adequado para o tratamento de sua doença;
- **dados históricos de contextos (trilhas):** identifica se são utilizados dados históricos de contextos (trilhas). Tal aspecto se faz bastante importante, a medida que utilizar informações históricas e aspectos relativos a eventos e decisões anteriores faz com que o processo de predição se torne cada vez mais preciso e coerente, sobretudo, quando se está trabalhando com RBs;
- **aplicabilidade das RBs:** busca identificar de que forma as RBs foram utilizadas, se para indicar uma **decisão** (resposta a um determinado questionamento) baseando-se no conjunto de dados utilizados em seu treinamento ou se para efetuar uma **predição** (indicar tendências e sugerindo comportamentos futuros);

- **suporte a dispositivos móveis:** o objetivo é identificar a utilização ou não desse tipo de dispositivo. O uso de dispositivos móveis está diretamente relacionado com a computação ubíqua e com a utilização de dados históricos de contextos.

Os aspectos mencionados acima foram considerados como presentes em cada um dos trabalhos estudados quando foram, no decorrer dos respectivos textos, citados de forma explícita ou quando fortes indícios da presença dos mesmos foram verificados.

**Tabela 3:** Comparativo entre os trabalhos relacionados

<b>Características</b>	Hwang and Cho, 2009	Lee and Lee, 2012	Petzold et al., 2005	Lee and Cho, 2012	Guo et al., 2012	Himes et al., 2009	Park and Cho, 2012
Suporte à saúde / bem-estar	não	não	não	não	sim	sim	sim
Análise de fatores de risco	não se aplica	não se aplica	não se aplica	não se aplica	sim	sim	sim
Suporte a múltiplos modelos de RBs	não	não	não	sim	não	não	não
Tipo de aplicação	metodologia	ferramenta	modelo	modelo	ferramenta	modelo	modelo
Acompanhamento das atividades diárias	não	não	não	sim	sim	não	não
Sensibilidade ao contexto	sim	sim	sim	sim	não	não	não
Dados históricos de contextos (trilhas)	sim	sim	sim	sim	não	não	não
Aplicabilidade das RBs	decisão	previsão	previsão	previsão	previsão	previsão	previsão
Suporte a dispositivos móveis	sim	sim	sim	sim	não	não	não

Fonte: Elaborado pelo autor

Dentre os trabalhos analisados, apenas os trabalhos apresentados em Guo, Bai e Hu (2012),

Himes et al. (2009) e Park e Cho (2012) oferecem algum tipo de suporte à saúde / bem estar do usuário através das predições efetuadas. Guo, Bai e Hu (2012) menciona que a ferramenta por eles desenvolvida tem como objetivo um maior controle da diabetes por parte das pessoas de meia idade e idosos, através da possibilidade de fazerem a auto-predição da doença em suas próprias casas. Já o modelo apresentado em Himes et al. (2009) tem por objetivo prever a presença da doença de COPD em pacientes que já sofrem de asma, podendo, desta forma, desenvolver formas mais eficientes de tratar os pacientes. Park e Cho (2012) desenvolveram um modelo que busca oferecer suporte a pacientes que possuem algum dos fatores que resultam na presença da síndrome metabólica. O objetivo é conseguir de forma preventiva melhorar os hábitos dos pacientes de forma que possam evitar a efetiva presença da síndrome. Todos os demais trabalhos efetuam predições de aspectos que, apesar de importantes, não são de suma importância para o bem-estar.

Quando se leva em consideração os fatores de risco, apenas os trabalhos apresentados em Guo, Bai e Hu (2012), Himes et al. (2009) e Park e Cho (2012) consideram fatores de risco nos modelos e ferramentas por eles propostos. Guo, Bai e Hu (2012) utiliza os principais fatores de risco que podem refletir de forma direta ou indireta na presença de diabetes. Himes et al. (2009) usam fatores de risco para identificar em pacientes que possuem de asma, tendência a virem desenvolver a doença de COPD. Já Park e Cho (2012) considera um conjunto de fatores de risco que influenciam na presença síndrome metabólica. Os demais trabalhos analisados não levam em consideração fatores de risco, tendo em vista, principalmente o fato de não serem diretamente ligados à área da saúde.

O suporte a múltiplos modelos de RBs se faz importante a medida que torna o modelo ou ferramenta apresentados flexível e possibilita que o mesmo seja utilizado para diferentes tipos de conclusões ou predições. Dentre as propostas analisadas apenas a ferramenta U-BASE (LEE; CHO, 2012) oferece suporte a múltiplos modelos, pois através do módulo seletor de RBs presentes na ferramenta, as cada RB é selecionada de acordo com os dados de contexto obtidos. Todos os demais trabalhos analisados se propõem a efetuar uma única predição específica, focando-se em um único modelo de RBs.

Petzold et al. (2005), Lee e Cho (2012), Himes et al. (2009), Park e Cho (2012) propuseram um modelo em seus respectivos trabalhos. Já Lee e Lee (2012) e Guo, Bai e Hu (2012) optaram por desenvolver uma ferramenta para efetuar predições, enquanto Hwang e Cho (2009) optaram por propor uma nova metodologia.

Acompanhar as atividades diárias dos usuários é um aspecto bastante importante para se fazer predições relacionadas a doenças, ou mesmo predições que não estejam relacionadas diretamente a doenças, mas que consideram dados do contexto analisado e que são sensíveis a ele. Dentre os modelos estudados apenas o modelo U-BASE de Lee e Cho (2012) e a ferramenta para predição de diabetes proposta por Guo, Bai e Hu (2012) acompanham diariamente os usuários / pacientes. O primeiro utiliza dados fornecidos por um dispositivo móvel portado pelo usuário para obter dados em tempo real relativos a localização e atividades desempenhadas

naquele instante. Já o segundo, necessita que os pacientes forneçam informações atualizadas para que sejam feitas predições sobre a incidência de diabetes com maior precisão. Todos os demais modelos não fazem um acompanhamento diário a fim de obter dados ou se utilizam apenas de dados históricos para proporem seus modelos / ferramentas.

Apenas os estudos reportados por Guo, Bai e Hu (2012), Himes et al. (2009) e Park e Cho (2012) não possuem mecanismos aplicados a sensibilidade de contexto. Isso explica-se pelo fato de que os três estudos baseiam-se suas predições através de RBs utilizando bases de dados previamente estabelecidas (não mudam ao longo do tempo) em conjunto com informações obtidas dos usuários / pacientes, mas sem considerar informações relacionados aos contextos. Todos os demais estudos utilizam alguma característica de sensibilidade ao contexto.

Novamente, apenas os estudos feitos por Guo, Bai e Hu (2012), Himes et al. (2009) e Park e Cho (2012) não utilizam dados históricos de contextos (trilhas). Isso pode ser explicado, principalmente, devido ao fato de que tais estudos não possuem mecanismos sensíveis ao contexto e a ubiquidade, ao contrário de todos os outros estudos analisados.

O único estudo que difere dos demais, onde são utilizadas RBs para efetuar predições, é o estudo desenvolvido por Hwang e Cho (2009), que utiliza RBs para decisão com o objetivo de extrair pontos importantes presentes em *logs* históricos gerados por dispositivos móveis.

Os estudos desenvolvidos por Guo, Bai e Hu (2012), Himes et al. (2009) e Park e Cho (2012) não utilizam dispositivos móveis nem dados fornecidos por estes em suas propostas. Todos os demais trabalhos utilizam *smartphones* ou outros tipos de dispositivos para obterem dados do contexto corrente a fim de serem utilizados para as predições.

De acordo com a Tabela 3, nota-se que nenhum dos trabalhos analisados apresenta **Suporte à saúde / bem-estar** de pacientes, considerando **fatores de risco, dados históricos de contexto** em conjunto com **múltiplos modelos de RBs e dispositivos móveis**. Tais características quando utilizadas em conjunto tornam-se importantes para que o paciente possa verificar o andamento e a evolução do seu tratamento e dos diversos fatores de risco através de seus próprios dados históricos, bem como utilizando-se de dados históricos de outros pacientes que possuam tratamentos semelhantes, o que faz com que as predições e recomendações efetuadas pelo modelo tendem a ser cada vez mais críveis.

De uma forma geral, os trabalhos relacionados se concentram na **utilização de dispositivos móveis**, no fato de serem **sensíveis ao contexto** e na utilização de **dados históricos de contexto**, mas sem focar no **suporte à saúde / bem-estar**, na utilização de **múltiplos modelos de RBs** e no **acompanhamento das atividades diárias**. Além disso, os trabalhos que se propõem a fazer **predições** e que consideram **fatores de risco e suporte à saúde / bem-estar** dos pacientes, não utilizam **dados históricos de contextos**, nem **dispositivos móveis**.

Contemplando as características mencionadas na Tabela 3, está sendo proposto o Chronic-Prediction que é um modelo computacional ubíquo para o monitoramento de fatores de risco de DCNTs através de RBs e dados históricos de contextos, fornecendo recomendações visando o bom andamento do tratamento do paciente e sendo utilizado na forma de um protótipo para

dispositivos móveis.

### **3.9 Considerações sobre o capítulo**

O presente capítulo teve como objetivo principal apresentar um panorama geral a respeito dos trabalhos relacionados ao modelo de predição aqui proposto. Considerando os aspectos que foram elencados como sendo mais relevantes, foi possível fazer um comparativo entre os mesmos. Tal análise possibilitou a identificação de novas lacunas a serem exploradas. Após a apresentação de uma série de conceitos básicos serviram de base para a concepção do modelo de predição e que são importantes para o bom entendimento da proposta como um todo. O próximo capítulo se propõe a apresentar o módulo ChronicPrediction, que será integrado ao modelo UDuctor.

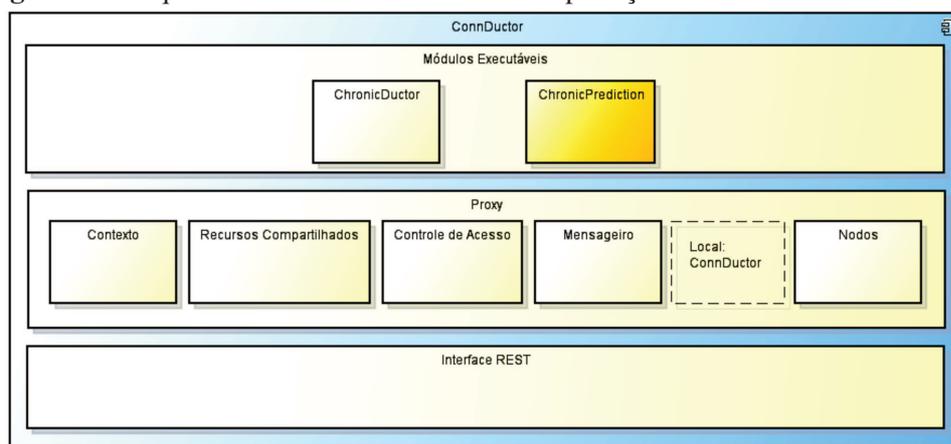
## 4 MODELO CHRONICPREDICTION

Este capítulo apresenta o ChronicPrediction, um modelo computacional ubíquo para o monitoramento de fatores de risco de DCNTs. O modelo de predição aqui proposto busca se integrar a estrutura do modelo UDUCTOR e utiliza as funcionalidades fornecidas pelo *middleware* ConnDuctor, atuando como um módulo executável. O capítulo, inicialmente, apresenta o posicionamento do modelo de predição aqui proposto na arquitetura organizacional do modelo UDUCTOR. Logo após, é apresentando um exemplo de uma relação de causa e efeito utilizando-se de uma RB e, em seguida, são apresentados os detalhes da arquitetura do modelo ChronicPrediction.

### 4.1 O ChronicPrediction e o Modelo UDUCTOR

O **ChronicPrediction** efetua o monitoramento, indicando tendências de agravamento ou melhoria de fatores de risco associados a DCNTs e efetuando recomendações para o melhor andamento do tratamento e bem-estar do paciente. Para tal, utiliza-se de RBs modeladas de acordo com a DCNT e os respectivos fatores de risco que serão monitorados e de dados históricos fornecidos pelo módulo de Contexto do *middleware* ConnDuctor com o intuito de modelar e calibrar as RBs. Da mesma forma que o ChronicDuctor, o ChronicPrediction é executado a partir de um NP (Nodo Pessoal), sendo também um módulo executável do *middleware* ConnDuctor. A Figura 16 mostra a arquitetura do modelo UDUCTOR incluindo o módulo ChronicPrediction.

**Figura 16:** Arquitetura do módulo executável de predição dentro do modelo UDUCTOR



Fonte: Elaborado pelo autor

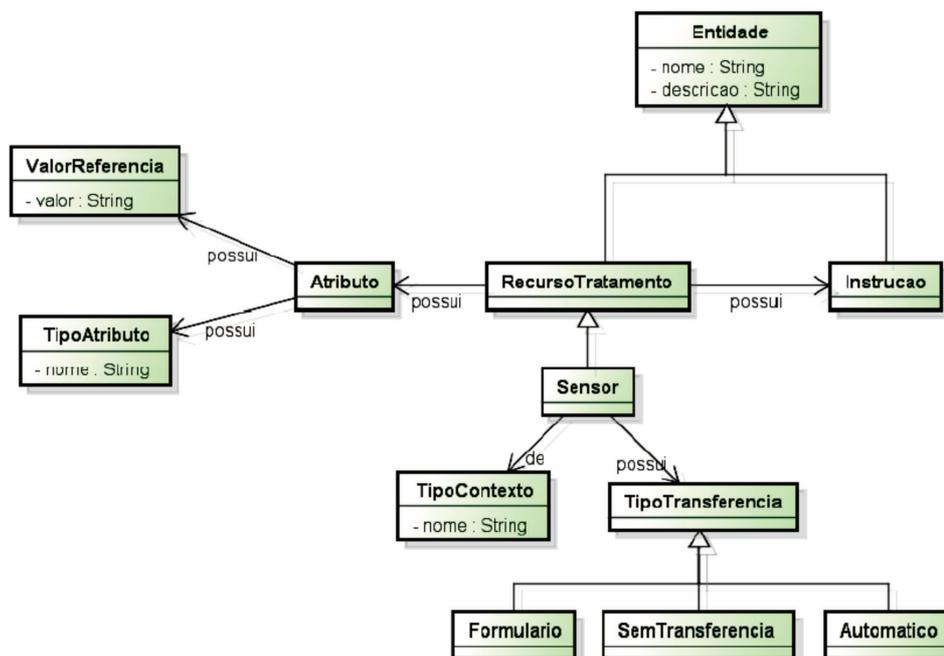
### 4.2 Arquitetura do ChronicPrediction

O ChronicPrediction trabalha com o monitoramento de condições crônicas utilizando-se de toda a estrutura já existente no módulo executável ChronicDuctor. O propósito do ChronicPrediction é, além de ser um módulo executável, atuar como um *plug-in* para o ChronicDuctor,

mantendo compatibilidade com todas as condições crônicas monitoradas por ele bem como com os fatores de risco que influenciam em cada uma dessas condições crônicas.

Para que seja possível efetuar um mapeamento das relações de causa e efeito existentes entre cada uma das características que influenciam nos fatores de risco de cada uma das condições crônicas que se deseja monitorar e, posteriormente, se possa criar cada uma das RBs utilizadas no processo de monitoramento executado pelo modelo ChronicPrediction, é utilizada a ontologia de Recursos existente no assistente pessoal ChronicDuctor. Tal ontologia envolve alguns dos conceitos utilizados pelos recursos no cuidado de DCNT. A classe **RecursoTratamento** deve ser utilizada para representar qualquer recurso que se possa utilizar para o cuidado de DCNT. Um recurso de tratamento pode possuir instruções que especificam como ele pode ser utilizado, tal conceito é representado pela relação *possui Instrução*. Um vídeo de operação de um monitor de pressão arterial, a bula de um medicamento ou qualquer outro material que possa ser utilizado para auxiliar o paciente, ou responsável nas atividades de cuidado pode ser considerado como sendo uma instrução. A Figura 17 apresenta a ontologia de Recursos.

Figura 17: Modelo ontológico de recursos



Fonte: (VIANNA, 2013)

Um **RecursoTratamento** possui atributos que descrevem suas características. Tal conceito é descrito pelo relacionamento **RecursoTratamento possui Atributo**. Cada **Atributo** pode ser descrito como sendo um par de **TipoAtributo** e **ValorReferencia**. Sendo assim, torna-se possível descrever diferentes tipos de recursos de tratamento como, por exemplo, alimentos e medicamentos.

Para mapear as relações de causa e efeito entre Tipos de Atributos dos Recursos e sua respectiva influência no valor de um determinado Contexto são consultados especialistas da

área médica ou nutricional para que, posteriormente, seja efetuado o monitoramento. Dentro do modelo UDuctor, um **Contexto** pode ser definido como sendo qualquer informação que representa a situação de um NP (pessoa na posse de um *smartphone*, movimentando-se entre espaços físicos). Tais informações podem ser o tipo de atividade exercida por um NP (por exemplo, correndo, parado, caminhando) ou a temperatura ambiente de um NL (região espacial disposta em algum local geográfico como, por exemplo, uma casa (DAMASCENO VIANNA; BARBOSA, 2014)).

Considere, por exemplo, o seguinte cenário, suponha a existência de um Recurso denominado “pão” com um Tipo de Atributo do tipo “Valor Energético” com um Valor igual a “160kcal (quilocalorias)” e um Contexto com o Tipo de Contexto denominado “Peso”. É sabido que a quantidade de calorias ingeridas tem influência direta no aumento ou diminuição do peso corporal de um indivíduo; portanto, pode-se dizer que existe uma relação de causa e efeito entre “quantidade de calorias” e “peso” (“quantidade de calorias” influencia no “peso”). Além disso, segundo a OMS, o controle alimentar é um dos principais mecanismos para o controle da obesidade / sobrepeso.

Após o mapeamento das relações de causa e efeito e a criação das RBs dedicadas a monitorar os fatores de risco relacionadas a cada uma das DCNT as quais se pretende analisar, as RBs são previamente calibradas com dados históricos de contexto (trilhas) provenientes do módulo de Contexto, que é componente do *middleware* ConnDuctor. Esses dados históricos de contexto são atributos gerados pelo NP (pessoa utilizando um *smartphone*) onde, por exemplo, se pode citar:

- informações sobre os valores das suas taxas de colesterol, glicose, triglicerídeos, entre outras;
- quantidade de exercícios físicos obtidos a partir do acelerômetro do *smartphone*;
- informações relativas à alimentos consumidos (quais foram e em que quantidade);
- informações relativas à fatores de risco não modificáveis, como idade, etnia, sexo, entre outros;
- em se tratando de um NL (local), atributos relativos à temperatura ambiente, umidade ou índice de qualidade do ar podem também ser armazenados.

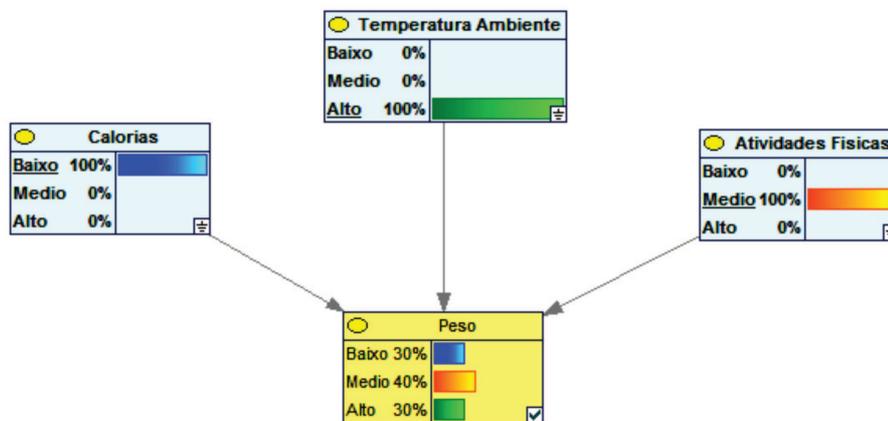
A Figura 18 apresenta um exemplo de relação de causa e efeito em uma RB. Essa abordagem se torna útil, à medida que o próprio paciente pode acompanhar de forma constante a evolução do seu tratamento e, sobretudo, como estão os fatores de risco que influenciam de forma direta ou indireta cada uma das condições crônicas por ele apresentadas.

Para tanto, o ChronicPrediction utiliza uma abordagem que possibilita ao paciente receber *feedbacks* e recomendações em relação ao estado das suas condições crônicas, visando o bom andamento do seu tratamento como um todo. Isso torna-se possível através das informações

que o próprio paciente insere por meio da utilização constante do assistente pessoal ChronicDuctor em seu uso normal, onde, através das atividades estipuladas pelo plano de cuidados a ele destinado, tais como: taxas glicêmicas informadas, níveis de pressão arterial, níveis de colesterol, bem como informações sobre alimentos consumidos, o modelo ChronicPrediction efetua o processo de inferências nas RBs específicas e obtém as previsões relacionadas, com o intuito de auxiliá-lo na melhora dos aspectos do tratamento da sua DCNT que estão sendo negligenciados. Por exemplo: se o paciente sofre de diabetes e, de acordo com os dados obtidos através da RB após ele fornecer as informações relativas, a probabilidade dele ter seu problema agravado for alta, o modelo pode lhe sugerir que ele aumente a frequência com a qual ele pratica exercícios físicos ou que priorize o consumo de alimentos com baixo índice de açúcar e gordura, por exemplo.

Além disso, o fato das RBs serem treinadas previamente através de dados históricos de contextos faz com que as recomendações efetuadas sejam mais coerentes e efetivas. Esse processo de treinamento das RBs pode ser feito de forma periódica com o intuito de manter a RB com as informações mais recentes presentes na base de dados de trilhas, uma vez que essa base é atualizada constantemente à medida que os pacientes vão utilizando o protótipo do modelo.

**Figura 18:** Exemplo de uma relação de causa e efeito em uma RB



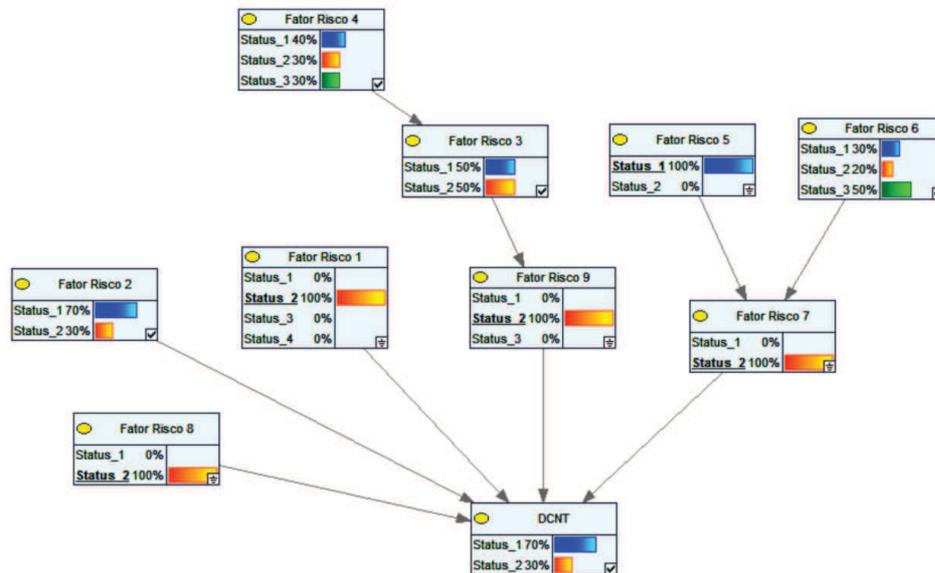
Fonte: Elaborado pelo autor

Os tipos de alimentos são obtidos a partir dos Recursos, que são especificados através do módulo ChronicDuctor, os quais já possuem seus respectivos atributos, tipos e valores previamente cadastrados, cabendo ao paciente informar apenas a quantidade consumida de cada um deles (quantas unidades, quantas colheres, quantas porções, e assim por diante). Informações relativas aos fatores de risco não modificáveis, tais como a idade, etnia e o sexo do paciente, são obtidas a partir dos dados de perfil do paciente presentes no ChronicDuctor.

O ChronicPrediction utiliza modelos de RBs previamente definidos, que podem se utilizar de conhecimento de especialistas no domínio médico para fazer com que se tornem mais confiáveis e contemplem as relações de causa e efeito já estabelecidas para efetuar previsões com

o objetivo de identificar previamente qual o provável *status* dos fatores de risco que afetam o paciente.

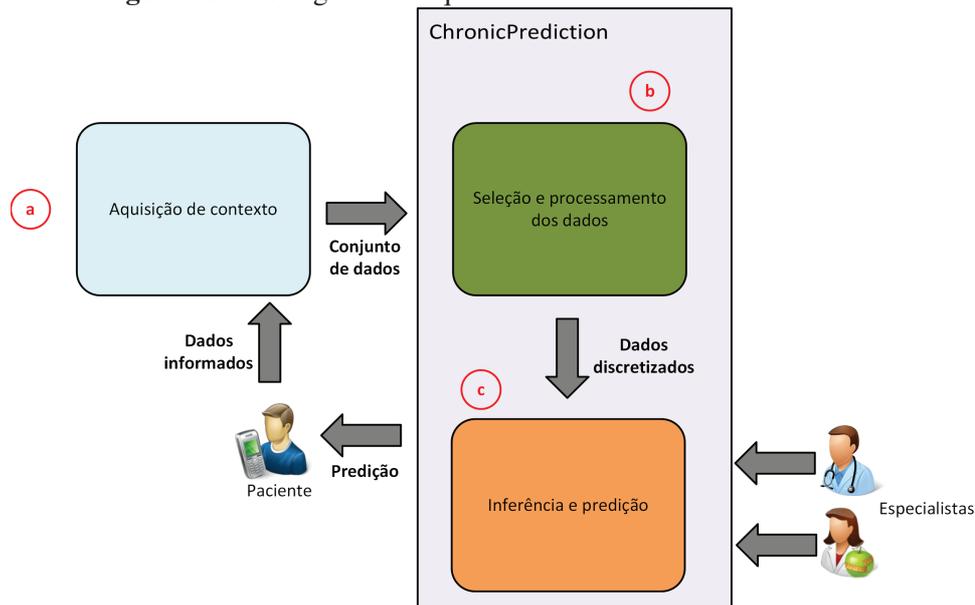
**Figura 19:** Exemplo de um modelo de RB



Fonte: Elaborado pelo autor

A estrutura básica dos modelos de RBs que são empregadas nas previsões efetuadas segue o padrão mostrado na Figura 19, onde aparecem cada um dos fatores de risco (sejam eles modificáveis ou não modificáveis) que influenciam na incidência ou agravamento da DCNT a qual se está monitorando. É importante salientar que cada um desses fatores de risco pode, além de influenciar na DCNT em questão, também influenciar outros fatores de risco. Na Figura 19 os fatores de risco são 9 e estão nomeados seguindo a convenção "Fator Risco 1" até "Fator Risco 9" e as relações de influência entre os fatores de risco são visualizadas entre o "Fator Risco 5", "Fator Risco 6" e "Fator Risco 7" e também entre o "Fator Risco 4", "Fator Risco 3" e "Fator Risco 9". O nó da RB identificado como "DCNT" diz respeito a DCNT a qual se deseja monitorar. É este nó que indicará qual a probabilidade da DCNT em questão ter se agravado ou regredido, podendo também indicar qual a probabilidade do paciente vir a contrair essa doença tendo como base seus hábitos e sua rotina diária.

Na Figura 20 é apresentada uma visão de alto nível da arquitetura de funcionamento interno do módulo ChronicPrediction, sendo executado sobre o *middleware* ConnDuctor e atuando em conjunto com o módulo ChronicDuctor.

**Figura 20:** Visão geral da arquitetura do modelo ChronicPrediction

Fonte: Elaborado pelo autor

O funcionamento do ChronicPrediction é regido por três etapas, onde cada uma delas executa um conjunto específico de tarefas para o funcionamento do módulo:

**Etapa A - Aquisição de contexto:** é composta pelo módulo executável ChronicDuctor, o *middleware* ConnDuctor e seu componente de Contexto. Os pacientes utilizam o ChronicDuctor como assistente pessoal que, por sua vez, controla as informações referentes aos nodos. O componente de Contexto pertencente ao *middleware* ConnDuctor, sendo responsável por armazenar informações referentes a contextos visitados e ações efetuadas, que são geradas ou recebidas pelo nodo. Sendo assim, é mantida uma base de histórico de contextos (trilhas), separadamente, para cada um dos nodos. Desta forma, cada nodo mantém seus dados históricos armazenados e com acesso disponível apenas a ele e a outros nodos que assinem seus contextos.

