



Programa Interdisciplinar de Pós-Graduação em

Computação Aplicada

Mestrado Acadêmico

Fábio de Oliveira Dias

Um Modelo Proativo de Antecipação de Ações de Times de
Resposta Rápida Baseado em Análise Preditiva

São Leopoldo, 2017

Fábio de Oliveira Dias

**UM MODELO PROATIVO DE ANTECIPAÇÃO DE AÇÕES DE TIMES
DE RESPOSTA RÁPIDA BASEADO EM ANÁLISE PREDITIVA**

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

Orientador: Prof. Dr. Cristiano André da Costa

São Leopoldo

2017

D541m Dias, Fábio de Oliveira

Um modelo proativo de antecipação de ações de times de resposta rápida baseado em análise preditiva / Fábio de Oliveira Dias - 2017.

104 f.: il.; 30 cm.

Dissertação (mestrado) - Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Computação Aplicada, 2017.

“Orientador: Prof. Dr. Cristiano André da Costa.”

1. Computação ubíqua. 2. Predição. 3. Processamento eletrônico de dados – Processamento distribuído. 4. Saúde. I. Costa, Cristiano André da. II. Título.

CDU 004

Dados Internacionais de Catalogação na Publicação (CIP)

(Bibliotecária: Raquel Herbcz França – CRB 10/1795)

Fábio de Oliveira Dias

Um Modelo Proativo de Antecipação de Ações de Times de Resposta Rápida
Baseado em Análise Preditiva

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 17/02/2017

BANCA EXAMINADORA

Prof. Dr. Claudio Fernando Resin Geyer – UFRGS

Prof. Dr. Rodrigo da Rosa Righi – UNISINOS

Prof. Dr. Cristiano André da Costa – UNISINOS (Orientador)

Visto e permitida a impressão.
São Leopoldo,

Prof. Dr. Sandro José Rigo
Coordenador PPG em Computação Aplicada

- “1. When a distinguished but elderly scientist states that something is possible, he is almost certainly right. When he states that something is impossible, he is very probably wrong.*
 - 2. The only way of discovering the limits of the possible is to venture a little way past them into the impossible.*
 - 3. Any sufficiently advanced technology is indistinguishable from magic.”*
- Clarke's three laws, Arthur C. Clarke*

AGRADECIMENTOS

À minha mãe, por todo o amor e os valiosos exemplos que me deu durante esses anos.

Aos meus irmãos, pelo amor, afeto e carinho que temos uns pelos outros.

À minha esposa Bárbara e à minha enteada Júlia, pelo amor, apoio e compreensão.

Ao meu orientador, Prof. Dr. Cristiano André da Costa, pelos ensinamentos, apoio, orientação, incentivo e paciência.

Aos professores do PIPCA, em particular ao Prof. Dr. Rodrigo da Rosa Righi, ao Prof. Dr. Jorge Luis Victoria Barbosa e ao Prof. Dr. Luiz Paulo Luna de Oliveira, pelas inestimáveis e relevantes contribuições.

Aos colegas do PIPCA, especialmente ao Daniel, Leandro, Ismael, Lucas e Vitor, pela parceria em todos os momentos desta jornada.

Ao ex-aluno e amigo Luis Henrique Valgoi pelo auxílio prestado com a identidade visual do projeto.

Aos meus ex-alunos do IFSul, pelo carinho demonstrado ao longo destes anos de docência.

Ao meu supervisor, Hugo Debiasi Coluzzi, pelo apoio dado em todas as fases deste projeto.

Ao IFSul, pelo apoio e incentivo que me deu para cumprir este objetivo.

RESUMO

A computação móvel e ubíqua tem propiciado o advento de soluções que permitem o monitoramento em tempo real de sinais provenientes de sensores e o seu processamento por aplicações que podem executar ações de acordo com as condições encontradas. Esta característica possibilita o uso da tecnologia para o monitoramento de condições de saúde de pacientes, denominado de cuidados ubíquos. Em diversas situações, a fim de salvar vidas de pacientes, é necessária a análise de seus sinais vitais de forma a prevenir eventuais colapsos. Este trabalho se insere nestas condições, estando voltado para a antecipação de ações de times de resposta rápida baseado em análise preditiva, propondo o modelo Predictvs. Um Time de Resposta Rápida busca prevenir mortes de pacientes que tenham piora clínica fora de ambientes de Unidades de Tratamento Intensivo em hospitais. De forma diversa dos trabalhos relacionados, que se preocupam apenas com ambientes de tratamento intensivo, o modelo Predictvs busca antecipar ações dos times de resposta rápida, através da análise dos sinais vitais dos pacientes com o uso de escores de alerta precoce e regressão linear. A contribuição científica do modelo é dada em virtude da possibilidade de efetuar a predição em tempo real de possíveis situações de colapso dos pacientes através do monitoramento e análise dos sinais vitais. A avaliação do Predictvs foi efetuada com a utilização de cenários, com a implementação de um protótipo e através de diversas simulações. Análises efetuadas com cerca de 228000 medições provenientes de um *dataset* público apresentaram bons resultados, onde a precisão da predição para a medição seguinte se mostrou bastante alta, atingindo mais de 99% no caso da frequência cardíaca e 100% na saturação de oxigênio arterial, ultrapassando 95% nos demais sinais vitais. Além disso, o índice de falsos negativos foi consideravelmente baixo, atingindo menos de 1% na frequência cardíaca e na saturação de oxigênio arterial. O índice de falsos positivos também foi baixo, embora não tanto quanto o de falsos negativos. No entanto, predições para três ou mais medições futuras mostram queda na precisão (mesmo demonstrando valores de acerto relativamente expressivos, com diversos sinais fisiológicos acima de 98%) e aumento do número de falsos negativos e, principalmente, de falsos positivos.

Palavras-Chave: Times de Resposta Rápida. Escores de Alerta Precoce. Predição. Computação Ubíqua. Computação Aplicada à Saúde.

ABSTRACT

The mobile and ubiquitous computing has allowed the emergence of solutions that enable real-time monitoring of signals coming from sensors and processing for applications that can perform actions according to the conditions found. This feature enables the use of this technology for monitoring health conditions of patients, called ubiquitous healthcare. In several situations, in order to save his lives, it is necessary to analyze the vital signs of patients to prevent any collapses. This work is part of these conditions and is aimed at anticipating the actions of rapid response teams based on predictive analysis, proposing the Predictvs model. A Rapid Response Team intends to prevent deaths in patients who have clinical deterioration outside of intensive care units in hospitals environments. Differently of related works, which are concerned only with intensive care environments, the Predictvs model seeks to anticipate the actions of teams of rapid response through the analysis of vital signs of patients with the use of early warning scores and linear regression. The scientific contribution of the presented model is that we could better predict possible collapse situations of patients, through the monitoring and analysis of vital signs. The Predictvs evaluation was performed with the use of scenarios, implementation of a prototype and several simulations. Analyzes performed with about 228,000 measurements from a public dataset showed good results, where the accuracy of the prediction for the next measurement was very high, reaching more than 99% in the case of heart rate and 100% in arterial oxygen saturation, surpassing 95% in other vital signs. In addition, the false negative index was considerably lower, reaching less than 1% in heart rate and arterial oxygen saturation. The rate of false positives was also low, although not so much as that of false negatives. However, predictions for three or more future measurements show a drop in accuracy (even showing relatively expressive set values with several physiological signals above 98%) and an increase in the number of false negatives and, mainly, false positives.

Keywords: Rapid Response Teams. Early Warning Scores. Prediction. Ubiquitous computing. Applied Computing in Health.

LISTA DE FIGURAS

Figura 1. Cenário de utilização do modelo Predictvs.....	27
Figura 2. Cenário genérico proposto por Weiser.....	30
Figura 3. Curva de característica de operação do receptor do grupo de validação.	37
Figura 4. Algoritmo de ciência ao contexto utilizado no estudo.	39
Figura 5. MEWS e tabela de observações desenvolvidos.	40
Figura 6. Exemplo de árvore de decisão e nodos obtidos pela frequência do pulso.	41
Figura 7. Curvas de eficiência DTEWS e NEWS.	42
Figura 8. Resumo dos alertas e das saídas gerados pela ferramenta de predição.....	44
Figura 9. Visão geral do modelo Predictvs.....	48
Figura 10. Arquitetura do Modelo Predictvs.	50
Figura 11. Módulo coletor.	51
Figura 12. Módulo de processamento.	56
Figura 13. Módulo de alertas.....	58
Figura 14. Execução do módulo de processamento do protótipo.....	62
Figura 15. Execução do módulo de alertas do protótipo.....	63
Figura 16. Integração do módulo de alertas com aplicativo de mensagens Telegram.....	63
Figura 17. Tendência dos dados simulados e dos dados resultantes da predição.....	68
Figura 18. Tendência dos dados provenientes do <i>dataset</i> e dos resultantes da predição.	69
Figura 19. Tendência dos dados utilizando o algoritmo de predição modificado.....	70
Figura 20. Gráficos resultantes das simulações – paciente “055”.....	83
Figura 21. Gráficos resultantes das simulações – paciente “211”.....	83
Figura 22. Gráficos resultantes das simulações – paciente “221”.....	84
Figura 23. Gráficos resultantes das simulações – paciente “226”.....	85
Figura 24. Gráficos resultantes das simulações – paciente “230”.....	85
Figura 25. Gráficos resultantes das simulações – paciente “248”.....	86
Figura 26. Gráficos resultantes das simulações – paciente “252”.....	86
Figura 27. Gráficos resultantes das simulações – paciente “253”.....	87
Figura 28. Gráficos resultantes das simulações – paciente “401”.....	88
Figura 29. Gráficos resultantes das simulações – paciente “403”.....	88

LISTA DE TABELAS

Tabela 1. Exemplo de escore de alerta precoce.....	32
Tabela 2. Comparativo entre os trabalhos relacionados.....	45
Tabela 3. Escore de alerta precoce modificado implementado na função <i>pontuacao</i>	53
Tabela 4. Escore de alerta precoce modificado implementado.	61
Tabela 5. Resumo dos registros do banco de dados MIMIC utilizados pelo protótipo.....	67
Tabela 6. Análise dos dados simulados e dos dados resultantes da predição.....	69
Tabela 7. Análise dos dados provenientes do <i>dataset</i> e dos dados resultantes da predição.	70
Tabela 8. Análise dos dados provenientes do algoritmo de predição modificado.	71
Tabela 9. Resultados obtidos com as simulações efetuadas – paciente “055”	72
Tabela 10. Acionamentos, falsos positivos e falsos negativos – paciente “055”	73
Tabela 11. Resultados obtidos com as simulações efetuadas – paciente “211”	73
Tabela 12. Acionamentos, falsos positivos e falsos negativos – paciente “211”	74
Tabela 13. Resultados obtidos com as simulações efetuadas – paciente “221”	74
Tabela 14. Acionamentos, falsos positivos e falsos negativos – paciente “221”	75
Tabela 15. Resultados obtidos com as simulações efetuadas – paciente “226”	75
Tabela 16. Acionamentos, falsos positivos e falsos negativos – paciente 226.....	76
Tabela 17. Resultados obtidos com as simulações efetuadas – paciente “230”	76
Tabela 18. Acionamentos, falsos positivos e falsos negativos – paciente “230”	77
Tabela 19. Resultados obtidos com as simulações efetuadas – paciente “248”	77
Tabela 20. Acionamentos, falsos positivos e falsos negativos – paciente “248”	78
Tabela 21. Resultados obtidos com as simulações efetuadas – paciente “252”	78
Tabela 22. Acionamentos, falsos positivos e falsos negativos – paciente “252”	79
Tabela 23. Resultados obtidos com as simulações efetuadas – paciente “253”	79
Tabela 24. Acionamentos, falsos positivos e falsos negativos – paciente “253”	80
Tabela 25. Resultados obtidos com as simulações efetuadas – paciente “401”	80
Tabela 26. Acionamentos, falsos positivos e falsos negativos – paciente “401”	81
Tabela 27. Resultados obtidos com as simulações efetuadas – paciente “403”	81
Tabela 28. Acionamentos, falsos positivos e falsos negativos – paciente “403”	82
Tabela 29. Consolidação de acionamentos, falsos positivos e falsos negativos – todos os pacientes	89
Tabela 30. Tempo estimado de antecipação de ocorrências ao Time de Resposta Rápida.....	90
Tabela 31. Contribuições do modelo Predictvs	92

LISTA DE ABREVIATURAS

BPM	Batimentos (cardíacos) por minuto
DBP	<i>Diastolic blood pressure</i> , pressão sanguínea diastólica
EB	Escala de Braden
FC	Frequência cardíaca
FP	Frequência do pulso
FR	Frequência respiratória
GLAS	Escala de Glasgow
HR	<i>Heart rate</i> , frequência cardíaca
IPM	Inspirações por minuto
MAP	<i>Mean arterial pressure</i> , pressão arterial média
PAS	Pressão arterial sistólica
PR	<i>Pulse rate</i> , frequência do pulso
ROC	<i>Receiver operating characteristic</i> , característica de operação do receptor
RR	<i>Respiratory rate</i> , frequência respiratória
SBP	<i>Systolic blood pressure</i> , pressão sanguínea sistólica
TEMP	Temperatura
URI	Nível de urina

LISTA DE SIGLAS

AMQP	<i>Advanced Message Queuing Protocol</i>
API	<i>Application programming interface</i> , interface de programação de aplicações
AVPU	<i>Alert, voice, pain, unresponsive</i> , alerta, voz, dor, sem resposta
DTEWS	<i>Decision-Tree Early Warning Score</i> , escore de alerta precoce baseado em árvore de decisão
EWS	<i>Early Warning Score</i> , escore de alerta precoce
ICH	Índice de choque hipovolêmico
IHI	<i>Institute for Healthcare Improvement</i>
MEWS	<i>Modified Early Warning Score</i> , escore de alerta precoce modificado
MIMIC	<i>Multiparameter Intelligent Monitoring in Intensive Care</i> , monitoramento multiparâmetro inteligente em cuidados intensivos
NEWS	<i>National Early Warning Score</i> , escore de alerta precoce nacional
PCR	Parada cardiorrespiratória
PEWS	<i>Pediatric Early Warning Score</i> , escore de alerta precoce pediátrico
PIPICA	Programa Interdisciplinar de Pós-Graduação em Computação Aplicada
RRT	<i>Rapid Response Team</i> , time de resposta rápida
STOMP	<i>Streaming Text Oriented Messaging Protocol</i>
UNISINOS	Universidade do Vale do Rio dos Sinos
UNSAFE	<i>Unrecognized situation awareness failures events</i> , eventos de falha de ciência de contexto não reconhecidas
UTI	Unidade de Terapia Intensiva

LISTA DE SÍMBOLOS

°C	Graus Celsius
h	Hora
kg	Quilograma
l	Litro
min	Minuto
ml	Mililitro
mmHg	Milímetro de mercúrio
O ₂	Oxigênio
SaO ₂	Saturação de oxigênio arterial
seg	Segundo

SUMÁRIO

1 INTRODUÇÃO	26
1.1 Contribuições e questão de pesquisa	27
1.2 Objetivos	28
1.3 Metodologia	28
1.4 Organização do texto	28
2 FUNDAMENTAÇÃO TEÓRICA	30
2.1 Computação ubíqua	30
2.2 Saúde ubíqua	31
2.2.1 Times de Resposta Rápida	31
2.2.2 Escores de alerta precoce.....	32
2.3 Regressão linear	33
2.4 Considerações sobre o capítulo.....	33
3 TRABALHOS RELACIONADOS	36
3.1 Artigo 1 – “ <i>A Clinical Deterioration Prediction Tool for Internal Medicine Patients</i> ”	36
3.2 Artigo 2 – “ <i>Improving Situation Awareness to Reduce Unrecognized Clinical Deterioration and Serious Safety Events</i> ”	38
3.3 Artigo 3 – “ <i>Monitoring Vital Signs: Development of a Modified Early Warning Score (MEWS) System for General Wards in a Developing Country</i> ”	39
3.4 Artigo 4 – “ <i>Decision-tree early warning scores (DTEWS) validates the design of the National Early Warning Scores</i> ”	41
3.5 Artigo 5 – “ <i>A Trial of a Real-Time Alert for Clinical Deterioration in Patients Hospitalized on General Medical Wards</i> ”	42
3.6 Avaliação dos trabalhos relacionados.....	44
3.6.1 Lacunas de pesquisa	46
4 MODELO PROPOSTO	48
4.1 Visão geral	48
4.2 Arquitetura	49
4.2.1 Módulo coletor	50
4.2.2 Módulo de processamento	51
4.2.3 Módulo de alertas	57
4.3 Considerações sobre o capítulo.....	58
5 IMPLEMENTAÇÃO	60
5.1 Protótipo Predictvs	60
5.1.1 Módulo coletor	60
5.1.2 Módulo de processamento	61
5.1.3 Módulo de alertas	62
5.2 Funcionamento do protótipo através de cenário.....	64
5.3 Considerações sobre o capítulo.....	65
6 AVALIAÇÃO E DISCUSSÃO	66
6.1 Ambiente de experimentação	66
6.2 Resultados	67
6.3 Discussão.....	82
6.4 Considerações sobre o capítulo.....	90
7 CONSIDERAÇÕES FINAIS	92
7.1 Trabalhos futuros	93
REFERÊNCIAS	96

1 INTRODUÇÃO

Em dezembro de 2004, o fundador e CEO do *Institute for Healthcare Improvement* (IHI), uma organização independente e sem fins lucrativos que busca promover melhorias nos cuidados médicos, Dr. Don Berwick, lançou um desafio na reunião anual da entidade, ocorrida em Orlando. Impaciente com o ritmo das mudanças relacionadas à segurança dos pacientes e com objetivos vagos da área da saúde, ele anunciou uma campanha para salvar 100 mil vidas nos hospitais nos 18 meses seguintes (WATCHER; PRONOVOST, 2006). Para atingir esse audacioso objetivo, foi proposta a adoção de seis práticas pelas instituições de saúde. Dentre essas práticas estava a sugestão de implantação de Times de Resposta Rápida (*Rapid Response Teams*, RRTs) nos hospitais. Passados os 18 meses, o instituto anunciou que o objetivo inicial havia sido ultrapassado, tendo sido salvas 122.300 vidas (WATCHER; PRONOVOST, 2006). Posteriormente, uma extensão dessa campanha foi lançada, propondo salvar 5 milhões de vidas entre dezembro de 2006 e dezembro de 2008 (MCCANNON et al., 2007).

Um Time de Resposta Rápida consiste em uma equipe de profissionais de saúde liderada por um médico, com a finalidade de prevenir mortes de pacientes que tenham piora clínica fora de um ambiente preparado para atendê-los em uma eventual situação crítica (por exemplo, pacientes em enfermarias). Para tanto, é necessária a análise de sinais vitais dos pacientes, de forma a prevenir ou detectar um eventual colapso dos mesmos (BERWICK et al., 2006). Estudos atuais têm comprovado a eficiência da técnica, seja pela diminuição das ocorrências de paradas cardíacas (ANGEL et al., 2016), seja em virtude do significativo decréscimo do índice de mortalidade de pacientes (JUNG et al., 2016).

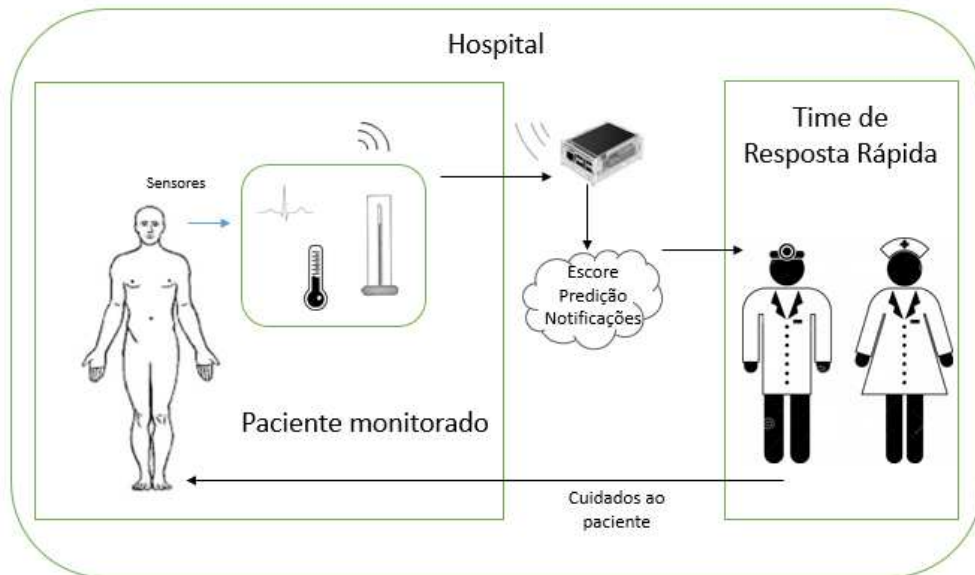
Em 1991, Mark Weiser, em seu seminal trabalho, vislumbrou um futuro através de um cenário de total integração entre dispositivos, onde a computação tornar-se-ia transparente e completamente acoplada ao cotidiano das pessoas, ou seja, ubíqua (WEISER, 1991). Em 2001, Satyanarayanan trouxe esta visão para o contexto tecnológico existente à época, consolidando a computação móvel e ubíqua no formato que se conhece atualmente (SATYANARAYANAN, 2001).

A computação móvel e ubíqua tem propiciado o advento de soluções que permitem o monitoramento em tempo real de sinais advindos de sensores e o seu processamento por aplicações que podem executar ações de acordo com as condições encontradas. Esta característica possibilita o uso da tecnologia para o monitoramento de condições de saúde de pacientes, denominado de cuidados ubíquos (*ubiquitous healthcare*) (GELOGO et al., 2013). Indo além, provê, inclusive, condições para que possa ser efetuada a predição de eventuais pioras clínicas e o acionamento de profissionais de saúde para prestar o adequado socorro, permitindo o salvamento de vidas.

Este trabalho se insere nestas condições, estando voltado para a antecipação de ações de times de resposta rápida baseado em análise preditiva, com o uso de escores de alerta precoce e regressão linear, propondo o modelo Predictvs. O modelo trabalha de forma reativa ou preditiva, de acordo com o contexto dos sinais fisiológicos dos pacientes.

A Figura 1 apresenta o cenário em que o modelo proposto se encaixa, demonstrando a transmissão dos dados advindos dos sensores e o envio de notificações aos profissionais de saúde que compõem o Time de Resposta Rápida. Como será visto posteriormente, o modelo apresenta componentes específicos para o monitoramento dos sinais fisiológicos, para o processamento destes sinais e para o envio de alertas e notificações ao Time de Resposta Rápida.

Figura 1. Cenário de utilização do modelo Predictvs.



Fonte: elaborado pelo autor

1.1 Contribuições e questão de pesquisa

O modelo apresentado propõe, como principal contribuição científica, a possibilidade de prever possíveis situações de colapso dos pacientes e antecipar, em um tempo que varia de acordo com o sinal fisiológico medido, indo de segundos a minutos, o acionamento dos times de resposta rápida através do monitoramento dos sinais vitais com o uso de escores de alerta precoce complementados por regressão linear. Os escores de alerta precoce dão base para o componente reativo e a regressão linear dá vida ao componente preditivo do modelo. A regressão linear foi utilizada para efetuar a predição, por ser um método rápido e preciso. Como será visto posteriormente, a agilidade na predição é um fator importante para o modelo.

Tomando como base os trabalhos relacionados, a questão de pesquisa que surge e que se busca responder com esta pesquisa é:

“Como seria um modelo para antecipar as ocorrências geradas para times de resposta rápida, usando a análise preditiva a partir da combinação de sinais vitais advindos de sensores?”

Por análise preditiva, entenda-se a capacidade do modelo de prever, através dos valores anteriores das medições dos sinais vitais, valores futuros que servirão como base para o cálculo de um novo escore de alerta precoce. A antecipação citada vai de segundos a minutos, variando de acordo com o sinal fisiológico e será explanado posteriormente. Por ocorrência, compreenda-se toda e qualquer alteração nos sinais fisiológicos que possa requerer intervenção médica. Por combinação de sinais vitais, entenda-se a compatibilidade do modelo de utilizar dados provenientes de medições de diversos sinais fisiológicos, tais como frequência cardíaca, frequência respiratória, pressão arterial, temperatura e saturação de oxigênio arterial, entre outros. Como será visto no Capítulo 3, as principais lacunas dos trabalhos relacionados foram a ausência de relação com os Times de Resposta Rápida e a carência de processamento em tempo real.

1.2 Objetivos

O principal objetivo deste trabalho é desenvolver um modelo, batizado de Predictvs, que efetua análise preditiva com base nos dados decorrentes da medição de sinais vitais dos pacientes para determinar a necessidade de acionamento, em tempo real, dos Times de Resposta Rápida em determinadas situações. Os objetivos específicos do trabalho são:

- Efetuar a identificação e a avaliação dos fundamentos teóricos da área;
- Comparar os trabalhos relacionados, que apresentam o tema da análise das condições de saúde de pacientes e a necessária predição da degradação de seus sinais vitais;
- Especificar a arquitetura do modelo Predictvs;
- Implementar o protótipo com base no modelo especificado;
- Avaliar o modelo com base em cenários e com o protótipo implementado, analisando os resultados obtidos.

1.3 Metodologia

Para a realização desta pesquisa, preliminarmente buscou-se estudar as características dos times de resposta rápida e dos escores de alerta precoce, de forma a apropriar conhecimentos essenciais para o transcorrer do trabalho. Foram identificados alguns atributos e condições que iriam se fazer necessários na elaboração do modelo proposto, tais como as condições de acionamento e tipos de alerta e códigos que são emitidos em situações de colapso. Posteriormente, foram elencadas tecnologias que pudessem servir como base para a concepção de um modelo que atingisse os objetivos propostos. A seguir, foi elaborado um esboço da arquitetura do modelo, de forma a tornar possível o detalhamento dos requisitos para a sua implementação.

Partindo deste contexto, buscou-se identificar trabalhos similares, a fim de efetuar a análise das metodologias abordadas e dos resultados obtidos. Em seguida, foi elaborada uma tabela comparativa entre estes trabalhos, de forma a identificar as suas principais virtudes e carências. Com base nas informações coletadas, o modelo foi consolidado em sua primeira versão.

A partir daí, buscou-se efetuar a implementação de um protótipo que contemplasse as principais funcionalidades do modelo proposto, de forma a tornar possível o acionamento dos times de resposta rápida com base nas condições clínicas dos pacientes. A avaliação do modelo foi efetuada através de simulações, que utilizaram várias séries de dados reais de pacientes provenientes de *datasets* públicos. A comparação entre os dados resultantes da análise preditiva e dos dados reais mostraram uma boa aproximação, validando o modelo proposto.

1.4 Organização do texto

Este trabalho foi dividido em seis capítulos. Após a introdução, o Capítulo 2 descreve a fundamentação teórica que alicerça o modelo. O Capítulo 3 apresenta e detalha os trabalhos relacionados, identificando as lacunas de pesquisa. O Capítulo 4 descreve o modelo Predictvs, esmiuçando a sua arquitetura e os seus componentes. O Capítulo 5 apresenta uma avaliação do modelo baseada em cenários e a implementação de protótipo. Finalmente, resultados e resumo do trabalho são apresentados no Capítulo 6.

