



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

---

Mestrado Acadêmico

Gabriel Souto Fischer

ElHealth :  
Utilizando Internet das Coisas e Predição Computacional para  
Gerenciamento Elástico de Recursos Humanos em Hospitais  
Inteligentes

São Leopoldo  
2019



Gabriel Souto Fischer

**ELHEALTH:  
Utilizando Internet das Coisas e Predição Computacional para Gerenciamento Elástico  
de Recursos Humanos em Hospitais Inteligentes**

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

Orientador:  
Prof. Dr. Rodrigo da Rosa Righi

São Leopoldo  
2019

F529e

Fischer, Gabriel Souto.

Elhealth : utilizando internet das coisas e predição computacional para gerenciamento elástico de recursos humanos em hospitais inteligentes / Gabriel Souto Fischer. – 2019.

143 f. : il. ; 30 cm.

Dissertação (mestrado) – Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Computação Aplicada, 2019.

“Orientador: Prof. Dr. Rodrigo da Rosa Righi.”

1. Internet das coisas. 2. Saúde. 3. Hospitais inteligentes. 4. Predição computacional. 5. Sensores. I. Título.

CDU 004

Dados Internacionais de Catalogação na Publicação (CIP)  
(Bibliotecária: Amanda Schuster – CRB 10/2517)

Gabriel Souto Fischer

ElHealth :

Utilizando Internet das Coisas e Predição Computacional para Gerenciamento Elástico de Recursos Humanos em Hospitais Inteligentes

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 28/02/2019

BANCA EXAMINADORA

---

Prof. Dr. Rodrigo da Rosa Righi - UNISINOS

---

Prof. Dr. Cristiano André da Costa - UNISINOS

---

Prof. Dr. Alberto Egon Schaeffer Filho - UFRGS

Prof. Dr. Rodrigo da Rosa Righi (Orientador)

Visto e permitido a impressão  
São Leopoldo,

Prof. Dr. Rodrigo da Rosa Righi  
Coordenador do PPG em Computação Aplicada



## **AGRADECIMENTOS À CAPES**

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001





A minha família.

*Our greatest weakness lies in giving up.  
The most certain way to succeed is always to try just one more time.  
(Nossa maior fraqueza está em desistir.  
O caminho mais seguro para o sucesso é sempre tentar apenas uma vez mais.)*  
— THOMAS A. EDISON



## AGRADECIMENTOS

Neste momento estou percorrendo mais uma etapa da minha vida, que é o fim de meu mestrado acadêmico e a entrega de minha dissertação. Foram muitos anos de luta e dedicação, com diversos desafios vencidos e perdidos para chegar até aqui. Diversos momentos de conciliação entre família, amigos, estudos e trabalho. Então não posso deixar de agradecer a todos aqueles que foram importantes para mim nessa jornada, estando ao meu lado, me ajudando e me compreendendo em todos os momentos difíceis do caminho.

Primeiramente, agradeço a Deus pelo dom da vida e por todas as coisas boas que já aconteceram e que ainda vão acontecer em minha vida.

Agradeço a meus pais, Carlos e Ireni, pela paciência, carinho, compreensão, em todos os momentos de minha vida, sobretudo durante minha formação acadêmica, e principalmente durante a escrita de minha monografia da graduação e dessa dissertação. Mas não apenas por isso, agradeço-os pelo apoio emocional em todos os momentos de minha vida e pelo amor incondicional recebido por eles. Agradeço a eles por sempre apoiarem e incentivarem os meus estudos.

Agradeço a meu irmão Gustavo, por ser simplesmente ele, por tornar mais engraçados momentos de frustração e por me ajudar a rir em qualquer situação. Agradeço a ele por constantemente me lembrar da criança que ainda existe dentro de mim.

Agradeço a minha esposa Michelle, por estar ao meu lado durante os últimos anos, me ajudando, me incentivando e me compreendendo. Mas não apenas por isso, também agradeço a ela pelo apoio emocional, estando ao meu lado nos momentos felizes e me apoiando incondicionalmente nos momentos tristes. Não posso deixar de agradecer-lá por todos os momentos felizes que vivemos no último ano, principalmente o nosso casamento. E por fim, quero agradecer-lá pelo apoio durante a escrita dessa dissertação. Suas palavras de incentivo foram extremamente importantes para mim e me ajudaram a continuar durante todo o processo.

Agradeço aos meus amigos, que em muitos momentos foram deixados de lado em função das inúmeras atividades acadêmicas aos quais tive que realizar, principalmente a escrita de minha dissertação, e por sempre estarem ao meu lado, rindo comigo nos bons momentos e me apoiando nos momentos ruins.

Agradeço a todos os professores do Programa de Pós-Graduação em Computação Aplicada, e principalmente a meu orientador Rodrigo da Rosa Righi que através de sua dedicação, incentivo e compreensão contribuiu muito para o desenvolvimento deste trabalho. Também quero deixar meu agradecimento aos professores Cristiano André da Costa e Gustavo Pessin que contribuíram positivamente para essa dissertação.

Agradeço também às seguintes agências brasileiras que apoiaram parcialmente este trabalho: CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico), FAPERGS (Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul) e CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior).

Por fim, agradeço a todos que direta ou indiretamente me ajudaram na minha jornada, tanto acadêmica, como pessoal, e também profissional.



*“O sucesso nasce do querer, da determinação e persistência em se chegar a um objetivo.  
Mesmo não atingindo o alvo, quem busca e vence obstáculos, no mínimo fará coisas  
admiráveis”.*  
(José de Alencar)



## RESUMO

Os hospitais são pontos de atendimento extremamente importantes para garantir o tratamento adequado da saúde humana. Um dos principais problemas a serem enfrentados são as filas de atendimento aos pacientes cada vez mais superlotadas, que fazem com que os pacientes fiquem cada vez mais tempo com problemas de saúde sem tratamento adequado. A alocação de profissionais de saúde em ambientes hospitalares não é capaz de se adaptar à demanda de pacientes, e há momentos em que salas com pouco uso têm profissionais ociosos, e salas com muito uso acabam tendo menos profissionais do que o necessário. Os trabalhos anteriores acabam não resolvendo o problema, uma vez que se concentram em maneiras de automatizar o tratamento da saúde, mas não em técnicas para melhorar a alocação de recursos humanos disponíveis. Neste contexto, o presente trabalho propõe o EIHealth, um modelo focado na IoT capaz de identificar o uso das salas pelos pacientes e, através de técnicas de predição computacional, identificar quando uma sala terá uma demanda que excede a capacidade de atendimento, propondo ações para movimentar os recursos humanos para se adaptar à demanda futura de pacientes. As principais contribuições do EIHealth são a definição da **Elasticidade Preditiva Multinível de Recursos Humanos**, uma extensão do conceito de elasticidade de recursos em *Cloud Computing* para gerenciar o uso de recursos humanos em diferente níveis de um ambiente hospitalar, e a definição do **Speedup Elástico Proativo de Recursos Humanos**, uma extensão do conceito de Speedup da computação paralela para identificar o ganho de tempo de atendimento com o uso paralelo dinâmico de recursos humanos para atendimento em um ambiente hospitalar. O EIHealth foi simulado em ambiente hospitalar utilizando dados de uma policlínica brasileira e obteve resultados promissores, sendo capaz de diminuir a quantidade média de pacientes aguardando e reduzir o tempo de espera por atendimento no ambiente proposto.

**Palavras-chave:** Internet das Coisas. Saúde. Hospitais Inteligentes. Predição Computacional. Sensores. Sistemas Distribuídos. Recursos Humanos. Elasticidade.





## ABSTRACT

Hospitals are extremely important care points for ensuring the proper treatment of human health. One of the main problems to be faced is the increasingly overcrowded patient care queues, who end up getting more and more time with health problems without proper treatment. The allocation of health professionals in hospital environments is not able to adapt to the demands of patients, and there are times when rooms with little use have idle professionals, and rooms with a lot of use having fewer professionals than necessary. Previous works end up not solving the problem since they focus on ways to automate the treatment of health, but not on techniques for better allocating available human resources. Against this background, the present work proposes EIHealth, an IoT-focused model able to identify patients' use of the rooms and, through data prediction techniques, to identify when a room will have a demand that exceeds the capacity of care, proposing actions to move human resources to adapt to future patients demand. The main contribution of EIHealth is the definition of **Multi-level Predictive Elasticity of Human Resources**, an extension of the concept of resource elasticity in *Cloud Computing* to manage the use of human resources at different levels of a healthcare environment, and the definition of **Proactive Human Resource Elastic Speedup**, an extension of the Speedup concept of parallel computing to identify the gain of medical care time with the dynamic parallel use of human resources for care in a hospital environment. EIHealth was simulated a hospital environment using data from a Brazilian polyclinic, and obtained promising results, being able to decrease the average number of patients waiting, and reduce waiting time for care in the proposed environment.

**Keywords:** Internet of Things. Health. Smart Hospitals. Data Prediction. Sensors. Distributed Systems. Human Resources. Elasticity.



## LISTA DE FIGURAS

Figura 1 – Imagem conceitual do paradigma de Internet das Coisas . . . . .	33
Figura 2 – Um exemplo de problema seria a superlotação dos Hospitais . . . . .	34
Figura 3 – Exemplo de cenário em que profissionais de saúde são alocados de maneira estática, onde existem dois setores, medicação e exames. Nesse exemplo, existem mais atendentes para exames do que para medicação, ao contrário da demanda de pacientes que é maior para a sala de medicação . . . . .	36
Figura 4 – Componentes do Sistema RFID . . . . .	40
Figura 5 – Exemplo de um Código de Produto Eletrônico de 96 bits (96-bit EPC) . . . . .	44
Figura 6 – O Sistema de Triagem de Manchester . . . . .	48
Figura 7 – Elasticidade Vertical e Horizontal . . . . .	52
Figura 8 – Configuração da Elasticidade de Recursos . . . . .	53
Figura 9 – Escopo da Elasticidade de Recursos . . . . .	54
Figura 10 – Objetivos da Elasticidade de Recursos . . . . .	55
Figura 11 – Métodos da Elasticidade de Recursos . . . . .	56
Figura 12 – Arquitetura da Elasticidade de Recursos . . . . .	57
Figura 13 – Provedor da Elasticidade de Recursos . . . . .	57
Figura 14 – Modos da Elasticidade de Recursos . . . . .	58
Figura 15 – Ambiente hospitalar com: (A) uma paciente em atendimento utilizando uma pulseira- <i>tag</i> de identificação e (B) uma profissional da saúde com crachá- <i>tag</i> . . . . .	72
Figura 16 – Elasticidade preditiva baseada no tempo estimado de espera adotado pelo EIHealth . . . . .	73
Figura 17 – Componentes e visão da rede no modelo EIHealth . . . . .	74
Figura 18 – Detalhamento da Arquitetura . . . . .	75
Figura 19 – Fluxo de Dados do modelo EIHealth . . . . .	79
Figura 20 – Calculando o Número Médio de Atendentes em uma sala do hospital entre os instantes de tempo 1 e 5, onde a cada instante de tempo a quantidade de atendentes alocados é alterada, chegando a um número médio de 3 atendentes alocados nessa sala hipotética entre os instantes de tempo . . . . .	82
Figura 21 – Calculando o Tempo Estimado de Atendimento em uma sala do hospital com 4 pacientes aguardando e tempo médio de atendimento de 10 minutos, chegando ao Tempo Estimado de Atendimento de 40 minutos . . . . .	83
Figura 22 – Calculando o tempo estimado de atendimento em uma sala do hospital usando alocação paralela de atendentes, com 4 pacientes aguardando, tempo médio de atendimento de 10 minutos e 2 atendentes, chegando ao tempo estimado de atendimento, através do Speedup Elástico de Recursos Humanos, de 20 minutos . . . . .	84
Figura 23 – Fluxograma de processos a Nível Local para verificar a possibilidade de alocar ou liberar recursos humanos em uma sala qualquer do hospital inteligente . . . . .	87
Figura 24 – Realocação através do algoritmo <i>Round Robin</i> adaptado, com uma fila de 4 salas, e 12 atendentes, onde foi previsto que a Sala 1 precisa alocar 5 atendentes . . . . .	89

Figura 25 – Realocação através do algoritmo <i>List Scheduling</i> adaptado, com uma lista de 4 salas, ordenada pela quantidade de recursos humanos disponíveis para elasticidade, e 12 atendentes, onde foi previsto que a Sala 1 precisa alocar mais 5 profissionais da saúde . . . . .	91
Figura 26 – Exemplo de Alocação, com uma lista de 4 salas, 12 atendentes em atendimento, e 3 profissionais disponíveis para alocação, onde foi previsto que a Sala 1 precisa alocar mais 5 recursos humanos . . . . .	93
Figura 27 – Classificações do modelo ElHealth para os atributos propostos por Al-Dhuraibi et al. (2017) . . . . .	97
Figura 28 – Fluxo de atendimento do ambiente hospitalar . . . . .	102
Figura 29 – Imagem da planta teórica desenvolvida . . . . .	105
Figura 30 – Representação gráfica dos padrões de carga utilizados na avaliação do ElHealth . . . . .	107
Figura 31 – Representação gráfica de um exemplo de alocação de recursos humanos ao longo do tempo de atendimento no ambiente hospitalar com e sem o uso do modelo ElHealth, onde no Hospital Atual têm-se $M2 = 10$ atendentes e no Hospital Inteligente têm-se $M2 = 8,75$ atendentes . . . . .	108
Figura 32 – Leitor RFID Intermec IF2 instalado no laboratório de Internet das Coisas e Aplicações Distribuídas do PPGCA da Universidade do Vale do Rio dos Sinos onde em (A) a antena foi instalada acima da porta e em (B) a antena foi instalada ao lado da porta . . . . .	110
Figura 33 – Instalação proposta das antenas do leitor Intermec IF2 em dois cenários: (A) com uma porta simples e (B) com uma porta dupla, onde em ambos os exemplos as portas possuem 2,1 metros de altura . . . . .	111
Figura 34 – Instante de tempo em que foi identificada a necessidade de alocação de dois novos médicos nos consultórios médicos . . . . .	114
Figura 35 – Instante de tempo em que foi identificada a necessidade de realocação de um enfermeiro da sala de medicação para a sala de eletrocardiograma . . . . .	114
Figura 36 – Tempo máximo de espera registrado no hospital com os diferentes padrões de carga para o Cenário C1, sem o uso da Elasticidade Preditiva Multinível de Recursos Humanos . . . . .	115
Figura 37 – Tempo máximo de espera registrado no hospital com os diferentes padrões de carga para o Cenário C2, com o uso parcial da Elasticidade Preditiva Multinível de Recursos Humanos . . . . .	116
Figura 38 – Tempo máximo de espera registrado no hospital com os diferentes padrões de carga para o Cenário C3, com o uso completo da Elasticidade Preditiva Multinível de Recursos Humanos . . . . .	117
Figura 39 – Tempo máximo de espera registrado no hospital para cada um dos cenários propostos utilizando os padrões de carga (A) Constante, (B) Crescente, (C) Decrescente e (D) Onda . . . . .	118
Figura 40 – Tempo máximo de espera registrado no hospital com os diferentes padrões de carga para o Cenário C3, com o uso completo da Elasticidade Preditiva Multinível de Recursos Humanos . . . . .	120

Figura 41 – Custo de atendimento por hora no hospital com os diferentes padrões de carga para o Cenário C1, sem o uso da Elasticidade Preditiva Multinível de Recursos Humanos . . . . .	121
Figura 42 – Custo de atendimento por hora no hospital com os diferentes padrões de carga para o Cenário C2, com o uso parcial da Elasticidade Preditiva Multinível de Recursos Humanos . . . . .	122
Figura 43 – Custo de atendimento por hora no hospital com os diferentes padrões de carga para o Cenário C3, com o uso completo da Elasticidade Preditiva Multinível de Recursos Humanos . . . . .	122
Figura 44 – Custo de atendimento por hora calculado no hospital para cada um dos cenários propostos utilizando os padrões de carga (A) Constante, (B) Crescente, (C) Decrescente e (D) Onda . . . . .	123
Figura 45 – Quantidade média de pacientes no hospital com os diferentes padrões de carga para o Cenário C1, sem o uso da Elasticidade Preditiva Multinível de Recursos Humanos . . . . .	125
Figura 46 – Quantidade média de pacientes no hospital com os diferentes padrões de carga para o Cenário C2, com o uso parcial da Elasticidade Preditiva Multinível de Recursos Humanos . . . . .	125
Figura 47 – Quantidade média de pacientes no hospital com os diferentes padrões de carga para o Cenário C3, com o uso completo da Elasticidade Preditiva Multinível de Recursos Humanos . . . . .	126
Figura 48 – Quantidade média de pacientes no hospital para cada um dos cenários propostos utilizando os padrões de carga (A) Constante, (B) Crescente, (C) Decrescente e (D) Onda . . . . .	127
Figura 49 – Área de leitura de <i>tags</i> -RFID em torno da antena do leitor Intermec IF2 . . . . .	129
Figura 50 – Área de leitura frontal de <i>tags</i> -RFID da antena do leitor Intermec IF2 . . . . .	129
Figura 51 – Instalação proposta das antenas do leitor Intermec IF2 em dois cenários: (A) com uma porta simples e (B) com uma porta dupla, onde em ambos os exemplos as portas possuem 2,1 metros de altura . . . . .	130



## LISTA DE TABELAS

Tabela 1 – Comparação entre as Tecnologias NFC, Bluetooth e Zigbee . . . . .	43
Tabela 2 – Comparativo de características entre código de barras e RFID EPC . . . . .	44
Tabela 3 – Trabalhos selecionados . . . . .	62
Tabela 4 – Trabalhos selecionados . . . . .	69
Tabela 5 – Nomenclaturas para os formalismos matemáticos do modelo EIHealth . . . . .	81
Tabela 6 – Distribuições triangulares de probabilidade para tempos de atendimento . . . . .	103
Tabela 7 – <i>Thresholds</i> de tempo para Gerenciamento de Elasticidade do modelo EIHealth . . . . .	104
Tabela 8 – Funções para expressar os diferentes comportamento de carga. Em $carga(x)$ , $x$ é o instante de tempo que será realizada a entrada de pacientes . . . . .	106
Tabela 9 – Métricas para Avaliação e resultados esperados em cada um dos cenários propostos . . . . .	109
Tabela 10 – Combinações possíveis de padrões de carga e cenários para simulação do modelo EIHealth . . . . .	113
Tabela 11 – Maior tempo de espera e média dos maiores tempos de espera registrados em cada padrão de carga nos cenários propostos . . . . .	118
Tabela 12 – Diminuição do tempo de espera em cada padrão de carga entre os cenários propostos . . . . .	119
Tabela 13 – Quantidade elástica de Recursos Humanos utilizados em cada padrão de carga nos cenários propostos . . . . .	120
Tabela 14 – Custo médio de atendimento em cada padrão de carga nos cenários propostos . . . . .	123
Tabela 15 – Diminuição do custo total de atendimento para cada padrão de carga entre os cenários propostos . . . . .	124
Tabela 16 – Quantidade média de pessoas aguardando em um mesmo intervalo de tempo em cada padrão de carga nos cenários propostos . . . . .	127
Tabela 17 – Diminuição da quantidade média de pacientes aguardando para cada padrão de carga entre os cenários propostos . . . . .	128
Tabela 18 – Métricas para avaliação e resultados encontrados em cada um dos cenários propostos, utilizando os padrões de carga Constante, Crescente, Decrescente e Onda . . . . .	131





## LISTA DE ALGORITMOS

Algoritmo 1 – ElHealth_Capture . . . . .	76
Algoritmo 2 – ElHealth_Formatter . . . . .	77
Algoritmo 3 – ElHealth_Predict . . . . .	78
Algoritmo 4 – Elasticidade Preditiva a Nível Local . . . . .	86
Algoritmo 5 – Realocação através do algoritmo <i>Round Robin</i> adaptado . . . . .	88
Algoritmo 6 – Realocação através do algoritmo <i>List Scheduling</i> adaptado . . . . .	90
Algoritmo 7 – Alocação de novos Recursos Humanos . . . . .	92
Algoritmo 8 – Definição de Recursos Humanos disponíveis para Alocação . . . . .	95
Algoritmo 9 – Desalocação de Recursos Humanos . . . . .	95



## LISTA DE ABREVIATURAS

Aprox.	Aproximadamente
cm	centímetro, -s
Dr.	Doutor, -a
m	metro, -s
Prof.	Professor, -a
s	segundo, -s
/s	por segundo
Unisinos	Universidade do Vale do Rio dos Sinos
Wi-Fi	Wireless Fidelity



## LISTA DE SIGLAS

ACM	Association for Computing Machinery
ADT	Admission, Discharge and Transfer
API	Application Programming Interface
AR	Auto-Regressivo
ARIMA	Auto-Regressive Integrated Moving Average
ARMA	Auto-Regressive and Moving Average
BLE	Bluetooth Low Energy
CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
CPU	Central Process Unit
CNPq	Conselho Nacional de Desenvolvimento Científico e Tecnológico
DMP	Distributed Movement Prediction
EPC	Electronic Product Code
FAPERGS	Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul
GARCH	Generalized Auto Regressive Conditional Heteroskedasticity
GBM	Gradient Boosted Machines
GIS	Geographic Information System
GNSS	Global Navigation Satellite System
GPS	Global Positioning System
GPU	Graphic Process Unit
HIS	Hospital Information Systems
HRLS	Human Resource List Scheduling
IaaS	Infrastructure as a Service
IEC	International Electrotechnical Commission
IEEE	Institute of Electrical and Electronics Engineers
IET	Institution of Engineering and Technology
IoT	Internet of Things
IP	Internet Protocol
ISO	International Organization for Standardization
MA	Moving Average
MIT	Massachusetts Institute of Technology
NFC	Near Field Communication
P2P	Peer-to-Peer
PaaS	Platform as a Service

PPGCA	Programa de Pós-Graduação em Computação Aplicada
QoE	Quality of Experience
QoS	Quality of Service
RAM	Random Access Memory
RAS	Ressource Allocation Strategy
RH	Recursos Humanos
RFID	Radio Frequency Identification
RIS	Radiology Information System
RSS	Received Signal Strength
RSSI	Received Signal Strength Indicator
RTLS	Real-Time Location System
SMO	Sequential Minimal Optimization
SQL	Structured Query Language
SD	System Dynamics
SSD	Solid-State Drive
SVM	Support Vector Machines
SVR	Support Vector Regression
STM	Sistema de Triagem de Manchester
TI	Threshold Inferior
TS	Threshold Superior
UWB	Ultra Wide Band
VM	Virtual Machine
WPAN	Wireless Personal Area Networks
WSN	Wireless Sensor Network

## LISTA DE SÍMBOLOS

GHz	GigaHertz
GB	Gigabytes
MHz	MegaHertz
Mbps	Megabits por segundos





## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>33</b>
1.1	Definição do Problema	34
1.2	Questão de Pesquisa	36
1.3	Objetivos	37
1.4	Organização do Texto	38
<b>2</b>	<b>REFERENCIAL TEÓRICO</b>	<b>39</b>
2.1	Internet das Coisas	39
2.1.1	Tecnologias Utilizadas para Internet das Coisas	39
2.1.2	Padrão EPC (Electronic Product Code)	43
2.1.3	Real-Time Location Systems	45
2.2	Processos Hospitalares	47
2.2.1	Ambulatório e Emergência	47
2.2.2	Exames de Diagnóstico e Tratamento	49
2.2.3	Internação Clínica ou Cirúrgica	49
2.3	Técnicas de Predição Computacional	49
2.3.1	Modelo Auto-Regressive Integrated Moving Average (ARIMA)	50
2.4	Elasticidade de Recursos	51
2.4.1	Configuração	53
2.4.2	Escopo	54
2.4.3	Objetivo	55
2.4.4	Método	55
2.4.5	Arquitetura	56
2.4.6	Provedor	57
2.4.7	Modo de Operação	57
2.5	Considerações Parciais	59
<b>3</b>	<b>TRABALHOS RELACIONADOS</b>	<b>61</b>
3.1	Metodologia de Pesquisa e Seleção dos Trabalhos	61
3.2	Predicting proximity with ambient mobile sensors for non-invasive health diagnostics (ORIMAYE et al., 2015)	62
3.3	Resource Frequency Prediction in Healthcare: Machine Learning Approach (VIEIRA; HOLLMÉN, 2016)	63
3.4	Forecasting the regional distribution and sufficiency of physicians in Japan with a coupled system dynamics: geographic information system model (ISHIKAWA et al., 2017)	64
3.5	Global Health Workforce Labor Market Projections for 2030 (LIU et al., 2017)	64
3.6	DMP-IOT: A distributed movement prediction scheme for IOT health-care applications (ZAMANIFAR; NAZEMI; VAHIDI-ASL, 2017)	65
3.7	Type-2 fuzzy ontology-aided recommendation systems for IoT-based healthcare (ALI et al., 2018)	66
3.8	Using Data Mining to Predict Hospital Admissions From the Emergency Department (GRAHAM et al., 2018)	67
3.9	Análise	68
3.10	Considerações Parciais	70

<b>4</b>	<b>MODELO ELHEALTH</b>	<b>71</b>
4.1	Decisões de Projeto	71
4.2	Arquitetura	74
4.3	Elasticidade Preditiva Multinível de Recursos Humanos	79
4.3.1	Elasticidade Preditiva a Nível Local	80
4.3.2	Elasticidade Preditiva a Nível Global	87
4.4	Considerações Parciais	98
<b>5</b>	<b>METODOLOGIA DE AVALIAÇÃO</b>	<b>99</b>
5.1	Implementação e Ambiente de Testes	99
5.1.1	Protótipo Desenvolvido	99
5.1.2	Simulador do ambiente hospitalar	100
5.1.3	Ambiente de Simulação	100
5.2	Cenários	100
5.3	Parâmetros	101
5.4	Infraestrutura	104
5.5	Workload de Entrada	105
5.6	Métricas de Avaliação	107
5.7	Metodologia de Testes para o Sistema RTLS	110
<b>6</b>	<b>RESULTADOS E DISCUSSÃO</b>	<b>113</b>
6.1	Funcionamento do Modelo	113
6.2	Métrica M1: Tempo Máximo de Espera	115
6.3	Métrica M2: Quantidade Elástica de Recursos Humanos utilizados	119
6.4	Métrica M3: Custo de Atendimento	120
6.5	Métrica M4: Quantidade Média de Pacientes aguardando por atendimento	124
6.6	Testes do Sistema RTLS	128
6.7	Discussão	130
<b>7</b>	<b>CONCLUSÃO</b>	<b>133</b>
7.1	Contribuições	134
7.2	Limitações	135
7.3	Trabalhos Futuros	136
7.4	Publicações	136
	<b>REFERÊNCIAS</b>	<b>139</b>

## 1 INTRODUÇÃO

A Internet das Coisas (*Internet of Things*, ou IoT) é um conceito onde objetos e “coisas” físicas são conectadas através de uma estrutura de rede e fazem parte das atividades da internet com o objetivo de trocar informações sobre si mesmos e sobre objetos e coisas ao seu redor. Ou seja, Internet das Coisas é um conceito da computação onde objetos do nosso dia-a-dia acabam por possuir algum tipo de *hardware* ou dispositivo embarcado que pode se conectar com uma rede, ou simplesmente estar online. O desenvolvimento desse paradigma está em crescimento constante. Isso ocorre por causa dos esforços contínuos da comunidade de pesquisadores, em função do IoT permitir aplicações ilimitadas para resolver necessidades também ilimitadas em todas as esferas da vida. Assim, em um futuro não tão distante, tudo em nossas casas, locais de trabalho e estudo terá um endereço único na Internet e, através da rede, será possível monitorar e controlar qualquer uma de nossas “coisas”. (SINGH; KAPOOR, 2017). Nesse conceito, IoT se torna uma grande rede de sensores, atuadores, e objetos do dia-a-dia que podem ser usados em vários domínios, como aeroportos, militar e na área da saúde. (SARHAN, 2018).

Figura 1 – Imagem conceitual do paradigma de Internet das Coisas



Fonte: Adaptada de IOT (2017).

Existem diversos dispositivos e abordagens capazes de trazer o paradigma da Internet das Coisas para o mundo real. Dentre elas podemos citar os sistemas de Comunicação por Campo de Proximidade e a Tecnologia de Identificação por Radiofrequência, ou *Radio Frequency Identification Technology*, comumente conhecida pela sigla RFID, que é uma tecnologia de identificação sem fio (RYU; KWON; HONG, 2013) que permite localizar objetos físicos e conectá-los

ao mundo virtual (PEDRAZA; GARCÍA; DEBBABI, 2010). Para conectar os dispositivos nas redes locais e globais, existem diversas tecnologias de comunicação sem-fio, tais como a tecnologia Zigbee, o Bluetooth, o Bluetooth Low Energy e o Wi-Fi. (ISLAM et al., 2015).

Um cenário particularmente relevante para a IoT é a área de saúde. De acordo com Pinto, Cabral e Gomes (2017), a IoT promete revolucionar as aplicações para a saúde, permitindo uma forma de cuidar dos pacientes mais personalizada, preventiva e colaborativa. Em particular, pacientes monitorados por sistemas IoT podem ser supervisionados ininterruptamente, permitindo que situações de risco sejam detectadas e adequadamente tratadas imediatamente. (DARSHAN; ANANDAKUMAR, 2015). Além disso, a IoT permite que os sistemas de saúde extraiam e analisem dados de pacientes, que podem então ser usados para detectar distúrbios de saúde em estágios iniciais por meio de técnicas de predição computacional.

### 1.1 Definição do Problema

Dentre as diversas situações-problemas do nosso dia-a-dia que podem ser minimizadas utilizando-se da ciência de contexto, temos uma que todas as pessoas se deparam ou vão se deparar em algum momento da vida: a necessidade de ter uma consulta médica. Existem pessoas que quando têm algum problema de saúde, conseguem marcar um atendimento em uma clínica com algum médico de sua confiança. Outras pessoas, decidem ir para o atendimento do hospital mais adequado para sua necessidade. Em outros casos, a situação de saúde é tão crítica ou emergencial que a única alternativa é ir o mais rápido possível para uma unidade de atendimento hospitalar.

Figura 2 – Um exemplo de problema seria a superlotação dos Hospitais



Fonte: Uma emergência está lotada e seis estão superlotadas na Capital (2011).

Assim hospitais são pontos de atendimento extremamente importantes para a população em geral por realizar uma das mais importantes tarefas: realizar o tratamento adequado da saúde humana. Diversos são os ambientes, recursos e processos dentro de um hospital para realizar essa tarefa. Assim, torna-se interessante ter-se um controle eficiente de como estes recursos e processos estão sendo utilizados e executados de forma a se identificar pontos de otimização. Isso se torna ainda mais necessário quando nos deparamos com a realidade brasileira, onde hospitais estão cada vez mais lotados de pessoas para se atender. O problema da superlotação de hospitais é de certa forma antigo (UMA EMERGÊNCIA ESTÁ LOTADA E SEIS ESTÃO SUPERLOTADAS NA CAPITAL, 2011) e extremamente recente (SUPERLOTADA, EMERGÊNCIA DO HOSPITAL CONCEIÇÃO ACOMODA PACIENTES NO CHÃO, 2017), o que mostra que é um problema que ainda persiste e que deve ser tratado.

Quando um hospital ou unidade de pronto-atendimento é inaugurada, geralmente leva-se um bom tempo até que a mesma exceda a sua capacidade de atendimento. Se fosse possível identificar com antecedência quando os pontos de atendimentos e recursos teriam uma demanda superior a sua capacidade de atender, seria possível estabelecer planos de ação para minimizar ou talvez até eliminar esses gargalos do sistema hospitalar. Entretanto, como analisar e definir quando esse momento está próximo de chegar? Confiar apenas no julgamento das pessoas que trabalham com esses recursos, sem nenhuma forma eficiente de registro do usos dos mesmos e nenhum sistema de previsão estatisticamente confiável, pode se tornar um problema, com grandes chances de se ocasionarem erros na avaliação dos mesmos.

De acordo com Butean et al. (2015), por mais fácil ou complicada que seja uma situação, se a equipe médica não reagir a tempo, tudo torna-se duvidoso e inseguro com relação a saúde dos pacientes. Assim, alguns dos recursos mais importantes na área da saúde são os profissionais que trabalham no atendimento dos pacientes. Esses profissionais vão desde as equipes de enfermeiros que realizam procedimentos de triagem e pequenos tratamentos até aos doutores que atendem as mais diversas especialidades médicas. Dessa forma, a alocação estática dos profissionais da saúde nesse caso pode ser considerada ineficiente, pois podem surgir situações em que um determinado enfermeiro ou médico esteja ocioso em um setor de atendimento com pouca demanda, enquanto que em outro setor exista um grande volume de pacientes, sobrecarregando os profissionais que o atendem. Tal problema é ilustrado na Figura 3, onde os atendentes disponíveis são estaticamente designados para dois setores de serviço, um para exames e outro para medicação. No exemplo, há mais atendentes examinando do que medicando os pacientes, embora o número de pacientes que esperam pelos exames seja consideravelmente menor do que aqueles que esperam receber alguma medicação. Nesse contexto, os atendentes ociosos de uma sala poderiam ser transferidos para a sala com maior necessidade. De fato, a alocação de atendentes deveria sempre se *adaptar* às condições dos ambientes de saúde.

Técnicas de predição computacional poder ser utilizadas nesse tipo de cenário. Em particular, com essas técnicas é possível antecipar a demanda de pacientes e preparar adequadamente a alocação da equipe médica. Diversos trabalhos abordaram esse problema na literatura. Za-



Figura 3 – Exemplo de cenário em que profissionais de saúde são alocados de maneira estática, onde existem dois setores, medicação e exames. Nesse exemplo, existem mais atendentes para exames do que para medicação, ao contrário da demanda de pacientes que é maior para a sala de medicação



Fonte: Elaborado pelo autor.

manifar, Nazemi e Vahidi-Asl (2017) utilizam técnicas de predição para antecipar a direção do movimento de um paciente, mas usam essa informação apenas para preparar os sensores para se comunicarem com o paciente. Ali et al. (2018) propuseram um sistema capaz de prever o estado de saúde de um paciente, mas eles usaram essa informação apenas para propor recomendações sobre medicamentos e alimentação. Portanto, de acordo com a pesquisa realizada, nenhum outro trabalho científico utilizou predição computacional para antecipar a demanda de pacientes e, assim, alocar eficientemente os profissionais em ambientes de saúde.

## 1.2 Questão de Pesquisa

Tendo identificado a situação-problema, foi definida a seguinte questão de pesquisa para ser trabalhada nesta dissertação: *Como seria um modelo para controlar um hospital de forma mais eficiente, garantindo um registro fidedigno do uso de recursos humanos nos processos hospitalares e permitindo identificar e prever possíveis gargalos que podem vir a ocorrer no*

*atendimento clínico, de forma a se realizar uma alocação adaptável dos recursos para atendimento?*

Dessa forma, este trabalho tem como foco de pesquisa identificar como seria um modelo capaz de controlar o uso de recursos humanos de um hospital de forma automatizada. Ao mesmo tempo, identificar como garantir um registro do uso e da alocação dos funcionários nos setores em todo o tempo em que estiverem a disposição do hospital. Utilizando dessas informações, também identificar como esse modelo poderia prever possíveis situações em que haveria uma demanda de pacientes superior a quantidade de funcionários disponíveis, trazendo soluções para a realocação (remanejamento de pessoas dentro dos setores do hospital) e alocação (chamar pessoas que estariam em casa ou profissionais disponíveis em outras unidades para o atendimento) dos mesmos para se ajustar a demanda.

### **1.3 Objetivos**

Uma vez identificada a questão de pesquisa, definiu-se o seguinte objetivo para esse trabalho: O presente trabalho objetiva o desenvolvimento de um modelo de sistema de ciência de contexto para controle de recursos humanos em um hospital, utilizando-se de sensores do paradigma de Internet das Coisas, para registrar a relação entre a capacidade de atendimento de pacientes de um hospital com a quantidade de funcionários que estão prestando socorro. A ideia é permitir que seja possível não apenas o registro e controle desses funcionários, mas também a visualização em uma ferramenta gerencial da subutilização ou da superutilização de recursos humanos no atendimento de uma emergência hospitalar. Além disso, espera-se que o sistema seja capaz de avaliar e prever quando a demanda será superior à capacidade de atendimento do hospital, de tal forma que possa indicar de forma pró-ativa a movimentação de pessoas, realizando alocação e desalocação de funcionários para o atendimento.

Para atingir esse objetivo, foram definidos os seguintes objetivos específicos:

- Identificar formas de medir a necessidade de profissionais de saúde em cada um dos ambientes de uma unidade hospitalar, e propor formas para um gerenciamento inteligente e automatizado do uso de recursos humanos;
- Propor um modelo de elasticidade pró-ativa para gerenciamento de recursos humanos em ambientes hospitalares;

Neste contexto, é proposto o modelo *ÉIHealth* como uma alternativa à alocação estática da equipe médica. *ElHealth* é um modelo para controlar o uso de recursos humanos em um hospital inteligente de forma automatizada. O modelo é capaz de identificar e alocar eficientemente funcionários da saúde para setores do hospital, considerando suas limitações de tempo. Usando essas informações, o modelo é capaz de prever situações em que a demanda por pacientes poderia ser maior que capacidade de atendimento dos funcionários disponíveis, permitindo propor

realocação e alocação de profissionais para ajustar a demanda. A ideia é oferecer sempre um tempo de espera razoável para os pacientes, independentemente da carga de trabalho (número deles no hospital). Para este fim, ElHealth propõe um algoritmo para alocação e migração de recursos humanos com o suporte de sensores de IoT e técnicas de predição computacional.