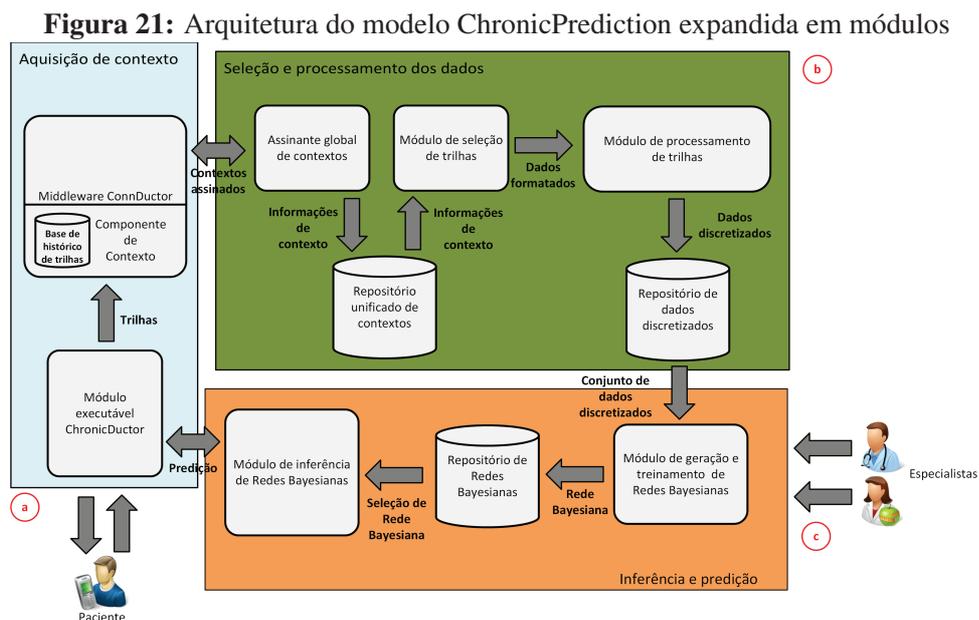
**Etapa B - Seleção e processamento dos dados:** nesta etapa existem três componentes, sendo o primeiro deles um assinante global de contextos, responsável por obter os dados de contextos os quais ele possui acesso a partir das bases históricas de contextos de cada um dos nodos e esses dados são armazenados em um repositório unificado de contextos (o segundo componente), o qual centraliza o armazenamento dos dados de contextos obtidos pelo assinante global. Além disso, nesta etapa, um módulo de seleção de trilhas (terceiro componente), seleciona no repositório unificado de contextos quais dados serão utilizados e é efetuada a discretização, que é o processo de transformação de dados contínuos em dados discretos (CERQUIDES; DE MANTARAS, 1997). Após armazenados, estes dados discretizados poderão ser utilizados no processo de treinamento das RBs.

**Etapa C - Inferência e predição:** é nesta etapa em que, a partir da interface designada, especialistas da área médica / nutricional ou qualquer pessoa que possua o conhecimento adequado poderá criar as RBs que se deseja utilizar. Além disso, a partir do repositório de dados

discretizados gerado na Etapa B, se pode efetuar o processo de aprendizagem da RB criada. Após isso a RB é armazenada em um repositório de redes Bayesianas para que possa ser utilizada por um módulo de inferência. O objetivo de cada uma das RBs deve ser o de fornecer ao paciente *feedbacks* sobre o andamento do seu tratamento, tomando como base para isso as informações que o paciente menciona através do uso do ChronicDuctor, durante o andamento do seu tratamento e do Plano de Atividades criado pelo profissional responsável. Um módulo de inferência, o qual a partir dos dados de tratamento do paciente obtidos através do uso do ChronicDuctor como assistente pessoal, efetua a inferência das RBs. Os resultados obtidos serão informados ao paciente através da interface do próprio assistente pessoal com o intuito de fornecer uma visão geral sobre o andamento do seu tratamento. Se este esta sendo efetivo ou não e se ele, paciente, está seguindo as diretivas estipuladas pelo Plano de Cuidados no tratamento das suas DCNT. Em seu perfil o paciente poderá informar sobre quais DCNTs ele desejará receber *feedbacks* durante seu tratamento e utilização do ChronicDuctor.

### 4.3 Modularização dos componentes do modelo ChronicPrediction

Cada uma das etapas do funcionamento do ChronicPrediction é composta por um conjunto de módulos e componentes que trocam informações e são responsáveis por definirem o fluxo de dados de uma etapa para a etapa seguinte. A Figura 21 apresenta a arquitetura do ChronicPrediction de forma expandida e detalhada, demonstrando a comunicação entre cada um de seus módulos e componentes.



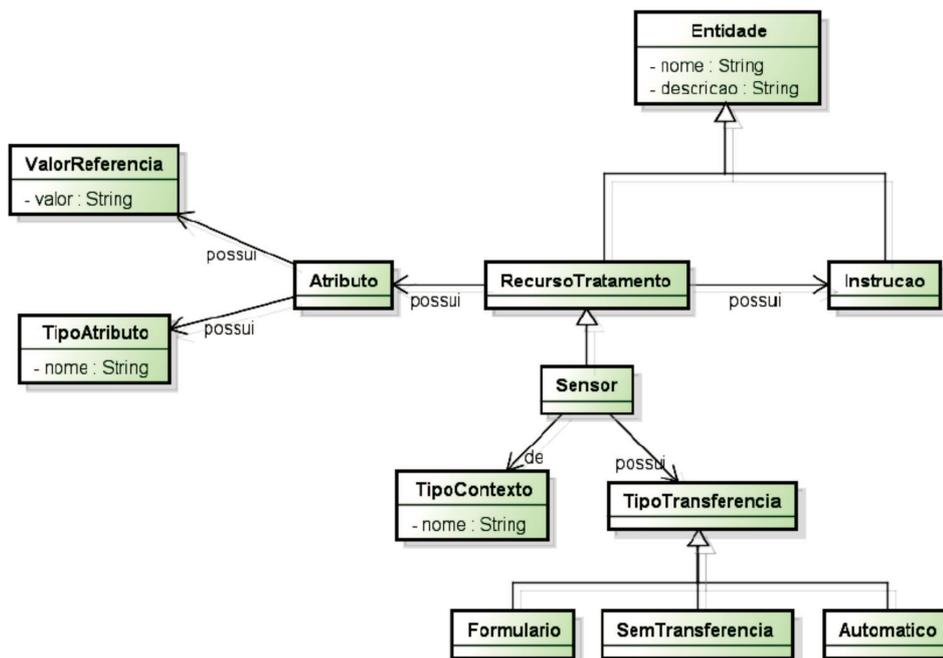
Fonte: Elaborado pelo autor

#### 4.3.1 Etapa de aquisição de contexto

**ChronicDuctor:** pacientes utilizam o ChronicDuctor como assistente pessoal no gerenciamento e prevenção de DCNTs. O ChronicDuctor, por sua vez, armazena informações referentes aos nodos que, quando representam uma pessoa, podem ser descritos como sendo a temperatura, pressão arterial, índice glicêmico, por exemplo.

A ontologia que caracteriza os recursos do ChronicDuctor é apresentada na Figura 22. Essa ontologia descreve os conceitos que envolvem os recursos utilizados para o cuidado de DCNTs. A classe **RecursoTratamento** é utilizada com o objetivo de representar qualquer recurso que possa ser utilizado para o cuidado de DCNTs. Um recurso de tratamento pode possuir instruções de como ele pode ser utilizado e esse conceito é representado pela relação *possui Instrucao*. Um vídeo de operação de um monitor de pressão arterial, a bula de um medicamento, ou qualquer outro material que possa auxiliar o paciente ou responsável nas atividades de cuidado pode ser considerado como sendo uma instrução.

Figura 22: ChronicDuctor - Modelo Ontológico de Recursos



Fonte: (VIANNA, 2013)

Um **RecursoTratamento** possuirá, por definição, atributos que descrevem suas características. Este conceito é representado pelo relacionamento **RecursoTratamento possui Atributo**. Cada **Atributo** é descrito por um par de **TipoAtributo** e **ValorReferencia**. Assim, é possível descrever diferentes tipos de recursos de tratamento como, tais como, alimentos e medicamentos.

**Sensor** é um tipo especial de recurso de tratamento utilizado para efetuar medições de algum tipo de indicador com o intuito de acompanhar a situação de saúde do paciente. Uma

balança, um glicosímetro, ou um monitor de pressão arterial são exemplos de sensores. O relacionamento “*de TipoContexto*” descreve o tipo de contexto que aquele sensor irá gerar, tais como o índice glicêmico, pressão arterial sistólica e diastólica, peso. O relacionamento “*possui TipoTransferencia*” descreve como os dados são transmitidos pelo sensor. A ontologia de recursos do ChronicDuctor prevê três tipos de entrada: **Formulario**, onde a transferência de dados entre o sensor e o *smartphone* do paciente é feita por meio de um formulário eletrônico; **Automatica**, a transferência é feita sem que o usuário necessite digitar os dados lidos, embora possa haver a necessidade de pareamento com o sensor; e **SemTransferencia**, onde o sensor não provê um meio para transferência da leitura efetuada.

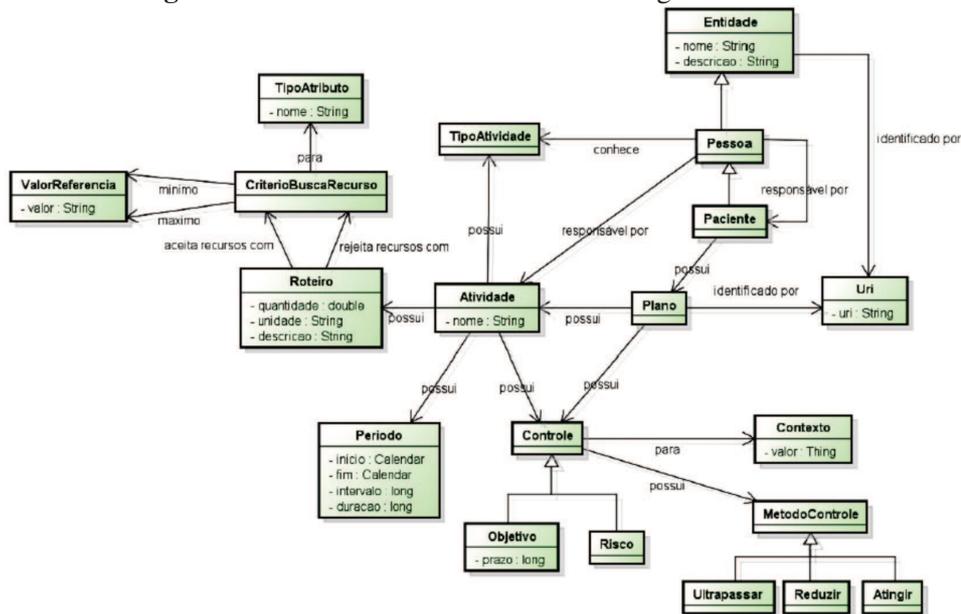
Já a ontologia de plano do ChronicDuctor descrita por Damasceno Vianna e Barbosa (2014) e apresentada na Figura 23 descreve o plano criado por médicos e outros profissionais de saúde com o objetivo de auxiliar o paciente a manter a concentração no cuidado de sua doença (DAMASCENO VIANNA; BARBOSA, 2014). Nessa ontologia a classe **Pessoa** possui três novos relacionamentos, “*responsável por paciente*”, “*conhece TipoAtividade*” e “*responsável por Atividade*”.

O relacionamento “*responsável por Paciente*” indica que a pessoa é responsável de alguma forma pelo andamento do cuidado do paciente, sendo autorizado a receber notificações alterações da situação de saúde do paciente. Enfermeiros, médicos e familiares são exemplos de responsáveis pelo paciente. O relacionamento “*responsável por Atividade*” descreve as pessoas que são responsáveis por alguma atividade específica do paciente, por exemplo, um nutricionista é responsável pelas atividades alimentares do paciente, enquanto que um educador corporal é responsável pelas atividades físicas executadas pelo paciente. Os responsáveis por atividades são autorizados a acompanhar o andamento dos indicadores relacionados a atividade. O relacionamento “*conhece TipoAtividade*” caracteriza que uma pessoa conhece, ou possui experiência, e algum um tipo de atividade de cuidado, assim é possível localizar pessoas que possam auxiliar o paciente em suas atividades de cuidado.

A classe **Paciente** representa uma pessoa que possui algum problema médico tratado através de um **Plano** de tratamento (“*possui Plano*”). A classe **Plano** define o plano de tratamento criado em parceria com o responsável médico do paciente, utilizado para auxiliar o paciente no cuidado de sua saúde. Já um plano é composto por atividades (“*possui Atividade*”) e controles (“*possui Controle*”).

A classe **Controle** faz parte da descrição do plano de cuidado do paciente, servindo para fazer com que o paciente mantenha a concentração no tratamento de sua doença. O relacionamento “*para Contexto*” indica um parâmetro utilizado como referência para controlar algum tipo de indicador corporal, enquanto que o relacionamento “*possui MetodoControle*” indica a forma como é feito esse controle. São três os métodos de controle: **Reduzir**, que indica que o novo contexto gerado pelo paciente é menor que o valor do parâmetro de controle; **Ultrapassar**, que indica que o novo contexto gerado pelo paciente ultrapassou o valor do parâmetro de controle; e **Atingir**, que indica que o contexto gerado pelo paciente é igual ao valor do parâmetro

Figura 23: ChronicDuctor - Modelo Ontológico de Planos



Fonte: (VIANNA, 2013)

de controle. Utilizando essa forma de controle torna-se possível avaliar se o paciente alcançou os objetivos planejados ou, ao contrário, se atingiu uma situação de risco.

A **Atividade** é uma tarefa que deve ser executada pelo paciente em um momento determinado como, por exemplo, fazer a medição de algum indicador corporal, ingerir um medicamento, ou efetuar uma atividade física. A relação “*possui Período*” define o momento de início e fim de tal atividade, o intervalo em que essa atividade deverá se repetir, e a sua duração. Por exemplo, o paciente deverá efetuar nebulização todo dia durante seis meses por dez minutos, nesse caso, o atributo início indica a data e hora em que o paciente deve iniciar a nebulização, o atributo fim define o momento em que a nebulização será interrompida, o atributo intervalo descreve de quanto em quanto tempo essa atividade se repetirá (no caso do exemplo, uma vez por dia) e a duração define por quanto tempo essa atividade será efetuada. A relação **Atividade** “*possui Controle*” possibilita a descrição de parâmetros que auxiliem no monitoramento da atividade que está sendo executada.

A relação **Atividade** “*possui Roteiro*” fornece instruções daquilo que o paciente deve executar na atividade. Ela indica a quantidade de vezes que um **Recurso Tratamento** será utilizado dentro da atividade, possibilitando que sejam descritas dietas, planos de atividade física, lembretes de uso de medicamento ou medições de algum tipo de indicador corporal. Nessa situação, a classe **CriterioBuscaRecurso** é utilizada para descrever as características dos recursos que podem ser utilizados pelo roteiro, através da relação *aceita recursos com CriterioBuscaRecurso*, ou recursos que devem ser ignorados, através da relação *rejeita recursos com CriterioBuscaRecurso*. A relação **CriterioBuscaRecurso** para *TipoAtributo* indica uma característica que o recurso deve possuir, enquanto que as relações **CriterioBuscaRecurso** *minimo ValorReferencia* e **CriterioBuscaRecurso** *maximo ValorReferencia*, descrevem os valores válidos que as

características devem possuir para que os recursos sejam aceitos.

**Middleware ConnDuctor e Componente de Contexto:** o Componente de Contexto, localizado no *middleware* ConnDuctor, possui, através da sua base de históricos de trilhas, a capacidade de armazenar informações de contextos recebidas ou geradas pelos nodos. Ou seja, considerando que um determinado nodo esteja representando um paciente, na base de histórico de trilhas referente a esse paciente estariam armazenadas informações como, por exemplo, sua pressão arterial e índice glicêmico. É importante destacar que as bases de históricos de contextos são individuais, ou seja, cada nodo possui sua própria base. Além disso, o Componente de Contexto torna possível que um determinado nodo ou qualquer elemento que implemente a interface de contexto (assine) tenha acesso a determinados dados de contextos e trilhas referentes a outros nodos e receba notificações quando ocorrerem alterações nesses dados. Um outro aspecto a se destacar é o fato de que os nodos podem especificar que tipo de informações poderão ser assinadas por outros nodos, permitindo que seja compartilhado apenas aquilo que achar mais conveniente.

Na Figura 24, Vianna (2013) apresentam uma ontologia que representa os conceitos do ConnDuctor. **Entidade** é a classe central dessa ontologia. Uma entidade é identificada por um **URI**, onde URI é um conjunto de caracteres gerado por meio de um esquema de nomeação extensível e que permite a identificação de maneira uniforme de diferentes tipos de recursos (BERNERS-LEE; FIELDING; MASINTER, 2005). Desta forma, todas as classes que possuem o relacionamento “*identificado por URI*” são equivalentes a classe **Recurso**.

Um **Recurso** possuirá uma ou mais representações, sendo elas identificadas através dos tipos MIME, os quais determinam o formato de apresentação desse recurso (FREED; BORENSTEIN, 1996). Este conceito é descrito na ontologia através do relacionamento “*possui Representação*”.

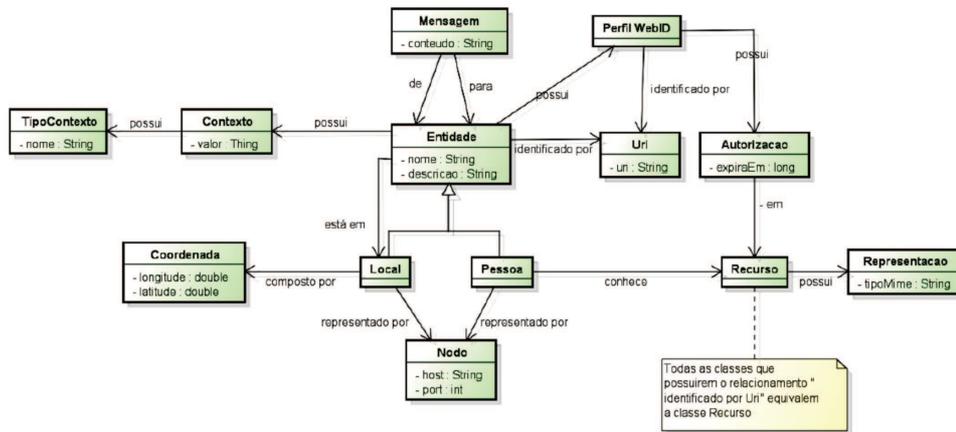
Um **Local** é utilizado com o intuito de representar uma região espacial disponível em algum local, tal como uma casa, rua ou um parque, por exemplo. O relacionamento “*está em*” identifica que uma entidade está presente em algum local. A relação “*composto por coordenada*” descreve os pontos que delimitam a área do local. Os atributos latitude e longitude mantêm as coordenadas geográficas que identificam cada ponto que compõe esse local.

Uma **Pessoa** identifica um usuário em determinado ambiente. A relação identificada como “*conhece*” possibilita descrever que uma determinada pessoa conhece algum **Recurso** específico, tal como um lugar, uma pessoa ou um livro, por exemplo.

A classe **Nodo** descreve um dispositivo que executa o *middleware* ConnDuctor, mantendo nos seus atributos as informações relevantes para a comunicação com ele. Um **Nodo** pode representar uma **Pessoa** ou **Local**.

A classe **Perfil WebId** identifica a relação entre a entidade e o documento utilizado para certificar a autenticidade de sua identidade (SPORNY et al., 2011), e descrevendo as ligações sociais existentes com outras entidades, com o intuito de inferir as autorizações a recursos através de confiança (GAMBLE; GOBLE, 2010). As autorizações a recursos que não puderam

Figura 24: Modelo Ontológico ConnDuctor



Fonte: (VIANNA, 2013)

ser inferidas de forma automática serão representadas através da classe **Autorização**, que possui um prazo para expiração, descrito pelo atributo “*expiraEm*”.

**Tipo Contexto** e **Contexto** são utilizados para representar genericamente as informações que caracterizam a situação de uma entidade (DEY; ABOWD; SALBER, 2001). Um **Contexto** deve possuir um determinado valor que o representa. Uma vez que esse valor pode possuir muitos formatos ele é descrito como sendo do tipo *Thing*, que é a classe raiz do modelo ontológico. Sendo assim, todas as classes definidas no modelo também são subclasses de *Thing*. A classe **TipoContexto** representa a classificação de determinada informação de contexto. Por exemplo: clima, local, quantidade de tráfego de dados.

A classe **Mensagem** é utilizada para caracterizar a comunicação entre duas ou mais entidades do modelo e possui os relacionamentos *de*, que representa a entidade de origem da comunicação, *para*, que representa os destinatários da comunicação, e o atributo *conteudo*, que representa a mensagem propriamente dita, que foi enviada pelo remetente aos destinatários.

#### 4.3.2 Etapa de seleção e processamento dos dados

**Assinante global de contextos:** como cada nodo possui seu próprio repositório contendo suas informações históricas de contextos, o assinante global busca unificar essas informações em um único repositório de forma centralizada. Esse repositório unificado de contextos armazena informações de todos os repositórios pertencentes aos nodos os quais o assinante global de contextos tem acesso (assina) as informações. É importante salientar que, quando novas informações de contexto provenientes de algum dos nodos os quais compartilham informações com o assinante global estiverem disponíveis, ele será notificado e receberá as novas informações. Isso pode ocorrer, por exemplo, quando um dos nodos sofrer uma mudança de contexto ou uma mudança no valor no contexto o qual ele se encontra.

**Repositório unificado de contextos:** o objetivo deste repositório unificado é facilitar o

acesso aos dados de contextos compartilhados pelos diferentes nodos e que são obtidos através do Assinante Global de Contextos, o qual cabe o papel de receber esses dados. Esse repositório é encarregado de fornecer as informações de contexto solicitadas e utilizadas pelo Módulo de Seleção de Trilhas, pois desta forma o módulo não necessitará acessar diferentes repositórios de dados para obter informações para o posterior treinamento das RBs utilizadas.

**Módulo de seleção de trilhas:** módulo que tem como funcionalidade principal acessar e selecionar dados do Repositório Unificado de Contextos (trilhas). A partir destes dados, são selecionados aqueles que são relevantes para o tipo de *feedback* que se deseja fornecer ao paciente e, conseqüentemente, para a RB que se deseja utilizar. Tal procedimento de seleção se faz necessário, uma vez que, nem todos os dados históricos de contexto que são armazenados serão utilizados pelas RBs, devido à relevância que eles podem ou não possuir para um determinado *feedback* em relação a alguma DCNT. A partir do tipo de condição crônica que se deseja monitorar, efetuar as predições e fornecer os *feedbacks*, existirá uma respectiva RB no Repositório de RBs. Sendo assim, para efetuar a seleção do conjunto de trilhas que se deseja utilizar para o processo de treinamento da RB desejada será utilizada linguagem SQL (*Structured Query Language*)<sup>1</sup> para fazer as consultas à base de dados de histórico de trilhas. Cada consulta selecionará o conjunto de dados referente a cada um dos nodos da RB que se deseja utilizar. Logo após, o conjunto de dados retornado pela consulta é armazenado em um arquivo formato texto para, posteriormente, ser utilizado pelo Módulo de Processamento de Trilhas para serem discretizados.

**Módulo de processamento de trilhas:** o módulo de processamento de trilhas tem como objetivo preparar os dados para serem utilizados no posterior processo de treinamento das RBs. O processo de preparação dos dados corresponde a discretização do conjunto de dados que será utilizado para o treinamento de uma RB. A discretização cumpre papel importante sobre o conjunto de dados utilizados, uma vez que esses dados podem ser, muitas vezes, contínuos e, através do processo de discretização, eles assumem valores discretos e podem mais facilmente serem divididos em faixas de intervalos.

Dois dos métodos de discretização mais simples e bastante utilizados são a Discretização em Intervalos Iguais (*Equal Width Discretization* - EWD) (CERQUIDES; DE MANTARAS, 1997; DOUGHERTY et al., 1995) e a Discretização em Frequências Iguais (*Equal Frequency Discretization* - EFD) (CERQUIDES; DE MANTARAS, 1997; LIU et al., 2002). Na EWD são criados  $k$  intervalos de igual tamanho onde  $k$  é um número inteiro maior que zero definido externamente. Já na EFD são criados  $k$  intervalos de modo que cada intervalo contenha aproximadamente o mesmo número de ocorrência de valores. Tais métodos de discretização não levam em conta qualquer informação sobre possíveis relacionamentos entre as variáveis e, portanto podem fazer com que os padrões de relacionamento sejam perdidos. Sua simplicidade de implementação, porém, os torna muito populares, principalmente na comparação de desempenho com outros métodos de discretização (YONEYAMA, 2003).

---

<sup>1</sup>[http://www.iso.org/iso/home/store/catalogue\\_tc/catalogue\\_detail.htm?csnumber=53681](http://www.iso.org/iso/home/store/catalogue_tc/catalogue_detail.htm?csnumber=53681)

**Repositório de dados discretizados:** o repositório de dados discretizados é responsável por armazenar os dados que já foram processados pelo Módulo de Processamento de Trilhas e que estão prontos para serem utilizados no processo de treinamento das RBs. Grande parte das APIs de desenvolvimento utilizadas para modelar RBs utiliza arquivos de dados no formato texto; desta forma, este repositório armazenará a localização física de cada um dos arquivos de dados discretizados.

#### 4.3.3 Etapa de inferência e predição

**Módulo de geração e treinamento de RBs:** este módulo tem como função controlar as funcionalidades de geração e modelagem das RBs bem como o processo de treinamento dessas redes. Especialistas da área médica / nutricional ou qualquer pessoa que possua o conhecimento adequado poderá criar as RBs que se deseja utilizar. Na modelagem de RBs, um dos modelos de raciocínio aceitos é o modelo de causa e efeito (PEARL, 2000). Além disso, destaca-se o fato de que o ChronicPrediction aceita, além do modelo de causa e efeito, modelos de inferência tanto de diagnóstico (AGRE, 1997), quanto intercausal (KJÆRULFF; MADSEN, 2007). Após a geração das RBs, elas serão treinadas e calibradas utilizando-se dos dados discretizados provenientes do módulo de processamento de trilhas e que estão armazenados no repositório de dados discretizados. Esses dados serão selecionados de acordo com o tipo de RB o qual se deseja modelar e calibrar.

**Repositório de RBs:** o repositório de RBs é utilizado para armazenar cada uma das RBs criadas, de forma centralizada, a fim de facilitar a sua posterior utilização. O repositório será acessado, inicialmente, pelo módulo de inferência, mas pode ser acessado por qualquer outro módulo que deseje utilizar as RBs criadas.

**Módulo de inferência de RBs:** o módulo de inferência tem o intuito de extrair as predições a partir dos dados fornecidos pelo paciente. Esses dados são obtidos a partir dos valores das informações inseridas pelos pacientes durante a utilização do módulo ChronicDuctor, ou obtidos automaticamente através dos sensores do próprio *smartphone*. Essas informações podem ser, por exemplo, referentes ao tipo de alimento consumido e em que quantidade, valores de medição da pressão arterial, temperatura ambiente, dentre outras informações. É neste módulo que as inferências são efetuadas e interpretadas e, após isso, estando de posse dos resultados das predições, o paciente que está utilizando o ChronicDuctor recebe *feedbacks*, sendo informado sobre a situação em que se encontram suas condições crônicas e, a partir disso, consegue ter uma orientação se as ações por ele tomadas, hábitos e atitudes, sejam elas alimentares ou comportamentais são as mais adequadas para o bom andamento do seu tratamento.

#### 4.4 Considerações finais sobre o capítulo

O presente capítulo apresentou o ChronicPrediction, um modelo para predição de fatores de risco em DCNTs. O ChronicPrediction é executado como um módulo executável do modelo UDUCTOR, que é um modelo para cuidados ubíquos de DCNT. O ChronicPrediction utiliza-se da infraestrutura fornecida pelo *middleware* ConnDuctor para acessar dados históricos de contexto e, desta forma, efetuar o calibragem (treinamento) das RBs utilizados pelo módulo de predição.



## 5 AVALIAÇÃO DO MODELO

Este capítulo apresenta as tecnologias que foram utilizadas na implementação do protótipo do ChronicPrediction, bem como a sistemática empregada para a avaliação do modelo. Na primeira seção são apresentados os principais aspectos relativos a implementação do protótipo e nas demais seções e subseções são descritos os dados utilizados nos processos de avaliação, bem como são descritos os cenários de avaliação e os experimentos efetuados.