2 FUNDAMENTAÇÃO TEÓRICA

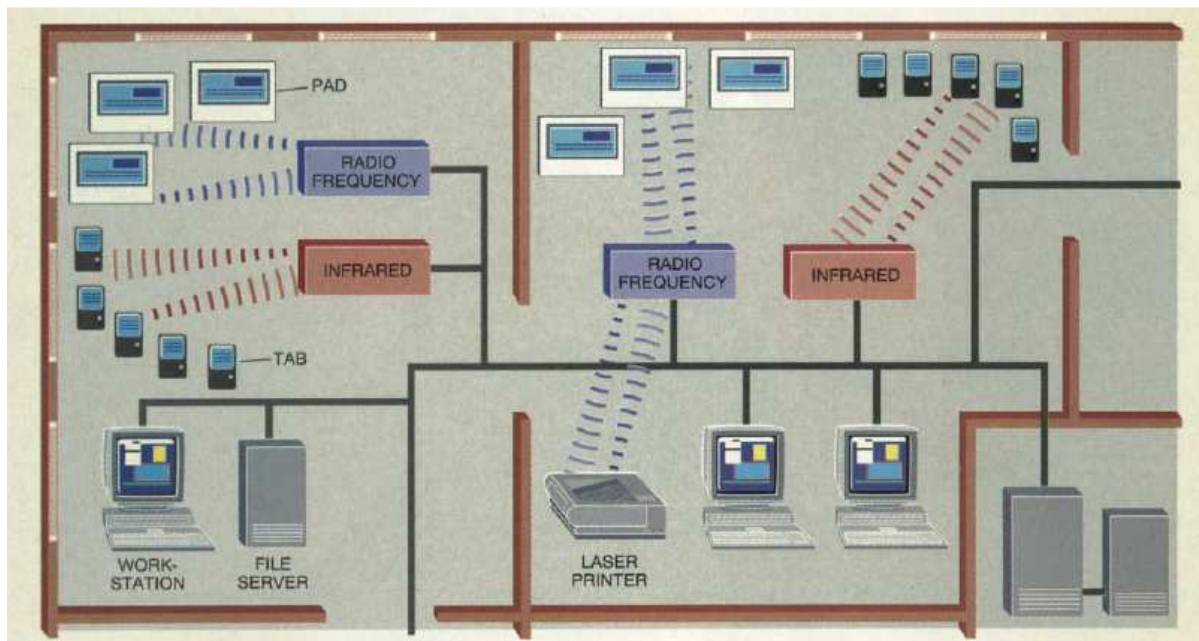
Este capítulo apresentará conceitos relevantes que embasam e fundamentam o modelo proposto. Para um melhor entendimento, serão descritos e relacionados os conceitos referentes à computação ubíqua, saúde ubíqua, times de resposta rápida, escores de alerta precoce e regressão linear.

2.1 Computação ubíqua

Weiser, em seu visionário artigo “*The computer for the 21st century*”, apresentou os conceitos relacionados à computação ubíqua. Para ele, as tecnologias mais relevantes para as pessoas são aquelas que se tornam imperceptíveis e transparentes no cotidiano. Elencando uma série de cenários onde suas teorias se encaixavam, em um momento da era tecnológica onde a comunicação entre dispositivos dependia de cabos, o autor previa o desenvolvimento e consolidação de tecnologias sem fio, bem como o advento da computação móvel (WEISER, 1991).

A Figura 2 demonstra um cenário genérico proposto por Weiser, prevendo tecnologias que se consolidariam anos mais tarde, tais como redes sem fio, *smartphones* e *tablets*.

Figura 2. Cenário genérico proposto por Weiser.



Fonte: Weiser, 1991

Em 2001, Satyanarayanan, em seu artigo “*Pervasive Computing: Vision and Challenges*”, aproximava os conceitos expostos por Weiser para as tecnologias existentes no século 21. Com o advento e consolidação da computação móvel e suas tecnologias relacionadas, os conceitos de computação ubíqua puderam tornar-se reais, sendo um grande avanço dentro da área da computação. O autor expõe os avanços dos sistemas distribuídos e da computação móvel e os trata como a base da computação pervasiva. Em seguida, elenca quatro desafios próprios da computação ubíqua, a saber: uso efetivo de espaços inteligentes, invisibilidade da tecnologia, escalabilidade localizada e a necessidade de técnicas para o mascaramento de

condições irregulares dos ambientes. Em seguida, em decorrência do uso de cenários apresentados, traz ao debate conceitos fundamentais, como gerenciamento de energia, ciência de contexto, privacidade e confiabilidade, entre outros (SATYANARAYANAN, 2001).

2.2 Saúde ubíqua

Um dos grandes campos de pesquisa dentro da computação ubíqua, a saúde ubíqua utiliza um variado número de sensores para monitorar a condição física e mental dos pacientes. Pequenos sensores são projetados para reunir informações sobre condições corporais, tais como temperatura, frequência cardíaca, pressão arterial, frequência respiratória e quase qualquer outra característica fisiológica que forneça informações que possam ser utilizadas para diagnosticar problemas de saúde (BROWN et al., 2007). Trata-se de um novo paradigma para a saúde, caracterizado pela coleta generalizada e contínua de sinais vitais e processamento em tempo real dos mesmos, de forma a possibilitar a tomada de decisões sensíveis ao contexto, sendo fundamental para oferecer soluções de saúde personalizados aos pacientes. No entanto, este novo paradigma requer processamento em tempo real dos sinais vitais obtidos usando modelos fisiológicos inerentemente complexos e a análise de informações processadas sob contexto (por exemplo, localização, condições ambientais, nível de atividade física) para extrair o conhecimento sobre o estado de saúde dos pacientes (VISWANATHAN et al., 2012).

A predição é considerada um dos pilares da transformação dos sistemas de cuidados em saúde. Neste novo paradigma, modelado também para diminuir custos nos sistemas públicos e privados de saúde, busca-se prever a ocorrência de doenças, ao invés de focar somente no diagnóstico e na cura, quando, nestes casos, a patologia já se faz presente (SNYDERMAN, 2008). Desta maneira, o termo "saúde preditiva" foi escolhido para enfatizar este conceito, em que a predição tem relevância em relação à doença. A saúde deve ser definida de forma positiva no âmbito de toda a experiência humana, não sendo apenas a ausência de doenças (sua condição padrão), mas inclui uma série de fatores que não se limitam apenas aos biológicos (BRIGHAM, 2010). Um foco de esforços e recursos em pessoas saudáveis pode identificar os fatores de predição mais robustos de saúde e de doenças, identificar as intervenções mais eficazes para aperfeiçoar a qualidade e a duração da saúde e traduzir esse conhecimento para as populações de uma maneira eficiente e de custo razoável (BRIGHAM, 2010). Dentro de todo este contexto, se encontram os times de resposta rápida e os escores de alerta precoce.

2.2.1 Times de Resposta Rápida

Um Time de Resposta Rápida é formado por uma equipe de profissionais liderada por um médico, que procura prevenir mortes de pacientes que tenham piora clínica fora de um ambiente de terapia intensiva. Para isso, se faz necessária a análise de sinais vitais dos pacientes, de forma a prevenir ou detectar um eventual colapso dos mesmos (BERWICK et al., 2006).

Os times de resposta rápida diferem de várias das equipes de código tradicionais presentes em hospitais e centros clínicos. Os times avaliam um número maior de pacientes internados em um estágio anterior ao da deterioração clínica, com o objetivo de prevenir eventos adversos graves, como ataques cardíacos e mortes inesperadas. Assim, os times de resposta rápida conseguem avaliar o desenvolvimento da deterioração cardíaca, respiratória ou neurológica de pacientes, por exemplo, ao invés de pacientes que já tiveram uma parada cardíaca ou respiratória (JONES et al., 2011).

2.2.2 Escores de alerta precoce

Um dos elementos que pode ser associado ao acionamento dos times de resposta rápida, os escores de alerta precoce são um sistema de rastreamento e gatilho para identificar os primeiros sinais de deterioração dos pacientes, onde cada parâmetro possui uma gama de pontos de corte com gatilhos correspondentes (MORGAN et al., 1997). Em 1997, Morgan, Williams e Wright foram os primeiros a desenvolver e publicar um escore de alerta precoce (EWS) no Reino Unido. Este EWS fazia referência a cinco parâmetros fisiológicos: frequência cardíaca, pressão arterial sistólica, frequência respiratória, temperatura e nível de consciência. Por exemplo, uma frequência cardíaca entre 111 e 129 bpm (batimentos por minuto) receberia um escore de 2 pontos, indicando a necessidade de escalada para intervenção pela equipe médica. (KYRIACOS et al., 2014)

Desde então, os sistemas de EWS foram modificados (sendo denominados MEWS, escores de alerta precoce modificados) e padronizados por todo o Reino Unido (KYRIACOS et al., 2014). Em adição aos cinco parâmetros fisiológicos citados, outros foram incorporados na maioria dos MEWS, tais como nível de saída da urina e oxigenação do sangue. Como não existe um MEWS ideal (KYRIACOS et al., 2014), a multiplicidade destes sistemas resultou em uma falta de consistência no reconhecimento e na resposta a deterioração clínica, tornando necessária a sua padronização. Em julho de 2012 foi implementado um escore de alerta precoce nacional (NEWS), com o monitoramento de seis parâmetros fisiológicos (frequência respiratória, saturação de oxigênio, temperatura, pressão arterial sistólica, frequência cardíaca e nível de consciência), porém a adoção deste não se tornou obrigatória nos hospitais (KYRIACOS et al., 2014). A Tabela 1 mostra um exemplo de tabela de escore de alerta precoce.

Tabela 1. Exemplo de escore de alerta precoce.

Sinal fisiológico/Escore	3	2	1	0	1	2	3
Frequência respiratória/min		≤ 9		9-14	15-20	21-29	≥ 30
Saturação O ₂	< 85	85-89	90-92	≥ 93			
Frequência cardíaca/min		≤ 40	41-50	51-100	101-110	111-129	≥ 130
Pressão sistólica	≤ 70	71-80	81-100	101-199		≥ 200	
Temperatura °C		≤ 35		35-38.4		≥ 38.5	
Estado neurológico Escala de Coma Glasgow				15	14	13-9	≤ 8
Estado neurológico Escala AVPU				Alerta	Reage à voz	Reage à dor	Sem resposta
Urina ml/kg em 1 hora	0.5ml/kg		≤ 1 ml/kg		≥ 3 ml/kg		

Fonte: Kyriacos et al., 2014

A análise de sinais vitais de pacientes permite monitorar possíveis ocorrências para acionar os times de resposta rápida. As ocorrências normalmente são classificadas em duas chamadas: Código Amarelo para urgências e Código Azul para emergências - PCR (parada cardiorrespiratória) (GONÇALES et al., 2012). Estudos comprovam a eficiência da abordagem, reduzindo a quantidade de óbitos nessas condições de forma significativa (OFFNER et al., 2007; GONÇALES et al., 2012). Abaixo são descritos alguns exemplos de sinais de alerta que podem disparar as ações dos Times de Resposta Rápida:

- Alteração súbita na frequência cardíaca, ficando abaixo de 40 ou acima de 130 bpm;
- Alteração súbita na pressão arterial sistólica, ficando menor que 90 mmHg (milímetros de mercúrio);
- Alteração súbita na frequência respiratória, estando abaixo de 8 ou acima de 28 ipm (inspirações por minuto), ou com comprometimento de via aérea;
- Alteração súbita de nível de consciência (OFFNER et al., 2007).

2.3 Regressão linear

Um dos métodos que pode ser empregado para efetuar predição de valores futuros, a regressão linear é uma abordagem estatística para modelar a relação entre uma variável escalar dependente y e uma ou mais variáveis independentes denotadas X . Para somente uma variável explicativa, o processo é chamado de regressão linear simples. Quando há mais de uma variável explicativa, o processo é chamado de regressão linear múltipla. Na regressão linear, as relações são modeladas utilizando as funções de previsão linear cujos parâmetros do modelo desconhecido são estimados a partir dos seus dados. Tais modelos são chamados modelos lineares. Em geral, a média condicional de y , dado o valor de x , é assumida como sendo uma função afim de x . Como todas as formas de análise de regressão, a regressão linear centra-se na distribuição de probabilidade condicional de y em virtude de x , ao invés da distribuição de probabilidade conjunta de y e x , que é o domínio da análise multivariada (KUTNER, 1996).

A regressão linear foi o primeiro tipo de análise de regressão estudado rigorosamente e é usado extensivamente em diversas aplicações práticas, uma vez que os modelos que dependem linearmente de seus parâmetros desconhecidos são mais fáceis de encaixar do que os modelos que não são linearmente relacionados com os seus parâmetros (KUTNER, 1996).

Salvo em casos de ocorrências de mal súbito, em geral, as medições de sinais vitais em pacientes que estão em repouso, situações comuns em ambientes hospitalares, mantêm um ritmo regular ao longo do tempo (MONK, 1994). Desta forma, através da regressão linear, um dos métodos estatísticos utilizados para efetuar a previsão de séries temporais, é possível antecipar a tendência e, conseqüentemente, efetuar a predição da degradação dos sinais fisiológicos dos pacientes (MAHLER; MACKOWIAK, 1995; SKLOOT et al., 2004; SCHNEIDER et al., 2010). Por ser simples e rápida, a regressão linear mostra-se bastante útil em aplicações reais onde o fator tempo é relevante. Estas características justificam a adoção desta técnica estatística no contexto deste trabalho. No modelo proposto no Capítulo 4, serão utilizados os dados anteriores da própria variável dependente para efetuar a predição de valores futuros.

2.4 Considerações sobre o capítulo

A computação ubíqua forneceu os alicerces sobre os quais a saúde ubíqua consolidou-se, tornando-se um importante ramo de pesquisas na área. Em decorrência disso, os sensores que permitem o monitoramento de sinais vitais evoluíram de forma a tornar possível a verificação em tempo real do estado de saúde de pacientes. Assim, o uso de escores de alerta precoce, técnica que atribui pontos a medições de sinais fisiológicos de forma a detectar situações de deterioração, bem como a regressão linear, técnica de predição que pode antecipar a evolução de medições futuras, podem ser viabilizadas e se tornar importantes aliadas aos sistemas de saúde. Um dos elementos diretamente beneficiados podem ser os times de resposta

rápida. Estas equipes, presentes nos hospitais e centros de saúde, possuem a missão de prestar assistência imediata a pacientes que não estão em unidades de tratamento intensivo.

Este capítulo demonstrou as bases teóricas onde o modelo proposto está alicerçado, relacionando os conceitos de computação e saúde ubíqua, bem como dos times de resposta rápida e escores de alerta precoce e a sua importância na predição da deterioração do estado clínico dos pacientes com o uso da regressão linear. No próximo capítulo serão analisados os trabalhos relacionados e uma comparação entre estes e o modelo proposto, de forma a identificar suas virtudes, carências e lacunas de pesquisa.

3 TRABALHOS RELACIONADOS

Serão apresentados, neste capítulo, cinco trabalhos relacionados com o tema da análise das condições de saúde de pacientes e a necessária predição da degradação de seus sinais vitais. Para tanto, foi realizada uma revisão sistemática da literatura, de acordo com os preceitos de Kitchenham (2004). Optou-se pelo uso da ferramenta de busca Google Acadêmico, em virtude do alto espectro de relevância de seus resultados, que são baseados em periódicos, bibliotecas e outras fontes reconhecidas cientificamente.

Para fins da busca efetuada, foram considerados artigos publicados entre 2013 e 2016 na língua inglesa. Os termos utilizados para a busca foram: *"rapid response team" AND (healthcare OR "health care") AND ("collapse" OR "damage" OR "disease" OR "deterioration") AND ("prediction" OR "predict") AND ("algorithm" OR "techniques") AND (method OR methodology OR approach OR framework OR process OR model) AND (design OR implementation OR development OR creation)*.

Os resultados da busca foram filtrados em três etapas. Na etapa 1, a seleção foi efetuada através da leitura dos resumos dos artigos. Aqui, foram encontrados 83 documentos significativos. Na etapa 2 buscou-se a identificação de artigos que apresentavam técnicas e modelos de predição consideradas adequadas para o escopo da dissertação, através da leitura da introdução, dos resultados e da conclusão. Avançaram, nesta etapa, 13 trabalhos. Na última etapa, foi efetuada a leitura e análise aprofundada dos artigos mais relevantes selecionados na etapa 2, de acordo com os critérios preestabelecidos, resultando nos cinco elencados neste capítulo e que serão apresentados detalhadamente nas próximas seções.

3.1 Artigo 1 – “*A Clinical Deterioration Prediction Tool for Internal Medicine Patients*”

Kirkland et al. (2013) propõem o desenvolvimento de uma ferramenta para predição da deterioração clínica de pacientes não monitorados durante seu tempo de permanência em um hospital, utilizando, para tanto, variáveis procedentes de análise de regressão. As variáveis inicialmente utilizadas no estudo foram pressão sistólica, diastólica e pressão arterial média (que é calculada através da soma da pressão sistólica com o dobro da pressão diastólica, dividida por três), frequência cardíaca, frequência respiratória, temperatura, saturação de oxigênio arterial por oximetria de pulso (SaO₂), índice de choque hipovolêmico (choque hemorrágico, que é determinado pela frequência cardíaca dividida pela pressão sistólica), Escala de Braden (referente a alterações na integridade da pele em virtude de úlceras ou escaras) e Modelo de Hendrich II de Risco de Queda, para prevenção de queda de pacientes (HENDRICH, 2007).

Para eliminar erros de entrada de dados, cada variável foi limitada em uma faixa ampla, mas clinicamente relevante. Sucintamente, uma análise de regressão multivariada foi efetuada para determinar variáveis clínicas estatisticamente associadas com deterioração de pacientes. Utilizando as variáveis citadas e o resultado dos tratamentos de 1882 pacientes conhecidos, um conjunto de dados temporais foi desenvolvido de forma a permitir a busca por um evento clínico severo futuro. Os prazos foram divididos em 2 a 12 horas, 12 a 24 horas ou 24 a 48 horas de antecipação a cada evento. Após, a ferramenta foi validada utilizando um grupo composto por 1946 pacientes.

A análise final de regressão multivariada demonstrou que as variáveis Escala de Braden, frequência respiratória, saturação de oxigênio arterial e índice de choque hipovolêmico foram associadas de forma independente aos eventos. Frequência cardíaca e temperatura foram

eliminadas do modelo final, apesar da primeira já estar representada através do índice de choque hipovolêmico. Utilizando os coeficientes de regressão da análise final, o escore de risco de deterioração clínica foi calculado através da fórmula abaixo (KIRKLAND et al., 2013).

$$score = -0,5238 + (0,8639 \times ICH) + (-0,0998 \times EB) + (0,0814 \times FR) + (-0,0275 \times SaO_2)$$

Onde:


- ICH = índice de choque hipovolêmico
- EB = Escala de Braden
- FR = frequência respiratória
- SaO₂ = saturação de oxigênio arterial

A probabilidade *P* de ocorrência de eventos nas 2 a 12 horas subsequentes foi calculada a partir de cada escore de risco, utilizando a equação exibida abaixo (KIRKLAND et al., 2013).

$$P = \frac{e^{score}}{(1 + e^{score})}$$

A Figura 3 mostra a curva de característica de operação do receptor (curva ROC) do grupo de validação. A área sob a curva de 0,71 (0,68-0,74) indica conformidade da ferramenta com eventos reais, identificando corretamente pacientes com risco de deterioração clínica dentro das próximas 2 a 12 horas.

Figura 3. Curva de característica de operação do receptor do grupo de validação.



Fonte: Kirkland et al. (2013)

3.2 Artigo 2 – “*Improving Situation Awareness to Reduce Unrecognized Clinical Deterioration and Serious Safety Events*”

Brady et al. (2013) apresentam um sistema que busca identificar e mitigar riscos de colapsos de pacientes utilizando princípios de organizações de alta confiabilidade, como os empregados em usinas nucleares e empresas de aviação comercial. Estas organizações lidam com riscos constantes e mantêm recordes de segurança exemplares.

Além disso, os autores acreditam que aprimorar a ciência de contexto do estado clínico dos pacientes leva a um melhor reconhecimento da deterioração precoce e é essencial para reduzir as falhas no salvamento em eventos ocorridos fora da UTI (unidade de terapia intensivo), uma situação associada com uma mortalidade de 50% a 67%. Segundo os autores, a ciência de contexto existe em três níveis e é definida como a percepção de elementos no ambiente dentro de um determinado tempo e espaço, a compreensão do seu significado e a projeção de sua condição em um futuro próximo.

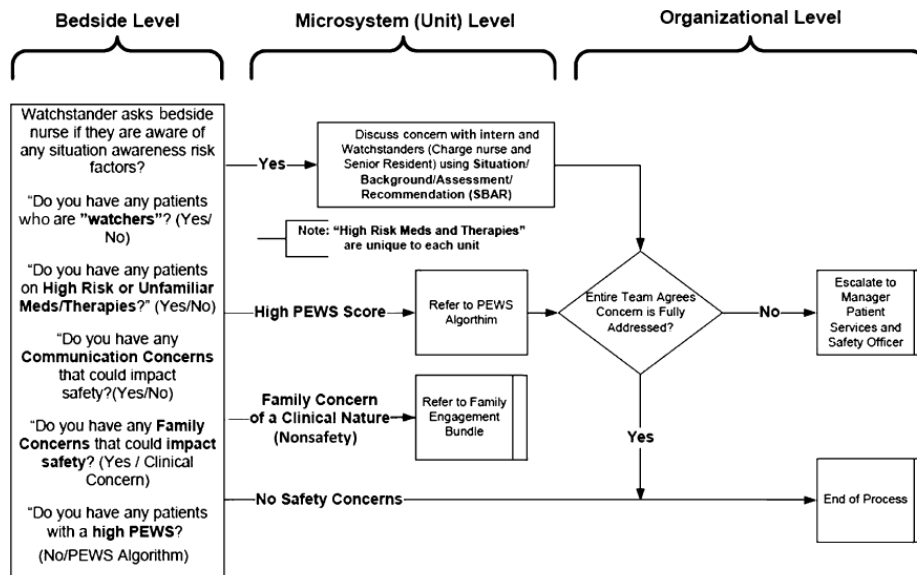
Eventos de falha de ciência de contexto não reconhecidas (UNSAFE) foram definidos como sendo a transferência de pacientes da unidade de cuidados intensivos para a unidade de terapia intensiva, onde o paciente recebeu intubação traqueal, medicamentos vasoativos para o suporte hemodinâmico, ou três ou mais bolsas de fluidos nos primeiros 60 minutos de cuidados na UTI ou antes da chegada na UTI. Os autores julgavam que esses incidentes representavam transferências potencialmente atrasadas, precursoras de eventos adversos sérios, definidos como um dano grave ou morte depois de variação da prática clínica.

Os autores conduziram o estudo em um hospital universitário pediátrico de Cincinnati, Ohio. Em 2006, a organização passou a buscar a redução dos índices de eventos adversos sérios e em 2007 a entidade passou a usar uma versão modificada do escore de alerta precoce pediátrico (PEWS).

Antes de iniciar os testes relacionados às mudanças propostas, dois pesquisadores analisaram os eventos adversos sérios mais recentes e as transferências para a UTI. Cinco fatores de risco foram associados com cada evento: familiares, terapias de alto risco, presença de alto escore de alerta precoce, problemas intestinais e de comunicação. Usando o modelo como base para melhorias, uma intervenção foi desenvolvida e testada para identificar com segurança e de forma proativa o risco de deterioração do estado clínico dos pacientes, bem como para mitigar este risco. A realização de conferências (três vezes por dia) foi adicionada às rotinas dos profissionais para assegurar que os riscos foram escalados e resolvidos. Após este passo, um plano robusto e explícito para pacientes em risco foi desenvolvido e divulgado. O artigo descreve cada uma das etapas citadas.

A Figura 4 descreve o algoritmo utilizado. No retângulo à esquerda são exibidos os critérios de entrada e, no restante da figura, é exibido o fluxograma adotado no desenvolvimento do algoritmo de ciência ao contexto.

Figura 4. Algoritmo de ciência ao contexto utilizado no estudo.



Fonte: Brady et al. (2013)

Após a intervenção, as taxas de transferência para a UTI em virtude de eventos de falha de ciência de contexto não reconhecidas (por 10000 pacientes que não estavam em UTI) reduziu de forma significativa de 4,4 para 2,4 durante o período do estudo. Os dias entre eventos adversos sérios também aumentaram de forma significativa. Assim, os autores comprovaram que um sistema confiável para identificar, mitigar e escalar riscos foram associados a uma redução de cerca de 50% de transferências para a UTI em virtude de eventos de falha de ciência de contexto não reconhecidas e de eventos adversos sérios.

3.3 Artigo 3 – “Monitoring Vital Signs: Development of a Modified Early Warning Score (MEWS) System for General Wards in a Developing Country”

O trabalho de Kyriacos et al. (2014) procura desenvolver e validar, por consenso entre especialistas da área de saúde, a construção e o conteúdo de uma tabela de observações para enfermeiros, incorporando um escore de alerta precoce modificado (MEWS) para o monitoramento de pacientes em um hospital público na África do Sul.

Os autores promoveram cinco rodadas de consenso, com uso das técnicas de processo Delphi (BROWN, 1968) e de grupo nominal, com uma abordagem multidisciplinar, de forma a criar um novo MEWS a partir de um MEWS do Reino Unido e a desenvolver um protótipo de uma tabela de observações para ser incorporada a este. O estudo foi conduzido durante quatro meses de 2009 em um hospital público universitário de 867 leitos na Cidade do Cabo. Participaram das rodadas de consenso um anestesista, um médico de emergência, dois enfermeiros de cuidados críticos e oito enfermeiros com experiência em monitoramento de leitos. O artigo descreve toda a metodologia empregada nas rodadas de consenso, que resultaram em um MEWS com sete parâmetros fisiológicos (frequência respiratória, frequência cardíaca, pressão arterial sistólica, temperatura, nível de consciência, saturação de oxigênio – SaO₂ e nível da saída de urina) e em uma tabela de observações.

Foi também definido um sistema de pontuação e um algoritmo de relato das condições dos pacientes. Para cada parâmetro fisiológico, foi definida uma faixa de limites (*thresholds*). Efetuada a leitura do parâmetro, esta é comparada com a condição normal (nível 0) e descrita na planilha. Níveis de 1 a 3 possuem cores diferentes, indicando a magnitude do desvio em relação a gama normal (cores cinza, amarelo e vermelho), para cada lado (abaixo ou acima do *threshold* definido). O algoritmo possuía regras de decisão para determinar o nível de urgência. As regras eram: 0 = sem ação; 1 = verificar novamente depois de 30 minutos e reportar se não houver melhora; 2 = checar após 5 minutos e reportar imediatamente se não houver melhora; 3 = crítica - informar imediatamente. A Figura 5 mostra o MEWS e a tabela de observações desenvolvidos, bem como os limites e as regras de decisão do algoritmo.

Figura 5. MEWS e tabela de observações desenvolvidos.