#### 1.4 Organização do Texto

Esta dissertação está organizada em sete capítulos. Após o capítulo de Introdução, o Capítulo 2 trará o Referencial Teórico utilizado para este trabalho, demonstrando o estado da arte das tecnologias que estão relacionadas ao tema proposto, apresentando os conceitos de Internet das Coisas e as tecnologias utilizadas para o paradigma, bem como um estudo sobre o padrão de Código Eletrônico de Produto, e os conceitos relacionados aos *Real-Time Location Systems*. Além disso, este capítulo também apresentará um estudo sobre os processos hospitalares e técnicas de predição computacional, apresentando os conceitos de séries temporais, e modelos matemáticos. Por fim trará um estudo sobre a elasticidade de recursos computacionais.

O Capítulo 3 trará uma relação de Trabalhos Relacionados a este, apresentando a metodologia de pesquisa utilizada para seleção dos estudos. O capítulo apresentará um breve resumo dos trabalhos escolhidos e as principais características de cada um deles, apresentando uma análise comparativa entre eles, mostrando pontos interessantes de cada uma das abordagens e as lacunas identificadas.

O Capítulo 4 apresentará o modelo ElHealth, proposto para tentar solucionar o problema levantando na Introdução. Trará uma visão da arquitetura necessária para o sistema e das decisões de projeto, bem como apresentará o conceito de Elasticidade Preditiva Multinível de Recursos Humanos, detalhando os algoritmos necessários para prover elasticidade de pessoas a nível local e a nível global.

No Capítulo 5 será expressa a metodologia de avaliação do modelo, apresentando a implementação desenvolvida e o ambiente utilizado para a simulação do sistema. Também definirá os cenários de testes escolhidos, juntamente com os parâmetros, a infraestrutura e a carga de trabalho que foram utilizados, bem como as métricas que foram elaboradas para análise e avaliação do modelo proposto.

O Capítulo 6 trará a apresentação dos resultados encontrados para cada um dos cenários de testes propostos na metodologia de avaliação. Além disso, apresentará uma análise dos resultados encontrados em cada uma das métricas propostas, de forma a avaliar o modelo proposto. Por fim, trará uma discussão sobre os resultados obtidos.

O Capítulo 7 será a conclusão desse trabalho. Nele serão elencadas as contribuições dessa dissertação, as limitações do modelo ElHealth e alguns possíveis trabalhos futuros que poderiam ser feitos para melhoria ou complementação do sistema proposto. Além de apresentar os agradecimentos às agências brasileiras que apoiaram de alguma forma este trabalho.



## 2 REFERENCIAL TEÓRICO

Este capítulo tem como objetivo apresentar os conceitos fundamentais para o desenvolvimento deste trabalho, sendo dividido em quatro seções principais. Primeiramente, na Seção 2.1, serão apresentados os conceitos referentes ao paradigma Internet das Coisas. Após, na Seção 2.2, serão descritos os processos hospitalares utilizados na área da saúde. A seguir, na Seção 2.3, serão apresentadas algumas técnicas de predição computacional. Por fim, a Seção 2.4 apresentará os conceitos referentes a elasticidade de recursos computacionais.

### 2.1 Internet das Coisas

A Internet das Coisas é um paradigma que vem ganhando terreno rapidamente no cenário atual da comunicação computacional. A ideia se baseia na presença de uma variedade de coisas ou objetos ao nosso redor que estão conectados ao mundo virtual, cada um podendo interagir com os outros e cooperar para alcançar objetivos em comum (ATZORI; IERA; MORABITO, 2010). Além disso, a Internet das Coisas torna possível para nossos dispositivos interagirem não apenas uns com os outros, mas com serviços e outras pessoas em uma escala global. (AKEJU; BUTAKOV; AGHILI, 2018).

A grande discussão em torno da IoT está no impacto que a mesma pode trazer em diversos aspectos de nosso dia-dia e quais são os usuários em potencial. Para um usuário comum, os efeitos mais visíveis da Internet das Coisas estão nas aplicações domésticas e de seus ambientes de trabalho. Um exemplo seria uma casa com sensores nas janelas que identificassem se as mesmas estão abertas e se, através de um sistema online, identificassem que estava chovendo, as mesmas poderiam se fechar automaticamente, ou notificar o dono da casa através de uma aplicação em seu *smartphone* para saber o que fazer. Já para um usuário de negócios, os usos da IoT estão mais atrelados a automação de atividades industriais ou de negócios, de logística, de manutenção empresarial, e gerência de bens e serviços e até mesmo de pessoas.

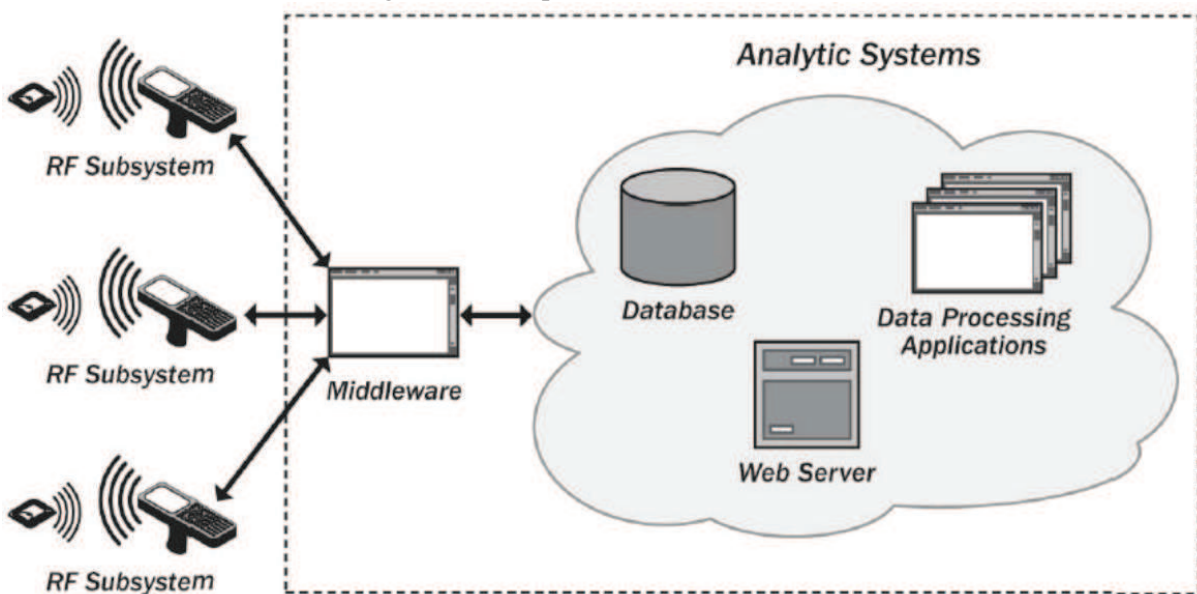
O mundo está passando por uma transformação tecnológica sem precedentes, que evolui de sistemas isolados para “coisas” onipresentes, habilitadas para a internet, capazes de gerar e trocar grandes quantidades de dados valiosos. A Internet das Coisas não é mais um conceito e sim uma nova realidade que está mudando completamente a vida cotidiana, aumentando a produtividade dos negócios e melhorando a eficiência até de governos. Além disso, também promete revolucionar as aplicações da área da saúde, permitindo uma forma de cuidar dos pacientes mais personalizada, preventiva e colaborativa. (PINTO; CABRAL; GOMES, 2017).

#### 2.1.1 Tecnologias Utilizadas para Internet das Coisas

Segundo Pereira (2012), a Tecnologia RFID é uma tecnologia de identificação automática, que funciona através de sinais de rádio, recuperando e armazenando dados remotamente. Con-

forme Landt (2005), ela é empregada em centenas, ou talvez até milhares, de aplicações com o objetivo de coletar dados sobre objetos de forma a identificar maneiras de resolver problemas do dia-a-dia. Nos últimos anos a tecnologia saiu da obscuridade para as principais aplicações, permitindo a identificação à distância, ao contrário do código de barras que realiza o reconhecimento somente através de um feixe de luz. As *tags* suportam além da identificação, uma variedade de informações adicionais, que podem ir desde o nome da fabricante, e tipos de produtos, até a fatores ambientais como, por exemplo, a temperatura. (WANT, 2006). Para que um sistema RFID funcione são necessários alguns componentes, dentre eles podemos citar os três principais: *Tags* RFID (Transponder), o Leitor RFID (Transceiver), e o Middleware.

Figura 4 – Componentes do Sistema RFID



Fonte: Moreira (2008).

As *tags* são pequenos circuitos que tem como objetivo atrelar dados lógicos a um objeto físico. Cada *tag* possui um mecanismo próprio para armazenar dados e uma forma de enviá-los, assim podemos dizer que elas possuem no mínimo três partes: uma antena, um chip semicondutor conectado a essa antena e alguma forma de encapsulamento (WANT, 2006). Elas podem ser divididas em dois principais grupos: as *tags* passivas, que são alimentadas diretamente pelo leitor e só são ativadas quando estão no raio de leitura, e as *tags* ativas que possuem fonte de energia própria, mantendo-se sempre em atividade. Já um leitor ou *reader* é o aparelho que permite comunicação, interpretação e leitura dos dados contidos em *tags* RFID que estão dentro do raio de alcance de sua antena. (PEREIRA, 2012). Por fim, o *middleware* é o elemento responsável pela filtragem, agregação e distribuição de dados, leitura e gravação das informações contidas nas *tags*, e gestão dos leitores. (PEREIRA, 2012).

Por muitos anos, as pesquisas em computação pervasiva têm explorado os benefícios de criar conexões entre o mundo virtual e o mundo físico onde vivemos. A Tecnologia de Comunicação por Campo de Proximidade, comumente conhecida por *Near Field Communication* ou

simplesmente NFC é um padrão para comunicação sem fio que está permitindo que essa visão ubíqua se torne uma realidade. O Conceito de NFC está geralmente próximo e atrelado ao conceito de Internet das Coisas, pois conectando o físico e o virtual, qualquer objeto, pessoa ou lugar pode ser automaticamente associado com algum documento ou conteúdo online. (WANT, 2011). Segundo Alves et al. (2015), o NFC permite a comunicação interativa entre dispositivos inteligentes. Segundo Nassar e Vieira (2014), diferentemente do RFID, o NFC é uma tecnologia que permite a transferência de dados em uma comunicação sem fio de curta distância. Como o NFC surgiu a partir da Tecnologia RFID, muitos dos benefícios observados por ela são compartilhados com o NFC. Entretanto, também existem diferenças entre as tecnologias. Um dispositivo inteligente com NFC por ser capaz de atuar como leitor e *tag* ao mesmo tempo, possibilitando uma comunicação P2P (Peer-to-Peer), ou seja, uma troca verdadeira de dados. Outra diferença está no alcance. Enquanto que em sistemas RFID o alcance chega na casa de dezenas de metros, no NFC têm-se um alcance pequeno de no máximo 10cm. Aplicações que necessitem de segurança tais como transações bancárias se beneficiam dessa limitação, pela dificuldade em se receber ataques sem que o usuário seja capaz de notar.

Outra tecnologia amplamente utilizada para IoT é a Wi-Fi (*Wireless Fidelity*). Segundo Moreira (2008), o Wi-Fi é o protocolo de comunicação *wireless* (sem-fio) que se aplica geralmente à comunicação entre dispositivos móveis em redes empresariais ou residenciais. Através de pontos de acesso, os dispositivos que estão na área de recepção do sinal podem se comunicar com a rede. (COSTA; SILVA; SILVA, 2017). Os dispositivos móveis, tais como *smartphones*, geralmente possuem a capacidade de receber o sinal dos pontos de acesso e, através deles, informações dos mais variados tipos conforme a necessidade. Os dispositivos podem medir a intensidade do sinal, denominada de Received Signal Strength Indicator (RSSI), que após é convertida em decibéis, conhecida como Received Signal Strength (RSS), permitindo que seja possível comparar a força da intensidade de sinal de diversos pontos de acesso. (COSTA; SILVA; SILVA, 2017).

Além dessas, outras tecnologias amplamente utilizadas que podem ser destacadas são as tecnologias Bluetooth e Bluetooth Low Energy (BLE). O Bluetooth é um padrão de comunicação de baixo custo utilizado para comunicação sem fio em curtas distâncias. Graças a essas características, pode ser utilizado para desenvolvimento de sistemas de posicionamento *indoor*. Segundo Costa, Silva e Silva (2017), a tecnologia Bluetooth está integrada na maioria dos dispositivos móveis comercializados hoje em dia, estando presente tanto em *smartphones*, quanto em *laptops*. O alcance máximo para a comunicação através da tecnologia varia, tendo uma média de 10 metros para dispositivos móveis comuns, porém podendo chegar a até 100 metros para uso industrial. (COSKUN; OZDENIZCI; OK, 2013).

Recentemente, o *Bluetooth Special Interest Group* (consórcio de empresas que detém os direitos de desenvolvimento e comercialização da tecnologia Bluetooth) desenvolveu o protocolo Bluetooth 4.0, também chamado de BLE, tendo diversas semelhanças com a tecnologia Bluetooth tradicional, porém trazendo algumas vantagens importantes sobre ela. (COSTA; SILVA;

SILVA, 2017). Segundo Wanjari e Patil (2016), se um dispositivo BLE for comparado com um dispositivo Bluetooth clássico, a mais importante diferença entre eles está no baixo consumo de energia que a tecnologia BLE possui. Assim, a grande vantagem do BLE está no fato de que sistemas que usam da tecnologia podem funcionar com uma pequena bateria em formato de moeda por um tempo que pode chegar até 4 ou 5 anos. Ao contrário do Bluetooth tradicional, o BLE se mantém constantemente em modo de espera depois que as conexões são iniciadas. O tempo de conexão está na casa dos milissegundos, sendo mais veloz que o Bluetooth tradicional. Porém, em função da conexão, a taxa de transferência de dados acaba por ser inferior. (WANJARI; PATIL, 2016).

Dentro das tecnologias de comunicação sem fio, destaca-se também a Ultra Wide Band, mais conhecida pela sigla UWB, que se baseia no envio de pequenos impulsos de sinais, em intervalos de tempo muito pequenos. Os impulsos de sinais do UWB possuem uma largura de banda ampla, isto é, maior do que 1 GHz, e uma transmissão muito baixa de energia, com valores inferiores a 10 microwatts. Uma das grandes diferenças da tecnologia UWB, com relação a outras tecnologias existentes, como o Wi-Fi e o Bluetooth, é que o UWB utiliza várias bandas de frequência do espectro para envio de um sinal. (COSTA; SILVA; SILVA, 2017). Segundo Costa, Silva e Silva (2017), o UWB quando é associado a outras técnicas de posicionamento, tais como o GPS ou o GNSS, pode proporcionar uma localização contínua do exterior para a posição no interior, uma vez que em ambientes abertos pode ter um alcance de quilômetros e em ambientes fechados pode atingir até 100 metros. Ainda segundo Costa, Silva e Silva (2017), um ponto interessante da tecnologia está no fato que como ela trabalha com pequenos impulsos de sinal de curta duração, é fácil para os receptores UWB identificarem qual frequência de operação é a ideal para aquele instante e quais estão sendo afetadas por interferências. Outra vantagem é que os sensores UWB são baratos, o que torna o sistema de posicionamento econômico quando comparado com outras tecnologias. A desvantagem está na falta de interoperabilidade, pois como o sinal é tão específico, é necessário o uso de equipamentos específicos para poder emitir e receber os sinais.

Por fim, também pode-se citar a tecnologia ZigBee, um padrão de comunicação global do tipo Wireless Sensor Network (WSN) que permite uma comunicação de baixa distância, baixa velocidade, pouco consumo de energia para comunicação e uma bateria de vida útil elevada. Originalmente, o ZigBee foi desenvolvido para ser um padrão para comunicação de dados entre um grande número de dispositivos para uso industrial, de forma a ser utilizada para aplicações baseadas em uma Rede de Área Pessoal Sem fio (*Wireless Personal Area Networks* ou WPAN). Assim como o BLE, com o ZigBee é possível realizar a comunicação com um baixo consumo de energia, já que uma bateria normal é capaz de alimentar o sistema por vários anos. Entretanto, o baixo consumo de energia, acaba por ser um limitador na capacidade de transferência de dados. Uma das vantagens da tecnologia é que a energia de saída é baixa e, por causa disso, mais segura para pessoas, o que a torna eficiente para uso nas áreas da saúde. (ALHARBE; ATKINS; AKBARI, 2013).

O sistema ZigBee funciona em dois modos de operação: Beacon e Não-Beacon. No modo Beacon, a rede aparenta ser uma Malha ou um Cluster. O sinal é periodicamente enviado de um coordenador da rede para os dispositivos, que se mantêm passivos, aguardando a comunicação, e o consumo de energia é controlado. No modo Não-Beacon, o ZigBee opera como uma rede peer-to-peer com comunicação em dois fluxos, onde o dispositivo precisa estar sempre ativo, aguardando para enviar e receber sinais. (ALHARBE; ATKINS; AKBARI, 2013). A Tabela 1 apresenta um comparativo entre algumas das características técnicas do ZigBee, com as tecnologias Bluetooth, BLE, NFC e RFID, já abordadas anteriormente neste trabalho.

Tabela 1 – Comparação entre as Tecnologias NFC, Bluetooth e Zigbee

<b>Características</b>	<b>RFID</b>	<b>NFC</b>	<b>Bluetooth</b>	<b>BLE</b>	<b>Zigbee</b>
Distância	Até 100m	Até 10cm	Até 100m	> 100m	Até 100m
Taxa de Dados	Até 1Mbps	Até 0.4Mbps	Até 2.1Mbps	Até 1.37Mbps	Até 0.2Mbps
Consumo	Baixo-Alto	Baixo	Alto	Baixo	Baixo
Custo	Baixo	Baixo	Baixo	Baixo	Baixo
Segurança	Média	Alta	Baixa	Média	Média
Conexão	< 0.1s	< 0.1s	Aprox. 6s	3ms	Aprox. 0.5s
Dispositivos por rede	Ilimitado	2	8	Ilimitado	65000

Fonte: Elaborada pelo autor, com base em Moreira (2008); Neiva (2012); Coskun, Ozdenizci e Ok (2013); Wanjari e Patil (2016); Costa, Silva e Silva (2017).

Este levantamento apresentou apenas algumas das principais tecnologias utilizadas para Internet das Coisas. Atualmente existe uma infinidade de abordagens para o paradigma que não forma estudadas, tais como *Z-Wave*, *Thread*, entre outras.

### 2.1.2 Padrão EPC (Eletronic Product Code)

Electronic Product Code, ou Código Eletrônico de Produto, comumente conhecida pela sigla EPC, é um código não-ambíguo para designação de bens físicos. Nos últimos anos o padrão têm se apresentado para diversos interesses, que não se restringem apenas a pesquisa, mas também ao uso na indústria e na sociedade em geral. A difusão da padrão está veiculada principalmente ao *Auto-ID Center*, um projeto desenvolvido pelo Massachusetts Institute of Technology, conhecido pela sigla MIT, em 1999 com o objetivo de desenvolver os padrões da tecnologia RFID. Eles desenvolveram o EPC para garantir a interoperabilidade RFID nas cadeias de produção e distribuição. (THIESSE et al., 2009). O padrão EPCglobal (GS1, 2018) é uma iniciativa da GS1 para desenvolver padrões voltados ao EPC e o uso da tecnologia RFID, permitindo a visualização global de itens.

Segundo Neiva (2012) um dos sistemas cujas possibilidades se assemelham bastante ao EPC é o código de barras. Ambos possibilitam o armazenamento de informações sobre os produtos aos quais são atribuídos, bem como um registro da localização destes e de vários recursos. Graças a essas características ambos são largamente utilizados em várias indústrias permitindo uma melhor gestão de recursos e estoque. No entanto, o EPC apresenta uma grande superioridade



tecnológica em relação ao código de barras, justificando a sua crescente expansão com relação ao mesmo. A Tabela 2 apresenta um comparativo entre os dois sistemas, relacionando algumas de suas principais características.

Tabela 2 – Comparativo de características entre código de barras e RFID EPC

<b>Características</b>	<b>Código de Barras</b>	<b>RFID EPC</b>
Tecnologia:	Ótica (Laser).	Radiofrequência.
Capacidade de leitura e escrita:	Apenas de leitura.	Leitura e escrita.
Taxa de leitura:	Baixa (1 leitura por vez).	Elevada (múltiplas leituras por vez)
Distância de leitura:	Alguns centímetros a alguns metros.	Até mais de uma centena de metros.
Memória:	Baixa.	Elevada.
Linha de vista:	Necessária.	Não necessária.
Resistência mecânica:	Baixa.	Alta.
Formatos:	Etiquetas.	Variados.
Segurança:	Não.	Sim.
Custo das etiquetas:	Muito baixo.	Aproximadamente 10 vezes mais caro que o código de barras.
Custo de manutenção:	Alto.	Baixo.
Vida Útil:	Baixa.	Alta.
Reutilização:	Não reutilizável.	Reutilizável.

Fonte: Adaptada de Neiva (2012).

Cada *tag* RFID possui um identificador único que é utilizado unicamente para a identificação da *tag*. Existem diversos formatos para codificação de identificadores mas em geral utilizam-se os identificadores definidos no padrão, com grupos de bits específicos para representação dos campos específicos. Um formato de identificador RFID utilizado em larga escala é justamente o EPC. (MOREIRA, 2008). Um exemplo de identificador de Código de Produto Eletrônico pode ser visto na Figura 5.



Fonte: Moreira (2008).

Conforme visto na Figura 5, o formato de identificador EPC possui quatro campos de dados:

- Cabeçalho (especifica o tipo de EPC)
- ID do Gestor EPC (identifica a organização responsável pela atribuição da Classe de Objeto, geralmente o fabricante da *tag*).
- Classe de Objeto (identifica uma classe de objetos. Por exemplo: um modelo de celular)

- Número de Série (identifica o objeto em específico. Por exemplo: um celular em específico)

### 2.1.3 Real-Time Location Systems

De acordo com Boulos e Berry (2012), Sistemas de Localização em Tempo Real, ou Real-time Locating Systems, comumente conhecidos pela sigla RTLS, são sistemas para a identificação e rastreamento da localização de ativos e/ou pessoas em tempo real ou quase em tempo real. Um RTLS geralmente consiste em leitores fixos especializados (sensores de localização) recebendo sinais sem fio de pequenos crachás de identificação ou *tags* anexadas a objetos de interesse ou pessoas, para determinar onde essas entidades estão localizadas dentro de um ambiente interno ou externo. Para isso, cada *tag* deve transmitir periodicamente seu próprio ID que deve ser registrado para o ativo ou pessoa que está sendo representado. Dependendo da tecnologia utilizada, o sistema é capaz de identificar e localizar as *tags* nos ambientes e consequentemente as pessoas e objetos que elas representam. Assim, quando alguém necessita localizar algum desses objetos ou pessoas, é só realizar uma consulta no sistema.

As informações de localização geradas pelos RTLS geralmente não incluem detalhes de navegação completos ou contínuos, como velocidade, direção de movimento ou orientação espacial de objetos e pessoas rastreados. (BOULOS; BERRY, 2012). Os padrões para o RTLS incluem a série de normas ISO/IEC 24730 (INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO); INTERNATIONAL ELECTROTECHNICAL COMMISSION (IEC), 2014), entretanto a norma não cobre toda a gama de tecnologias RTLS existentes. (BOULOS; BERRY, 2012). Ainda de acordo com Boulos e Berry (2012), emergências, hospitais, sistemas de saúde domiciliares, e até aplicações assistenciais para vida doméstica cotidiana podem ser potencialmente beneficiadas com o uso de uma solução RTLS apropriada.

Segundo Boulos e Berry (2012), em um RTLS, o software de localização se comunica com *tags* e sensores para determinar a localização das pessoas e objetos. O software retransmite essas informações para *middlewares* e aplicações especializadas. O *middleware* é responsável por intermediar a comunicação entre os principais componentes do RTLS (*tags*, sensores de localização e software) e uma variedade de aplicações capazes de exibir e explorar a localização em tempo real e as informações de status das entidades rastreadas. Essas aplicações podem variar de simples interfaces para consultar e exibir as informações sobre a localização das pessoas e objetos, até uma integração mais abrangente de sistemas comerciais ou empresariais, por meio de aplicações abertas para enriquecer esses sistemas com informações de localização, de forma a torná-los capazes de realizar uma variedade de tarefas e operações de gerenciamento. Um exemplo de uso seria em sistemas hospitalares ADT (Admission, Discharge and Transfer, ou Admissão, Descarga e Transferência), HIS (Hospital Information Systems, ou Sistemas de Informações Hospitalares), RIS (Radiology Information Systems, ou Sistemas de Informações Radiológicas), sistemas de sala de cirurgia e sistemas de gerenciamento de leitos.

De acordo com Boulos e Berry (2012), ao rastrear a localização física de um ativo ou de um indivíduo, dependendo das necessidades das aplicações, pode ser necessário saber a posição absoluta (coordenadas absolutas, como latitude, longitude e altitude), posição relativa (distância em três dimensões com referência a um ponto fixo) ou posição simbólica (presença em uma área específica, por exemplo, o cirurgião está na sala de operações). Assim, soluções RTLS estão disponíveis para atender aos requisitos de diferentes aplicações, independentemente da precisão da localização, em diferentes resoluções:

- **Localização baseada em presença:** O RTLS retorna a localização da *tag* quando a mesma está presente em uma determinada área;
- **Localização no nível de sala:** O RTLS retorna em qual sala específica a *tag* está localizada (Por exemplo, o sistema é capaz de informar a sala exata onde uma determinada enfermeira está localizada);
- **Localização no nível de sub-sala:** o RTLS é capaz de identificar a *tag* em uma parte específica da sala (Por exemplo, em um quarto de um hospital com vários pacientes, saber em qual leito a *tag* está localizada);
- **Localização em ponto específico:** A localização da *tag* é retornada por um ponto específico, como entrada ou saída de alas e locais. Ao monitorar os tempos em que as *tags* foram detectadas em pontos, é possível determinar a direção de movimento das mesmas;
- **Localização com precisão:** A localização exata da *tag* é identificada precisamente em um mapa e relatada como posição absoluta ou relativa.
- **Localização por associação:** A localização de uma *tag* é retornada com relação a proximidade com outra *tag* (Um exemplo de uso seria se um paciente possui uma *tag* e um monitor cardíaco possui outra *tag*, é possível identificar quando o monitor está sendo usado para aquele paciente);

Um RTLS pode ser realizado usando várias tecnologias, incluindo sensores de luz, imagens de câmeras, infravermelho, som, ultrassom, Bluetooth, Wi-Fi, RFID, ZigBee, UWB, GPS e celular, entre outras tecnologias. Diferentes tecnologias usam diferentes abordagens, e cada método suporta diferentes aplicações ou resolve um problema ligeiramente diferente. Essas tecnologias também variam em muitos aspectos, como a forma usada para detecção da localização, a forma de associação entre sensores e *tags*, requisitos de energia, alcance, instalação, manutenção, e precisão. Em alguns sistemas, a *tag* localizada na verdade calcula sua própria posição, enquanto em outros RTLS, o software que localiza a *tag* é externo à mesma. (BOULOS; BERRY, 2012).

No final, todas as tecnologias RTLS compartilham o objetivo comum de determinar a localização de ativos e indivíduos com a precisão necessária para a aplicação final. Cada tecnologia



terá sucesso à sua maneira, desde que tenha sido cuidadosamente adaptada para as aplicações. Para certos sistemas, o uso das soluções RTLS combinadas que incorporam tecnologias complementares, como infravermelho e RFID, podem fornecer níveis de precisão e flexibilidade inatingíveis por qualquer tecnologia concorrente. (BOULOS; BERRY, 2012).

## 2.2 Processos Hospitalares

Segundo Azevedo et al. (2010), hospitais podem ser vistos como portas de entrada para o sistema de saúde. Nesse sentido, um sistema de saúde poderia ser pensando como um circuito com vários pontos de entrada, onde existe um lugar adequado para se atender a necessidade de cada tipo de paciente. Assim, hospitais devem ser serviços de porta aberta para toda a população, não sendo aceitáveis qualquer medida que tente restringir o acesso a saúde.

De acordo com Bittar (2000), quando se pensa em um hospital, podemos subdividi-lo em quatro grandes áreas: (I) Infra-Estrutura, (II) Ambulatório e Emergência, (III) Internação Clínica e Cirúrgica, e (IV) Diagnostico e Tratamento. Para cada uma dessas áreas, podemos elencar diversas subáreas e diversos processos importantes para a realização do atendimento hospitalar.

### 2.2.1 Ambulatório e Emergência

Os processos relacionados à área Ambulatorial e de Emergência são extremamente importantes, por serem as alimentadoras da demanda que um hospital pode possuir. É uma área que pode contribuir não apenas com a qualidade do atendimento, mas também com a melhora da qualidade de vida do paciente, pois nesse processo situações que não necessitem de internação podem ser diagnosticadas, prevenidas e até tratadas. Possui como principais subáreas os ambulatórios clínico e cirúrgico, e os serviços de urgência e emergência. (BITTAR, 2000).

O processo de triagem nos serviços do hospital deve ser bem organizado, não somente com relação a área física, material e equipamentos, mas também com pessoal competente e suficientemente treinado para analisar e definir a prioridade no atendimento de emergência a pacientes com enfermidades graves que correm risco de vida, ou que necessitam de assistência médica imediata. (AZEVEDO et al., 2010). Segundo Coutinho, Cecílio e Mota (2012), os objetivos da triagem ou da classificação de risco são:

- Identificar os pacientes em situações de risco de vida;
- Determinar a área mais adequada para realizar o tratamento do paciente que se apresenta a um serviço de emergência;
- Reduzir o congestionamento do serviço de emergência, melhorando o fluxo de pacientes nas áreas de tratamento;

- Informar aos pacientes o tempo de espera estimado para atendimento, bem como o tipo adequado de serviço ao qual eles necessitam;
- Assegurar que pacientes que necessitem de uma prioridade de atendimento, sejam atendidos primeiro através da classificação;
- Contribuir com informações que ajudem a definir as causas do serviço, bem como sua complexidade;
- Garantir que os pacientes sejam reavaliados periodicamente;
- Priorizar o atendimento de pacientes sem realizar o diagnóstico.

O Sistema de Triagem de Manchester (GRUPO PORTUGUÊS DE TRIAGEM, 2010), conhecido pela sigla STM, é um sistema para gerenciamento de risco clínico, usado para gerenciar o fluxo de pacientes de forma segura, quando o sistema estiver com a sua capacidade de atendimento excedida. O STM possui cinco níveis de prioridade. Para cada nível é definido um número, cor, nome e tempo-alvo máximo aceitável para o atendimento médico. A Figura 6 traz uma representação visual dos níveis desse sistema.

Figura 6 – O Sistema de Triagem de Manchester

Nível	Tipo de Urgência	Cor	Tempo de Espera
1	Emergente	Vermelho	Imediato
2	Muito Urgente	Laranja	10 Minutos
3	Urgente	Amarelo	60 Minutos
4	Pouco Urgente	Verde	120 Minutos
5	Não Urgente	Azul	240 Minutos

Fonte: Elaborada pelo autor, com base em Coutinho, Cecílio e Mota (2012).

Dessa forma, a finalidade dos serviços de emergência é oferecer atendimento imediato e de bom padrão aos pacientes, trazendo uma equipe de saúde treinada sobre as técnicas de atendimento, e capaz de atender os pacientes com foco na produção de saúde e qualidade de vida. (AZEVEDO et al., 2010). Através do Sistema de Triagem de Manchester, enfermeiros são capazes de classificar os pacientes conforme o nível de urgência em que eles precisam ser atendidos. Assim, diminuindo o risco de erro por parte dos atendentes, priorizando o atendimento de pacientes em estado grave e melhorando o processo como um todo.

### 2.2.2 Exames de Diagnóstico e Tratamento

Os processos relacionados à área de Diagnóstico e Tratamento são aqueles relacionados ao atendimento realizado pelos médicos e enfermeiros a fim de identificar o problema de saúde que acomete o paciente. Além de identificar as patologias através dos mais variados tipos de exames, tem como objetivo definir qual o tratamento adequado ao paciente e, dependendo do caso, aplicá-lo.

Segundo Bittar (2000), nas últimas décadas a área de Exames de Diagnóstico e Tratamento foi uma área hospitalar que recebeu um desenvolvimento tecnológico enorme, contribuindo com a melhoria da qualidade dos diagnósticos e tratamentos. Em função desses avanços, houve um aumento significativo no número e na complexidade dos processos, exigindo uma tecnologia cada vez mais cara e recursos humanos altamente treinados. Diversos são os tipos de exames e processos relacionados a estes. Em um hospital geralmente se têm as seguintes subáreas: anatomia patológica, angiografia/hemodinâmica, banco de sangue, banco de tecidos, betaterapia, biologia molecular, cardiocardiografia, dermatologia, diálise peritoneal, ecocardiografia, endoscopia, eletrocardiografia, eletroencefalografia, eletromiografia, ergometria, fisioterapia, fonoaudiologia, hemodiálise, holter, litotripsia, medicina nuclear, microondoterapia prostática, neurofisiologia, oftalmologia, ortóptica, patologia clínica, pneumologia, potencial evocado, quimioterapia, radiologia, reprodução humana, radioterapia, reabilitação, ressonância magnética, tomografia, ultra-sonografia e urodinâmica.

### 2.2.3 Internação Clínica ou Cirúrgica

Os casos graves necessariamente serão levados a uma internação, com utilização de processos mais complexos do que exames e tratamentos simples, tendo procedimentos invasivos, como perfusões intravenosas, que consomem mais recursos do hospital e causam uma maior carga de trabalho, na qual o paciente permanece em atendimento por um tempo maior. Com isso, sendo sujeito a conflitos e possibilidades de observação do que ocorre no desenvolvimento de alguns processos. Em um hospital geralmente se têm as seguintes subáreas: anestesia, centro cirúrgico, centro obstétrico, centro de recuperação anestésica, internação clínico-cirúrgica, obstétrica e pediátrica, unidade neonatal, unidade de moléstia infecto-contagiosa, e serviço de controle da infecção hospitalar. (BITTAR, 2000).

## 2.3 Técnicas de Predição Computacional

De acordo com Nisha e Sreekumar (2017), uma predição ou previsão computacional pode ser definida como uma declaração sobre um evento incerto que vai ocorrer no futuro. Para isso, é utilizado o conhecimento de uma série temporal do passado para prever o futuro. Uma previsão acurada ajuda a evitar possíveis riscos ou diminuir os riscos para problemas que ainda

não ocorreram. A previsão de algum período específico pode ajudar a controlar as situações que fujam ao que se espera para determinado problema. Em séries temporais, a previsão parece significar estimar valores futuros através de valores passados de uma série. A predição computacional pode ser usada para planejamento estratégico (planejamentos de longo prazo), para finanças e contabilidade (orçamentos e controle de custos), na área de marketing (análise de vendas futuras e impacto de novos produtos) e também para as áreas de produção e operações.

A análise de séries temporais é considerada uma ferramenta extremamente poderosa para determinar modelos dinâmicos, visando definir e controlar variáveis de um sistema de forma mais apropriada. Um grande número de modelos de séries temporais estão disponíveis para a previsão. Existem os modelos que utilizam da probabilidade e estatística, como o modelo *Auto-Regressive Integrated Moving Average* (ARIMA), e aqueles que utilizam de Inteligência Artificial, como os modelos que utilizam de Redes Neurais Artificiais e do algoritmo *Random Forest*. (NISHA; SREEKUMAR, 2017).

A previsão de séries temporais é uma área com bastante relevância, onde previsões de observações passadas são coletadas e analisadas, para desenvolver um modelo que descreve relações que não se situam claras e definidas, de forma que seja possível a predição de um determinado evento no futuro. (ROSSI, 2013). Nesse método de predição computacional, são utilizadas técnicas de probabilidade e estatística para realizar a inferência do futuro. Para isso, um modelo matemático é desenvolvido para representar o problema de previsão. Diversos são os modelos usando abordagens estatísticas, como o *Generalized Auto Regressive Conditional Heteroskedasticity* (GARCH), o *Naïve Bayes*, o *Wavelet analysis* e o *Support Vector Regression* (SVR), entretanto um dos mais utilizados, e escolhido para o trabalho proposto, é o modelo ARIMA. (NISHA; SREEKUMAR, 2017).