### 5.1 Aspectos de Implementação

O desenvolvimento do protótipo está dividido em duas etapas: a etapa de projeto e análise e a etapa de implementação. Para a etapa de projeto utiliza-se a linguagem UML, por ser um padrão amplamente estabelecido e utilizado na indústria de Engenharia de Software para modelagem de sistemas, principalmente, aqueles baseados no paradigma da orientação a objetos (FOWLER, 2004). As RBs utilizadas pelo modelo, foram elaboradas através da ferramenta GeNIe<sup>1</sup>, por ser uma ferramenta gratuita, que contém um conjunto significativo de funcionalidades e está constantemente sendo atualizada. A ferramenta é desenvolvida pelo *Decision Systems Laboratory*, da universidade de Pittsburgh (DRUZDZEL, 1999).

A etapa de implementação do protótipo utiliza a plataforma móvel *Android*<sup>2</sup> para o desenvolvimento da interface no aplicativo para dispositivo móvel, enquanto que a parte dos módulos de serviço foram desenvolvidos utilizando interface REST na plataforma J2SE, através do pacote Jersey<sup>3</sup>, que é uma implementação da especificação JAX-RS<sup>4</sup> para *web services* utilizando REST na arquitetura Java. Na plataforma Android a interface REST foi desenvolvida através do uso da API Restlet<sup>5</sup>. Toda a comunicação do módulo ChronicPrediction com o *middleware* ConnDuctor e seus componentes se dará através da interface REST disponibiliza pelo *middleware*. Isso oferece uma interface unificada e padronizada para a obtenção das informações históricas de contexto requeridas pelo módulo através do componente de Contexto que faz parte do *middleware*, podendo da mesma forma ser utilizada por outros módulos que venham a fazer parte da plataforma UDuctor posteriormente.

Além da comunicação com o *middleware* ConnDuctor, o módulo ChronicPrediction utilizará informações relativas a Recursos e seus atributos, que são obtidas a partir do módulo executável ChronicDuctor, e que são utilizados para a posterior geração das RBs. Da mesma forma, essa comunicação se dará através de interfaces REST. Caso seja necessário, ajustes serão feitos no modelo UDuctor e no módulo ChronicDuctor de forma que os dados que serão

---

<sup>1</sup><http://genie.sis.pitt.edu/>

<sup>2</sup><http://www.android.com>

<sup>3</sup><http://Jersey.java.net>

<sup>4</sup><http://jax-rs-spec.java.net>

<sup>5</sup><http://www.restlet.org>

utilizados pelo ChronicPrediction sejam retornados no formato JSON<sup>6</sup>, que trata-se de um formato leve de troca de dados, sendo fácil de interpretar e de ser gerado, estando baseado em um subconjunto da linguagem JavaScript (OSKARSSON et al., 1996).

Para que seja possível efetuar o processo de inferência nas RBs e realizar as predições, foi utilizada a biblioteca jSMILE<sup>7</sup>, que é a versão da biblioteca SMILE<sup>8</sup> portada para a linguagem Java. SMILE é uma biblioteca que permite criar, editar e salvar modelos gráficos para utilizar raciocínio probabilístico e tomada de decisão sob incerteza.

## 5.2 Metodologia de Avaliação

Para que fosse possível efetuar a avaliação do modelo proposto através do protótipo desenvolvido, foram estabelecidos três tipos de avaliação, os quais se deram através da aplicação de experimentos controlados.

Um experimento é um procedimento ordenado com o objetivo de verificar, rejeitar ou estabelecer a validade de uma hipótese. Experimentos controlados fornecem uma visão de causa e efeito, demonstrando o resultado que ocorre quando um determinado fator é manipulado. Experimentos controlados variam muito em seu objetivo e escala, mas sempre dependem de um processo repetitivo e análise lógica dos resultados (MORESI, 2003).

Como primeira avaliação, tem-se o teste do protótipo em cenários elaborados utilizando-se de dados reais coletados a partir de pacientes portadores de Doença Arterial Coronariana (DAC) (GAEDKE, 2013), onde se busca verificar se através do acompanhamento diário das suas rotinas e através de recomendações feitas pelo protótipo desenvolvido, os pacientes poderiam melhorar a sua condição crônica e evoluir no seu tratamento.

Na segunda avaliação o objetivo é demonstrar a capacidade do modelo de monitorar e controlar não apenas pacientes portadores de DAC, mas sim, pacientes portadores de mais de uma deficiência crônica, podendo, desta forma, monitorar os aspectos relativos a cada uma dessas doenças, oferecendo informações e recomendações.

Para concluir o processo, como terceiro tipo de avaliação optou-se pela utilização de um questionário simples que foi respondido por pessoas com algum tipo de doença cardíaca, onde lhes era perguntado, dentre outras coisas, se eles utilizariam um aplicativo para dispositivo móvel cujo objetivo é monitorar e acompanhar sua rotina e condições crônicas, lhes fornecendo recomendações e informações. Além disso, mencionaram que tipo de problema cardíaco possuem, o que achariam relevante ter em um aplicativo destinado a este fim, dentre outras informações.

---

<sup>6</sup><http://www.json.org>

<sup>7</sup>[http://genie.sis.pitt.edu/wiki/Introduction\\_to\\_jSMILE](http://genie.sis.pitt.edu/wiki/Introduction_to_jSMILE)

<sup>8</sup>[http://genie.sis.pitt.edu/wiki/Introduction:\\_SMILE](http://genie.sis.pitt.edu/wiki/Introduction:_SMILE)

## 5.3 Primeira Avaliação

### 5.3.1 Dados de Pacientes Portadores de Doenças Cardiovasculares

As doenças cardiovasculares representam um importante problema de saúde pública não só no nosso meio, mas em todo o mundo, visto que constituem a principal causa de morbimortalidade e representam os mais altos custos em assistência médica (GUS et al., 1999; GUS; FISCHMANN; MEDINA, 2002).

Aproximadamente 3/4 das mortes causadas por doenças cardiovasculares no mundo são provenientes de países desenvolvidos, e o infarto agudo do miocárdio é uma importante causa de morte. O Brasil é um dos maiores países na América Latina e a avaliação dos fatores de risco para o infarto do miocárdio é crucial para um gerenciamento mais eficaz (PIEGAS et al., 2003).

Fatores de Risco são definidos como sendo qualquer elemento clínico ou laboratorial associado com a probabilidade da doença e sua progressão durante um período de tempo variável (KANDEL, 1990).

O controle dos Fatores de Risco pode reduzir as doenças coronárias e sua mortalidade. Assim, a identificação e avaliação do impacto dos fatores de risco na população tem uma importância fundamental no gerenciamento da doença e pode explicar o motivo pelo qual nos anos recentes, a mortalidade por doenças coronárias tem decido em alguns países e crescido em outros (PIEGAS et al., 2003).

De acordo com estimativas da OMS, aproximadamente 40% de todas as mortes serão relacionadas a doenças cardiovasculares em 2020, com o infarto agudo do miocárdio sendo a principal causa isolada (LOPEZ; PROJECT, 2006).

Para o teste do protótipo ChronicPrediction e a realização dos experimentos utilizando dados reais de pacientes portadores de doenças cardiovasculares foi necessário que, inicialmente, fossem identificados os principais fatores de risco que ocasionam a DAC e, posteriormente, definir de que forma esses fatores de risco se relacionam uns com os outros. Como base científica para a obtenção dos fatores de risco, utilizou-se o Escore de Framingham (LOTUFO, 2013; POLANCZYK et al., 2005), que é uma fórmula de previsão na população em geral que busca através dos seus resultados especificar a probabilidade de ocorrência de doença coronariana. De acordo com faixa etária, sexo, valores de pressão arterial sistólica, valores da razão entre colesterol total e fração HDL, presença de tabagismo e diagnóstico de diabetes, torna-se possível estabelecer o risco de infarto do miocárdio e angina do peito em dez anos.

Além do Escore de Framingham, foram feitas diversas reuniões onde foram consultados quatro especialistas da área médica e nutricional (duas professoras, uma aluna de doutorado e uma aluna de pós-doutorado), todos participantes de projetos de pesquisa no Programa de Pós-Graduação em Saúde Coletiva da Unisinos, com o intuito de refinar e complementar os fatores de risco que seriam envolvidos. Foram, então, estabelecidos os seguintes fatores de risco como sendo os principais envolvidos na DAC:

- Tabagismo
- Pressão Arterial Sistólica
- Pressão Arterial Diastólica
- Colesterol Total
- Colesterol HDL
- Glicose
- Sexo
- Peso
- Medida da Cintura
- Atividade Física
- Histórico Familiar de DCNT
- Idade

Outro ponto importante para a posterior criação da RB a partir destes fatores de risco é a necessidade de se definir quais intervalos de valores estariam contemplados em cada um dos status de cada um dos nodos da RB. Para tanto, com base na literatura médica (CACOUB et al., 2011; SANTOS et al., 2002a,b; SPOSITO et al., 2013), foram obtidos os seguintes dados para aqueles fatores de risco que possuem valores contínuos ou que são tratados de forma distinta de acordo com o seu valor (Tabela 4).

Definidos os intervalos de valores representativos para cada um dos fatores de risco envolvidos, foram então definidas as relações de causa e efeito entre esses fatores, de forma a compor a RB para DAC. Da mesma forma, foram consultados novamente quatro especialistas da área médica e nutricional (duas professoras, uma aluna de doutorado e uma aluna de pós-doutorado), participantes do Programa de Pós-Graduação em Saúde Coletiva da Unisinos que, após análise de cada um dos fatores, estabeleceu-se que uma possível relação entre eles se daria da seguinte maneira, conforme demonstra a Figura 25.

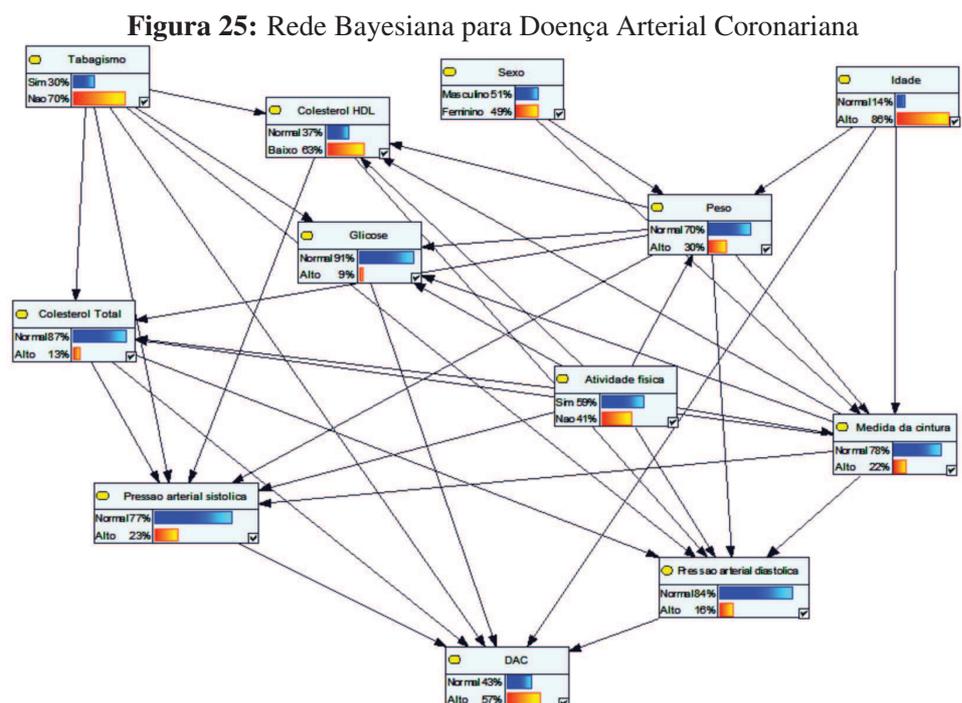
Para o adequado processo de treinamento das RBs, torna-se importante que se tenha um conjunto de dados relacionados diretamente ao domínio o qual a RB se propõe a mapear e inferir informações. Além disso, a utilização de dados reais faz com que o modelo de RB utilizado tenha a capacidade de efetuar predições e diagnósticos de forma coerente e refletindo com um alto grau de exatidão o valor das informações as quais se busca obter.

Os dados utilizados no processo de treinamento da RB de DAC foram obtidos a partir do trabalho de dissertação de mestrado intitulado “Uso de Medicamentos de Prevenção Secundária Após Síndrome Coronariana Aguda” (GAEDKE, 2013), que foi desenvolvido através do

**Tabela 4:** Fatores de risco para DAC e seus respectivos intervalos de valores

Fator de Risco	Intervalos de valores		
	Normal	Alto	
Pressão Arterial Sistólica	<140mmHg	>= 140mmHg	(CACOUB et al., 2011)
Pressão Arterial Diastólica	<90mmHg	>= 90mmHg	(CACOUB et al., 2011)
Colesterol Total	<200mg/dl	>= 200mg/dl	(CACOUB et al., 2011)
Glicose	<110mg/dl	>= 110mg/dl	(CACOUB et al., 2011)
Peso	<25 valor do IMC	>= 25 valor do IMC	(SANTOS et al., 2002a)
Medida da Cintura	<102cm (Homens)	>= 102cm (Homens)	(SANTOS et al., 2002a)
	<88cm (Mulheres)	>= 88cm (Mulheres)	
Idade	<45 anos (Homens)	>= 45 anos (Homens)	(SANTOS et al., 2002b)
	<55 anos (Mulheres)	>= 55 anos (Mulheres)	
Fator de Risco	Intervalos de valores		
	Baixo	Normal	
Colesterol HDL	<40mg/dl	>= 40mg/dl	(SPOSITO et al., 2013)

Fonte: Elaborado pelo autor



Fonte: Elaborado pelo autor

Programa de Pós-Graduação em Saúde Coletiva da Unisinos. A dissertação por ela desenvolvida teve como origem um estudo intitulado “Projeto de coorte prospectiva de pacientes com Síndrome Coronariana Aguda” com duração de dois anos envolvendo pacientes de trinta anos ou mais, de ambos os sexos, com diagnóstico da referida síndrome e internados no Instituto de Medicina Vascular do Hospital Mãe de Deus, em Porto Alegre, RS. A entrada de pacientes no projeto aconteceu de maio de 2009 a maio de 2011.

As subseções seguintes descrevem o local de estudo onde foram obtidos os dados utilizados, a população estudada, os critérios de exclusão, além da quantidade de amostras e experimentos aplicados no estudo realizado. Logo após, são apresentadas as variáveis selecionadas a partir da base de dados e os cenários de avaliação propostos para utilização do protótipo do modelo ChronicPrediction.

### 5.3.2 Local do Estudo e Descrição dos Dados

O Hospital Mãe de Deus corresponde a uma das cinco unidades do Sistema de Saúde Mãe de Deus, estando localizado na cidade de Porto Alegre, Rio Grande do Sul, Brasil. É uma entidade filantrópica, criada pelas irmãs Scalabrianas, sendo inaugurada em 1º de junho de 1979, oferecendo 40 leitos para internação. Atualmente, o hospital conta com 400 leitos, mais de 1700 funcionários e 50 mil m<sup>2</sup> de área construída, dispondo de recursos de diagnósticos utilizando tecnologias de ponta. Foi acreditado pela Organização Nacional de Acreditação como nível 3, sendo considerado como uma referência para o Estado e para a região Sul do Brasil.

O projeto de coorte prospectiva previa em um primeiro momento a inclusão de pacientes portadores de síndrome coronariana aguda, com mais de 30 anos, de ambos os sexos, egressos do Instituto de Medicina Vascular do Hospital Mãe de Deus, residentes no estado do Rio Grande do Sul. Porém, logo no início do arrolamento de pacientes através da lista inicial de problemas foi identificada a necessidade de se ampliar os critérios de inclusão. Sendo assim, foram incluídas no estudo, além da referida síndrome, pacientes com acidente vascular cerebral, acidente isquêmico transitório, cardiopatia isquêmica, placa de carótida e dor torácica (GAEDKE, 2013).

Os pacientes elegíveis para o estudo foram aqueles de trinta anos ou mais, de ambos os sexos, com diagnóstico de SCA (angina instável, IAM sem supradesnivelamento do segmento ST e IAM com supradesnivelamento do segmento ST), provenientes do Instituto de Medicina Vascular do Hospital Mãe de Deus durante os dois anos de entrada na coorte, acompanhados aos seis meses e um ano após a alta hospitalar.

Do estudo original foram excluídos do estudo aqueles pacientes que residiam fora do Estado do Rio Grande do Sul, os que não possuíam telefone para serem contatados, além daqueles que tiveram seu diagnóstico alterado ao longo do período de hospitalização para outro não contemplado nos critérios de inclusão e aqueles incapacitados de responder ao questionário ou que não possuíam familiar ou responsável acessível ao Hospital Mãe de Deus após serem feitas três tentativas de contato para coleta dos dados. A efeito de estudo, foram excluídos também pacientes com diagnóstico diferente de SCA (GAEDKE, 2013).

No planejamento do estudo de coorte do qual o projeto desenvolvido por (GAEDKE, 2013) faz parte, foi estimado o ingresso total ao final dos dois anos de 960 pessoas, com uma entrada aproximada de 40 indivíduos por mês. No entanto, ao final deste período (maio de 2011), houveram 499 entradas, sendo que dentre estes, 302 tiveram diagnóstico de SCA, compondo estes a amostra.

Segundo Gaedke (2013), durante a coleta de dados do “Projeto de coorte prospectiva de pacientes com síndrome coronariana aguda” foram utilizados três modelos de questionários padronizados e pré-codificados: um questionário basal e dois questionários de acompanhamento aos seis meses e um ano após alta hospitalar.

Os dados basais dos pacientes que satisfizeram os critérios de inclusão foram registrados no Questionário 1 – Dados basais do usuário (Anexo A), neste instrumento foram listados os problemas/diagnósticos que levaram à internação do paciente, permitindo a identificação daqueles com SCA (em todas as suas formas clínicas). Este questionário foi aplicado por entrevistadores diretamente aos pacientes durante a internação. Dados de exame físico e informações laboratoriais foram coletadas dos prontuários dos pacientes, sendo que a logística do estudo garantiu que todas as informações estivessem disponíveis aos entrevistadores. Por meio deste instrumento foram coletados também dados socioeconômicos, demográficos, comportamentais e as morbidades referidas. Os dados sobre uso de medicamentos foram auto referidos e dizem respeito àqueles que o paciente usava à data da internação. Desta forma não foi obtida informação sobre os medicamentos prescritos na alta hospitalar. Para tanto foi realizada busca em prontuário eletrônico de todos os pacientes participantes do estudo, com o objetivo de coletar dados sobre os medicamentos prescritos no último dia da internação hospitalar (Anexo B).

Os questionários de acompanhamentos foram realizados por entrevistadores mediante entrevistas telefônicas. O seguimento de seis meses foi realizado utilizando-se de um terceiro questionário e o de um ano através de um quarto questionário. Com estes instrumentos buscaram-se informações sobre ocorrência de óbito, número de consultas médicas no período, readmissão hospitalar, ocorrência de complicações, intervenções, estilo de vida, uso de medicamentos e resultados de exames laboratoriais.

Conforme mencionando em Gaedke (2013), a coleta dos dados basais realizada no Hospital Mãe de Deus pelos entrevistadores iniciava-se pela consulta à lista de internação, conforme as instruções do fluxograma de coleta.

Já a coleta de dados do seguimento de seis meses e um ano após a alta hospitalar foram realizadas nas dependências da UNISINOS, em salas do Programa de Pós-graduação em Saúde Coletiva disponibilizadas para este fim, e registradas em questionários padronizados e pré-codificados. Para a coleta dos dados referentes ao período de seis meses após a alta, os pacientes a serem entrevistados foram identificados através de consulta ao Relatório de Entrada no Estudo, emitido mensalmente pelo supervisor de campo, onde era registrada a data de alta dos pacientes. Procedimento similar foi feito para identificação dos pacientes a serem acompanhados em um ano após a alta.

Após a coleta os questionários foram codificados pelos entrevistadores e revisados pelo supervisor de campo. Os questionários prontos eram encaminhados para processamento de dupla entrada de dados e posterior correção.

A coleta de dados referente à prescrição de alta foi realizada nas dependências do Hospital Mãe de Deus em consulta ao prontuário eletrônico, por mestRADOS do Programa de Pós-

graduação em Saúde Coletiva.

O material utilizado pelos entrevistadores fica armazenado na UNISINOS, nas dependências do Programa de Pós-graduação em Saúde Coletiva.

### 5.3.3 Seleção das Variáveis para Treinamento da Rede Bayesiana

Tendo em vista a quantidade de variáveis utilizadas durante o processo de obtenção dos dados dos pacientes pelo Programa de Pós-graduação em Saúde Coletiva da Unisinos (858 variáveis), tornou-se necessário identificar dentre elas quais que correspondiam aos fatores de risco para DAC. Sendo assim, foi feita uma análise dos dados utilizando o software SPSS 19 (*Statistical Package for the Social Sciences*) (NORUSIS, 2012), através do qual dois especialistas da área médica e nutricional (um professor do curso de pós-graduação e uma aluna de doutorado) identificaram e extraíram as seguintes variáveis, totalizando 11 variáveis, cada uma contendo informações relativas a um dos fatores de risco utilizados, conforme mostra a Tabela 5. Optou-se por essas variáveis, pois eram as variáveis obtidas que possuíam correspondência direta com os fatores de risco presentes no Escore de Framingham e na Doença Arterial Coronariana (DAC).

**Tabela 5:** Mapeamento entre variáveis da base de dados e fatores de risco

Variável		Fator de risco
fumaju	↔	Tabagismo
psiss	↔	Pressão arterial sistólica
pdias	↔	Pressão arterial diastólica
ldl6m	↔	Colesterol Total
hdl6m	↔	Colesterol HDL
glic360	↔	Diabetes
sexo	↔	Sexo
peso	↔	Peso
cabd	↔	Medida da cintura
lazer	↔	Atividade física
idade	↔	Idade

Fonte: Elaborado pelo autor

### 5.3.4 Cenários de utilização do ChronicPrediction com uma Rede Bayesiana para DAC

Com o intuito de avaliar a relevância de utilização do modelo ChronicPrediction através do protótipo desenvolvido, foram propostos alguns cenários através dos quais foram desenvolvidos experimentos. Cada um dos cenários descritos é composto por dados reais de um paciente portador de algum tipo de Doença Arterial Coronariana (DAC). Os dados dos pacientes utilizados são provenientes da base de dados obtida pelo Programa de Pós-graduação em Saúde

**Figura 26:** Plano de Cuidados para os cenários de avaliação

**Plano**

**Atividades**

**Nome:**  **Tipo:**  **Início:**  (dd/mm/aaaa hh:mm) **Repetir a cada:**   **Por:**

**Responsável:**

**Critério para Busca de Recursos**

**Tipo Recurso:**

---

**Nome:**  **Tipo:**  **Início:**  (dd/mm/aaaa hh:mm) **Repetir a cada:**   **Por:**

**Responsável:**

**Critério para Busca de Recursos**

**Tipo Recurso:**

---

**Nome:**  **Tipo:**  **Início:**  (dd/mm/aaaa hh:mm) **Repetir a cada:**   **Por:**

**Responsável:**

**Critério para Busca de Recursos**

Fonte: Elaborado pelo autor

Coletiva da Unisinos, conforme descrito anteriormente e foram selecionados com o objetivo de que cada um dos quatro pacientes tivesse características distintas um dos outros, mesmo que parcialmente. Durante a avaliação dos cenários, os pacientes cujos dados foram utilizados são identificados como “Paciente 1”, “Paciente 2”, “Paciente 3” e “Paciente 4”.

### 5.3.5 Plano de Cuidados Aplicado aos Cenários Propostos

Como ponto de partida para a construção dos cenários, buscou-se criar um Plano de Cuidados para os pacientes, onde são descritas cada uma das atividades que o paciente deve executar, objetivos a cumprir, além de mecanismos e instrumentos que utilizará para executar as atividades e ações propostas pelo Plano. A página web destinada a criação do Plano de Cuidados é apresentada na Figura 26.

Como os cenários avaliados baseiam-se em pacientes portadores de algum tipo de doença coronariana, optou-se por incluir no Plano de Cuidados, atividades que estejam diretamente relacionadas com os fatores de risco pertencentes a esta doença, mas que também são comuns a diversas outras DCNTs. São atividades que fazem parte da rotina normal de tratamento de grande parte dos pacientes e que, caso sejam seguidas e cumpridas, tendem a trazer grandes benefícios para a evolução do tratamento. Outro aspecto importante em relação as atividades propostas é o fato de pertencerem ao grupo de fatores de risco modificáveis, sendo passíveis de variação de acordo com o tratamento do paciente. A Tabela 6 mostra as tarefas e sua periodicidade.

Além disso, outras informações sobre o paciente são obtidas através dos dados do seu próprio perfil, cadastrado no protótipo do ChronicDuctor. Esses dados dizem respeito aos fatores de risco não-modificáveis e outros modificáveis e que são igualmente utilizados pelo Chronic-Prediction para efetuar as recomendações através da RB. A Tabela 7 mostra os dados do perfil

**Tabela 6:** Atividades do Plano de Cuidados relativas aos fatores de risco modificáveis

Atividade	Periodicidade
Pesar-se	1x ao dia
Medir glicose	1x ao dia
Fazer 30mins de caminhada	2x ao dia
Medir pressão arterial	1x ao dia
Medir taxa de colesterol	1x por semana
Medir taxa de colesterol HDL	1x por semana

Fonte: Elaborado pelo autor

do paciente obtidos a partir do protótipo ChronicDuctor e que são utilizados pela RB para fazer as recomendações e que tipo de informação é inferida a partir de cada um desses dados.

**Tabela 7:** Fatores de risco não-modificáveis e demais informações

Dado do perfil		Informação inferida
Data de nascimento	↔	Idade do paciente
Altura	↔	Índice de massa corporal
Sexo	↔	Masculino ou feminino
Fumante	↔	Consumo de tabaco
DCNT que possui	↔	DCNT que deseja monitorar
Etnia	↔	Cor da pele
Histórico familiar	↔	Familiares com alguma DCNT

Fonte: Elaborado pelo autor

### 5.3.6 Cenário 1

O primeiro cenário de utilização diz respeito a utilização do protótipo desenvolvido e contendo as informações relativas ao Paciente 1. A Tabela 8 apresenta as informações do paciente obtidas a partir da base de dados utilizada para modelar e calibrar a RB de DAC.

A partir dos dados da Tabela 8 são cadastrados no protótipo as informações que pertencem ao perfil do usuário, bem como aquelas que dizem respeito aos fatores de risco não-modificáveis. A Figura 27 mostra o perfil do Paciente 1 preenchido com seus próprios dados (Tabela 7 e Tabela 8).

Levando em consideração as informações do paciente antes da utilização do protótipo, a RB proposta para DAC teria o seguinte comportamento (Figura 28).