REPORTING ALGORITHM FOR SINGLE AND TOTAL SCORE		MEWS		CAPE TOWN WARD MODIFIED EARLY WARNING SCORE (MEWS) OBSERVATION CHART																		
				DATE	TIME																	
0 Nil No action required	1 Recheck after 30 mins back & report if no improvement	2 Check after 5 mins report immediately if no improvement	3 Critical	RESPIRATORY RATE		≥30	3															
				Write full value	21-29	2																
						15-20	1															
						12-14	0															
						10-11	1															
						8-9	2															
						<8	3															
					HEART RATE		≥130	3														
					Write full value	111-129	2															
						101-110	1															
						80-100	0															
						61-59	1															
						40-50	2															
						<40	3															
					O ₂ Saturation %		95+	0														
						90-94	1															
						85-89	2															
						<85	3															
					Inspired O ₂		%															
					SYSTOLIC BP		>180	3														
					Write full value	170-179	2															
						150-169	1															
						101-149	0															
						81-100	1															
						71-80	2															
						<70	3															
					Write full DIASTOLIC BP value																	
					Temperature °C		>39.6	3														
					Write full value	38.6-39.5	2															
						37.8-38.5	1															
						36-37.7	0															
						35.1-35.9	1															
						34-35	2															
						<34	3															
					PERCUSSED - respiratory refil <3 sec																	
					SKIN COLOUR		Pale/Cyanotic															
					PAIN		Severe	3														
							Moderate	2														
							Mild	1														
								0														
					PAIN MEDICATION		Yes/No															
					Sweating		Yes/No															
					Respiratory effort		Yes/No															
					Other																	
					Pulse pulses		Yes/No															
					Blood glucose																	
					Finger pulse ox																	
					NEUROLOGICAL STATUS																	
					Unresponsive (U)		(GCS <8)	3														
					Reaching to pain (P)/Confused		(GCS 13-8)	2														
					Reaching to voice (V)		(GCS 14)	1														
					Alert (A)		(GCS 15)	0														
					Pupil: Right		Size															
							Reaction															
					Left		Size															
							Reaction															
					IV THERAPY		Yes/No															
					URINE OUTPUT																	
					C=Catheter		<20ml/hr	3														
							≤30ml/hr	2														
							≤50ml/hr	1														
					(if normally anuric)		60ml/hr	0														
							<300ml/hr for 2 hrs	3														
					Looks unwell		Yes/No															
					TOTAL MEWS																	
					SIGNATURE																	

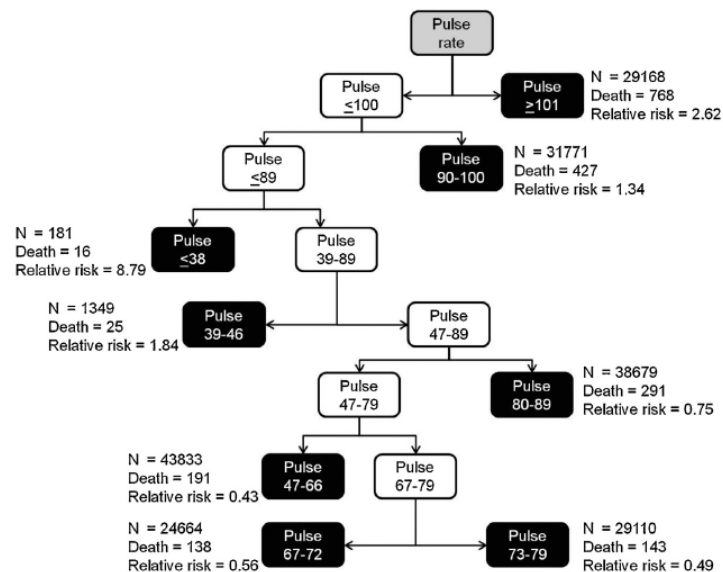
A tabela permite o preenchimento dos valores medidos de uma série de sinais vitais. Dependendo da medição, este sinal fisiológico ganha um escore (linhas vermelhas, amarelas e cinzas), de acordo com o quadro existente no canto superior esquerdo da tabela. Ao final, este escore é totalizado. Ocorrendo escores do tipo *critical*, o atendimento é escalonado para o próximo nível.

3.4 Artigo 4 – “Decision-tree early warning scores (DTEWS) validates the design of the National Early Warning Scores”

O objetivo do trabalho de Badriyah et al. (2013) é comparar o desempenho de um escore de alerta precoce nacional (NEWS), gerado por humanos e otimizado por tentativa e erro, com um escore de alerta precoce baseado em árvore de decisão (DTEWS), gerado totalmente por meios computacionais. Foi utilizada a análise da árvore de decisão para construir o DTEWS a partir de um banco de dados com 198.755 conjuntos de sinais vitais observados a partir de 35.585 admissões médicas. Os autores avaliaram a habilidade do DTEWS de discriminar pacientes com risco de parada cardíaca, admissão imprevista em UTI ou morte, cada um dentro de 24 horas a partir de uma dada observação de sinais vitais. Foram comparadas as performances de DTEWS e NEWS utilizando a área sob a curva característica de operação do receptor (curva ROC), tal como no primeiro artigo estudado.

Os autores utilizaram a função *classregtree* do software MATLAB¹ para gerar um DTEWS a partir da base de dados de sinais vitais. A análise de árvore de decisão é uma técnica de classificação de mineração de dados para a construção de árvores de decisão através da divisão recursiva de conjuntos de dados em grupos homogêneos. A Figura 6 demonstra um exemplo de árvore de decisão e nodos obtidos pela frequência do pulso. O retângulo cinza descreve o sinal fisiológico analisado; os retângulos pretos simbolizam as análises efetuadas em determinados nodos da árvore de decisão, demonstrando os riscos relativos.

Figura 6. Exemplo de árvore de decisão e nodos obtidos pela frequência do pulso.

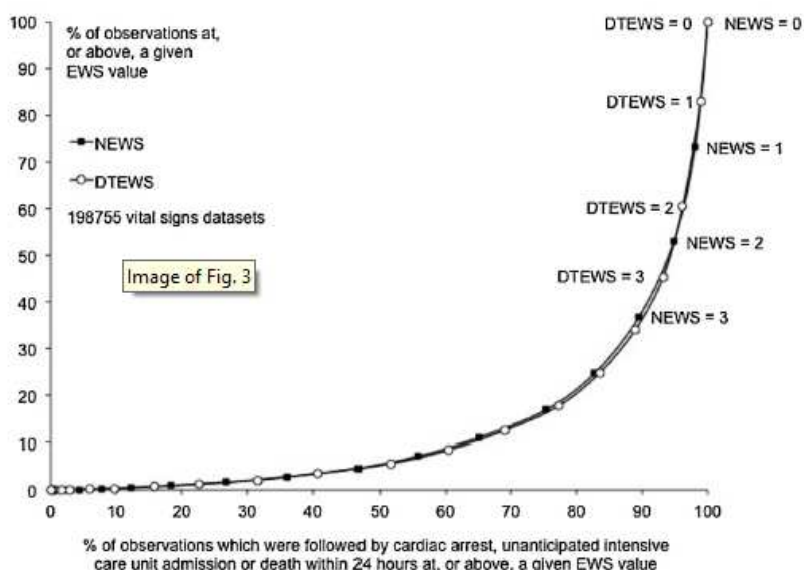


Fonte: Badriyah et al. (2013)

¹ <http://www.mathworks.com/products/matlab>

Os estudos comprovaram que as estruturas DTEWS e NEWS eram muito similares. A área sob a curva ROC (com intervalo de confiança de 95%) para parada cardíaca, admissão imprevista em UTI, morte ou qualquer outro tipo de resultado, no intervalo de 24 horas, foram 0,708 (0,669–0,747), 0,862 (0,852–0,872), 0,899 (0,892–0,907) e 0,877 (0,870–0,883), respectivamente. Os valores NEWS foram 0,722 (0,685–0,759), 0,857 (0,847–0,868), 0,894 (0,887–0,902) e 0,873 (0,866–0,879) para as mesmas situações. A Figura 7 mostra as curvas de eficiência DTEWS e NEWS, que demonstram a validade do modelo aplicado.

Figura 7. Curvas de eficiência DTEWS e NEWS.



Fonte: Badriyah et al. (2013)

Os autores concluem o trabalho afirmando que a técnica de árvore de decisão valida de forma independente o padrão NEWS. A abordagem por árvore de decisão provê rapidamente um escore de alerta precoce quase idêntico ao NEWS. Os autores acreditam que a análise por árvore de decisão pode ser usada para desenvolver rapidamente modelos candidatos a escores de alerta precoce para doenças específicas.

3.5 Artigo 5 – “A Trial of a Real-Time Alert for Clinical Deterioration in Patients Hospitalized on General Medical Wards”

O artigo de Bailey et al. (2013) mostra um ensaio de predição em tempo real com pacientes em enfermarias. O estudo foi realizado no Barnes-Jewish Hospital em St. Louis, Missouri, um hospital universitário de 1250 leitos. Foram avaliadas oito enfermarias adultas de julho de 2007 até dezembro de 2011. O período de julho de 2007 a janeiro de 2010 foi usado para treinar e testar a predição e o período de janeiro a dezembro 2011 foi usado para validá-la.

O objetivo central do estudo era validar um algoritmo preditivo da piora clínica em pacientes da ala médica geral e conduzir um teste de alertas em tempo real baseados neste algoritmo. Esses alertas em tempo real foram gerados por um algoritmo projetado para prever a necessidade de transferência para UTI usando dados eletronicamente disponíveis. Os alertas eram enviados ao enfermeiro chefe da ala.

Para tanto, foi desenvolvida uma ferramenta de predição em tempo real, utilizando o particionamento recursivo da análise da árvore de regressão para identificar iminentes infecções. Essa implementação com base na ferramenta resultou em aumento de intervenções antecipadas, incluindo escalada de antibióticos, fluídos intravenosos, oxigenoterapia e diagnósticos em pacientes identificados como de risco.

Para prever a transferência para a UTI dos pacientes da enfermaria, foi utilizada a regressão logística, através de um novo framework, para analisar o fluxo de dados de cada paciente, atribuindo notas para refletir a sua probabilidade de transferência à UTI. As variáveis utilizadas pela ferramenta foram frequência respiratória, saturação de oxigênio, índice de choque hipovolêmico, pressão arterial sistólica, uso de anticoagulantes, frequência cardíaca e pressão arterial diastólica.

O algoritmo foi primeiramente implementado através do software MATLAB, utilizado para gerar o modelo com base nos dados analisados. Posteriormente, o modelo gerado foi implementado através de uma aplicação Java. Os alertas em tempo real gerados 24 horas por dia, 7 dias por semana, eram enviados ao enfermeiro chefe. Além disso, eram armazenados em um banco de dados.

Os dados resultantes desse estudo mostraram que doentes que apresentavam o limiar de alerta possuíam quase 5,3 vezes risco maior de transferência para UTI (com intervalo de confiança de 95%) do que aqueles que não satisfazem o limiar de alerta (358, de 2.353 [15,2%], contra 512 de 17.678 [2,9%]). Pacientes com alertas possuíam risco de morte 8,9 vezes maior (com intervalo de confiança de 95%) do que aqueles sem alertas (244 de 2.353 [10,4%], contra 206 de 17.678 [1,2%]). Entre os identificados pelo sistema de alerta precoce, não houve diferenças na proporção de pacientes que foram transferidos para a UTI ou que morreram no grupo de intervenção em comparação com o grupo de controle.

Os pacientes foram escolhidos por raça, sexo, idade e diagnóstico básico e todos os alertas foram reportados para os enfermeiros chefe e associados a uma chamada para o médico responsável em cuidar do paciente alertado. Entre os pacientes identificados pela ferramenta, não houve diferenças na proporção de pacientes que foram transferidos para a UTI ou que morreram no grupo de intervenção, em comparação com o grupo de controle.

Apesar de não haver diferença no tempo de permanência do grupo de intervenção em comparação com o grupo de controle, a identificação pela ferramenta de predição foi associada com uma média mais significativa deste tempo (7,01 contra 2,94 dias). Um número maior de mortes ou transferências para a UTI ocorreram no primeiro dia de hospitalização e 60% das transferências para a UTI ocorreram nos primeiros 4 dias, ao passo que mortes foram mais uniformemente distribuídas ao longo da estadia no hospital.

A conclusão que o experimento chega é de que os alertas em tempo real eram altamente precisos para prever a deterioração clínica (resultando na transferência para UTI ou morte) e foram associados com maior tempo de permanência hospitalar. No entanto, notificações ao enfermeiro chefe não resultaram em melhorias nestes resultados, isto é, os dados também mostraram que simplesmente fornecer um alerta para unidades de enfermagem com base na ferramenta de predição não geraram qualquer melhoria demonstrável na evolução dos pacientes. A Figura 8 resume os alertas e as saídas gerados pela ferramenta de predição, dividindo-os por transferências para a UTI, alertas e alertas de morte.

Figura 8. Resumo dos alertas e das saídas gerados pela ferramenta de predição.

			Sensitivity, %	Specificity, %	PPV, %	NPV, %	Positive Likelihood Ratio	Negative Likelihood Ratio
ICU Transfer Alert	Yes (N=870) 358	No (N=19,161) 1,995	41.1 (95% Ct: 37.9-44.5)	89.6 (95% Ct: 89.2-90.0)	15.2 (95% Ct: 13.8-16.7)	97.1 (95% Ct: 96.8-97.3)	3.95 (95% Ct: 3.61-4.30)	0.66 (95% Ct: 0.62-0.70)
No Alert	512	17,166						
Death Alert	Yes (N=450) 244	No (N=19,581) 2109	54.2 (95% Ct: 49.6-58.8)	89.2 (95% Ct: 88.8-89.7)	10.4 (95% Ct: 9.2-11.7)	98.8 (95% Ct: 98.7-99.0)	5.03 (95% Ct: 4.58-5.53)	0.51 (95% Ct: 0.46-0.57)
No Alert	206	17,472						

NOTE: Abbreviations: CI, confidence interval; ICU, intensive care unit; NPV, negative predictive value; PPV, positive predictive value.

Fonte: Bailey et al (2013)

3.6 Avaliação dos trabalhos relacionados

A Tabela 2 apresenta um comparativo entre os trabalhos relacionados, utilizando como parâmetros as seguintes características:

- Técnica utilizada: discrimina a técnica apresentada no trabalho para abordar a questão. Aqui são elencados os métodos estatísticos ou computacionais utilizados na pesquisa em questão;
- Variáveis utilizadas no escopo do trabalho: relaciona os itens fisiológicos utilizados no estudo e que serviram como base para a aplicação da técnica;
- Suporte computacional descrito no trabalho: informa se o trabalho descreveu o uso de algum suporte computacional para a solução do problema;
- Faz uso de ciência de situação: informa se a técnica utilizada faz uso de ciência de situação;
- Padrões utilizados: descreve os padrões utilizados no trabalho. Aqui são discriminados os padrões de escore de alerta precoce utilizados pelos autores;
- Elaboração de protótipo: informa se houve elaboração de algum protótipo do método descrito no trabalho;
- Modelo proposto se relaciona com times de resposta rápida: reporta se o modelo proposto efetua alguma interação com os times de resposta rápida.

Tabela 2. Comparativo entre os trabalhos relacionados.

Características		Trabalhos				
		Kirkland et al., 2013	Brady et al., 2013	Kyriacos et al., 2014	Badriyah et al., 2013	Bailey et al., 2013
Técnica utilizada		Escala de Braden Semi-Markov	Algoritmo de ciência de situação	Sistema de escores <i>Thresholds</i>	Árvore de decisão	Regressão logística
Variáveis utilizadas no escopo do trabalho	Pressão sistólica	Sim	Não	Sim	Sim	Sim
	Pressão diastólica	Sim	Não	Não	Sim	Sim
	Frequência cardíaca	Sim	Não	Sim	Sim	Sim
	Índice de choque hipovolêmico	Sim	Não	Não	Não	Sim
	Frequência respiratória	Sim	Não	Sim	Sim	Sim
	Frequência do pulso	Não	Não	Não	Sim	Não
	Temperatura	Sim	Não	Sim	Sim	Não
	Saturação O ₂	Sim	Não	Sim	Sim	Sim
	Nível de consciência	Não	Não	Sim	Sim	Não
	Fatores de risco	Não	Sim	Não	Não	Não
	Escala de Braden	Sim	Não	Não	Não	Não
Medição do nível de urina	Não	Não	Sim	Não	Não	
Suporte computacional descrito no trabalho		Não	Sim	Não	Sim	Sim
Faz uso de ciência de situação		Não	Sim	Não	Não	Não
Padrões utilizados		Baseado em EWS	EWS e PEWS	MEWS	NEWS e DTEWS	Atribuição de escores baseados em EWS
Elaboração de protótipo		Não	Não	Não	Não	Sim
Modelo proposto se relaciona com times de resposta rápida		Não	Não	Não	Não	Não

Fonte: elaborado pelo autor

3.6.1 Lacunas de pesquisa

Este capítulo buscou resumir e descrever pesquisas relacionadas com o objeto de pesquisa deste trabalho. Verificou-se que todos os trabalhos analisados utilizam a atribuição de escores como padrão para a predição da deterioração do estado clínico do paciente. No entanto, apenas o estudo de Kirkland et al. (2013) utiliza o padrão EWS original. Todos os demais fazem uso de aprimoramentos deste padrão, como MEWS (KYRIACOS et al., 2014), PEWS (BRADY et al., 2013) e DTEWS (BADRIYAH et al., 2013), já explanados anteriormente. Nota-se, assim, que a metodologia de atribuição de escores é um padrão consolidado, com fundamentação e resultados estatisticamente justificados em todos os trabalhos que a utilizam e deve ser utilizado pelo modelo proposto.

Basicamente todos os artigos descrevem a frequência cardíaca, a frequência respiratória, a pressão arterial e a temperatura como sinais vitais utilizados para a atribuição de escores. Além disso, o nível de consciência é utilizado em alguns trabalhos (KYRIACOS et al., 2014; BADRIYAH et al., 2013). No entanto, talvez essa métrica não possa ser determinada através de sensores, sendo necessária a atribuição manual de algum profissional da área da saúde.

Analisando os trabalhos relacionados, verifica-se que apenas o trabalho de Bailey et al. (2013) executa processamento em tempo real para a solução do problema. A maioria dos trabalhos foca em técnicas heurísticas e em análise estatística, comprovando matematicamente a eficiência das propostas apresentadas, sem, no entanto, aplicá-las em situações de onde o fator tempo é relevante. Além disso, nenhum modelo se relaciona com os times de resposta rápida. Essas lacunas devem ser preenchidas pelo modelo proposto.

Assim, a principal contribuição científica do trabalho decorre da possibilidade de, através do monitoramento dos sinais vitais com o uso de escores de alerta precoce complementados por regressão linear, prever possíveis situações de colapso dos pacientes e antecipar o acionamento dos times de resposta rápida em tempo real. Não foram encontrados, durante as pesquisas de trabalhos relacionados, modelos com essa característica. Os trabalhos relacionados demonstraram que o uso de escores de alerta precoce são uma importante ferramenta utilizada pelos profissionais de saúde para efetuar a medição do estado clínico dos pacientes, mas as totalizações geralmente ocorrem de forma manual, em formulários de papel situados junto ao prontuário dos pacientes (MORGAN et al., 1997; KYRIACOS et al., 2014). O modelo propõe a incorporação de regressão linear e a automatização da totalização da pontuação do escore de alerta precoce, de forma a possibilitar a antecipação do acionamento dos times de resposta rápida. O modelo proposto com base nas lacunas observadas será descrito no próximo capítulo.

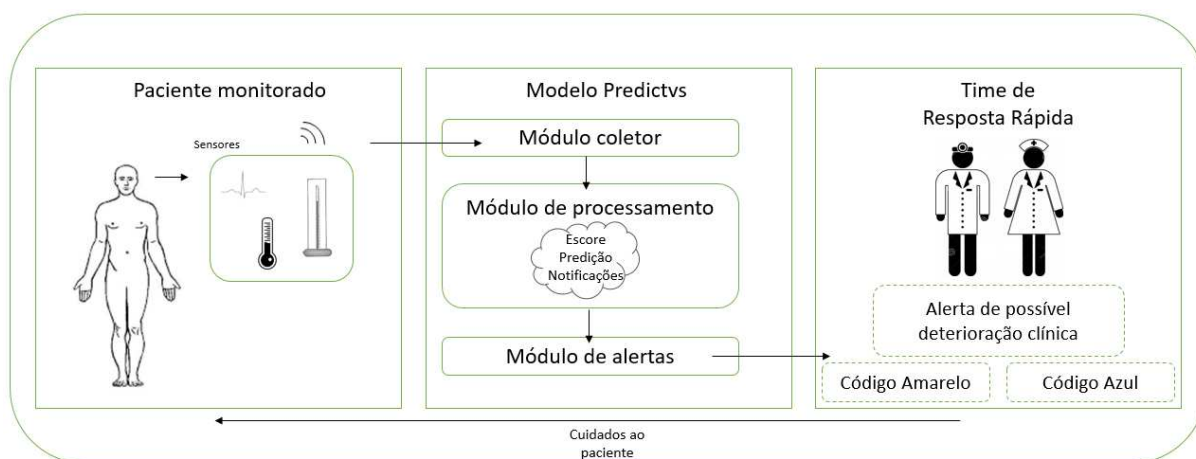
4 MODELO PROPOSTO

Este capítulo está dividido em duas seções. A primeira seção demonstrará a visão geral e a arquitetura do modelo proposto. A segunda seção detalhará o modelo Predictvs, explicando o funcionamento de seus módulos.

4.1 Visão geral

Weiser estabelece que as mais profundas tecnologias são aquelas que desaparecem, se entrelaçam na vida cotidiana até tornarem-se indistinguíveis desta (WEISER, 1991). Satyanarayanan, ao elencar os desafios dos sistemas computacionais para tornar efetiva a computação pervasiva, reforça tais conceitos e avança, estabelecendo premissas fundamentais que devem ser alcançadas por tais sistemas (SATYANARAYANAN, 2001). Por sua vez, Costa propõe um modelo de arquitetura, com suporte a *frameworks* e *middlewares*, que considera todos os desafios significativos na área de computação ubíqua (DA COSTA, 2008). Dentro deste contexto, é proposto o modelo Predictvs. Como visto no capítulo anterior, a principal lacuna que este trabalho pretende atacar refere-se à predição, em tempo real, do acionamento do Time de Resposta Rápida em virtude da deterioração do estado clínico de enfermos a partir da pontuação do escore de alerta precoce, complementado por regressão linear. Bailey et al. (2013) determinam que o tempo é um fator essencial para intervenções médicas em situações de urgência e emergência, de forma a evitar o agravamento da degradação do estado de saúde dos pacientes. Partindo dessa premissa, o modelo Predictvs foi planejado para ter uma arquitetura simples, de forma a dispendir o tempo mínimo no processamento dos sinais fisiológicos, porém eficiente, provendo as notificações e os alertas necessários e adequados para os times de resposta rápida. A Figura 9 exibe a visão geral do modelo proposto.

Figura 9. Visão geral do modelo Predictvs.



Fonte: elaborado pelo autor

O paciente, fora de ambiente de cuidados intensivos, recebe dos médicos e enfermeiros uma série de sensores para a captação de seus sinais fisiológicos. Tais sensores interagem com o modelo Predictvs, reportando as medições efetuadas através da tecnologia Bluetooth. Tais medições são validadas e processadas, de acordo com os escores de alerta precoce definidos pelos profissionais de saúde, ocorrendo a pontuação dos sinais vitais de acordo com os escores pré-determinados. Além disso, com o uso de regressão linear, ocorre a predição das medições

dos sinais vitais. Com base nestes valores, é estimado um novo escore de alerta precoce, que prevê a deterioração clínica do paciente. Assim, de acordo com as regras estabelecidas, com a pontuação atribuída e com o resultado da predição, notificações e alertas de podem ser emitidos ao time de resposta rápida. Em casos extremos, de acordo com as condições que serão expostas na próxima seção, alertas de ocorrência de Código Amarelo para urgências ou Código Azul para emergências (parada cardiorrespiratória) podem ser informados à equipe.

4.2 Arquitetura

O modelo Predictvs é composto, basicamente, por três módulos, responsáveis pela coleta, processamento e emissão de alertas ao time de resposta rápida, respectivamente. Além disso, interage com uma base escores de alerta precoce, que é alimentada pelos profissionais de saúde e com uma função que executa a regressão linear. O módulo coletor é responsável pela comunicação com os sensores dos sinais fisiológicos, recebendo as medições e requisitando novas leituras, quando demandado pelo módulo de processamento.

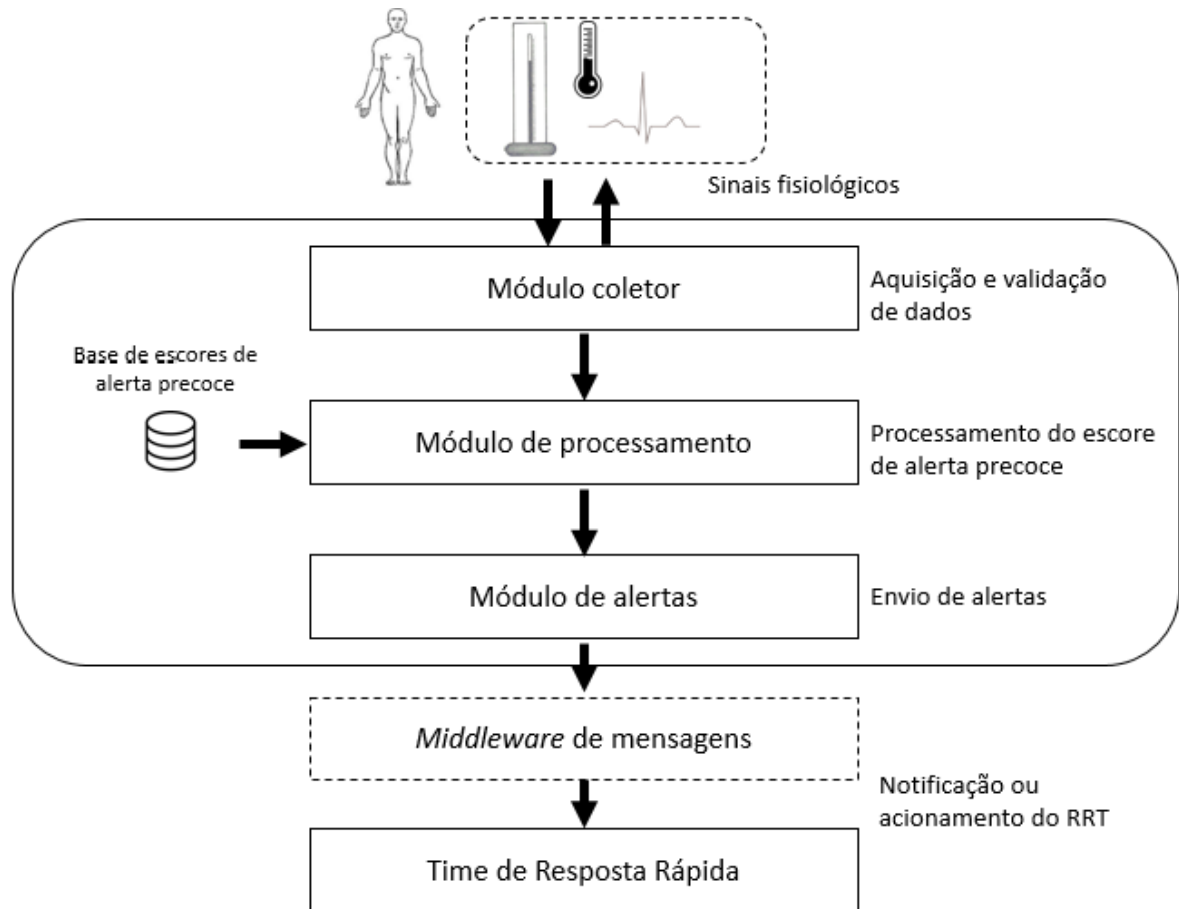
O módulo de processamento efetua a análise dos sinais fisiológicos, a pontuação do escore de alerta precoce e a predição da deterioração clínica do paciente através de regressão linear. Conforme descrito no Capítulo 2, optou-se pelo uso de regressão linear como técnica associada à predição da deterioração clínica dos pacientes por ser, em tese, um método rápido e preciso, consoante com os requisitos necessários para processamento das medições de sinais fisiológicos em tempo real.

Neste módulo ocorre a predição das medições dos sinais vitais para o próximo ciclo. Após, com base na predição destes valores, são estimados os escores de alerta precoce para a próxima etapa. Caso o resultado indique a possibilidade de ocorrência de deterioração do estado clínico do paciente, é emitida uma notificação ao Time de Resposta Rápida. O algoritmo de predição com base em regressão linear pode ser utilizado para prever as medições para mais ciclos adiante, ao invés de apenas o próximo. Seria possível, por exemplo, efetuar a predição da medição para três, cinco ou dez ciclos futuros, ampliando de segundos para minutos a antecipação das ocorrências.