### 2.3.1 Modelo Auto-Regressive Integrated Moving Average (ARIMA)

O modelo Auto-Regressivo Integrado de Médias Móveis, ou *Auto-Regressive Integrated Moving Average*, comumente conhecido apenas pela sigla ARIMA usa o conceito de atraso e deslocamento de informações passadas para prever padrões futuros. (NISHA; SREEKUMAR, 2017). De acordo com Rossi (2013), esse tipo de modelo é muito popular por causa de suas propriedades estatísticas. Os modelos ARIMA possuem características flexíveis, que permitem ajustes e adaptações de seus parâmetros, fazendo com que diferentes tipos de séries temporais possam ser representadas através dele. Os modelos ARIMA também podem ser considerados bastante flexíveis, por terem a capacidade de representar séries temporais como o Auto-Regressivo puro (AR), Médias Móveis puro (MA), e a série combinada ARMA. Se o modelo for bem modelado, ele é mais do que capaz de fornecer bons resultados de previsões computacionais.

O modelo ARIMA é uma generalização dos modelos citados anteriormente por Rossi (2013):

- ARIMA (p, 0, 0) = AR (p);

- ARIMA (0, 0, q) = MA (q);
- ARIMA (p, 0, q) = ARMA (p, q).

De acordo com Neto (2011), a equação auto-regressiva de médias móveis, ARMA (p, q), pode ser descrita pela Equação 1:

$$y_t = \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + u_t - \theta_1 u_{t-1} - \dots - \theta_q u_{t-q} \quad (1)$$

onde  $\phi$  e  $\theta$  são os parâmetros do modelo proposto e  $u_t$  é o termo de erro do modelo. As variáveis  $y_t$  representam a parte Auto-Regressiva do modelo, conhecida como AR (p), enquanto que  $u_t$  representam a parte das Médias Móveis, conhecida como MA (q).

Conforme Neto (2011), na equação ARMA (p, q) explicada acima, ainda falta um termo de Integração  $I$  para que o modelo esteja de forma completa. Dessa forma, o modelo ARIMA (p,d,q) completo é obtido pela Equação 2:

$$y_t = \phi_1 y_{t-1} + \dots + \phi_{p+d} y_{t-p-d} + u_t - \theta_1 u_{t-1} - \dots - \theta_q u_{t-q} \quad (2)$$

Os modelos ARIMA são extremamente úteis na previsão de diferentes séries setoriais, pois podem representar séries estacionárias, através do uso do modelo ARIMA (p, 0, q), e também séries não-estacionárias, através do modelo ARIMA completo (p,d,q), sendo que o ajuste destes modelos sempre foi notável com relação ao desempenho para previsões. (NETO, 2011). Uma das etapas mais importante do ciclo iterativo do método é a identificação do modelo ARIMA. Nessa fase o principal objetivo é encontrar os valores adequados para  $p$ ,  $d$  e  $q$  e também determinar os parâmetros que vão ser úteis nas próximas etapas. (ROSSI, 2013).

Depois de identificados os parâmetros, deve-se verificar se os mesmos foram bem representados. Uma das técnicas para fazer isso é o *superajustamento*, onde é estimado um modelo com parâmetros extras e examinado se estes são significativos. Logo após, verificar se a inclusão dele diminui significativamente a variância residual. Para isso é necessário analisar os resíduos do modelo ajustado. Então se a Equação 3:


$$\phi(B)W_t = \theta(B)a_t \quad (3)$$

for verdadeira, com  $W_t = \Delta^d Z_t$ , então, os “erros verdadeiros”  $a_t = \theta^{-1}(B)\phi(B)W_t$  serão ruído branco. Após os modelos já identificados, estimados e diagnosticados para que representem adequadamente os dados observados, eles estão prontos para realizar o processo de previsão conforme a necessidade. (ROSSI, 2013).

## 2.4 Elasticidade de Recursos

Al-Dhuraibi et al. (2017) definem o conceito de elasticidade como a habilidade de um sistema ser capaz de adicionar ou remover recursos computacionais durante o uso e processamento

dos dados, de forma a se adaptar a variação de carga de trabalho em tempo real. Estes recursos podem ser núcleos de CPU, memória RAM, GPU, instâncias de Máquinas Virtuais (conhecidas como *Virtual Machines* ou VM's), entre outros. Ainda de acordo com Al-Dhuraibi et al. (2017), elasticidade é uma propriedade dinâmica da Computação em Nuvem (conhecida como *Cloud Computing*). Existem dois tipos de elasticidade na literatura: horizontal e vertical. A elasticidade vertical consiste na capacidade do sistema de aumentar ou diminuir as características dos recursos computacionais, tais como Tempo de CPU, núcleos, memória e rede. Já a elasticidade horizontal consiste na capacidade do sistema de adicionar ou remover instâncias dos recursos computacionais associados a aplicação que os usa. A Figura 7 ilustra ambos os conceitos, onde no eixo horizontal é possível ver o aumento da quantidade de nós computacionais, através da elasticidade horizontal, e no eixo vertical é possível ver o aumento de tamanho dos nós, representando o aumento dos recursos dos mesmos, através da elasticidade vertical.



Fonte: Al-Dhuraibi et al. (2017), traduzida pelo autor.

Conforme a pesquisa de Rostirolla et al. (2017), o conceito de elasticidade pode ser estendido para o gerenciamento de consumo de energia em cidades inteligentes, de forma que os recursos de uma cidade podem ser ligados e desligados automaticamente, conforme a necessidade dos usuários. Com base nisso, pode-se inferir que o conceito de elasticidade apesar de proposto para a alocação dinâmica de recursos na computação em nuvem pode ser estendido para outras áreas de aplicação. Para Al-Dhuraibi et al. (2017) e Rostirolla et al. (2017) escalabilidade é a habilidade de um sistema de sustentar crescentes cargas de trabalho, fazendo uso dos mais diversos recursos adicionais. Assim, para ter uma melhor compreensão e ilustrar o assunto, Al-Dhuraibi et al. (2017) resumiram o conceito de elasticidade na seguinte equação:

$$Elasticidade = \underbrace{\text{escalabilidade} + \text{automação}}_{\text{auto-escalabilidade}} + \text{otimização}$$




Com base nessa fórmula, Al-Dhuraibi et al. (2017) dizem que a elasticidade é construída em cima do conceito de escalabilidade, podendo ser considerada uma automação desse processo, no entanto, visa otimizar o mais rápido possível os recursos em um determinado momento de um sistema qualquer. Outro termo bastante associado com a elasticidade é a eficiência, que tenta definir de forma adequada como um recurso pode ser eficientemente utilizado junto ao processo de escalonamento de um sistema. Dessa forma, quanto menor a quantidade de recursos utilizados para realizar uma determinada tarefa em um tempo aceitável, melhor é a eficiência do sistema escalável.

A elasticidade, ou as ações de redimensionamento de recursos, idealmente deve ser invisível para o usuário do sistema, devido a dinamicidade do provisionamento dos recursos. A elasticidade é extremamente dependente do tempo do sistema. Portanto, a velocidade para realizar os ajustes é um ponto extremamente importante para a elasticidade. O tempo de reação é o intervalo de tempo entre o momento em que uma reconfiguração foi acionada ou solicitada, até que esta adaptação tenha sido concluída. Sistemas elásticos podem ser classificados de várias formas, dependendo de seus atributos, que podem ser: (I) Configuração, (II) Escopo, (III) Objetivo, (IV) Método, (V) Arquitetura, (VI) Provedor e (VII) Modo de Operação. (AL-DHURAIBI et al., 2017).

#### 2.4.1 Configuração

Segundo Al-Dhuraibi et al. (2017), a configuração de um sistema elástico refere-se a alocação específica de CPU, memória, rede e armazenamento. Nesse contexto, a configuração representa a reserva inicial de recursos para o sistema. Durante a primeira aquisição do serviço elástico, o usuário geralmente escolhe entre uma lista de pacotes de recursos, conforme a sua necessidade.



Fonte: Elaborada pelo autor, com base em Al-Dhuraibi et al. (2017).


De acordo com Al-Dhuraibi et al. (2017) e conforme pode ser visto na Figura 8, a configuração pode ter dois modos de operação: (I) Rígido ou (II) Configurável. No modo rígido, os recursos são oferecidos e provisionados em capacidades constantes. Nesse modo, as instâncias de máquinas virtuais possuem limites predefinidos de recursos (CPU, memória, entre outros). O problema com a configuração rígida é que os recursos alocados raramente atendem à demanda, portanto, há sempre um provisionamento inferior ou excessivo ao que realmente é necessário. Já no modo configurável, o cliente é capaz de escolher os recursos específicos de cada uma das

máquinas virtuais. Para ambos os modos, os usuários podem reservar os recursos de acordo com os seguintes métodos de reserva:

- **Reserva sob demanda:** Os recursos são reservados imediatamente ou as solicitações são rejeitadas se não houver recursos disponíveis suficientes.
- **Reserva antecipada:** Os clientes enviam solicitações iniciais para reservar recursos e uma cobrança de preço fixo é necessária para iniciar a reserva. Os recursos devem estar disponíveis em um horário pré-especificado.
- **Reserva de melhor esforço:** As solicitações de reserva são enfileiradas e atendidas adequadamente conforme o esforço necessário.
- **Reserva baseada em leilão:** Configurações específicas de recursos são reservadas dinamicamente assim que seus preços são inferiores ao valor do lance oferecido pelo cliente.

#### 2.4.2 Escopo

Para Al-Dhuraibi et al. (2017) e conforme pode ser visto na Figura 9, as ações de elasticidade podem ser aplicadas em dois níveis, de **infraestrutura** ou de **aplicação/plataforma**. As ações de elasticidade são responsáveis por executar as decisões tomadas pelo sistema de controle de elasticidade, de forma a dimensionar os recursos conforme a necessidade e a estratégia estabelecida. As ações de elasticidade podem ser executadas no nível de infraestrutura, onde o controlador de elasticidade monitora o sistema e toma as decisões. As infraestruturas de nuvem são baseadas na tecnologia de virtualização, que podem ser máquinas virtuais ou contêineres. Além disso, com relação a aplicação/plataforma, as mesmas podem ser de (I) uma camada ou (II) várias camadas.



Fonte: Elaborada pelo autor, com base em Al-Dhuraibi et al. (2017).

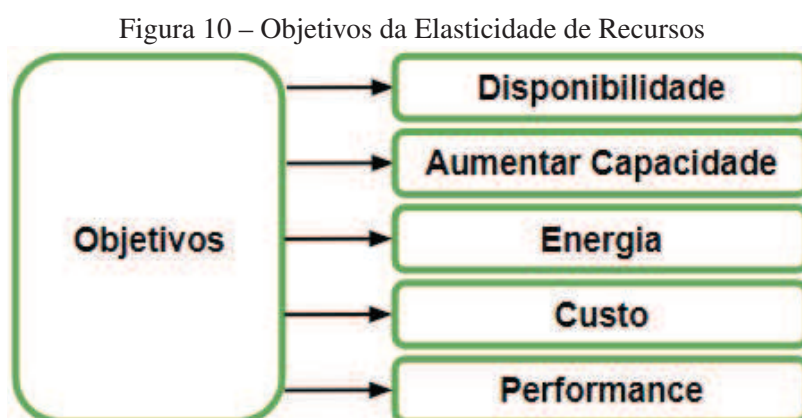
A maioria das soluções de elasticidade existentes são dedicadas a aplicações de uma camada onde o gerenciamento de elasticidade é realizado apenas em uma camada, principalmente a de negócios. Quando o controle de ação de elasticidade está no nível de aplicação/plataforma, ele é denominado elasticidade embarcada. A maioria das soluções existentes é dedicada a aplicações baseadas em servidor. No entanto, existem aplicações que têm particularidades de comportamento de execução diferentes, como aplicações científicas. Devido à natureza de uma aplicação



científica, como paralelismo e modelos, uma solução de elasticidade não pode ser generalizada. A solução de elasticidade deve considerar a estrutura interna e o comportamento de uma aplicação científica, portanto, para ter uma solução elástica confiável, ela deve ser incorporada no código fonte da aplicação. Na elasticidade embarcada, as aplicações elásticas são capazes de ajustar seus próprios recursos de acordo com os requisitos de tempo de execução ou devido a mudanças no fluxo de execução. (AL-DHURAIBI et al., 2017).

### 2.4.3 Objetivo

A elasticidade de recursos pode ter diferentes propósitos, como melhorar o desempenho, aumentar a capacidade de recursos, economizar energia, reduzir custos e garantir a disponibilidade. Com relação aos objetivos da elasticidade, há diferentes perspectivas: Os provedores da *Cloud IaaS (Infrastructure as a Service* ou Infraestrutura como Serviço) tentam maximizar o lucro minimizando os recursos enquanto oferecem uma boa Qualidade de Serviço (*Quality of Service* ou QoS), os provedores de *PaaS (Platform as a Service* ou Plataforma como Serviço) procuram minimizar o custo que pagam à nuvem e os clientes buscam aumentar sua Qualidade de Experiência (*Quality of Experience* ou QoE) e minimizar seus pagamentos. As soluções de elasticidade não podem cumprir os propósitos de elasticidade de diferentes perspectivas ao mesmo tempo, cada solução normalmente lida com uma perspectiva. No entanto, algumas soluções tentam encontrar uma maneira ideal de equilibrar alguns dos objetivos contraditórios. (AL-DHURAIBI et al., 2017). A Figura 10 apresenta todos os objetivos encontrados para sistemas de elasticidade de recursos encontrados por Al-Dhuraibi et al. (2017) em sua pesquisa.

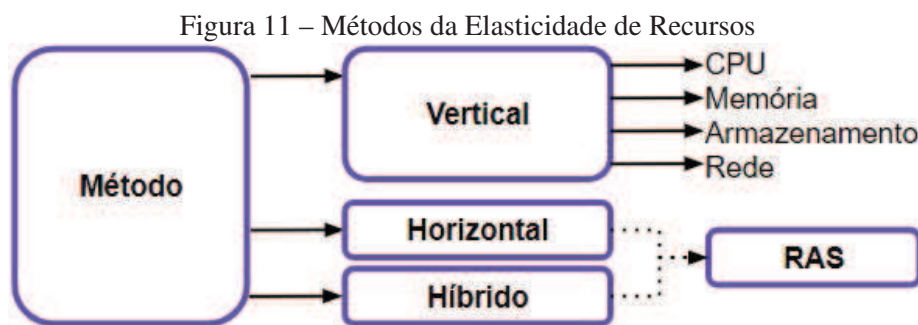


Fonte: Elaborada pelo autor, com base em Al-Dhuraibi et al. (2017).

### 2.4.4 Método

De acordo com Al-Dhuraibi et al. (2017), para implantar soluções de elasticidade, deve ser implementado um dos seguintes métodos: escalabilidade horizontal, escalabilidade vertical ou

escalabilidade híbrida. Técnicas de escalabilidade horizontais e verticais têm suas vantagens e desvantagens. A elasticidade horizontal é fácil de implementar e é amplamente utilizada no meio comercial. No entanto, ela pode levar a uma utilização ineficiente dos recursos, devido ao fato de fornecer instâncias fixas ou estáticas, que na maioria das vezes não são capazes de se ajustar exatamente a demanda requerida pela aplicação. Já a elasticidade vertical permite redimensionar as instâncias, entretanto não é amplamente utilizada, tendo poucos sistemas comerciais que a suportem. Como dito anteriormente, na escalabilidade horizontal, instâncias são adicionadas e removidas conforme técnicas de balanceador de carga e na escalabilidade vertical, recursos como memória, CPU, são redimensionados em tempo de execução como pode ser visto na Figura 11.




Fonte: Elaborada pelo autor, com base em Al-Dhuraibi et al. (2017).

A migração também pode ser considerada como uma ação necessária para permitir ainda mais o redimensionamento vertical quando não há recursos suficientes disponíveis, ou quando é necessário transferir uma instância para uma máquina física com menos recursos de forma a melhorar o desempenho. Antes de executar o processo de migração ou replicação de VMs, uma Estratégia de Alocação de Recursos (Resource Allocation Strategy ou RAS) é utilizada para decidir onde a nova instância será alocada ou criada, em qual servidor da nuvem. Existem ainda sistemas que utilizam uma estrutura que combinam o redimensionamento vertical, adicionado e removendo recursos de VMs existentes, e dimensionamento horizontal, adicionando novas VMs conforme a necessidade. O RAS pode ser baseado no custo e velocidade do uso de cada máquina virtual, no uso e custo de CPU da máquina física, nas condições de carga especificadas pelo usuário, dentre outros. (AL-DHURAIBI et al., 2017).

#### 2.4.5 Arquitetura

Para Al-Dhuraibi et al. (2017) e como pode ser visto na Figura 12, a arquitetura das soluções para gerenciamento de elasticidade de recursos pode ser centralizada ou descentralizada. Na arquitetura centralizada existe apenas um controlador de elasticidade, responsável por realizar o redimensionamento automático, provisionando e desprovisionando recursos. Já na arquitetura descentralizada, existem vários controladores de elasticidade, responsáveis pelo provisionamento de recursos em diferentes plataformas em nuvem. Nesse modelo existe ainda um árbitro,


considerado um ponto chave na arquitetura descentralizada, responsável por alocar recursos para os controladores nos diferentes componentes do sistema.



Fonte: Elaborada pelo autor, com base em Al-Dhuraibi et al. (2017).

#### 2.4.6 Provedor

Conforme Al-Dhuraibi et al. (2017) e como pode ser visto na Figura 13, as soluções de elasticidade de recursos podem ser aplicadas a um ou a vários provedores da nuvem. Um único provedor de nuvem pode ser público ou privado, estando presente fisicamente em uma ou várias regiões ou centros de dados. Nesse contexto, várias nuvens significam que existem mais de um provedor de nuvem. Provedores de nuvem podem incluir nuvens híbridas que podem ser privadas ou públicas. A maioria das soluções e propostas para elasticidade de recursos suporta apenas um único provedor de nuvem.

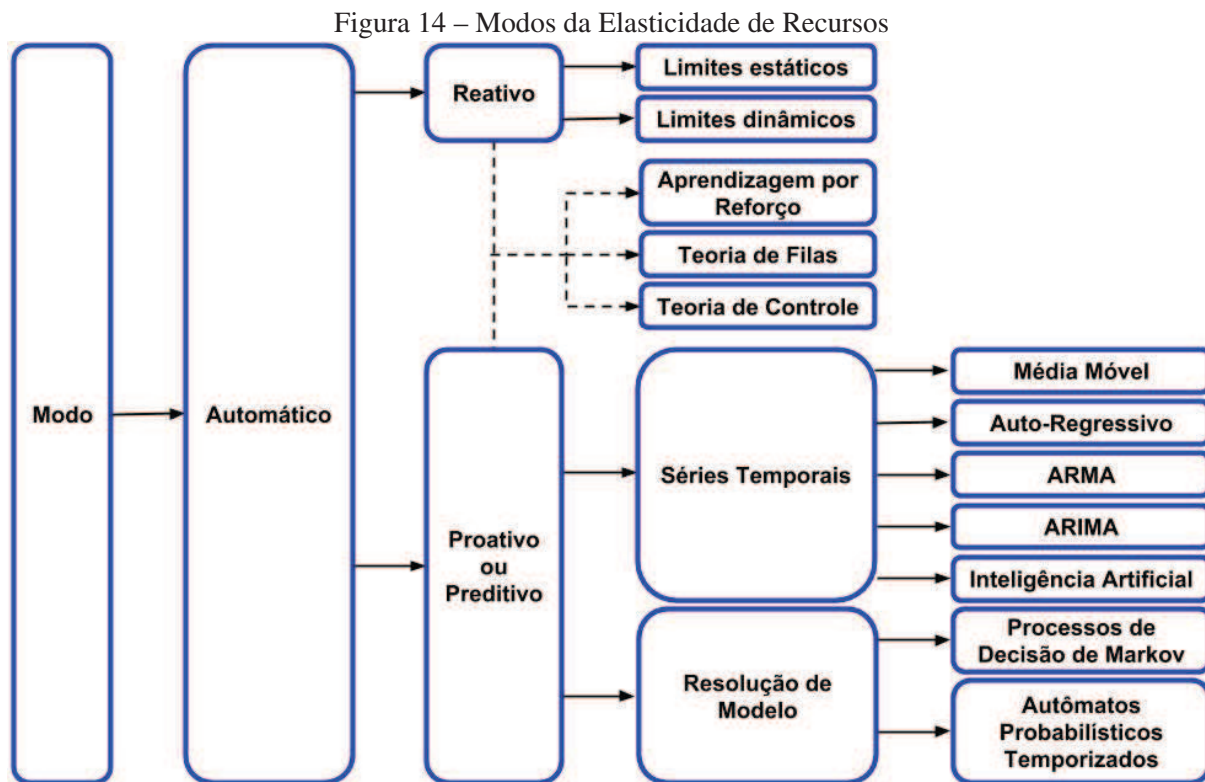


Fonte: Elaborada pelo autor, com base em Al-Dhuraibi et al. (2017).

#### 2.4.7 Modo de Operação

Modo de operação refere-se às interações necessárias para realizar as ações de elasticidade no sistema. Normalmente, ações de elasticidade são executadas de forma automática. Ações de escalabilidade podem ser alcançadas por intervenção manual do usuário, através de um modo manual ou programável, onde as ações de elasticidade são geralmente executadas através de uma Interface de Programação de Aplicações (Application Programming Interface, comumente conhecida como API). A política manual é usada em alguns sistemas comerciais de nuvem onde o usuário é responsável por realizar o monitoramento do ambiente virtual e por executar todas as ações de redimensionamento. Este modo apesar de ser atrelado ao conceito de escalabilidade, não pode ser considerado como um modo de elasticidade, uma vez que viola o conceito de

automação, necessário para o sistema ser considerado elástico. Dessa forma, um sistema elástico possui apenas um modo, o modo automático, onde todas as ações de redimensionamento são realizadas automaticamente, podendo ser classificado em dois sub-modos: (I) Reativo e (II) Proativo ou Preditivo, conforme pode ser visto na Figura 14. (AL-DHURAIBI et al., 2017).



Fonte: Elaborada pelo autor, com base em Al-Dhuraibi et al. (2017).

Na elasticidade reativa, as ações de elasticidade são disparadas conforme regras ou *thresholds* predefinidos, fazendo com que o sistema reaja disparando ações para adaptar as alterações no sistema de acordo com a carga (carga de trabalho ou utilização de recursos). Nesse modo, existem duas abordagens principais, baseadas em (I) Limites Estáticos e em (II) Limites Dinâmicos. (AL-DHURAIBI et al., 2017).

Nos limites estáticos as ações de elasticidade são disparadas para aumentar ou diminuir recursos quando uma determinada condição é atendida. Essa política depende de limites ou requisitos predeterminados, onde as condições são baseadas nas medidas de um ou de um conjunto de métricas de recursos, como uso de CPU, utilização de memória, tempo de resposta entre outros. Geralmente dois ou mais limites são usados para cada métrica, assim os valores medidos são comparados com as métricas para realizar o processo de escalabilidade. Um exemplo poderia ser: se a utilização da CPU for maior que 80% e essa situação durar por 5 minutos, o recurso deverá ser redimensionado. Já nos limites dinâmicos, ocorre o contrário, os limites não são estáticos e sim adaptativos, isto é, eles mudam dinamicamente de acordo com o estado das aplicações que os hospedam. (AL-DHURAIBI et al., 2017).

De acordo com Al-Dhuraibi et al. (2017), na elasticidade proativa ou preditiva, as ações

de elasticidade são disparadas com base em técnicas de previsão, antecipando as necessidades futuras da aplicação e acionando ações de elasticidade com base nessa antecipação prevista. Nesse modo, existem duas abordagens principais, baseadas em (I) Análise de Séries Temporais e (II) Mecanismos de Resolução de Modelos.

A análise de séries temporais, é usada para identificar padrões de repetição na carga de trabalho do sistema ao longo do tempo e para tentar prever os valores futuros dessa carga de trabalho. Assim, essa abordagem é responsável por fazer uma estimativa do uso futuro de um determinado recurso e da carga de trabalho da aplicação e, com base nessa previsão, o controlador de elasticidade executará as ações necessárias conforme seu método de redimensionamento. Geralmente, a análise de séries temporais possui dois objetivos principais: prever valores futuros da série temporal com base nas últimas observações e identificar os padrões repetidos, se encontrados, de forma a usá-los para prever valores futuros. Para alcançar este objetivo, existem várias técnicas, como Média Móvel, Auto-Regressivo, série combinada ARMA, modelo ARIMA (apresentados na Subseção 2.3.1) e Inteligência Artificial. (AL-DHURAIBI et al., 2017).

Já os mecanismos de resolução de modelos são abordagens baseadas na verificação probabilística de modelos ou estruturas de modelagem matemática para estudar os diversos comportamentos do sistema e antecipar seus estados futuros, como Processos de Decisão de Markov e Autômatos Probabilísticos Temporizados. Existem outros mecanismos que podem ser usados tanto com abordagens reativas quanto proativas, como: Aprendizagem por Reforço, Teoria de Filas e Teoria de Controle. (AL-DHURAIBI et al., 2017).

## **2.5 Considerações Parciais**

Este capítulo apresentou conceitos pertinentes para a compreensão do restante do trabalho. Primeiramente foram apresentados os conceitos relacionados a Internet das Coisas, os quais são fundamentais para a coleta de dados necessária ao modelo EIHealth. A seguir, são apresentados os processos hospitalares, um item fundamental para entendimento de um modelo de aplicação para a área da saúde. Após, são apresentadas técnicas de previsão computacional, e um detalhamento do modelo estatístico para análise de séries temporais, noções importantes para o modelo preditivo de demanda de pacientes proposto. Por fim, são retratados os conceitos relacionados a elasticidade de recursos computacionais, fundamentais para o modelo de elasticidade de recursos humanos propostas pelo modelo EIHealth. Estes conceitos compõem a base necessária para compreensão das tecnologias utilizadas e as decisões tomadas para o modelo proposto.



### 3 TRABALHOS RELACIONADOS

Este capítulo tem como objetivo apresentar os trabalhos relacionados ao modelo proposto. Com base no tema de pesquisa, foram analisados alguns trabalhos relacionados que tentam resolver problemas parecidos, ou que servem como base para possíveis tentativas de solução. Desse forma, as próximas Seções descrevem algumas abordagens que utilizam Internet das Coisas e predição computacional para suporte na área de saúde, a fim de obter uma visão do atual estado da arte dessas tecnologias. Os artigos foram classificados em ordem crescente por ano de publicação e depois por ordem alfabética dos nomes dos autores. Por fim, as iniciativas serão comparadas e analisadas para identificar as atuais lacunas na literatura da área.

#### 3.1 Metodologia de Pesquisa e Seleção dos Trabalhos

De acordo com os estudos de Roehrs et al. (2017), a definição da estratégia de pesquisa é um dos passos mais importantes de uma revisão da literatura. Nesse processo foram definidas as palavras-chaves de pesquisa e a definição do escopo de pesquisa. Essas palavras foram definidas de forma a se obter os resultados de pesquisa focados no tema deste trabalho. Portanto, a *String de Pesquisa* localizada na Caixa de Texto 1 foi definida para a busca e seleção dos artigos nas bibliotecas acadêmicas eletrônicas.

##### Caixa de Texto 1: String de Pesquisa

*((prediction OR analytics OR forecast OR time serie) AND (health OR healthcare OR hospitalar OR clinical) AND ((Internet of Things OR IoT OR sensors) OR (human resource OR human resource management OR hr OR hr management OR nurse management OR resource)))*

Fonte: Elaborada pelo autor.

De forma a se cobrir um grande número de estudos, foram selecionadas várias bibliotecas científicas eletrônicas para serem utilizadas como base para pesquisa dos trabalhos relacionados, sendo elas: *ACM Digital Library, Google Scholar, IEEE Xplore Digital Library, IET Digital Library, PubMed, Elsevier B. V. ScienceDirect e Wiley Online Library*. De acordo com Roehrs et al. (2017), estes portais são algumas das bibliotecas que cobrem os jornais e conferências mais relevantes da área da ciência da computação. Durante a busca por trabalhos relacionados, não foram encontrados trabalhos que utilizem o conceito de Internet das Coisas, juntamente com técnicas de predição para antecipar a demanda por recursos humanos e propor soluções concretas nesse aspecto. Após a realização da busca, apenas trabalhos que envolvem alguns critérios, mas não todos, foram encontrados. Dessa forma optou-se por selecionar trabalhos que relacionassem no mínimo dois dos seguintes critérios:

- Critério 1: Trabalho aborda o uso de sistemas IoT para saúde.
- Critério 2: Trabalho aborda o uso de técnicas de predição computacional na área da saúde.



- Critério 3: Trabalho aborda a falta de recursos humanos para atender a demanda de pacientes

Na Tabela 3 são apresentados todos os Trabalhos Relacionados selecionados, trazendo: (I) Um identificador para cada um deles, (II) os nomes dos autores em formato de referência bibliográfica, juntamente com o ano da publicação, (III) a *publisher* da publicação, e o (IV) tipo de publicação, que pode ser artigo de revista ou artigo de conferência. Os trabalhos foram ordenados em ordem ascendente pelo ano de publicação e, após, por ordem alfabética dos nomes dos autores.

Tabela 3 – Trabalhos selecionados

Identificador	Autores (ano)	Publisher	Tipo
TR1	Orimaye et al. (2015)	IEEE	Conferência
TR2	Vieira e Hollmén (2016)	IEEE	Conferência
TR3	Ishikawa et al. (2017)	BioMed Central	Revista
TR4	Liu et al. (2017)	BioMed Central	Revista
TR5	Zamanifar, Nazemi e Vahidi-Asl (2017)	Elsevier	Revista
TR6	Ali et al. (2018)	Elsevier	Revista
TR7	Graham et al. (2018)	IEEE	Revista

Fonte: Elaborada pelo autor.

### 3.2 Predicting proximity with ambient mobile sensors for non-invasive health diagnostics (ORIMAYE et al., 2015)

Orimaye et al. (2015) realizaram uma pesquisa na área de reconhecimento da proximidade de seres humanos através de dispositivos móveis. Segundos os autores, os cada vez mais modernos *smartphones* estão se tornando extremamente úteis para a Internet das Coisas e para a área da saúde. O reconhecimento da proximidade humana pode ser considerado importante e pode mudar significativamente a forma como as pessoas interagem com dispositivos móveis e sensores. Através do uso da técnica de reconhecimento de proximidade, em uma ambiente inteligente de saúde, sinais vitais dos pacientes podem ser capturados por diversos tipos de sensores de forma automática, transparente e não-invasiva. Um exemplo, seria o uso de sensores ambientais em um determinado local, capazes de capturar informações que possam ser prejudiciais a pacientes. Assim, uma pessoa que possui asma pode ser alertada sobre um ambiente prejudicial a sua condição. Detectar as mudanças ambientais em torno dos humanos poderia potencialmente prevenir problemas de saúde. Um ponto importante a se mostrar é que as abordagens para análise ambientais se baseiam em sensores capturando dados a todo momento, mas nem sempre os dados capturados são úteis, gastando recursos em momentos desnecessários.

Neste contexto, o sistema proposto por Orimaye et al. (2015) tem como objetivo identificar a aproximação de pessoas em um ambiente tridimensional, sem nenhum contato físico, através do uso de dispositivos móveis. O objetivo do sistema é habilitar sensores localizados em ambiente



por onde os pacientes podem passar para realizarem diagnósticos de saúde de forma automática e não-invasiva. Para isso, os autores mostraram que o corpo humano gera padrões que interagem com outros sinais ambientais que ocorrem naturalmente e que podem ser medidos por sensores móveis, como temperatura, umidade, campo magnético, aceleração, gravidade e luz. Essa interação com o corpo humano altera os padrões dos sinais que ocorrem naturalmente e, portanto, exibe características que podem ser aprendidas para prever a proximidade do corpo humano a um dispositivo móvel, fornecendo, portanto, informações diagnósticas para médicos. Para realizar essa previsão, os autores utilizaram o método *Sequential Minimal Optimization* (SMO), uma variante do método *Support Vector Machines* (SVM).

Para avaliar o sistema, Orimaye et al. (2015) compararam os resultados obtidos pela SVM proposta com outros dois métodos de predição. A técnica mostrou resultados promissores quando comparada com as outras técnicas. Entretanto, a grande limitação do modelo proposto pelos autores está no fato dos testes terem sido conduzidos por sensores em um ambiente controlado. O sistema seria útil para ambientes não-controlados como espaços públicos, o que requer o desenvolvimento de algoritmos mais complexos. A título de trabalhos futuros, os autores planejam detectar a respiração humana usando as mesmas técnicas propostas, e incluir uma interface web para o uso da aplicação por médicos.

### **3.3 Resource Frequency Prediction in Healthcare: Machine Learning Approach (VIEIRA; HOLLMÉN, 2016)**

Vieira e Hollmén (2016) focaram sua pesquisa na simulação e otimização hospitalar. De acordo com os autores, um problema comum nos centros de saúde é como determinar com eficiência quantos e quais tipos de recursos serão necessários para melhorar e manter um fluxo de atendimento de pacientes desejável. O simples aumento no número de recursos acaba por causar problemas na otimização de recursos individuais. Determinar a quantidade adequada de recursos necessários para garantir o fluxo de atendimento não apenas promove a satisfação dos pacientes, mas também proporciona benefícios financeiros aos hospitais. Além disso, ainda de acordo com os autores, o aumento dos dados coletados pelas unidades de saúde nos últimos anos acaba por trazer novas oportunidades para aplicar técnicas de aprendizado de máquina para lidar com os problemas expostos.

Nesse contexto, Vieira e Hollmén (2016) propuseram um sistema para identificar o número de recursos necessários para garantir um número mínimo de gargalos no fluxo de atendimento hospitalar, a fim de melhorar a satisfação dos pacientes atendidos e proporcionar benefícios financeiros aos hospitais. Para realizar a previsão do uso de recursos, foram utilizados dados sobre visitas, reservas, pacientes e recursos (médicos, maquinário e aparelhos), coletados entre agosto de 2011 e novembro de 2014 no Hospital da Universidade de Oulu, na Finlândia. Para realizar predição, o sistema proposto faz uso das técnicas de *Random Forest* e *Nearest Neighbours*. A aplicação de técnicas de *clustering* de dados como uma etapa de pré-processamento

também é explorada como uma maneira de melhorar a precisão da previsão de recursos cujo comportamento muda com o tempo.

De acordo com os autores, os resultados encontrados após o treinamento do modelo e testes do mesmo foram satisfatórios, indicando que os recursos altamente utilizados podem ser previstos com maior precisão do que os recursos menos utilizados. Também foi possível notar que apesar de *Random Forest* e *Nearest Neighbours* possuírem um desempenho semelhante no problema estudado, a técnica de *Random Forest* acaba por ter um desempenho melhor. Além disso, o processo de *clustering* é capaz de melhorar o desempenho da técnica de *Nearest Neighbours*, mas não modifica a performance nas *Random Forests*.

### **3.4 Forecasting the regional distribution and sufficiency of physicians in Japan with a coupled system dynamics: geographic information system model (ISHIKAWA et al., 2017)**

Ishikawa et al. (2017) focaram seus estudos no desequilíbrio entre oferta e demanda de recursos humanos para a área da saúde. De acordo com os autores, a falta de médicos é um problema comum tanto em nações em desenvolvimento como em países desenvolvidos. Um dos principais problemas é a má distribuição da força de trabalho. Dessa forma, é essencial o uso de técnicas de predição para prever o suprimento de recursos humanos na área de saúde, de forma a propor políticas para tratar o problema baseadas em evidências.

Dessa forma, Ishikawa et al. (2017) propuseram um sistema para identificar a distribuição e suficiência de médicos na província de Hokkaido, no Japão, até 2030, a fim de propor formas de garantir o atendimento da demanda atual de pacientes. Para tanto, os autores combinaram o modelo de *System Dynamics* (SD) juntamente com a tecnologia dos sistemas de informação geográfica (Geographic Information System ou GIS) para identificar as mudanças no equilíbrio oferta-demanda tanto em função da área geográfica quanto em função do tempo. Para validar o modelo de previsão proposto, foram comparados os resultados de predição com os valores efetivamente apurados entre os anos de 1998 e 2008. Para determinar a suficiência de médicos, foi comparada a quantidade necessária de médicos para cada 1000 habitantes com o número previsto de doutores.

Assim, combinando a pesquisa na previsão de número de médicos com uma previsão do número de especialistas, foi possível para os autores proporem um plano para treinamento de médicos que considerassem os requisitos geográficos. O modelo proposto foi capaz de prever que até 2020 a falta de médicos na província de Hokkaido no Japão poderia ser resolvida.

### **3.5 Global Health Workforce Labor Market Projections for 2030 (LIU et al., 2017)**

Liu et al. (2017) focaram seus estudos na falta de recursos humanos para a área da saúde em países de baixa e média renda. Conforme os autores puderem identificar, o problema da falta de

recursos humanos está relacionado a diversos fatores, como a baixa oferta de profissionais qualificados, a má distribuição dos mesmos nos locais onde mais são necessários, a produtividade dos trabalhadores da área da saúde, e a qualidade dos cuidados que são prestados. De acordo com os autores, pesquisadores e agências internacionais chamaram a atenção para a escassez global e má distribuição da força de trabalho em saúde, para que os governos façam esforços conjuntos para enfrentar esses desafios, a fim de alcançar a cobertura universal de saúde.