Analisando a RB já contendo as informações do Paciente 1, e sabendo que ele já é portador de Doença Arterial Coronariana, percebe-se que sua DCNT está bastante agravada (nodo “DAC” com 99% no nível “Alto”). A partir disso, segue-se para a utilização do protótipo propriamente dito, onde encontram-se cadastradas as tarefas designadas pelo Plano de Cuidados (Tabela 6). De acordo com as informações iniciais do paciente (Tabela 8), percebe-se que os

**Tabela 8:** Dados do Paciente 1

Característica	Valor	Valor desejado
Id	Paciente_1	-
Nome	Paciente 1	-
Idade	62	<55 (mulheres) e <45(homens)
Sexo	Feminino	-
Altura	1,65m	-
Peso	83kg (IMC 30,51)	IMC <25 (desejável)
Tabagismo	Não	Não
Atividade física	Não	Sim
Glicose	97mg/dl	<110mg/dl (desejável)
Pressão Arterial Sistólica	140mmHg	<140mmHg (desejável)
Pressão Arterial Diastólica	80mmHg	<90mmHg (desejável)
Colesterol Total	180mg/dl	<200mg/dl (desejável)
Colesterol HDL	37mg/dl	>60mg/dl (desejável)
DCNT	Doença Arterial Coronariana	-

Fonte: Elaborado pelo autor

**Figura 27:** Perfil do Paciente 1 no ChronicDuctor com as informações preenchidas

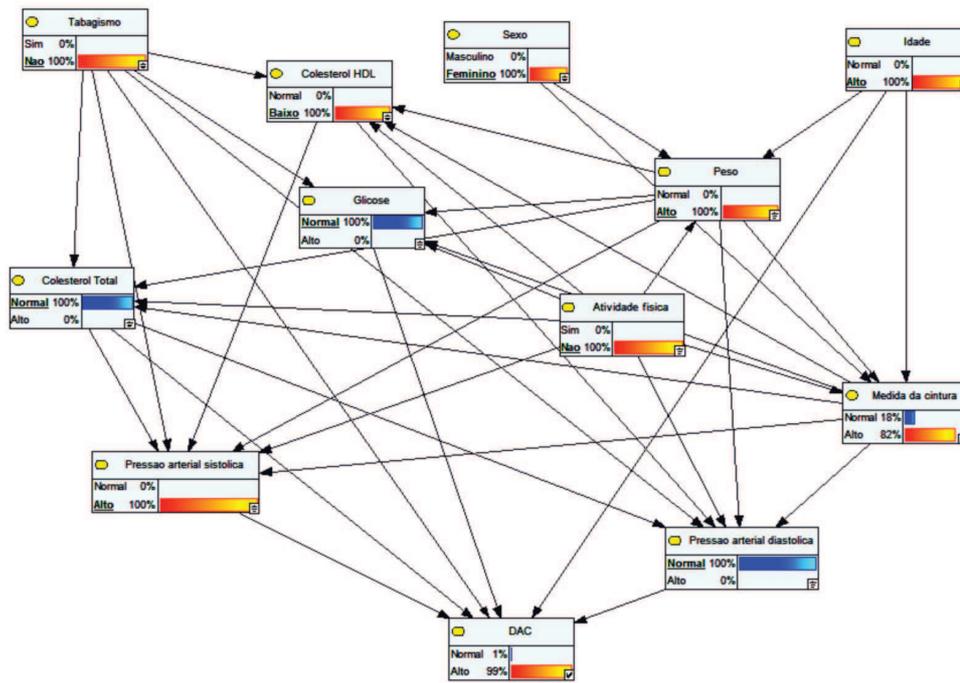
Fonte: Elaborado pelo autor

aspectos em que ele mais destoa dos níveis clinicamente aceitáveis são seu Peso, a falta de Atividade Física e sua Pressão Arterial.

Desta forma, se faz o seguinte questionamento: “*Caso o paciente siga as recomendações fornecidas pelo protótipo, passando a praticar exercícios físicos, reduzindo seu peso, e baixando sua pressão arterial suas condições crônicas melhorariam?*”

A Figura 29 mostra a tela do aplicativo ChronicDuctor já apresentando as atividades presentes no Plano de Cuidados.

Quando atinge-se a data e o horário estipulados para cada uma das atividades é solicitado

**Figura 28:** Comportamento da RB com os dados do perfil do Paciente 1

Fonte: Elaborado pelo autor

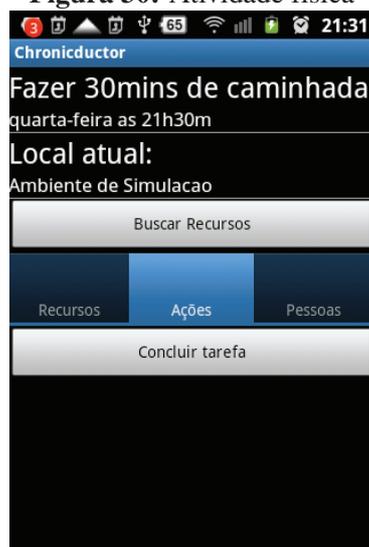
que o paciente realize cada uma delas, informando o respectivo valor (quando for uma tarefa relacionada ao peso ou alguma das taxas sanguíneas, por exemplo) ou apenas confirmar sua realização. A Figura 30 mostra a tarefa do Plano de Cuidados relacionada a atividade física (“Fazer 30mins de caminhada”) tendo sua execução confirmada pelo Paciente 1.

Ao confirmar a realização da atividade (“Fazer 30mins de caminhada”), a informação é enviada para a RB para Doença Arterial Coronariana (DAC), que efetua a inferência e, baseando-se nas probabilidades calculadas efetua a recomendação (Figura 31). A recomendação salienta a importância da prática de exercícios físicos, porém menciona que mesmo assim, a prática de exercícios somando-se as demais características do paciente ainda não é suficiente para uma melhora significativa no seu tratamento. Isso é salientado pela Figura 32, onde é apresentada a RB para DAC já com a informação sobre os exercícios físicos praticados.

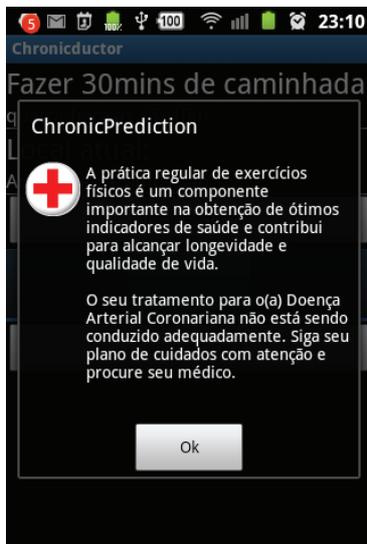
Uma outra atividade estipulada pelo Plano de Cuidados é “Pesar-se”. De acordo com o perfil do Paciente 1, ele encontra-se bastante acima do peso ideal, tendo seu IMC (Índice de Massa Corporal), que é uma padrão internacional para avaliar o grau de obesidade, sendo calculado dividindo-se o peso do indivíduo pela sua altura ao quadrado (ANJOS, 1992). Com as características atuais do Paciente 1 (83kg e 1,65m de altura), considera-se o valor 30,51 um índice bastante alto, pois o valor clinicamente recomendado é algo inferior a 24,9. A Figura 33 mostra a tela do protótipo ChronicDuctor com as novas informações fornecidas pelo Paciente 1, referente ao seu peso. Com a nova informação relativa ao peso (64kg) o novo valor de IMC passar a ser 23,51. Com isso, as inferências na RB são refeitas e a nova recomendação apresentada (Figura 34), onde o paciente é informado que com a prática regular de exercícios físicos e

**Figura 29:** Atividades do Plano de Cuidados

Fonte: Elaborado pelo autor

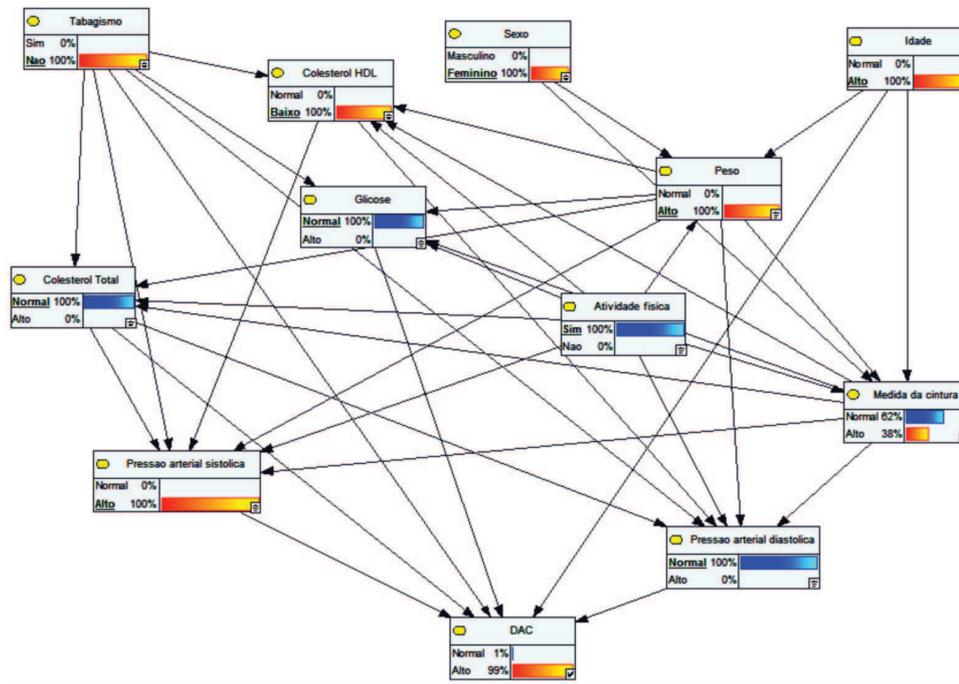
**Figura 30:** Atividade física

Fonte: Elaborado pelo autor

**Figura 31:** Recomendação após a atividade física realizada

Fonte: Elaborado pelo autor

**Figura 32:** RB de DAC com a informação de atividade física para o Paciente 1



Fonte: Elaborado pelo autor

uma considerável redução do seu peso, seu tratamento passa a estar melhor controlado e suas condições crônicas não estão se agravando.

A RB com as novas informações relativas ao peso do Paciente 1 é apresentada na Figura 35, onde é possível observar que as probabilidades referentes a DAC passaram dos anteriores 99% (no nível Alto) para os atuais 68% (no nível Normal). Além disso, percebe-se que segundo a RB, os níveis de Pressão Arterial Sistólica também tendem a ter baixado em decorrência, principalmente, da diminuição de peso do paciente.

### 5.3.7 Cenário 2

No segundo cenário de utilização do protótipo, são utilizadas as informações relativas ao Paciente 2. A Tabela 9 apresenta as informações do paciente que, assim como as informações pertencentes aos demais pacientes utilizados nos cenários avaliados, foram obtidas a partir da base de dados utilizada para modelar e calibrar a RB de DAC, a qual contém informações sobre pacientes portadores de algum tipo de doença cardiovascular.

Com a utilização do protótipo ChronicPrediction e após se obter os dados dos fatores de risco não-modificáveis, além de outras características do Paciente 2 obtidas a partir do seu perfil no protótipo, a RB tem, inicialmente, o seguinte comportamento (Figura 36).

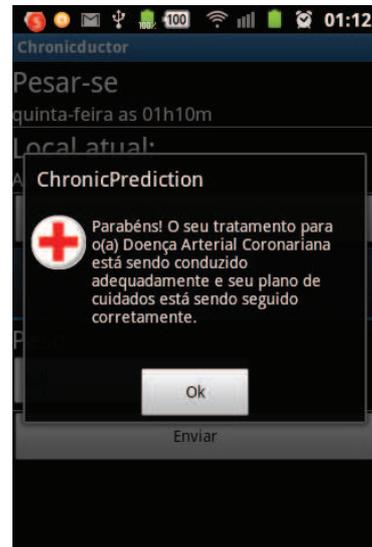
Observando as informações iniciais sobre o Paciente 2 (Tabela 9), se pode observar que os aspectos os quais o paciente mais destoava dos níveis clinicamente aceitáveis dizem respeito ao consumo de tabagismo, que é o principal causador, tanto de problemas cardíacos quanto para

Figura 33: Peso informado pelo Paciente 1



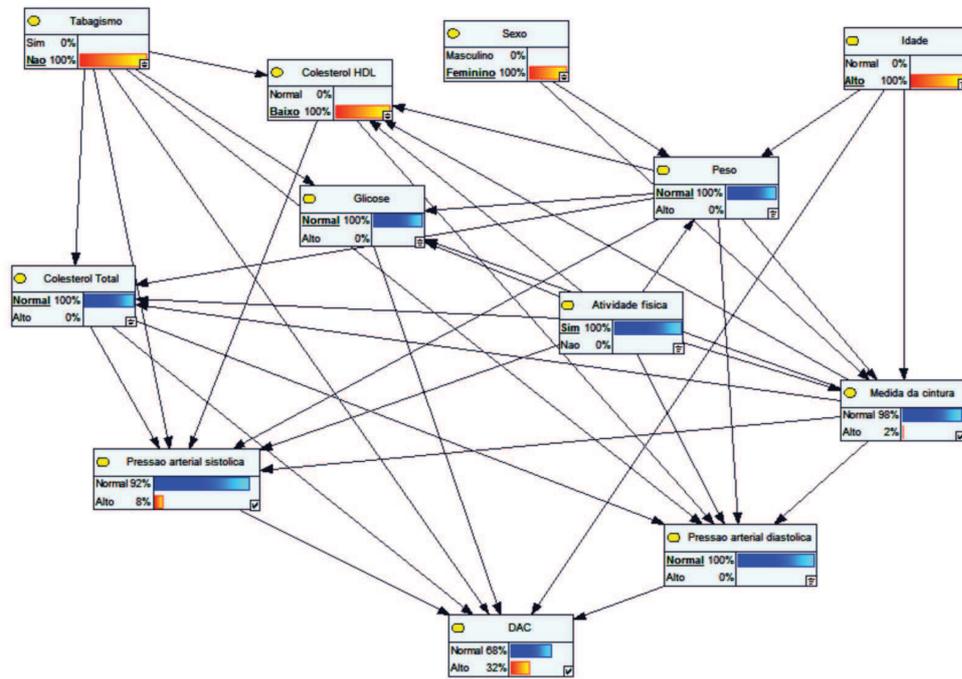
Fonte: Elaborado pelo autor

Figura 34: Recomendação após as informações de peso e atividade física



Fonte: Elaborado pelo autor

Figura 35: RB de DAC com a informação de atividade física e de peso do Paciente 1



Fonte: Elaborado pelo autor

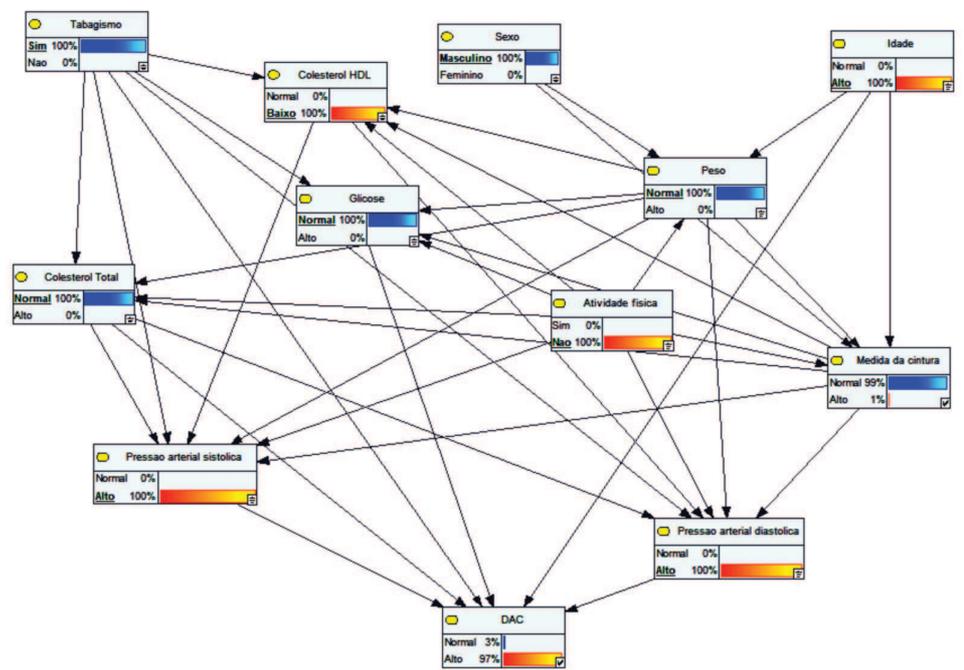
problemas relacionados as taxas metabólicas. Além disso, seus níveis de pressão arterial, tanto sistólica quanto diastólica estão muito altos. Seu colesterol HDL (colesterol bom) está com um nível abaixo do mínimo recomendável e o Paciente 2 não pratica nenhum tipo de atividade física. Sendo assim, é proposto a ele o Plano de Cuidados descrito na Tabela 6

Assim, para este cenário se faz o seguinte questionamento: “Se o paciente seguir as recomendações fornecidas pelo protótipo, parando de fumar, baixando seus níveis de pressão

**Tabela 9:** Dados do Paciente 2

Característica	Valor	Valor desejado
Id	Paciente_2	-
Nome	Paciente 2	-
Idade	63	<55 (mulheres) e <45(homens)
Sexo	Masculino	-
Altura	1,73m	-
Peso	56kg (IMC 18,73)	IMC <25 (desejável)
Tabagismo	Sim	Não
Atividade física	Não	Sim
Glicose	79mg/dl	<110mg/dl (desejável)
Pressão Arterial Sistólica	150mmHg	<140mmHg (desejável)
Pressão Arterial Diastólica	102mmHg	<90mmHg (desejável)
Colesterol Total	93mg/dl	<200mg/dl (desejável)
Colesterol HDL	40mg/dl	>60mg/dl (desejável)
DCNT	Doença Arterial Coronariana	-

Fonte: Elaborado pelo autor

**Figura 36:** Comportamento da RB com os dados do perfil do Paciente 2

Fonte: Elaborado pelo autor

*arterial e passando a adquirir o hábito da prática de atividade física suas condições crônicas melhorariam?”*

A Figura 37 mostra a tarefa do Plano de Cuidados relativa a “Medir Pressão Arterial”, onde são inseridos os valores 10 (Pressão Arterial Diastólica) e 15 (Pressão Arterial Sistólica) presentes nos seus dados coletados inicialmente (Tabela 9).

Na Figura 38 é apresentada a recomendação efetuada pelo ChronicPrediction quando as informações relativas a pressão arterial são confirmadas.

Conforme é possível observar na RB para controle de DAC, existe relação entre o consumo de tabaco e os níveis de pressão arterial (Figura 25). Desta forma, considerando que o Paciente 2 deixou de fumar e conseguiu controlar adequadamente sua pressão arterial dentro dos níveis considerados normais, ao mencionar esses novos valores ao protótipo, um novo *feedback* a respeito do seu tratamento lhe seria dado (Figura 39 e Figura 40) A RB contemplando os novos níveis de pressão arterial e o não consumo de tabagismo encontra-se na Figura 41, onde é possível perceber que, se anteriormente o agravamento da doença crônica estava com um nível bastante alto (97%), agora após o término do consumo de tabaco e com a melhora nas taxas de pressão arterial, passou a estar controlada com um nível de 74%.

### 5.3.8 Cenário 3

Para o terceiro cenário de utilização do protótipo, procurou-se buscar uma situação antagônica aos demais cenários propostos. Neste terceiro cenário o protótipo é utilizado por um indivíduo que inicialmente não possui características e taxas metabólicas que favoreçam a existência ou agravamento de alguma Doença Arterial Coronariana (DAC). O objetivo é verificar se uma variação nos seus dados, sejam peso, taxas metabólicas ou até o consumo de tabaco podem fazer com que ele passe de uma condição clínica saudável para uma condição não qual passe a estar propenso a ter uma doença arterial. As informações iniciais relativas ao Paciente 3 são, da mesma forma que as informações dos demais pacientes utilizados nos outros cenários, provenientes da base de dados obtida pelo Programa de Pós-graduação em Saúde Coletiva da Unisinos e encontram-se na Tabela 10.

Após o teste do protótipo tendo como ponto inicial os dados obtidos a partir da Tabela 10, a RB tem, inicialmente, o comportamento mostrado na Figura 42.

Considerando que o Paciente 3 está com sua condição clínica normal, tendo em vista suas informações iniciais (Tabela 10), a probabilidade dele estar sofrendo de alguma DAC e a mesma estar agravada é mínima (97%), conforme é mostrado pela RB utilizada pelo protótipo (Figura 42). Da mesma forma, é aplicado para este paciente, o Plano de Cuidados proposto (Tabela 6) para que possa verificar a consequência que um descaso com os seus hábitos diários poderá ter na sua condição de saúde.

Para este cenário é feito o seguinte questionamento: "*Caso o paciente resolva abandonar seus hábitos saudáveis passando a fumar e aumentando seu peso, que consequências essas ações teriam na sua saúde?*"

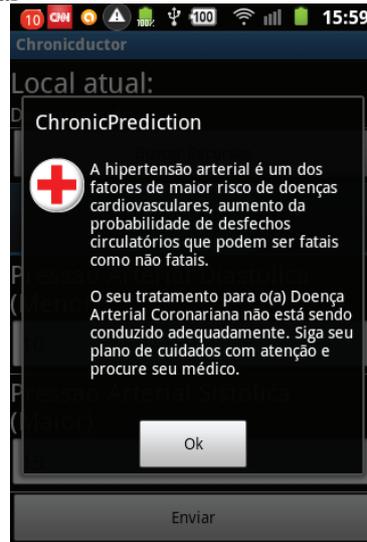
A Figura 43 mostra o comportamento da RB, onde, inicialmente, é apenas alterada a informação relativa ao consumo de cigarro, onde inicialmente tinha o valor "Não", pois o Paciente 3 não fumava e, a partir da mudança nos seus hábitos, passou agora a ter o valor "Sim", já que passou a fumar regularmente.

**Figura 37:** Pressão arterial do Paciente 2



Fonte: Elaborado pelo autor

**Figura 38:** Recomendação efetuada a partir da pressão arterial



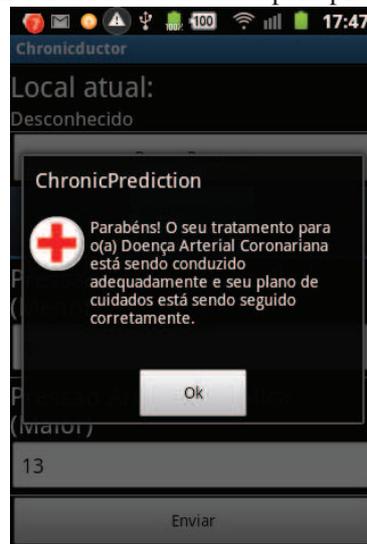
Fonte: Elaborado pelo autor

**Figura 39:** Novos níveis de pressão arterial do Paciente 2



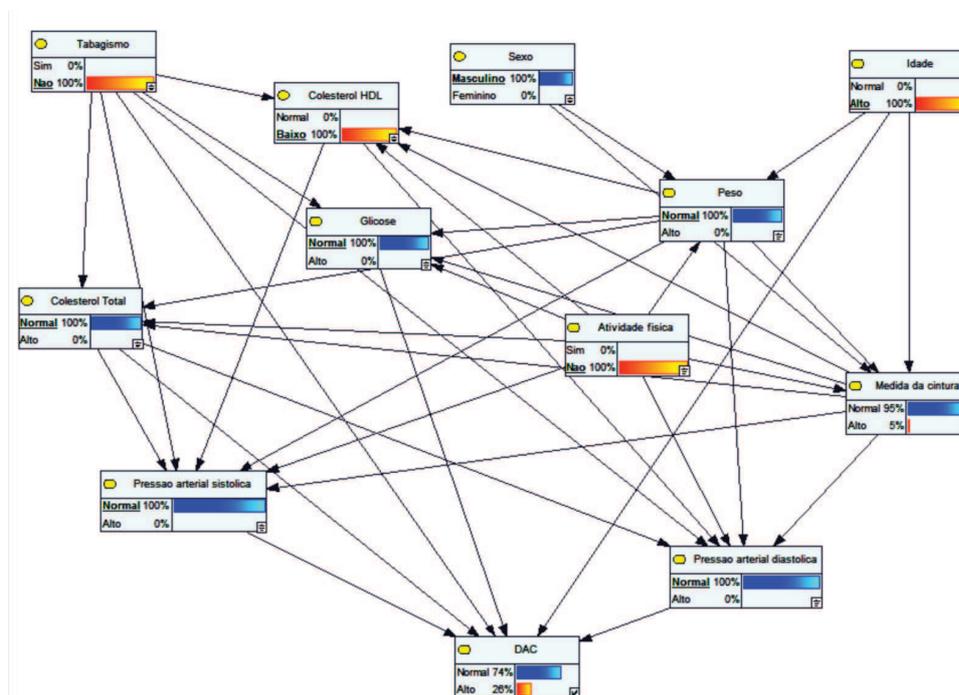
Fonte: Elaborado pelo autor

**Figura 40:** Feedback dado pelo protótipo



Fonte: Elaborado pelo autor

**Figura 41:** RB de DAC sem o consumo de tabaco e com os novos níveis de pressão arterial do Paciente 2



Fonte: Elaborado pelo autor

**Tabela 10:** Dados do Paciente 3

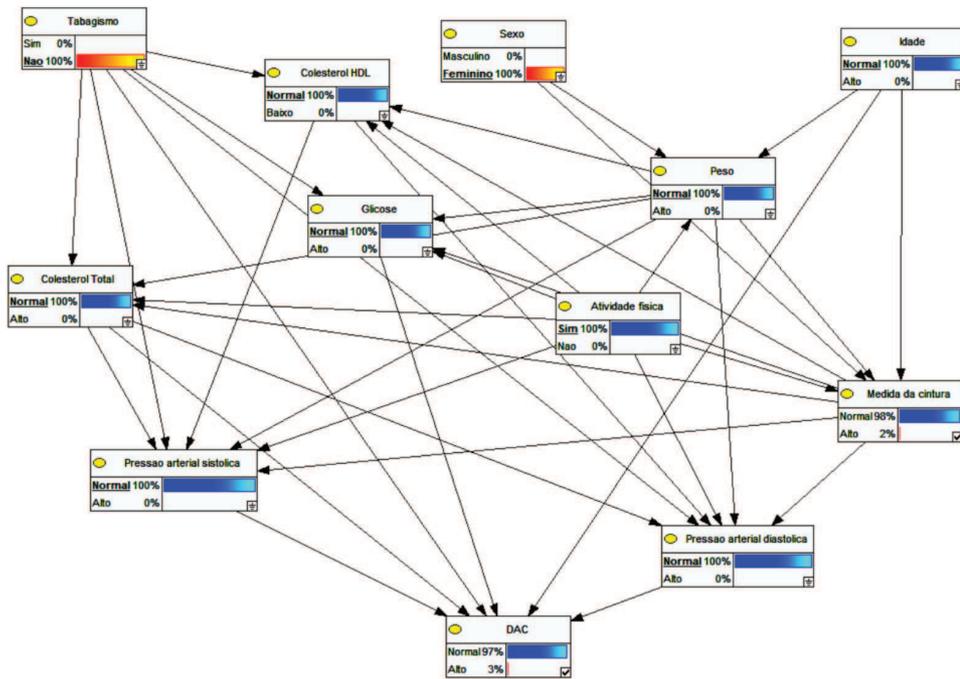
Característica	Valor	Valor desejado
Id	Paciente_3	
Nome	Paciente 3	
Idade	35	<55 (mulheres) e <45(homens)
Sexo	Feminino	-
Altura	1,65m	-
Peso	60kg (IMC 22,06)	IMC <25 (desejável)
Tabagismo	Não	Não
Atividade física	Sim	Sim
Glicose	98mg/dl	<110mg/dl (desejável)
Pressão Arterial Sistólica	130mmHg	<140mmHg (desejável)
Pressão Arterial Diastólica	80mmHg	<90mmHg (desejável)
Colesterol Total	120mg/dl	<200mg/dl (desejável)
Colesterol HDL	65mg/dl	>60mg/dl (desejável)
DCNT	-	-

Fonte: Elaborado pelo autor

Percebe-se que o simples fato do Paciente 3 passar a fumar, faz com que, mesmo até então ele tendo uma condição clínica aparentemente saudável, ele passe a ser altamente propenso (87%) a sofrer de uma doença cardíaca ou, caso já seja portador de doença cardíaca, ela poderia ser agravada.

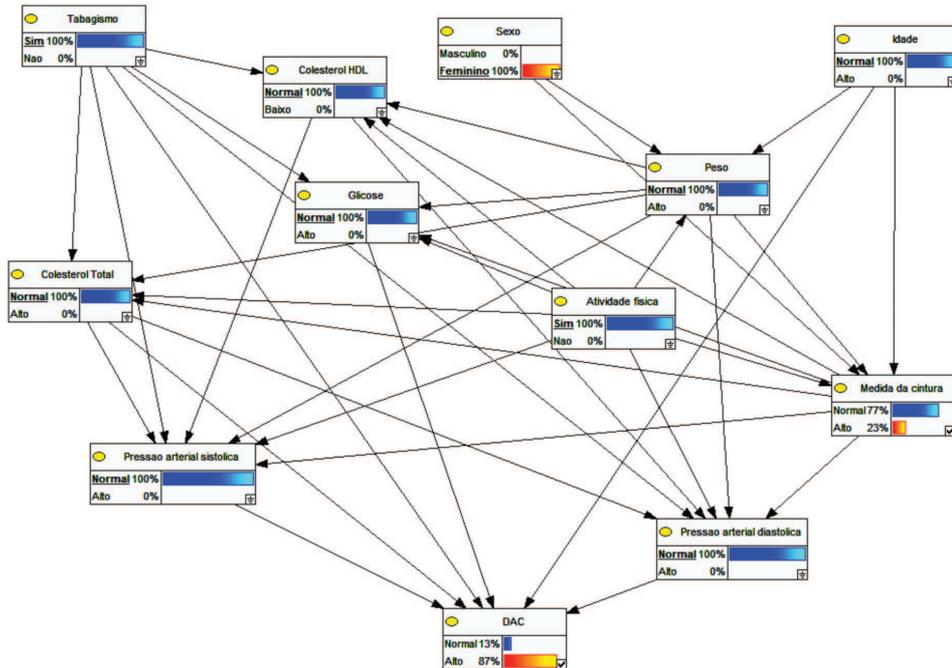
A Figura 44 mostra o perfil do Paciente 3 no protótipo. Na Figura 45 é apresentada a tela

Figura 42: Comportamento da RB com os dados do perfil do Paciente 3



Fonte: Elaborado pelo autor

Figura 43: RB após o Paciente 3 passar a ser fumante



Fonte: Elaborado pelo autor

do protótipo com a nova informação de "Peso" informada pelo paciente. A Figura 46 apresenta a recomendação feita pela RB após ser informado um valor para o "Peso" (75kg), o que fez com que seu valor de IMC passasse dos anteriores 22,06 (Normal) para os atuais 27,55 (Alto).