Assim, segundo o escore calculado e o resultado da predição, o modelo envia as notificações e os acionamentos do time de resposta rápida para o módulo de alertas. O módulo de alertas recebe as informações do módulo de processamento e as remete ao *middleware* mensageiro, responsável por disparar as notificações e alertas para os dispositivos dos integrantes time de resposta rápida. Para tanto, os profissionais de saúde, previamente, efetuam a assinatura da fila de tópicos do sistema mensageiro, como será explanado posteriormente.

A Figura 10 exhibe a arquitetura do modelo Predictvs, exibindo seus três módulos e a interação destes com os dados advindos dos pacientes, bem como com o *middleware* de mensagens e o Time de Resposta Rápida. O módulo coletor é implementado em um computador *small single-board*, tal como o Raspberry Pi. Os módulos de processamento e de alertas, bem como o *middleware* mensageiro, são implementados em servidores e suportam recursos de alta disponibilidade.

Figura 10. Arquitetura do Modelo Predictvs.



Fonte: elaborado pelo autor

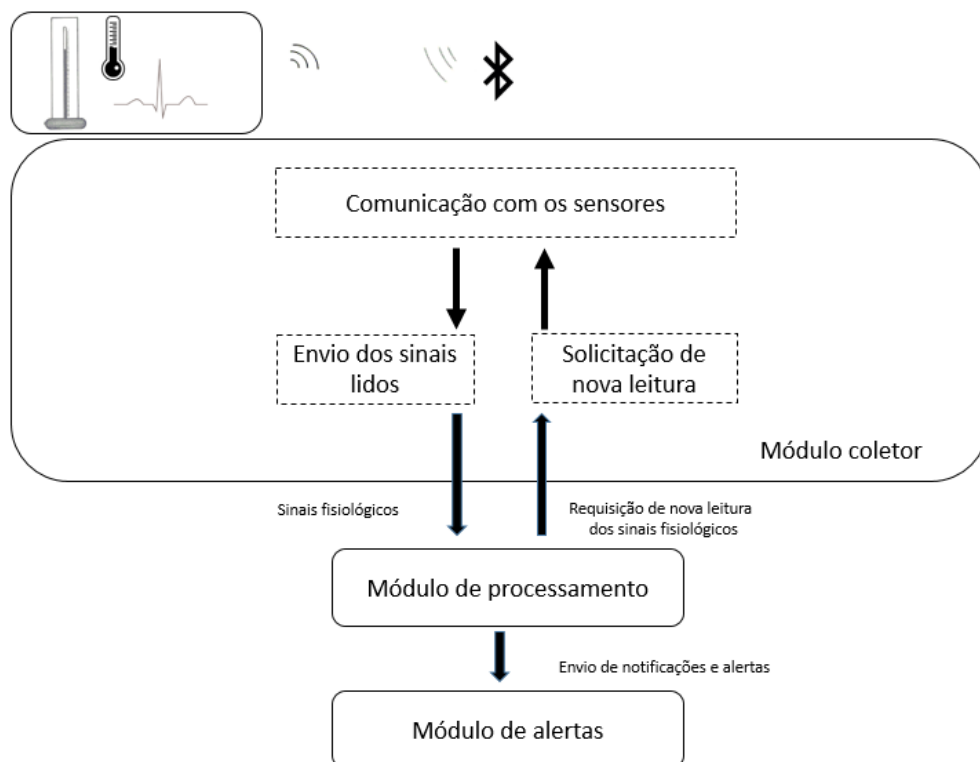
Inicialmente, o perfil do paciente deve ser informado ao sistema, que consiste basicamente em identificação, sexo e idade, bem como o tipo de escore de alerta precoce que será utilizado. O modelo permite o uso de múltiplos escores de alerta precoce, que devem ser cadastrados previamente pelo médico responsável. Com base em um perfil genérico pode ser construído um perfil personalizado. Assim, os *thresholds* dos sinais vitais presentes no escore de alerta precoce atribuído pelo médico também podem ser personalizados, de forma a refletir eventuais peculiaridades no estado clínico do paciente, permitindo uma predição mais apurada. Tal questão é importante, tendo em vista que eventuais condições clínicas preexistentes do paciente como, por exemplo, insuficiência cardíaca ou respiratória, poderão ser tratadas de forma particular. Com base nessas regras, adicionalmente, ocorre o processamento da função que executa regressão linear, de forma a também prever o próximo escore de alerta precoce.

4.2.1 Módulo coletor

Sensores acoplados aos pacientes efetuam a leitura de seus sinais fisiológicos (tais como frequência cardíaca, frequência respiratória, pressão arterial sistólica e temperatura, dentre outros) e os transmitem para um módulo coletor. Esta leitura é efetuada em frequências variadas, de acordo com o sinal fisiológico. Por exemplo, a leitura da frequência cardíaca pode ser atualizada uma vez a cada 15 segundos; já a leitura da pressão arterial sistólica pode ser efetuada uma vez a cada cinco minutos. A comunicação deve ocorrer através da tecnologia Bluetooth, versão 4.0 ou superior. A partir desta versão é oferecida a tecnologia *Bluetooth Low*

Energy (BLE), que, através do baixo consumo de energia, permite que dispositivos inteligentes operem por meses ou anos (RAWAT et al., 2014). A interação entre os sensores e o módulo coletor é feita através da função *comunicação com os sensores*. O módulo coletor pode ser implementado em um dispositivo conectado à rede local da instituição e possui a finalidade de transmitir os dados lidos ao módulo de processamento do modelo, através da função *envio dos sinais lidos*. Além disso, caso seja demandado pelo módulo de processamento, em virtude de aquisição de algum sinal fisiológico com valor discrepante, pode requisitar nova leitura aos sensores, pela função *solicitação de nova leitura*. O modelo suporta múltiplos módulos coletores, provendo escalabilidade e redundância ao sistema. A Figura 11 detalha o módulo coletor.

Figura 11. Módulo coletor.



Fonte: elaborado pelo autor

4.2.2 Módulo de processamento

O módulo de processamento é o cerne do modelo Predictvs. Da mesma forma que o módulo coletor, o modelo permite a coexistência de múltiplos módulos de processamento, trabalhando de forma a suportar a carga de sinais advindos de diversos pacientes. Neste módulo estão implementadas todas as funções e regras necessárias, relacionadas à análise preditiva, para que:

- Ocorra a correta interpretação dos sinais fisiológicos advindos do módulo coletor, inclusive descartando dados inválidos e requisitando nova leitura, se for o caso;
- Seja efetuado o processamento adequado das medições, através da pontuação do escore de alerta precoce com base nos parâmetros fornecidos pelos profissionais de saúde;

- Seja efetuada a predição da deterioração clínica do paciente, através de regressão linear;
- Quando necessário, envie ao módulo de alertas as notificações e os alertas pertinentes para o acionamento dos integrantes do Time de Resposta Rápida.

Recebendo os sinais fisiológicos do módulo coletor, o módulo de processamento, através da função de *análise da leitura efetuada*, verifica se houve alguma discrepância na medição efetuada (como, por exemplo, a detecção de um sinal nulo ou negativo). Tal situação leva ao descarte do dado e à solicitação de nova leitura. Mantendo-se a leitura irregular, uma notificação é enviada ao Time de Resposta Rápida, para que os sensores do paciente sejam verificados. Em seguida, a função *pontuacao* faz o cálculo do escore de alerta precoce dos sinais vitais lidos, com base nos parâmetros configurados pelo médico. O código da função *pontuacao*, gerada na linguagem Python², que implementa o escore de alerta precoce exibido na tabela 3, pode ser visto abaixo.

```

1. # Função puntuacao(sinal,valor)
2. # Parâmetros:
3. #  sinal - sigla do sinal fisiológico
4. #  valor - valor medido
5. # Retorno: valor tipo int contendo o escore de alerta precoce calculado
6. def puntuacao(sinal,valor):
7.     # EWS Frequência respiratória
8.     if sinal=="fr":
9.         if valor<=9:
10.            ews = 2
11.        elif valor>=10 and valor <=14:
12.            ews = 0
13.        elif valor>=15 and valor <=20:
14.            ews = 1
15.        elif valor>=21 and valor <=29:
16.            ews = 2
17.        elif valor>=30:
18.            ews = 3
19.     # EWS Saturação O2
20.     elif sinal=="sao2":
21.         if valor<85:
22.            ews = 3
23.        elif valor>=85 and valor <=89:
24.            ews = 2
25.        elif valor>=90 and valor <=92:
26.            ews = 1
27.        elif valor>=93:
28.            ews = 0
29.     # EWS Frequência cardíaca
30.     elif sinal=="fc":
31.         if valor<=40:
32.            ews = 2
33.        elif valor>=41 and valor <=50:
34.            ews = 1
35.        elif valor>=51 and valor <=100:
36.            ews = 0
37.        elif valor>=101 and valor <=110:
38.            ews = 1
39.        elif valor>=111 and valor <=129:
40.            ews = 2
41.        elif valor>=130:
42.            ews = 3

```

² <https://www.python.org/>

```

43. # EWS Pressão arterial sistólica
44. elif sinal=="pas":
45.     if valor<=70:
46.         ews = 3
47.     elif valor>=71 and valor <=80:
48.         ews = 2
49.     elif valor>=81 and valor <=100:
50.         ews = 1
51.     elif valor>=101 and valor <=199:
52.         ews = 0
53.     elif valor>=200:
54.         ews = 2
55. # EWS Temperatura
56. elif sinal=="temp":
57.     if valor<=34.9:
58.         ews = 2
59.     elif valor>=35.0 and valor<=38.4:
60.         ews = 0
61.     elif valor>=38.5:
62.         ews = 2
63. # EWS Escala de Glasgow
64. elif sinal=="glas":
65.     if valor==15:
66.         ews = 0
67.     elif valor==14:
68.         ews = 1
69.     elif valor<=13 and valor>=9:
70.         ews = 2
71.     elif valor<=8:
72.         ews = 3
73. # EWS Nível de urina
74. elif sinal=="uri":
75.     if valor<=0.5:
76.         ews = 3
77.     elif valor>0.5 and valor<=1:
78.         ews = 1
79.     elif valor>1 and valor<=3:
80.         ews = 0
81.     elif valor>=3:
82.         ews = 1
83. return ews

```

Tabela 3. Escore de alerta precoce modificado implementado na função *pontuacao*.

Sinal fisiológico/Escore	3	2	1	0	1	2	3
Frequência respiratória/min		≤ 9		10-14	15-20	21-29	≥ 30
Saturação O ₂	< 85	85-89	90-92	≥ 93			
Frequência cardíaca/min		≤ 40	41-50	51-100	101-110	111-129	≥ 130
Pressão sistólica	≤ 70	71-80	81-100	101-199		≥ 200	
Temperatura °C		≤ 35		35-38.4		≥ 38.5	
Estado neurológico Escala de Coma Glasgow				15	14	13-9	≤ 8
Urina ml/kg em 1 hora	0.5ml/kg		≤ 1 ml/kg		≥ 3 ml/kg		

Fonte: elaborado pelo autor, com base em Kyriacos et al., 2014

Escores acima de 3 pontos geram alertas do tipo *critical* contendo um Código Azul (se houve parada cardiorrespiratória) ou um Código Amarelo (se houve outro tipo de colapso), obrigando o acionamento imediato do Time de Resposta Rápida. Escores abaixo ou iguais a 3 pontos acionam a função de *predição*. Neste caso, a função recebe como parâmetro os sinais fisiológicos e efetua a regressão linear. Caso o resultado deste processamento chegue à conclusão de que há chance de ocorrência de deterioração do estado de saúde do paciente, são enviadas notificações do tipo *warning* para o Time de Resposta Rápida, indicando possível necessidade de intervenção. As notificações ou alertas, quando ocorrem, são remetidos para o módulo de alertas. O código da função *predicao*, bem como o trecho de código que faz os testes necessários e os acionamentos do Time de Resposta Rápida, também em linguagem Python, são exibidos abaixo. No caso da função *predicao*, são passados como parâmetros a série de dados já existentes e quantos ciclos futuros se deseja prever. A função retorna a predição do valor com base na regressão linear. Desta forma, por exemplo, para prever o estado futuro da frequência cardíaca do paciente, utilizando as cinco medições anteriores, a função seria chamada desta maneira:

```
fc_next = predicao(fc_pacientes[id_paciente],1,5)
```

```

1. #!/usr/bin/env python
2. import numpy as np
3. from sklearn import linear_model
4.
5. # Função predicao(sinais_fisiologicos,ciclos,limite)
6. # Parâmetros:
7. # sinais_fisiologicos - lista, delimitada por caracteres ':', contendo os valores
8. # que passarão pela regressão linear
9. # ciclos - quantidade de ciclos futuros que deve ser efetuada a predição
10. # limite - quantos sinais fisiológicos anteriores serão utilizados para efetuar RL
11. # Retorno: valor tipo float contendo o valor da predição efetuada com a RL
12. def predicao(sinais_fisiologicos,ciclos,limite):
13.     # Divide a lista passada como parâmetro para array
14.     med=sinais_fisiologicos.split(':')
15.     # Para efetuar a predição, o array deve conter no mínimo dois valores
16.     if len(med)<=limite:
17.         # Valor de retorno que indica que não há dados suficientes para efetuar RL
18.         return -1
19.     else:
20.         # Inicialização dos arrays que serão utilizados pela função de RL
21.         # Os arrays contêm a lista de valores lidos e o número do ciclo
22.         medicoes = np.array([[ ]])
23.         # Define a posição inicial para iniciar a regressão linear
24.         inicio = len(med) - limite + 1
25.         for x in range(inicio,len(med)):
26.             medicoes = np.append(medicoes,med[x]).astype(np.float)
27.         ciclo = np.array([[ ]])
28.         for x in range(inicio,len(med)):
29.             ciclo = np.append(ciclo,int(x))
30.         # Variável recebe o valor dos ciclos a prever no futuro
31.         ciclos_a_prever = x + ciclos
32.         # Cria o modelo linear
33.         regr = linear_model.LinearRegression()
34.         # O modelo é treinado com as medições efetuadas
35.         regr.fit(ciclo, medicoes)
36.         # O valor do ciclo futuro é atribuído ao array que contém ciclos a prever
37.         ciclo_pred = np.array([ciclos_a_prever])
38.
39.         # Predição é efetuada
40.         pred = regr.predict(ciclo_pred)
41.         # Retorno da predição efetuada com base na regressão linear
42.         return pred[0]

```

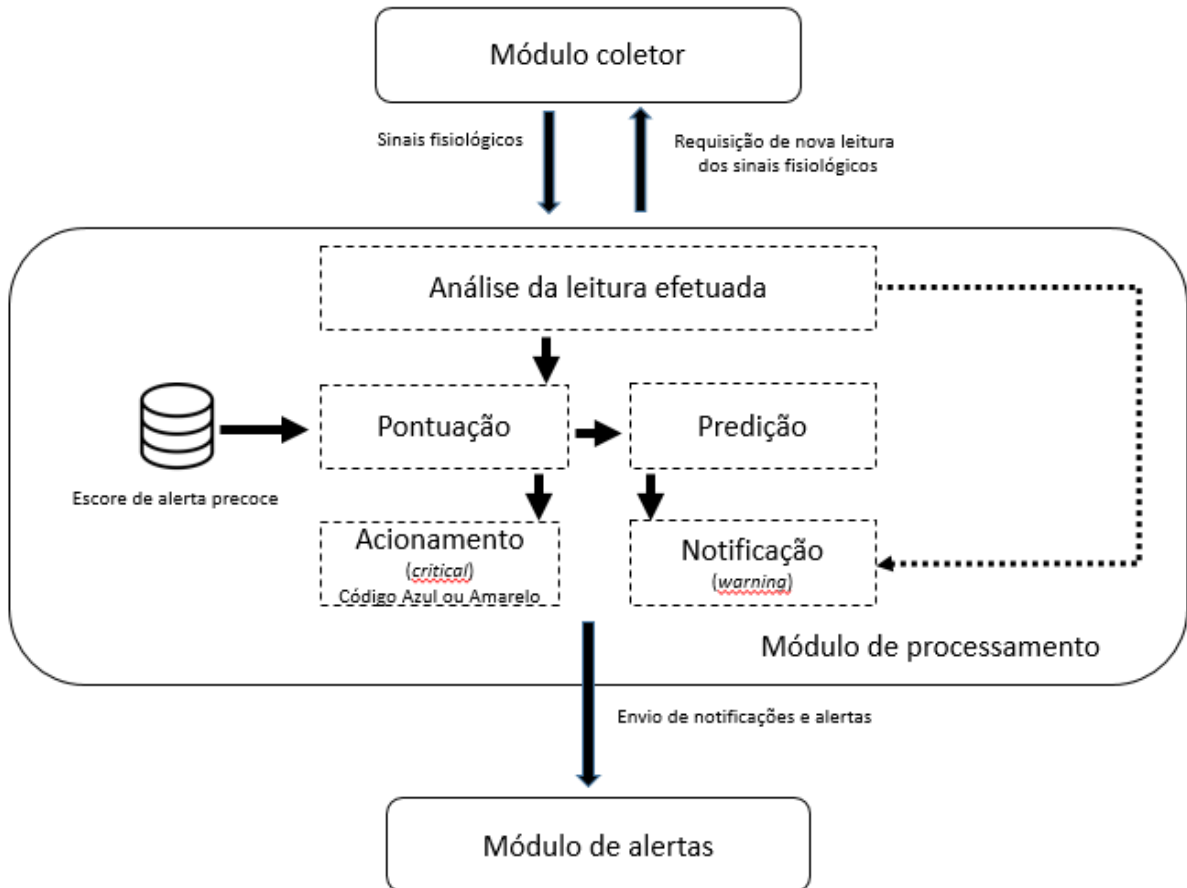
```

41.
42.
43.   ...
44.   ...
45.   ...
46.
47.
48.
49.   # Calcula MEWS do sinal fisiológico lido
50.   mews = pontuacao(sinal_fisiologico,valor)
51.   if mews>=2:
52.       # Se score for maior ou igual a 2, emite notificação
53.       alerta = "ALERTA - " + nome_sinal(sinal_fisiologico) + " - CÓDIGO "
54.       if sinal_fisiologico=="fc":
55.           # Se for alerta cardíaco, código azul
56.           cor="AZUL"
57.       else:
58.           # Caso contrário, código amarelo
59.           cor="AMARELO"
60.       print alerta
61.       # Aciona procedimento envia_alerta(paciente,alerta,valor,"critical")
62.
63.   # Acumula score de alerta precoce do paciente
64.   ews_acumulado[codigo_paciente] = ews_acumulado[codigo_paciente] + mews
65.   # Se score acumulado for maior ou igual a 3, emite alerta
66.   if ews_acumulado[codigo_paciente]>=3:
67.       print "Acionamento Time de Resposta Rápida efetuado - CRITICAL"
68.       # Aciona procedimento envia_alerta(paciente,"Acionamento Time de \
Resposta Rápida efetuado - CRITICAL",ews_acumulado[codigo_paciente],"critical")
69.   else:
70.       # Caso contrário, efetua predição (limites foram definidos com valor 5)
71.       print "MEWS igual ou inferior a 3 - efetuando predição..."
72.       pas_next = predicacao(pas_pacientes[codigo_paciente],1,limite_pas)
73.       fc_next = predicacao(fc_pacientes[codigo_paciente],1,limite_fc)
74.       fr_next = predicacao(fr_pacientes[codigo_paciente],1,limite_fr)
75.       temp_next = predicacao(temp_pacientes[codigo_paciente],1,limite_temp)
76.       if pas_next<=0 or fc_next<=0 or fr_next<=0 or temp_next<=0:
77.           # Não há dados suficientes para a predição
78.           msg = "Ainda não há dados suficientes para efetuar a predição...\
Aguardando a próxima leitura..."
79.           print msg
80.       else:
81.           # Calcula score de alerta precoce com base na regressão linear
82.           mews_previsto = pontuacao("pas",pas_next) + \
pontuacao("fc",fc_next) + pontuacao("fr",fr_next) + pontuacao("temp",temp_next)
83.           msg = "Predição efetuada. Tendência no próximo ciclo: FC: "+ \
str(fc_next)+" - PAS: "+str(pas_next)+" - FR: "+str(fr_next)+" - Temp: "+ \
str(temp_next)+" - MEWS: "+str(mews_previsto)
84.           print msg
85.           if mews_previsto>=3:
86.               print "Tendência de acionamento de Time de Resposta Rápida \
- WARNING"
87.               # Aciona procedimento envia_alerta(paciente,"Tendência de \
acionamento de Time de Resposta Rápida - WARNING",mews_previsto,"warning")
88.
89.   ...
90.   ...
91.   ...

```

A Figura 12 exhibe o detalhamento do módulo de processamento, contendo a interação entre seus diversos componentes.

Figura 12. Módulo de processamento.



Fonte: elaborado pelo autor

Resumindo, o fluxo do módulo de processamento é o seguinte:

- Ocorre o recebimento dos dados obtidos pelos sensores e enviados ao módulo coletor. Estes dados consistem na descrição do sinal fisiológico e no valor da medição efetuada, entre outros;
- É efetuada a análise dos dados recebidos pela função de *análise da leitura efetuada*. Caso os dados sejam inválidos, ocorre solicitação de nova leitura dos sinais fisiológicos. Persistindo a discrepância, é enviada notificação ao Time de Resposta Rápida para verificação;
- Estando os dados consistentes, a função de *pontuação* efetua o cálculo de score de alerta precoce. Para tanto, utiliza scores de alerta precoce fornecidos pelos profissionais de saúde. Caso o score obtido seja superior a 3 pontos, o Time de Resposta Rápida é imediatamente acionado com alertas do tipo *critical* contendo um Código Azul (se houve parada cardiorrespiratória) ou um Código Amarelo (se houve outro tipo de colapso). Este é um componente **reativo** do modelo;
- Havendo scores abaixo ou igual a 3 pontos, ocorre o encaminhamento dos sinais fisiológicos para a função de *predição*. Aqui ocorre a predição com base em regressão linear. Se o resultado indicar chances de ocorrência de deterioração do estado de saúde do paciente, são enviadas notificações do tipo *warning* para o Time

de Resposta Rápida, indicando possível necessidade de intervenção. Este é um componente **proativo** do modelo;

- Surgindo necessidade de notificação ou alerta ao Time de Resposta Rápida, tais ocorrências são encaminhadas ao módulo de alertas.

A regressão linear é executada utilizando os dados históricos da própria variável de interesse (que são os sinais fisiológicos dos pacientes, tais como frequência cardíaca, frequência respiratória, temperatura, pressão arterial média e saturação de oxigênio arterial, dentre outros) com relação ao tempo (intervalo entre os ciclos de medição), de forma a efetuar a predição dos próximos valores. A classe *LinearRegression* da biblioteca Python *scikit-learn*³ foi utilizada no contexto deste trabalho para efetuar a regressão linear. Por padrão, essa classe utiliza o método dos mínimos quadrados para efetuar o melhor ajuste do conjunto de dados, tentando minimizar os resíduos através da soma dos quadrados das diferenças entre o valor estimado e os dados observados. A interpretação dos dados obtidos é efetuada comparando as curvas do gráfico dos dados reais e dos dados resultantes da predição e analisando as médias e desvios-padrão entre os dois conjuntos de dados.

O módulo de processamento requer algumas informações relacionadas ao paciente. Basicamente devem ser fornecidos a sua identificação e o perfil de escore de alerta precoce a ser utilizado. O modelo é extremamente customizável. Além do escore de alerta precoce ser adaptável, permitindo a criação e utilização de múltiplos escores de alerta precoce modificados (MEWS), os profissionais de saúde podem atribuir os *thresholds* que julgarem apropriados em cada item do escore, levando em conta, por exemplo, prévio histórico médico do paciente. O médico responsável pode, ainda, definir os limites de dados anteriores que serão utilizados na regressão linear, personalizando-os de acordo com cada sinal fisiológico.

Cabe ressaltar que a existência de um componente reativo e um componente proativo no modelo busca unir o melhor de dois mundos. Caso o paciente subitamente tenha um colapso, o elemento reativo trata esta condição de forma imediata, de forma a alertar celeremente o Time de Resposta Rápida. Por outro lado, o elemento proativo busca antecipar eventuais ocorrências, detectando a possibilidade de deterioração do estado clínico do paciente e notificando a equipe. Por este motivo, a análise reativa ocorre antes da predição: caso o paciente já esteja com condições clínicas degradadas, o acionamento do Time de Resposta Rápida é instantâneo.

4.2.3 Módulo de alertas

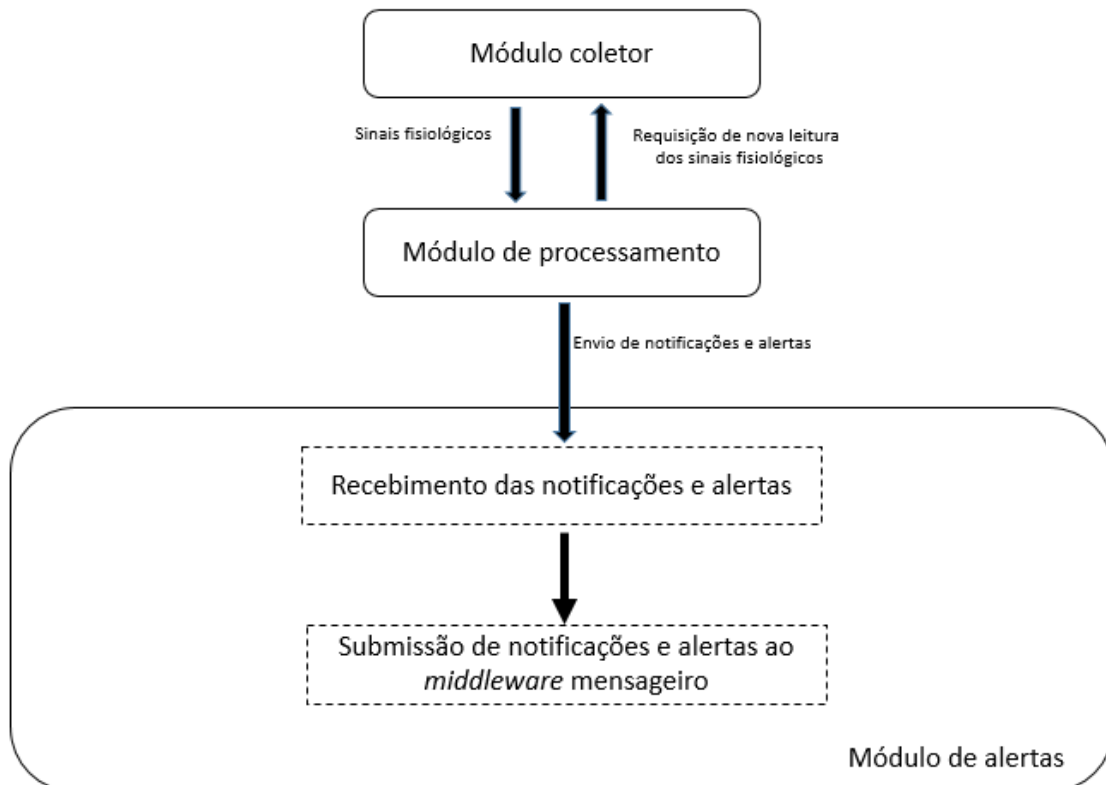
O módulo de alertas é a interface entre o modelo Predictvts, o *middleware* mensageiro e os integrantes dos times de resposta rápida. Seu papel consiste em receber as notificações e os alertas do módulo de processamento e encaminhá-las ao sistema mensageiro. O modelo permite a existência de diversos módulos de alertas no ambiente e a possibilidade de interação destes com múltiplos sistemas mensageiros. Tal característica propicia a viabilidade de comunicação com os mais variados tipos de dispositivos que possam notificar e alertar os profissionais de saúde, tais como avisos sonoros via sistema de som do hospital, painéis informativos, televisores, *smartwatches*, *smartphones* e *tablets* (nestes três últimos, com a possibilidade do recebimento de e-mails e mensagens).