Assim, Liu et al. (2017) propuseram um sistema para identificar a distribuição e suficiência de médicos até o ano de 2030 em escala global. Além disso, também identificar a demanda futura de pacientes de forma a comparar as projeções de demanda com o crescimento projetado na oferta de profissionais de saúde; e também identificar as necessidades dos trabalhadores de saúde, conforme estimados pela Organização Mundial de Saúde para alcançar os objetivos de desenvolvimento sustentável e a cobertura essencial de saúde. Os autores adotaram uma abordagem para projetar a demanda futura da força de trabalho em saúde utilizando um Modelo Linear Generalizado com base no crescimento econômico projetado, na demografia e na cobertura de saúde, e no uso de dados da força de trabalho em saúde entre 1990 e 2013 para 165 países do Observatório Mundial de Saúde.

O modelo proposto prevê que a demanda global por profissionais de saúde aumentará para 80 milhões de trabalhadores em 2030, enquanto a oferta de recursos humanos deverá chegar a aproximadamente 65 milhões no mesmo período, resultando em uma escassez líquida mundial de 15 milhões de trabalhadores de saúde. De acordo com os autores, a má distribuição da força de trabalho, vai beneficiar alguns países com maior renda, que vão acabar recebendo mais profissionais de saúde, aumentando ainda mais a falta de profissionais em países mais pobres.

### **3.6 DMP-IOT: A distributed movement prediction scheme for IOT health-care applications (ZAMANIFAR; NAZEMI; VAHIDI-ASL, 2017)**

Zamanifar, Nazemi e Vahidi-Asl (2017) focaram sua pesquisa na previsão de mobilidade em Redes WSNs baseadas em IP. Nessa rede é possível se realizar a previsão da direção de movimento dos sensores móveis, podendo resultar em um menor consumo de energia e um menor atraso durante a transferência dos dados. Sabendo a direção para onde os sensores móveis estão indo, a infraestrutura do ambiente pode se preparar com antecedência para uma melhor transferência dos dados, economizando energia mantendo desativados pontos por onde o sensor não está passando. O grande problema está no fato que muitas abordagens que tentam fazer isso precisam de instalações de hardware específicas e impõem uma sobrecarga considerável durante o processo de transferência.

Para abordar as questões mencionadas, Zamanifar, Nazemi e Vahidi-Asl (2017) desenvolveram um novo esquema de rede e previsão de movimento distribuído, conhecido como *Distributed Movement Prediction-IOT* ou apenas DMP-IOT. O sistema proposto é capaz de prever a direção do movimento dos sensores móveis em aplicações de saúde para reduzir o custo de

transferência dos sensores móveis. Para este fim, foi utilizado um modelo de Markov Oculto de segunda ordem (*Second-order Hidden Markov*) personalizado para previsão da mobilidade na aplicação de cuidados de saúde. O DMP-IOT inclui um mecanismo de recuperação de previsões falsas que evita a desconexão dos sensores na rede em caso de previsão incorreta do movimento do paciente. Para avaliar o DMP-IOT, foi realizada uma simulação do ambiente proposto. Os dados de movimentação de um determinado paciente foram gerados sinteticamente após o estudo do estilo de vida de vários idosos.

Os resultados da simulação feita pelos autores mostraram uma melhoria com o uso do DMP-IOT de cerca de 25% na economia de consumo de energia e na redução de atrasos e perda de pacotes, em comparação com abordagens de direção de movimento em trabalhos similares. Comparando o modelo de Markov Oculto de segunda ordem com Redes Neurais, os autores puderam revelar a superioridade do modelo proposto para a situação-problema estudada.

### **3.7 Type-2 fuzzy ontology-aided recommendation systems for IoT-based healthcare (ALI et al., 2018)**

Ali et al. (2018) focaram seus estudos no aumento significativo do número de pessoas com doenças crônicas nos últimos anos. Segundo os autores, a indústria médica está passando por cada vez mais desafios em função do aparecimento cada vez mais rápido das doenças crônicas e dos tratamentos médicos contínuos e extremamente longos. Com o aumento do número de pessoas doentes, e o avanço da idade das mesmas, fica cada vez mais difícil para elas se dirigirem para um posto de atendimento médico adequado. Nesse contexto, sensores vestíveis através da Internet das Coisas se tornam mais efetivos para extração de informações sobre a saúde de pacientes, de forma a ajudar no tratamento das doenças. Entretanto a tecnologia ainda possui problemas com relação a controle de dietas e de recomendação de medicamentos para pessoas com doenças como a diabetes. Hoje em dia, especialistas em saúde, como nutricionistas, analisam os dados dos pacientes e definem a melhor dieta baseado nos exames. O problema dessa abordagem está no fato que os índices relacionados a saúde dos pacientes mudam a todo momento, e uma dieta feita com um exame de sangue de um mês atrás, por exemplo, pode não ser mais tão eficiente atualmente.

Nesse contexto, Ali et al. (2018) propuseram um sistema de recomendação baseado em ontologias (modelo de dados que permite armazenar conhecimento e relações entre informações) *Fuzzy* e lógica *Fuzzy* do tipo 2 para aplicações de saúde baseadas em IoT, de forma a monitorar o paciente e, ao mesmo tempo, recomendar dietas com alimentos e medicamentos específicos para cada pessoa. O sistema proposto extrai os valores dos fatores de risco e determina a condição de saúde de cada paciente por meio de sensores vestíveis e, em seguida, recomenda prescrições específicas para uma caixa de medicamentos inteligente, e uma dieta com alimentos específicos para uma geladeira inteligente. A combinação da lógica *Fuzzy* do tipo 2 com ontologias *Fuzzy* aumenta significativamente a acurácia da predição das condições futuras de saúde

do paciente, aumentando também a precisão das recomendações de medicamentos e comida. As informações a respeito do histórico de doenças do paciente, hábitos alimentares, e remédios prescritos são armazenadas em uma ontologia para ajudar o sistema de tomada de decisão. Os dados que o sistema utiliza do paciente para realizar a predição e a recomendação são: pressão sanguínea, açúcar no sangue, colesterol, ritmo cardíaco, condição de saúde, idade, peso, sexo e altura.

Para avaliar o desempenho do sistema proposto, o mesmo foi implementado no ambiente de simulação Matlab<sup>1</sup>, que pode gerar as informações de sensores vestíveis, de forma a se encontrar os valores de risco para um paciente com diabetes. Os resultados experimentais mostraram que o sistema proposto é eficiente para extração de fatores de risco do paciente e prescrição de medicamentos e alimentação para pessoas com diabetes. O sistema foi comparado com uma abordagem baseada apenas em ontologias e outra em ontologias com lógica *Fuzzy* do tipo 1. Os resultados mostraram que o uso da lógica *Fuzzy* do tipo 2 com ontologias *Fuzzy* foram capazes de gerar recomendações mais precisas do que as outras abordagens. A título de trabalhos futuros, os autores vislumbram o uso da lógica *Fuzzy* do tipo 2 juntamente com redes neurais e um sistema de análise de sentimentos baseado em ontologias para criar um sistema de recomendação de tratamentos para doenças.

### **3.8 Using Data Mining to Predict Hospital Admissions From the Emergency Department (GRAHAM et al., 2018)**

Graham et al. (2018) estudaram a superlotação das emergências hospitalares e as consequências negativas significativas para os pacientes. De acordo com os autores, as emergências precisam explorar métodos inovadores para melhorar o fluxo de atendimento de pacientes, de forma a evitar e prevenir a superlotação. Uma forma de fazer isso é a através das técnicas de aprendizado de máquina e mineração de dados para prever a entrada de pacientes nos ambientes hospitalares. Dessa forma, os autores acreditam que através da previsão da chegada de pacientes, é possível preparar o ambiente hospitalar para a demanda de pacientes.

Nesse contexto, Graham et al. (2018) propuseram um sistema para prever a chegada de pacientes em um departamento de emergência de um hospital através do uso de técnicas de mineração de dados. Para tanto, o modelo proposto faz uso de dados administrativos coletados rotineiramente de dois hospitais na Irlanda do Norte para comparar algoritmos contrastantes de aprendizado de máquina na previsão do risco de admissão no departamento de emergência. Os autores usaram três algoritmos para construir modelos preditivos: regressão logística, árvores de decisão e Gradient Boosted Machines (GBM).

Através do modelo, os autores identificaram e puderam identificar que as GBM possuem um desempenho melhor que as árvores de decisão e regressão logística para previsão da chegada de pacientes. Através das técnicas estudadas, os autores também foram capazes de identificar

---

<sup>1</sup><https://www.mathworks.com/products/matlab.html>

vários fatores relacionados às internações hospitalares, incluindo local do hospital, idade, modo de chegada, categoria de triagem, grupo de cuidados, e internações anteriores do mesmo paciente no último mês e no ano anterior. Assim, de acordo com os autores, usando as informações identificadas pelo modelo, o gerente do hospital pode realizar o planejamento antecipado de recursos, evitando gargalos no fluxo do paciente. No entanto, embora o modelo possa ser usado para apoiar o planejamento e a tomada de decisões, os autores deixam claro que as decisões individuais de admissão ainda requerem o julgamento dos gestores.

### 3.9 Análise

Nesta revisão da literatura, buscou-se identificar uma amostra de estudos que permitisse obter uma visão do atual estado da arte das tecnologias relacionadas ao uso de Internet das Coisas e predição computacional para apoio na área da Saúde. A Tabela 4 apresenta uma comparação entre os artigos coletados, mostrando algumas lacunas em cada uma das abordagens, relacionando algumas de suas principais características, mostradas a seguir:

- **Problema:** Refere-se ao problema estudado pelos autores;
- **Proposta:** Refere-se a proposta de solução ao problema apresentada;
- **IoT:** Apresenta qual tarefa o trabalho realiza com a ajuda de sensores do paradigma Internet das Coisas;
- **Predição:** Relaciona em que tarefa o trabalho faz uso de técnicas de predição computacional; e
- **Recursos Humanos:** Refere-se as propostas, quando existentes, para tratar a falta de recursos humanos nos ambientes hospitalares

Com base nos artigos selecionados, pode-se identificar que existem atualmente várias frentes e abordagens quando o objetivo é prever problemas relacionadas à área de saúde utilizando os conceitos de Internet das Coisas e predição computacional. Através dos artigos pesquisados foi possível constatar que não só é possível utilizar a tecnologia para isso, como já está sendo utilizado em diversas abordagens na comunidade científica. A maioria dos sistemas que fazem uso da IoT com predição computacional para a área da saúde pesquisados se concentram no monitoramento das condições de saúde do paciente, a fim de gerar alertas caso sejam identificadas situações de risco. Esses sistemas são capazes de prever quando os sinais vitais do paciente vão entrar em situação de risco, ao mesmo tempo em que podem identificar problemas cardíacos, eficácia de tratamentos e situações de risco ambientais aos pacientes. Quando tem-se a predição computacional aliada com o problema da falta de recursos em ambientes hospitalares, os artigos encontrados se concentram apenas em prever a demanda futura dos pacientes ou a quantidade futura de médicos disponíveis, não propondo soluções para o problema, deixando para outros



Tabela 4 – Trabalhos selecionados

<b>Trabalho</b>	<b>Problema</b>	<b>Proposta</b>	<b>IoT</b>	<b>Predição</b>	<b>Recursos Humanos</b>
Orimaye et al. (2015)	Uso de sensores para coletar dados de pacientes	Ativar sensores não invasivos sob demanda	Identificar a localização dos pacientes	Localização futura de pacientes	Não aborda o problema
Vieira e Hollmén (2016)	Falta de recursos para o atendimento dos pacientes	Identificar a quantidade de recursos necessários para o atendimento	Não aplicável	Uso futuro de recursos	Não propõe soluções, apenas fornece dados para tomada de decisão
Ishikawa et al. (2017)	Falta de médicos para demanda de pacientes	Identificar distribuição e suficiência de médicos para propor um plano de ação	Não aplicável	Distribuição e suficiência de médicos	Propõe um plano para treinar médicos considerando requisitos geográficos
Liu et al. (2017)	Falta de médicos para atender a demanda global de pacientes	Identificar distribuição e suficiência de médicos e comparar com as projeções de demanda	Não aplicável	Distribuição e suficiência de profissionais de saúde, e demanda de pacientes	Não propõe soluções, apenas fornece dados para mostrar o crescimento do problema
Zamanifar, Nazemi e Vahidi-Asl (2017)	Consumo de energia, sobrecargas e perdas na transferência de dados entre sensores	Preparar sensores para coletar dados dos pacientes sob demanda	Identificar a localização dos pacientes	Localização futura de pacientes	Não aborda o problema
Ali et al. (2018)	Necessidade de cuidados médicos de longo prazo para pacientes com doenças crônicas	Recomendação de medicamentos e alimentos baseado no estado de saúde do paciente	Identificar o estado de saúde as condições do paciente	Estado futuro de saúde dos pacientes	Não aborda o problema, mas ajuda indiretamente, automatizando o tratamento
Graham et al. (2018)	Superlotação de emergências	Uso de mineração de dados para prever admissões em um hospital	Não aplicável	Chegada de pacientes na emergência	Não propõe soluções, apenas fornece dados para tomada de decisão

Fonte: Elaborada pelo autor.

a responsabilidade de procurar por soluções ao problema. Nesse contexto, podemos listar as seguintes lacunas na área:

- Mesmo esses modelos sendo capazes de integrar dados capturados por sensores de IoT com técnicas de predição de dados, eles não analisam o uso de recursos em ambientes hospitalares, nem a sobrecarga de pacientes em determinados locais;

- Embora existam vários modelos capazes de identificar a demanda futura em um ambiente hospitalar, falta a esses modelos propor soluções concretas para ajudar a resolver o problema da insuficiência de recursos hospitalares; e
- Falta a esses sistemas a capacidade de otimizar os processos de uma forma automatizada.

O problema da insuficiência de recursos humanos para atendimento hospitalar não é algo recente e pode-se notar que vários estudos mostram que no futuro ainda será um problema. Formas de otimizar o uso dos recursos existentes e ajustar a capacidade dos hospitais para atender a demanda de pacientes são desafios que podem fazer toda a diferença. O uso da Internet das Coisas juntamente com predição computacional auxilia na proposição de futuras soluções ou na automatização de processos na área da saúde. Mas o potencial das tecnologias está sendo subutilizado, já que é possível propor soluções como otimização e melhor aproveitamento dos recursos humanos existentes.

### **3.10 Considerações Parciais**

Este capítulo apresentou um levantamento de trabalhos relacionados a esta dissertação. Considerando os trabalhos encontrados, é possível encontrar soluções que façam uso de no máximo dois dos três critérios de inclusão estabelecidos na metodologia de pesquisa. Existem diversos sistemas que fazem uso de IoT para saúde, diversas frentes para uso de técnicas de predição para a saúde, e algumas frentes atuando na análise de recursos humanos. Dentre as frentes que abordam a falta de recursos humanos para atender a demanda de pacientes, nenhum trabalho propôs soluções concretas para ajudar a resolver o problema da insuficiência de pessoas para atendimento atualmente. Desta forma, identificou-se a oportunidade para um modelo elástico e multinível para gerenciamento de recursos humanos em hospitais inteligentes.



## 4 MODELO ELHEALTH

Com base no atual estado da arte e nas lacunas identificadas nos trabalhos relacionados, pode-se perceber que não apenas é possível realizar um controle do estado de saúde de pacientes em ambientes hospitalares através do uso da Internet das Coisas, como também identificar a localização de pessoas dentro de um ambiente qualquer utilizando-se da tecnologia. Entretanto, a maioria das abordagens vistas focam apenas em identificar a localização e o estado de saúde, atual e futuro, dos pacientes sem se preocupar em descobrir como adaptar os recursos do ambiente de saúde para melhor atendê-los. Como visto anteriormente, um dos principais problemas dos ambientes hospitalares é a superlotação de pacientes que acaba por criar grandes filas para atendimento. E por mais simples ou complicada que o problema de saúde de um determinado paciente pode ser, se a equipe médica não reagir a tempo não existem garantias sobre o futuro da saúde desse paciente. Com base nisso, o modelo aqui proposto tem como objetivo, utilizando-se das tecnologias da Internet das Coisas, identificar a entrada e saída de pacientes em um ambiente hospitalar de forma automática, criando um registo das passagens pelos ambientes de atendimento preciso e consistente. Além disso, também identificar os padrões relacionados a chegada de pacientes e necessidades de atendimento, e analisar esses dados de forma a tentar identificar quando será necessário ajustar os recursos humanos disponíveis, de forma a atender a demanda de pacientes de forma segura, sem trazer riscos a saúde.

Este capítulo descreve o modelo ElHealth, um modelo elástico e multinível para gerenciamento de recursos humanos em hospitais inteligentes, e está dividido em três seções. Primeiramente, a Seção 4.1, apresenta as decisões de projeto, seguida da arquitetura na Seção 4.2. A seguir, o conceito de Elasticidade Preditiva Multinível de Recursos Humanos é apresentado e descrito na Seção 4.3. Na Subseção 4.3.1 são apresentados os conceitos, algoritmos e formalismos matemáticos relacionados à elasticidade preditiva a nível local e, por fim, a Subseção 4.3.2 apresenta os conceitos e algoritmos relacionados à elasticidade preditiva a nível global.

### 4.1 Decisões de Projeto

O modelo parte da premissa que existam sensores espalhados pelos ambientes do hospital, que possam identificar os pacientes que passarem por eles. Primeiramente, eles devem estar em todas as entradas e saídas, de forma que sempre que um paciente entrar ou sair do hospital seja possível identificá-lo. Já para detectar a movimentação e a localização dos pacientes nos ambientes internos, devem existir sensores espalhados por todas as salas do hospital, bem como em todos os laboratórios e outros lugares onde ocorram exames clínicos, e em todos os corredores por onde os pacientes podem vir a passar durante sua estadia no hospital. Cada paciente deve possuir uma pulseira-*tag* de identificação vinculada a si no sistema de forma que os sensores sejam capazes de identificá-lo, e deve carregá-la consigo durante todo o seu período de permanência no ambiente interno do hospital. O funcionário responsável pela recepção de

pacientes deve ser capaz de realizar o cadastro e vínculo de uma pulseira de identificação a um determinado paciente assim que o mesmo dar entrada no hospital. Assim pode-se identificar quando e onde determinado paciente está logo que ele entra no ambiente hospitalar, juntamente com o tempo que ele se mantém em cada uma das salas enquanto está sendo atendido. Além disso, cada profissional de saúde também deve possuir uma *tag* vinculada a si no sistema, devendo carregá-la consigo durante todo o seu período em atividade no hospital. Assim, todos os atendentes disponíveis também podem ser localizados dentro do hospital da mesma forma que os pacientes. A Figura 15 apresenta uma representação do modelo proposto, onde temos uma paciente com uma pulseira-*tag* e uma enfermeira portando seu crachá-*tag*. Dessa forma, esse modelo propõe um RTLS com precisão de localização no nível de sala. A escolha de um sistema de localização em tempo real se baseia na sua capacidade de permitir identificação automática, evitando a existência do erro humano nos processos de identificação. Além disso, segundo Boulos e Berry (2012), para certas aplicações, o uso de soluções RTLS que incorporem tecnologias complementares (como RFID, Wi-Fi, Infravermelho ou BLE) podem fornecer níveis de precisão e flexibilidade inatingíveis por qualquer tecnologia concorrente.

Figura 15 – Ambiente hospitalar com: (A) uma paciente em atendimento utilizando uma pulseira-*tag* de identificação e (B) uma profissional da saúde com crachá-*tag*

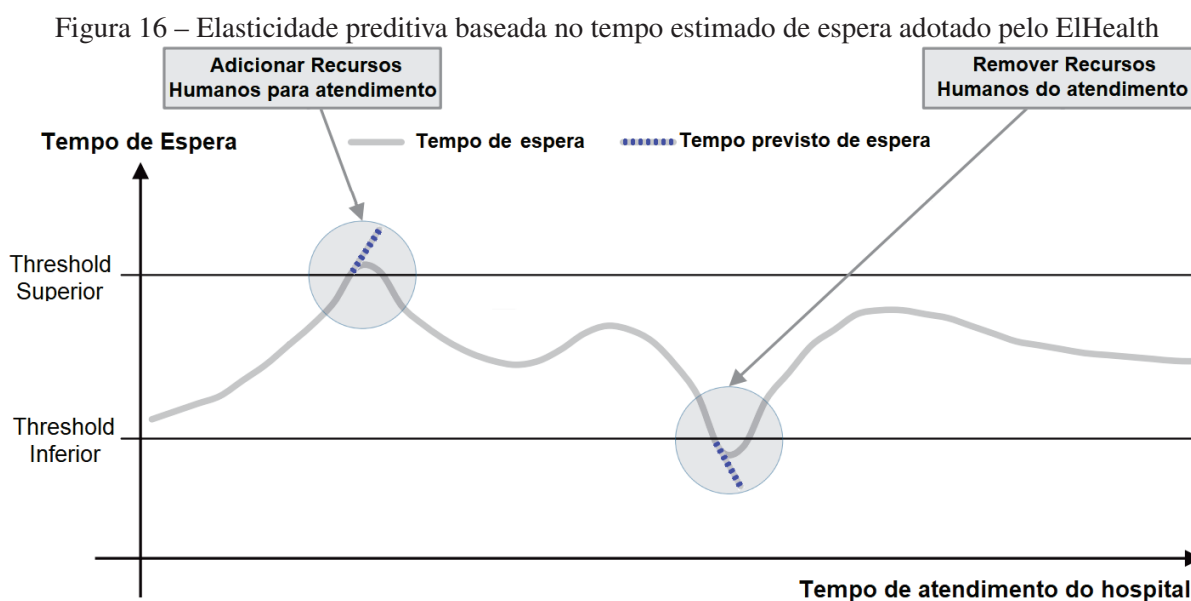


Fonte: RFID for health sector (2018), adaptada pelo autor.

O funcionamento se baseia na capacidade do sistema de marcar as entradas e saídas de cada paciente em cada uma das salas e lugares existentes no ambiente do hospital e registrar as mesmas, gerando marcações fidedignas a movimentação das pessoas. Com base nisso, o sistema deve ser capaz de identificar o uso de cada um dos ambientes por parte dos pacientes durante seu processo de atendimento. Além disso, com base no uso histórico de uma determinada sala ou recurso físico, o sistema deve ser capaz de prever o uso futuro, com um bom grau de

confiança, de forma a se realizar a alocação de recursos humanos nos ambientes hospitalares adequadas à demanda futura de atendimento. Do ponto de vista dos usuários, o EIHealth deve ser transparente ao paciente, no sentido que o mesmo não precisa informar nenhuma condição relacionada a sua movimentação pelos ambientes hospitalares, sendo uma atividade realizada automaticamente pelo sistema.

O modelo EIHealth adapta a estratégia de elasticidade preditiva utilizando *thresholds* superior e inferior da elasticidade de recursos para o contexto de pessoas, com base na previsão da demanda de pacientes, conforme será abordado em detalhes na Seção 4.3. A Figura 16 demonstra a utilização de *thresholds* aonde em um certo momento a previsão do sistema informa que o *threshold* superior será alcançado e os recursos humanos devem ser alocados, e logo em seguida a previsão informa que o *threshold* inferior será atingido e os recursos humanos devem ser liberados. Para esse processo, o sistema deve ser capaz de alertar as pessoas para se alocarem, entretanto a decisão final deve ser sempre do profissional de saúde ou de seu gestor.



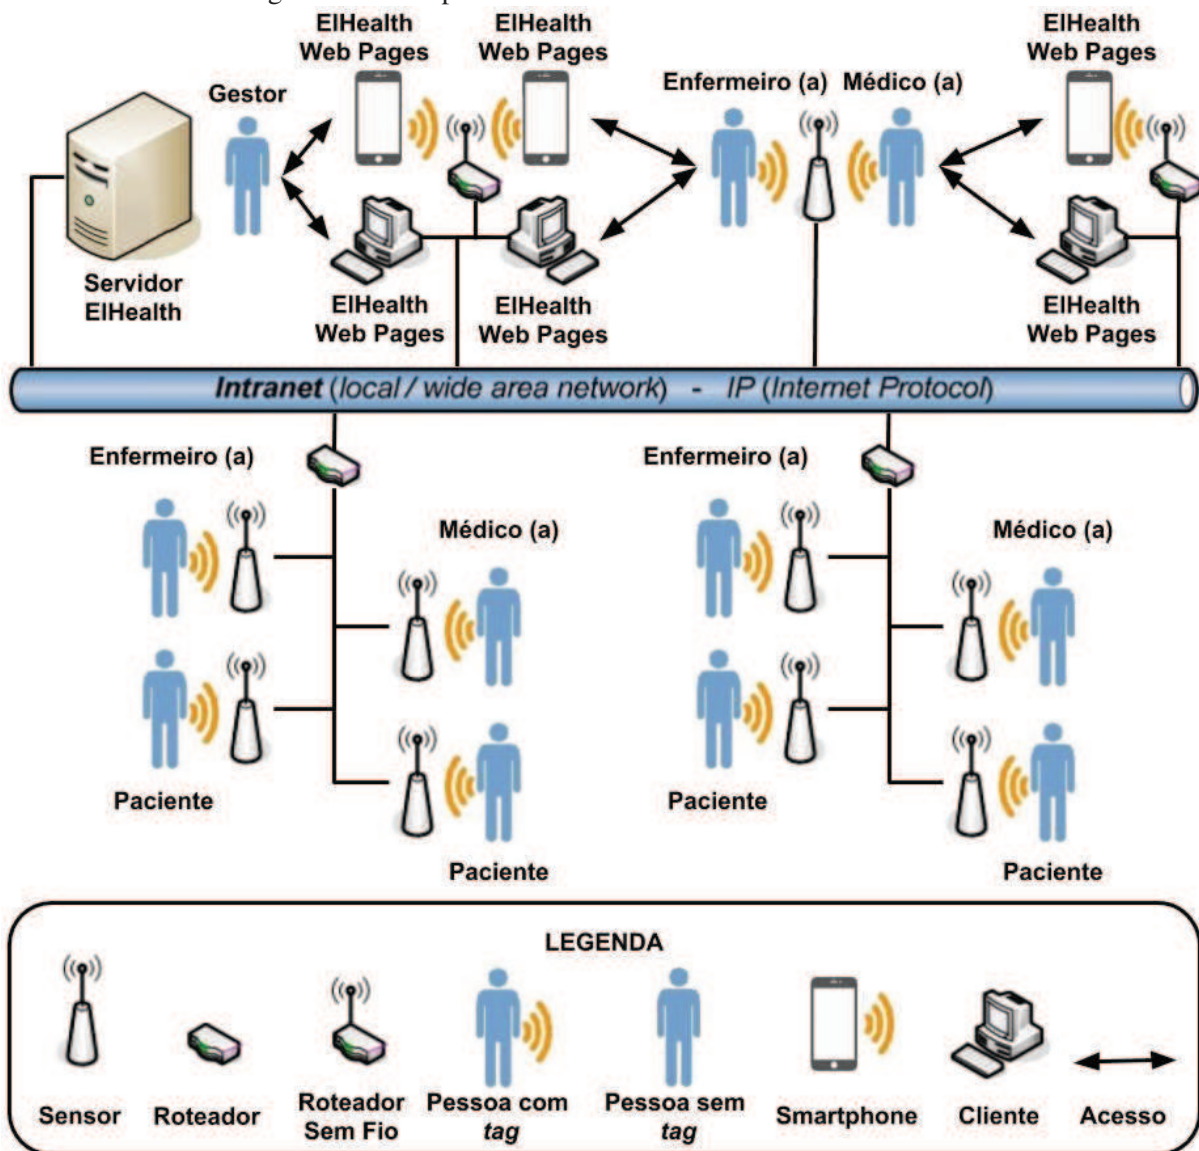
Fonte: Elaborada pelo autor.

Com relação a estratégia de predição computacional, o modelo EIHealth faz uso da abordagem baseada em probabilidade e estatística, através de uma implementação do modelo ARIMA. Uma vez que o problema da quantidade de pacientes aguardando para atendimento ao longo do tempo pode ser descrito como uma série temporal, optou-se pelo uso da abordagem através do ARIMA em função do mesmo ser um modelo matemático bastante flexível com um bom desempenho para previsão de séries temporais (NISHA; SREEKUMAR, 2017). O uso de um modelo não estacionário como o ARIMA se baseia no fato que existe sazonalidade na demanda por médicos, uma vez que acidentes, epidemias, feriados, entre outros eventos, podem alterar a demanda de pacientes.

## 4.2 Arquitetura

A arquitetura do modelo EIHealth se baseia na existência de três servidores lógicos. Tem-se primeiramente um servidor web, que ficará responsável pela camada de visualização, disponibilizando a interface **EIHealth Web Pages**. Tem-se também um servidor de inferência, que será responsável pelo processamento dos dados, tratando os registros de movimentação de pessoas, realizando as previsões de demanda de paciente e definindo a alocação de recursos humanos para o atendimento. E por fim, deve existir um servidor de banco de dados para a gestão da informação. Todos esses servidores lógicos devem estar alocados dentro do Servidor EIHealth. A Figura 17 apresenta os componentes e a visão da rede no modelo proposto.

Figura 17 – Componentes e visão da rede no modelo EIHealth



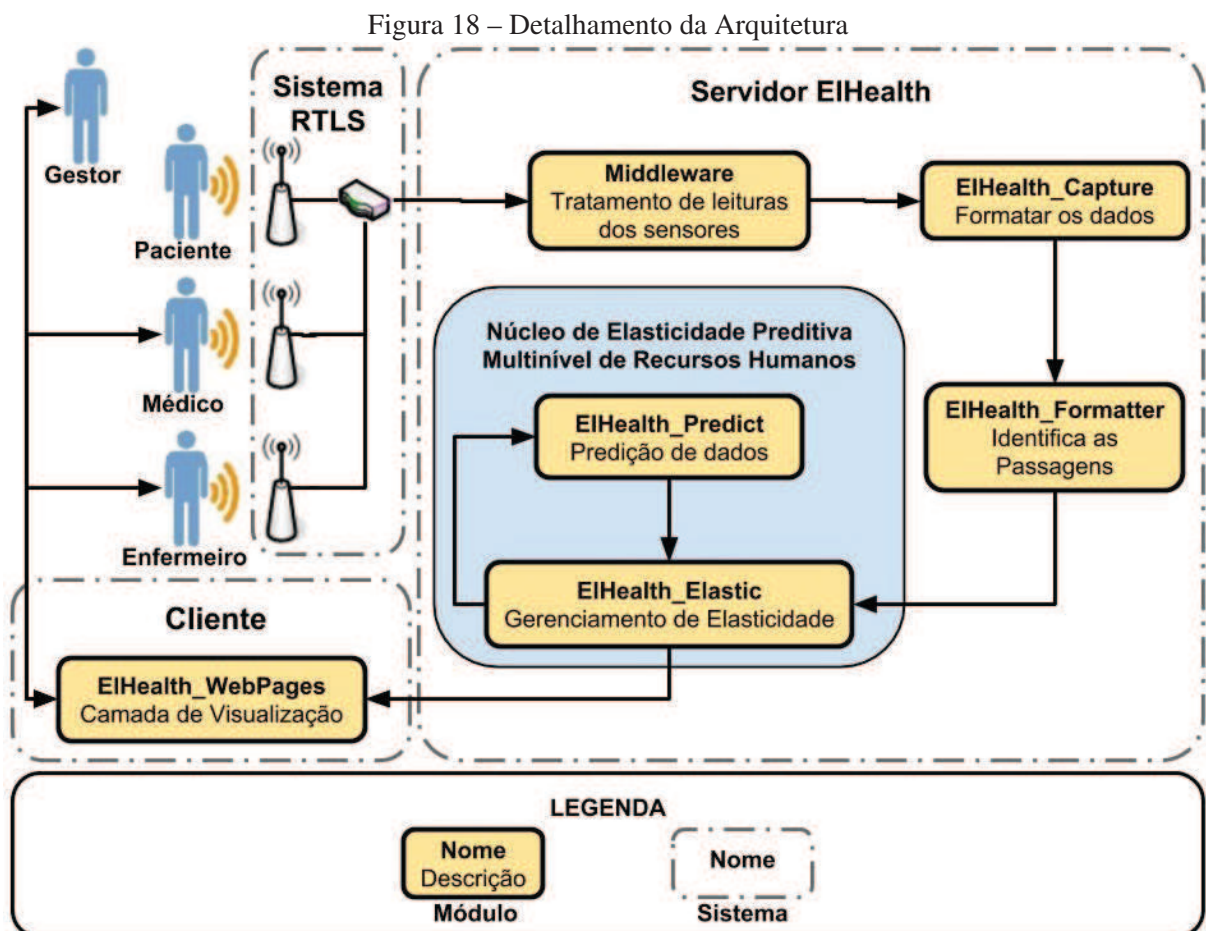
Fonte: Elaborada pelo autor.

A arquitetura do modelo se baseia na existência de: (I) uma interface web, nesse trabalho



chamada de EIHealth Web Pages, por onde as pessoas possam acessar o sistema proposto; **(II)** o Servidor EIHealth, responsável pelo processamento das informações e tomada de decisão; **(III)** o sistema RTLS, composto por diversos sensores ligados a roteadores que fazem parte da rede do hospital, responsáveis por trocar informações com as *tags* das pessoas que estão no hospital; e **(IV)** as pessoas que fazem uso do sistema, que podem ser médicos, pacientes e enfermeiros, que devem carregar *tags* em todo o tempo de permanência no hospital, de forma a interagirem com o sistema RTLS, e os gestores.

Os sensores devem ficar instalados nos ambientes do hospital e estar ligados logicamente aos servidores, podendo trocar informações com eles. Os computadores clientes conectados a essa rede devem apenas ter acesso a interface EIHealth Web Pages, enquanto que a aplicação que controla os dados recebidos deve ser executada no servidor. O modelo parte do pressuposto que a interface será utilizada através do navegador web e deve funcionar em qualquer máquina cliente que tenha a permissão para acesso, e um navegador instalado. Assim, sempre que um usuário carregar uma página do sistema, o servidor web interpreta as requisições, acionando a aplicação e coletando os dados a serem exibidos no banco de dados.



Fonte: Elaborada pelo autor.

O modelo EIHealth é subdividido em cinco módulos responsáveis pelo tratamento da informação desde a sua captura pelos sensores até ao resultado final exibido na aplicação web. Cada

módulo possui uma função específica, possuindo uma informação de entrada e um resultado específico de saída que pode ser utilizado como entrada de outros módulos. A Figura 18 apresenta os módulos propostos, detalhando a arquitetura do modelo.

**EIHealth\_Capture** é o módulo responsável por recepcionar os dados capturados pelos sensores espalhados pelo hospital, realizar o pré-processamento dos mesmos e armazená-los na base de dados. Para tanto, esse módulo deve ser capaz de se comunicar com o *middleware* RTLS. Para garantir a inclusão das informações assim que as mesmas são capturadas pelos sensores, a aplicação deve verificar constantemente com o *middleware* sobre a chegada de novos dados dos sensores. Nessa etapa, a partir dos identificadores da *tag* e do sensor, devem ser identificados o paciente e o sensor físico a qual pertencem. Com base nisso, deve ser criada uma marcação de passagem pelo sensor (*Marking*) e o resultado final deve ser armazenado na base de dados. Caso o sistema capture muitas marcações de passagens de uma única vez, o módulo deve ser capaz de processá-los pouco-a-pouco, evitando sobrecargas na aplicação em função do volume de dados. O Algoritmo 2 apresenta o pseudo-código proposto para o processamento do módulo. Nas Linhas 8 e 9 as informações contidas nas leituras são utilizadas para a busca pelo Paciente e Sensor ao qual se referem. Na Linha 11, uma *Marking* é criada utilizando os dados encontrados anteriormente e na Linha 12 o mesmo é persistido na base de dados.

---

#### Algoritmo 1: EIHealth\_Capture

---

**Entrada:** *Readings* gerados pelos sensores

**Saída:** *Marking* utilizado pelo EIHealth\_Formatter

---

1 **início**

2      $conn \leftarrow connect\_with\_middleware()$ ;

3     **repita**

4          $verify\_readings\_to\_analyse(conn)$ ;

5         **se existe** *Readings* **para processar então**

6              $readings\_list \leftarrow get\_readings\_to\_process()$ ;

7             **para todo elemento de** *readings\_list* **faça**

8                  $patient \leftarrow search\_patient(reading)$ ;

9                  $sensor \leftarrow search\_sensor(reading)$ ;

10                  $time \leftarrow get\_time(reading)$ ;

11                  $marking \leftarrow create\_marking(patient, sensor, time)$ ;

12                  $persist(marking)$ ;

13             **fim**

14         **senão**

15             aguarda  $x$  milissegundos;

16         **fim**

17     **até desligar o servidor;**

18 **fim**

---

**EIHealth\_Formatter** é o módulo responsável por realizar o processamento dos dados do tipo *Marking*. Nesta etapa, devem ser identificadas as passagens dos pacientes pelos ambientes e salas do hospital. Cada par de marcações identifica a saída de um Lugar e a entrada em outro,

e um novo tipo de dados chamado *Pass* deve ser criado. Nele é armazenado a informação do Lugar por onde o paciente passou, a data e hora de entrada e saída, o tempo de permanência neste lugar e o paciente que realizou essa passagem. Além disso, esse módulo deve ser capaz de armazenar a localização atual do paciente e o tempo de permanência. Em função do escopo do módulo e da necessidade de haver pares de marcações para identificar a movimentação dos pacientes, a sua execução ocorre sempre que são identificados novos pares de marcações, não sendo executado sobre marcações individuais. Em função da necessidade dos dados serem rapidamente processados pela aplicação, esse módulo se mantém em processo de busca constante por novas marcações. O Algoritmo 2 apresenta o pseudo-código proposto do módulo.