**Figura 44:** Perfil do Paciente 3 cadastrado no protótipo

The screenshot shows the 'Mobiductor' app interface. At the top, it says 'Bem-vindo ao Mobiductor'. Below this are two buttons: 'Conectar' and 'Perfil'. The 'Perfil' section contains the following information:

- Nome: Paciente 3
- Data de nascimento: 15/01/1980
- Sexo:
  - masculino
  - feminino
- Altura: 1.65

Fonte: Elaborado pelo autor

**Figura 45:** Peso informado pelo Paciente 3

The screenshot shows the 'Chronicductor' app interface. The title is 'Pesar-se' and the date is 'terça-feira as 23h00m'. Below this is the 'Local atual:' field, which is 'Desconhecido'. There is a 'Buscar Recursos' button. A navigation bar at the bottom has three tabs: 'Recursos', 'Ações', and 'Pessoas'. The 'Ações' tab is selected. Below the navigation bar, there is a 'Peso' input field with the value '75' and an 'Enviar' button.

Fonte: Elaborado pelo autor

**Figura 46:** Recomendação após as informações de peso e consumo de cigarro

The screenshot shows a 'ChronicPrediction' dialog box overlaid on the 'Pesar-se' screen. The dialog box contains the following text:

**ChronicPrediction**

Ter um peso ideal contribui para o bom funcionamento do seu organismo e de sua saúde de uma forma geral.

O seu tratamento para o(a) Doença Arterial Coronariana não está sendo conduzido adequadamente. Siga seu plano de cuidados com atenção e procure seu médico.

At the bottom of the dialog box is an 'Ok' button.

Fonte: Elaborado pelo autor

Mesmo com a informação de peso sofrendo alteração, os valores apresentado pela RB se mantiveram os mesmos, mantendo ainda uma probabilidade muito grande (nível Alto), mantendo-se em 87%, ficando evidente a forte influência que o tabagismo tem sobre as doenças cardiovasculares em geral.

### 5.3.9 Cenário 4

Da mesma forma que o Cenário 3, o Cenário 4 apresenta um paciente que ainda não possui Doença Arterial Coronariana, pois suas características e taxas metabólicas não estão com níveis fora dos considerados normais. O objetivo é verificar se variações nos seus níveis de glicose e colesterol total podem afetar sua condição de saúde atual, lhe oferecendo uma probabilidade maior de sofrer de uma doença cardíaca. As informações iniciais relativas ao Paciente 4 encontram-se na Tabela 11.

**Tabela 11:** Dados do Paciente 4

Característica	Valor	Valor desejado
Id	Paciente_4	
Nome	Paciente 4	
Idade	42	<55 (mulheres) e <45(homens)
Sexo	Masculino	-
Altura	1,86m	-
Peso	94kg (IMC 27,17)	IMC <25 (desejável)
Tabagismo	Não	Não
Atividade física	Sim	Sim
Glicose	98mg/dl	<110mg/dl (desejável)
Pressão Arterial Sistólica	130mmHg	<140mmHg (desejável)
Pressão Arterial Diastólica	70mmHg	<90mmHg (desejável)
Colesterol Total	195mg/dl	<200mg/dl (desejável)
Colesterol HDL	33mg/dl	>60mg/dl (desejável)
DCNT	-	-

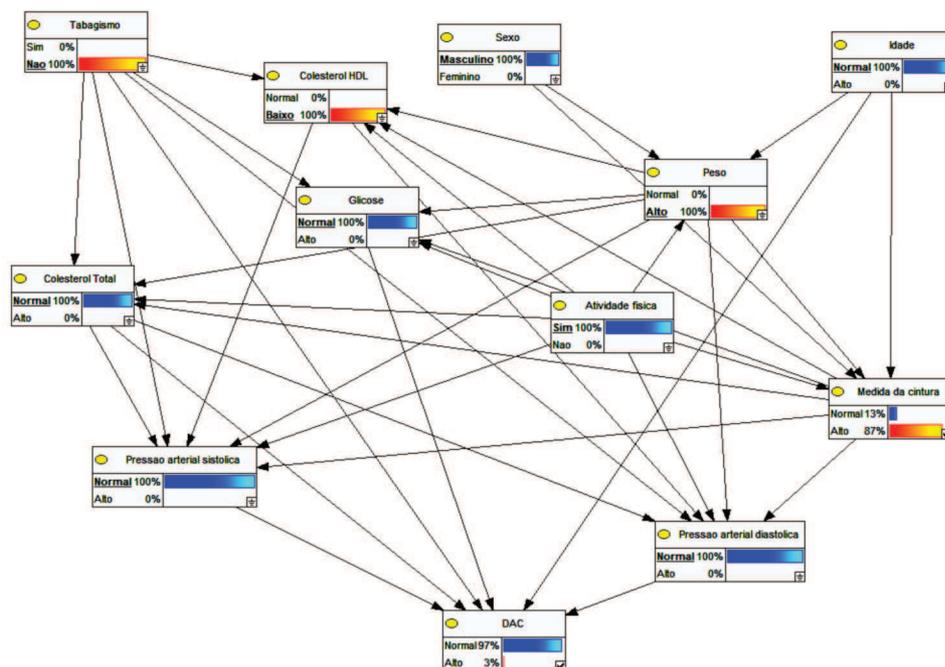
Fonte: Elaborado pelo autor

Como ponto inicial para o teste do protótipo com o cenário proposto, são utilizadas as informações do Paciente 4, obtidas a partir da Tabela 11. Inicialmente, a RB para DAC tem o comportamento descrito pela Figura 47.

Como se pode perceber ao observar a Tabela 11, as condições clínicas do Paciente 4 podem ser consideradas normais e essa situação é veementemente confirmada pela RB utilizada para DAC ao receber os dados do perfil do paciente. Ela mostra que a probabilidade do Paciente 4 estar sofrendo de algum tipo de doença cardiovascular e ter sua condição crônica agravada em decorrência dos seus dados atuais é mínima (97%), o que denota uma situação bastante semelhante ao Paciente 3.

Assim como para os demais cenários, é aplicado para este paciente o Plano de Cuidados

**Figura 47:** Comportamento da RB contendo os dados do perfil do Paciente 4



Fonte: Elaborado pelo autor

proposto na Tabela 6. O objetivo é verificar o que mudanças nos seus hábitos, principalmente aqueles relativos a alimentação, podem ter na sua saúde.

Desta maneira, para este cenário é levantado o seguinte questionamento: *"Se o paciente parar de praticar atividade física, passando a se alimentar inadequadamente e tendo uma aumento no seu nível de glicose e colesterol, quais consequências que essas ações teriam na sua saúde, principalmente tratando-se de alguma Doença Arterial Coronariana?"*

Na Figura 48 mostra o perfil do Paciente 4 no protótipo já com as informações do seu perfil contidos na Tabela 11. A Figura 49 mostra a tela do protótipo com a nova informação de "Glicose" inserida pelo paciente. A Figura 50 apresenta a recomendação feita pela RB após a informação sobre o novo nível de "Glicose" ser informado. Essa nova informação fez com que seu nível saísse de uma condição clínica considerada Normal (98mg/dl) para uma condição Alta (118mg/dl).

Na Figura 51 é apresentado o comportamento da RB após a nova informação sobre "Glicose" ser informada pelo paciente. Onde, inicialmente, tinha-se uma probabilidade de 97% do Paciente 4 ter sua condição de saúde considerada clinicamente normal (Figura 47), após a alteração no nível de "Glicose" passou a ter uma probabilidade de 55% do Paciente 4 vir a ter algum problema cardiovascular agravado, tendo em vista sua nova condição clínica.

Como se pode perceber, apesar da probabilidade do Paciente 4 ter uma probabilidade maior de ter sua condição de saúde agravada, o valor dessa probabilidade ainda não chega a ser algo alarmante, pois não está tão distante de uma situação clínica considerada normal.

Posteriormente, o Paciente 4 informa novos valores para o seu nível de "Colesterol", pas-

**Figura 48:** Perfil do Paciente 4 cadastrado

Mobiductor

Bem-vindo ao Mobiductor

Conectar Perfil

Nome:  
Paciente 4

Data de nascimento:  
04/01/1973

Sexo:  
 masculino  
 feminino

Altura:  
1.86

Fonte: Elaborado pelo autor

**Figura 49:** Taxa de glicose informada pelo Paciente 4

Chronicductor

Local atual:  
Desconhecido

Buscar Recursos

Recursos Ações Pessoas

Glicose  
118

Enviar

Fonte: Elaborado pelo autor

**Figura 50:** Recomendação após o novo valor para glicose

Chronicductor

Local atual:  
ChronicPrediction

 Manter o nível normal da glicose igual ou menor que 99mg/dl é fundamental para preservar a saúde, pois níveis superiores indicam um risco maior de diversos tipos de doenças crônicas.

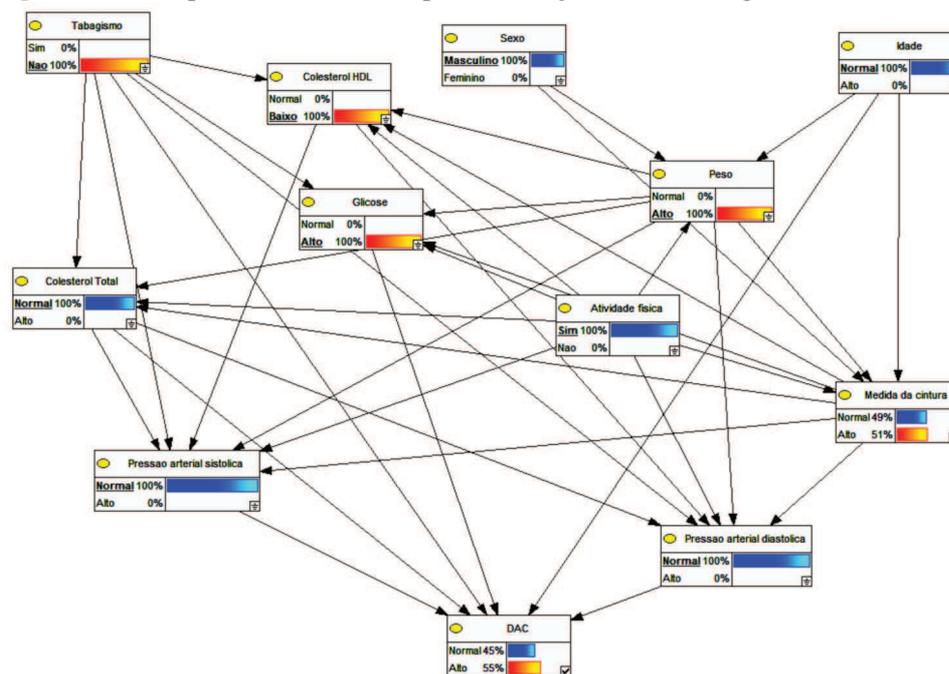
O seu tratamento para o(a) Doença Arterial Coronariana não está sendo conduzido adequadamente. Siga seu plano de cuidados com atenção e procure seu médico.

Ok

Enviar

Fonte: Elaborado pelo autor

**Figura 51:** Comportamento da RB após a alteração no nível de glicose do Paciente 4



Fonte: Elaborado pelo autor

sando dos anteriores 195mg/dl (nível considerado clinicamente normal) para os atuais 218mg/dl. A Figura 52 mostra a tela do protótipo com o novo valor para "Colesterol" informado pelo Paciente 4. Na Figura 53 é apresentado o *feedback* fornecido pelo protótipo após a confirmação da nova taxa.

Se anteriormente, quando informou novos valores apenas para suas taxas glicêmicas, o Paciente 4 possui uma probabilidade de 55% de vir a sofrer de um problema cardiovascular ou do mesmo estar agravado (Figura 51), agora com a informação de novos níveis também para suas taxas de colesterol, a probabilidade passou para 75%, conforme mostrado na Figura 54.

Ao analisar o comportamento da RB para DAC nas duas situações verificadas para o Paciente 4, percebe-se que o fato do paciente ter níveis de colesterol e glicose alterados implica em 20% a mais de chances dele ter uma doença cardiovascular (75%) (ou tê-la agravada caso já a possua) em relação ao fato de ter apenas o nível de glicose alterado (55%).

## 5.4 Segunda Avaliação

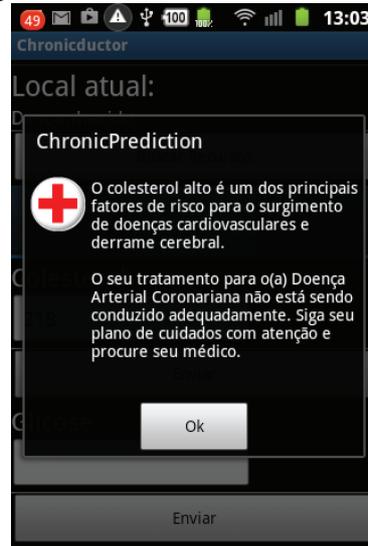
A segunda avaliação proposta tem como objetivo verificar a capacidade do modelo ChronicPrediction de suportar o monitoramento de mais de uma DCNT simultaneamente, ou seja, ao contrário da primeira avaliação onde os cenários propostos eram compostos por dados de pacientes que sofriam de algum tipo de Doença Arterial Coronariana (DAC), nesta segunda avaliação é apresentado um cenário onde o mesmo paciente possui duas DCNTs: DAC e Diabetes. A RB de Doença Arterial Coronariana (DAC) é a mesma utilizada anteriormente, já a

**Figura 52:** Taxa de colesterol informada pelo Paciente 4



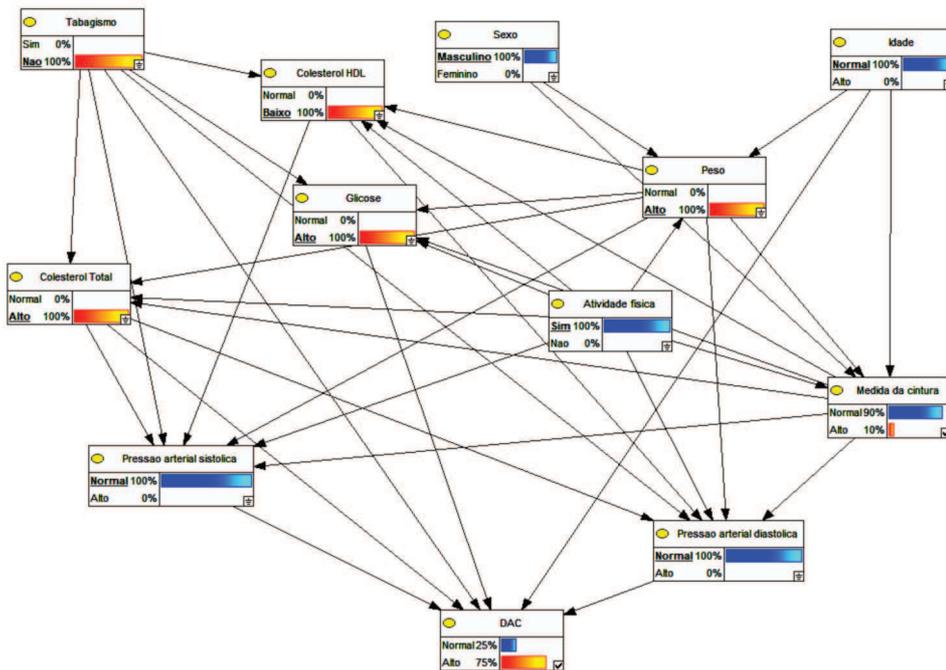
Fonte: Elaborado pelo autor

**Figura 53:** Recomendação após a informação de colesterol



Fonte: Elaborado pelo autor

**Figura 54:** RB com os novos valores para as taxas de colesterol e glicose

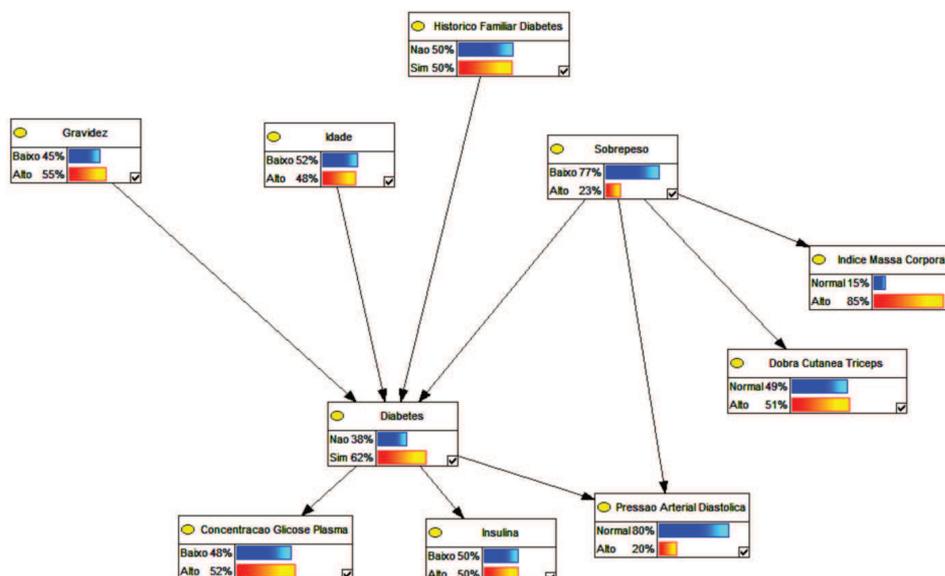


Fonte: Elaborado pelo autor

RB de diabetes foi construída tomando como base a RB construída por Guo, Bai e Hu (2012). O objetivo estipulado por Guo, Bai e Hu (2012) foi construir um sistema de tomada de decisões para pessoas tanto de meia idade quanto idosos para a auto-predição de diabetes tipo 2 em casa utilizando RBs. Para o treinamento da RB de diabetes, foi utilizado o conjunto de dados de pacientes *Pima Indians Diabetes Data Set* (KNOWLER et al., 1990), o qual contém informações de pacientes com e sem desenvolvimento de diabetes tipo 2. Esse é o mesmo conjunto de dados

utilizado por Guo, Bai e Hu (2012) para modelar e calibrar a RB proposta por eles. A Figura 55 apresenta a RB de diabetes desenvolvida.

**Figura 55:** RB para diabetes treinada com o conjunto de dados Pima Indians Diabetes Data Set



Fonte: (GUO; BAI; HU, 2012)

Para verificar o funcionamento do protótipo do modelo proposto monitorando duas DCNTs simultaneamente são utilizadas as informações do Paciente 5, de acordo com a Tabela 12.

**Tabela 12:** Dados do Paciente 5

Característica	Valor	Valor desejado
Id	Paciente_5	
Nome	Paciente 5	
Idade	35	<55 (mulheres) e <45(homens)
Sexo	Feminino	-
Altura	1,65m	-
Peso	78kg (IMC 28,65)	IMC <25 (desejável)
Tabagismo	Não	Não
Atividade física	Sim	Sim
Glicose	98mg/dl	<110mg/dl (desejável)
Pressão Arterial Sistólica	150mmHg	<140mmHg (desejável)
Pressão Arterial Diastólica	100mmHg	<90mmHg (desejável)
Colesterol Total	120mg/dl	<200mg/dl (desejável)
Colesterol HDL	65mg/dl	>60mg/dl (desejável)
Histórico Familiar de DCNT	Sim	Não
DCNT	Doença Arterial Coronariana	-
	Diabetes	-

Fonte: Elaborado pelo autor

Inicialmente, percebe-se claramente que as características do Paciente 5 que mais estão

agravadas são seu peso (IMC = 28,65) e seus níveis de pressão arterial, tanto sistólica quanto diastólica (150mmHg / 100mmHg). Desta forma, para verificar as recomendações que são fornecidas para o Paciente 5 e o consequente suporte a mais de uma DCNT, os dados do paciente são cadastrados no protótipo de acordo com a Figura 56. A Figura 57 apresenta as informações sobre pressão arterial no protótipo. Após confirmadas as informações, as recomendações são feitas pelo protótipo baseando-se nas informações fornecidas pelas RBs, tanto de diabetes quanto de doença arterial coronariana. A Figura 58 apresenta a recomendação feita para diabetes e a Figura 59 apresenta a recomendação para doença arterial coronariana, que são as duas doenças que o paciente informou no preenchimento do seu perfil no protótipo.

Como as recomendações e *feedbacks* feitos pelo protótipo são baseados nas probabilidades calculadas pelas RBs, se faz importante apresentar o comportamento de cada uma das duas RBs após receberem as informações relativas a pressão arterial do Paciente 5. A Figura 60 apresenta a RB de Diabetes já com as informações de pressão arterial, além das demais informações preenchidas no perfil do paciente, e o respectivo valor de probabilidade para o nodo "Diabetes", que é o nodo que se observa.

Da mesma forma, a Figura 61 apresenta o comportamento da RB de DAC após as informações dos fatores de risco não modificáveis serem obtidos a partir do perfil do Paciente 5 e já com os dados informados sobre a Pressão Arterial.

Posteriormente, o protótipo solicita ao Paciente 5 que informe seu peso onde, de acordo com o seu perfil (Tabela 12) é de 78kg. A Figura 62 apresenta o protótipo com a informação relativa ao peso já preenchida. A Figura 63 o *feedback* emitidos pelo protótipo para Diabetes e na Figura 64 o *feedback* para DAC.

As Figura 65 e a Figura 66 mostram, respectivamente, o comportamento da RB de Diabetes e de DAC após as informações relativas ao Peso serem informadas pelo Paciente 5.

Ao analisarmos a Figura 60 e a Figura 65 percebe-se que, se após o paciente informar sua pressão arterial a probabilidade dele sofrer de diabetes ou de ter sua DCNT agravada era de 60% (Sim), após ele informar seu Peso passou para 73% (Sim), o que detona uma probabilidade considerável de agravamento das suas condições clínicas. Algo semelhante pode ser percebido ao analisarmos a Figura 61 e a Figura 66, onde após os dados de pressão arterial o Paciente 5 tinha uma probabilidade de 71% (Alto) de ter sua DAC agravada ou de vir a sofrer da doença e, após os dados sobre o seu peso serem informadas, essa probabilidade passou para 73% (Alto).

## 5.5 Terceira Avaliação

A terceira avaliação proposta teve como objetivo principal consultar pessoas com alguma DCNT com o intuito de efetuar um pré-teste e verificar o quão importante seria para elas a utilização de um aplicativo para *smartphone* com a função de monitorar e acompanhar suas rotinas e condições crônicas, oferecendo recomendações e *feedbacks*. Para efetuar essa consulta às pessoas foi adotada a seguinte estratégia:

**Figura 56:** Informações do perfil do Paciente 5

Mobiductor  
Bem-vindo ao Mobiductor

Conectar Perfil

Nome:  
Paciente 5

Data de nascimento:  
12/09/1979

Sexo:  
 masculino  
 feminino

Altura:  
1.65

Fonte: Elaborado pelo autor

**Figura 57:** Informações sobre pressão arterial do Paciente 5

Chronicductor

Local atual:  
Desconhecido

Buscar Recursos

Recursos Ações Pessoas

Pressao Arterial Diastolica (Menor)  
10

Pressao Arterial Sistolica (Maior)  
15

Enviar

Fonte: Elaborado pelo autor

**Figura 58:** Feedback p/ hipertensão em paciente diabético

Chronicductor

Local atual:

ChronicPrediction

 Estima-se que 35% a 75% das complicações do diabetes possam ser atribuídos à hipertensão. A elevação na pressão arterial acelera a evolução de lesões renais provocadas pela diabetes.

O seu tratamento para o(a) Diabetes não está sendo conduzido adequadamente. Siga seu plano de cuidados com atenção e procure seu médico.

Ok

Enviar

Fonte: Elaborado pelo autor

**Figura 59:** Feedback p/ hipertensão em paciente com DAC

Chronicductor

Local atual:

ChronicPrediction

 A hipertensão arterial é um dos fatores de maior risco de diversos tipos de doenças crônicas, aumento da probabilidade de desfechos circulatórios que podem ser fatais como não fatais.

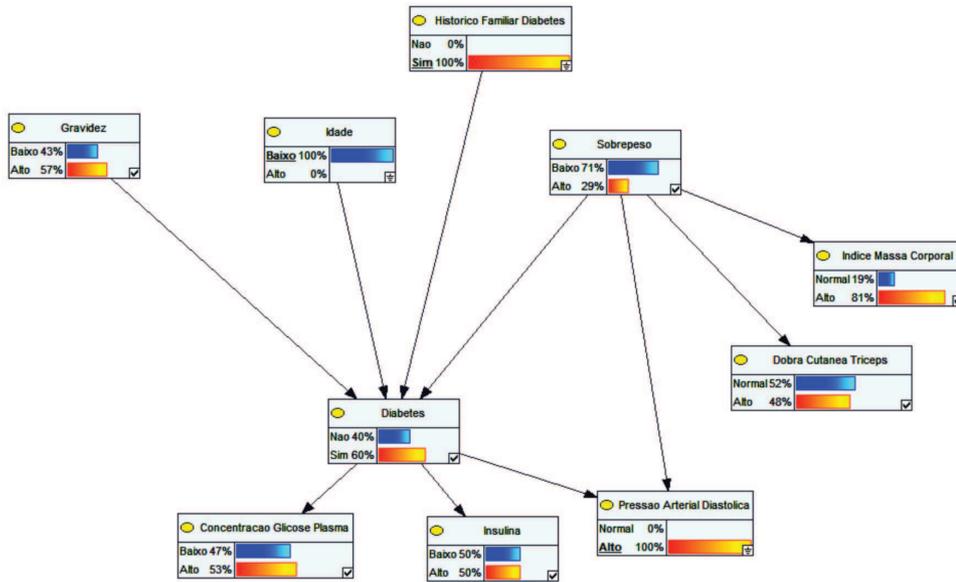
O seu tratamento para o(a) Doença Arterial Coronariana não está sendo conduzido adequadamente. Siga seu plano de cuidados com atenção e procure seu médico.