O módulo de alertas obtém as sinalizações do módulo de processamento através da função *recebimento de notificações e alertas*. A seguir, remete-os para o *middleware*

³ <http://scikit-learn.org/stable/index.html>

mensageiro através do papel *submissão de mensagens e alertas ao middleware mensageiro*. De forma sucinta, o modelo prevê que os profissionais de saúde devem assinar uma fila de tópicos de mensagens para receber as notificações e os alertas do Predictvs, aproveitando as características inerentes do desacoplamento temporal e do padrão *publish-subscribe*. Assim, o módulo de alertas efetua a transmissão da mensagem e, de acordo com as condições do paciente, os integrantes do time de resposta rápida recebem as notificações e os acionamentos. A Figura 13 mostra o detalhamento deste módulo.

Figura 13. Módulo de alertas.



Fonte: elaborado pelo autor

4.3 Considerações sobre o capítulo

Este capítulo detalhou o modelo proposto. Primeiramente foi apresentada uma visão geral do modelo, demonstrando a relação dos dados advindos dos sensores dos pacientes com os acionamentos do Time de Resposta Rápida. A seguir, a arquitetura dos três módulos presentes no modelo foi esmiuçada. O módulo coletor efetua a comunicação das medições de sinais fisiológicos ao módulo de processamento. O módulo de processamento possui diversas funções relevantes dentro do modelo: análise dos sinais lidos para que, em casos de discrepâncias, solicite nova leitura ou dispare um alerta à equipe para verificação dos sensores do paciente; pontuação do escore de alerta precoce, com base nos parâmetros fornecidos pelos médicos e enfermeiros; predição da deterioração clínica do paciente, com o uso de regressão linear; envio de alertas e notificações ao módulo de alertas. O módulo de alertas é o conector entre o módulo de processamento, o *middleware* mensageiro e os integrantes do Time de Resposta Rápida. Este módulo recebe as notificações e alertas do módulo de processamento e as encaminha ao sistema mensageiro.

O próximo capítulo descreve a metodologia do trabalho efetuado, demonstrando os elementos de implementação de um protótipo e as estratégias adotadas para a avaliação do modelo.

5 IMPLEMENTAÇÃO

Este capítulo foi dividido em duas seções. A primeira seção detalhará o protótipo desenvolvido, explicando o funcionamento de seus módulos. A segunda seção demonstrará o cenário adotado para a avaliação preliminar do modelo proposto.

5.1 Protótipo Predictvs

Para permitir a avaliação do modelo, um protótipo foi desenvolvido. O *back-end* do protótipo gerado foi codificado em Python utilizando, fundamentalmente, as bibliotecas *pika*⁴, *scikit-learn*, *numpy*⁵, *tg*⁶ e *PyTg*⁷ e o *front-end* consiste em uma interface web desenvolvida em JavaScript⁸. O *middleware* RabbitMQ⁹ foi selecionado para ser o *message broker* da implementação, com o uso de sua fila de tópicos, tendo em vista suas características de robustez, alta disponibilidade e tolerância a falhas (ROSTANSKI et al., 2014). O uso de fila de tópicos propicia dinamismo ao módulo de alertas, pois em tempo real pode-se selecionar qual paciente ou qual tipo de alerta se deseja monitorar. Assim, caso a unidade de saúde possua subdivisões em seu Time de Resposta Rápida, é possível que determinados integrantes recebam notificações e alertas de determinados pacientes.

5.1.1 Módulo coletor

O módulo coletor consiste em um dispositivo que recebe os dados dos múltiplos sensores acoplados aos pacientes e os transmite ao módulo de processamento. Na implementação deste protótipo, foram utilizados dois dispositivos Raspberry Pi 2, modelo B versão 1.1, com sistema operacional Raspbian para esta finalidade. A opção por este dispositivo é justificada por sua alta performance, por seu baixo custo, por ser um dos menores computadores disponíveis no mercado e por sua aplicação na área da saúde (BANERJEE et al., 2013).

Para fins de avaliar o protótipo, foram executadas sucessivas simulações de envio de dados de pacientes. Para tanto, foi elaborado um conjunto de dados que corresponde a 100 medições de sinais fisiológicos (relacionados à paciente hipotética Júlia) e, adicionalmente, em outro conjunto de simulações, foram utilizados dados reais provenientes de um *dataset* público que será detalhado adiante. Estes conjuntos de dados possuíam mensurações de frequência cardíaca, frequência respiratória, pressão arterial sistólica, temperatura e saturação de oxigênio arterial. Os dados foram injetados em um arquivo separado por delimitadores e submetidos, pelo módulo coletor, através de uma fila de mensagens do *middleware* RabbitMQ, utilizando o protocolo AMQP (*Advanced Message Queuing Protocol*), ao módulo de processamento. O conjunto de dados utilizado nas simulações encontra-se discriminado no Apêndice A.

⁴ <https://pypi.python.org/pypi/pika>

⁵ <http://www.numpy.org>

⁶ <https://github.com/vysheng/tg>

⁷ <https://github.com/luckydonald/pytg>

⁸ <https://www.javascript.com>

⁹ <http://www.rabbitmq.com>

5.1.2 Módulo de processamento

O módulo de processamento recebe os sinais vitais enviados pelo módulo coletor através do middleware RabbitMQ. Como os dados recebidos são provenientes de um arquivo separado por delimitadores, ocorre a divisão dos dados recebidos em variáveis apropriadas, para que seja iniciado o processamento da medição efetuada. Cabe ressaltar, por tratar-se de protótipo em desenvolvimento, que não há, neste momento, qualquer interação com banco de dados e todos os dados são armazenados e tratados em memória RAM.

Após o recebimento dos dados, a função *analise_da_leitura_efetuada* é acionada. Neste momento, tendo em vista que se trata de uma simulação e esta função não é relevante para a validação do modelo, é verificado apenas se o valor do sinal medido é diferente de zero. Em seguida, a função *pontuacao* efetua a atribuição de alerta precoce ao valor mensurado. O protótipo desenvolvido implementa o escore de alerta precoce modificado (MEWS) descrito na Tabela 4.

Tabela 4. Escore de alerta precoce modificado implementado.

Sinal fisiológico/Escore	3	2	1	0	1	2	3
Frequência respiratória/min		≤ 9		10-14	15-20	21-29	≥ 30
Saturação O ₂	< 85	85-89	90-92	≥ 93			
Frequência cardíaca/min		≤ 40	41-50	51-100	101-110	111-129	≥ 130
Pressão sistólica	≤ 70	71-80	81-100	101-199		≥ 200	
Temperatura °C		≤ 35		35-38.4		≥ 38.5	
Estado neurológico Escala de Coma Glasgow				15	14	13-9	≤ 8
Urina ml/kg em 1 hora	0.5ml/kg		≤ 1 ml/kg		≥ 3 ml/kg		

Fonte: elaborado pelo autor, com base em Kyriacos et al., 2014

Caso alguma medição atinja escore maior ou igual a 2, um alerta é enviado ao Time de Resposta Rápida. Caso o sinal fisiológico medido seja a frequência cardíaca, é enviado um Código Azul; em qualquer outra situação é enviado um Código Amarelo. Além disso, o escore de cada sinal fisiológico é acumulado e, ao final de cada ciclo, é totalizado e apresentado. Caso este total seja maior ou igual a 3 pontos, um alerta do tipo *critical* é enviado ao Time de Resposta Rápida, acionando-o. Caso contrário, a função *predicao* é acionada. Esta função executa a análise de regressão linear do sinal fisiológico enviado como parâmetro.

Inicialmente, a regressão utilizava todos os valores mensurados até o momento. Como será visto na próxima seção, uma alteração nesta metodologia, utilizando menos valores previamente mensurados, propiciou resultados muito mais precisos. É efetuada a predição de cada sinal fisiológico e, com base nestes dados, também é efetuada a predição de um escore de alerta precoce futuro para o paciente. Se este escore previsto for maior ou igual a 3, um alerta do tipo *warning*, com a tendência de acionamento futuro é encaminhado ao Time de Resposta Rápida.

A Figura 14 apresenta a tela do módulo de processamento em ação, demonstrando o escore MEWS calculado a cada ciclo de leitura dos sensores, bem como as notificações e o acionamento do time de resposta rápida.

Figura 14. Execução do módulo de processamento do protótipo

```

Prompt de Comando - python processamento.py
*****
17/06/2016 20:31:40 - Paciente: 1. Julia - Sinal fisiológico: Frequência cardíaca - Medição: 97 - MENS: 0
17/06/2016 20:31:45 - Paciente: 1. Julia - Sinal fisiológico: Frequência respiratória - Medição: 11 - MENS: 0
17/06/2016 20:31:50 - Paciente: 1. Julia - Sinal fisiológico: Pressão arterial sistólica - Medição: 112 - MENS: 0
17/06/2016 20:31:55 - Paciente: 1. Julia - Sinal fisiológico: Temperatura - Medição: 37.9 - MENS: 0
MENS acumulado: 0
MENS igual ou inferior a 3 - efetuando predição...
Predição efetuada. Tendência no próximo ciclo: FC: 98.53 - PAS: 110.53 - FR: 10.0 - Temp: 37.9 - MENS: 0
*****
17/06/2016 20:32:00 - Paciente: 1. Julia - Sinal fisiológico: Frequência cardíaca - Medição: 99 - MENS: 0
17/06/2016 20:32:05 - Paciente: 1. Julia - Sinal fisiológico: Frequência respiratória - Medição: 9 - MENS: 2
ALERTA - Frequência respiratória - CÓDIGO AMARELO
17/06/2016 20:32:10 - Paciente: 1. Julia - Sinal fisiológico: Pressão arterial sistólica - Medição: 115 - MENS: 0
17/06/2016 20:32:15 - Paciente: 1. Julia - Sinal fisiológico: Temperatura - Medição: 37.9 - MENS: 0
MENS acumulado: 2
MENS igual ou inferior a 3 - efetuando predição...
Predição efetuada. Tendência no próximo ciclo: FC: 101.14 - PAS: 112.29 - FR: 8.86 - Temp: 37.9 - MENS: 3
Tendência de acionamento de Time de Resposta Rápida - WARNING
*****
17/06/2016 20:32:20 - Paciente: 1. Julia - Sinal fisiológico: Frequência cardíaca - Medição: 100 - MENS: 0
17/06/2016 20:32:25 - Paciente: 1. Julia - Sinal fisiológico: Frequência respiratória - Medição: 9 - MENS: 2
ALERTA - Frequência respiratória - CÓDIGO AMARELO
17/06/2016 20:32:30 - Paciente: 1. Julia - Sinal fisiológico: Pressão arterial sistólica - Medição: 112 - MENS: 0
17/06/2016 20:32:35 - Paciente: 1. Julia - Sinal fisiológico: Temperatura - Medição: 37.9 - MENS: 0
MENS acumulado: 2
MENS igual ou inferior a 3 - efetuando predição...
Predição efetuada. Tendência no próximo ciclo: FC: 102.96 - PAS: 111.82 - FR: 8.25 - Temp: 37.9 - MENS: 3
Tendência de acionamento de Time de Resposta Rápida - WARNING
*****
17/06/2016 20:32:40 - Paciente: 1. Julia - Sinal fisiológico: Frequência cardíaca - Medição: 101 - MENS: 1
17/06/2016 20:32:45 - Paciente: 1. Julia - Sinal fisiológico: Frequência respiratória - Medição: 9 - MENS: 2
ALERTA - Frequência respiratória - CÓDIGO AMARELO
17/06/2016 20:32:50 - Paciente: 1. Julia - Sinal fisiológico: Pressão arterial sistólica - Medição: 110 - MENS: 0
17/06/2016 20:32:55 - Paciente: 1. Julia - Sinal fisiológico: Temperatura - Medição: 37.9 - MENS: 0
MENS acumulado: 3
Acionamento Time de Resposta Rápida efetuado - CRITICAL
*****

```

Fonte: elaborado pelo autor

5.1.3 Módulo de alertas

O módulo de alertas, implementado em Javascript, recebe os alertas e as notificações provenientes do módulo de processamento. Com isto, o acionamento do Time de Resposta Rápida é possível. O módulo acessa a fila de tópicos de notificações do RabbitMQ através do protocolo STOMP (*Streaming Text Oriented Messaging Protocol*), por meio da biblioteca *stomp.js*¹⁰. Este módulo pode ser disponibilizado em um servidor *web* e ser acessado por qualquer tipo de navegador, incluindo os de dispositivos móveis, tais como *smartphones* e *tablets*. Neste momento, o módulo está disponível na URL <http://www.predictvs.com.br>.

Ao acessar a interface do módulo de alertas, um *pop-up* é exibido, solicitando ao usuário que informe a chave de pesquisa. Como dito anteriormente, isto propicia dinamismo ao módulo, pois em tempo real pode-se selecionar qual paciente ou tipo de alerta se deseja monitorar. Caso o usuário queira visualizar somente os alertas do tipo *critical*, basta inserir o valor “*.critical” nesta tela; caso queira visualizar quaisquer mensagens referentes somente à paciente Júlia, por exemplo, bastaria informar “julia.*” neste campo. Se o valor padrão deste campo (“#”) for mantido, todas as mensagens serão exibidas.

A seguir, o módulo aguarda a transmissão de alertas e de notificações por parte do módulo de processamento, exibindo-os quando ocorrerem. Na parte inferior da tela, para fins didáticos, há um quadro de logs, que exhibe a troca de mensagens entre o módulo e a fila de tópicos do RabbitMQ. A Figura 15 exhibe o módulo de alertas em funcionamento, com as notificações e os alertas recebidos e o log das mensagens provenientes do sistema messageiro.

¹⁰ <http://jmesnil.net/stomp-websocket/doc>

Figura 15. Execução do módulo de alertas do protótipo

07/01/2017 09:02:08	- Paciente: Julia - Mensagem: ALERTA - Temperatura - CÓDIGO AMARELO - Medição: 38.5
07/01/2017 09:02:10	- Paciente: Julia - Mensagem: ALERTA - Temperatura - CÓDIGO AMARELO - Medição: 38.5
07/01/2017 09:02:10	- Paciente: Julia - Mensagem: ALERTA - Frequência cardíaca - CÓDIGO AZUL - Medição: 112
07/01/2017 09:02:11	- Paciente: Julia - Mensagem: ALERTA - Frequência respiratória - CÓDIGO AMARELO - Medição: 9
07/01/2017 09:02:11	- Paciente: Julia - Mensagem: Acionamento Time de Resposta Rápida efetuado - CRITICAL - MEWS: 7
07/01/2017 09:02:11	- Paciente: Julia - Mensagem: ALERTA - Temperatura - CÓDIGO AMARELO - Medição: 38.7
07/01/2017 09:02:11	- Paciente: Julia - Mensagem: ALERTA - Frequência cardíaca - CÓDIGO AZUL - Medição: 113
07/01/2017 09:02:11	- Paciente: Julia - Mensagem: ALERTA - Frequência respiratória - CÓDIGO AMARELO - Medição: 8
07/01/2017 09:02:13	- Paciente: Julia - Mensagem: Acionamento Time de Resposta Rápida efetuado - CRITICAL - MEWS: 6

Logs

```

<<< MESSAGE subscription:sub-0 destination:/exchange/rft_messages/Julia.critical message-id:1_sub-0@session-3c9mkUlv28XVpFZaLw@28 redelivered:false content-length:71
07/01/2017:09:02:10;Julia;ALERTA - Temperatura - CÓDIGO AMARELO;38.5;1
<<< MESSAGE subscription:sub-0 destination:/exchange/rft_messages/Julia.critical message-id:1_sub-0@session-3c9mkUlv28XVpFZaLw@21 redelivered:false content-length:77
07/01/2017:09:02:10;Julia;ALERTA - Frequência cardíaca - CÓDIGO AZUL;112;1
<<< MESSAGE subscription:sub-0 destination:/exchange/rft_messages/Julia.critical message-id:1_sub-0@session-3c9mkUlv28XVpFZaLw@22 redelivered:false content-length:82
07/01/2017:09:02:11;Julia;ALERTA - Frequência respiratória - CÓDIGO AMARELO;9;1
<<< MESSAGE subscription:sub-0 destination:/exchange/rft_messages/Julia.critical message-id:1_sub-0@session-3c9mkUlv28XVpFZaLw@23 redelivered:false content-length:86
07/01/2017:09:02:11;Julia;Acionamento Time de Resposta Rápida efetuado - CRITICAL;7;2
<<< MESSAGE subscription:sub-0 destination:/exchange/rft_messages/Julia.critical message-id:1_sub-0@session-3c9mkUlv28XVpFZaLw@24 redelivered:false content-length:71
07/01/2017:09:02:11;Julia;ALERTA - Temperatura - CÓDIGO AMARELO;38.7;1
<<< MESSAGE subscription:sub-0 destination:/exchange/rft_messages/Julia.critical message-id:1_sub-0@session-3c9mkUlv28XVpFZaLw@25 redelivered:false content-length:77
07/01/2017:09:02:11;Julia;ALERTA - Frequência cardíaca - CÓDIGO AZUL;113;1
<<< MESSAGE subscription:sub-0 destination:/exchange/rft_messages/Julia.critical message-id:1_sub-0@session-3c9mkUlv28XVpFZaLw@26 redelivered:false content-length:82
  
```

Fonte: elaborado pelo autor

Com o uso das bibliotecas *tg* e *PyTg*, foi efetuada a integração do módulo de alertas com o aplicativo de mensagens instantâneas *Telegram*¹¹. Desta forma, torna-se possível o envio de notificações diretamente aos *smartphones* dos profissionais de saúde envolvidos, de forma individual ou coletiva (através do uso de grupos). A Figura 16 mostra as notificações e os alertas recebidos pelo aplicativo.

Figura 16. Integração do módulo de alertas com aplicativo de mensagens Telegram

Chats

RRT
2 membros, 2 online

Predictvts
07/01/2017 - 09:17:22 - Paciente: Julia - ALERTA - Temperatura - CÓDIGO AMARELO - Medição: 39 09:17

Predictvts
07/01/2017 - 09:17:22 - Paciente: Julia - Acionamento Time de Resposta Rápida efetuado - CRITICAL - MEWS: 7 09:17

Predictvts
07/01/2017 - 09:17:22 - Paciente: Julia - ALERTA - Frequência cardíaca - CÓDIGO AZUL - Medição: 115 09:17

Predictvts
07/01/2017 - 09:17:22 - Paciente: Julia - ALERTA - Frequência respiratória - CÓDIGO AMARELO - Medição: 7 09:17

Predictvts
07/01/2017 - 09:17:22 - Paciente: Julia - ALERTA - Temperatura - CÓDIGO AMARELO - Medição: 39.1 09:17

Predictvts
07/01/2017 - 09:17:23 - Paciente: Julia - Acionamento Time de Resposta Rápida efetuado - CRITICAL - MEWS: 7 09:17

Mensagem

Fonte: elaborado pelo autor

¹¹ <https://telegram.org/>

5.2 Funcionamento do protótipo através de cenário

A utilização de cenários tem sido empregada pela comunidade científica para a avaliação de aplicações ubíquas (SATYANARAYANAN, 2001; DA ROCHA, 2015). Desta forma, foi construído um cenário para a avaliação do funcionamento do modelo proposto. O cenário demonstra a atuação do Predictvs na predição da deterioração clínica dos pacientes, com base nos sinais vitais coletados. O cenário utilizado foi:

“Júlia, por requisição de seu médico, em virtude de seu histórico de problemas cardíacos, vai ao centro clínico de seu hospital para que seja realizado um ecodopplercardiograma bidimensional com mapeamento de fluxo em cores, um importante exame para pacientes que possuem doenças relacionadas ao coração. Ao chegar, Júlia recebe uma série de sensores, que são acoplados ao seu corpo e que se comunicam com um dispositivo coletor conectado à rede local do hospital. Tais sensores efetuam, periodicamente, a leitura de sua frequência cardíaca, frequência respiratória, pressão arterial sistólica e temperatura e repassam os dados ao dispositivo coletor, que os retransmite ao módulo de processamento do sistema Predictvs. Júlia realiza o exame e é deixada em repouso na enfermaria. Em determinado momento, o Predictvs detecta que seus sinais vitais começam a se deteriorar, em especial a frequência cardíaca e a pressão arterial sistólica, com seu score de alerta precoce atingindo a pontuação 2. Com isso, o sistema efetua a predição da deterioração de seu estado clínico. Com base no processamento da função de regressão linear, o sistema chega à conclusão de que há grande probabilidade de Júlia sofrer um colapso em breve. Assim, o módulo de alertas do sistema envia uma notificação do tipo warning ao Time de Resposta Rápida, indicando tal situação. No entanto, a deterioração de seus sinais vitais torna-se ainda mais aguda (com a pontuação de seu score de alerta precoce chegando a 7, em virtude de alterações detectadas nas medições das frequências cardíaca e respiratória e de sua pressão arterial sistólica) e o sistema Predictvs emite um novo alerta, agora do tipo critical, contendo um Código Azul, acionando os integrantes do Time de Resposta Rápida do hospital. Desta maneira, os devidos cuidados são aplicados à paciente.”

Analisando o cenário apresentado, as principais funções do modelo Predictvs se fazem presentes, sendo estas:

- Módulo coletor: recebe os dados dos sensores e os envia ao módulo de processamento;
- Módulo de processamento: recebe os dados do módulo coletor e efetua o cálculo do score de alerta precoce, bem como efetua a predição da deterioração dos sinais fisiológicos da paciente. Além disso, encaminha as notificações do tipo *warning* e *critical*, de acordo com o contexto, ao módulo de alertas;
- Módulo de alertas: recebe as notificações do módulo de processamento e as encaminha ao Time de Resposta Rápida, acionando-o.

Desta forma, ao menos hipoteticamente, o modelo atende aos quesitos fundamentais de sua arquitetura.

5.3 Considerações sobre o capítulo

Neste capítulo, foi pormenorizado o protótipo criado para fins de validação prática do modelo, sendo descritos os aspectos de implementação dos módulos coletor, de processamento e de alertas. Posteriormente, como avaliação inicial do modelo, foi utilizado um cenário onde uma paciente hipotética, denominada Júlia, seria submetida a um exame cardíaco em um hospital. Após o exame, em situação de repouso, a análise das medições dos valores dos sensores previamente acoplados em seu corpo efetuada pelo modelo Predictvs detecta a possibilidade de colapso e notifica o Time de Resposta Rápida. Em seguida, em virtude da contínua deterioração dos seus sinais vitais, um alerta é emitido à equipe, o que denotaria a validade teórica do modelo proposto.

O próximo capítulo detalhará o ambiente de experimentação e os resultados obtidos através das sequências de simulações efetuadas, promovendo uma discussão sobre os mesmos.

6 AVALIAÇÃO E DISCUSSÃO

Este capítulo foi dividido em três seções. A primeira seção irá pormenorizar o ambiente de experimentação, esmiuçando o uso do *dataset* público MIMIC, que disponibilizou os dados reais de pacientes utilizados nas simulações efetuadas. A segunda seção elencará os resultados obtidos e a última seção fará a discussão sobre os mesmos.

6.1 Ambiente de experimentação

Para avaliar o modelo proposto, diversas simulações foram executadas utilizando o protótipo elaborado e descrito na seção anterior. Além do conjunto de 100 medições de sinais fisiológicos da paciente hipotética Júlia, fazia-se necessário um escopo maior e mais robusto de valores. Como a utilização de dados coletados diretamente de pacientes reais em enfermarias não era viável, em virtude do alto custo e do tempo que seriam demandados, foi vislumbrada a utilização de bancos de dados públicos e de referência, contendo medições de sinais vitais de pacientes reais, porém tornados anônimos.

Bases de dados de referência são recursos valiosos para pesquisadores, que podem efetuar a análise de sinais e testar, repetidamente, algoritmos com dados reais. Esses bancos de dados também têm valor na educação médica, fornecendo estudos de caso bem documentados de doenças comuns e raras, mas clinicamente significativas. Ao disponibilizar dados clínicos bem caracterizados aos investigadores, estas bases de dados permitem formular e responder a inúmeras questões fisiológicas, sem necessidade de desenvolver um novo conjunto de dados de referência a um custo elevado em cada caso (GOLDBERGER et al., 2000).

Após pesquisas em trabalhos da área, definiu-se, então, que seriam utilizadas medições disponibilizadas publicamente através do banco de dados MIMIC (*Multiparameter Intelligent Monitoring in Intensive Care*)¹². O banco de dados MIMIC, em sua primeira versão, disponibiliza registros de mais de 90 pacientes internados em UTIs, coletados entre os anos de 1992 a 1999, contendo, em média, 40 horas de registros de sinais fisiológicos em cada um. Os dados são disponibilizados em arquivos-texto brutos, sem delimitadores. Além disso, os dados coletados são altamente representativos do que pode ser encontrado em uma UTI e, portanto, estão repletos de ruídos devido aos movimentos do paciente, degradação dos sensores, erros de transmissão, interferência eletromagnética e erro humano (CLIFFORD et al., 2011). A segunda versão do banco de dados MIMIC (MIMIC II) disponibiliza registros de 23180 pacientes, sendo 17468 adultos e 5712 crianças, coletados entre 2001 e 2012. Já a terceira versão do banco de dados MIMIC (MIMIC III) disponibiliza registros de 46467 pacientes, sendo 38597 adultos e 7870 crianças, coletados também entre 2001 e 2012.

Assim, dentre os 72 registros completos de pacientes disponibilizados, foram analisados e descartados, através de um *script* elaborado em *Python*, aqueles que possuíam volume alto de valores inválidos (sinalizados como zero nos registros). O mesmo *script* gerava, em sua saída, um arquivo delimitado por vírgulas contendo os dados agora prontos para serem processados pelo protótipo. Ao final do processo, foram consideradas medições de sinais fisiológicos de 10 pacientes, contendo individualmente mais de 20 mil medições válidas (sendo mais de 5 mil medições válidas por sinal fisiológico), que totalizam mais de 228 mil valores. Os sinais fisiológicos considerados foram frequência cardíaca, frequência respiratória, pressão arterial

¹² <https://www.physionet.org/physiobank/database/mimicdb/>

sistólica e saturação de oxigênio arterial, que coincidem com os existentes no MEWS implementado no protótipo.

Para fins de avaliação dos resultados obtidos pelos ciclos de simulação efetuados, os dados simulados e os dados resultantes da predição foram gravados em arquivos separados por delimitadores. Posteriormente, com base nestes arquivos e com o uso do Microsoft Excel¹³, foram elaborados gráficos que comparam os pontos dos dados reais e dos dados resultantes da predição e que serão vislumbrados na seção 6.3. Além disso, foram calculadas médias e desvios-padrão dos dados reais e dos resultantes da predição, bem como os índices de falso positivo e de falso negativo resultantes do processamento.

A Tabela 5 mostra um resumo dos registros do banco de dados MIMIC utilizados pelo protótipo. O campo paciente informa o identificador numérico de cada registro considerado, uma vez que todos os dados que poderiam identificar o paciente foram suprimidos pelos autores. A descrição completa deste *dataset* encontra-se no final do Apêndice A.