---

**Algoritmo 2:** ElHealth\_Formatter

---

**Entrada:** *Markings*

**Saída:** Localização atual do Paciente e *Pass*

```

1 início
2   repita
3     se existe par de Markings para processar então
4       markings_list ← get_markings_to_process();
5       markings_pair_list ← verify_correct_pairs(markings_list) forall
6         elementos de markings_pair_list do
7           outgoing ← search_pass_to_finish(marking_patient);
8           outgoing_pass(outgoing, first_marking);
9           pass ← create_new_pass ← incoming(second_marking);
10          persist(pass);
11          update_patient_location(second_marking);
12        end
13      senão
14        aguarda x milissegundos;
15    fim
16 até desligar o servidor;
17 fim

```

---

Na Linha 5 do algoritmo, o pseudo-método *verify\_correct\_pairs*() foi proposto para garantir que apenas pares de marcações válidas sejam utilizadas. Isso ocorre em função de existir a possibilidade de um paciente passar por um sensor, ser capturado pelo seu sensor par, que indicaria a troca de sala, e novamente ser capturado pelo sensor inicial. Quando isso acontece, apesar do paciente ter chegado no limiar para entrar em uma nova sala, ele retrocedeu e se manteve no ambiente anterior, sendo necessário descartar essas marcações. Quando um paciente entra em um ambiente, uma passagem é criada com o horário de chegada e o horário de saída fica em aberto. Na Linha 6 o método *search\_pass\_to\_finish*() é responsável por procurar essa passagem com saída em aberto do paciente e a Linha 7 é responsável por marcar o horário de saída utilizando o tempo contido na *first\_marking*. Logo após, na Linha 8, uma nova passagem é criada tendo como horário de chegada e o local aqueles presentes na *second\_marking* e na Linha 9 a mesma é persistida na base de dados. Por fim, na Linha 10, uma vez que o paci-

ente mudou de ambiente dentro do hospital, o registrador próprio que armazena sua localização atual é atualizado utilizando o local presente na *second\_marking*.

**EIHealth\_Predict** é o módulo responsável por identificar os padrões de movimentação dos pacientes pelo ambiente hospitalar. Com base nos registros de passagens, do tipo *Pass*, geradas anteriormente, deve ser identificado o caminho que os pacientes percorrem durante sua movimentação pelo hospital, e o tempo de permanência em cada um dos ambientes. Dessa forma, esse módulo deve ser capaz de identificar os padrões relacionados à chegada de pacientes nesses ambientes, os padrões relacionados ao tempo de permanência e espera por atendimento e realizar previsões sobre as chegadas que irão acontecer no futuro. Essa previsão deve ser armazenada no sistema de tal forma que possa ser utilizada pelo gerenciador de elasticidade. É o módulo com maior carga de processamento do sistema. A sua execução não ocorre de forma constante como nos módulos anteriores em função de que as chegadas de pacientes nos ambientes hospitalares geralmente não ocorrem de forma constante, sendo necessário o processamento em intervalos de tempo pré-definidos. O Algoritmo 3 apresenta o pseudo-código proposto.

---

**Algoritmo 3:** EIHealth\_Predict

---

**Entrada:** Lista de *Pass*  $p$ , tipo de série  $s$  e número  $n$  de valores a serem preditos

**Saída:**  $n$  valores futuros preditos para a série temporal

```

1 início
2    $t \leftarrow$  uma nova série temporal;
3   forall  $pass$  in  $p$  do
4      $t.update\_series(pass, s)$ ;
5   end
6    $model \leftarrow auto\_arima(t)$ ;
7    $model.fit(t)$ ;
8    $forecast \leftarrow model.predict(n\_periods = n)$ ;
9   return  $forecast$ ;
10 fim

```

---

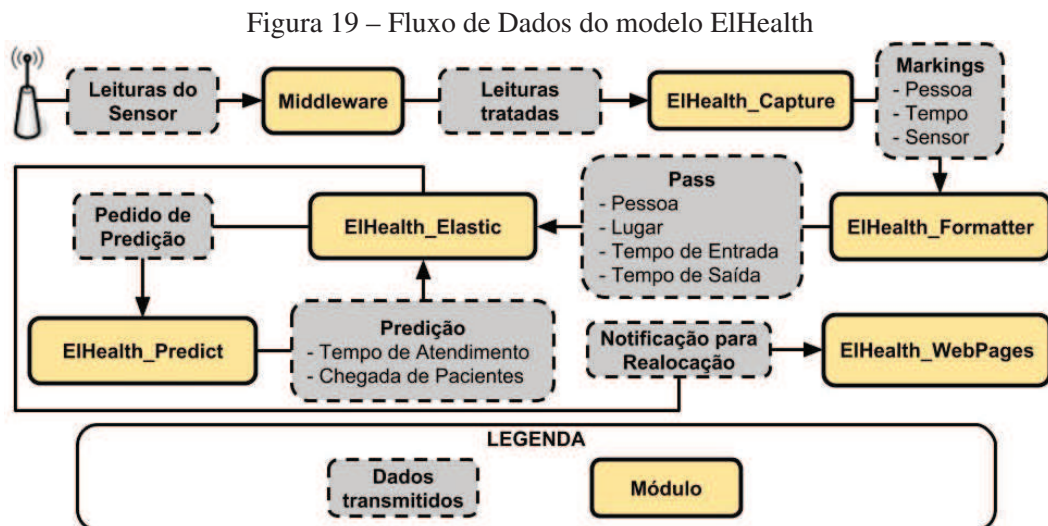
Na Linha 4 do algoritmo, o pseudo-método *update\_series()* foi proposto para com base nos dados contidos na passagem *pass* atualizar uma determinada série temporal. Isto ocorre pois para uma série temporal para tempo de atendimento, o tempo de permanência em uma sala é levado em conta, e para uma série temporal para chegada de pacientes, a quantidade de *pass* em um mesmo instante de tempo para uma determinada fila são levadas em conta. Após a série temporal ter sido definida, na Linha 6 o método *auto\_arima()* é responsável por gerar o modelo de predição. A Linha 7 é responsável por realizar o processo de identificação dos parâmetros para o modelo ARIMA e por fim, o pseudo-método *predict(n\_periods)* na Linha 8 é responsável por realizar a predição de  $n\_periods$  valores futuros para a série temporal.

**EIHealth\_Elastic** é o módulo responsável pelo gerenciamento de elasticidade do sistema. Ele deve ser capaz de verificar a alocação de recursos humanos em cada um dos ambientes, verificar as passagens atuais de pacientes e comparar os dados com as previsões feitas pelo módulo EIHealth\_Predict. Com base nessa comparação, o módulo deve ser capaz de gerar uma alocação



inteligente e automática dos recursos humanos para melhor atender a demanda futura de pacientes. Vale ressaltar que o sistema gera notificações para os recursos humanos se realocarem, mas a realocação efetiva depende das pessoas cumprirem o que foi indicado pela aplicação. O módulo *EIHealth\_Elastic* juntamente com o módulo *EIHealth\_Predict* são considerados a parte mais importante e o núcleo do modelo proposto. Ao contrário dos módulos anteriores, esse módulo solicita previsões ao módulo *EIHealth\_Predict* para tomar ações de elasticidade, ou seja, ele realiza a análise dos recursos com base nas previsões feitas pelo módulo anterior. Na Seção 4.3 serão detalhados os algoritmos e a forma como o módulo realiza o gerenciamento elástico dos recursos humanos no ambiente hospitalar.

*EIHealth\_WebPages* é responsável pela camada de visualização da informação processada pelos outros módulos da aplicação. Através desse módulo os usuários podem visualizar as informações geradas automaticamente pelo sistema, bem como devem ser capazes de acompanhar o tempo de permanência dos pacientes nas filas, tempo médio de atendimento e espera, e visualizarem as notificações de elasticidade geradas.



Fonte: Elaborada pelo autor.

O fluxo de informação no sistema começa a partir do módulo *EIHealth\_Capture* que recebe os registros identificados pelo *middleware* através dos sensores. Logo após, a informação pré-tratada trafega para o módulo *EIHealth\_Formatter*. Os dados referente as passagens das pessoas então são enviados para o *EIHealth\_Elastic*, que realiza as tomadas de decisão. Para tanto, o módulo requisita e recebe previsões do *EIHealth\_Predict*. Ao final, as notificações de elasticidade são enviadas para as *EIHealth\_WebPages*.

### 4.3 Elasticidade Preditiva Multinível de Recursos Humanos

O modelo *EIHealth* utiliza o termo elasticidade de uma forma diferente do conceito de elasticidade de recursos. No contexto do modelo proposto, elasticidade refere-se a habilidade

do sistema de um ambiente hospitalar ser capaz de alocar e desalocar recursos humanos capazes de atender pacientes, de forma a se adaptar a variação da demanda de pacientes em diferentes ambientes em tempo real. Para a elasticidade de recursos humanos proposta nesse modelo, é necessário adaptar alguns conceitos da elasticidade de recursos em *Cloud Computing*. Assim, no contexto de recursos humanos, os conceitos de elasticidade devem ser:

- **Alocação**, que refere-se a capacidade do sistema de requisitar profissionais da saúde que não estão em atendimento no ambiente hospitalar para se deslocarem para o mesmo e direcioná-los para o atendimento da demanda de pacientes;
- **Realocação (ou migração)**, que refere-se a capacidade do sistema de migrar profissionais que estão atendendo em determinado ambiente hospitalar para algum outro que possua uma necessidade maior; e
- **Desalocação** que refere-se a capacidade do sistema de liberar de suas atividades os recursos humanos não mais necessários para o atendimento da demanda de pacientes.

Para realizar os procedimentos de alocação, desalocação e realocação de recursos humanos de forma elástica, o modelo EIHealth faz uso de uma abordagem multinível para prever a demanda futura de pacientes e do uso das salas de um ambiente hospitalar inteligente. Com base nessa abordagem, o modelo considera a elasticidade preditiva de forma diferente dependendo do nível: (I) a nível **Local**, onde o modelo deve ser capaz de identificar o uso futuro de uma determinada sala, e com base nisso verificar se haverá atendentes suficientes para atender a demanda de pacientes daquela sala, e (II) a nível **Global**, onde o EIHealth deve ser capaz de verificar se haverá atendentes suficientes para atender a demanda de pacientes de todas as salas do ambiente hospitalar, com a movimentação do número de atendentes entre as dependências.

#### 4.3.1 Elasticidade Preditiva a Nível Local

A nível local, o EIHealth deve verificar a quantidade atual de pacientes aguardando atendimento em uma determinada sala e com base na estratégia preditiva utilizando o método matemático ARIMA, analisar as séries temporais de chegadas de pacientes que ocorreram no passado e determinar as chegadas em um determinado intervalo de tempo no futuro. Para realizar essa previsão, o sistema deve levar em conta questões como o tempo médio que leva o atendimento em cada sala com um atendente, o tempo médio que leva o atendimento com a alocação atual de atendentes, e a estimativa do tempo de espera para a fila de atendimentos. Quando o algoritmo identificar que o tempo de espera se tornará superior ou inferior aos valores limites definidos pelo gestor do hospital, o EIHealth deve gerar um alerta. Para identificar que o tempo de espera vai superar o *threshold* superior ou ficar abaixo do *threshold* inferior, definidos pelo gestor hospitalar, o algoritmo faz uso de alguns formalismos matemáticos que serão descritos na

Tabela 5 – Nomenclaturas para os formalismos matemáticos do modelo EIHealth

Nomenclatura	Significado
$s$	Sala ou ambiente do hospital
$ti$	Instante de tempo inicial
$tf$	Instante de tempo final
$a$	Atendentes alocados para atendimento
$p$	Pacientes aguardando atendimento
$ti.f$	Instante de tempo inicial futuro
$tf.f$	Instante de tempo final futuro

Fonte: Elaborada pelo autor.

sequência. A Tabela 5 apresenta algumas nomenclaturas que serão utilizadas nos formalismos matemáticos propostos no modelo EIHealth.

O Conjunto de atendimentos (Care Vector) da sala “ $s$ ” entre os tempos “ $ti$ ” e “ $tf$ ” pode ser encontrado através da função  $CV(s, ti, tf)$ . Além disso, a função  $size(x)$  é responsável por retornar o tamanho de um vetor qualquer  $x$ . Com o uso dessa duas funções, é possível determinar o Tempo Médio de Atendimento (Average Care Time) na sala “ $s$ ” do hospital entre os tempos “ $ti$ ” e “ $tf$ ”, definido pela Equação 4, onde  $CDT(x[i])$  refere-se ao Tempo de Duração de um Atendimento (Care Duration Time)  $x[i]$  que já ocorreu naquela sala e  $x[]$  é o conjunto de atendimentos que ocorreram na sala.

$$ACT(s, ti, tf) = \frac{1}{size(x)} \sum_{i=0}^{size(x)-1} CDT(x[i]), \text{ onde } x[] = CV(s, ti, tf) \quad (4)$$

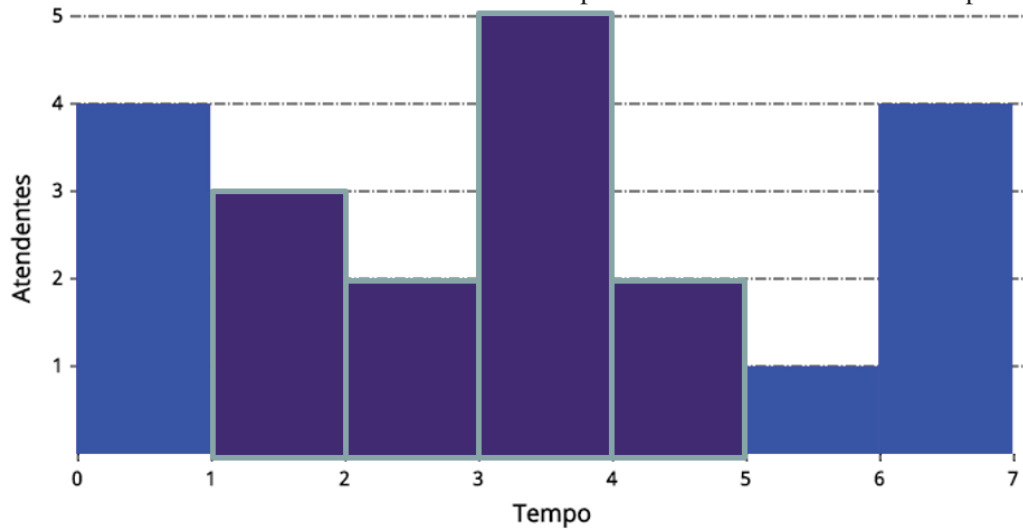
A Equação  $ACT(s, ti, tf)$  tem como resultado um valor numérico de tempo. Um exemplo seria uma sala qualquer “ $s$ ”, entre os tempos 1 e 5, onde o resultado poderia ser definido como:  $ACT(s, 1, 5) = 15$  minutos. Com o uso dessa equação, é possível estimar o tempo médio que levará um atendimento em uma determinada sala do hospital inteligente.

Em função da elasticidade de recursos humanos, em diferentes instantes de tempo existem diferentes quantidades de atendentes alocados para atendimento em cada uma das salas dos hospital. Assim, a Quantidade Média de Atendentes (Average Number of Attendants) na sala “ $s$ ” do hospital entre os tempos “ $ti$ ” e “ $tf$ ” é definida pela Equação 5, onde  $NA(s, i)$  refere-se ao número de atendentes alocados para atendimento na sala “ $s$ ” no instante de tempo “ $i$ ”.

$$ANA(s, ti, tf) = \frac{1}{tf - ti} \sum_{i=ti}^{tf-1} NA(s, i) \quad (5)$$

Um exemplo seria a sala  $s$ , com diferentes alocações de atendentes entre os tempos 0 e 7 conforme pode ser visto na Figura 20. Se fosse necessário identificar o número médio de atendentes dessa sala entre os tempos 1 e 5, por exemplo, a Equação 5 poderia ser aplicada da

Figura 20 – Calculando o Número Médio de Atendentes em uma sala do hospital entre os instantes de tempo 1 e 5, onde a cada instante de tempo a quantidade de atendentes alocados é alterada, chegando a um número médio de 3 atendentes alocados nessa sala hipotética entre os instantes de tempo



Fonte: Elaborada pelo autor.

seguinte forma:

$$ANA(s, 1, 5) = \frac{1}{5-1} \sum_{i=1}^{5-1} NA(s, i) = \frac{1}{4} (NA(s, 1) + NA(s, 2) + NA(s, 3) + NA(s, 4))$$

Na situação hipotética exposta na Figura 20, no instante de tempo 1 haviam 3 atendentes alocados para atendimento, no instante 2 haviam 2 atendentes, no instante 3 haviam 5 atendentes e no instante de tempo 4 haviam novamente 2 atendentes. Dessa forma, seguindo a equação, nesse intervalo de tempo estariam alocados em média 3 atendentes, conforme pode ser visto continuando o cálculo:

$$ANA(s, 1, 5) = \frac{3 + 2 + 5 + 2}{4} = \frac{12}{4} = 3 \text{ atendentes}$$

A mesma ideia da função anterior pode ser adequada para realidade de pacientes, pois em diferentes instantes de tempo existem diferentes quantidades de pacientes aguardando atendimento em cada uma das salas dos hospital. Assim, a Quantidade Estimada de Pacientes (Estimated Number of Patients) aguardando para atendimento na sala “s” do hospital entre os tempos “ $t_i$ ” e “ $t_f$ ” é definida pela Equação 6, onde  $NWP(s, t_i)$  refere-se ao número de pacientes aguardando (Number of Waiting Patients) atendimento na sala “s” no instante de tempo “ $t_i$ ” e  $NIP(s, i)$  refere-se ao número de pacientes entrando (Number of Incoming Patients) na sala “s” para atendimento no instante de tempo “ $i$ ”.


$$ENP(s, t_i, t_f) = NWP(s, t_i) + \sum_{i=t_i+1}^{t_f-1} NIP(s, i) \quad (6)$$

Utilizando as equações propostas anteriormente, o modelo se torna capaz de chegar ao Tempo Estimado para Atendimento (Estimated Care Time) de todos os pacientes aguardando, ou seja, o tempo que um novo paciente entrando na fila precisa esperar para ser atendido. O  $ECT(s, ti, tf)$  é definido pela Equação 7, onde  $ACT(s, ti, tf)$  refere-se ao tempo médio para os atendimentos na sala “s” entre os tempos “ti” e “tf” e  $ENP(s, ti, tf)$  refere-se a quantidade estimada de pessoas que estão esperando na fila para atendimento na sala “s” entre os tempos “ti” e “tf”.

$$ECT(s, ti, tf) = ACT(s, ti, tf) \cdot ENP(s, ti, tf) \quad (7)$$

Um exemplo seria a sala  $s$ , entre dois tempos  $ti = 0$  e  $tf = 40$  que resultassem em uma quantidade média de 4 pacientes e um tempo médio de atendimento de 10 minutos conforme pode ser visto na Figura 21.

Figura 21 – Calculando o Tempo Estimado de Atendimento em uma sala do hospital com 4 pacientes aguardando e tempo médio de atendimento de 10 minutos, chegando ao Tempo Estimado de Atendimento de 40 minutos



Fonte: Elaborada pelo autor.

Na situação hipotética exposta na Figura 21, no instante de tempo  $0min$  haviam 4 pacientes aguardando e nenhum em atendimento pelo médico, ou seja, nesse instante o primeiro paciente foi encaminhado ao atendimento. Já no instante  $10min$ , 3 pacientes estão aguardando, o primeiro paciente termina seu atendimento e vai embora, sendo assim o segundo paciente é encaminhado ao atendimento. No instante  $20min$ , 2 pacientes estão aguardando, o segundo paciente termina seu atendimento e vai embora, e o terceiro paciente é chamado para o aten-



dimento. No instante  $30min$ , 1 paciente está aguardando, o terceiro paciente é liberado, e o último paciente é chamado para o atendimento. Assim, no instante  $40min$ , o último paciente é liberado, de forma que todos os pacientes foram atendidos em 40 minutos. Aplicando-se a Equação 7, chega-se ao mesmo resultado:

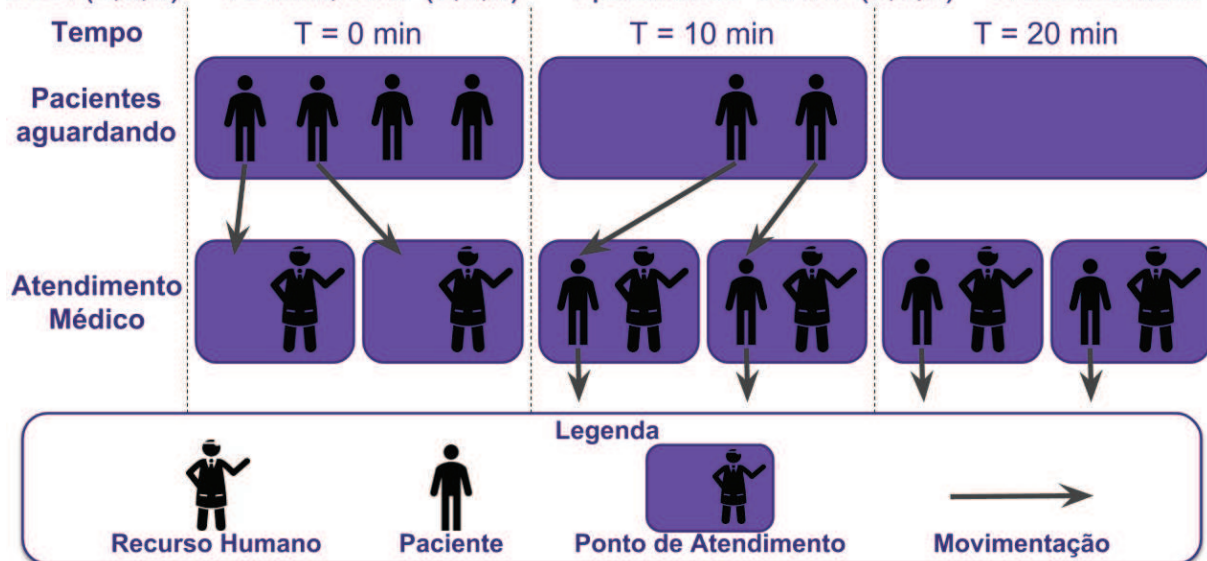
$$ECT(s, ti, tf) = ACT(s, ti, tf) \cdot ENP(s, ti, tf) = 10 \cdot 4 = 40 \text{ minutos}$$

Sabendo o  $ECT(s, ti, tf)$ , é possível analisar qual o tempo médio que levou para o atendimento de todos os pacientes aguardando na sala  $s$  entre os tempos “ $ti$ ” e “ $tf$ ”. Entretanto, esse valor refere-se a uma sala do hospital com um único atendente alocado para atendimento, mas na maioria dos casos haverá mais de um profissional da saúde atuando naquela sala, tornando-se necessário identificar qual o tempo médio com diferentes quantidades de atendentes. Nesse contexto, o modelo EIHealth faz uso de uma alocação paralela de recursos humanos, tal como a alocação paralela de máquinas virtuais utilizada nos sistemas elásticos (AL-DHURAIBI et al., 2017) ou a utilização de processadores em paralelo na computação de alto-desempenho. (ROSA RIGHI et al., 2016). Dessa forma, baseado no Speedup Elástico Reativo proposto por Rosa Righi et al. (2016), o modelo EIHealth propõe a Equação 8 para Speedup Elástico de Recursos Humanos (Human Resources Elastic Speedup).

$$HRES(s, ti, tf) = \frac{ACT(s, ti, tf) \cdot ENP(s, ti, tf)}{ANA(s, ti, tf)} = \frac{ECT(s, ti, tf)}{ANA(s, ti, tf)} \quad (8)$$

Figura 22 – Calculando o tempo estimado de atendimento em uma sala do hospital usando alocação paralela de atendentes, com 4 pacientes aguardando, tempo médio de atendimento de 10 minutos e 2 atendentes, chegando ao tempo estimado de atendimento, através do Speedup Elástico de Recursos Humanos, de 20 minutos

$ACT(s, ti, tf) = 10 \text{ min}$ ,  $ENP(s, ti, tf) = 4 \text{ pacientes}$  e  $ANP(s, ti, tf) = 2 \text{ atendentes}$



Fonte: Elaborada pelo autor.

Um exemplo seria a mesma sala  $s$  anterior, entre dois tempos  $ti$  e  $tf$  com uma quantidade

média de 4 pacientes, um tempo médio de atendimento de 10 minutos e com a alocação de 2 profissionais de saúde, conforme pode ser visto na Figura 22. Nessa situação hipotética, no instante de tempo  $0min$  haviam 4 pacientes aguardando e nenhum em atendimento pelo médico, ou seja, nesse instante os dois primeiros pacientes foram encaminhado ao atendimento. Já no instante  $10min$ , 2 pacientes estão aguardando, e os dois primeiros pacientes são liberados, sendo assim os dois últimos pacientes são encaminhados ao atendimento. Assim, no instante  $20min$ , os dois últimos pacientes são liberados, de forma que todos os pacientes forma atendidos em apenas 20 minutos. Aplicando-se a Equação 8, chega-se ao mesmo resultado:

$$HRES(s, ti, tf) = \frac{ACT(s, ti, tf) \cdot ENP(s, ti, tf)}{ANA(s, ti, tf)} = \frac{10 \cdot 4}{2} = \frac{40}{2} = 20 \text{ minutos}$$

A função  $HRES(s, ti, tf)$  retorna o tempo estimado de atendimento da sala “s” entre os tempos “ti” e “tf”, considerando a alocação paralela de atendentes nesse período de tempo, através da função  $ANA(s, ti, tf)$ . Assim, com o aumento do número médio de atendentes alocados, o tempo estimado de atendimento acaba diminuindo, de forma inversamente proporcional.

Dessa forma, o modelo ElHealth propõe o Speedup Elástico Proativo de Recursos Humanos (Proactive Human Resources Elastic Speedup) através da Equação 9, onde a função  $ACT(s, tif, tff)'$  é responsável por encontrar o tempo médio de atendimento na sala “s” com “a” atendentes alocados entre os tempos “tif” e “tff” futuros através do uso da técnica de predição computacional ARIMA, a função  $ENP(s, tif, tff)'$  é responsável por encontrar a quantidade média de pacientes futura na sala do hospital, e a função  $ECT(s, tif, tff)'$  é responsável por encontrar o tempo estimado de atendimento futuro nessa mesma sala, também utilizando ARIMA.

$$PHRES(s, a, tif, tff) = \frac{ACT(s, tif, tff)' \cdot ENP(s, tif, tff)'}{a} = \frac{ECT(s, tif, tff)'}{a} \quad (9)$$

Com base nos formalismos matemáticos apresentados até o momento, o modelo ElHealth adiciona na literatura o conceito de “Speedup Elástico Proativo de Recursos Humanos” em ambientes hospitalares que pode ser definida da seguinte forma:

**Definição 1: Speedup Elástico Proativo de Recursos Humanos** é uma extensão do conceito de Speedup da computação paralela (AMDAHL, 1967) para identificar o ganho de tempo de atendimento com o uso paralelo dinâmico de recursos humanos para atendimento em um ambiente hospitalar. O Speedup Elástico Proativo utiliza de uma abordagem preditiva para determinar a demanda futura de pacientes e dinamicamente definir a quantidade adequada de atendentes, identificando o ganho de tempo de atendimento futuro em um ambiente hospitalar.

Dessa forma, utilizando a abordagem preditiva a nível de sala, o modelo deve ser capaz de identificar a quantidade futura de pacientes e com esse número estimado de pacientes, e a quantidade de atendentes que estarão disponíveis na sala, estimar o tempo de espera dos pacientes que irão chegar no futuro. Sabendo o tempo médio que um novo paciente irá esperar para ser atendido em determinada sala do hospital, o EIHealth se torna capaz de analisar se esse tempo será maior que o limite superior ou menor que o limite inferior, definidos pelo gestor do hospital, e gerar alertas para o gerenciador de elasticidade da aplicação. O Algoritmo 4 apresenta o pseudo-código proposto para verificar a necessidade de alocar ou liberar recursos humanos em uma sala qualquer  $s$  do hospital inteligente.

---

**Algoritmo 4:** Elasticidade Preditiva a Nível Local

---

**Entrada:** Sala  $s$ ,  $a$  atendentes, tempo inicial futuro  $tif$ , tempo final futuro  $tf f$

**Saída:** Quantidade de atendentes a serem liberados ou alocados

```

1 início
2    $upper\_threshold \leftarrow$  Threshold Superior de tempo de espera na sala  $s$ ;
3    $lower\_threshold \leftarrow$  Threshold Inferior de tempo de espera na sala  $s$ ;
4    $n \leftarrow 0$ ;
5    $a' \leftarrow a$ ;
6   se  $PHRES(s, a, tif, tff) > upper\_threshold$  então
7     enquanto  $a' < limit(s)$  e  $PHRES(s, a', tif, tff) > upper\_threshold$  faça
8        $n \leftarrow n + 1$ ;
9        $a' \leftarrow a + n$ ;
10    fim
11  senão se  $PHRES(s, a, tif, tff) < lower\_threshold$  então
12    enquanto  $a' > 0$  e  $PHRES(s, a', tif, tff) < lower\_threshold$  faça
13       $n \leftarrow n - 1$ ;
14       $a' \leftarrow a + n$ ;
15    fim
16  fim
17  se  $n > 0$  então
18    return  $s$  precisa alocar mais  $n$  atendentes;
19  senão se  $n < 0$  então
20    return  $s$  pode liberar  $n$  atendentes;
21  senão
22    return  $s$  está com a alocação adequada e/ou permitida;
23  fim
24 fim

```

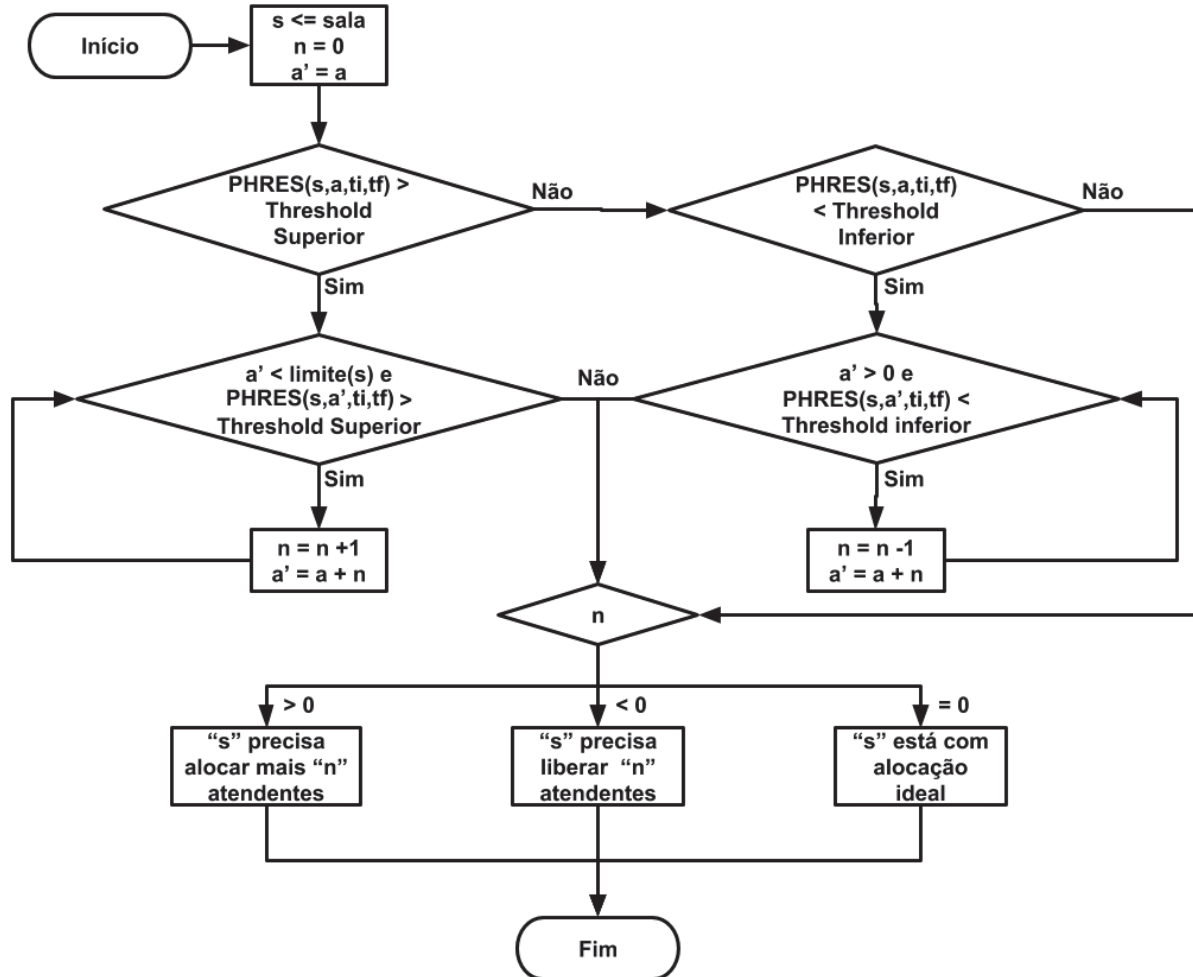
---

Assim, o EIHealth se torna capaz de filtrar e realizar previsões complementares com o aumento e diminuição do número de atendentes sempre que necessário. Nesse ponto, o algoritmo é capaz realizar previsões do tempo estimado de espera das salas com alertas, com o aumento e a diminuição do número de profissionais de saúde em atendimento de forma a identificar quantos atendentes seriam necessários para adequar o tempo da sala aos limites propostos pela gestão do hospital. Pode-se dizer que a predição a nível local é pró-ativa, ocorrendo a todo momento, e



é capaz de prever a super ou subutilização de cada uma das salas do ambiente hospitalar através da utilização do Algoritmo 4. Dessa forma, o algoritmo proposto pode ser representado através do fluxograma de processos apresentado na Figura 23.

Figura 23 – Fluxograma de processos a Nível Local para verificar a possibilidade de alocar ou liberar recursos humanos em uma sala qualquer do hospital inteligente



Fonte: Elaborada pelo autor.

#### 4.3.2 Elasticidade Preditiva a Nível Global

No contexto da predição a nível global, o algoritmo deve testar a movimentação de atendentes até encontrar a alocação ideal de recursos humanos para que as salas em alerta possam sair do seu estado de superlotação. Para tanto, o algoritmo deve analisar a possibilidade de mover os profissionais de saúde entre os ambientes hospitalares de forma a otimizar o tempo de atendimento. Para realizar o processo de movimentação de pessoas entre as salas do hospital, o modelo faz uso de algumas estratégias conhecidas de outros contextos da computação, adaptando-as para a necessidade da elasticidade preditiva de recursos humanos.

Uma vez que o algoritmo a nível local analisou as estimativas de tempo de espera e iden-

tificou a existência de uma sala com demanda crescente de pacientes, e ao mesmo tempo uma outra sala com demanda decrescente, o algoritmo a nível global é acionado. O objetivo do algoritmo é verificar e propor as movimentações de pessoas necessárias para o ajuste do tempo de espera com a alteração da demanda de atendimento. Para tanto, as opções disponíveis podem ser a alocação de um novo atendente, a realocação de um profissional de saúde entre dois setores ou a desalocação de algum atendente que não seja mais necessário. A primeira opção do ElHealth deve ser sempre a possibilidade de realocação dos recursos humanos já alocados no atendimento hospitalar. A realocação é priorizada pois é a opção que traz menos custos ao hospital, uma vez que realiza o ajuste do atendimento sem o acréscimo de atendentes.

Dessa forma, para realizar-se a realocação de recursos humanos, em um primeiro momento pensou-se em adaptar o algoritmo *Round Robin* utilizado para escalonamento de processos, conforme Silberschatz, Galvin e Gagne (2012), para o contexto elástico de recursos humanos. Nesse algoritmo adaptado, todas as salas devem estar em uma espécie de fila circular no sistema, e sempre que uma sala necessitar de mais atendentes, o gerenciador de elasticidade dever procurar na próxima sala da fila se há algum atendente disponível. Caso exista, este é encaminhado para a sala que necessita. Caso não exista, ou a sala de origem ainda necessite de mais atendentes, o algoritmo deve verificar na sala sequente e assim sucessivamente até a sala de origem obter todos os atendentes da qual necessita. O Algoritmo 5 apresenta o pseudo-código proposto para esse processo.