Ok

Enviar

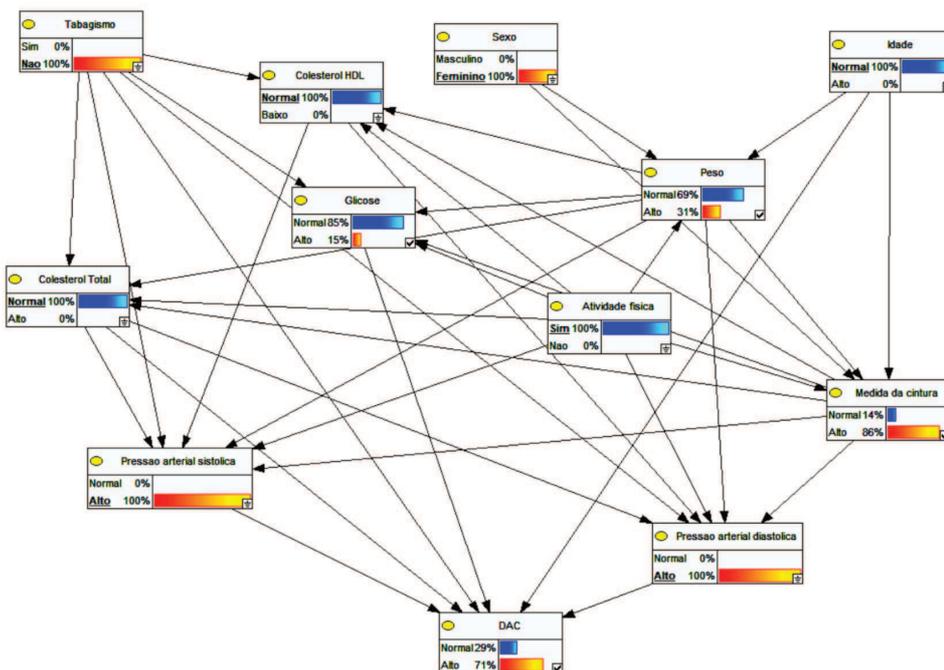
Fonte: Elaborado pelo autor

**Figura 60:** RB para diabetes com as informações sobre pressão arterial



Fonte: (GUO; BAI; HU, 2012)

**Figura 61:** RB para DAC com as informações sobre pressão arterial



Fonte: Elaborado pelo autor

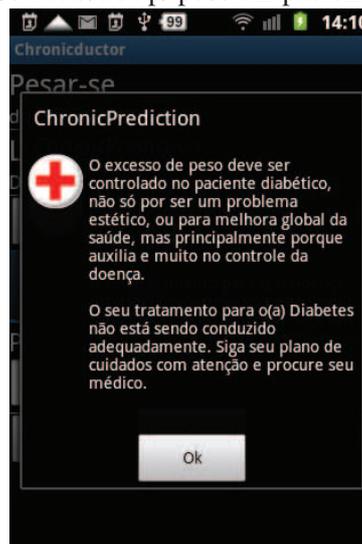
- a) o protótipo desenvolvido foi apresentado a elas;
- b) foi elaborado e apresentado a elas um questionário (Apêndice A), onde foram feitas diversas perguntas que englobaram desde o tipo de DCNT que a pessoa possui, passando pelo possível papel do *smartphone* no seu tratamento e concluindo com informações pessoais, tais como "nome" e "idade", além de aspectos que eles achariam importante que aplicati-

**Figura 62:** Protótipo com a informação de Peso preenchida



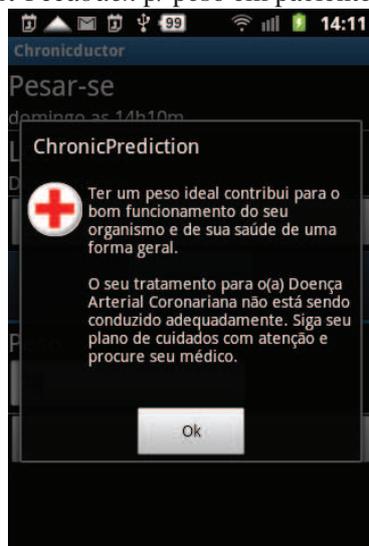
Fonte: Elaborado pelo autor

**Figura 63:** Feedback p/ peso em paciente diabético



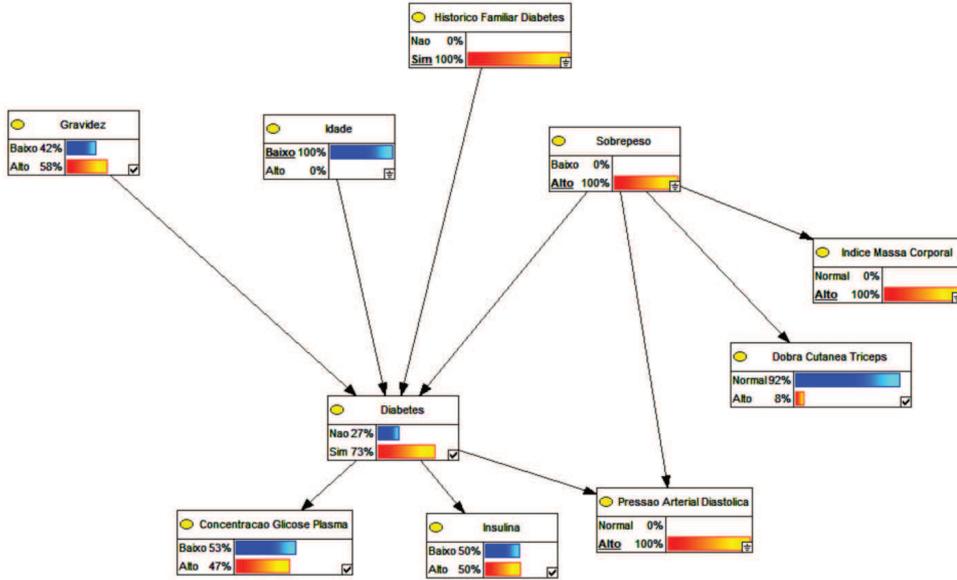
Fonte: Elaborado pelo autor

**Figura 64:** Feedback p/ peso em paciente com DAC



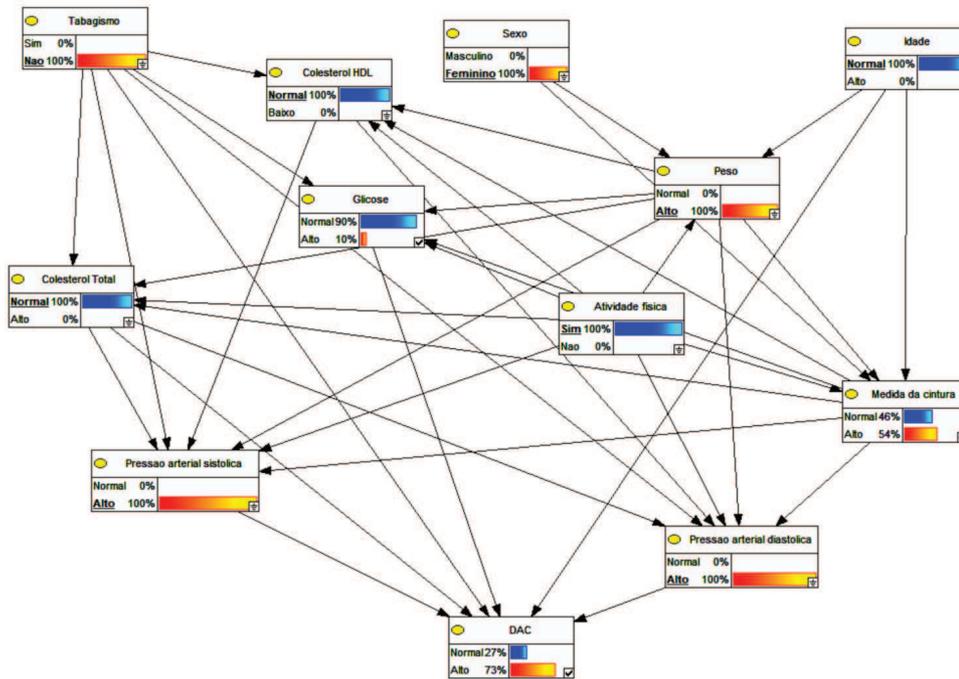
Fonte: Elaborado pelo autor

**Figura 65:** RB para diabetes com as informações sobre peso



Fonte: (GUO; BAI; HU, 2012)

**Figura 66:** RB para DAC com as informações sobre peso



Fonte: Elaborado pelo autor

vos para dispositivos móveis voltados para o acompanhamento de DCNTs deveriam ter para facilitar o bom gerenciamento da doença.

A seguir são apresentadas cada uma das questões presentes no questionário proposto e as respostas das duas pessoas consultadas. Ambos são portadores de algum tipo de Doença Arterial Coronariana (DAC).

- a) "Você tem como hábito a utilização de aplicativos para *smartphones* que possuem como foco o acompanhamento de alguma atividade relevante para o seu tratamento?"
- *Não, não utilizo nenhum aplicativo p/ acompanhar meu tratamento.*
  - *Sim, utilizo apenas p/ o monitoramento de atividades físicas.*
- b) "Idade?"
- *60 anos.*
  - *43 anos.*
- c) "Além dos fatores de risco de uma DCNT, o protótipo do modelo ChronicPrediction poderia monitorar outras características / atividades. Se você pudesse sugerir uma característica / atividade a qual pudesse ser monitorada diariamente e que fosse relevante para o seu tratamento, qual seria?"
- *Maneira fácil de memorizar a especificações do remédio que tomo, e ter facilidade de cadastrar alarmes para lembrar o horário, e facilidade para registrar a medições de pressão que faço quase todos dias. São coisas que quando preciso nunca as tenho comigo. indicação de locais adequados para fazer refeições fora de casa ou em lugares pouco conhecidos.*
  - *Dor de cabeça e tontura.*
- d) "Uma das características do tratamento de uma DCNT é o fato de necessitar de acompanhamento constante e a necessidade de participação ativa e envolvimento do próprio paciente no seu tratamento. *Smartphones* possuem como característica principal o fato de estarem sempre com os seus proprietários. Você consideraria o *smartphone* como sendo um mecanismo valioso no tratamento de uma DCNT desde que possuísse um aplicativo específico para este fim?"
- *Sim, considero um smartphone o mecanismo ideal para este fim.*
  - *Sim, considero um smartphone o mecanismo ideal para este fim.*
- e) "Se você tivesse em seu *smartphone* um aplicativo que lhe oferecesse recomendações e dicas periodicamente com o intuito de auxiliá-lo no bom andamento do seu tratamento durante as suas atividades diárias, você o utilizaria?"
- *Sim, utilizaria raramente.*
  - *Sim, utilizaria constantemente.*
- f) "O protótipo do modelo ChronicPrediction será disponibilizado, inicialmente, apenas para o sistema operacional Android, porém, posteriormente, o objetivo será disponibilizar para outras plataformas. Qual o sistema operacional presente no seu *smartphone*?"

- *Android (Google).*
- *Android (Google).*

g) "Tipo de problema / doença cardíaca que possui?"

- *Obstrução total de uma das coronárias.*
- *Deficiência de 17% do coração parado.*

h) "Comentários / Sugestões?"

- *No meu caso, a dificuldade maior foi decidir qual tratamento fazer. Decidido isso, muitas coisas posteriores foram consequência dessa decisão: os médicos com quem iria iniciar o tratamento, os especialistas (nutricionista, a academia, etc). Nesta fase onde estive querendo tomar decisões, toda informação de fonte segura foi-me útil. Nunca usei informação ou orientação de sites de cunho comercial, ou cuja fonte o princípio ativo era duvidoso ou pouco convincente. Por isso, marquei que raramente usaria um aplicativo nesta fase. Nas fases em que o intuito é ajudar no cumprimento do tratamento traçado, principalmente indicando locais em que há refeições e lanches aderentes ao tratamento (pouquíssimo açúcar, gorduras saturadas, triglicerídios, etc) são bem vindos e imagino-me usando.*
- *Nenhum comentário ou sugestão.*

Analisando as respostas para cada uma das questões do questionário de pré-teste respondido pelas duas pessoas consultadas, alguns aspectos podem ser salientados:

- Apenas uma das pessoas consultadas utiliza algum tipo de aplicativo para acompanhar seu tratamento e, mesmo assim, um aplicativo que tem como propósito apenas monitorar suas atividades físicas;
- Ambas as pessoas consultadas julgam importante que um aplicativo para *smartphone* voltando para o acompanhamento da rotina de pessoas com DCNT ofereça suporte à cadastro de medicamentos, medidas de pressão arterial e indicação de locais para refeições adequadas. Além disso, suporte à outros aspectos, como dores de cabeça e tontura também são salientados.
- Ambas as pessoas consultadas consideram o *smartphone* como sendo o mecanismo ideal para o monitoramento do tratamento de DCNTs desde que tenha um aplicativo específico para este fim, fomentando o envolvimento do próprio paciente no seu tratamento.
- Um dos pacientes mencionou que, caso lhe fosse disponibilizado um aplicativo que oferecesse recomendações e dicas periodicamente para auxiliá-lo no seu tratamento, utilizaria constantemente. O outro paciente mencionou que utilizaria tal aplicativo, porém de forma esporádica, pois atualmente ele está delineando com os médicos qual o melhor tratamento

a se fazer. Porém, deixou bem claro que tendo definido que tratamento irá seguir utilizaria um aplicativo para o acompanhamento do seu tratamento o qual pudesse lhe auxiliar indicando locais em que há refeições e lanches aderentes ao tratamento (pouquíssimo açúcar, gorduras saturadas, triglicerídios, etc).

- Ambas as pessoas consultadas mencionaram que o fato do protótipo do ChronicPrediction ser disponibilizado apenas para a plataforma Android não seria um problema, pois é o sistema operacional que utilizam em seus *smartphones*.
- Ambas as pessoas consultadas possuem algum tipo de DAC, sendo que uma delas possui obstrução total de uma das coronárias e o outro uma deficiência que faz com que tenha 17% do coração parado.



## 6 CONSIDERAÇÕES FINAIS

O suporte à pacientes portadores de DCNTs e o acompanhamento das suas atividades diárias é um aspecto fundamental para o bom andamento do tratamento. O modelo UDuctor (DAMASCENO VIANNA; BARBOSA, 2014) é um modelo para cuidado ubíquo de DCNT que tem como papel preencher a lacuna apresentada em outros trabalhos com relação a integração entre pacientes e recursos da comunidade e organizações de saúde. O aplicativo ChronicDuctor (DAMASCENO VIANNA; BARBOSA, 2014) foi desenvolvido para explorar as funcionalidades da arquitetura do modelo UDuctor, oferecendo suporte a integração e ao autogerenciamento com recursos, membros da comunidade e organizações de saúde.

O modelo ChronicPrediction aqui apresentado tem como objetivo estender o modelo UDuctor e o aplicativo ChronicDuctor, oferecendo suporte à utilização de dados históricos de contextos (SILVA et al., 2010; KÖNIG; KLEIN; DAVID, 2013), que são utilizados em conjuntos com Redes Bayesianas (RBs) (CHARNIAK, 1991), oferecendo recomendações e *feedbacks* continuamente aos pacientes para que eles possam ter uma visão mais detalhada sobre o andamento do seu tratamento.

O ChronicPrediction toma como base as informações relativas aos dados pessoais do pacientes e os dados dos fatores de risco modificáveis e não-modificáveis, que são obtidos através da utilização contínua do aplicativo ChronicDuctor. Os fatores de risco são um dos principais aspectos que devem ser considerados no correto gerenciamento e controle de DCNTs, os quais podem ser classificados em “não modificáveis” (sexo, idade e herança genética) e “comportamentais” ou “modificáveis”(tabagismo, alimentação, inatividade física, consumo de álcool e outras drogas).

Para avaliar a viabilidade do modelo proposto foram propostos três tipos de experimentos. O primeiro experimento utilizou-se de dados reais de pacientes portadores de algum tipo de Doença Arterial Coronariana (DAC) e de uma RB para DAC, criada em conjunto com quatro especialistas da área médica e nutricional (duas professoras, uma aluna de doutorado e uma aluna de pós-doutorado), todos participantes de projetos de pesquisa no Programa de Pós-Graduação em Saúde Coletiva da Unisinos. Foram gerados a partir destes dados cenários de utilização para o protótipo desenvolvido e verificada a relevância das recomendações feitas pelo protótipo para a melhora das condições crônicas dos pacientes. O segundo experimento teve como objetivo verificar a capacidade do protótipo de suportar o tratamento de pacientes portadores de mais de um tipo de DCNT, oferecendo as recomendações e gerando os *feedbacks* relevantes para cada uma das doenças. Neste caso foi utilizada a RB para DAC e uma RB para Diabetes, desenvolvida por Guo, Bai e Hu (2012) em conjunto com informações reais de pacientes. A terceira avaliação teve como objetivo consultar pacientes portadores de alguma DCNT com o objetivo de verificar a importância e relevância que um aplicativo para *smartphone* cujo objetivo principal é monitorar e ajudar no controle e gerenciamento do tratamento teria caso fosse utilizado por eles e se eles efetivamente utilizariam um aplicativo criado para este fim.

As seções a seguir descrevem as conclusões obtidas a partir do trabalho desenvolvido, as contribuições deixadas por ele, além de sugestões para a sua continuação.

## 6.1 Conclusões

Durante a avaliação dos quatro cenários propostos na primeira avaliação, procurou-se utilizar a seguinte regra: dois cenários dizem respeito a pacientes que são portadores de Doença Arterial Coronariana (DAC) e dois pacientes não possuem, inicialmente, nenhuma DCNT. A partir disso procurou-se observar se aqueles pacientes portadores de DCNT que seguissem as recomendações e respeitassem os *feedbacks* fornecidos pelo protótipo, teriam uma melhora gradual das suas condições crônicas. Da mesma forma, para aquelas pacientes que inicialmente não são portadores de nenhuma DCNT, se ao desrespeitarem o plano de cuidados a eles proposto, passando a ter seus fatores de risco alterados, passaram a receber recomendações e *feedbacks* do protótipo lhes informando sobre uma piora nas suas condições crônicas e sendo informados sobre de que forma devem proceder. Tais aspectos monitorados se comprovaram na prática, tendo em vista que as informações que o paciente coloca no protótipo após executar cada uma das tarefas do seu plano de cuidados são imediatamente informadas a RB correspondente a DCNT monitorada, fornecendo recomendações e *feedbacks* de forma imediata.

Na segunda avaliação, ao verificar o suporte do modelo a múltiplas DCNTs para os casos em que um único paciente sofra de mais de uma doença, verificou-se que para o cenário em que um mesmo paciente era portador de Doença Arterial Coronariana (DAC) e diabetes o protótipo do modelo gerou recomendações e emitiu *feedbacks* específicos para cada um dos fatores de risco avaliados. É importante salientar que o modelo suporta um número ilimitado de DCNTs, o que o torna bastante flexível e abrangente no cuidado de DCNTs.

A análise da terceira avaliação, apesar do reduzido número de portadores de DCNTs consultados, percebe-se que as respostas do questionário proposto denotam uma carência de aplicações voltadas para o cuidado e monitoramento de condições crônicas, em conjunto com a contínua necessidade que esses pacientes mencionaram em terem apoio no momento de tomarem determinadas decisões a respeito do seu tratamento. Além disso, destacaram a capacidade do protótipo em disponibilizar acesso a recursos que estejam disponíveis próximos aos locais onde se encontram, além da capacidade do modelo em lhes efetuar recomendações e suportar o registro de suas taxas sanguíneas e os dados de seu perfil.

## 6.2 Contribuições

O modelo ChronicPrediction complementa e estende o modelo UDUCTOR desenvolvido por Damasceno Vianna e Barbosa (2014), que originalmente foi projetado para suportar o gerenciamento de fatores de risco, além de oferecer suporte ao trabalho corporativo entre os principais membros participantes da cadeia de cuidados de DCNTs. O ChronicDUCTOR é um dos quatro

componentes que compõem o modelo, sendo um assistente para o paciente portador de DCNT, auxiliando-o nas tarefas diárias do seu tratamento, armazenando os dados informados por ele.

O ChronicPrediction oferece ao aplicativo ChronicDuctor a capacidade de após informados os dados relativos a cada uma das tarefas diárias do paciente, efetuar recomendações instantâneas sobre o andamento da sua DCNT considerando todos os fatores de risco envolvidos e mapeados no seu tratamento, utilizando para isso RBs. Além disso, o mesmo é válido para pacientes que possuem mais de uma DCNT. Um ponto importante a se destacar é o fato das funcionalidades oferecidas pelo ChronicPrediction funcionarem em harmonia com as funcionalidades já existentes tanto no aplicativo ChronicDuctor quanto no modelo UDuctor como um todo, garantindo total compatibilidade. A base para o processo de treinamento das RBs utilizadas podem ser dados provenientes de fontes externas, como dados provenientes de prontuários médicos, por exemplo, e também dados dos próprios pacientes que utilizam o aplicativo durante um determinado período de tempo (dados históricos de contextos).

A Tabela 13 apresenta um comparativo dos modelos apresentados nos trabalhos analisados relacionados com o modelo ChronicPrediction. Após a análise dos trabalhos relacionados, pode-se perceber que, dentre eles, nenhum possui todos os aspectos que foram elencados como sendo relevantes para o acompanhamento e controle de fatores de risco de DCNT com o objetivo de monitorar e gerenciar as condições de saúde em condições fora do ambiente hospitalar. O modelo ChronicPrediction apresenta como diferenciais a utilização de RBs em conjunto com dados históricos de contextos com o intuito de fornecer *feedbacks* e recomendações ao paciente para ajudá-lo a acompanhar seu tratamento de forma contínua e podendo readequá-lo de forma a promover seu bem-estar e aprimorando sua qualidade de vida.

A utilização de dados históricos de contextos (trilhas) é um aspecto importante a se destacar no modelo ChronicPrediction, pois a medida que o modelo vai sendo utilizado pelos mais diferentes pacientes, novos dados vão sendo armazenados, o que faz com que as futuras recomendações *efeedbacks* fornecidos pelas RBs sejam cada vez mais relevantes e eficientes. Além disso, a organização do modelo permite que diversas DCNTs possam ser monitorados e controladas simultaneamente, desde que novas RBs sejam criadas, o que faz com que o modelo se torne genérico e abrangente. Além disso, o fato do protótipo funcionar em um dispositivo móvel é outro fator de destaque em relação aos modelos de predição voltados a área da saúde que foram estudados, a medida que estes não se utilizam de nenhum tipo de dispositivo móvel.

Um capítulo para o livro *Handbook of Research on Advancing Health Education through Technology* que será publicado pelo IGI Global foi aprovado e encontra-se em fase de revisão e tem como título “*An education driven model for ubiquitous non-communicable diseases care*”. Neste capítulo proposto foram apresentadas a arquitetura do ChronicPrediction, além do modelo UDuctor e do aplicativo ChronicDuctor. Foi dada ênfase ao aspecto educacional, salientando a necessidade que os pacientes possuem em ter conhecimento contínuo sobre o seu tratamento. No momento da elaboração do capítulo proposto uma versão do aplicativo contendo o ChronicPrediction estava em fase final de desenvolvimento, o que permitiu que fosse

**Tabela 13:** Comparativo dos modelos estudados com o ChronicPrediction

<b>Características</b>	Hwang and Cho, 2009	Lee and Lee, 2012	Petzold et al., 2005	Lee and Cho, 2012	Guo et al., 2012	Himes et al., 2009	Park and Cho, 2012	ChronicPrediction
Suporte à saúde / bem-estar	não	não	não	não	sim	sim	sim	sim
Análise de fatores de risco	não se aplica	não se aplica	não se aplica	não se aplica	sim	sim	sim	sim
Suporte a múltiplos modelos de RBs	não	não	não	sim	não	não	não	sim
Tipo de aplicação	metodologia	ferramenta	modelo	modelo	ferramenta	modelo	modelo	modelo
Acompanhamento das atividades diárias	não	não	não	sim	sim	não	não	sim
Sensibilidade ao contexto	sim	sim	sim	sim	não	não	não	sim
Dados históricos de contextos (trilhas)	sim	sim	sim	sim	não	não	não	sim
Aplicabilidade das RBs	decisão	previsão	previsão	previsão	previsão	previsão	previsão	previsão
Suporte a dispositivos móveis	sim	sim	sim	sim	não	não	não	sim

Fonte: Elaborado pelo autor

apresentado um plano de cuidados com um conjunto de atividades que foram executadas e seus dados informados através da interface do aplicativo onde, logo após, eram recebidas as recomendações e um panorama geral sobre a situação atual da condição crônica do paciente. Desta forma, o capítulo a ser publicado conterá uma visão resumida do trabalho como um todo, pois contempla os principais pontos estudados e elaborados ao longo da pesquisa.

### 6.3 Trabalhos Futuros

Durante os testes efetuados com o protótipo, se pode destacar como aspectos relevantes para serem desenvolvidos e avaliados em trabalhos futuros, o teste do aplicativo desenvolvido em dispositivos Android cuja versão do sistema operacional seja superior a versão 2.X. Esse aspecto é importante a partir do momento que se tem como objetivo que o aplicativo seja utilizado por uma ampla quantidade de pacientes, além do fato de que dispositivos com versões do sistema operacional superior a versão 2.X são cada vez mais comuns e presentes, principalmente, nos dispositivos mais sofisticados. Outro aspecto que poderia ser analisado em futuros trabalhos diz respeito a integração do Plano de Cuidados do modelo UDUCTOR com o cadastro de recomendações e *feedbacks* feitos pelo aplicativo ChronicPrediction. Esse é um ponto importante, pois atualmente as recomendações são cadastradas uma a uma de forma bastante manual e estando elas integradas com o cadastro do Plano de Cuidados proporcionaria que os próprios profissionais de saúde ou da área nutricional pudessem cadastrar as recomendações de acordo com as tarefas do plano ou de acordo com o perfil específico de cada paciente.

Por fim, com o intuito de verificar o potencial do ChronicPrediction atuando em conjunto com o aplicativo ChronicDUCTOR, torna-se importante que seja feita uma avaliação de efetividade, pois desta forma poderiam ser obtidos resultados mais conclusivos a respeito da utilização / efetividade do modelo, sobretudo se o mesmo for amplamente testado em um ambiente hospitalar ou por uma grande quantidade de pacientes portadores, preferencialmente, de diferentes tipos de DCNTs. Assim, poderão ser obtidos resultados mais conclusivos e evidenciar novos desafios e novas potencialidades a serem supridas pelo modelo.



## REFERÊNCIAS

- AGRE, G. Diagnostic Bayesian Networks. **Computers and Artificial Intelligence**, [S.l.], v. 16, n. 1, p. 47–67, 1997.
- ANJOS, L. A. Índice de massa corporal (massa corporal. estatura-2) como indicador do estado nutricional de adultos: revisão da literatura. **Revista de Saúde Pública**, [S.l.], v. 26, n. 6, p. 431–436, 1992.
- BALDAUF, M.; DUSTDAR, S.; ROSENBERG, F. A survey on context-aware systems. **Int. J. Ad Hoc Ubiquitous Comput.**, Inderscience Publishers, Geneva, SWITZERLAND, v. 2, n. 4, p. 263–277, June 2007.
- BARBOSA, J. L. V.; HAHN, R. M.; BARBOSA, D. N. F.; SACCOL, A. I. d. C. Z. A Ubiquitous Learning Model Focused on Learner Interaction. **Int. J. Learn. Technol.**, Inderscience Publishers, Geneva, SWITZERLAND, v. 6, n. 1, p. 62–83, May 2011.
- BARDRAM, E. Activity-based computing: support for mobility and collaboration in ubiquitous computing. **Personal and Ubiquitous Computing**, [S.l.], v. 9, n. 5, p. 312–322, 2005.
- BARDRAM, J. E.; CHRISTENSEN, H. B. Pervasive Computing Support for Hospitals: an overview of the activity-based computing project. **Pervasive Computing, IEEE**, [S.l.], v. 6, n. 1, p. 44–51, Jan. 2007.
- BERNERS-LEE, T.; FIELDING, R.; MASINTER, L. RFC 3986: uniform resource identifier (uri): generic syntax. **The Internet Society**, [S.l.], 2005.
- BODENHEIMER, T.; WAGNER, E. H.; GRUMBACH, K. Improving primary care for patients with chronic illness. **JAMA: the journal of the American Medical Association**, [S.l.], v. 288, n. 15, p. 1909–1914, 2002.
- BYUN, H. E.; CHEVERST, K. Supporting proactive ”intelligent” behaviour: the problem of uncertainty. In: IN: PROC. WORKSHOP ON USER MODELLING FOR UBIQUITOUS COMPUTING IN USER MODELING 2003, 2003. **Anais...** [S.l.: s.n.], 2003.
- CACOUB, P. P.; ZEYMER, U.; LIMBOURG, T.; BAUMGARTNER, I.; POLDERMANS, D.; ROTHER, J.; BHATT, D. L.; STEG, P. G. Effects of adherence to guidelines for the control of major cardiovascular risk factors on outcomes in the REDuction of Atherothrombosis for Continued Health (REACH) Registry Europe. **Heart**, [S.l.], v. 97, n. 8, p. 660–667, 2011.
- YORK, S.-V. N. (Ed.). **Expert Systems and Probabilistic Network Models**. [S.l.]: Springer, 1997. (Monographs in computer science).
- CERQUIDES, J.; DE MANTARAS, R. L. Proposal and Empirical Comparison of a Parallelizable Distance-Based Discretization Method. In: KDD, 1997. **Anais...** [S.l.: s.n.], 1997. p. 139–142.
- CHARITOS, T.; VAN DER GAAG, L. C.; VISSCHER, S.; SCHURINK, K. A.; LUCAS, P. J. A dynamic Bayesian network for diagnosing ventilator-associated pneumonia in ICU patients. **Expert Systems with Applications**, [S.l.], v. 36, n. 2, p. 1249–1258, 2009.