Tabela 5. Resumo dos registros do banco de dados MIMIC utilizados pelo protótipo

Paciente	Medições FC	Medições FR	Medições PAS	Medições SaO ₂	Total
055	5834	5859	5859	5857	23409
211	5839	5283	5823	5271	22216
221	5820	5838	5851	5853	22362
226	5821	5829	5849	5369	22868
230	5823	5841	5798	5859	23321
248	5804	5826	5826	5849	23305
252	5774	5827	5594	5028	22223
253	5825	5849	5854	5468	22996
401	5756	5788	5849	5417	22810
403	5814	5842	5815	5859	23330
Total	58110	57782	58118	55830	228840

Fonte: elaborado pelo autor

6.2 Resultados


Simulando o cenário descrito no capítulo anterior, onde foi utilizado um conjunto de 100 medições de sinais fisiológicos, assim que foram acoplados ao corpo de Júlia, os sensores passaram a reportar, via *bluetooth*, os dados de sua frequência cardíaca, sua frequência respiratória, sua pressão arterial sistólica e sua temperatura. Em determinado momento, logo após Júlia ter realizado o exame e ter sido colocada em repouso, sua frequência cardíaca estava em 101 bpm, sua frequência respiratória estava em 11 ipm e sua pressão arterial sistólica estava

¹³ <https://products.office.com/pt-br/excel>

em 100 mmHg. O módulo de pontuação do Predictvs atribuiu 2 pontos a essa condição clínica, o que disparou um alerta de possível colapso ao Time de Resposta Rápida. Além disso, a regressão linear aplicada demonstrou que em poucos ciclos o escore de alerta precoce seria superior a 3 pontos, o que gerou nova notificação à equipe. Poucos minutos depois, as condições clínicas de Júlia deterioraram-se ainda mais: sua frequência cardíaca subiu para 114 bpm, sua frequência respiratória baixou para 7 ipm e sua pressão arterial sistólica baixou para 94 mmHg. Neste caso, o escore de alerta precoce de Júlia, atribuído pela função de pontuação, recebeu 5 pontos, o que gerou o acionamento do Time de Resposta Rápida do hospital com um Código Azul. Assim, Júlia recebeu os devidos cuidados médicos, sendo transferida para a Unidade de Tratamento Intensivo do hospital e teve a sua vida salva.

Como se pode verificar na Figura 16, as linhas de tendência resultantes da simulação são compatíveis. O eixo x mostra a série de leituras efetuadas para cada tipo de sinal fisiológico (simulado e resultante da análise preditiva) e o eixo y exibe a escala dos valores lidos.

Figura 17. Tendência dos dados simulados e dos dados resultantes da predição.



Fonte: elaborado pelo autor

Posteriormente, foram calculadas as médias e os desvios-padrão das populações simuladas e resultantes da predição, para as quatro categorias de sinais fisiológicos (frequência cardíaca, frequência respiratória, pressão arterial sistólica e temperatura). Os dados demonstram razoável aproximação de valores entre as populações, considerando o baixo tempo dispendido pelo algoritmo de predição, conforme pode ser visto na Tabela 6.


Tabela 6. Análise dos dados simulados e dos dados resultantes da predição.

Sinal fisiológico	Média	Desvio-padrão
FC simulada	104,640	9,329
FC predição	107,582	10,585
FR simulada	10,120	2,065
FR predição	10,169	1,999
PAS simulada	104,520	7,996
PAS predição	104,966	8,006
TEMP simulada	38,360	0,444
TEMP predição	38,280	0,412

Fonte: elaborado pelo autor

Como estes resultados foram obtidos a partir de uma simulação que considerava uma amostra muito pequena de sinais fisiológicos, tendo sido efetuada apenas para verificar o funcionamento do protótipo, novas rodadas de simulações foram efetuadas utilizando os dados fisiológicos dos pacientes disponibilizados pelo banco de dados MIMIC. Inicialmente, foi realizada uma simulação com parte de dados de um paciente MIMIC e, em seguida, contendo todos os dados descritos na Tabela 5.

A nova avaliação utilizou uma fração dos dados do paciente “055”. Foram utilizadas 570 medições de frequência cardíaca, 585 medições de frequência respiratória, 586 medições de temperatura e 585 medições de saturação de oxigênio arterial, totalizando um universo de 2326 amostras. Estes dados foram enviados pelo módulo coletor ao módulo de processamento. Posteriormente, os dados resultantes da função de predição foram armazenados em um arquivo separado por delimitadores e submetidos à mesma análise efetuada anteriormente com o uso do Microsoft Excel, resultando no gráfico exibido na Figura 17 e nas médias e desvios-padrão descritas na Tabela 7. O eixo x mostra a série de leituras efetuadas para cada tipo de sinal fisiológico (proveniente do *dataset* público e resultante da análise preditiva) e o eixo y exibe a escala dos valores lidos.

Figura 18. Tendência dos dados provenientes do *dataset* e dos resultantes da predição.

Fonte: elaborado pelo autor

Tabela 7. Análise dos dados provenientes do *dataset* e dos dados resultantes da predição.

Sinal fisiológico	Média	Desvio-padrão
FC <i>dataset</i>	104,551	2,214
FC predição	104,546	2,059
FR <i>dataset</i>	15,360	2,003
FR predição	15,584	1,352
TEMP <i>dataset</i>	37,115	0,035
TEMP predição	37,123	0,034
SaO ₂ <i>dataset</i>	99,242	0,428
SaO ₂ predição	99,285	0,571


Fonte: elaborado pelo autor

Neste caso, também foi verificada uma razoável aproximação entre os dados reais e os dados resultantes da predição. No entanto, nestas duas abordagens foram utilizadas todas as medições existentes nas séries de dados para efetuar a regressão linear. Assim, o último sinal resultante da análise preditiva utilizava todas as medições anteriores para efetuar a regressão linear, o que poderia levar a eventuais distorções no cálculo.


Para comprovar esta hipótese, três novas sequências de avaliação foram executadas com a fração dos dados do paciente “055”, com uma pequena modificação no algoritmo da função *predicao*: ao invés de utilizar todos os dados anteriores, agora a função utilizaria dez, cinco e três valores previamente medidos para efetuar a regressão linear, respectivamente. Por conta desta alteração, para cada sinal fisiológico, é necessário um tempo de aquecimento (*warm-up*) do sistema de dez, cinco e três ciclos, respectivamente, para que a regressão linear possa ser efetuada.

Posteriormente, os dados resultantes da função de predição foram armazenados em um arquivo separado por delimitadores e submetidos à mesma análise efetuada anteriormente com o uso do Microsoft Excel, resultando nos gráficos exibidos na Figura 18 (a, b e c) e nas médias e desvios-padrão descritas na Tabela 8. O eixo x de cada figura mostra a série de leituras efetuadas para cada tipo de sinal fisiológico (proveniente do *dataset* público e resultante da análise preditiva) e o eixo y exibe a escala dos valores lidos.


Figura 19. Tendência dos dados utilizando o algoritmo de predição modificado.
a) utilizando 10 medições anteriores



b) utilizando 5 medições anteriores



c) utilizando 3 medições anteriores



Fonte: elaborados pelo autor

Tabela 8. Análise dos dados provenientes do algoritmo de predição modificado.

Dados	Sinais/Resumo	FC	FR	Temp	SaO ₂
Reais (MIMIC)	Média	104,551	15,365	37,115	99,242
	Desvio-padrão	2,214	2,003	0,037	0,428
10 medições anteriores	Média	104,467	15,365	37,115	99,246
	Desvio-padrão	2,179	2,185	0,037	0,446
5 medições anteriores	Média	104,507	15,362	37,115	99,244
	Desvio-padrão	2,208	2,094	0,039	0,442
3 medições anteriores	Média	104,523	15,360	37,115	99,243
	Desvio-padrão	2,230	2,114	0,043	0,445

Fonte: elaborado pelo autor

Analisando os gráficos e os dados de média e desvio-padrão, se verificou que os melhores resultados, neste contexto, foram encontrados utilizando os cinco valores previamente medidos a cada ciclo de predição. Por conta desta situação, o protótipo foi modificado, permitindo que o médico responsável pelo Time de Resposta Rápida defina, para cada sinal fisiológico, o limite de valores previamente medidos que deve ser considerado pela função de predição. Por padrão, o protótipo considera este valor como 5.

Após estes experimentos preliminares, foram efetuadas simulações utilizando todos os dados dos pacientes MIMIC constantes na Tabela 5. Para cada paciente, três simulações foram efetuadas, buscando a predição para um, três e cinco medições futuras, respectivamente. Com os resultados de cada simulação, foram calculadas médias e desvios-padrão dos dados obtidos. Como forma adicional de controle, foram calculados os índices de falso positivo e de falso negativo dos acionamentos do Time de Resposta Rápida, com base nos dados reais dos pacientes. Estes dados reais foram submetidos ao módulo de processamento e foram contabilizadas todas as situações em que ocorreriam notificações e alertas ao Time de Resposta Rápida, com base no EWS utilizado.

A Tabela 9 mostra o resumo dos resultados obtidos através das simulações efetuadas com o conjunto de dados do paciente “055”. São exibidos os resultados de média e de desvio-padrão dos dados reais e dos resultantes das simulações efetuadas, contendo a predição para um, três e cinco medições futuras, respectivamente. É possível verificar a boa aproximação entre os valores originais e os resultantes da predição.

Tabela 9. Resultados obtidos com as simulações efetuadas – paciente “055”

Dados	Sinais/Resumo	FC	FR	PAS	SaO ₂
Reais (MIMIC)	Média	103,492	15,340	116,364	98,988
	Desvio-padrão	7,148	1,894	12,587	0,616
Predição de 1 medição	Média	103,368	15,329	116,214	98,96
	Desvio-padrão	7,158	1,936	12,614	0,641
Predição de 3 medições	Média	103,314	15,314	116,15	98,947
	Desvio-padrão	7,215	2,098	12,675	0,757
Predição de 5 medições	Média	103,311	15,313	116,141	98,948
	Desvio-padrão	7,291	2,365	12,758	0,878

Fonte: elaborado pelo autor

A Tabela 10 exibe os índices de acionamento (totais e corretos), falsos positivos e falsos negativos obtidos através das simulações efetuadas com o conjunto de dados do paciente “055”. O item “Acionamento” se refere a situações em que, de acordo com os dados reais, o Time de Resposta Rápida seria notificado ou alertado sobre as condições do paciente; “acionamentos totais” denota a quantidade de acionamentos efetuados pelo protótipo em virtude da predição; “acionamentos corretos” totaliza os momentos em que os acionamentos efetuados pelo protótipo coincidiram com os acionamentos que seriam efetuados através dos dados reais; “falsos positivos” contabiliza quantos acionamentos indevidos foram efetuados; “falsos negativos” calcula quantas ocorrências deixaram de ser reportadas ao Time de Resposta Rápida.

Estes mesmos itens serão contabilizados e exibidos nas tabelas 12, 14, 16, 18, 20, 22, 24, 26, 28 e 29.

No caso do paciente “055”, a predição foi efetuada de forma adequada, mas a predição para três e cinco medições mostra incremento no índice de falsos positivos.

Tabela 10. Acionamentos, falsos positivos e falsos negativos – paciente “055”

Dados	Sinais/Resumo	FC	FR	PAS	SaO ₂
Reais (MIMIC)	Acionamentos	562	118	200	0
Predição de 1 medição	Ac totais	556	113	205	0
	Acionamentos corretos	555	112	199	0
	Falsos positivos	1	1	6	0
	Falsos negativos	7	6	1	0
Predição de 3 medições	Acionamentos totais	560	116	199	0
	Acionamentos corretos	551	102	190	0
	Falsos positivos	9	14	9	0
	Falsos negativos	11	16	10	0
Predição de 5 medições	Acionamentos totais	570	130	196	0
	Acionamentos corretos	549	97	185	0
	Falsos positivos	21	33	11	0
	Falsos negativos	13	21	15	0

Fonte: elaborado pelo autor

A Tabela 11 mostra o resumo dos resultados obtidos através das simulações efetuadas com o conjunto de dados do paciente “211”. Como ocorre pouca variação entre os valores medidos, há boa aproximação entre os dados reais e os resultantes da predição.

Tabela 11. Resultados obtidos com as simulações efetuadas – paciente “211”

Dados	Sinais/Resumo	FC	FR	PAS	SaO ₂
Reais (MIMIC)	Média	90,37	13,422	183,87	95,657
	Desvio-padrão	1,564	6,461	13,927	1,516
Predição de 1 medição	Média	90,325	13,318	183,635	95,631
	Desvio-padrão	1,599	6,812	14,022	1,526
Predição de 3 medições	Média	90,303	13,222	183,52	95,618
	Desvio-padrão	1,726	7,852	14,309	1,580
Predição de 5 medições	Média	90,303	13,206	183,508	95,617
	Desvio-padrão	1,897	9,297	14,672	1,645

Fonte: elaborado pelo autor

A Tabela 12 exibe os índices de acionamento (totais e corretos), falsos positivos e falsos negativos obtidos através das simulações efetuadas com o conjunto de dados do paciente “211”. A partir da predição de três medições há incremento no índice de falsos positivos da frequência respiratória e pressão arterial sistólica.

Tabela 12. Acionamentos, falsos positivos e falsos negativos – paciente “211”

Dados	Sinais/Resumo	FC	FR	PAS	SaO ₂
Reais (MIMIC)	Acionamentos	0	1939	447	0
Predição de 1 medição	Acionamentos totais	0	2005	424	0
	Acionamentos corretos	0	1859	419	0
	Falsos positivos	0	146	5	0
	Falsos negativos	0	80	28	0
Predição de 3 medições	Acionamentos totais	1	2106	450	0
	Acionamentos corretos	0	1725	391	0
	Falsos positivos	1	381	59	0
	Falsos negativos	0	183	56	0
Predição de 5 medições	Acionamentos totais	5	2200	478	1
	Acionamentos corretos	0	1600	372	0
	Falsos positivos	5	600	106	1
	Falsos negativos	0	251	75	0

Fonte: elaborado pelo autor

A Tabela 13 mostra o resumo dos resultados obtidos através das simulações efetuadas com o conjunto de dados do paciente “221”, com boa aproximação entre os valores reais e resultantes da predição.

Tabela 13. Resultados obtidos com as simulações efetuadas – paciente “221”

Dados	Sinais/Resumo	FC	FR	PAS	SaO ₂
Reais (MIMIC)	Média	79,52	23,271	194,002	99,584
	Desvio-padrão	7,67	4,098	6,575	0,599
Predição de 1 medição	Média	79,304	23,112	193,804	99,544
	Desvio-padrão	7,754	4,305	6,626	0,673
Predição de 3 medições	Média	79,197	22,976	193,693	99,527
	Desvio-padrão	8,024	4,998	6,838	0,845
Predição de 5 medições	Média	79,199	22,956	193,707	99,526
	Desvio-padrão	8,471	5,932	7,16	1,002

Fonte: elaborado pelo autor

A Tabela 14 exibe os índices de acionamento (totais e corretos), falsos positivos e falsos negativos obtidos através das simulações efetuadas com o conjunto de dados do paciente “221”. Há maior incremento nos índices de falsos positivos na frequência respiratória e na pressão arterial sistólica.

Tabela 14. Acionamentos, falsos positivos e falsos negativos – paciente “221”

Dados	Sinais/Resumo	FC	FR	PAS	SaO ₂
Reais (MIMIC)	Acionamentos	98	4779	488	0
Predição de 1 medição	Acionamentos totais	91	4622	471	0
	Acionamentos corretos	88	4596	464	0
	Falsos positivos	3	26	7	0
	Falsos negativos	10	183	24	0
Predição de 3 medições	Acionamentos totais	103	4295	509	0
	Acionamentos corretos	79	4223	446	0
	Falsos positivos	24	72	63	0
	Falsos negativos	19	555	42	0
Predição de 5 medições	Acionamentos totais	106	4100	559	0
	Acionamentos corretos	74	3993	435	0
	Falsos positivos	32	107	124	0
	Falsos negativos	24	783	53	0

Fonte: elaborado pelo autor

A Tabela 15 mostra o resumo dos resultados obtidos através das simulações efetuadas com o conjunto de dados do paciente “226”. A aproximação entre os valores reais e resultantes da predição é boa, mas não tanto quanto nos pacientes anteriores. Isto provavelmente deve-se a maior variação entre os valores medidos.

Tabela 15. Resultados obtidos com as simulações efetuadas – paciente “226”

Dados	Sinais/Resumo	FC	FR	PAS	SaO ₂
Reais (MIMIC)	Média	133,413	39,756	153,27	95,863
	Desvio-padrão	2,722	11,521	17,504	1,847
Predição de 1 medição	Média	133,282	39,523	153,016	95,791
	Desvio-padrão	2,814	12,256	17,838	1,917
Predição de 3 medições	Média	133,235	39,322	152,823	95,756
	Desvio-padrão	2,981	14,335	18,768	2,106
Predição de 5 medições	Média	133,237	39,306	152,826	95,754
	Desvio-padrão	3,182	17,113	20,154	2,327

Fonte: elaborado pelo autor

A Tabela 16 exibe os índices de acionamento (totais e corretos), falsos positivos e falsos negativos obtidos através das simulações efetuadas com o conjunto de dados do paciente 226. Como este paciente apresenta muitas variações nas medições, há incremento mais acentuado nos índices de falsos positivos.

Tabela 16. Acionamentos, falsos positivos e falsos negativos – paciente 226

Dados	Sinais/Resumo	FC	FR	PAS	SaO ₂
Reais (MIMIC)	Acionamentos	5817	5698	61	31
Predição de 1 medição	Acionamentos totais	5817	5683	66	48
	Acionamentos corretos	5817	5679	60	31
	Falsos positivos	0	4	6	17
	Falsos negativos	0	19	1	0
Predição de 3 medições	Acionamentos totais	5817	5574	77	75
	Acionamentos corretos	5817	5566	55	31
	Falsos positivos	0	8	22	44
	Falsos negativos	0	130	6	0
Predição de 5 medições	Acionamentos totais	5817	5406	98	97
	Acionamentos corretos	5817	5390	52	31
	Falsos positivos	0	16	46	66
	Falsos negativos	0	300	9	0

Fonte: elaborado pelo autor

A Tabela 17 mostra o resumo dos resultados obtidos através das simulações efetuadas com o conjunto de dados do paciente “230”. A tabela demonstra uma grande aproximação entre os valores reais e resultantes da predição.

Tabela 17. Resultados obtidos com as simulações efetuadas – paciente “230”

Dados	Sinais/Resumo	FC	FR	PAS	SaO ₂
Reais (MIMIC)	Média	73,153	17,069	108,5	94,261
	Desvio-padrão	2,16	2,753	13,074	3,329
Predição de 1 medição	Média	73,114	16,987	108,293	94,216
	Desvio-padrão	2,183	2,837	13,194	3,352
Predição de 3 medições	Média	73,091	16,932	108,184	94,197
	Desvio-padrão	2,257	3,15	13,566	3,397
Predição de 5 medições	Média	73,091	16,928	108,174	94,197
	Desvio-padrão	2,345	3,569	14,08	3,448

Fonte: elaborado pelo autor

A Tabela 18 exibe os índices de acionamento (totais e corretos), falsos positivos e falsos negativos obtidos através das simulações efetuadas com o conjunto de dados do paciente “230”. O índice de falsos positivos nas predições relacionadas à pressão arterial sistólica e saturação de oxigênio arterial é menos expressivo.

Tabela 18. Acionamentos, falsos positivos e falsos negativos – paciente “230”

Dados	Sinais/Resumo	FC	FR	PAS	SaO ₂
Reais (MIMIC)	Acionamentos	0	343	1	393
Predição de 1 medição	Acionamentos totais	0	351	2	395
	Acionamentos corretos	0	327	1	393
	Falsos positivos	0	24	1	2
	Falsos negativos	0	16	0	0
Predição de 3 medições	Acionamentos totais	0	419	3	410
	Acionamentos corretos	0	305	1	391
	Falsos positivos	0	114	2	19
	Falsos negativos	0	38	0	2
Predição de 5 medições	Acionamentos totais	0	505	8	429
	Acionamentos corretos	0	294	1	387
	Falsos positivos	0	211	7	42
	Falsos negativos	0	49	0	6

Fonte: elaborado pelo autor

A Tabela 19 mostra o resumo dos resultados obtidos através das simulações efetuadas com o conjunto de dados do paciente “248”. Como há maior variação nas medições, a aproximação entre os valores reais e resultantes da predição é um pouco menor.

Tabela 19. Resultados obtidos com as simulações efetuadas – paciente “248”

Dados	Sinais/Resumo	FC	FR	PAS	SaO ₂
Reais (MIMIC)	Média	95,137	18,416	131,397	96,856
	Desvio-padrão	8,003	2,882	5,366	0,979
Predição de 1 medição	Média	94,873	18,279	131,136	96,841
	Desvio-padrão	8,458	3,04	5,543	1,001
Predição de 3 medições	Média	94,68	18,173	130,941	96,837
	Desvio-padrão	9,786	3,529	6,123	1,05
Predição de 5 medições	Média	94,675	18,164	130,933	96,838
	Desvio-padrão	11,565	4,167	6,947	1,104

Fonte: elaborado pelo autor

A Tabela 20 exibe os índices de acionamento (totais e corretos), falsos positivos e falsos negativos obtidos através das simulações efetuadas com o conjunto de dados do paciente “248”. O índice de falsos positivos na frequência cardíaca e na frequência respiratória é incrementado em virtude da variação dos sinais mensurados.

Tabela 20. Acionamentos, falsos positivos e falsos negativos – paciente “248”

Dados	Sinais/Resumo	FC	FR	PAS	SaO ₂
Reais (MIMIC)	Acionamentos	352	1162	0	0
Predição de 1 medição	Acionamentos totais	362	1145	0	1
	Acionamentos corretos	314	1088	0	0
	Falsos positivos	48	57	0	1
	Falsos negativos	38	74	0	0
Predição de 3 medições	Acionamentos totais	428	1268	0	4
	Acionamentos corretos	287	1004	0	0
	Falsos positivos	141	264	0	4
	Falsos negativos	65	158	0	0
Predição de 5 medições	Acionamentos totais	558	1447	2	8
	Acionamentos corretos	278	976	0	0
	Falsos positivos	280	471	2	8
	Falsos negativos	74	185	0	0

Fonte: elaborado pelo autor

A Tabela 21 mostra o resumo dos resultados obtidos através das simulações efetuadas com o conjunto de dados do paciente “252”. Há boa aproximação entre os valores reais e resultantes da predição.

Tabela 21. Resultados obtidos com as simulações efetuadas – paciente “252”

Dados	Sinais/Resumo	FC	FR	PAS	SaO ₂
Reais (MIMIC)	Média	59,428	16,162	113,458	92,777
	Desvio-padrão	1,59	2,106	19,809	2,543
Predição de 1 medição	Média	59,383	16,133	113,292	92,757
	Desvio-padrão	1,624	2,239	19,871	2,562
Predição de 3 medições	Média	59,359	16,102	113,234	92,747
	Desvio-padrão	1,74	2,638	20,037	2,623
Predição de 5 medições	Média	59,356	16,097	113,242	92,747
	Desvio-padrão	1,867	3,184	20,299	2,71

Fonte: elaborado pelo autor

A Tabela 22 exibe os índices de acionamento (totais e corretos), falsos positivos e falsos negativos obtidos através das simulações efetuadas com o conjunto de dados do paciente “252”. Há incremento nos índices de falsos positivos, em virtude da variação das medições dos sinais fisiológicos.

Tabela 22. Acionamentos, falsos positivos e falsos negativos – paciente “252”

Dados	Sinais/Resumo	FC	FR	PAS	SaO ₂
Reais (MIMIC)	Acionamentos	0	210	292	262
Predição de 1 medição	Acionamentos totais	0	223	304	270
	Acionamentos corretos	0	192	292	262
	Falsos positivos	0	31	12	8
	Falsos negativos	0	18	0	0
Predição de 3 medições	Acionamentos totais	0	292	304	288
	Acionamentos corretos	0	181	284	258
	Falsos positivos	0	111	20	30
	Falsos negativos	0	29	6	4
Predição de 5 medições	Acionamentos totais	0	379	309	305
	Acionamentos corretos	0	168	281	255
	Falsos positivos	0	211	28	50
	Falsos negativos	0	35	8	7

Fonte: elaborado pelo autor

A Tabela 23 mostra o resumo dos resultados obtidos através das simulações efetuadas com o conjunto de dados do paciente “253”. Há boa aproximação entre os valores reais e os resultantes da predição, mas nota-se alguma distorção na frequência respiratória.

Tabela 23. Resultados obtidos com as simulações efetuadas – paciente “253”

Dados	Sinais/Resumo	FC	FR	PAS	SaO ₂
Reais (MIMIC)	Média	69,461	19,762	122,196	92,463
	Desvio-padrão	1,066	2,591	8,262	0,654
Predição de 1 medição	Média	69,438	19,642	122,024	92,446
	Desvio-padrão	1,084	2,8	8,293	0,676
Predição de 3 medições	Média	69,427	19,52	121,93	92,438
	Desvio-padrão	1,149	3,424	8,394	0,755
Predição de 5 medições	Média	69,429	19,485	121,93	92,438
	Desvio-padrão	1,216	4,283	8,53	0,838

Fonte: elaborado pelo autor

A Tabela 24 exibe os índices de acionamento (totais e corretos), falsos positivos e falsos negativos obtidos através das simulações efetuadas com o conjunto de dados do paciente “253”. É possível verificar o incremento do índice de falsos positivos na frequência respiratória.

Tabela 24. Acionamentos, falsos positivos e falsos negativos – paciente “253”

Dados	Sinais/Resumo	FC	FR	PAS	SaO ₂
Reais (MIMIC)	Acionamentos	0	2873	0	0
Predição de 1 medição	Acionamentos totais	0	2582	0	0
	Acionamentos corretos	0	2488	0	0
	Falsos positivos	0	94	0	0
	Falsos negativos	0	385	0	0
Predição de 3 medições	Acionamentos totais	0	2503	0	10
	Acionamentos corretos	0	2369	0	0
	Falsos positivos	0	134	0	10
	Falsos negativos	0	504	0	0
Predição de 5 medições	Acionamentos totais	0	2604	0	45
	Acionamentos corretos	0	2333	0	0
	Falsos positivos	0	271	0	45
	Falsos negativos	0	540	0	0

Fonte: elaborado pelo autor

A Tabela 25 mostra o resumo dos resultados obtidos através das simulações efetuadas com o conjunto de dados do paciente “401”. Há boa aproximação entre os valores reais e os provenientes dos resultados da predição.

Tabela 25. Resultados obtidos com as simulações efetuadas – paciente “401”

Dados	Sinais/Resumo	FC	FR	PAS	SaO ₂
Reais (MIMIC)	Média	74,329	17,456	137,735	96,192
	Desvio-padrão	3,983	6,606	16,709	1,351
Predição de 1 medição	Média	74,231	17,334	137,585	96,146
	Desvio-padrão	3,981	6,714	16,711	1,388
Predição de 3 medições	Média	74,185	17,238	137,509	96,124
	Desvio-padrão	4,053	7,145	16,772	1,506
Predição de 5 medições	Média	74,186	17,228	137,522	96,125
	Desvio-padrão	4,16	7,806	16,92	1,638

Fonte: elaborado pelo autor

A Tabela 26 exibe os índices de acionamento (totais e corretos), falsos positivos e falsos negativos obtidos através das simulações efetuadas com o conjunto de dados do paciente “401”. Como o paciente apresenta variações na frequência cardíaca, frequência respiratória e na pressão arterial sistólica, isto implica no incremento no índice de falsos positivos.

Tabela 26. Acionamentos, falsos positivos e falsos negativos – paciente “401”

Dados	Sinais/Resumo	FC	FR	PAS	SaO ₂
Reais (MIMIC)	Acionamentos	0	1074	17	12
Predição de 1 medição	Acionamentos totais	0	1044	16	14
	Acionamentos corretos	0	1029	16	12
	Falsos positivos	0	15	0	2
	Falsos negativos	0	45	1	2
Predição de 3 medições	Acionamentos totais	0	1000	14	19
	Acionamentos corretos	0	949	12	12
	Falsos positivos	0	51	2	7
	Falsos negativos	0	124	5	0
Predição de 5 medições	Acionamentos totais	0	1042	21	26
	Acionamentos corretos	0	898	12	12
	Falsos positivos	0	144	9	14
	Falsos negativos	0	173	5	0

Fonte: elaborado pelo autor

A Tabela 27 mostra o resumo dos resultados obtidos através das simulações efetuadas com o conjunto de dados do paciente “403”. Os resultados mostram grande aproximação entre os valores reais e resultantes do processo de predição.