---

**Algoritmo 5:** Realocação através do algoritmo *Round Robin* adaptado

---

**Entrada:** Sala  $s$  que precisa de atendentes, e a fila circular  $f$  com todas as salas

**Saída:** Situação final da sala  $s$

---

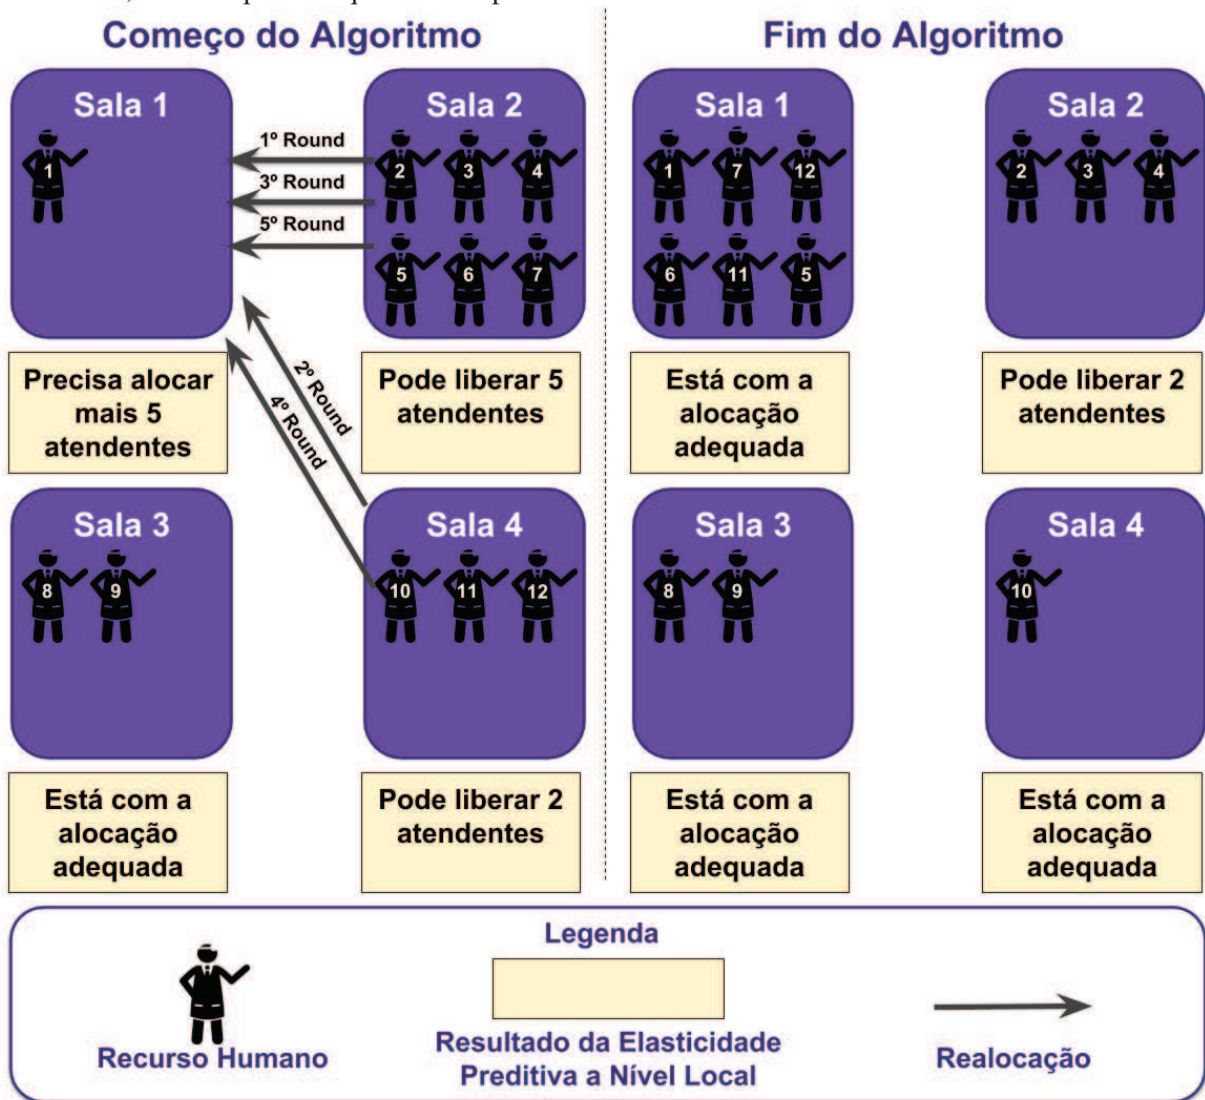
```

1 início
2    $next \leftarrow$  próxima sala da fila  $f$ ;
3   enquanto  $s$  precisa de atendentes e há atendentes disponíveis em  $f$  faça
4     se  $next$  tem atendentes disponíveis para a sala  $s$  então
5        $s$  recebe um atendente de  $next$ ;
6     se  $s$  ainda precisa de atendentes então
7        $next \leftarrow$  próxima sala da fila  $f$ ;
8     senão
9       return  $s$  está com a alocação adequada;
10  fim
11  return  $s$  ainda está com a alocação inadequada;
12 fim
```

---

A Figura 24 ilustra um cenário de execução do algoritmo proposto, onde a Sala 1 precisa de mais 5 atendentes e as Salas 2 e 4 possuem atendentes disponíveis. Seguindo a lógica da fila circular, no 1º *Round* o atendente 7 da Sala 2 é realocado para a Sala 1, no 2º *Round* o atendente 12 da Sala 4 é realocado, logo após no 3º *Round* o atendente 6 da Sala 2 é realocado, então no 4º *Round* o atendente 11 da Sala 4 também é realocado e por fim no 5º *Round* o atendente 5 da Sala 2 é transferido para a Sala 1.

Figura 24 – Realocação através do algoritmo *Round Robin* adaptado, com uma fila de 4 salas, e 12 atendentes, onde foi previsto que a Sala 1 precisa alocar 5 atendentes



Fonte: Elaborada pelo autor.

Após uma análise do algoritmo, pode-se encontrar um possível problema no mesmo, onde em função da alocação ser circular, sempre um atendente será retirado de uma sala diferente por *Round*. Dessa forma, uma sala que possui 2 atendentes para serem liberados, que é o caso da Sala 4 no exemplo anterior, acaba por ser mais impactada do que a Sala 2, com 5 atendentes disponíveis, pois ao final da execução do algoritmo, a Sala 4 ficou no limite mínimo de pessoal, enquanto a Sala 2 ficou com 2 atendentes para liberar ainda, de forma que o processo de movimentação de recursos humanos se torna desbalanceado. Assim, no próximo ciclo de monitoramento, as chances da Sala 4 precisar de um de seus atendentes de volta é maior do que a Sala 2.

Pensando nisso, para realizar-se a realocação de recursos humanos, de forma balanceada, foi decidido adaptar o algoritmo *List Scheduling* dinâmico, também utilizado para escalonamento de processos segundo Wang e Sinnen (2018), onde todas as salas do hospital estão em

uma espécie de lista ordenada pela quantidade de atendentes disponíveis para realocação. Dessa forma, sempre que uma sala necessitar de mais atendentes, o gerenciador de elasticidade deve procurar na primeira sala da lista se há algum atendente disponível. Caso exista, este é encaminhado para a sala que necessita, e a lista deve ser ordenada novamente. Se a sala de origem ainda necessita de mais atendentes, o algoritmo deve procurar no primeiro da lista novamente, e assim sucessivamente até a sala de origem obter todos os atendentes da qual necessita. O Algoritmo 6 apresenta o pseudo-código proposto para esse processo.

---

**Algoritmo 6:** Realocação através do algoritmo *List Scheduling* adaptado

---

**Entrada:** Sala  $s$  que precisa de atendentes, e a lista ordenada  $l$  com todas as salas

**Saída:** Situação final da sala  $s$

```

1 início
2    $next \leftarrow$  primeira sala da lista  $l$ ;
3   enquanto  $s$  precisa de atendentes e há atendentes disponíveis em  $l$  faça
4      $s$  recebe um atendente de  $next$ ;
5      $l \leftarrow$  a lista  $l$  reordenada;
6     se  $s$  ainda precisa de atendentes então
7        $next \leftarrow$  primeira sala da lista  $l$ ;
8     senão
9       return  $s$  está com a alocação adequada;
10  fim
11  return  $s$  ainda está com a alocação inadequada;
12 fim

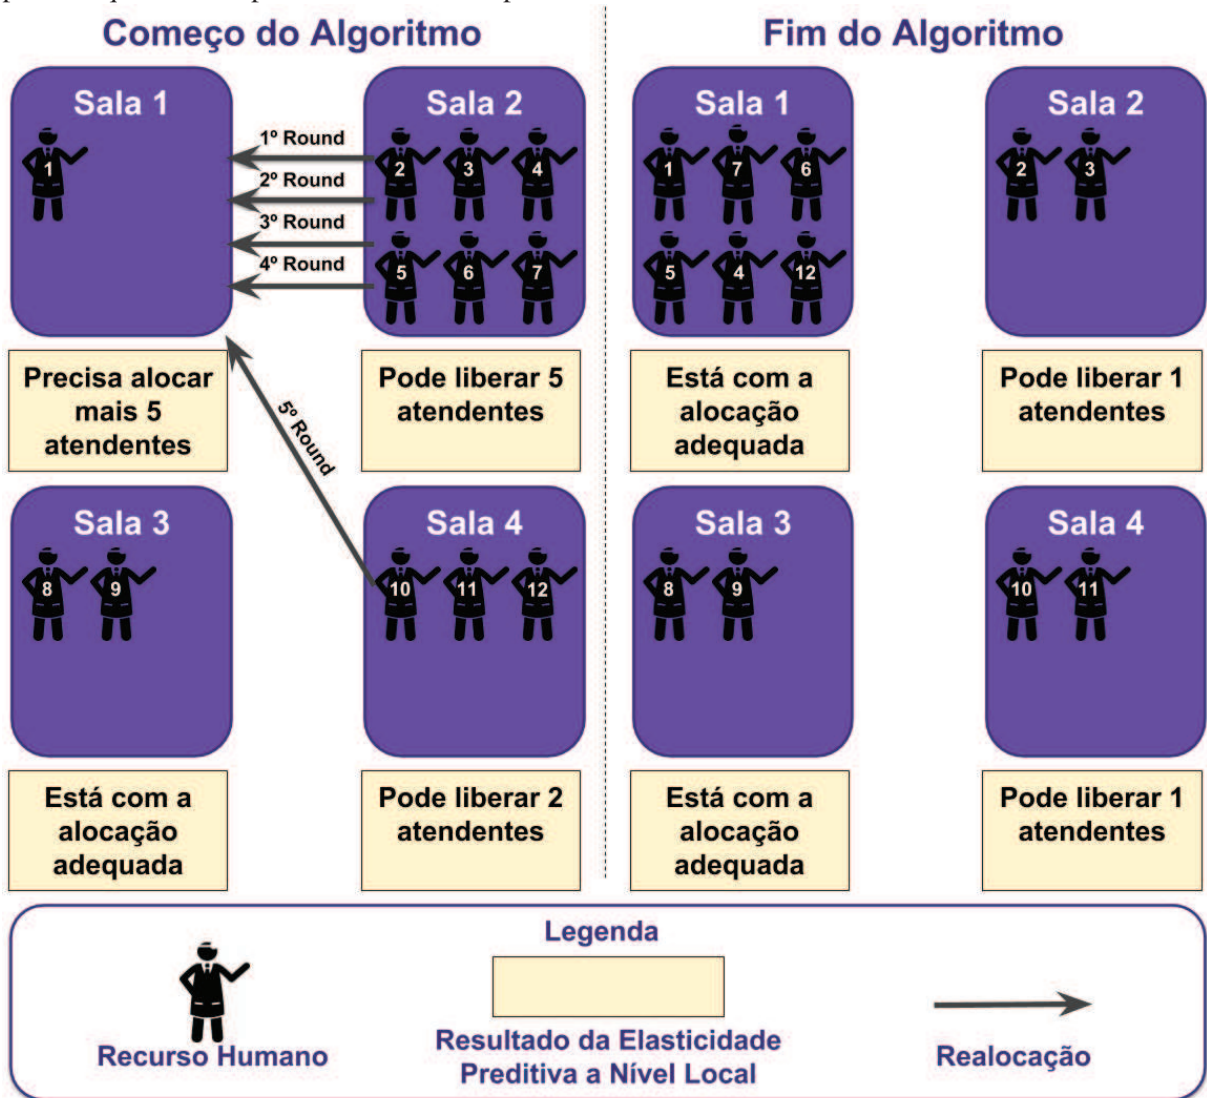
```

---

A Figura 25 ilustra o mesmo cenário apresentado anteriormente, para execução do novo algoritmo proposto, onde a Sala 1 precisa de mais 5 atendentes e as Salas 2 e 4 possuem atendentes disponíveis. Seguindo a lógica de *List Scheduling*, no 1º *Round* a Sala 2 é a primeira da lista, com 5 atendentes disponíveis, e fornece o atendente 7 para a Sala 1. Já no 2º *Round* a Sala 2 continua sendo a primeira da lista, agora com 5 profissionais da saúde para serem liberados, e fornece o atendente 6 para realocação. Logo após, no 3º *Round*, a Sala 2 mantém-se no topo da lista, com 4 recursos humanos, e o atendente 5 é realocado. Após, no 4º *Round*, apesar de ambas as salas estarem com a mesma quantidade de atendentes disponíveis, a Sala 2 ainda está no topo da lista e o atendente 4 é realocado. Por fim no 5º *Round*, a Sala 4 tornou-se a primeira da lista por possuir 2 funcionários disponíveis, contra apenas 1 da Sala 2, e o atendente 12 é transferido para a Sala 1.

Após uma análise desse novo algoritmo utilizando uma lista ordenada, pode-se notar que o mesmo não apresenta o mesmo problema da alocação por fila circular, uma vez que existe um balanceamento de carga entre as salas do hospital. Dessa forma, ambas as salas que possuíam atendentes disponíveis para liberação no exemplo ilustrado na Figura 25 ficaram com a mesma quantidade de recursos humanos disponíveis ao final da execução. Assim, no próximo ciclo de monitoramento, ambas as salas possuem as mesmas chances de necessitarem de novos profissionais para atendimento. Então, para o processo de realocação de recursos humanos

Figura 25 – Realocação através do algoritmo *List Scheduling* adaptado, com uma lista de 4 salas, ordenada pela quantidade de recursos humanos disponíveis para elasticidade, e 12 atendentes, onde foi previsto que a Sala 1 precisa alocar mais 5 profissionais da saúde



Fonte: Elaborada pelo autor.

optou-se pelo uso do algoritmo de *List Scheduling* adaptado, nesse trabalho nomeado de *Human Resource List Scheduling* (HRLS).

Um problema da elasticidade, tanto na mecânica, quanto na computação em nuvem, é a *histerese*, isto é, a tendência do sistema de retornar ao estado anterior na ausência do impulso que ocasionou a mudança. No contexto da elasticidade de recursos humanos, a *histerese* pode ocorrer quando em um determinado instante de tempo uma sala fornece atendentes para outra, e no instante seguinte, ela precisa deles de volta, e a sala destino os fornece. Um exemplo, seria a Sala 1 precisar de mais dois profissionais para atendimento e a Sala 2 fornecer esses atendentes para a mesma. Como o tempo de espera da Sala 1 vai melhorar, o impulso que ocasionou a mudança deixa de existir. Já como a Sala 2 teve uma quantidade menor de funcionários em atendimento, provavelmente o tempo de espera vai piorar e a mesma vai precisar de no-



vos atendentes. Nesse contexto, a Sala 1 vai acabar devolvendo os profissionais anteriormente realocados para a Sala 2, ocasionando o problema da *histerese*.

A fim de tratar o problema da *histerese* na elasticidade de recursos humanos, decidiu-se por utilizar uma estratégia baseada em um *cooldown period* para evitar que ocorra o efeito indesejado. Assim, definiu-se que o *cooldown period* para a elasticidade global baseia-se no fato de que se uma determinada sala receber atendentes em um ciclo de monitoramento, no ciclo seguinte, independente se ela estiver com funcionários disponíveis para liberação, ela não pode fornecer atendentes. Dessa forma, no exemplo anterior, se a Sala 1 receber recursos humanos da Sala 2 no primeiro ciclo, no próximo ciclo, mesmo se a Sala 2 necessitar de atendentes, os mesmos serão fornecidos de outra fonte, evitando que ocorra o efeito de *histerese*.

Como pôde ser visto no Algoritmo 6 de HRLS, uma saída possível é que mesmo com a movimentação de pessoas entre os ambientes do hospital, ainda podem existir salas que necessitem de mais atendentes para fornecer o atendimento aos pacientes. Assim, já que não existem mais funcionários disponíveis para realocação, o modelo deve partir para o processo de alocação de novos recursos humanos. O Algoritmo 7 apresenta o pseudo-código proposto para a alocação de recursos humanos. A Linha 2, do algoritmo é responsável por tentar fazer a realocação de recursos humanos, conforme a prioridade proposta nesse modelo, e apenas se a realocação não é capaz de suprir a demanda, um novo atendente deve ser buscado externamente.

---

**Algoritmo 7:** Alocação de novos Recursos Humanos

---

**Entrada:** Sala  $s$  que precisa de atendentes, a lista ordenada  $l$  com todas as salas, e um vetor  $v$  com atendentes disponíveis para alocação externa

**Saída:** Situação final da sala  $s$

```

1 início
2   Executar o Algoritmo 6 de Human Resource List Scheduling utilizando  $s$  e  $l$  como
   entrada;
3   se  $s$  não precisa de mais atendentes então
4     return  $s$  está com a alocação adequada;
5   senão
6     enquanto  $s$  precisa de atendentes e há atendentes disponíveis em  $v$  faça
7        $s$  recebe um atendente de  $v$ ;
8     se  $s$  não precisa de mais atendentes então
9       return  $s$  está com a alocação adequada;
10    fim
11    return  $s$  ainda está com a alocação inadequada;
12  fim
13 fim

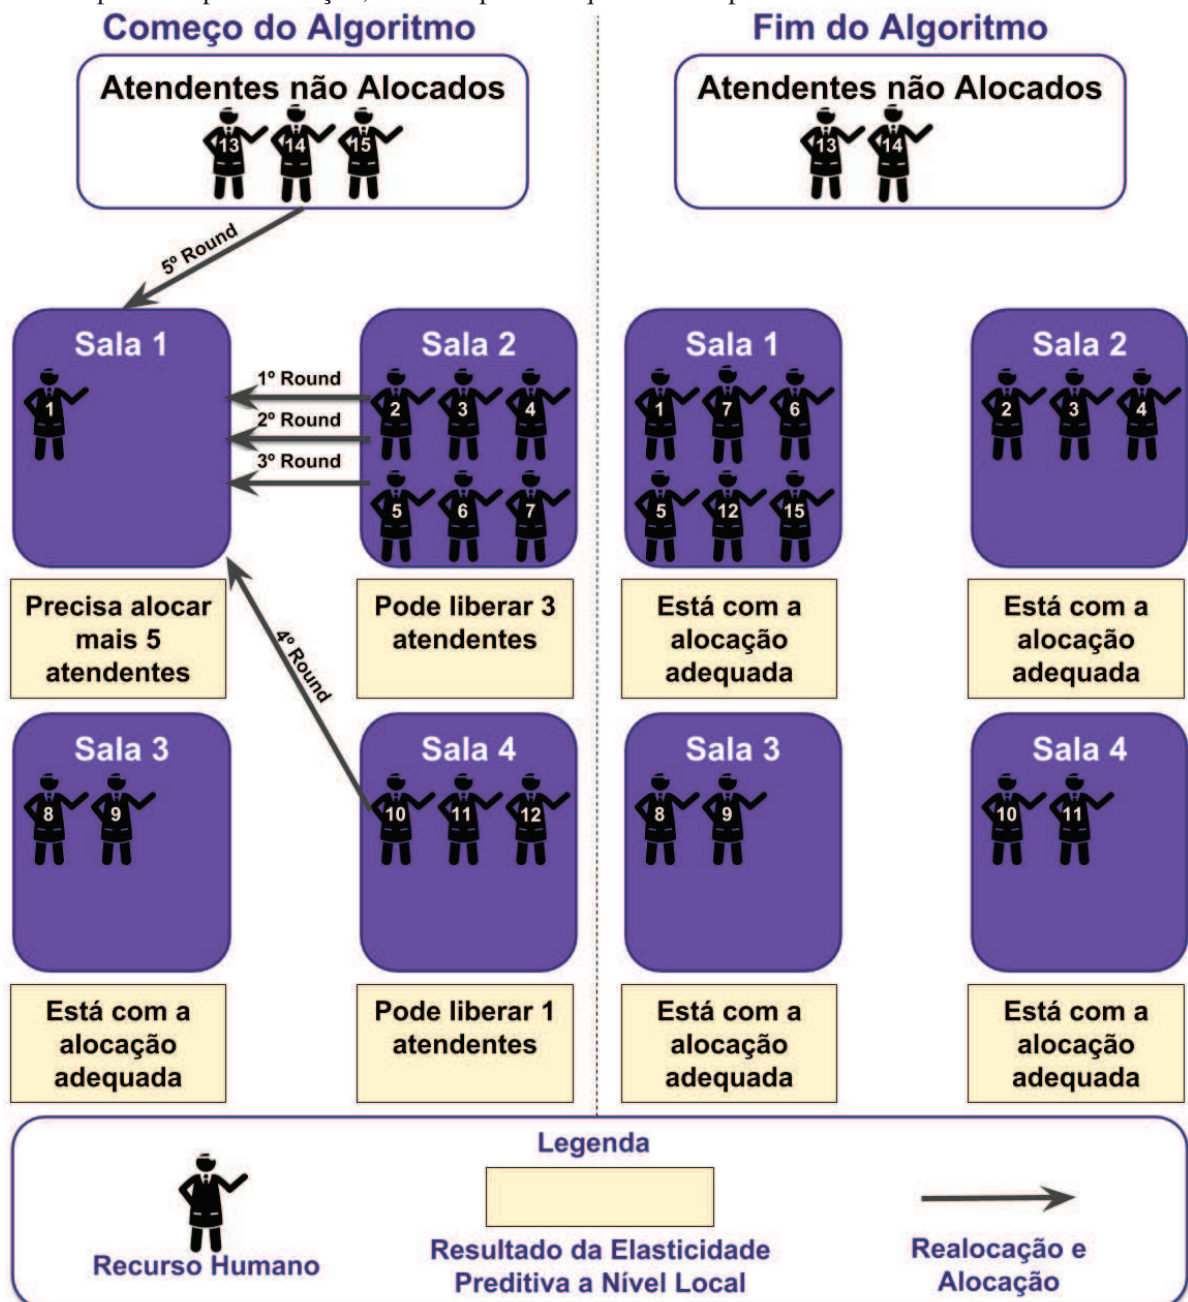
```

---

A Figura 26 ilustra um cenário em que é necessária a alocação de atendentes, através do algoritmo proposto, onde a Sala 1 precisa de mais 5 atendentes e as Salas 2 e 4 possuem atendentes disponíveis. Seguindo a lógica de *List Scheduling*, no 1º *Round* a Sala 2 é a primeira da lista, com 3 atendentes disponíveis, e fornece o atendente 7 para a Sala 1. Já no 2º *Round*

a Sala 2 continua sendo a primeira da lista, agora com 2 profissionais da saúde para serem liberados, e fornece o atendente 6 para realocação. Logo após, no 3º Round, apesar de ambas as salas estarem com a mesma quantidade de atendentes disponíveis, a Sala 2 ainda está no topo da lista e o atendente 5 é realocado. Após, no 4º Round, a Sala 4 tornou-se a primeira da lista por possuir 1 funcionário disponível, e o atendente 12 é transferido para a Sala 1. Nesse ponto não há mais atendentes disponíveis para realocação, mas a Sala 1 ainda precisa de mais um recurso humano, então no 5º Round o atendente 15 é alocado dentre os funcionários que não estão atuando naquele instante no hospital.

Figura 26 – Exemplo de Alocação, com uma lista de 4 salas, 12 atendentes em atendimento, e 3 profissionais disponíveis para alocação, onde foi previsto que a Sala 1 precisa alocar mais 5 recursos humanos



Em um ambiente hospitalar, geralmente é utilizado um modelo de trabalho conhecido como 12x36. Conforme a Lei nº 13.467 (BRASIL, 2017) nesse regime de trabalho um funcionário pode trabalhar por doze horas consecutivas (com direito a uma hora de almoço dentro desse período) e deve descansar por trinta e seis horas seguidas antes de uma nova jornada de doze horas. Nesse regime de trabalho, com quatro pessoas atuando em um mesmo posto é possível garantir a atuação vinte e quatro horas, sete dias por semana, de forma que todos trabalhem na mesma proporção dentro do período mensal. Ainda conforme o entendimento da lei, se por qualquer motivo um funcionário precisar trabalhar dentro do seu período de descanso, deve ser tratado como hora extra, a não ser que as horas sejam compensadas em outro momento.

Assim, enquanto um recurso humano do hospital está em efetivo trabalho, existem outros três funcionários que desempenham a mesma função dentro do seu período de descanso remunerado. Conforme o Decreto-Lei nº 5.452 (BRASIL, 1943), o descanso mínimo entre duas jornadas de trabalho deve ser de onze horas consecutivas. Dessa forma, mesmo que existam horas extras, um funcionário obrigatoriamente precisa descansar onze horas para retornar ao próximo turno de trabalho. Dessa forma, podemos dizer que esses três funcionários em período de descanso não estariam disponíveis para serem alocados a qualquer momento para atendimento, sendo necessário respeitar as seguintes regras para os mesmos estarem disponíveis:

**Regra 1:** O período mínimo de descanso para o recurso humano estar disponível para alocação é de onze horas;

**Regra 2:** Um funcionário alocado não pode desempenhar suas funções fora do seu período normal de trabalho por um grande período de tempo. Apesar da legislação trabalhista autorizar o acordo individual para definir questões como essa, o maior período possível de trabalho na legislação é o de doze horas, em função disso, decidiu-se que um funcionário alocado não pode trabalhar mais do que doze horas;

**Regra 3:** O funcionário alocado deve ser desalocado no máximo onze horas antes do seu próximo período normal de trabalho; e

**Regra 4:** Cada funcionário deve obrigatoriamente cumprir um dos períodos de 36 horas de descanso dentro da mesma semana, a fim de cumprir a lei que exige que todos os trabalhadores possuam um período de 24 horas seguidas de descanso por semana.

Assim, o Algoritmo 8 apresenta o pseudo-código proposto para definir quais funcionários, dentre todos aqueles em seu período de descanso, estão disponíveis para alocação, caso seja necessário aos interesses do hospital. A Linha 5 é responsável por garantir que a Regra 1 e a Regra 3 sejam cumpridas. Apesar de entre 24 e 36 horas existir um intervalo de doze horas, e não onze, espera-se que um funcionário alocado trabalhe por no mínimo uma hora, sendo necessário considerar essa hora juntamente ao intervalo de onze horas. Já a Linha 6 é responsável por garantir a Regra 4. A Regra 2 deve ser garantida pelo algoritmo responsável pela desalocação de recursos humanos.



---

**Algoritmo 8:** Definição de Recursos Humanos disponíveis para Alocação
 

---

**Entrada:** Vetor  $d$  com todos os recursos humanos do hospital em período de descanso

**Saída:** Vetor  $v$  com todos os recursos humanos disponíveis para alocação

```

1 início
2    $v \leftarrow$  um novo vetor de recursos humanos vazio;
3   para todo Recurso Humano  $rh$  do vetor  $d$  faça
4      $td \leftarrow$  tempo de descanso atual de  $rh$ ;
5     se  $td > 11$  horas e  $td < 24$  horas então
6       se  $rh$  já teve um período de 36 horas de descanso ou ainda possui mais
7         um período de 36 horas de descanso a acontecer nessa semana então
8            $v.add(rh)$ ;
9     fim
10  return  $v$ ;
11 fim

```

---

Por fim, se o algoritmo identificar que a demanda de atendimento de todas as salas do hospital está muito baixa e que a desalocação de atendentes de alguma sala não prejudique o todo, o algoritmo deve identificar quais atendentes foram alocados fora de seu horário habitual de trabalho e desalocá-los para diminuir os custos financeiros do hospital. Nos casos em que apenas existam atendentes dentro do horário habitual de trabalho, o sistema deve gerar relatórios para que os gestores do hospital posteriormente avaliem a possibilidade de uma alteração do turno de trabalho de algum atendente para diminuir os custos do hospital. O Algoritmo 9 apresenta o pseudo-código proposto para a desalocação de recursos humanos.

---

**Algoritmo 9:** Desalocação de Recursos Humanos
 

---

**Entrada:** Lista ordenada com todas as salas  $l$  do hospital e o vetor  $a$  com todas os atendentes alocados no hospital

**Saída:** Lista de salas  $l$  atualizada

```

1 início
2   para todo Recurso Humano  $rh$  da lista de atendentes  $a$  faça
3      $tt \leftarrow$  tempo que falta para o próximo turno de  $rh$ ;
4     se  $tt \leq 11$  horas então
5       libera  $rh$ ;
6   fim
7    $qd \leftarrow$  quantidade de atendentes disponíveis nas salas de  $l$ ;
8    $qf \leftarrow$  quantidade de atendentes faltando nas salas de  $l$ ;
9   enquanto  $qd < qf$  e  $size(a) > 0$  faça
10    ordena  $a$ , por tempo em atendimento decrescente;
11     $rh \leftarrow a.get(0)$ ;
12    libera  $rh$ ;
13  fim
14  return  $l$ ;
15 fim

```

---

Em todas as possibilidades, alocação, realocação ou desalocação, o ElHealth deve gerar uma notificação e encaminhar ao recurso humano para que o mesmo possa realizar a ação escolhida pelo algoritmo. As notificações de elasticidade de recursos humanos devem estar todas disponíveis para os gestores do hospital visualizarem na hora em que elas ocorrem. Isso se torna necessário, pois situações pontuais podem exigir que os gestores sejam contra uma determinada escolha do algoritmo, conforme a necessidade do hospital naquele momento específico. Além disso, o algoritmo apenas envia as notificações e monitora a movimentação dos atendentes, não sendo responsável pela efetiva movimentação dos profissionais de saúde, que podem decidir acatar a movimentação ou não. Nos casos em que um determinado atendente não realizar a movimentação indicada pelo algoritmo, o ElHealth deve notificar os gestores do hospital, para que os mesmos sejam capazes de entrar em contato com o atendente e avaliarem a sua recusa em seguir o que o algoritmo indicou.

Com base em todas as descrições, algoritmos e formalismos apresentados até o momento, o modelo ElHealth adiciona na literatura o conceito de “Elasticidade Preditiva Multinível de Recursos Humanos” em ambientes hospitalares que pode ser definida da seguinte forma:

**Definição 2: Elasticidade Preditiva Multinível de Recursos Humanos** é uma extensão do conceito de elasticidade de recursos em *Cloud Computing* (AL-DHURAIBI et al., 2017) para gerenciar o uso de recursos humanos em diferentes níveis de um ambiente hospitalar, de modo que os recursos humanos são alocados e desalocados conforme a demanda prevista de pacientes. A Elasticidade Preditiva Multinível de Recursos Humanos visa gerar planos de alocação de profissionais da saúde nos ambientes hospitalares com base na demanda de pacientes, mas sempre considerando a qualidade dos serviços oferecidos atualmente pelos ambientes hospitalares.

Conforme proposto por Al-Dhuraibi et al. (2017), sistemas elásticos podem ser classificados de várias formas, dependendo de seus atributos, dentre eles: (I) Configuração, (II) Escopo, (III) Objetivo, (IV) Método, (V) Arquitetura, (VI) Provedor e (VII) Modo de Operação. Com relação ao atributo Configuração, o modelo ElHealth propõe um sistema elástico configurável, uma vez que o gerenciador de elasticidade deve ser capaz de solicitar atendentes que tenham as características (ou configurações) necessários ao atendimento da demanda de uma sala em específico. Se o sistema fosse rígido, só haveria um tipo de atendente disponível, mas no modelo proposto podem existir vários. Ainda nesse atributo, com relação ao método de reserva, o ElHealth faz uso da reserva sob demanda, uma vez que assim que o modelo identificar a necessidade de novos atendentes, o recurso humano é “reservado” imediatamente, ou a reserva é rejeitada caso não existam profissionais disponíveis para alocação.

Já para o atributo Escopo, o modelo ElHealth propõe um sistema de elasticidade embarcada para aplicação ou plataforma. Essa é a melhor classificação, pois segundo Al-Dhuraibi et al. (2017) na elasticidade embarcada, as aplicações elásticas são capazes de ajustar seus próprios recursos de acordo com os requisitos de tempo ou devido a mudanças no fluxo de execução, tal

qual o modelo EIHealth propõe. Além disso, o modelo faz elasticidade em várias camadas, pois toma decisões de elasticidade em dois níveis, local e global. Para o atributo Objetivo, o modelo EIHealth apresenta um sistema elástico para aumentar capacidade, uma vez que o principal objetivo do EIHealth é justamente o aumento da capacidade de atendimento do hospital sempre que a demanda de pacientes exigir.

Com relação ao Método, o modelo EIHealth propõe um sistema de elasticidade horizontal apenas. Isso ocorre pois o EIHealth trabalha com recursos humanos que já são funcionários do ambiente hospitalar, sendo impossível para o modelo propor alterações na capacidade de atendimento individual de cada profissional de saúde. Dessa forma, a única ação de elasticidade possível ao EIHealth é adicionar ou remover recursos humanos horizontalmente para atender a demanda. No que se refere a Arquitetura, o modelo EIHealth apresenta um gerenciador elástico centralizado, uma vez que o módulo EIHealth\_Elastic é o único responsável por tomar as decisões de elasticidade.

Quanto ao Provedor, o EIHealth propõe um provedor único. No modelo proposto, só estão sendo considerados para a alocação funcionários que já trabalham para o hospital em outros turnos de trabalho, dessa forma só existe um provedor de recursos. Por fim, com relação ao Modo de Operação, o modelo EIHealth propõe um sistema elástico automático proativo e preditivo, através de uso de análise de séries temporais por meio do modelo ARIMA. O EIHealth é considerado proativo, pois as decisões de elasticidade são tomadas antes que o modelo atinja os *thresholds* pré-definidos, e não após como na elasticidade reativa. Ao mesmo tempo o modelo é preditivo, pois faz uso de técnicas de previsão computacional para prever a demanda de pacientes e propor as ações de elasticidade baseada na demanda prevista. A Figura 27 sumariza as classificações do modelo EIHealth para os atributos apresentados.

Figura 27 – Classificações do modelo EIHealth para os atributos propostos por Al-Dhuraibi et al. (2017)



Fonte: Elaborada pelo autor.

#### 4.4 Considerações Parciais

Este capítulo apresentou o modelo ElHealth, um modelo elástico preditivo multinível para gerenciamento de recursos humanos em hospitais inteligentes. A elasticidade proposta deve ser transparente aos pacientes e não deve afetar negativamente o atendimento já oferecido aos mesmos. O modelo trabalha com elasticidade em dois níveis: (I) a nível local, onde é analisada a demanda de cada sala do ambiente hospitalar e identificada a necessidade de alocar ou liberar atendentes; e (II) a nível global, onde é analisada a necessidade identificada por cada uma das salas de forma a serem propostas ações de alocação, realocação ou desalocação de recursos humanos.

Também nesse capítulo estão presentes as principais decisões de projeto, como a proposta de um RTLS com precisão a nível de sala, o uso de *thresholds* baseados em tempo de espera para a elasticidade preditiva, e o uso da abordagem de predição computacional baseada em probabilidade e estatística de séries temporais, através do modelo ARIMA. Está presente também uma descrição detalhada da arquitetura proposta, com a descrição de cada um dos componentes do modelo, bem como as suas interligações, e os algoritmos propostos para cada um deles. Dentro dos componentes do ElHealth, destacam-se os mecanismos para gerenciamento de recursos humanos, onde são propostos o (I) **Speedup Elástico Proativo de Recursos Humanos**, uma extensão do conceito de Speedup da computação paralela (AMDAHL, 1967) para identificar o ganho de tempo de atendimento com o uso paralelo de recursos humanos em ambientes hospitalares; e a (II) **Elasticidade Preditiva Multinível de Recursos Humanos**, uma extensão do conceito de elasticidade de recursos em *Cloud Computing* (AL-DHURAIBI et al., 2017) para gerenciamento do uso de recursos humanos em diferente níveis de um ambiente hospitalar, de forma que os profissionais são alocados, desalocados e realocados conforme a demanda prevista de pacientes.

## 5 METODOLOGIA DE AVALIAÇÃO

Para avaliação e validação do modelo EIHealth, definiu-se que seria interessante o uso de uma simulação computacional do ambiente hospitalar. Com o uso de uma simulação, um grande número de dados sintéticos podem ser gerados para treinar o modelo de predição, e alimentar a aplicação que será desenvolvida. Cargas de trabalho sintéticas foram escolhidas em função da indisponibilidade de dados reais. Além disso, de acordo com Islam et al. (2012), cargas de trabalho sintéticas são consideradas uma forma representativa para avaliar a elasticidade em nuvens computacionais. Nas Seções abaixo, serão detalhados os cenários que serão simulados, os parâmetros que serão utilizados, a infraestrutura do hospital inteligente, quais as métricas de avaliação que serão utilizadas, as cargas de trabalho geradas e os testes do sistema RTLS.