- CHARNIAK, E. Bayesian Networks Without Tears. **AI MAGAZINE**, [S.l.], v. 12, n. 4, p. 50–63, 1991.
- CIARAMELLA, A.; CIMINO, M. G. C. A.; LAZZERINI, B.; MARCELLONI, F. Using context history to personalize a resource recommender via a genetic algorithm. In: ISDA, 2010. **Anais...** IEEE, 2010. p. 965–970.
- COSTA, C.; KELLERMANN, F.; ANTUNES, R.; CAVALHEIRO, L.; YAMIN, A.; GEYER, C. Continuum: a service-based software infrastructure for ubiquitous computing. In: PERSVASIVE COMPUTING AND COMMUNICATIONS, 2009. PERCOM 2009. IEEE INTERNATIONAL CONFERENCE ON, 2009. **Anais...** [S.l.: s.n.], 2009. p. 1–4.
- DAHLGREN, G.; WHITEHEAD, M. Policies and Strategies to Promote Social 9. **Equity in Health**. Stockholm: **Institute for Future Studies**, [S.l.], 1991.
- DAMASCENO VIANNA, H.; BARBOSA, J. A Model for Ubiquitous Care of Noncommunicable Diseases. **Biomedical and Health Informatics, IEEE Journal of**, [S.l.], v. 18, n. 5, p. 1597–1606, Sept 2014.
- DE OLIVEIRA, P. E. L. Aplicação de redes bayesianas na administração estratégica das organizações. **Dissertação (Mestrado) - Universidade Federal de Pernambuco, CTG. Programa de Pós-Graduação em Engenharia da Produção**, [S.l.], v. 1, p. 122, 2007.
- DEY, A. K.; ABOWD, G. D.; SALBER, D. A conceptual framework and a toolkit for supporting the rapid prototyping of context-aware applications. **Hum.-Comput. Interact.**, Hillsdale, NJ, USA, v. 16, n. 2, p. 97–166, Dec. 2001.
- DORR, D. A.; WILCOX, A.; BURNS, L.; BRUNKER, C. P.; NARUS, S. P.; CLAYTON, P. D. Implementing a multidisease chronic care model in primary care using people and technology. **Disease Management**, [S.l.], v. 9, n. 1, p. 1–15, 2006.
- DOUGHERTY, J.; KOHAVI, R.; SAHAMI, M. et al. Supervised and unsupervised discretization of continuous features. In: MACHINE LEARNING: PROCEEDINGS OF THE TWELFTH INTERNATIONAL CONFERENCE, 1995. **Anais...** [S.l.: s.n.], 1995. v. 12, p. 194–202.
- DRUZDZEL, M. J. SMILE: structural modeling, inference, and learning engine and genie: a development environment for graphical decision-theoretic models. In: AAAI/IAAI, 1999. **Anais...** [S.l.: s.n.], 1999. p. 902–903.
- FENTON, N. E.; NEIL, M. A Critique of Software Defect Prediction Models. **IEEE Transactions on Software Engineering**, Los Alamitos, CA, USA, v. 25, p. 675–689, 1999.
- FIRMINO P. R. A.; DROGUETT, E. L. **Redes Bayesianas para a Parametrização da Confiabilidade em Sistemas Complexos**. 2004. Dissertação (Mestrado em Ciência da Computação) — Universidade Federal de Pernambuco, 2004.
- FOWLER, M. **UML Distilled**: a brief guide to the standard object modeling language. [S.l.]: Addison-Wesley, 2004. (Addison-Wesley object technology series).
- FRANCO, L. K.; ROSA, J. H.; BARBOSA, J. L. V.; COSTA, C. A.; YAMIN, A. C. MUCS: a model for ubiquitous commerce support. **Electron. Commer. Rec. Appl.**, Amsterdam, The Netherlands, The Netherlands, v. 10, n. 2, p. 237–246, Mar. 2011.

- FREED, N.; BORENSTEIN, N. **Multipurpose internet mail extensions (MIME) part two: media types.** [S.l.]: rfc 2046, November, 1996.
- GAEDKE, M. Ângela. **Uso de Medicamentos de Prevenção Secundária Após Síndrome Coronariana Aguda.** 2013. Dissertação (Mestrado em Ciência da Computação) — Universidade do Vale do Rio dos Sinos, Programa de Pós-graduação em Saúde Coletiva, São Leopoldo, RS, 2013.
- GAMBLE, M.; GOBLE, C. Standing on the shoulders of the trusted web: trust, scholarship and linked data. In: **WEB SCIENCE CONFERENCE, 2010. Proceedings...** [S.l.: s.n.], 2010.
- GILMER, T.; O'CONNOR, P. J. Cost effectiveness of diabetes mellitus management programs. **Disease Management & Health Outcomes**, [S.l.], v. 11, n. 7, p. 439–453, 2003.
- GILMER, T. P.; O'CONNOR, P. J.; RUSH, W. A.; CRAIN, A. L.; WHITEBIRD, R. R.; HANSON, A. M.; SOLBERG, L. I. Impact of office systems and improvement strategies on costs of care for adults with diabetes. **Diabetes Care**, [S.l.], v. 29, n. 6, p. 1242–1248, 2006.
- GLASGOW, R. E.; WAGNER, E. H.; SCHAEFER, J.; MAHONEY, L. D.; REID, R. J.; GREENE, S. M. Development and validation of the patient assessment of chronic illness care (PACIC). **Medical care**, [S.l.], v. 43, n. 5, p. 436–444, 2005.
- GOOGLE. **Our Mobile Planet.** A pesquisa Our Mobile Planet foi encomendada pelo Google e realizada pela Ipsos MediaCT em parceria com a Mobile Marketing Association e o Interactive Advertising Bureau., Internet, 2014.
- GUO, Y.; BAI, G.; HU, Y. Using Bayes Network for Prediction of Type-2 Diabetes. In: **INTERNET TECHNOLOGY AND SECURED TRANSACTIONS, 2012 INTERNATIONAL CONFERENCE FOR, 2012. Anais...** [S.l.: s.n.], 2012. p. 471–472.
- GUS, I.; FISCHMANN, A.; MEDINA, C. Prevalência dos fatores de risco da doença arterial coronariana no Estado do Rio Grande do Sul. **Arq bras cardiol**, [S.l.], v. 78, n. 5, p. 478–83, 2002.
- GUS, I.; ZIELINSKY, P.; FERREIRA, C.; PÓVOA, R. As cardiopatias no Brasil. **Ferreira C; Póvoa R. Cardiologia para o Clínico Geral. Rio de Janeiro: Atheneu**, [S.l.], p. 131–43, 1999.
- HIMES, B. E.; DAI, Y.; KOHANE, I. S.; WEISS, S. T.; RAMONI, M. F. Prediction of chronic obstructive pulmonary disease (COPD) in asthma patients using electronic medical records. **Journal of the American Medical Informatics Association**, [S.l.], v. 16, n. 3, p. 371–379, 2009.
- HOAREAU, C.; SATOH, I. Modeling and Processing Information for Context-Aware Computing: a survey. **New Generation Comput.**, [S.l.], v. 27, n. 3, p. 177–196, 2009.
- HONG, J.; SUH, E.-H.; KIM, J.; KIM, S. Context-aware system for proactive personalized service based on context history. **Expert Syst. Appl.**, Tarrytown, NY, USA, v. 36, n. 4, p. 7448–7457, May 2009.
- HULL, R.; NEAVES, P.; BEDFORD-ROBERTS, J. Towards Situated Computing. In: **IEEE INTERNATIONAL SYMPOSIUM ON WEARABLE COMPUTERS, 1., 1997, Washington, DC, USA. Proceedings...** IEEE Computer Society, 1997. p. 146–. (ISWC '97).

- HWANG, K.-S.; CHO, S.-B. Landmark detection from mobile life log using a modular Bayesian network model. **Expert Syst. Appl.**, [S.l.], v. 36, n. 10, p. 12065–12076, 2009.
- JESTER, R. Supporting People with Long-term Conditions. **Advancing Practice in Rehabilitation Nursing**, [S.l.], p. 158, 2008.
- KANNEL, W. B. Contribution of the Framingham Study to preventive cardiology. **Journal of the American College of Cardiology**, [S.l.], v. 15, n. 1, p. 206–211, 1990.
- KINDBERG, T.; FOX, A. System Software for Ubiquitous Computing. **IEEE Pervasive Computing**, Piscataway, NJ, USA, v. 1, n. 1, p. 70–81, Jan. 2002.
- KJÆRULFF, U.; MADSEN, A. **Bayesian Networks and Influence Diagrams: a guide to construction and analysis: a guide to construction and analysis**. [S.l.]: Springer, 2007. (Information Science and Statistics).
- KÖNIG, I.; KLEIN, B. N.; DAVID, K. On the stability of context prediction. In: ACM CONFERENCE ON PERVASIVE AND UBIQUITOUS COMPUTING ADJUNCT PUBLICATION, 2013., 2013. **Proceedings...** [S.l.: s.n.], 2013. p. 471–480.
- KNOWLER, W. C.; PETTITT, D. J.; SAAD, M. F.; BENNETT, P. H. Diabetes mellitus in the Pima Indians: incidence, risk factors and pathogenesis. **Diabetes/metabolism reviews**, [S.l.], v. 6, n. 1, p. 1–27, 1990.
- KOLLER, D.; FRIEDMAN, N. **Probabilistic graphical models: principles and techniques**. [S.l.]: MIT press, 2009.
- KORHONEN, I.; PARKKA, J.; VAN GILS, M. Health monitoring in the home of the future. **Engineering in Medicine and Biology Magazine, IEEE**, [S.l.], v. 22, n. 3, p. 66–73, 2003.
- LANDIM, C. A. P. **Adaptação cultural para o Brasil e Portugal do instrumento Patient Assessment of Chronic Illness Care (PACIC)**. 2012. Tese (Doutorado em Ciência da Computação) — Universidade de São Paulo, 2012.
- LEE, K. C.; CHO, H. Integration of General Bayesian Network and ubiquitous decision support to provide context prediction capability. **Expert Syst. Appl.**, [S.l.], v. 39, n. 5, p. 6116–6121, 2012.
- LEE, S.; LEE, K. C. Context-prediction performance by a dynamic Bayesian network: emphasis on location prediction in ubiquitous decision support environment. **Expert Syst. Appl.**, Tarrytown, NY, USA, v. 39, n. 5, p. 4908–4914, Apr. 2012.
- LIU, H.; HUSSAIN, F.; TAN, C. L.; DASH, M. Discretization: an enabling technique. **Data mining and knowledge discovery**, [S.l.], v. 6, n. 4, p. 393–423, 2002.
- LOPEZ, A.; PROJECT, D. **Global Burden of Disease and Risk Factors**. [S.l.]: World Bank Publications, 2006. (Disease Control Priorities Project).
- LOTUFO, P. A. O escore de risco de Framingham para doenças cardiovasculares. **Revista de Medicina**, [S.l.], v. 87, n. 4, p. 232–237, 2013.
- MARQUES, R. L.; DUTRA, I. **Redes Bayesianas: o que são, para que servem, algoritmos e exemplos de aplicações**. Rio de Janeiro: Universidade Federal do Rio de Janeiro, 2000.

MAYRHOFER, R. An Architecture for Context Prediction. In: IN ADVANCES IN PERVASIVE COMPUTING, NUMBER 3-85403-176-9. AUSTRIAN COMPUTER SOCIETY (OCG, 2004. **Anais...** [S.l.: s.n.], 2004.

MAYRHOFER, R. Context Prediction based on Context Histories: expected benefits, issues and current state-of-the-art. In: INTERNATIONAL WORKSHOP ON EXPLOITING CONTEXT HISTORIES IN SMART ENVIRONMENTS (ECHISE2005), 1., 2005. **Proceedings...** [S.l.: s.n.], 2005.

MENDES, E. V. As redes de atenção à saúde. **Ciência & saúde coletiva**, [S.l.], v. 15, n. 5, p. 2297–305, 2010.

MIHAILIDIS, A.; BOGER, J. N.; CRAIG, T.; HOEY, J. The COACH prompting system to assist older adults with dementia through handwashing: an efficacy study. **BMC geriatrics**, [S.l.], v. 8, n. 1, p. 28, 2008.

MORESI, E. Metodologia da pesquisa. **Universidade Católica de Brasília**, [S.l.], 2003.

NICK, R.; PASCOE, J.; MORSE, D. Enhanced reality fieldwork: the context-aware archaeologist assistant. In: COMPUTER APPLICATIONS & QUANTITATIVE METHODS IN ARCHAEOLOGY, 1997. **Anais...** Archaeopress, 1997. v. 0.

NORUSIS, M. J. **IBM SPSS statistics 19 statistical procedures companion**. [S.l.]: Prentice Hall, 2012.

OLIVEIRA-CAMPOS, M.; RODRIGUES-NETO, J. F.; SILVEIRA, M. F.; NEVES, D. M. R.; VILHENA, J. M.; OLIVEIRA, J. F.; MAGALHÃES, J. C.; DRUMOND, D. Impacto dos fatores de risco para doenças crônicas não transmissíveis na qualidade de vida. **Ciência & Saúde Coletiva**, [S.l.], v. 18, p. 873–82, 2013.

ORGANIZATION, W. H. et al. Preventing chronic diseases: a vital investment: who global report. **Geneva: World Health Organization**, [S.l.], 2005.

ORWAT, C.; RASHID, A.; HOLTSMANN, C.; WÖLK, M.; SCHEERMESSER, M.; KOSOW, H.; GRAEFE, A. Adopting pervasive computing for routine use in healthcare. **IEEE Pervasive Computing**, [S.l.], v. 9, n. 2, p. 64–71, 2010.

OSKARSSON, A.; SCHÜTZ, A.; SKERFVING, S.; HALLÉN, I. P.; OHLIN, B.; LAGERKVIST, B. J. Total and inorganic mercury in breast milk and blood in relation to fish consumption and amalgam fillings in lactating women. **Archives of Environmental Health: An International Journal**, [S.l.], v. 51, n. 3, p. 234–241, 1996.

PARK, H.-S.; CHO, S.-B. Evolutionary attribute ordering in Bayesian networks for predicting the metabolic syndrome. **Expert Systems with Applications**, [S.l.], v. 39, n. 4, p. 4240–4249, 2012.

PEARL, J. **Causality: models, reasoning and inference**. [S.l.]: Cambridge Univ Press, 2000. v. 29.

PETZOLD, J.; PIETZOWSKI, A.; BAGCI, F.; TRUMLER, W.; UNGERER, T. Prediction of Indoor Movements Using Bayesian Networks. In: IN PROCEEDINGS OF LOCATION- AND CONTEXT-AWARENESS (LOCA 2005), 2005. **Anais...** [S.l.: s.n.], 2005.

- PIEGAS, L. S.; AVEZUM, I.; PEREIRA, J. C. R.; NETO, J. M. R.; HOEPFNER, C.; FARRAN, J. A.; RAMOS, R. F.; TIMERMAN, A.; ESTEVES, J. P. Risk factors for myocardial infarction in Brazil. **American heart journal**, [S.l.], v. 146, n. 2, p. 331–338, 2003.
- POLANCZYK, C. A. et al. Fatores de risco cardiovascular no Brasil: os próximos 50 anos. **Arq Bras Cardiol**, [S.l.], v. 84, n. 3, p. 199–201, 2005.
- PUOANE, T.; TSOLEKILE, L.; SANDERS, D.; PARKER, W. et al. Chronic non-communicable diseases. **South African health review**, [S.l.], v. 1, p. 73–87, 2008.
- RODRÍGUEZ, M. D.; NAVARRO, R. F.; FAVELA, J.; HOEY, J. An Ontological Representation Model to Tailor Ambient Assisted Interventions for Wandering. In: AAAI FALL SYMPOSIUM SERIES, 2012., 2012. **Anais...** [S.l.: s.n.], 2012.
- ROSS, S. M. **Introduction to probability models**. [S.l.]: Academic press, 2006.
- RUSSELL, S. J.; NORVIG, P. **Artificial intelligence: a modern approach**. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 1995. 415-429 p.
- SAÚDE, B. dMinistério da. **Diretrizes e recomendações cuidado integral de doenças crônicas não-transmissíveis: promoção da saúde, vigilância, prevenção e assistência**. [S.l.]: Ministério da Saúde Brasília, 2008.
- SAÚDE, O. M. da. **Cuidados inovadores para condições crônicas: componentes estruturais de ação: relatório mundial**. [S.l.]: Organização mundial da Saúde Brasília, 2003.
- SANTOS, R. D.; TIMERMAN, S.; SPÓSITO, A. C.; HALPERN, A.; SEGAL, A.; RIBEIRO, A. B.; GARRIDO, A.; MADY, C.; FERNANDES, F.; LORENZI FILHO, G. et al. Diretrizes para cardiologistas sobre excesso de peso e doença cardiovascular dos Departamentos de Aterosclerose, Cardiologia Clínica e FUNCOR da Sociedade Brasileira de Cardiologia. **Arq. bras. cardiol**, [S.l.], v. 78, n. supl. 1, p. 01–13, 2002.
- SANTOS; RAUL; MARTINEZ; L, T. Fatores de risco para doença cardiovascular: velhos e novos fatores de risco, velhos problemas! **Arquivos Brasileiros de Endocrinologia & Metabologia**, [S.l.], v. 46, n. 3, p. 212–214, 2002.
- SATYANARAYANAN, M. Pervasive Computing: vision and challenges. **IEEE Personal Communications**, [S.l.], v. 8, p. 10–17, 2001.
- SCHILIT, B.; THEIMER, M. Disseminating Active Map Information to Mobile Hosts. **IEEE Network**, [S.l.], v. 8, p. 22–32, 1994.
- SEPPALA, A.; NYKANEN, P.; RUOTSALAINEN, P. Development of Personal Wellness Information Model for Pervasive Healthcare. **Journal of Computer Networks and Communications**, [S.l.], v. 2012, 2012.
- SILVA, J. M.; ROSA, J. H.; BARBOSA, J. L. V.; BARBOSA, D. N. F.; PALAZZO, L. A. M. Content distribution in trail-aware environments. **J. Braz. Comp. Soc.**, [S.l.], v. 16, n. 3, p. 163–176, 2010.
- SINGH, D.; HAM, C. **Improving care for people with long-term conditions: a review of uk and international frameworks**. [S.l.]: University of Birmingham. Health services management centre, 2006.

SOHN, M.; LEE, J. U-health in Korea: opportunities and challenges. In: MANAGEMENT OF ENGINEERING AND TECHNOLOGY, PORTLAND INTERNATIONAL CENTER FOR, 2007. **Anais...** [S.l.: s.n.], 2007. p. 2791–2794.

SONG, T.-M.; RYU, S.; LEE, S. H. U-Health service for managing chronic disease: a case study on managing metabolic syndrome in a health center in south korea. **Healthcare informatics research**, [S.l.], v. 17, n. 4, p. 260–266, 2011.

SPORNY, M.; INKSTER, T.; STORY, H.; HARBULOT, B.; BACHMANN-GMÜR, R. WebID 1.0: web identification and discovery. **W3C Editor's Draft**, [S.l.], 2011.

SPOSITO, A. C.; CARAMELLI, B.; FONSECA, F. A.; BERTOLAMI, M. C.; AFIUNE NETO, A.; SOUZA, A. D.; LOTTENBERG, A. M. P.; CHACRA, A. P.; FALUDI, A. A.; LOURES-VALE, A. A. et al. V Diretriz brasileira sobre dislipidemias e prevenção da aterosclerose: departamento de aterosclerose da sociedade brasileira de cardiologia. **Arquivos Brasileiros de Cardiologia**, [S.l.], v. 101, p. 2–19, 2013.

THOMSEN, L. P.; WEINREICH, U. M.; KARBING, D. S.; HELBO JENSEN, V. G.; VUUST, M.; FRØKJÆR, J. B.; REES, S. E. Can computed tomography classifications of chronic obstructive pulmonary disease be identified using Bayesian networks and clinical data? **Computer methods and programs in biomedicine**, [S.l.], v. 1, p. 361–368, 2013.

THOYIB, W.; LEE, E.-S.; PARK, M.-G. Ubiquitous Healthcare system: a design on the remote monitoring based on walking activities. In: ELECTRICAL ENGINEERING AND INFORMATICS (ICEEI), 2011 INTERNATIONAL CONFERENCE ON, 2011. **Anais...** [S.l.: s.n.], 2011. p. 1–6.

TRUMLER, W.; BAGCI, F.; PETZOLD, J.; UNGERER, T. Smart doorplate. **Personal and Ubiquitous Computing**, [S.l.], v. 7, n. 3-4, p. 221–226, 2003.

TUNG, J.; SNYDER, H.; HOEY, J.; MIHAILIDIS, A.; CARRILLO, M.; FAVELA, J. Everyday Patient-Care Technologies for Alzheimer's Disease. **IEEE Pervasive Computing**, [S.l.], v. 12, n. 4, p. 0080–83, 2013.

VIANNA, H. D. **U'Ductor, um modelo para cuidado ubíquo de doenças crônicas não transmissíveis**. 2013. Dissertação (Mestrado em Ciência da Computação) — Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Computação Aplicada, 2013.

VOIGTMANN, C.; SCHUTTE, C.; WACKER, A.; DAVID, K. A new approach for distributed and collaborative context prediction. In: PERVASIVE COMPUTING AND COMMUNICATIONS WORKSHOPS (PERCOM WORKSHOPS), 2013 IEEE INTERNATIONAL CONFERENCE ON, 2013. **Anais...** [S.l.: s.n.], 2013. p. 20–24.

WAGNER, E. H. Chronic disease management: what will it take to improve care for chronic illness? **Effective clinical practice: ECP**, [S.l.], v. 1, n. 1, p. 2–4, 1997.

WAGNER, E. H.; AUSTIN, B. T.; DAVIS, C.; HINDMARSH, M.; SCHAEFER, J.; BONOMI, A. Improving chronic illness care: translating evidence into action. **Health affairs**, [S.l.], v. 20, n. 6, p. 64–78, 2001.

WAGNER, E. H.; GROVES, T. Care for chronic diseases. **BMJ**, [S.l.], v. 325, n. 7370, p. 913–914, 10 2002.

WANG, X.-H.; ZHENG, B.; GOOD, W. F.; KING, J. L.; CHANG, Y.-H. Computer-assisted diagnosis of breast cancer using a data-driven Bayesian belief network. **International Journal of Medical Informatics**, [S.l.], v. 54, n. 2, p. 115–126, 1999.

WEISER, M. The computer for the 21st century. **Scientific american**, [S.l.], v. 265, n. 3, p. 94–104, 1991.

YAP, G.-E.; TAN, A.-H.; PANG, H. Dynamically-optimized context in recommender systems. In: MOBILE DATA MANAGEMENT, 2005. **Anais...** ACM, 2005. p. 265–272.

YONEYAMA, T. **DISCRETIZAÇÃO PARA APRENDIZAGEM BAYESIANA: aplicação no auxílio à validação de dados em proteção ao voo**. 2003. Tese (Doutorado em Ciência da Computação) — Instituto Tecnológico de Aeronáutica, 2003.

YOO, S.; JUNG, S.; CHOI, J.; RHO, D. Development of ubiquitous health monitoring system. In: CONVERGENCE INFORMATION TECHNOLOGY, 2007. INTERNATIONAL CONFERENCE ON, 2007. **Anais...** [S.l.: s.n.], 2007. p. 1116–1120.

## APÊNDICE A QUESTIONÁRIO PARA PESSOAS COM DCNTS

### ChronicPrediction - prognóstico ubíquo de fatores de risco de DCNT

Doenças Crônicas Não Transmissíveis (DCNTs) são as que mais contribuem para o aumento da incidência de doenças em países desenvolvidos, e estão aumentando rapidamente nos países em desenvolvimento. DCNTs incluem doenças cardíacas, doenças vasculares, câncer, doenças respiratórias crônicas, diabetes, dentre outras. Para 2015, projeta-se que haverá um total de 64 milhões de mortes, sendo 41 milhões de mortes decorrentes em função de doenças crônicas. Doenças cardiovasculares irão permanecer como sendo a causa principal de morte, com uma estimativa de morte de 20 milhões de pessoas, principalmente devido a doenças cardíacas e problemas cardiovasculares.

Se faz importante que o paciente portador de alguma DCNT possa ter acesso rápido e direto sobre a situação atual do seu tratamento independentemente do local onde ele esteja e do período do dia. Nesse sentido, a ascensão de dispositivos móveis com acesso à internet, tais como smartphones, oferece características importantes e com grande potencial para facilitar o controle e acompanhamento contínuo dos doentes, afinal, a grande maioria das pessoas carrega seus smartphones a todos lugares que frequentam diariamente e, além disso, dispondo de acesso à internet de forma ininterrupta, podem obter auxílio especializado sempre que necessário.

O ChronicPrediction, é um modelo para prognóstico de fatores de risco de DCNTs cuja função é verificar a evolução ou involução de certos aspectos que influenciam nesses fatores, além de fornecer recomendações e dicas para o paciente com o intuito de auxiliá-lo na melhora do seu estado de saúde. O modelo é disponibilizado na forma de um aplicativo para smartphones que utilizam o sistema operacional Android.

\* Required

1. **Você tem como hábito a utilização de aplicativos para smartphones que possuem como foco o acompanhamento de alguma atividade relevante para o seu tratamento? \***

*Mark only one oval.*

- Sim, utilizo sempre que encontro algum relevante
- Sim, utilizo apenas p/ o monitoramento de atividades físicas
- Sim, utilizo apenas p/ o registro e acompanhamento da taxa bioquímica sanguínea (colesterol, glicose, pressão arterial)
- Não, não utilizo nenhum aplicativo p/ acompanhar meu tratamento.

2. **Idade: \***

.....

3. **Além dos fatores de risco de uma DCNT, o protótipo do modelo ChronicPrediction poderia monitorar outras características / atividades. Se você pudesse sugerir uma característica / atividade a qual pudesse ser monitorada diariamente e que fosse relevante para o seu tratamento, qual seria? \***

.....

4. **Uma das características do tratamento de uma DCNT é o fato de necessitar de acompanhamento constante e a necessidade de participação ativa e envolvimento do próprio paciente no seu tratamento. Smartphones possuem como característica principal o fato de estarem sempre com os seus proprietários. Você consideraria o smartphone como sendo um mecanismo valioso no tratamento de uma DCNT desde que possuísse um aplicativo específico para este fim? \***

*Mark only one oval.*

- Sim, considero um smartphone o mecanismo ideal para este fim
- Sim, considero que os smartphones possuem características adequadas, porém, existem outros dispositivos melhores para este fim
- Não, não considero os smartphones adequados para este fim, pois os outros dispositivos destinados para este fim já cumprem com os objetivos desejados

5. **Se você tivesse em seu smartphone um aplicativo que lhe oferecesse recomendações e dicas periodicamente com o intuito de auxiliá-lo no bom andamento do seu tratamento durante as suas atividades diárias, você o utilizaria? \***

*Mark only one oval.*

- Sim, utilizaria constantemente
- Sim, utilizaria raramente
- Não, nunca utilizaria

6. **Comentários / Sugestões:**

.....

.....

.....

.....

.....

7. **O protótipo do modelo ChronicPrediction será disponibilizado, inicialmente, apenas para o sistema operacional Android, porém, posteriormente, o objetivo será disponibilizar para outras plataformas. Qual o sistema operacional presente no seu smartphone? \***

*Mark only one oval.*

- iOS (Apple)
- Android (Google)
- Windows Phone (Microsoft)
- Symbian (Nokia)

8. **Tipo de problema / doença cardíaca que possui: \***

.....

9. **Nome: \***

.....

## ANEXO A DADOS BASAIS DO USUÁRIO (GAEDKE, 2013)

	Instituto de Medicina Vascular - Hospital Mãe de Deus Mestrado em Saúde Coletiva - Unisinos Projeto de Coorte Prospectiva de Usuários com Síndrome Coronariana Aguda Questionário 01 - Dados Basais do Usuário	
	Nome: _____ Coletor: _____ Número de atendimento HMD: _____ Data da coleta: __/__/____	
Lista de Problemas e diagnósticos (coletar do prontuário ou da lista de internação)		
Angina estável (0) não           (1) sim  Angina instável (0) não           (1) sim  Angina sem diagnóstico específico (0) não           (1) sim  Acidente vascular cerebral hemorrágico (0) não           (1) sim  Acidente vascular cerebral isquêmico (0) não           (1) sim  Acidente vascular cerebral sem diagnóstico específico (0) não           (1) sim  Infarto agudo do miocárdio prévio (0) não           (1) sim  Infarto agudo do miocárdio (IAM) (0) não           (1) sim  Infarto agudo do miocárdio sem data definida (0) não           (1) sim  Síndrome coronariana aguda (SCASST) (0) não           (1) sim  Hipertensão Arterial Sistêmica (HAS) (0) não           (1) sim  Diabetes mellitus (DM) (0) não           (1) sim  Obesidade (0) não           (1) sim  Outro: _____	LPAngE ____  LPAngI ____  LPAngs ____  LPAVCh ____  LPAVCi ____  LPAVCs ____  LPIAMp ____  LPIAM ____  LPIAMd ____  LPSCA ____  LPHAS ____  LPDM ____  LPObesi____  LPOut ____	
Dados da tramitação do questionário (preenchido pela supervisão)		
<input type="checkbox"/> Codificação <input type="checkbox"/> Revisão final <input type="checkbox"/> Segunda entrada <input type="checkbox"/> Revisão do prontuário <input type="checkbox"/> Primeira entrada <input type="checkbox"/> Agendado seguimento <input type="checkbox"/> Correções: _____ <input type="checkbox"/> Arquivamento		



1. Qual o seu estado civil? (0) solteiro (1) em união/casado  
(2) separado/divorciado (3) viúvo

Estciv \_\_

2. Data de nascimento: \_\_/\_\_/\_\_\_\_

Datn \_\_/\_\_/\_\_\_\_

3. Sexo: (0) feminino (1) masculino

Sexo \_\_

4. Qual sua cor da pele? (0) branca (1) não branca

Cor \_\_

5. Você mora sozinho? (0) não (1) sim

Mora \_\_

6. Quantos anos de estudo completos você tem? \_\_\_\_\_ anos

Escola \_\_

7. Você está trabalhando? (0) Sim (1) Não  
(2) Aposentado (3) Desempregado  
(4) Encostado (5) Dona de casa  
(6) Estudante (7) Outro: \_\_\_\_\_

Trab \_\_

8. Qual a sua renda familiar mensal (média em reais)? \_\_\_\_\_.\_\_\_\_,\_\_\_\_

Renda \_\_\_\_\_.\_\_\_\_,\_\_\_\_

9. Qual seu endereço completo?

\_\_\_\_\_

Endereço

\_\_\_\_\_

Endereço (cont.)