Tabela 27. Resultados obtidos com as simulações efetuadas – paciente “403”

Dados	Sinais/Resumo	FC	FR	PAS	SaO ₂
Reais (MIMIC)	Média	68,905	12,154	126,107	94,639
	Desvio-padrão	2,975	0,615	5,733	0,719
Predição de 1 medição	Média	68,854	12,145	125,982	94,628
	Desvio-padrão	2,998	0,622	5,897	0,729
Predição de 3 medições	Média	68,827	12,14	125,921	94,624
	Desvio-padrão	3,055	0,703	6,4	0,772
Predição de 5 medições	Média	68,823	12,139	125,936	94,624
	Desvio-padrão	3,116	0,806	7,087	0,82

Fonte: elaborado pelo autor

A Tabela 28 exibe os índices de acionamento (totais e corretos), falsos positivos e falsos negativos obtidos através das simulações efetuadas com o conjunto de dados do paciente “403”. Como ocorrem poucas variações nos sinais mensurados, o índice de falsos positivos é significativamente menor que em outras situações.

Tabela 28. Acionamentos, falsos positivos e falsos negativos – paciente “403”

Dados	Sinais/Resumo	FC	FR	PAS	SaO ₂
Reais (MIMIC)	Acionamentos	0	0	1	0
Predição de 1 medição	Acionamentos totais	0	2	3	0
	Acionamentos corretos	0	0	1	0
	Falsos positivos	0	2	2	0
	Falsos negativos	0	0	0	0
Predição de 3 medições	Acionamentos totais	0	10	3	0
	Acionamentos corretos	0	0	1	0
	Falsos positivos	0	10	2	0
	Falsos negativos	0	0	0	0
Predição de 5 medições	Acionamentos totais	0	22	3	0
	Acionamentos corretos	0	0	1	0
	Falsos positivos	0	22	2	0
	Falsos negativos	0	0	0	0

Fonte: elaborado pelo autor

6.3 Discussão

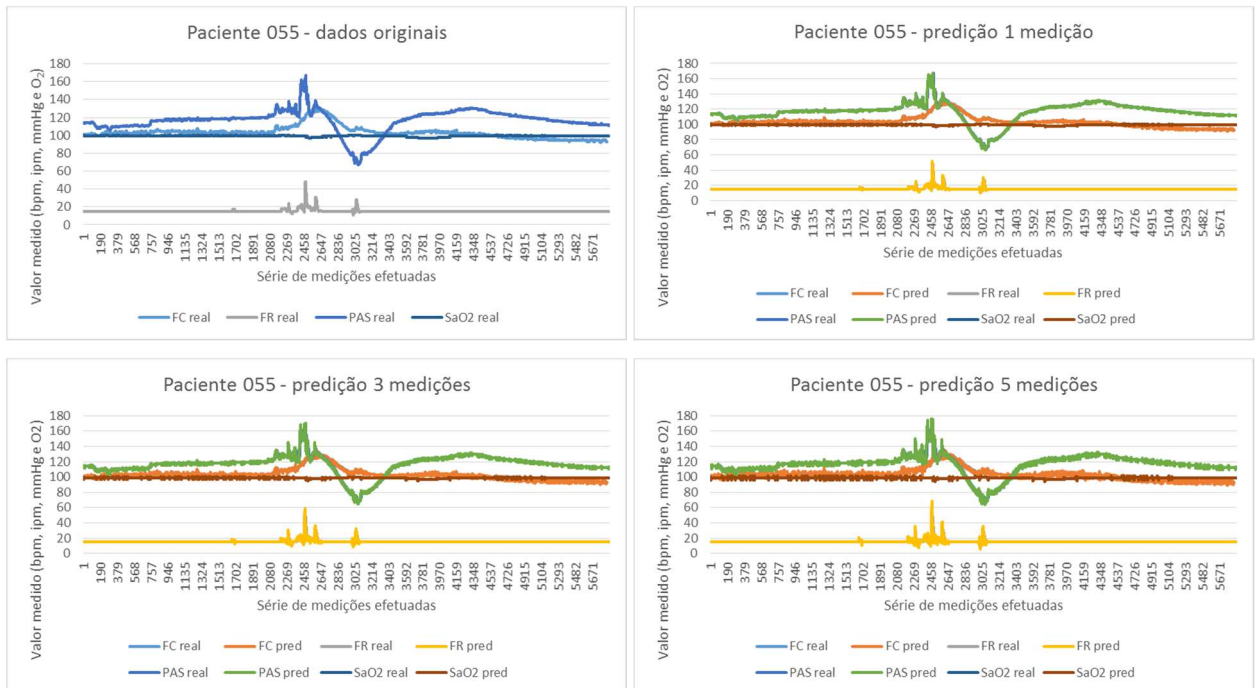
Com base nos resultados obtidos através das séries de simulações efetuadas, foram gerados, através do Microsoft Excel, gráficos contendo as linhas de tendência observadas durante o processamento dos dados reais e dos dados resultantes do processo de predição. As Figuras 20 a 29 exibem os gráficos resultantes das simulações. Para cada figura, há quatro gráficos: dados originais, resultados da predição da medição seguinte, resultados da predição de três medições futuras e resultados da predição de cinco medições futuras. Em cada gráfico, o eixo x mostra a série de leituras efetuadas para cada tipo de sinal fisiológico e o eixo y exibe a escala dos valores lidos.

É possível observar, em cada gráfico, o detalhamento da evolução das séries dos dados reais e dos dados resultantes da predição. No caso da predição para medição seguinte, se verifica grande afinidade entre os traçados. Nas simulações efetuando predição para três e cinco medições futuras, respectivamente, também se observa certa conformidade. No entanto, é possível notar o início de uma distorção nos gráficos gerados, em virtude dos altos índices de falsos positivos que serão detalhados adiante. De qualquer forma, a boa aproximação entre as linhas dos dados reais e dos dados resultantes da predição, aliados ao baixo tempo de processamento necessário para obtê-los, foram bastante aceitáveis.

A Figura 20 exibe os gráficos referentes ao paciente “055”. Este paciente apresentou oscilações na frequência cardíaca e na pressão arterial sistólica entre as medições 2000 e 3200, com reflexos na frequência respiratória. A predição foi efetuada de forma adequada, mas, como

pode ser visto no aumento da espessura das linhas dos quadrantes inferiores, a predição para três e cinco medições indica incremento no índice de falsos positivos.


Figura 20. Gráficos resultantes das simulações – paciente “055”




Fonte: elaborado pelo autor

A Figura 21 exibe os gráficos referentes ao paciente “211”. Este paciente apresentou alterações em sua pressão arterial sistólica a partir da medição 4000, com reflexos na frequência respiratória. A predição foi efetuada de forma adequada, mas, como pode ser visto no aumento da espessura das linhas dos quadrantes inferiores, a predição para três e cinco medições indica incremento no índice de falsos positivos. Fica nítida essa distorção no incremento da amplitude da predição das alterações da frequência respiratória (pico sobre o valor 4726).

Figura 21. Gráficos resultantes das simulações – paciente “211”

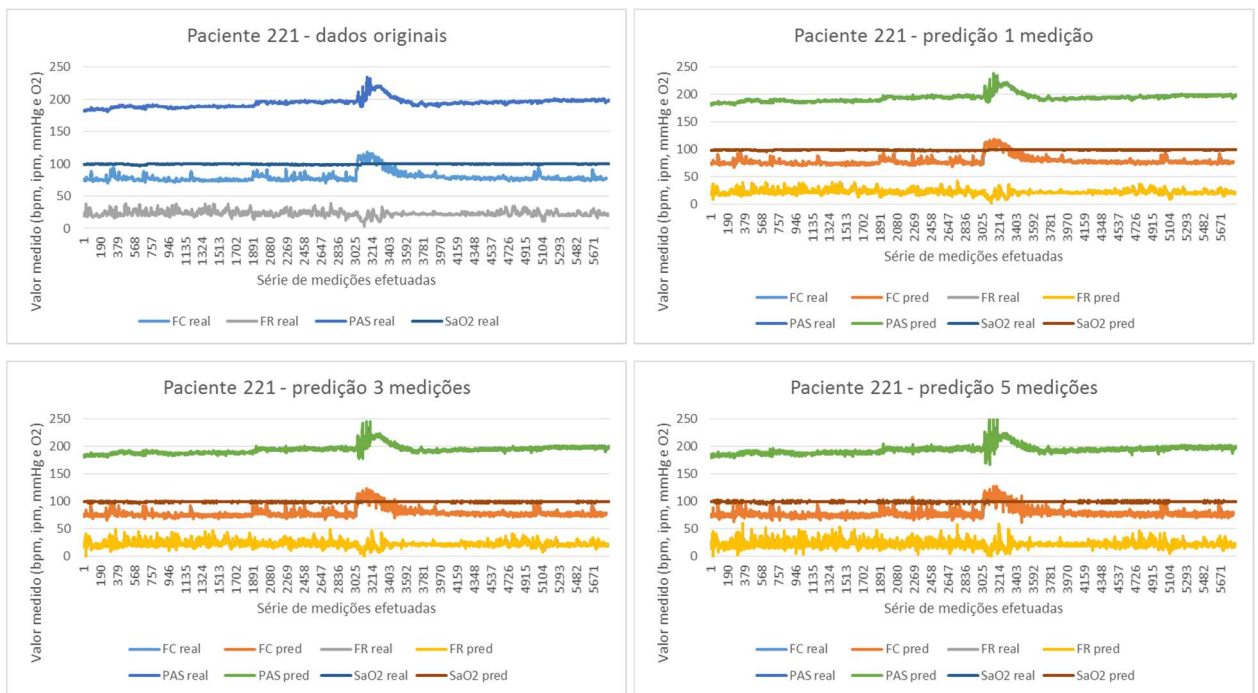




Fonte: elaborado pelo autor

A Figura 22 exibe os gráficos referentes ao paciente “221”. Este paciente apresentou alterações em sua frequência cardíaca e na sua pressão arterial sistólica a partir da medição 3000. Sua frequência respiratória apresenta oscilações durante todo o período. A predição foi efetuada de forma adequada, mas, como pode ser visto no aumento da espessura das linhas dos quadrantes inferiores, a predição para três e cinco medições indica incremento no índice de falsos positivos.

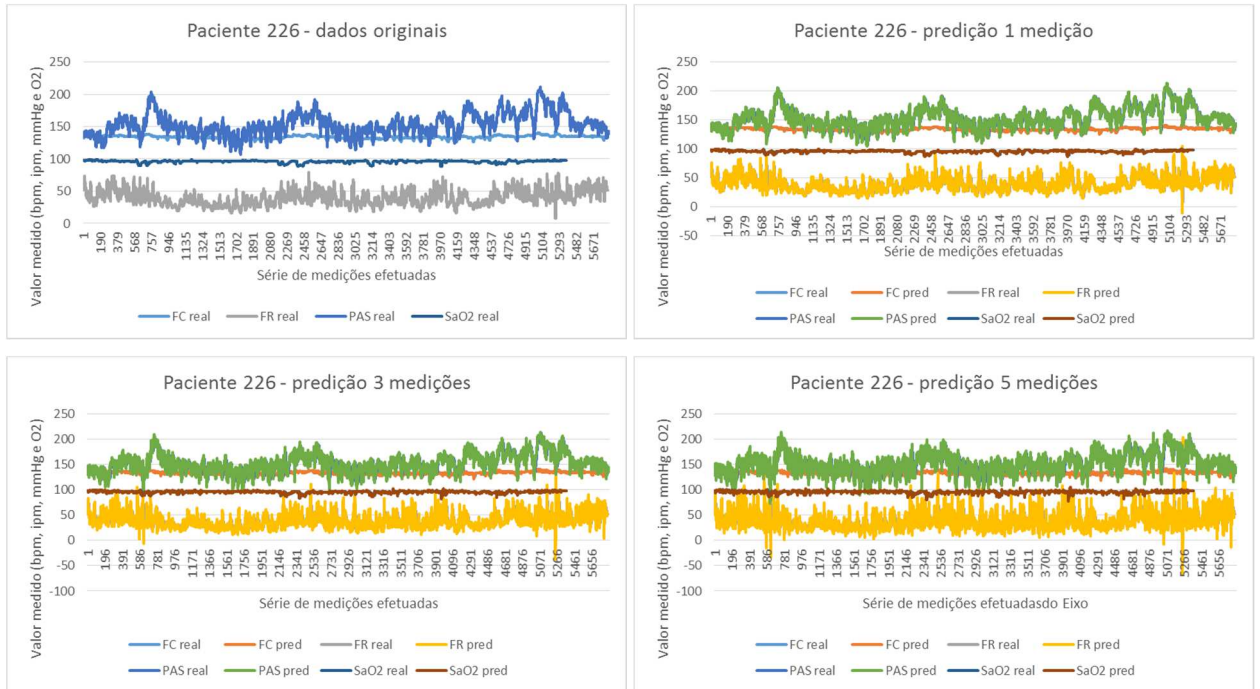
Figura 22. Gráficos resultantes das simulações – paciente “221”



Fonte: elaborado pelo autor

A Figura 23 exibe os gráficos referentes ao paciente “226”. Este paciente apresentou grandes alterações em sua frequência respiratória e na sua pressão arterial sistólica durante todo o período. Em casos assim, fica bastante evidente o incremento no índice de falsos positivos nas predições para três e cinco medições.

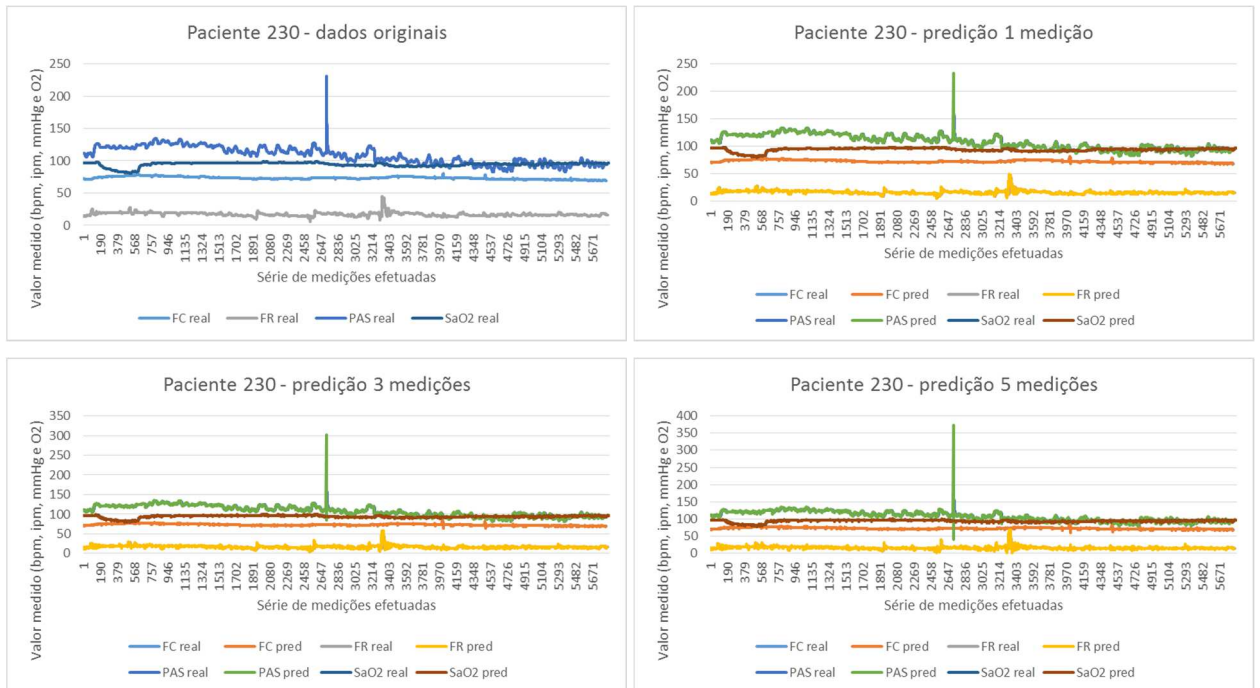
Figura 23. Gráficos resultantes das simulações – paciente “226”



Fonte: elaborado pelo autor

A Figura 24 exibe os gráficos referentes ao paciente “230”. Este paciente apresenta oscilações na pressão arterial sistólica, com pequenos reflexos na frequência respiratória. Neste caso, onde há pouca variação, o índice de falsos positivos nas predições relacionadas à pressão arterial sistólica é menos expressivo.

Figura 24. Gráficos resultantes das simulações – paciente “230”



Fonte: elaborado pelo autor

A Figura 25 exibe os gráficos referentes ao paciente “248”, com muitas oscilações na frequência cardíaca e na pressão arterial sistólica. Pode-se notar que o índice de falsos positivos nas predições para três e cinco medições fica mais expressivo quando ocorre maior variação nos valores medidos.


Figura 25. Gráficos resultantes das simulações – paciente “248”





Fonte: elaborado pelo autor

A Figura 26 exibe os gráficos referentes ao paciente “252”. Este paciente experimenta uma grande variação na pressão arterial sistólica, que, por duas vezes, sofre decréscimo abaixo de 80mmHg e torna a ficar alta. A frequência respiratória também demonstra esta variação. A predição ocorre de forma adequada, mas o pico experimentado entre as medições 1300 e 1500 gera distorção na predição de três e cinco medições futuras.

Figura 26. Gráficos resultantes das simulações – paciente “252”









Fonte: elaborado pelo autor

A Figura 27 exibe os gráficos referentes ao paciente “253”. Este paciente apresenta sucessivas oscilações na pressão arterial sistólica. Este comportamento eleva o índice de falsos positivos nas predições de três e cinco medições, como pode ser visto na parte inferior da Figura.

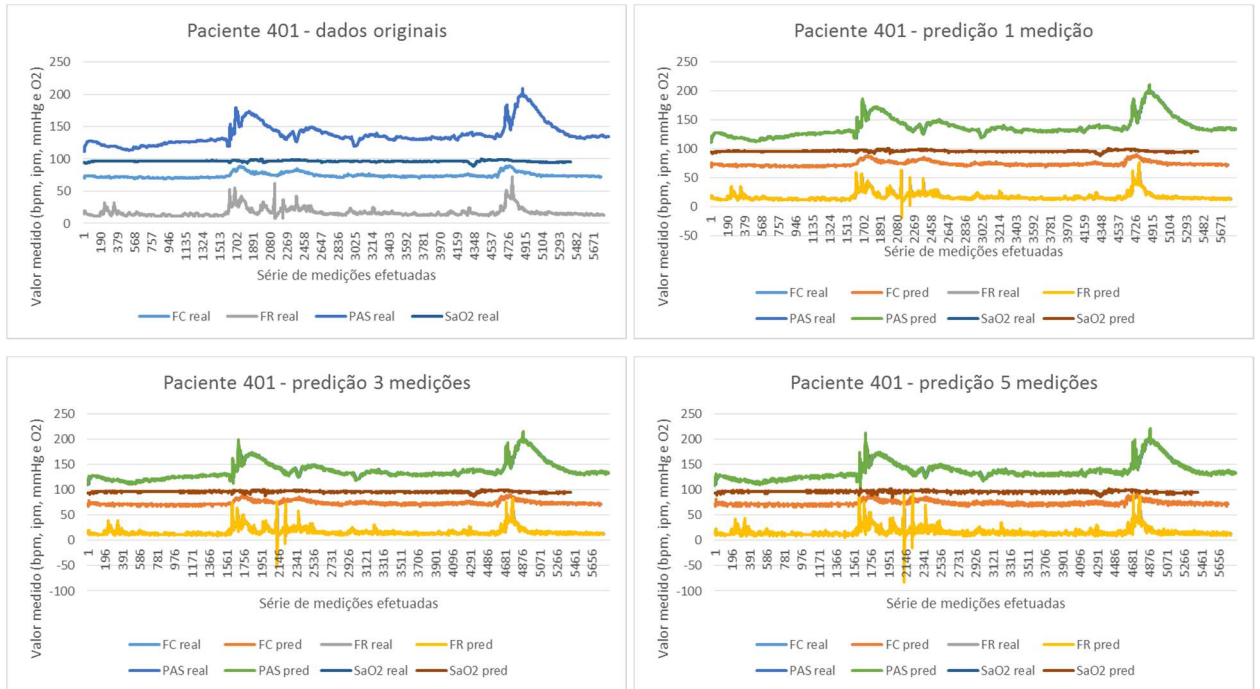
Figura 27. Gráficos resultantes das simulações – paciente “253”



Fonte: elaborado pelo autor

A Figura 28 exibe os gráficos referentes ao paciente “401”. O paciente apresenta variações coincidentes na frequência cardíaca, frequência respiratória e na pressão arterial sistólica. A predição foi efetuada de forma adequada, mas a predição para três e cinco medições sofre incremento no índice de falsos positivos.

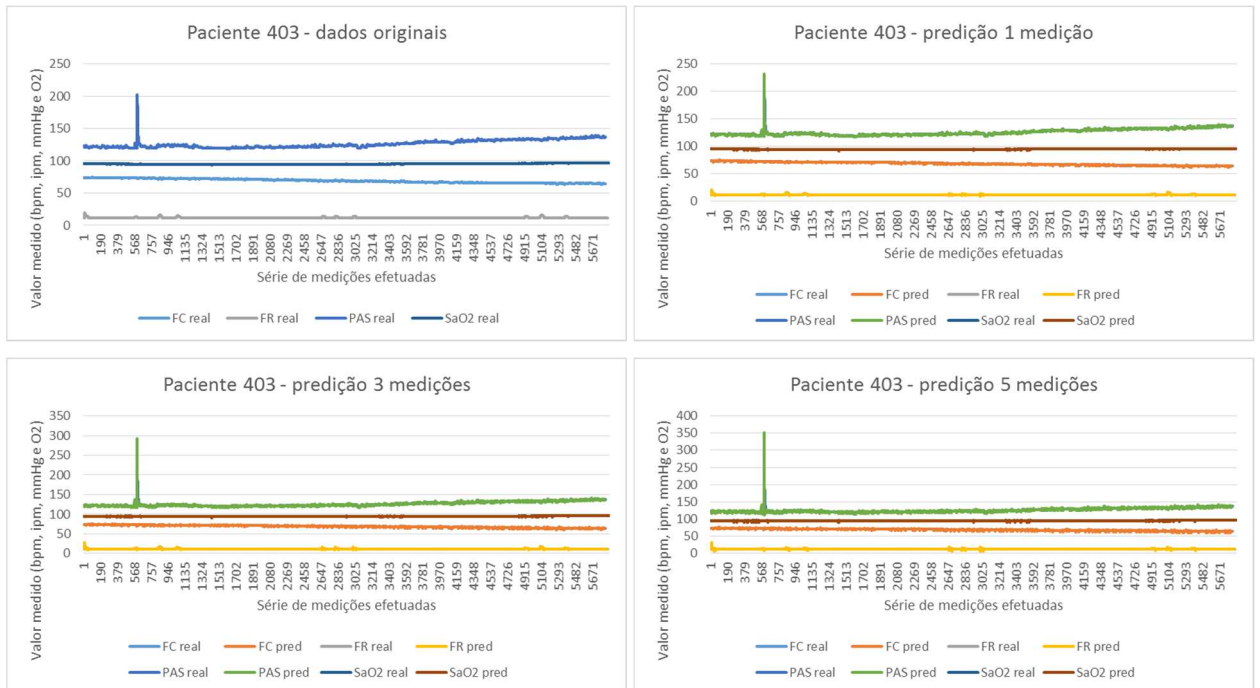
Figura 28. Gráficos resultantes das simulações – paciente “401”



Fonte: elaborado pelo autor

A Figura 29 exibe os gráficos referentes ao paciente “403”. Este é o paciente mais estável, que apesar de estar com a pressão arterial sistólica alta, apresenta apenas um pico, por volta da medição 600. Neste caso, o índice de falsos positivos é menor que nas situações onde ocorrem grandes oscilações nas medições.

Figura 29. Gráficos resultantes das simulações – paciente “403”



Fonte: elaborado pelo autor

A Tabela 29 exibe a consolidação dos índices de acionamento (totais e corretos), falsos positivos e falsos negativos obtidos referentes a todas as medições de todos os pacientes.

Tabela 29. Consolidação de acionamentos, falsos positivos e falsos negativos – todos os pacientes

Dados	Sinais/Resumo	FC	FR	PAS	SaO ₂
Reais (MIMIC)	Acionamentos	6829	18196	1507	698
Predição de 1 medição	Acionamentos totais	6826 99,96%	17770 97,66%	1491 98,94%	728 104,3%
	Acionamentos corretos	6774 99,19%	17370 95,46%	1452 96,35%	698 100%
	Falsos positivos	52 0,76%	400 2,25%	39 2,62%	30 4,12%
	Falsos negativos	55 0,81%	826 4,65%	55 3,69%	2 0,27%
Predição de 3 medições	Acionamentos totais	6909 101,17%	17583 96,63%	1559 103,45%	806 115,47%
	Acionamentos corretos	6734 98,61%	16424 90,26%	1380 91,57%	692 99,14%
	Falsos positivos	175 2,53%	1159 6,59%	179 11,48%	114 14,14%
	Falsos negativos	95 1,38%	1737 9,88%	125 8,02%	6 0,74%
Predição de 5 medições	Acionamentos totais	7056 103,32%	17835 98,02%	1674 111,08%	911 130,52%
	Acionamentos corretos	6718 98,37%	15749 86,55%	1339 88,85%	685 98,14%
	Falsos positivos	338 4,79%	2086 11,7%	335 20,01%	226 24,81%
	Falsos negativos	111 1,57%	2337 13,1%	165 9,86%	13 1,43%

Fonte: elaborado pelo autor

Pode-se observar que a precisão da predição para a medição seguinte é bastante alta, atingindo mais de 99% no caso da frequência cardíaca e 100% na saturação de oxigênio arterial, ultrapassando 95% nos demais sinais vitais. Além disso, o índice de falsos negativos é consideravelmente baixo, atingindo menos de 1% na frequência cardíaca e na saturação de oxigênio arterial. O índice de falsos positivos também é baixo, embora não tanto quanto o de falsos negativos.

No entanto, predições para três ou mais medições futuras mostram queda na precisão (mesmo que demonstrem valores de acerto relativamente expressivos, com diversos sinais fisiológicos acima de 98%) e aumento do número de falsos negativos e, principalmente, de falsos positivos. Esta discrepância parece ser diretamente proporcional à variação nas leituras dos sinais fisiológicos e não era esperada. Pode-se verificar que os pacientes mais “estáveis”, tais como “230” e “403” possuem melhores resultados na predição. Pacientes com maiores variações, tais como “226” e “248”, mostram índices menos precisos.

De qualquer forma, é possível concluir que, combinando os resultados das predições, seria possível obter, com boa precisão, a antecipação de ocorrências ao Time de Resposta Rápida nos tempos estimados exibidos na tabela 30. Foram desconsiderados resultados de predição com precisão inferior a 90%.

Tabela 30. Tempo estimado de antecipação de ocorrências ao Time de Resposta Rápida

Sinal fisiológico	Predição 1 medição	Predição 3 medições	Predição 5 medições
FC	20seg	1min	1min40seg
FR	1min	3min	5min
PAS	5min	15min	-
SaO ₂	5min	15min	-

Fonte: elaborado pelo autor

6.4 Considerações sobre o capítulo

Além do cenário exposto, que contava com 100 sinais fisiológicos simulados, foram analisados dados provenientes do *dataset* público MIMIC, com mais de 228 mil medições reais de pacientes. Os resultados dos experimentos foram utilizados para a geração de gráficos, onde foram comparadas as tendências dos sinais simulados e reais com os provenientes do processo de predição utilizando regressão linear, bem como suas médias e seus desvios-padrão. Além disso, foram calculados índices referentes aos acionamentos efetuados corretamente, bem como dos valores de falsos positivos e falsos negativos. Foram obtidos bons resultados com a predição para a medição seguinte, proporcionando boa aproximação entre os dados originais e os resultantes da predição. Nas predições para três e cinco medições futuras, apesar da boa precisão de alguns valores, nota-se a degradação da acuracidade, bem como o aumento dos índices de falsos negativos e, fundamentalmente, de falsos positivos. O próximo capítulo irá pormenorizar as considerações finais da pesquisa.