### 5.1 Implementação e Ambiente de Testes

Para a realização dos experimentos no ambiente hospitalar, foi desenvolvido um protótipo em Java e em Python do sistema EIHealth. Esse protótipo contemplou o desenvolvimento do gerenciador de elasticidade EIHealth\_Elastic, juntamente com o sistema de predição EIHealth\_Predict . Além destes, foi desenvolvido um simulador para o ambiente hospitalar.

#### 5.1.1 Protótipo Desenvolvido

Para realização da avaliação do modelo EIHealth, foi implementado um protótipo do gerenciador de elasticidade EIHealth\_Elastic utilizando a linguagem Java. Esse protótipo consiste em um gerenciador que realiza as operações de monitoramento de recursos humanos, tempo de espera e quantidade de pacientes aguardando atendimento para realizar elasticidade de recursos humanos em um ambiente hospitalar inteligente. O monitoramento do ambiente é realizado através de consultas ao banco de dados da aplicação, onde estão armazenadas informações referente a movimentação de pessoas entre as salas do hospital, bem como os tempos de permanência em cada um dos setores. Para o controle do ambiente, o modelo envia notificações de elasticidade aos recursos humanos, informando para qual sala os mesmos devem se deslocar. Apesar do gerenciador de elasticidade armazenar o resultado da movimentação dos funcionários, no ciclo seguinte de monitoramento, o mesmo faz novamente todas as consultas ao banco de dados para verificar o estado real do sistema. Isso faz-se necessário pois se um recurso humano não cumprir a notificação de elasticidade, o resultado de elasticidade do ciclo anterior não vai condizer com a realidade do sistema. Para tomar as decisões de elasticidade, o modelo consulta a cada ciclo de monitoramento os limites de tempo estabelecidos individualmente para cada sala do ambiente hospitalar. Dessa forma, caso seja interessante para os gestores de um hospital, podem ser estabelecidos limites diferentes para salas com características distintas.

Para o gerenciador EIHealth\_Elastic realizar o controle elástico dos recursos humanos, ele

faz uso de uma abordagem preditiva de demanda e capacidade de atendimento, através da análise da chegada de pacientes e do tempo de atendimento em cada ciclo de monitoramento. Para realizar a análise preditiva, foi implementado um protótipo do sistema de predição *ElHealth\_Predict* utilizando a linguagem Java e Python. Esse protótipo consiste em uma aplicação em Java responsável por identificar as séries temporais que representam a realidade do ambiente hospitalar e uma aplicação em Python responsável por aplicar o modelo ARIMA sobre as séries temporais de forma a prever os valores futuros para as séries. Para identificar as séries temporais, a aplicação faz consultas ao banco de dados, e agrupa as informações identificadas em intervalos de tempo equivalentes aos ciclos de monitoramento. A cada novo ciclo, o sistema *ElHealth\_Predict*, faz uma atualização nas séries temporais e reaplica o modelo ARIMA.

### 5.1.2 Simulador do ambiente hospitalar

Partindo-se do modelo proposto, foi desenvolvida uma implementação capaz de realizar a simulação do ambiente hospitalar proposto e armazenar algumas estatísticas após sua execução, de forma a serem utilizadas para análise dos resultados. Para a implementação do simulador foi utilizada a linguagem Java. Para a simulação das filas do hospital, optou-se pelo uso de um relógio com incrementos discretos de dez segundos. A cada avanço no relógio da simulação, o simulador verifica os pacientes que estão em atendimento e aqueles que devem sair do atendimento. A cada ciclo de monitoramento, deve ser verificada a chegada de pacientes. Para definir o tempo de atendimento em cada um dos setores, e a movimentação dos pacientes ao longo do ambiente hospitalar, o simulador utiliza a classe *StdRandom* desenvolvida por Sedgewick e Wayne (2017), disponibilizada pela Universidade de Princeton. A classe *StdRandom* é responsável por gerar números aleatórios para as mais diversas distribuições de probabilidade.

### 5.1.3 Ambiente de Simulação

O ambiente utilizado para a simulação hospitalar e para os testes do protótipo desenvolvido é um equipamento com as seguintes características: Processador Intel Core I7 3770 com quatro núcleos físicos de 3.4 GHz, Memória de 16GB com frequência de 1600 MHz, Disco rígido SSD de 240 GB Kingston v300, Sistema operacional Windows 10 Pro, Servidor MySQL 5.7.23, Java Virtual Machine versão Java 8 Update 91 e Python versão 3.7.

## 5.2 Cenários

Para avaliação do modelo *ElHealth*, foram definidos três cenários de estudo para análise. Em todos os cenários serão utilizados os mesmos parâmetros de entrada, com os mesmos padrões de carga para chegadas de pacientes, e as mesmas distribuições de probabilidade para tempos médios e limites de atendimento e espera. As diferenças nos cenários estão relacionadas ao uso

do modelo proposto no ambiente hospitalar e serão descritas a seguir:

- C1: Hospital Atual (Não Elástico):** de forma a se ter os dados para comparação, o primeiro cenário de testes se baseia na simulação de um ambiente hospitalar sem o uso do modelo ElHealth com a alocação de atendentes de forma estática, como ocorre na maioria dos hospitais.
- C2: Hospital Inteligente com Realocação de Recursos Humanos (usando o ElHealth, mas de forma parcial):** o segundo cenário de testes foca na simulação do ambiente hospitalar com o uso do conceito de realocação de pessoas proposto no modelo ElHealth, possuindo uma alocação inicial de atendentes idêntica a do primeiro cenário, entretanto, com base na Elasticidade Preditiva Multinível de Recursos Humanos proposta neste trabalho, a alocação se torna dinâmica ao longo do dia de atendimento, com os profissionais de saúde sendo realocados de forma elástica conforme a demanda. Nesse cenário serão utilizados apenas os atendentes já alocados no hospital, sem alocação externa de recursos humanos.
- C3: Hospital Inteligente com Alocação, Realocação e Desalocação de Recursos Humanos (usando o ElHealth):** o terceiro cenário de testes foca na simulação do ambiente hospitalar com o uso da alocação, realocação e desalocação de pessoas proposta no modelo ElHealth, possuindo uma alocação inicial de atendentes idêntica aos cenários anteriores, entretanto, com base na Elasticidade Preditiva Multinível de Recursos Humanos proposta neste trabalho, a alocação se torna dinâmica ao longo do dia de atendimento, com os profissionais de saúde sendo ajustados de forma elástica conforme a demanda. Ao contrário do segundo cenário, poderão ser alocados novos recursos humanos para atendimento no hospital conforme a necessidade.

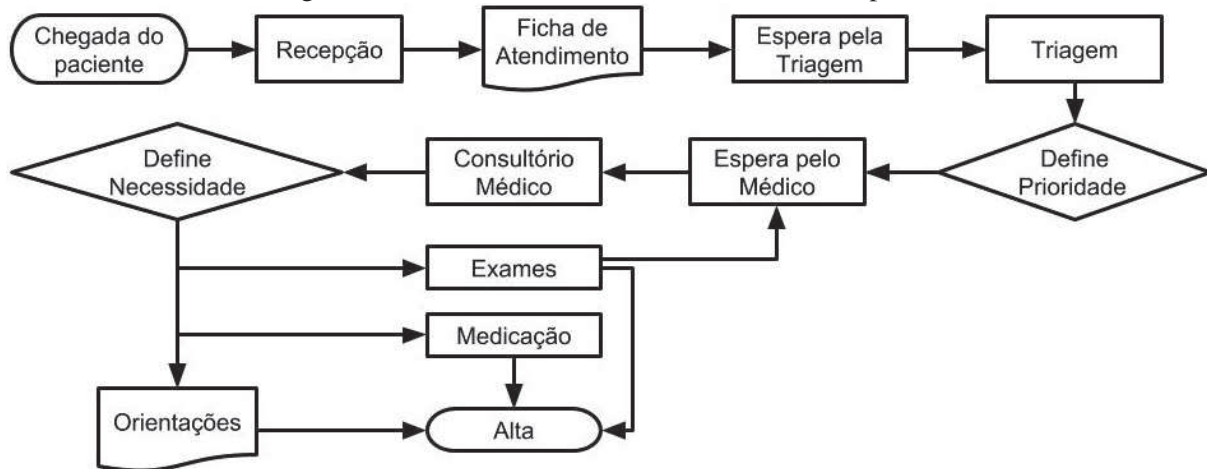
### 5.3 Parâmetros

Para realizar a simulação do ambiente hospitalar, primeiramente optou-se por realizar uma coleta de dados referente a chegadas de pacientes em um ambiente hospitalar e a sua movimentação durante o atendimento. Com base na coleta de dados, torna-se possível a definição dos parâmetros que serão utilizados pela simulação do modelo ElHealth. Em função do tempo disponível e da indisponibilidade de parcerias com hospitais próximos que estivessem dispostos a fornecer os dados necessários para aplicação do modelo, optou-se pelo uso dos dados levantados na pesquisa de Capocci et al. (2016) realizada em um ambiente hospitalar localizado na cidade de Guarulhos no estado de São Paulo. O fluxo de atendimento nessa unidade de saúde pode ser visto na Figura 28.

De acordo com Capocci et al. (2016), todos os pacientes ao entrarem na unidade passam primeiramente por uma recepção, onde é elaborada a ficha de atendimento. Após a elaboração da ficha, os pacientes são encaminhados para a espera pela triagem. No procedimento de triagem, os pacientes são examinados pela equipe de enfermagem e classificados em prioridades



Figura 28 – Fluxo de atendimento do ambiente hospitalar



Fonte: Elaborada pelo autor com base em Capocci et al. (2016).

conforme a urgência do problema de saúde e são encaminhados para a espera pelo atendimento médico. O médico que atender o paciente pode encaminhá-lo para a área de medicação, ou para exames laboratoriais, ou dar alta. A área de medicação conta com atendimentos diferentes para aplicação intravenosa, intramuscular e por inalação. Na área de exames laboratoriais, o ambiente hospitalar possui raio-x, eletrocardiograma, ou exames de coleta (exame de sangue, por exemplo). Após os exames ou medicação, o paciente pode receber alta pela equipe de enfermagem ou retornar ao atendimento médico.

Ainda de acordo com Capocci et al. (2016), o tempo de atendimento em cada uma das salas do ambiente hospitalar sempre segue uma distribuição triangular, com tempos mínimo e máximo e um tempo médio mais frequente. A Tabela 6 apresenta as distribuições para todos os atendimentos possíveis nessa unidade hospitalar, conforme identificado na pesquisa de Capocci et al. (2016).

Segundo Capocci et al. (2016), na unidade de saúde estudada pelos autores, os seguintes parâmetros foram identificados com relação a chegada de pacientes:

- Em média são atendidos 190 novos paciente por dia;
- Após a triagem, 5% dos pacientes são classificados como emergência, 12% como urgência, 23% como pouco urgentes e 60% como não urgentes.

Com relação ao primeiro atendimento no consultório médico:

- Em geral, 24% dos pacientes são encaminhados para Raio-x, 37% para exames de coleta, 8% para eletrocardiogramas e 31% não necessitam fazer nenhum exame;
- Apenas 1% dos pacientes não tomam medicação e recebem alta apenas com uma receita, porém 50% dos pacientes necessitam de medicação intravenosa, 30% de medicação intramuscular e 19% de medicação por inalação.



Tabela 6 – Distribuições triangulares de probabilidade para tempos de atendimento

<b>Atendimento</b>	<b>Tempo de Atendimento</b>		
	<b>Mínimo</b>	<b>Médio</b>	<b>Máximo</b>
<b>Entrada no Hospital</b>			
Elaboração da Ficha de Atendimento	2 minutos	3 minutos	5 minutos
Processo de Triagem	5 minutos	8 minutos	10 minutos
<b>Consultório Médico</b>			
Primeiro atendimento no consultório médico	5 minutos	11 minutos	16 minutos
Atendimento de retorno ao consultório médico	4 minutos	7 minutos	10 minutos
<b>Exames Laboratoriais</b>			
Exames de Coleta	6 minutos	8 minutos	13 minutos
Raio-x	10 minutos	15 minutos	23 minutos
Eletrocardiograma	30 minutos	45 minutos	60 minutos
<b>Medicação</b>			
Medicação intramuscular	3 minutos	3,5 minutos	5 minutos
Preparação para a medicação intravenosa e por inalação	0,5 minuto	1,5 minutos	2,5 minutos
Medicação intravenosa	40 minutos	70 minutos	120 minutos
Medicação por inalação	8 minutos	10 minutos	13 minutos

Fonte: Elaborada pelo autor com base em Capocci et al. (2016).

Com relação ao atendimento na área de medicação:

- Medicação intravenosa possui 10 lugares para o processo;
- Medicação por inalação disponibiliza 6 lugares para o procedimento;

Com relação ao atendimento na área de exames:

- O resultado de exames de coleta sai em 4 horas;
- O Raio-x leva meia hora para ficar pronto;
- Após os exames, em média 60% dos pacientes precisam retornar ao atendimento médico os outros 40% recebem alta;
- Os pacientes de retorno são reclassificados nas prioridades pela espera do atendimento médico com 90% como não urgentes, 9% como pouco urgentes e apenas 1% como urgente.

Com relação ao atendimento de retorno no consultório médico:

- Após o atendimento 78% recebem alta, 2% precisam de novos exames e 20% necessitam de medicação no local.

Com relação ao gerenciamento de elasticidade, de acordo com Al-Dhuraibi et al. (2017), é necessária a definição de *thresholds* ou limites para que o sistema reaja disparando as ações para adaptar o sistema à demanda. No contexto do gerenciamento elástico de recursos humanos, optou-se por *thresholds* de tempo de espera em cada um dos pontos de atendimento do ambiente hospitalar. Para definir o tempo máximo que um paciente pode aguardar pelo atendimento, em um primeiro momento pensou-se em utilizar os limites definidos no Protocolo de Triagem de Manchester. Entretanto, no ambiente hospitalar estudado por Capocci et al. (2016), não é utilizado a classificação *Muito Urgente*, dessa forma, o menor *threshold* para cada ponto de atendimento seria a classificação *Urgente* com 60 minutos de espera. Em função de uma hora de espera parecer ser muito tempo, optou-se por realizar uma busca na legislação brasileira a respeito do tema. Não encontrou-se nenhuma lei que defina limites de tempo de espera para unidades hospitalares, entretanto encontrou-se o Projeto de Lei de 14 de junho de 2018 (FÁBIO, 2018) que propõe um tempo máximo de espera por atendimento em hospitais, clínicas e laboratórios de 30 minutos em dias normais (de segunda-feira a domingo) e 45 minutos em feriados, véspera de feriados e nos dias subseqüentes a eles. Dessa forma foi estabelecido ao EIHealth o limite superior de 30 minutos de espera.

Para definir o limite inferior, adotou-se uma estratégia baseada em trabalhos como os propostos por Rostirolla et al. (2017); Righi et al. (2016); Rosa Righi et al. (2016), onde são adotados *thresholds* inferiores para elasticidade entre 30% e 50% da carga máxima do sistema. Esse intervalo de limites inferiores também foi baseado no trabalho de Al-Haidari, Sqalli e Salah (2013), que propõe uma análise teórica com teoria de filas para observar o desempenho de elasticidade em nuvem. Dessa forma, partindo-se do tempo máximo de espera de 30 minutos, 30% seria equivalente a um *threshold* inferior de 9 minutos e 50% seria equivalente a 15 minutos. Dessa forma optou-se por um limite inferior de 9 minutos, pois partiu-se do pressuposto de que quanto menor a espera de um paciente por atendimento, melhor será a experiência do mesmo com o hospital. Assim, a Tabela 7 apresenta os limites de tempo estabelecidos para as ações de elasticidade no modelo EIHealth.

Tabela 7 – *Thresholds* de tempo para Gerenciamento de Elasticidade do modelo EIHealth

<i>Thresholds</i>	Tempo de Atendimento
<i>Threshold</i> Superior (TS)	30 minutos
<i>Threshold</i> Inferior (TI)	9 minutos

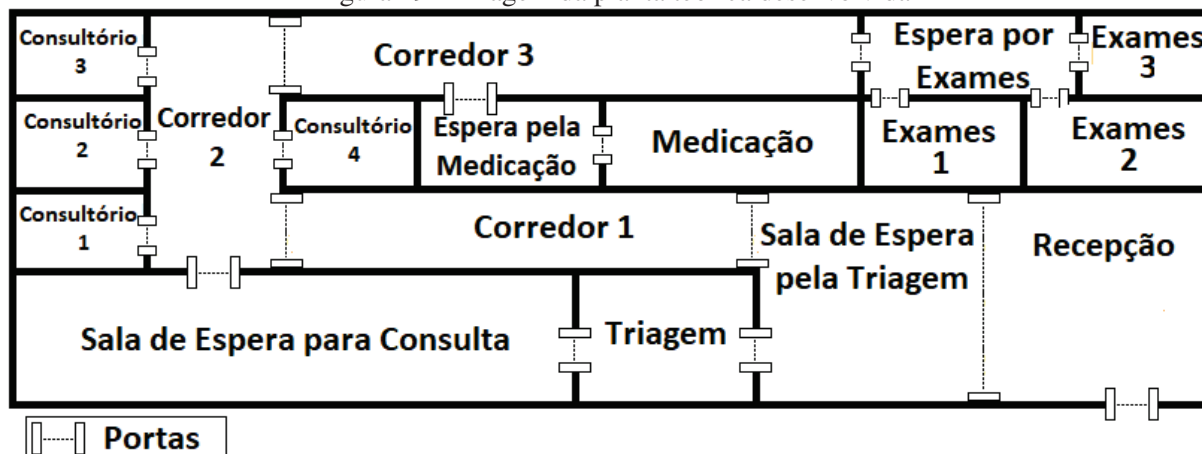
Fonte: Elaborada pelo autor.

## 5.4 Infraestrutura

De forma a se realizar a simulação do ambiente hospitalar proposto no modelo EIHealth, foi desenvolvida uma unidade de atendimento teórica, usando como base as especificações da unidade estudada por Capocci et al. (2016). Nessa unidade hospitalar existem diversos ambien-

tes distintos, onde cada um é caracterizado com um dos possíveis lugares nos quais o sistema estará preparado para identificar pacientes e profissionais de saúde. Na Figura 29 temos a representação visual da planta desse ambiente hospitalar.

Figura 29 – Imagem da planta teórica desenvolvida



Fonte: Elaborada pelo autor.

O hospital proposto possui uma recepção que acomoda os atendentes que são responsáveis pelo primeiro contato com os pacientes e geração do boletim de atendimento e uma sala de espera onde os pacientes já inclusos no sistema devem aguardar a chamada para a triagem. Logo após, existe uma área de triagem, onde os pacientes devem receber o primeiro atendimento clínico por enfermeiros capacitados para tanto. Após a triagem, existe uma nova sala de espera, onde os pacientes podem aguardar para o atendimento no consultório dos médicos. Também existem diversos consultórios, onde os médicos devem estar alocados para atender os pacientes. O ambiente hospitalar possui uma sala de espera para pacientes aguardando para receber medicações e a área onde eles devem receber as medicações e enfermeiros habilitados para aplicá-las. No ambiente estudado por Capocci et al. (2016), existem dez vagas para pacientes estarem recebendo medicação intravenosa ao mesmo tempo, seis vagas para medicação por inalação e uma vaga para medicação intravenosa, então esse trabalho seguirá com os mesmos números. Além da área de medicação, deve existir uma sala de espera para os exames hospitalares, e várias salas onde os exames de raio-x, eletrocardiograma e coleta podem ocorrer.

### 5.5 Workload de Entrada

Para o presente trabalho, será utilizado a alocação de recursos humanos encontrada por Capocci et al. (2016) no ambiente hospitalar estudado em sua pesquisa. Nessa unidade clínica o atendimento é prestado 24 horas por dia, sete dias por semana, possuindo uma alocação de 11 recursos humanos, atuando diretamente no atendimento aos pacientes, destes sendo dois médicos, seis enfermeiros, um técnico em radiologia e dois atendentes. Em qualquer horário do dia existe a mesma quantidade de atendentes, sendo mantido o número através de mais de um

turno de trabalho. A alocação dos profissionais de saúde nos ambientes é definida da seguinte forma:

- 2 atendentes sem qualificação médica atuando na recepção;
- 1 enfermeiro atuando na triagem de pacientes;
- 2 médicos atuando no atendimento em consultórios;
- 2 profissionais de enfermagem atuando com exames de coleta;
- 2 enfermeiros atuando em toda a área de medicação;
- 1 enfermeiro atuando no eletrocardiograma; e
- 1 técnico em radiologia atuando com os exames de raio-x.

Com relação a carga de pacientes, optou-se pelo uso dos mesmos parâmetros levantados por Capocci et al. (2016), dessa forma será utilizada a quantidade média de pacientes identificada pelo autor em um dia de atendimento na unidade hospitalar. Esses parâmetros foram utilizados para modelar quatro cargas de trabalho: Crescente, Constante, Decrescente e Onda. A ideia de usar diferentes comportamentos de carga para uma mesma aplicação é utilizada para observar como a carga de entrada pode impactar em pontos de saturação, gargalos e na adição ou remoção de recursos. (RIGHI et al., 2016). Esses quatro comportamentos de padrões de carga são baseados nos proposto por Righi et al. (2016) em seu trabalho. Dessa forma, para cada instante de tempo em que ocorre entrada de pacientes, um parâmetro  $carga(x)$  é recalculado individualmente, modelando um determinado comportamento de carga. Por exemplo,  $carga(x)$  pode ser igual a  $1x$  em um primeiro instante,  $2x$  no segundo instante,  $3x$  no terceiro instante e assim sucessivamente para gerar o comportamento crescente. A Tabela 8 apresenta as funções para cálculo do valor para  $carga(x)$  para a geração de cada comportamento de carga, onde existem 48 instantes de tempo por dia, o equivalente a um instante de tempo a cada 30 minutos.

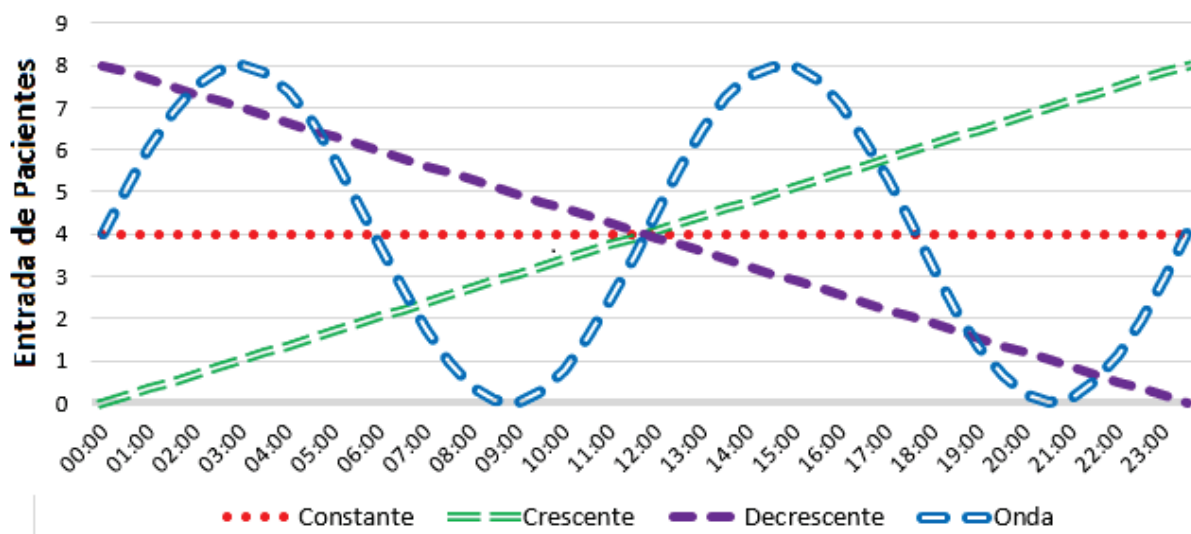
Tabela 8 – Funções para expressar os diferentes comportamento de carga. Em  $carga(x)$ ,  $x$  é o instante de tempo que será realizada a entrada de pacientes

Carga	Função de Carga	Parâmetros			
		v	w	t	z
Constante	$carga(x) = w$	-	4	-	-
Crescente	$carga(x) = x * t$	-	-	0,1703	-
Decrescente	$carga(x) = (w - x) * t$	-	47	0,1703	-
Onda	$carga(x) = v * z * sen(t * x) + v * z + w$	1	0	0,2674	4

Fonte: Elaborada pelo autor.

A Figura 30 apresenta graficamente uma representação de cada padrão de carga do modelo. O eixo  $x$  expressa o tempo disponível em um dia de atendimento na unidade hospitalar, enquanto que o eixo  $y$  representa a chegada de pacientes em cada instante de tempo.

Figura 30 – Representação gráfica dos padrões de carga utilizados na avaliação do ElHealth



Fonte: Adaptado de Righi et al. (2016).

Em função das equações propostas para os padrões de carga gerarem números decimais, foi necessário estabelecer uma estratégia para gerar números inteiros para chegada dos pacientes no ambiente hospitalar. Isso ocorre pois em um ambiente real, não é possível a chegada de 0,2 paciente ou 1,7 pacientes, por exemplo. Dessa forma, adotou-se uma estratégia baseada no acúmulo de carga. Assim, se em um determinado instante houver algo ente 0,1 e 0,9 paciente, esse valor é acumulado com a carga do instante seguinte. Um exemplo dessa estratégia seria um instante qualquer com a carga de 0,6 paciente. Como não haveria um número inteiro de carga, não seria introduzido um paciente no sistema e a carga ficaria acumulada para o próximo instante de tempo. No instante seguinte, com uma nova carga de 0,6 paciente, a carga acumulada seria de 1,2 paciente, resultando na entrada de 1 paciente no hospital. Assim, sobraria ainda 0,2 paciente, que seria acumulado para o próximo instante e assim sucessivamente.

## 5.6 Métricas de Avaliação

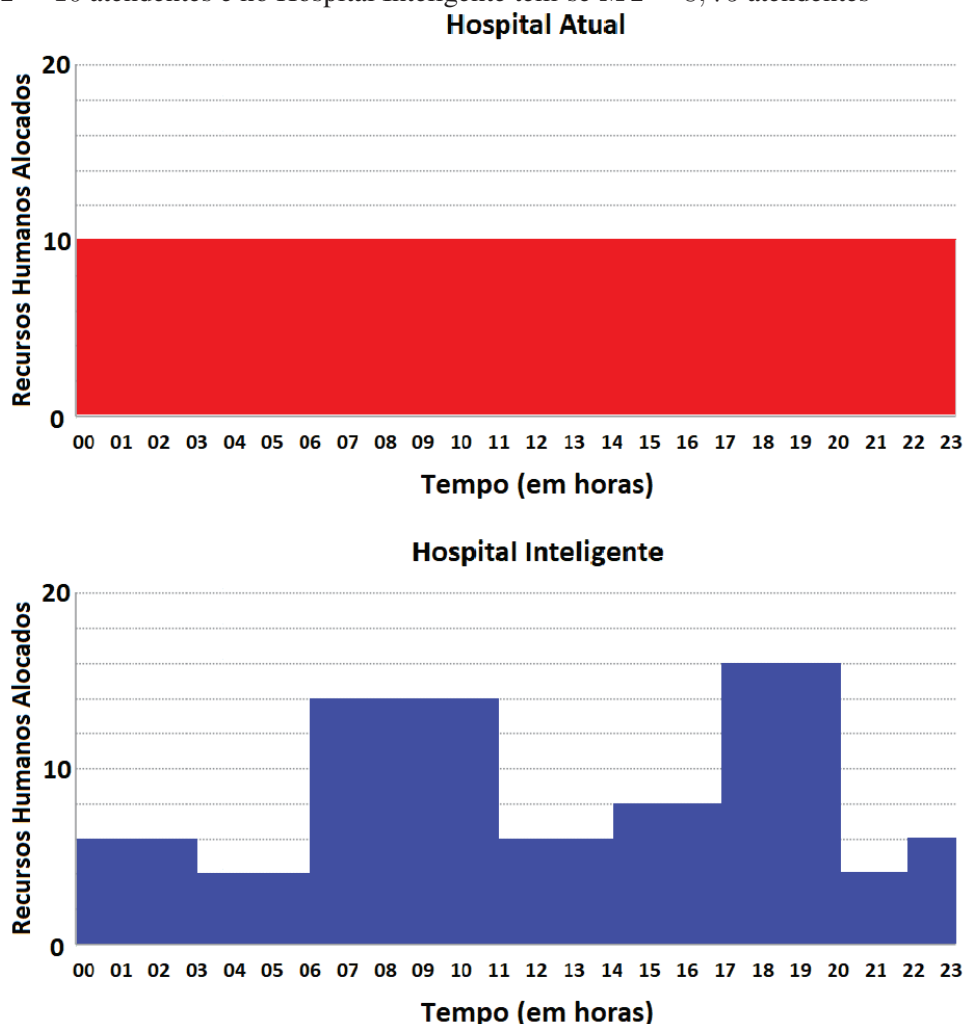
A fim de avaliar o modelo proposto, serão analisadas quatro principais métricas:

- **M1:** Tempo máximo de espera por atendimento,
- **M2:** Quantidade elástica de recursos humanos utilizados,
- **M3:** Custo de atendimento e
- **M4:** Quantidade média de pacientes aguardando.

Para avaliar o tempo de espera, será utilizado como parâmetro a variação do tempo máximo de espera entre os cenários e a adequação do tempo máximo de espera aos limites estabelecidos.

Dessa forma, devem ser realizadas várias simulações do ambiente hospitalar teórico, de forma a encontrar os tempos de espera por atendimento para todos os cenários propostos nessa metodologia de avaliação. A escolha do uso do maior tempo de espera como parâmetro ao invés de usar o tempo médio de espera têm como objetivo avaliar se todos os pacientes serão atendidos dentro dos tempos de atendimento estabelecidos. Um exemplo em que o uso do tempo médio de espera seria inadequado aos objetivos do EIHealth poderia acontecer se houvessem cem atendimentos, dos quais 10 pacientes tivessem que esperar 40 minutos para serem atendidos enquanto que os outros 90 pacientes tivessem que esperar apenas 10 minutos cada. Apesar do tempo médio ficar bem inferior ao limite de tempo de 30 minutos, ainda haveriam 10 pacientes insatisfeitos.

Figura 31 – Representação gráfica de um exemplo de alocação de recursos humanos ao longo do tempo de atendimento no ambiente hospitalar com e sem o uso do modelo EIHealth, onde no Hospital Atual têm-se  $M2 = 10$  atendentes e no Hospital Inteligente têm-se  $M2 = 8,75$  atendentes



Fonte: Elaborada pelo autor.

Com relação a quantidade de recursos humanos, espera-se que o modelo seja capaz de utilizar os profissionais de saúde existentes na unidade hospitalar de uma forma otimizada, de forma que a alocação fixa do primeiro cenário, com onze funcionários atuando 24 horas por dia, possam ser comparados com a alocação proposta pelo EIHealth, com a quantidade de

profissionais do hospital variando ao longo do dia conforme a demanda. Nesse contexto, espera-se que o modelo utilize a mesma quantidade de recursos humanos já utilizada pelo ambiente hospitalar, entretanto aceita-se o aumento da quantidade de profissionais atuando desde que o custo de atendimento seja reduzido. A Figura 31 apresenta graficamente uma representação da alocação de recursos humanos ao longo de um dia de atendimento na unidade hospitalar com e sem o uso da Elasticidade Preditiva Multinível de Recursos Humanos. O eixo  $x$  expressa o tempo, enquanto que o eixo  $y$  representa a alocação de atendentes em cada instante de tempo.

A terceira métrica a ser avaliada é o custo de atendimento no ambiente hospitalar, que leva em consideração as duas métricas apresentadas anteriormente. Dessa forma, o custo de atendimento em um intervalo de tempo pode ser descrito pela Equação 10, onde  $i$  representa o tempo inicial e  $f$  o tempo final,  $TE(i, f)$  representa o tempo médio de espera no intervalo de tempo  $i$  até  $f$ , e  $RH(i, f)$  representa a quantidade de recursos humanos alocados no intervalo de tempo  $i$  até  $f$ .

$$C(i, f) = TE(i, f) \cdot RH(i, f) \quad (10)$$

Dessa forma, mesmo se a quantidade média de recursos humanos no terceiro cenário aumentar durante o dia de atendimento na unidade hospitalar, se o tempo médio de espera diminuir, o custo de atendimento pode acabar sendo inferior ao do primeiro e segundo cenários. Essa métrica é uma adaptação da noção de custo de uma computação paralela de Wilkinson e Allen (2005), já adaptada para o conceito de elasticidade por Righi et al. (2016).

Por fim, a quarta métrica a ser avaliada é a quantidade média de pacientes aguardando atendimento na unidade hospitalar. Dessa forma, serão analisadas quantas pessoas estão dentro do sistema hospitalar, impactando nas filas de atendimento. Para essa métrica, será analisada a quantidade total de pessoas aguardando em todas as filas de atendimento, ou seja, a soma dos pacientes aguardando em cada uma das filas. Com relação a essa métrica, espera-se que o modelo seja capaz de diminuir a quantidade média de pessoas nas filas por atendimento do ambiente hospitalar.

A Tabela 9 apresenta todas as métricas para avaliação descritas anteriormente, relacionando os resultados esperados para o segundo e terceiro cenários, com o uso do ElHealth, quando comparado ao ambiente hospitalar atual, sem o modelo ElHealth.

Tabela 9 – Métricas para Avaliação e resultados esperados em cada um dos cenários propostos

Métrica	C1	C2 (Esperado)	C3 (Esperado)
<b>M1:</b> Tempo Máximo de Espera	Atual	Menor que no C1	Menor que no C2
<b>M2:</b> Quantidade Elástica de Recursos Humanos utilizados	11 por turno	11 por turno	11 ou mais por turno
<b>M3:</b> Custo de Atendimento	Atual	Menor que no C1	Menor que no C2
<b>M4:</b> Quantidade média de pacientes aguardando	Atual	Menor que no C1	Menor que no C2

Fonte: Elaborada pelo autor.




## 5.7 Metodologia de Testes para o Sistema RTLS

Além de testes a nível de software para verificar a eficácia do modelo EIHealth para o gerenciamento elástico de recursos humanos, também optou-se por realizar testes a nível de hardware. Como o modelo EIHealth baseia-se no uso da Internet das Coisas e um sistema RTLS para identificar a localização e movimentação de pacientes, bem como o tempo de permanência em cada ambiente e consequente o tempo despendido para atendimento, decidiu-se que seria interessante fazer a instalação do sistema RTLS em um ambiente real para testar sua capacidade de capturar a movimentação de pessoas.

Dentre as tecnologias estudadas para Internet das Coisas, optou-se pelo uso da tecnologia RFID para os testes do modelo. A escolha do RFID se baseia na sua capacidade de permitir identificação automática, evitando a existência do erro humano nos processos de identificação. Além disso, segundo Boulos e Berry (2012), para certas aplicações, o uso de soluções RTLS que incorporem tecnologias complementares como RFID, podem fornecer níveis de precisão e flexibilidade inatingíveis por qualquer tecnologia concorrente. O ambiente selecionado para instalação do equipamento RFID para realização dos testes foi o laboratório de Internet das Coisas e Aplicações Distribuídas, localizado na sala C01 416 do Programa de Pós-Graduação em Computação Aplicada (PPGCA) da Universidade do Vale do Rio dos Sinos.

Figura 32 – Leitor RFID Intermec IF2 instalado no laboratório de Internet das Coisas e Aplicações Distribuídas do PPGCA da Universidade do Vale do Rio dos Sinos onde em (A) a antena foi instalada acima da porta e em (B) a antena foi instalada ao lado da porta



Fonte: Elaborada pelo autor.

Para os testes do sistema RTLS, foi escolhido o uso do leitor RFID *Intermec IF2*<sup>1</sup>. A escolha desse leitor baseia-se no fato do mesmo trabalhar com até quatro antenas para leitura de *tags*,

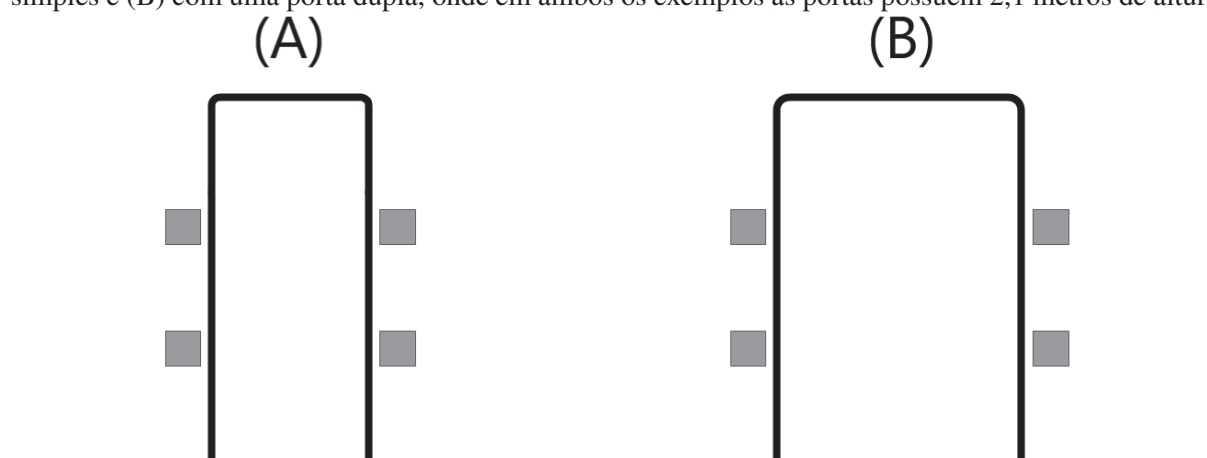
<sup>1</sup><https://www.honeywellaidc.com/products/rfid/fixed-readers/if2>



o que permite o aumento da área de captura com a instalação de diversas antenas. Além disso, ao contrário de leitores como o *Identix miniPad*<sup>2</sup> que possuem um raio de leitura de alguns centímetros, cada antena do leitor IF2 pode realizar leituras de *tags*-RFID localizadas até a alguns metros de distância. As *tags* utilizadas nos testes foram etiquetas adesivas EPC. Para os testes, o leitor IF2 foi instalado com apenas uma antena, em um primeiro momento localizada acima da porta de entrada do laboratório, e após foi remanejada para ao lado dessa mesma porta conforme pode ser visto na Figura 32.