\_\_\_\_\_

Bairro

\_\_\_\_\_

Cidade

Telefones

Fixo \_\_\_\_\_

Celular \_\_\_\_\_

10. Você poderia nos fornecer o endereço de um parente ou pessoa próxima, para o caso de termos dificuldade em encontrá-lo(a) no futuro?

\_\_\_\_\_

Nome

\_\_\_\_\_

Parentesco

\_\_\_\_\_

Endereço

\_\_\_\_\_

Endereço (cont.)

\_\_\_\_\_

Bairro

\_\_\_\_\_

Cidade

Telefones

Fixo \_\_\_\_\_

Celular \_\_\_\_\_

## Coleta de dados da Internação (Coletar do prontuário)

Peso (1ª medida)	— — — kg	
- Forma de mensuração	(0) medido	(1) referido
Altura	— — — cm	
- Forma de mensuração	(0) medido	(1) referido
Circunferência abdominal	— — — , — cm	
PA sistólica (1ª medida)	— — — mmHg	
PA diastólica (1ª medida)	— — — mmHg	
PA sistólica (2ª medida)	— — — mmHg	
PA diastólica (2ª medida)	— — — mmHg	

Peso	— — — , —
Pesol	—
Alt	— — —
AltI	—
Cabd	— — — , —
PsisE	— — —
PdiaE	— — —
PsisS	— — —
PdiaS	— — —

### Agora vamos falar sobre sua Alimentação.

11. Quantas vezes por semana você costuma comer frutas?

- (1) Todos os dias  
 (2) 5 a 6 dias por semana  
 (3) 3 a 4 dias por semana  
 (4) 1 a 2 dias por semana  
 (5) Quase nunca/nunca (**pula para pergunta de nº 13**)

**1 Porção de fruta é:**

1 fruta (ex.: uma maçã, banana)  
 ou  
 1 uma fatia média (ex.: mamão)  
 ou  
 1 copo de suco de fruta

FrefruS \_\_\_

12. Em um dia comum, quantas porções de frutas você come?

- (1) 1 porção (8) NSA  
 (2) 2 porções  
 (3) 3 porções  
 (4) 4 ou mais porções

Porfrud \_\_\_

13. Quantas vezes por semana você costuma comer verduras e legumes?

- (1) Todos os dias  
 (2) 5 a 6 dias por semana  
 (3) 3 a 4 dias por semana  
 (4) 1 a 2 dias por semana  
 (5) Quase nunca/nunca (**pula para pergunta de nº 15**)

**1 Porção de verdura ou legume é:**

1 xícara de vegetais folhosos (ex.: alface, rúcula)  
 ou  
 1/2 xícara de outros vegetais (ex.: cenoura beterraba)

FreverS \_\_\_

14. Em um dia comum, quantas porções de verduras ou legumes você come?

- (1) 1 porção (8) NSA  
 (2) 2 porções  
 (3) 3 porções  
 (4) 4 ou mais porções

Porverd \_\_\_

15. Quando você come carne vermelha, você costuma (**Ler opções**):

- (1) tira a gordura (2) come com a gordura (3) não come carne vermelha

Carneg \_\_\_

16. Quando você come frango, você costuma (**Ler opções**):

- (1) tira a pele (2) come com a pele (3) não come frango

Frangop \_\_\_

17. Você costuma comer peixe?

- (1) Sim (2) não come peixe

Peixe \_\_\_

Quantas vezes por mês? \_\_\_ \_\_\_

Peixfre \_\_\_ \_\_\_

18. Qual tipo de gordura mais utilizada na sua casa para preparar os alimentos (**Ler opções**)?

- (1) Banha animal  
 (2) Manteiga  
 (3) Óleo vegetal como: soja, girassol, milho, algodão ou canola  
 (4) Margarina  
 (5) Azeite de oliva  
 (6) Não sei

Tipogord \_\_\_

19. Quantas vezes por semana você costuma comer (**Ler opções**)?

- ovo frito: \_\_\_ \_\_\_  
 - ovo cozido: \_\_\_ \_\_\_  
 - leite integral: \_\_\_ \_\_\_  
 - margarina: \_\_\_ \_\_\_  
 - manteiga: \_\_\_ \_\_\_  
 - miúdos (fígado, moela, coração de frango): \_\_\_ \_\_\_

Ovofri \_\_\_ \_\_\_

Ovoco \_\_\_ \_\_\_

Leitei \_\_\_ \_\_\_

Marga \_\_\_ \_\_\_

Mante \_\_\_ \_\_\_

Miudo \_\_\_ \_\_\_

20. Quantos dias por semana você costuma comer qualquer um dos seguintes alimentos: frituras, toucinho, embutidos como mortadela, presunto, salsicha, salame, linguiça?

- (1) Todos os dias  
(2) 5 a 6 dias por semana  
(3) 3 a 4 dias por semana  
(4) 1 a 2 dias por semana  
(5) Quase nunca/nunca

Congor \_\_\_

**Agora vamos perguntar algumas coisas sobre Fumo.**

21. Você fuma ou já fumou?

(0) Não (Se nunca fumou, pular para questão nº 22) (9) IGN

(1) Se sim: Há quanto tempo você fuma? \_\_\_ anos (00 = se menos de 1 ano)

Quantos cigarros você fuma por dia? \_\_\_

(2) Se ex-fumante: Há quanto tempo parou (há quantos anos)? \_\_\_ anos

Fuma \_\_\_

Fumtem \_\_\_

Cigdia \_\_\_

Fumex \_\_\_

**História prévia de Doença Isquêmica**  
**Agora vamos conversar sobre alguns problemas que você possa ter tido.**

22. Você já teve ou passou por:

Cirurgia de carótida	(0) não	(1) sim	(9) IGN
Insuficiência cardíaca	(0) não	(1) sim	(9) IGN
Fibrilação atrial/flutter/arritmia	(0) não	(1) sim	(9) IGN
Estenose de válvula aórtica	(0) não	(1) sim	(9) IGN
Aneurisma de aorta abdominal	(0) não	(1) sim	(9) IGN
Diabetes	(0) não	(1) sim	(9) IGN

Se sim, há quanto tempo \_\_\_ anos

Hipertensão arterial (0) não (1) sim (9) IGN

Se sim, há quanto tempo \_\_\_ anos

23. Faz tratamento para colesterol (0) não (1) sim (9) IGN

24. Você teve ataque isquêmico transitório diagnosticado?

(0) não (1) sim, -1 ano (2) sim, +1 ano (9) IGN

25. Você teve derrame ou AVC isquêmico diagnosticado?

(0) não (1) sim, -1 ano (2) sim, +1 ano (9) IGN

26. Você tem ou teve angina **estável** diagnosticada?

(0) não (1) sim, -1 ano (2) sim, +1 ano (9) IGN

27. Você tem ou teve angina **instável** diagnosticada?

(0) não (1) sim -1 ano (2) sim +1 ano (9) IGN

28. Você teve infarto do miocárdio diagnosticado?

(0) não (1) sim, -1 ano (2) sim, +1 ano (9) IGN

29. Você fez angioplastia ou colocou stent?

(0) não (1) sim, -1 ano (2) sim, +1 ano (9) IGN

30. Você fez bypass coronariano/cirurgia cardíaca?

(0) não (1) sim, -1 ano (2) sim, +1 ano (9) IGN

31. Você teve Estenose de carótida assintomática?

(0) não (1) sim, -1 ano (2) sim, +1 ano (9) IGN

32. Você tem alguma placa na carótida?

(0) não (1) sim, -1 ano (2) sim, +1 ano (9) IGN

33. Registro de claudicação intermitente associada com:

\* ITB < 0,9

(8) sem registro (0) não (1) sim, -1 ano (2) sim, +1 ano (9) IGN

\* Angioplastia/ stent/ bypass em artéria do membro inferior

(0) não (1) sim, -1 ano (2) sim, +1 ano (9) IGN

\* Amputações nos membros inferiores

(0) não (1) sim, -1 ano (2) sim, +1 ano (9) IGN

Circa \_\_\_

ICC \_\_\_

Flut \_\_\_

Est \_\_\_

Aoabd \_\_\_

Diab \_\_\_

Diabtem \_\_\_

Hast \_\_\_

Hastem \_\_\_

Tacoles \_\_\_

hptia \_\_\_

hpavc \_\_\_

hpane \_\_\_

hpins \_\_\_

hpiam \_\_\_

hpsten \_\_\_

hpcabg \_\_\_

hrcar \_\_\_

hrpla \_\_\_

hpclabi \_\_\_

hpclang \_\_\_

hpclmp \_\_\_

**Agora vamos perguntar algumas coisas sobre o consumo de bebida alcoólica.**

34. Com que frequência você costuma ingerir bebida alcoólica?  
 (0) não consome bebida alcoólica (**pula para a pergunta de nº 37**)  
 (1) Todos os dias  
 (2) 5 a 6 dias por semana  
 (3) 3 a 4 dias por semana  
 (4) 1 a 2 dias por semana  
 (5) Quase nunca/nunca (**pula para pergunta de nº 37**)

Frealcm \_\_\_

35. Em um único dia você chega a tomar mais do que 01 lata de cerveja ou mais do que 01 taça de vinho ou mais do que 01 dose de qualquer outra bebida alcoólica?  
 (0) Não (**pula para a pergunta de nº 37**)  
 (1) Sim  
 (8) NSA

Qualcm \_\_\_

36. No último mês, você chegou a consumir **05 ou mais doses** de bebida alcoólica em um único dia?

Mesalcm\_\_\_

- (0) Não (**pula para a pergunta de nº 37**)  
 (1) Sim  
 (8) NSA

**01 dose de bebida alcoólica é:**

- 01 lata de cerveja  
 ou  
 01 taça de vinho  
 ou  
 01 dose de bebida destilada

**Agora vamos perguntar algumas coisas sobre seu hábito de atividade física.**

37. Você pratica alguma atividade física de lazer há mais de 01 mês?  
 (0) Não (**pula para a pergunta de nº 39**)  
 (1) Sim

Lazer \_\_\_

38. Agora você vai me dizer qual atividade física pratica, frequência e duração:

Atividade	Quantas vezes por semana?	Tempo de duração da sessão
A01 _____	Vs01 _____	Ts01 _____
A02 _____	Vs02 _____	Ts02 _____
A03 _____	Vs03 _____	Ts03 _____
A04 _____	Vs04 _____	Ts04 _____
A05 _____	Vs05 _____	Ts05 _____

A01 \_\_\_ \_\_\_  
 Vs01 \_\_\_ \_\_\_  
 Ts01 \_\_\_ \_\_\_  
 A02 \_\_\_ \_\_\_  
 Vs02 \_\_\_ \_\_\_  
 Ts02 \_\_\_ \_\_\_  
 A03 \_\_\_ \_\_\_  
 Vs03 \_\_\_ \_\_\_  
 Ts03 \_\_\_ \_\_\_  
 A04 \_\_\_ \_\_\_  
 Vs04 \_\_\_ \_\_\_  
 Ts04 \_\_\_ \_\_\_  
 A05 \_\_\_ \_\_\_  
 Vs05 \_\_\_ \_\_\_  
 Ts05 \_\_\_ \_\_\_

Atvout (88) NSA (77) realiza outra(s) mas não lembra

Atvout \_\_\_ \_\_\_

**39. Uso de Medicamentos**

Eu gostaria de fazer algumas perguntas sobre os remédios que o(a) Sr.(a) está tomando atualmente. O(a) Sr.(a) poderia pegar as caixinhas dos remédios para eu anotar os nomes?

Medicamentos	Apresentação (99 = IGN)	Dose (888 = NSA)	Frequência diária (99 = IGN)
M01 _____	A01 ___ ___	D01 ___ ___ ___	F01 ___ ___
M02 _____	A02 ___ ___	D02 ___ ___ ___	F02 ___ ___
M03 _____	A03 ___ ___	D03 ___ ___ ___	F03 ___ ___
M04 _____	A04 ___ ___	D04 ___ ___ ___	F04 ___ ___
M05 _____	A05 ___ ___	D05 ___ ___ ___	F05 ___ ___
M06 _____	A06 ___ ___	D06 ___ ___ ___	F06 ___ ___
M07 _____	A07 ___ ___	D07 ___ ___ ___	F07 ___ ___
M08 _____	A08 ___ ___	D08 ___ ___ ___	F08 ___ ___
M09 _____	A09 ___ ___	D09 ___ ___ ___	F09 ___ ___
M10 _____	A10 ___ ___	D10 ___ ___ ___	F10 ___ ___

Mout (00) Não usa medicamentos (77) Usa outro(s) mas não lembra



## ANEXO B MEDICAMENTOS PRESCRITOS (GAEDKE, 2013)

	<p>Instituto de Medicina Vascular - Hospital Mãe de Deus Mestrado em Saúde Coletiva - Unisinos Projeto de Coorte Prospectiva de Usuários com Síndrome Coronariana Aguda Questionário 02 - Acompanhamento 30 dias</p>	
Nome: _____ Coletor: _____ Data da coleta: __/__/____	Pron _____ Colet2 __ __ Colseg __/__/____	
Estou ligando em nome do Instituto de Medicina Vascular para lhe perguntar sobre sua saúde após sua internação com a equipe do coração do Mãe de Deus. Todas as perguntas a seguir referem-se aos acontecimentos após a sua alta hospitalar.		
1. O paciente faleceu? (0) não ( <b>pula para a questão nº 02</b> ) (1) sim Em que data? __/__/____ 1.a. Foi IAM? (0) não (1) sim (9) IGN (8) NSA 1.b. Foi AVC fatal? (0) não (1) sim (9) IGN (8) NSA 1.c. Foi outra doença circulatória (inclusive morte súbita de causa desconhecida)? (0) não (1) sim (9) IGN (8) NSA 1.d. Foi por causa não circulatória? (0) não (1) sim (9) IGN (8) NSA	F1obit __  Datobi __/__/____  F1iam __ F1avc __ F1circ __  F1iam __	
2. Desde sua última internação no Mãe de Deus, quantas vezes o(a) Sr(a) consultou com o médico? (00) nenhuma ( <b>pula para a questão nº 9</b> ) __ __ vezes (8) NSA 3. Após sua alta hospitalar o(a) Sr(a) foi hospitalizado novamente por algum problema de saúde como derrame, infarto, ponte de safena, amputação, dor no peito, coração aumentado ou colocação de stent?? (00) não ( <b>pula para a questão nº 05</b> ) (1) sim (9) IGN (8) NSA 4. Após sua alta hospitalar o(a) Sr(a) teve um derrame? (0) não ( <b>pula para a questão nº 05</b> ) (1) sim Em que data? __/__/____ 4.a. Foi isquêmico? (0) não (1) sim (9) IGN (8) NSA 4.b. Foi hemorrágico? (0) não (1) sim (9) IGN (8) NSA 4.c. O Sr(a) apresenta incapacidade moderada ou piora? (0) não (1) sim (8) NSA 4.d. Quantos eventos de derrame após a alta o(a) Sr(a) teve? __ __ vezes (8) NSA 4.d. Quantas hospitalizações de relacionadas a esse(s) derrame o(a) Sr(a) teve? __ __ vezes (8) NSA	F1cons __  F1hosp __  F1dernf __ __ Datder __/__/____ F1disq __ F1dhe __  F1inc __ F1dev __  F1dho __	
5. Após sua alta hospitalar o(a) Sr(a) teve um infarto? (0) não ( <b>pula para a questão nº 06</b> ) (1) sim Em que data? __/__/____ 5.a. Quantos eventos de infarto após a alta o(a) Sr(a) teve? __ __ vezes (8) NSA 5.b. Quantas hospitalizações de relacionadas a esse(s) infartos o(a) Sr(a) teve? __ __ vezes (8) NSA	F1iamnf __  Datiam __/__/____ F1iaev __  F1iaho __	
Dados da tramitação do questionário (preenchido pela supervisão)		
<input type="checkbox"/> Codificação <input type="checkbox"/> Revisão final <input type="checkbox"/> Segunda entrada <input type="checkbox"/> Revisão do prontuário <input type="checkbox"/> Primeira entrada <input type="checkbox"/> Agendado seguimento <input type="checkbox"/> Correções: _____ <input type="checkbox"/> Arquivamento		

<p>6. Após sua alta hospitalar o(a) Sr.(a) teve trombose ou entupimento das artérias das pernas?  (0) não (<b>pula para a questão nº 07</b>)  (1) sim  Em que data? ___/___/_____</p> <p>5.b. Quantas hospitalizações de relacionadas a esse problema o(a) Sr(a) teve?  ___ vezes (8) NSA</p>	<p>F1tromb __</p> <p>Dattro ___/___/_____</p> <p>F1itho __</p>
---	--

**Outras causas de hospitalização**  
**Agora vamos conversar sobre alguns problemas que possam ter causado hospitalização.**

<p>7. O(a) Sr(a) teve ou tem?</p> <p>7.a. Dor no peito que levou à hospitalização?  (00) nenhuma ___ vezes (8) NSA</p> <p>7.b. Derrame com recuperação total?  (00) nenhuma ___ vezes (8) NSA</p> <p>7.c. Insuficiência cardíaca congestiva/coração grande?  (00) nenhuma ___ vezes (8) NSA</p> <p>7.d. Episódio de sangramento desde a internação no Mãe de Deus que tenha levado a hospitalização ou transfusão?  (00) nenhuma ___ vezes (8) NSA</p>	<p>F1angis __</p> <p>F1agev __</p> <p>F1dert __</p> <p>F1dtev __</p> <p>F1lcc __</p> <p>F1lceev __</p> <p>F1sang __</p> <p>F1saev __</p>
--	--

<p>8. O(a) Sr(a) fez?</p> <p>8.a. Ponte de safena?  (00) nenhuma ___ vezes (8) NSA</p> <p>8.b. Angioplastia/stent de coronária?  (00) nenhuma ___ vezes (8) NSA</p> <p>8.c. Cirurgia de carótida?  (00) nenhuma ___ vezes (8) NSA</p> <p>8.d. Angioplastia/stent de carótida?  (00) nenhuma ___ vezes (8) NSA</p> <p>8.e. Amputação de membros inferiores?  (00) nenhuma ___ vezes (8) NSA</p> <p>8.f. Cirurgia para circulação das pernas (sem ser varizes)?  (00) nenhuma ___ vezes (8) NSA</p> <p>8.g. Desentupimento das artérias das pernas por cirurgia?  (00) nenhuma ___ vezes (8) NSA</p> <p>8.h. Desentupimento das artérias das pernas por cateter?  (00) nenhuma ___ vezes (8) NSA</p>	<p>F1posa __</p> <p>F1psev __</p> <p>F1scoro __</p> <p>F1coev __</p> <p>F1ccar __</p> <p>F1ccaev __</p> <p>F1acaro __</p> <p>F1acev __</p> <p>F1ami __</p> <p>F1aiev __</p> <p>F1ccp __</p> <p>F1cpev __</p> <p>F1dap __</p> <p>F1dapev __</p> <p>F1dapc __</p> <p>F1dacev __</p>
--	---

**Agora vamos perguntar algumas coisas sobre Fumo.**

<p>9. Você fuma ou já fumou?  (0) Não (<b>Se nunca fumou, pular para questão nº 10</b>) (9) IGN</p> <p>(1) Se sim: Há quanto tempo você fuma? ___ anos (00 = se menos de 1 ano)  Quantos cigarros você fuma por dia? ___ ___</p> <p>(2) Se ex-fumante: Há quanto tempo parou (há quantos anos)? ___ anos</p>	<p>Fumaf1 __</p> <p>Fumtemf1 ___</p> <p>Cigdiaf1 ___ ___</p> <p>Fumexf1 ___</p>
--	---

**Agora vamos conversar sobre sua situação de trabalho**

10. Você está trabalhando? (0) Sim (1) Não  
 (2) Aposentado (3) Desempregado  
 (4) Encostado (5) Dona de casa  
 (6) Estudante (7) Outro: \_\_\_\_\_

Trabf1 \_\_

**Agora vamos falar sobre sua Alimentação.**

11. Quantas vezes por semana você costuma comer frutas?

- (1) Todos os dias  
 (2) 5 a 6 dias por semana  
 (3) 3 a 4 dias por semana  
 (4) 1 a 2 dias por semana  
 (5) Quase nunca/nunca (**pula para pergunta de nº 13**)

**1 Porção de fruta é:**

1 fruta (ex.: uma maçã, banana)  
 ou  
 1 uma fatia média (ex.: mamão)  
 ou  
 1 copo de suco de fruta

FFrefruS \_\_

12. Em um dia comum, quantas porções de frutas você come?

- (1) 1 porção (8) NSA  
 (2) 2 porções  
 (3) 3 porções  
 (4) 4 ou mais porções

Fporfrud \_\_

13. Quantas vezes por semana você costuma comer verduras e legumes?

- (1) Todos os dias  
 (2) 5 a 6 dias por semana  
 (3) 3 a 4 dias por semana  
 (4) 1 a 2 dias por semana  
 (5) Quase nunca/nunca (**pula para pergunta de nº 15**)

**1 Porção de verdura ou legume é:**

1 xícara de vegetais folhosos (ex.: alface, rúcula)  
 ou  
 1/2 xícara de outros vegetais (ex.: cenoura beterraba)

FFreverS \_\_

14. Em um dia comum, quantas porções de verduras ou legumes você come?

- (1) 1 porção (8) NSA  
 (2) 2 porções  
 (3) 3 porções  
 (4) 4 ou mais porções

Fporverd \_\_

15. Quando você come carne vermelha, você costuma (**Ler opções**):

- (1) tira a gordura (2) come com a gordura (3) não come carne vermelha

Fcarneg \_\_

16. Quando você come frango, você costuma (**Ler opções**):

- (1) tira a pele (2) come com a pele (3) não come frango

Ffrango \_\_

17. Você costuma comer peixe?

- (1) Sim (2) não come peixe

Fpeixe \_\_

Quantas vezes por mês? \_\_ \_\_

Fpeixfre \_\_ \_\_

18. Qual tipo de gordura mais utilizada na sua casa para preparar os alimentos (**Ler opções**)?

- (1) Banha animal  
 (2) Manteiga  
 (3) Óleo vegetal como: soja, girassol, milho, algodão ou canola  
 (4) Margarina  
 (5) Azeite de oliva  
 (6) Não sei

Ftipogor \_\_

19. Quantas vezes por semana você costuma comer (**Ler opções**)?

- ovo frito: \_\_ \_\_ \_\_  
 - ovo cozido: \_\_ \_\_ \_\_  
 - leite integral: \_\_ \_\_ \_\_  
 - margarina: \_\_ \_\_ \_\_  
 - manteiga: \_\_ \_\_ \_\_  
 - miúdos (fígado, moela, coração de frango): \_\_ \_\_ \_\_

Fovofri \_\_ \_\_ \_\_

Fovoco \_\_ \_\_ \_\_

Fleitei \_\_ \_\_ \_\_

Fmarga \_\_ \_\_ \_\_

Fmante \_\_ \_\_ \_\_

Fmiudo \_\_ \_\_ \_\_

20. Quantos dias por semana você costuma comer qualquer um dos seguintes alimentos: frituras, toucinho, embutidos como mortadela, presunto, salsicha, salame, linguiça?

- (1) Todos os dias
- (2) 5 a 6 dias por semana
- (3) 3 a 4 dias por semana
- (4) 1 a 2 dias por semana
- (5) Quase nunca/nunca

Fcongor \_\_\_

**Agora vamos perguntar algumas coisas sobre seu hábito de atividade física.**

21. Após a alta do Mãe de Deus você passou a praticar alguma atividade física de lazer?

- (0) Não (**pula para a pergunta de nº 23**)
- (1) Sim

Flazer \_\_\_

22. Agora você vai me dizer qual atividade física pratica, frequência e duração:

Atividade	Quantas vezes por semana?	Tempo de duração da sessão
Fa01 _____	Fvs01 _____	Fts01 _____
Fa02 _____	Fvs02 _____	Fts02 _____
Fa03 _____	Fvs03 _____	Fts03 _____
Fa04 _____	Fvs04 _____	Fts04 _____
Fa05 _____	Fvs05 _____	Fts05 _____

Fa01 \_\_\_ \_\_\_  
 Fvs01 \_\_\_ \_\_\_  
 Fts01 \_\_\_ \_\_\_  
 Fa02 \_\_\_ \_\_\_  
 Fvs02 \_\_\_ \_\_\_  
 Fts02 \_\_\_ \_\_\_  
 Fa03 \_\_\_ \_\_\_  
 Fvs03 \_\_\_ \_\_\_  
 Fts03 \_\_\_ \_\_\_  
 Fa04 \_\_\_ \_\_\_  
 Fvs04 \_\_\_ \_\_\_  
 Fts04 \_\_\_ \_\_\_  
 Fa05 \_\_\_ \_\_\_  
 Fvs05 \_\_\_ \_\_\_  
 Fts05 \_\_\_ \_\_\_

Atvout (88) NSA

(77) realiza outra(s) mas não lembra

Atvout \_\_\_ \_\_\_

**23. Uso de Medicamentos**

Eu gostaria de fazer algumas perguntas sobre os remédios que o(a) Sr.(a) está tomando atualmente. O(a) Sr.(a) poderia pegar as caixinhas dos remédios para eu anotar os nomes?

Medicamentos	Apresentação (99 = IGN)	Dose (888 = NSA)	Frequência diária (99 = IGN)
Fm01 _____	Fa01 _____	Fd01 _____	Ff01 _____
Fm02 _____	Fa02 _____	Fd02 _____	Ff02 _____
Fm03 _____	Fa03 _____	Fd03 _____	Ff03 _____
Fm04 _____	Fa04 _____	Fd04 _____	Ff04 _____
Fm05 _____	Fa05 _____	Fd05 _____	Ff05 _____
Fm06 _____	Fa06 _____	Fd06 _____	Ff06 _____
Fm07 _____	Fa07 _____	Fd07 _____	Ff07 _____
Fm08 _____	Fa08 _____	Fd08 _____	Ff08 _____
Fm09 _____	Fa09 _____	Fd09 _____	Ff09 _____
Fm10 _____	Fa10 _____	Fd10 _____	Ff10 _____

Mout (00) Não usa medicamentos

(77) Usa outro(s) mas não lembra

**Agora vamos precisar saber algumas medidas do seu corpo**

Peso \_\_\_\_\_, \_\_\_ kg

- Forma de mensuração (0) medido (1) referido

Altura \_\_\_\_\_ cm

- Forma de mensuração (0) medido (1) referido

Circunferência abdominal \_\_\_\_\_, \_\_\_ cm

Após a alta do Mãe de Deus, o(a) Sr(a) mediu a sua pressão arterial alguma vez?

(0) não (1) sim (9) IGN (8) NSA

O(a) Sr(a) sabe informar o valor da última vez que mediu a pressão depois da alta?

(0) não (1) sim. Quanto? (9) IGN (8) NSA

PA sistólica \_\_\_\_\_ mmHg

PA diastólica \_\_\_\_\_ mmHg

Pesof1 \_\_\_\_\_, \_\_\_

Pesolf1 \_\_\_

Altif1 \_\_\_\_\_

Altif \_\_\_

Cabdf1 \_\_\_\_\_, \_\_\_

Psisf1 \_\_\_\_\_

Pdiaf1 \_\_\_\_\_