7 CONSIDERAÇÕES FINAIS

O presente trabalho apresentou o modelo Predictvs, que permite antecipar ações dos times de resposta rápida dos hospitais através do monitoramento dos sinais vitais dos pacientes utilizando escores de alerta precoce e regressão linear. O protótipo desenvolvido mostrou-se, nos cenários apresentados e nas simulações realizadas, um competente instrumento na tarefa de efetuar a análise de sinais vitais, de forma a prevenir ou detectar um eventual colapso dos pacientes e, nos casos pertinentes, enviar os devidos alertas ao Time de Resposta Rápida. A Tabela 31 compara as principais características do modelo Predictvs com os trabalhos relacionados estudados e descritos no Capítulo 3.

Tabela 31. Contribuições do modelo Predictvs

Características		Trabalhos					
		Kirkland et al., 2013	Brady et al., 2013	Kyriacos et al., 2014	Badriyah et al., 2013	Bailey et al., 2013	Predictvs
Técnica utilizada		Escala de Braden Semi-Markov	Algoritmo de ciência de situação	Sistema de escores <i>Thresholds</i>	Árvore de decisão	Regressão logística	Regressão linear
Variáveis utilizadas no escopo do trabalho	Pressão sistólica	Sim	Não	Sim	Sim	Sim	Sim
	Pressão diastólica	Sim	Não	Não	Sim	Sim	Sim
	Frequência cardíaca	Sim	Não	Sim	Sim	Sim	Sim
	Índice de choque	Sim	Não	Não	Não	Sim	Sim
	Frequência respiratória	Sim	Não	Sim	Sim	Sim	Sim
	Frequência do pulso	Não	Não	Não	Sim	Não	Sim
	Temperatura	Sim	Não	Sim	Sim	Não	Sim
	Saturação O ₂	Sim	Não	Sim	Sim	Sim	Sim
	Nível de consciência	Não	Não	Sim	Sim	Não	Sim
	Fatores de risco	Não	Sim	Não	Não	Não	Sim
	Escala de Braden	Sim	Não	Não	Não	Não	Sim
	Medição do nível de urina	Não	Não	Sim	Não	Não	Sim
Suporte computacional		Não	Sim	Não	Sim	Sim	Sim
Faz uso de ciência de situação		Não	Sim	Não	Não	Não	Sim
Padrões utilizados		Baseado em EWS	EWS e PEWS	MEWS	NEWS e DTEWS	Atribuição de escores	Qualquer EWS
Elaboração de protótipo		Não	Não	Não	Não	Sim	Sim
Relaciona-se com RRTs		Não	Não	Não	Não	Não	Sim

Fonte: elaborado pelo autor

Com a análise dos trabalhos relacionados, observou-se que nenhum deles se relaciona com times de resposta rápida e somente um deles utiliza alguma técnica de processamento em tempo real para efetuar a predição da deterioração clínica de pacientes. O modelo Predictvs preenche essas lacunas, permitindo o uso de diversos tipos de escore de alerta precoce e o uso de praticamente qualquer tipo de sinal vital mensurado para efetuar a predição e acionamento

dos times de resposta rápida. Além disso, como o fator tempo é extremamente relevante, o modelo atua em duas frentes, reativa e proativa, de forma a explorar as melhores características de ambos os contextos.

A predição com o uso da regressão linear mostrou melhores resultados quando os pacientes exibiam menor variação nas medições dos sinais vitais, algo que não era previsto. Oscilações com maior frequência ampliavam os índices, principalmente, de falsos positivos. De qualquer forma, como o modelo é reativo e proativo, isto não implica em deficiência nas notificações e alertas destinados ao Time de Resposta Rápida. A avaliação mostra que, aos primeiros indícios de degradação dos sinais fisiológicos, o Time de Resposta Rápida é devidamente avisado.

Além disso, este trabalho procura contribuir com uma questão chave que vem à tona durante os atendimentos de urgência e emergência, que são os tempos de resposta. Qualquer possibilidade de melhoria neste quesito, permitindo a antecipação de eventuais colapsos, pode representar o salvamento de vidas. O sucesso na adoção dos times de resposta rápida nas instituições de saúde (ANGEL et al., 2016; JUNG et al., 2016) demonstra a relevância deste tema.

O artigo "Um modelo proativo de ações de times de resposta rápida baseado em análise preditiva", escrito com base no presente trabalho, foi submetido e aceito no 8º SBCUP - Simpósio Brasileiro de Computação Ubíqua e Pervasiva, evento satélite do XXXVI Congresso da Sociedade Brasileira de Computação e foi apresentado no dia 07 de julho de 2016.

7.1 Trabalhos futuros

Em relação a trabalhos futuros, pretende-se combinar outros métodos de predição ao modelo, de forma a considerar variações e características inerentes ao tipo de sinal fisiológico medido. Outra possibilidade seria considerar o auxílio de profissionais da área da saúde para efetuar alguma relação dos sinais fisiológicos do paciente entre si, de forma a verificar se haveria alguma melhora nos índices de precisão da predição. Indo um pouco além, poderia ser testada a relação entre sinais fisiológicos de diferentes pacientes. Entretanto, teria de ser avaliado, também, se tal melhoria não comprometeria o tempo de processamento dispendido em cada predição, que no estágio atual, é pequeno. Tomando como exemplo uma máquina modesta, com processador Intel Core i3 2330M e 16GB de RAM, foi possível executar mais de mil predições por segundo com o protótipo desenvolvido.

Deve ser considerada a possibilidade de implementação de mecanismos de autenticação e criptografia nos dados que trafegam entre os módulos. Como o protótipo implementado tinha por finalidade a avaliação do modelo Predictvs, estes aspectos não foram levados em conta neste momento.

Pode ser cogitada, também, a implantação de um mecanismo de *heartbeat* do módulo coletor, de forma a detectar eventual indisponibilidade do mesmo, permitindo que outro dispositivo assumira, de forma dinâmica, as suas funções.

Por fim, nem todos os sinais fisiológicos podem ser medidos com o uso de sensores. O nível de consciência, por exemplo, é medido através da interação do profissional de saúde com o paciente, que atribui uma nota ao mesmo de acordo com sua resposta a estímulos (por exemplo, se está alerta, se reage à voz, se reage a dor, entre outros). Desta forma, como um trabalho futuro, pode-se pensar em desenvolver um painel que permita auferir o nível de consciência do paciente e automaticamente lhe atribuir um escore. Este painel consistiria em demandar ao paciente a resposta a determinados estímulos. Obviamente, estudos aprimorados

devem ser conduzidos, com a participação obrigatória de profissionais de saúde qualificados, de forma a validar esta técnica proposta.

REFERÊNCIAS

- ALVAREZ, C. A. et al. Predicting out of intensive care unit cardiopulmonary arrest or death using electronic medical record data. **BMC medical informatics and decision making**, London, v. 13, n. 1, p. 1, 2013.
- AMEYED, D.; MIRAQUI, M.; TADJ, C. A Survey of Prediction Approach in Pervasive Computing. **International Journal of Scientific & Engineering Research**, Houston, v. 6, n. 5, p. 306-316, 2015.
- ANGEL, Melissa et al. The effects of a rapid response team on decreasing cardiac arrest rates and improving outcomes for cardiac arrests outside critical care areas. **MedSurg Nursing**, New Jersey, v. 25, n. 3, p. 153-159, 2016.
- BADRIYAH, T. et al. Decision-tree early warning score (DTEWS) validates the design of the National Early Warning Score (NEWS). **Resuscitation**, Shannon, v. 85, n. 3, p. 418-423, 2014.
- BAILEY, T. C. et al. A trial of a real-time Alert for clinical deterioration in Patients hospitalized on general medical wards. **Journal of hospital medicine**, Philadelphia, v. 8, n. 5, p. 236-242, 2013.
- BALDAUF, M.; DUSTDAR, S.; ROSENBERG, F. A survey on context-aware systems. **International Journal of Ad Hoc and Ubiquitous Computing**, Olney, v. 2, n. 4, p. 263-277, 2007.
- BANERJEE, S. et al. Secure sensor node with Raspberry Pi. In: **Multimedia, Signal Processing and Communication Technologies (IMPACT), 2013 International Conference on**, Aligarh, 2013. p. 26-30.
- BERWICK, D. M. et al. The 100 000 lives campaign: setting a goal and a deadline for improving health care quality. **Jama**, Chicago, v. 295, n. 3, p. 324-327, 2006.
- BRADY, P. W. et al. Improving situation awareness to reduce unrecognized clinical deterioration and serious safety events. **Pediatrics**, Elk Grove Village, v. 131, n. 1, p. e298-e308, 2013.
- BRIGHAM, K. L. Predictive health: the imminent revolution in health care. **Journal of the American Geriatrics Society**, New York, v. 58, n. s2, p. S298-S302, 2010.
- BROWN, B. B. **Delphi process: A methodology used for the elicitation of opinions of experts**. Santa Monica:Rand Corp, 1968.
- BROWN, I. et al. The ethical challenges of ubiquitous healthcare. **International Review of Information Ethics**, Karlsruhe, v. 8, n. 12, p. 53-60, 2007.
- BURBEY, I.; MARTIN, T. L. A survey on predicting personal mobility. **International Journal of Pervasive Computing and Communications**, Bingley, v. 8, n. 1, p. 5-22, 2012.

- CLIFFORD, Gari D.; SCOTT, Daniel J.; VILLARROEL, Mauricio. User guide and documentation for the MIMIC II database. **MIMIC-II database version**, Cambridge, p. 3-17, 2009.
- DA COSTA, C. A.; YAMIN, A.; GEYER, C. Toward a general software infrastructure for ubiquitous computing. **IEEE Pervasive Computing**, New York, n. 1, p. 64-73, 2008.
- DA ROCHA, C. C. L.; DA COSTA, C. A.; DA ROSA RIGHI, R. Um modelo para monitoramento de sinais vitais do coração baseado em ciência da situação e computação ubíqua. **Anais do 7º SBCUP - Simpósio Brasileiro de Computação Ubíqua e Pervasiva**, Recife, 2015.
- DA ROSA, J. H.; BARBOSA, J. L.V.; RIBEIRO, G. D. ORACON: An adaptive model for context prediction. **Expert Systems with Applications**, Amsterdam, v. 45, p. 56-70, 2016.
- DAMASCENO VIANNA, H.; BARBOSA, J. L.V. A model for ubiquitous care of noncommunicable diseases. **Biomedical and Health Informatics, IEEE Journal of**, Hoes Lane Piscataway, v. 18, n. 5, p. 1597-1606, 2014.
- DE PAIVA, P. et al. A Hierarchical Architecture for Ontology-based Recommender Systems. In: **Computational Intelligence and 11th Brazilian Congress on Computational Intelligence (BRICS-CCI & CBIC), 2013 BRICS Congress on**. IEEE, Recife, 2013. p. 362-367.
- DEVITA, M. A. et al. "Identifying the hospitalised patient in crisis" - A consensus conference on the afferent limb of Rapid Response Systems. **Resuscitation**, Shannon, v. 81, n. 4, p. 375-382, 2010.
- DEY, A. K.; ABOWD, G. D.; SALBER, D. A conceptual framework and a toolkit for supporting the rapid prototyping of context-aware applications. **Human-computer interaction**, Abingdon, v. 16, n. 2, p. 97-166, 2001.
- DOSSOT, D. **RabbitMQ Essentials**. Birmingham:Packt Publishing Ltd, 2014. 182 p.
- ELGAZZAR, K. et al. Ubiquitous health monitoring using mobile web services. **Procedia Computer Science**, Amsterdam, v. 10, p. 332-339, 2012.
- GELOGO, Y. E.; KIM, H. Unified Ubiquitous Healthcare System Architecture with Collaborative Model. **International Journal of Multimedia and Ubiquitous Engineering**, Tasmania, v. 8, n. 3, p. 239-244, 2013.
- GOLDBERGER, A. L. et al. Physiobank, physiokit, and physionet components of a new research resource for complex physiologic signals. **Circulation**, Hagerstown, v. 101, n. 23, p. e215-e220, 2000.
- GONÇALES, P. D. S. et al. Reduced frequency of cardiopulmonary arrests by rapid response teams. **Einstein**. São Paulo, v. 10, n. 4, p. 442-448, 2012.
- HACKMANN, G. et al. Toward a two-tier clinical warning system for hospitalized patients. In: **AMIA Annual Symposium proceedings**. American Medical Informatics Association, Bethesda, 2011. p. 511.

HENDRICH, A. Predicting patient falls. **AJN The American Journal of Nursing**, New York, v. 107, n. 11, p. 50-58, 2007.

HIGHTOWER, J.; BORRIELLO, G. Location systems for ubiquitous computing. **Computer**, Oxford, n. 8, p. 57-66, 2001.

JOHNS, M. M. E.; BRIGHAM, K. L. Transforming health care through prospective medicine: The first step. **Academic Medicine**, Washington, v. 83, n. 8, p. 706, 2008.

JOHNSON, Alistair EW et al. MIMIC-III, a freely accessible critical care database. **Scientific data**, Cambridge, v. 3, 2016.

JONES, B. et al. RabbitMQ Performance and Scalability Analysis. **People at VT Computer Science**, Falls Church, v. 4284.

JONES, D. A.; DEVITA, M. A.; BELLOMO, R. Rapid-response teams. **New England Journal of Medicine**, Massachusetts, v. 365, n. 2, p. 139-146, 2011.

JUNG, Boris et al. Rapid response team and hospital mortality in hospitalized patients. **Intensive care medicine**, Berlin, v. 42, n. 4, p. 494-504, 2016.

KIRKLAND, L. L. et al. A clinical deterioration prediction tool for internal medicine patients. **American Journal of Medical Quality**, Bethesda, v. 28, n. 2, p. 135-142, 2013.

KITCHENHAM, B. Procedures for performing systematic reviews. **Keele**, Staffordshire, v. 33, n. 2004, p. 1-26, 2004.

KOLLEF, M. H. et al. A randomized trial of real-time automated clinical deterioration alerts sent to a rapid response team. **Journal of hospital medicine**, Philadelphia, v. 9, n. 7, p. 424-429, 2014.

KÖNIG, I. et al. Enhancing alignment based context prediction by using multiple context sources: experiment and analysis. In: **Modeling and Using Context**. Springer Berlin Heidelberg, Berlin, 2011. p. 159-172.

KUTNER, M. H. **Applied linear statistical models**. Chicago:Irwin, 1996.

KYRIACOS, U. et al. Monitoring vital signs: development of a modified early warning scoring (MEWS) system for general wards in a developing country. **PloS one**, Cambridge, v. 9, n. 1, p. e87073, 2014.

MAHARAJ, R.; RAFFAELE, I.; WENDON, J. Rapid response systems: a systematic review and meta-analysis. **Critical Care**, London, v. 19, p. 254, 2015.

MAHLER, D. A.; MACKOWIAK, J. I. Evaluation of the short-form 36-item questionnaire to measure health-related quality of life in patients with COPD. **Chest Journal**, Glenview, v. 107, n. 6, p. 1585-1589, 1995.

MCCANNON, C. Joseph; HACKBARTH, Andrew D.; GRIFFIN, Frances A. Miles to go: an introduction to the 5 Million Lives Campaign. **The Joint Commission Journal on Quality and Patient Safety**, Oakbrook Terrace, v. 33, n. 8, p. 477-484, 2007.

- MONK, T. H. et al. Regularity of daily life in relation to personality, age, gender, sleep quality and circadian rhythms. **Journal of sleep research**, Regensburg, v. 3, n. 4, p. 196-205, 1994.
- MOODY, G. B.; MARK, R. G. A database to support development and evaluation of intelligent intensive care monitoring. In: **Computers in Cardiology**, Indianapolis, 1996. p. 657-660.
- MORGAN, R. J. M.; WILLIAMS, F.; WRIGHT, M. M. An early warning scoring system for detecting developing critical illness. **Clinical Intensive Care**, Abingdon, v. 8, n. 2, p. 100, 1997.
- OFFNER, P. J.; HEIT, J.; ROBERTS, R. Implementation of a rapid response team decreases cardiac arrest outside of the intensive care unit. **Journal of Trauma and Acute Care Surgery**, Chicago, v. 62, n. 5, p. 1223-1228, 2007.
- PATTERSON, D. J. et al. Inferring high-level behavior from low-level sensors. In: **UbiComp 2003: Ubiquitous Computing**, Seattle, p. 73-89, 2003.
- PEBERDY, M. Ann et al. Recommended guidelines for monitoring, reporting, and conducting research on medical emergency team, outreach, and rapid response systems: an Utstein-style scientific statement. A scientific statement from the International Liaison Committee on Resuscitation (American Heart Association, Australian Resuscitation Council, European Resuscitation Council, Heart and Stroke Foundation of Canada, InterAmerican Heart Foundation, Resuscitation Council of Southern Africa, and the New Zealand Resuscitation Council ... **Circulation**, Dallas, 2007.
- PEJOVIC, V.; MUSOLESI, M. Anticipatory mobile computing: A survey of the state of the art and research challenges. **ACM Computing Surveys (CSUR)**, New York, v. 47, n. 3, p. 47, 2015.
- RAWAT, P. et al. Wireless sensor networks: a survey on recent developments and potential synergies. **The Journal of supercomputing**, New York, v. 68, n. 1, p. 1-48, 2014.
- ROSTANSKI, M.; GROCHLA, K.; SEMAN, A. Evaluation of highly available and fault-tolerant middleware clustered architectures using RabbitMQ. In: **Computer Science and Information Systems (FedCSIS)**, Warsaw, 2014. p. 879-884.
- SAEED, Mohammed et al. Multiparameter Intelligent Monitoring in Intensive Care II (MIMIC-II): a public-access intensive care unit database. **Critical care medicine**, Mount Prospect, v. 39, n. 5, p. 952, 2011.
- SATYANARAYANAN, M. Pervasive computing: Vision and challenges. **Personal Communications**, New York, v. 8, n. 4, p. 10-17, 2001.
- SCHNEIDER, A.; HOMMEL, G.; BLETTNER, M. Linear Regression Analysis. **Deutsches Ärzteblatt International**, Köln, v. 107, p. 776-782, 2010.
- SIGG, S. **Development of a novel context prediction algorithm and analysis of context prediction schemes**. Kassel:Kassel University Press, 2008.

SKLOOT, G. et al. Respiratory symptoms and physiologic assessment of ironworkers at the World Trade Center disaster site. **Chest Journal**, Glenview, v. 125, n. 4, p. 1248-1255, 2004.

SONI, J. et al. Predictive data mining for medical diagnosis: An overview of heart disease prediction. **International Journal of Computer Applications**, New York, v. 17, n. 8, p. 43-48, 2011.

SRINIVAS, K.; RANI, B. Kavihta; GOVRDHAN, A. Applications of data mining techniques in healthcare and prediction of heart attacks. **International Journal on Computer Science and Engineering (IJCSE)**, Chennai, v. 2, n. 02, p. 250-255, 2010.

SNYDERMAN, R.; YOEDIONO, Z. Perspective: prospective health care and the role of academic medicine: lead, follow, or get out of the way. **Academic Medicine**, Washington, v. 83, n. 8, p. 707-714, 2008.

THE MIMIC Database. Disponível em: <<https://www.physionet.org/physiobank/database/mimicdb/>>. Acesso em: 01 jun. 2016.

VANSYCKEL, S.; BECKER, C.. A survey of proactive pervasive computing.
In: **Proceedings of the 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing: Adjunct Publication**, Seattle, 2014. p. 421-430.

VISWANATHAN, H.; CHEN, B.; POMPILI, Dario. Research challenges in computation, communication, and context awareness for ubiquitous healthcare. **Communications Magazine**, New York, v. 50, n. 5, p. 92-99, 2012.

WACHTER, R. M.; PRONOVOST, P. J. The 100,000 Lives Campaign: a scientific and policy review. **The Joint Commission Journal on Quality and Patient Safety**, Oak Brook, v. 32, n. 11, p. 621-627, 2006.

WANG, S. et al. Analysis of hospital rapid response protocols using simulation.
In: **Automation Science and Engineering (CASE)**, Seoul, 2012. p. 315-322.

WEISER, M. The computer for the 21st century. **Scientific american**, New York, v. 265, n. 3, p. 94-104, 1991.

WEISS, G. M.; HIRSH, H. Learning to predict rare events in categorical time-series data.
In: **Proceedings of the 1998 AAAI/ICML Workshop on Time-Series Analysis**, Madison, 1998.

YU, S. et al. Comparison of risk prediction scoring systems for ward patients: a retrospective nested case-control study. **Critical Care**, London, v. 18, p. R132, 2014.

APÊNDICE A - CONJUNTO DE DADOS UTILIZADOS NA SIMULAÇÃO

1. paciente;data;hora;sinal_fisiologico;valor_medido
2. 1;17/06/2016;20:30:00;fc;85
3. 1;17/06/2016;20:30:05;fr;13
4. 1;17/06/2016;20:30:10;pas;115
5. 1;17/06/2016;20:30:15;temp;37.9
6. 1;17/06/2016;20:30:20;fc;87
7. 1;17/06/2016;20:30:25;fr;13
8. 1;17/06/2016;20:30:30;pas;115
9. 1;17/06/2016;20:30:35;temp;37.9
10. 1;17/06/2016;20:30:40;fc;89
11. 1;17/06/2016;20:30:45;fr;13
12. 1;17/06/2016;20:30:50;pas;115
13. 1;17/06/2016;20:30:55;temp;37.9
14. 1;17/06/2016;20:31:00;fc;92
15. 1;17/06/2016;20:31:05;fr;13
16. 1;17/06/2016;20:31:10;pas;114
17. 1;17/06/2016;20:31:15;temp;37.9
18. 1;17/06/2016;20:31:20;fc;94
19. 1;17/06/2016;20:31:25;fr;12
20. 1;17/06/2016;20:31:30;pas;114
21. 1;17/06/2016;20:31:35;temp;37.9
22. 1;17/06/2016;20:31:40;fc;96
23. 1;17/06/2016;20:31:45;fr;12
24. 1;17/06/2016;20:31:50;pas;113
25. 1;17/06/2016;20:31:55;temp;37.9
26. 1;17/06/2016;20:32:00;fc;98
27. 1;17/06/2016;20:32:05;fr;12
28. 1;17/06/2016;20:32:10;pas;113
29. 1;17/06/2016;20:32:15;temp;37.9
30. 1;17/06/2016;20:32:20;fc;100
31. 1;17/06/2016;20:32:25;fr;12
32. 1;17/06/2016;20:32:30;pas;112
33. 1;17/06/2016;20:32:35;temp;37.9
34. 1;17/06/2016;20:32:40;fc;101
35. 1;17/06/2016;20:32:45;fr;11
36. 1;17/06/2016;20:32:50;pas;110
37. 1;17/06/2016;20:32:55;temp;37.9
38. 1;17/06/2016;20:33:00;fc;103
39. 1;17/06/2016;20:33:05;fr;11
40. 1;17/06/2016;20:33:10;pas;108
41. 1;17/06/2016;20:33:15;temp;37.9
42. 1;17/06/2016;20:33:20;fc;105
43. 1;17/06/2016;20:33:25;fr;11
44. 1;17/06/2016;20:33:30;pas;108
45. 1;17/06/2016;20:33:35;temp;38.1
46. 1;17/06/2016;20:33:40;fc;107
47. 1;17/06/2016;20:33:45;fr;11
48. 1;17/06/2016;20:33:50;pas;106
49. 1;17/06/2016;20:33:55;temp;38.3
50. 1;17/06/2016;20:34:00;fc;109
51. 1;17/06/2016;20:34:05;fr;10
52. 1;17/06/2016;20:34:10;pas;106
53. 1;17/06/2016;20:34:15;temp;38.3
54. 1;17/06/2016;20:34:20;fc;110
55. 1;17/06/2016;20:34:25;fr;10
56. 1;17/06/2016;20:34:30;pas;104
57. 1;17/06/2016;20:34:35;temp;38.4
58. 1;17/06/2016;20:34:40;fc;110
59. 1;17/06/2016;20:34:45;fr;10

60. 1;17/06/2016;20:34:50;pas;102
 61. 1;17/06/2016;20:34:55;temp;38.5
 62. 1;17/06/2016;20:35:00;fc;110
 63. 1;17/06/2016;20:35:05;fr;9
 64. 1;17/06/2016;20:35:10;pas;100
 65. 1;17/06/2016;20:35:15;temp;38.5
 66. 1;17/06/2016;20:35:20;fc;111
 67. 1;17/06/2016;20:35:25;fr;9
 68. 1;17/06/2016;20:35:30;pas;99
 69. 1;17/06/2016;20:35:35;temp;38.5
 70. 1;17/06/2016;20:35:40;fc;112
 71. 1;17/06/2016;20:35:45;fr;9
 72. 1;17/06/2016;20:35:50;pas;98
 73. 1;17/06/2016;20:35:55;temp;38.7
 74. 1;17/06/2016;20:36:00;fc;113
 75. 1;17/06/2016;20:36:05;fr;8
 76. 1;17/06/2016;20:36:10;pas;97
 77. 1;17/06/2016;20:36:15;temp;38.8
 78. 1;17/06/2016;20:36:20;fc;113
 79. 1;17/06/2016;20:36:25;fr;8
 80. 1;17/06/2016;20:36:30;pas;96
 81. 1;17/06/2016;20:36:35;temp;38.9
 82. 1;17/06/2016;20:36:40;fc;113
 83. 1;17/06/2016;20:36:45;fr;8
 84. 1;17/06/2016;20:36:50;pas;95
 85. 1;17/06/2016;20:36:55;temp;38.9
 86. 1;17/06/2016;20:37:00;fc;114
 87. 1;17/06/2016;20:37:05;fr;7
 88. 1;17/06/2016;20:37:10;pas;94
 89. 1;17/06/2016;20:37:15;temp;39
 90. 1;17/06/2016;20:37:20;fc;114
 91. 1;17/06/2016;20:37:25;fr;7
 92. 1;17/06/2016;20:37:30;pas;94
 93. 1;17/06/2016;20:37:35;temp;39
 94. 1;17/06/2016;20:37:40;fc;115
 95. 1;17/06/2016;20:37:45;fr;7
 96. 1;17/06/2016;20:37:50;pas;93
 97. 1;17/06/2016;20:37:55;temp;39
 98. 1;17/06/2016;20:38:00;fc;115
 99. 1;17/06/2016;20:38:05;fr;7
 100. 1;17/06/2016;20:38:10;pas;92
 101. 1;17/06/2016;20:38:15;temp;39.1

O *dataset* listado abaixo foi utilizado para avaliação da predição com o uso de regressão linear, com o uso do protótipo detalhado no Capítulo 5:

1. *The MIMIC database*

Autores: GOLDBERGER et al., 2000

Disponível em: <https://www.physionet.org/physiobank/database/mimicdb/>

Dados dos pacientes disponíveis em: <https://physionet.org/pn2/mimicdb/>

Dados resultantes do processamento disponíveis em: <http://www.predictvs.com.br/dados>

ANEXO A - ARTIGOS PUBLICADOS

O artigo "Um modelo proativo de ações de times de resposta rápida baseado em análise preditiva", escrito com base no presente trabalho, foi submetido e aceito no 8º SBCUP - Simpósio Brasileiro de Computação Ubíqua e Pervasiva, evento satélite do XXXVI Congresso da Sociedade Brasileira de Computação e foi apresentado no dia 07 de julho de 2016.