O objetivo dos testes é identificar qual o raio de captura de um leitor RFID em um ambiente real, de forma a propor o melhor local para instalação do mesmo de forma a capturar a entrada de pessoas em ambientes físicos, tais como o hospital inteligente proposto nesse trabalho. Para tanto, serão medidas as distâncias máximas em que o leitor é capaz de captar o sinal da *tag* em todas as direções. Através dos valores encontrados, espera-se identificar se o uso de quatro antenas é o suficiente para cobrir a área de portas simples e também de portas duplas. A Figura 33 apresenta o conceito em uma porta simples e em uma porta dupla, mostrando a posição aproximada para instalação das antenas, que devem estar localizadas o mais próximo possível do marco da porta, e igualmente espaçadas com relação a altura da mesma.

Figura 33 – Instalação proposta das antenas do leitor Intermec IF2 em dois cenários: (A) com uma porta simples e (B) com uma porta dupla, onde em ambos os exemplos as portas possuem 2,1 metros de altura



Fonte: Elaborada pelo autor.

<sup>2</sup><https://www.identix.us.com/minipad>



## 6 RESULTADOS E DISCUSSÃO

A partir da metodologia de avaliação proposta para o modelo EIHealth, foram realizadas doze simulações do ambiente hospitalar proposto a fim de colher resultados para análise. Para cada cenário proposto, entre C1, C2 e C3, foi executada uma simulação para cada um dos padrões de carga, Constante, Crescente, Decrescente e Onda. A Tabela 10 apresenta as simulações realizadas para avaliação do modelo proposto. Nas Seções 6.2, 6.3, 6.4 e 6.5 serão analisadas cada umas das métricas de avaliação propostas e os resultados obtidos em todas as simulações realizadas.

Tabela 10 – Combinações possíveis de padrões de carga e cenários para simulação do modelo EIHealth

Cenário	Padrões de Carga			
	Constante	Crescente	Decrescente	Onda
C1	C1 e Constante	C1 e Crescente	C1 e Decrescente	C1 e Onda
C2	C2 e Constante	C2 e Crescente	C2 e Decrescente	C3 e Onda
C3	C3 e Constante	C3 e Crescente	C3 e Decrescente	C3 e Onda

Fonte: Elaborada pelo autor.

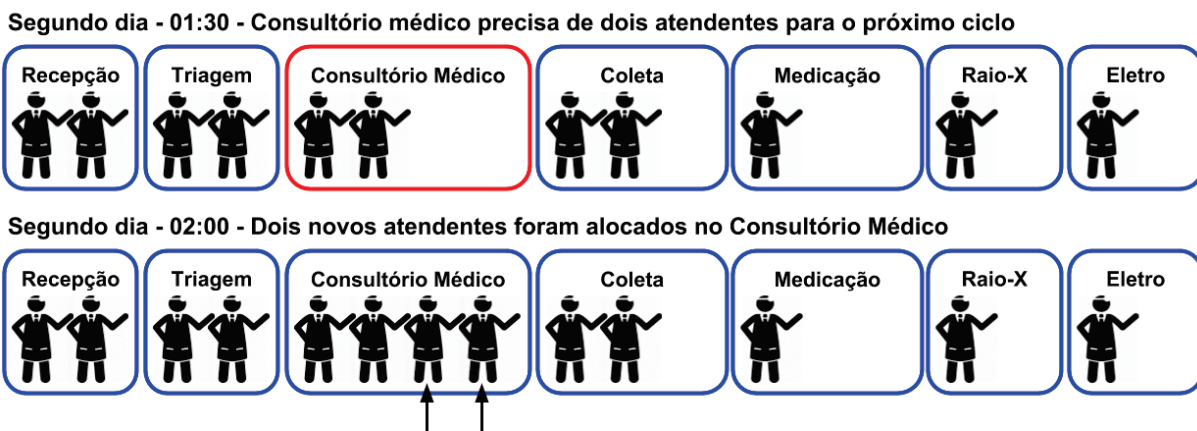
Além disso, a partir da metodologia de testes proposta para o sistema RTLS, foi instalado o equipamento para leitura RFID em um ambiente real e realizados sucessivos testes para definir a sua capacidade de captura de *tags* e identificar a capacidade do mesmo de captar a entrada de pessoas em ambientes físicos. A Seção 6.6 apresenta os resultados obtidos com os testes do sistema RTLS. Por fim, a Seção 6.7 apresenta uma discussão sobre os resultados encontrados durante a avaliação do modelo proposto.

### 6.1 Funcionamento do Modelo

A fim de mostrar o funcionamento do modelo proposto, resolveu-se apresentar um momento, dentre os cenários que foram simulados, em que o algoritmo solicitasse a alocação e a realocação de pessoas. Assim, por ser o padrão de carga com os maiores picos de quantidade média de recursos humanos em atendimento no cenário C3, o único com alocação de pessoas, definiu-se o uso do padrão Decrescente para uma amostra do processo de Elasticidade Preditiva Multinível de Recursos Humanos.

Um exemplo de funcionamento da elasticidade de recursos humanos pode ser identificado no segundo dia simulado às 01:30, onde haviam 2 atendentes alocados na recepção, dois na triagem, dois para o consultório médico, dois para exames de coleta, um para eletrocardiograma e um para medicação. O modelo preditivo identificou que no instante de tempo entre 02:00 e 02:30 haveriam 9,76 pacientes aguardando por atendimento no consultório médico. Com o tempo de atendimento médio previsto de 10,66 minutos para o mesmo período de tempo, identificou-se que haveria uma espera de até 52,02 minutos para todos os atendimentos. Como esse tempo supera o *Threshold Superior* de 30 minutos, a elasticidade a nível local aplicou a

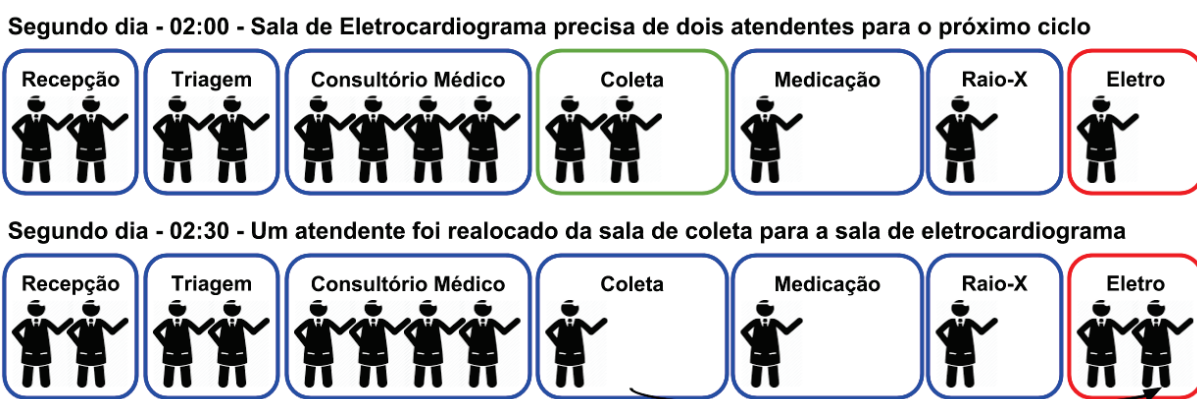
Figura 34 – Instante de tempo em que foi identificada a necessidade de alocação de dois novos médicos nos consultórios médicos



Fonte: Elaborada pelo autor.

equação de Speedup Elástico Proativo de Recursos Humanos para identificar a quantidade de atendentes necessários para atender a demanda de pacientes. Com o uso de três atendentes em paralelo, o algoritmo chegou em 34,68 minutos estimados de espera. Como esse valor ainda é superior ao limite máximo, foi reaplicada a equação com quatro atendentes. Já com o uso de 4 recursos humanos, a espera cairia para 26,01 minutos, dentro dos limites estabelecidos. Dessa forma, o algoritmo a nível local solicitou dois novos atendentes para essa sala. Como nos demais ambientes não existem médicos prestando atendimento, não foi possível a realocação de recursos humanos, sendo necessária a alocação de dois novos profissionais. Nesse contexto, dois atendentes foram alocados na sala, conforme ilustrado na Figura 34.

Figura 35 – Instante de tempo em que foi identificada a necessidade de realocação de um enfermeiro da sala de medicação para a sala de eletrocardiograma



Fonte: Elaborada pelo autor.


Já um exemplo de realocação pode ser vista no ciclo seguinte de monitoramento, quando às 02:00 o modelo preditivo identificou que entre 02:30 e 03:00 haveriam 1,02 pacientes aguardando atendimento na sala de eletrocardiograma. Com o tempo médio previsto de 46,6 minutos para o exame, identificou-se que haveria uma espera de 47,6 minutos nessa sala. Como

esse tempo supera o *Threshold* Superior de 30 minutos, a elasticidade a nível local aplicou a equação de Speedup Elástico Proativo de Recursos Humanos para identificar a quantidade de atendentes necessários para atender a demanda de pacientes. Com o uso de dois atendentes em paralelo, o algoritmo chegou em 23,8 minutos de espera. Dessa forma, o algoritmo a nível local solicitou um novo atendente para essa sala. Nesse mesmo instante de tempo, a sala de exames de coleta previa a entrada de apenas 1,39 pacientes e um tempo médio de atendimento de apenas 9 minutos, o que representava 6,27 minutos estimados de espera. Como esse tempo é inferior ao *Threshold* Inferior de 9 minutos, a elasticidade a nível local aplicou a equação de Speedup Elástico Proativo de Recursos Humanos para identificar a quantidade de atendentes necessários para atender a demanda de pacientes. Com o uso de um único atendente, o algoritmo calculou apenas 12,55 minutos estimados de espera. Como esse tempo fica entre os dois *thresholds* estabelecidos, o algoritmo a nível local liberou um atendente da sala de exames de coleta, que foi realocado para a sala de eletrocardiograma, conforme ilustrado na Figura 35.

## 6.2 Métrica M1: Tempo Máximo de Espera

O primeiro parâmetro a ser avaliado é o tempo máximo de espera por atendimento nas filas do ambiente hospitalar proposto. Para a comparação e a análise dessa métrica, a cada cenário de testes, o maior tempo registrado de espera a cada hora foi medido e armazenado. O principal objetivo dessa métrica é verificar se através da Elasticidade Preditiva Multinível de Recursos Humanos, parcial (com realocação apenas) ou completa (com alocação, realocação e desalocação), é possível diminuir o tempo de espera por atendimento de pacientes aguardando em um ambiente hospitalar. Além disso, espera-se verificar se a maior espera identificada nas observações e a média das maiores esperas é inferior ao TS de 30 minutos.

Figura 36 – Tempo máximo de espera registrado no hospital com os diferentes padrões de carga para o Cenário C1, sem o uso da Elasticidade Preditiva Multinível de Recursos Humanos




Fonte: Elaborada pelo autor.

A Figura 36 apresenta o maior tempo de espera registrado nas diversas filas por atendimento

do hospital simulado no cenário C1, para cada uma das cargas de trabalho propostas ao longo do período simulado de uma semana. Como pôde ser observado, ao longo do tempo, independente do padrão de carga utilizado, houve um aumento gradativo do tempo máximo de espera. A cada período de 24 horas, foi identificada uma espécie de repetição do padrão de tempo de espera, com relação ao padrão de carga utilizado, porém com um crescimento linear das filas. De acordo com o gráfico é possível notar que os maiores tempos de espera foram observados nos padrões de carga Crescente e Decrescente, os menores tempos de espera ficaram na carga Constante e o tempo de espera na carga em Onda manteve-se aproximadamente no meio entre os outros padrões de carga. O principal gargalo no cenário C1 foi o tempo de espera pela Triagem. O maior tempo máximo registrado de espera foi com o uso do padrão de carga Decrescente, com 880 minutos.

Figura 37 – Tempo máximo de espera registrado no hospital com os diferentes padrões de carga para o Cenário C2, com o uso parcial da Elasticidade Preditiva Multinível de Recursos Humanos



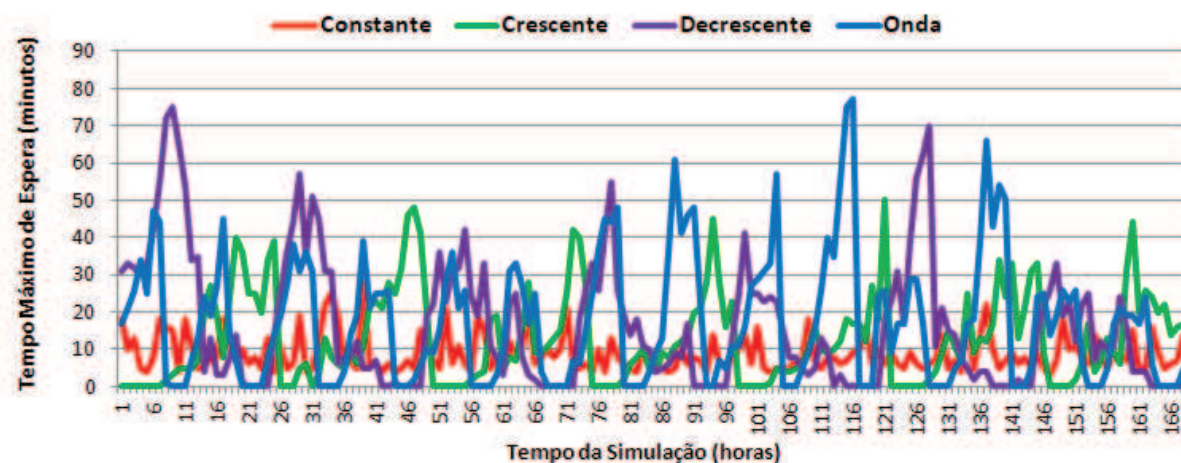
Fonte: Elaborada pelo autor.

A Figura 37 apresenta o maior tempo de espera registrado nas diversas filas por atendimento do hospital simulado no cenário C2, para cada uma das cargas de trabalho propostas ao longo do período simulado de uma semana. Como pôde ser observado, ao longo do tempo, independente do padrão de carga, a espera se mantém entre um intervalo mínimo e máximo constantes, diferentes para carga de trabalho, ao contrário de C1, onde houve um aumento gradativo da espera ao longo do tempo. Da mesma forma que aconteceu em C1, para todas as cargas de trabalho, a cada período de 24 horas foi identificada uma repetição do padrão do tempo de espera. O maior tempo máximo registrado de espera foi com o uso do padrão de carga Decrescente, com 184 minutos. Comparando-se os resultados de C2 com os resultados registrados em C1, pode-se identificar uma queda significativa no tempo de espera entre os dois cenários. Isso ocorreu pois o principal gargalo encontrado em C1 pode ser resolvido com a realocação de pessoas. Dessa forma, em C2 o tempo de espera nas filas para atendimento de Triagem acabou diminuindo. Entretanto, apesar da diminuição na espera, o tempo de atendimento ainda possui alguns picos expressivos ao longo do tempo. Isso ocorreu em função de um novo principal gargalo para o



cenário C2: o tempo de espera pela Consulta Médica.

Figura 38 – Tempo máximo de espera registrado no hospital com os diferentes padrões de carga para o Cenário C3, com o uso completo da Elasticidade Preditiva Multinível de Recursos Humanos

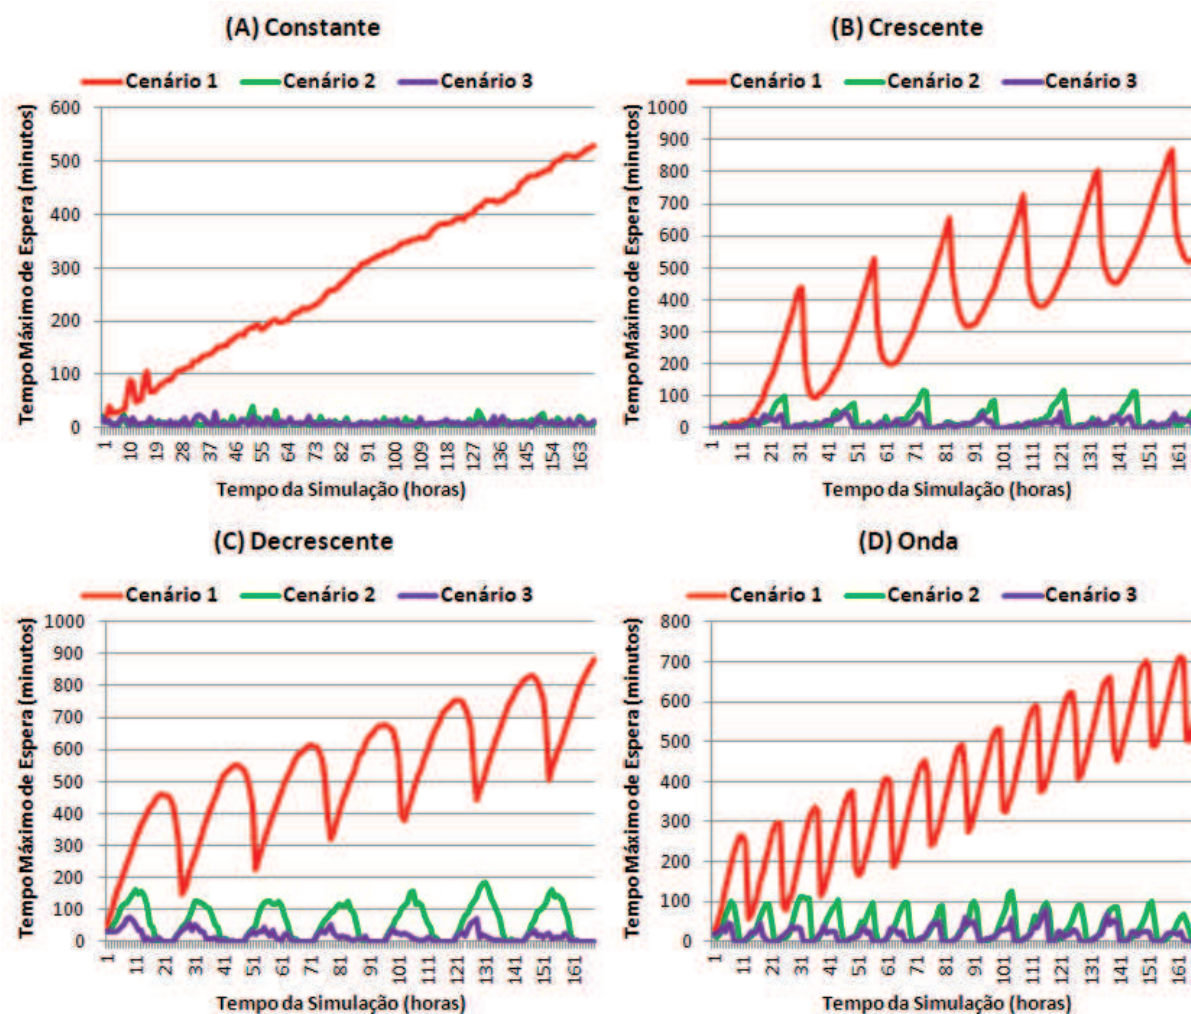


Fonte: Elaborada pelo autor.

Por fim, a Figura 38 apresenta o tempo máximo de espera registrado nas diversas filas por atendimento do hospital simulado no cenário C3, para cada uma das cargas de trabalho propostas ao longo do período simulado de uma semana. Pôde-se observar que da mesma forma que ocorreu em C2, e ao contrário de C1, em C3 o tempo de espera se manteve dentro de limites mínimos e máximos constantes ao longo do tempo. Da mesma forma que aconteceu em C1 e em C2, para todas as cargas de trabalho, a cada período de 24 horas foi identificada uma repetição do padrão do tempo de espera. O maior tempo máximo registrado de espera foi com o uso do padrão de carga Onda, com 77 minutos. Comparando-se com os resultados registrados em C2, pode-se identificar uma queda significativa no tempo de espera entre os dois cenários. Isso ocorreu, pois os dois principais gargalos identificados nos cenários anteriores foram resolvidos graças a alocação elástica de recursos humanos. Assim, no cenário C3, não houve um principal gargalo de tempo de espera ao contrário de C1 e C2. Após uma análise minuciosa dos dados, pode-se identificar que em C3 para a recepção e as áreas de triagem, consulta médica e exames de coleta, em nenhum momento foi registrada espera superior a 30 minutos, independente do padrão de carga utilizado. Já para as áreas de medicação, raio-x e eletrocardiograma, com o uso dos padrões de carga Crescente, Decrescente e Onda houveram alguns instantes em que esse limite foi excedido. Assim, o único cenário de testes em que para nenhuma sala do ambiente hospitalar foi registrada espera superior a 30 minutos foi C3 com o uso do padrão de carga Constante.

A Figura 39 apresenta o tempo máximo de espera registrado para cada um dos cenários propostos com relação ao padrão de carga utilizado ao longo do período simulado de uma semana. Conforme já analisado nos gráficos anteriores, é possível perceber uma queda significativa no tempo máximo de espera entre os cenários C1 e C2 e logo após, uma segunda queda quando comparamos os cenários C2 e C3, independente do padrão de carga utilizado durante os testes.

Figura 39 – Tempo máximo de espera registrado no hospital para cada um dos cenários propostos utilizando os padrões de carga (A) Constante, (B) Crescente, (C) Decrescente e (D) Onda



Fonte: Elaborada pelo autor.

A Tabela 11 apresenta a média dos tempos máximos de esperas identificados, juntamente com o maior tempo máximo de espera identificado, em cada um dos cenários propostos para cada padrão de carga.

Tabela 11 – Maior tempo de espera e média dos maiores tempos de espera registrados em cada padrão de carga nos cenários propostos

Cenário	Métrica	Tempo de Espera (em minutos)			
		Constante	Crescente	Decrescente	Onda
C1	Tempo Médio	279,27	388,81	531,01	384,18
	Maior Tempo	529	868	880	711
C2	Tempo Médio	8,97	25,32	61,11	39,15
	Maior Tempo	39	117	184	126
C3	Tempo Médio	8,91	12,88	16,22	17,21
	Maior Tempo	28	50	75	77

Fonte: Elaborada pelo autor.



Através dos dados levantados é possível identificar uma redução significativa no tempo de espera no ambiente hospitalar com o uso da Elasticidade Preditiva Multinível de Recursos Humanos quando se compara com o hospital sem o uso da elasticidade. A Tabela 12 apresenta a porcentagem da diminuição dos tempos de espera entre os cenários propostos em cada um dos padrões de carga utilizados na simulação.

Tabela 12 – Diminuição do tempo de espera em cada padrão de carga entre os cenários propostos

Carga	Cenário	Diminuição do Tempo de Espera (em %)			
		Tempo Médio		Maior Tempo	
		C2	C3	C2	C3
Constante	C1	96,8%	96,8%	92,6%	94,7%
	C2	-	0,7%	-	28,2%
Crescente	C1	93,5%	96,7%	86,5%	94,2%
	C2	-	49,1%	-	57,3%
Decrescente	C1	88,5%	96,9%	79,1%	91,5%
	C2	-	73,5%	-	59,2%
Onda	C1	89,9%	95,5%	82,3%	89,2%
	C2	-	56,0%	-	38,9%

Fonte: Elaborada pelo autor.


A maior diminuição na média do tempo máximo de espera entre os cenários C1 e C3 ocorreu com o uso da carga Decrescente, com uma queda de 96,9%, e a menor diminuição ocorreu com o uso da carga Onda, com uma queda de 95,5% na média do tempo máximo de espera. Já com relação ao maior tempo máximo de espera identificado, a maior diminuição entre os cenários C1 e C3 ocorreu com o uso da carga Constante, com uma queda de 94,7%, e a menor diminuição ocorreu com o uso da carga Onda, com uma queda de 89,2%. A diminuição do tempo médio entre os cenários C1 e C2 varia entre 88,5% e 96,8%, e a diminuição do maior tempo entre C1 e C2 varia entre 79,1% e 92,6%. Entre os cenários C2 e C3, a diminuição do maior tempo máximo de espera varia entre 28,2%, com o uso da carga Constante, e 59,2%, com o uso da carga Decrescente. Já a diminuição do tempo médio entre os cenários C2 e C3 varia entre 0,7%, com a carga Constante, e 73,5%, com a carga Decrescente. Observa-se que o uso da elasticidade com alocação, realocação e desalocação possui um melhor desempenho para redução do tempo de espera do que a elasticidade apenas com realocação, independente do padrão de carga de pacientes.

### 6.3 Métrica M2: Quantidade Elástica de Recursos Humanos utilizados

O segundo parâmetro a ser avaliado é a quantidade elástica de recursos humanos utilizados para prover o atendimento aos pacientes no ambiente hospitalar proposto. Para comparação e análise dessa métrica, a quantidade média de recursos humanos alocados no hospital a cada hora foi calculada e armazenada. O principal objetivo dessa métrica é verificar qual foi o aumento do uso de recursos humanos com o uso da Elasticidade Preditiva Multinível de Recursos Humanos

completa (com alocação, realocação e desalocação). O aumento da quantidade de pessoas em atendimento não representa um problema ao ambiente hospitalar, desde que a métrica M3, que será analisada na sequência, apresente uma redução.

Figura 40 – Tempo máximo de espera registrado no hospital com os diferentes padrões de carga para o Cenário C3, com o uso completo da Elasticidade Preditiva Multinível de Recursos Humanos



Fonte: Elaborada pelo autor.

A Figura 40 apresenta a quantidade elástica média de recursos humanos utilizados para atendimento no hospital para o cenário C3, o único cenário em que a quantidade de funcionários acaba por apresentar alguma variação. Como pôde ser visto, a quantidade média de recursos humanos acabou variando entre 11 e 14 por hora. Apesar de existirem momentos com a alocação de até 14 profissionais de saúde em atendimento, a média por hora de profissionais em atendimento acaba por ser ligeiramente inferior em função do tempo que leva para um funcionário ser alocado ou realocado no sistema. A Tabela 13 apresenta a quantidade elástica de recursos humanos utilizados em cada padrão de carga nos cenários propostos.

Tabela 13 – Quantidade elástica de Recursos Humanos utilizados em cada padrão de carga nos cenários propostos

Cenário	Métrica	Quantidade elástica de Recursos Humanos			
		Constante	Crescente	Decrescente	Onda
C1	-	11	11	11	11
C2	-	11	11	11	11
C3	Quantidade média	11,13	11,36	12,16	11,68
	Maior quantidade	12	14	14	14


Fonte: Elaborada pelo autor.

#### 6.4 Métrica M3: Custo de Atendimento

O terceiro parâmetro a ser avaliado é o custo de atendimento no ambiente hospitalar, que leva em consideração o tempo de espera e a quantidade de recursos humanos em atendimento.

Para comparação e análise da métrica, o custo de atendimento foi calculado utilizando o tempo médio de espera e a quantidade média de recursos humanos a cada hora da simulação. O principal objetivo dessa métrica é verificar se através da Elasticidade Preditiva Multinível de Recursos Humanos, parcial (com realocação apenas) ou completa (com alocação, realocação e desalocação), é possível diminuir o custo do atendimento de um ambiente hospitalar.

Figura 41 – Custo de atendimento por hora no hospital com os diferentes padrões de carga para o Cenário C1, sem o uso da Elasticidade Preditiva Multinível de Recursos Humanos




Fonte: Elaborada pelo autor.

A Figura 41 apresenta o custo de atendimento calculado para o hospital simulado no cenário C1, para cada uma das cargas de trabalho propostas ao longo do período simulado de uma semana. Como pôde ser observado, ao longo do tempo, independente do padrão de carga utilizado, houve um aumento gradativo do custo de atendimento. A cada período de 24 horas, foi identificada uma espécie de repetição do padrão de custo, com relação ao padrão de carga utilizado. Isto se deve a relação com o alto tempo de espera identificado na métrica M1 para o mesmo cenário. De acordo com o gráfico é possível notar que os maiores custos foram observados nos padrões de carga Crescente e Decrescente, o menor custo ficou na carga Constante, e o custo da carga Onda manteve-se entre eles. O maior custo de atendimento calculado foi com o uso do padrão de carga Decrescente, onde o custo médio foi de 527,03.

A Figura 42 apresenta o custo de atendimento calculado para o hospital simulado no cenário C2, para cada uma das cargas de trabalho propostas ao longo do período simulado de uma semana. Como pôde ser observado, ao longo do tempo, independente do padrão de carga, o custo se manteve entre um intervalo mínimo e máximo aproximadamente constantes, diferentes para cada carga de trabalho, ao contrário de C1, onde houve um aumento gradativo do custo ao longo do tempo. Da mesma forma que aconteceu em C1, para todas as cargas, a cada período de 24 horas foi identificada uma repetição do padrão de custo. Comparando-se com os resultados registrados em C1, pode-se identificar uma queda significativa no custo de atendimento entre os dois cenários. O maior custo de atendimento calculado foi com o uso do padrão de carga Decrescente, onde o custo médio foi de 117,81, menos do que um quarto do maior custo


Figura 42 – Custo de atendimento por hora no hospital com os diferentes padrões de carga para o Cenário C2, com o uso parcial da Elasticidade Preditiva Multinível de Recursos Humanos



Fonte: Elaborada pelo autor.

observado em C1.

Figura 43 – Custo de atendimento por hora no hospital com os diferentes padrões de carga para o Cenário C3, com o uso completo da Elasticidade Preditiva Multinível de Recursos Humanos




Fonte: Elaborada pelo autor.

Por fim, a Figura 43 apresenta o custo de atendimento calculado para o hospital simulado no cenário C3, para cada uma das cargas de trabalho propostas ao longo do período simulado de uma semana. Pôde-se observar que ao contrário de C2, que o custo se manteve aproximadamente constante ao longo do tempo, e C1, que a custo aumentou gradativamente, em C3, houve uma maior variação do custo para todos os padrões de carga. A principal diferença entre os cenários está no fato de que em C2 o custo total foi superior ao calculado para C3. Para esse cenário, o maior custo de atendimento calculado foi com o uso do padrão de carga Onda, onde o custo foi de 29,82, aproximadamente um quarto do maior custo observado em C2.

A Figura 44 apresenta o custo calculado para cada um dos cenários propostos com relação ao

Figura 44 – Custo de atendimento por hora calculado no hospital para cada um dos cenários propostos utilizando os padrões de carga (A) Constante, (B) Crescente, (C) Decrescente e (D) Onda



Fonte: Elaborada pelo autor.

padrão de carga utilizado ao longo do período simulado de uma semana. Conforme já analisado nos gráficos anteriores, é possível perceber uma queda significativa no custo entre os cenários C1 e C2 e logo após, uma segunda queda entre os cenários C2 e C3, independente do padrão de carga utilizado. A Tabela 14 apresenta os custos médios identificados em cada um dos cenários propostos para cada padrão de carga.

Tabela 14 – Custo médio de atendimento em cada padrão de carga nos cenários propostos

Cenário	Custo Médio de Atendimento			
	Constante	Crescente	Decrescente	Onda
C1	280,00	383,13	527,03	376,67
C2	13,27	46,79	117,81	73,87
C3	13,31	21,07	27,18	29,82

Fonte: Elaborada pelo autor.

Através dos dados levantados é possível identificar uma redução significativa no custo de atendimento no ambiente hospitalar com o uso da Elasticidade Preditiva Multinível de Recursos



Humanos quando comparada com o hospital sem o uso da elasticidade. A Tabela 15 apresenta a porcentagem da diminuição do custo de atendimento entre os cenários propostos em cada um dos padrões de carga utilizados na simulação.

Tabela 15 – Diminuição do custo total de atendimento para cada padrão de carga entre os cenários propostos

Carga	Cenário	Diminuição do Custo de Atendimento (em %)	
		C2	C3
Constante	C1	95,3%	95,2%
	C2	-	-0,3%*
Crescente	C1	87,8%	94,5%
	C2	-	55,0%
Decrescente	C1	77,6%	94,8%
	C2	-	76,9%
Onda	C1	80,4%	92,1%
	C2	-	59,6%

\* Para este cenário houve aumento do custo de atendimento

Fonte: Elaborada pelo autor.


A maior diminuição no custo de atendimento entre os cenários C1 e C3 ocorreu com o uso da carga Constante, com uma queda de 95,2%, e a menor diminuição ocorreu com o uso da carga Onda, com uma queda de 92,1%. A diminuição do custo de atendimento entre os cenários C1 e C2 varia entre 80,4%, com carga em Onda e 95,3% para carga Constante. Entre os cenários C2 e C3, a diminuição do custo varia entre 55%, com o uso da carga Crescente, e 76,9%, com o uso da carga Decrescente. Assim, o padrão de carga Constante apresentou o melhor desempenho na diminuição de custo entre os cenários C1 e C3 e o padrão de carga Decrescente apresentou a maior diminuição de custo entre os cenários C2 e C3. Entretanto para o padrão de carga Constante entre C2 e C3 houve um aumento do custo total de atendimento de 0,3%. Dessa forma, observa-se que o uso da elasticidade com alocação, realocação e desalocação possui um melhor desempenho para redução do custo de atendimento do que a elasticidade apenas com realocação. A única exceção é a carga Constante que entre o cenário C1 e C2 obteve uma redução de custo de 95,3% apenas com a realocação, acima das reduções com uso de alocação, realocação e desalocação de todos os padrões de carga.

## 6.5 Métrica M4: Quantidade Média de Pacientes aguardando por atendimento

O quarto e último parâmetro a ser avaliado é a quantidade média de pacientes aguardando por atendimento no ambiente hospitalar. O principal objetivo dessa métrica é verificar se através da Elasticidade Preditiva Multinível de Recursos Humanos, parcial (com realocação apenas) ou completa (com alocação, realocação e desalocação), é possível diminuir quantidade média de pessoas nas filas de espera de um ambiente hospitalar.

A Figura 45 apresenta a quantidade média de pacientes aguardando no hospital simulado no


Figura 45 – Quantidade média de pacientes no hospital com os diferentes padrões de carga para o Cenário C1, sem o uso da Elasticidade Preditiva Multinível de Recursos Humanos



Fonte: Elaborada pelo autor.

cenário C1, para cada uma das cargas de trabalho propostas ao longo do período simulado de uma semana. Como pôde ser observado, ao longo do tempo, independente do padrão de carga utilizado, houve um aumento gradativo da quantidade média de pessoas aguardando, dentro de seus próprios padrões de variação do tamanho das filas a cada período de 24 horas. Isto se deve a relação com o alto tempo de espera para a sala de Triagem identificado na métrica M1 para o mesmo cenário, que ocasionou grandes filas. De acordo com o gráfico é possível notar que as maiores quantidades médias de pacientes aguardando foram observados nos padrões de carga Crescente e Decrescente, e as menores quantidades médias ficaram na carga Constante e a carga Onda manteve-se entre eles. A maior quantidade média de pacientes identificada foi com o uso do padrão de carga Crescente, onde haviam 114,57 pacientes em um mesmo intervalo de tempo.

Figura 46 – Quantidade média de pacientes no hospital com os diferentes padrões de carga para o Cenário C2, com o uso parcial da Elasticidade Preditiva Multinível de Recursos Humanos




Fonte: Elaborada pelo autor.



A Figura 46 apresenta a quantidade média de pacientes aguardando no hospital simulado no cenário C2, para cada uma das cargas de trabalho propostas ao longo do período simulado de uma semana. Pode-se observar que, ao longo do tempo, independente do padrão de carga, a quantidade média de pessoas aguardando se manteve entre um intervalo mínimo e máximo aproximadamente constantes, ao contrário de C1, onde houve um aumento gradativo ao longo do tempo simulado. Assim como em C1, a cada período de 24 horas, observou-se uma repetição no ciclo de pessoas aguardando. Comparando-se com os resultados registrados em C1, pode-se identificar uma queda significativa na quantidade média de pessoas nas filas entre os dois cenários. A maior quantidade média de pacientes no ambiente hospitalar foi com o uso do padrão de carga Decrescente, onde haviam 25,87 pacientes em um mesmo intervalo de hora.

Figura 47 – Quantidade média de pacientes no hospital com os diferentes padrões de carga para o Cenário C3, com o uso completo da Elasticidade Preditiva Multinível de Recursos Humanos

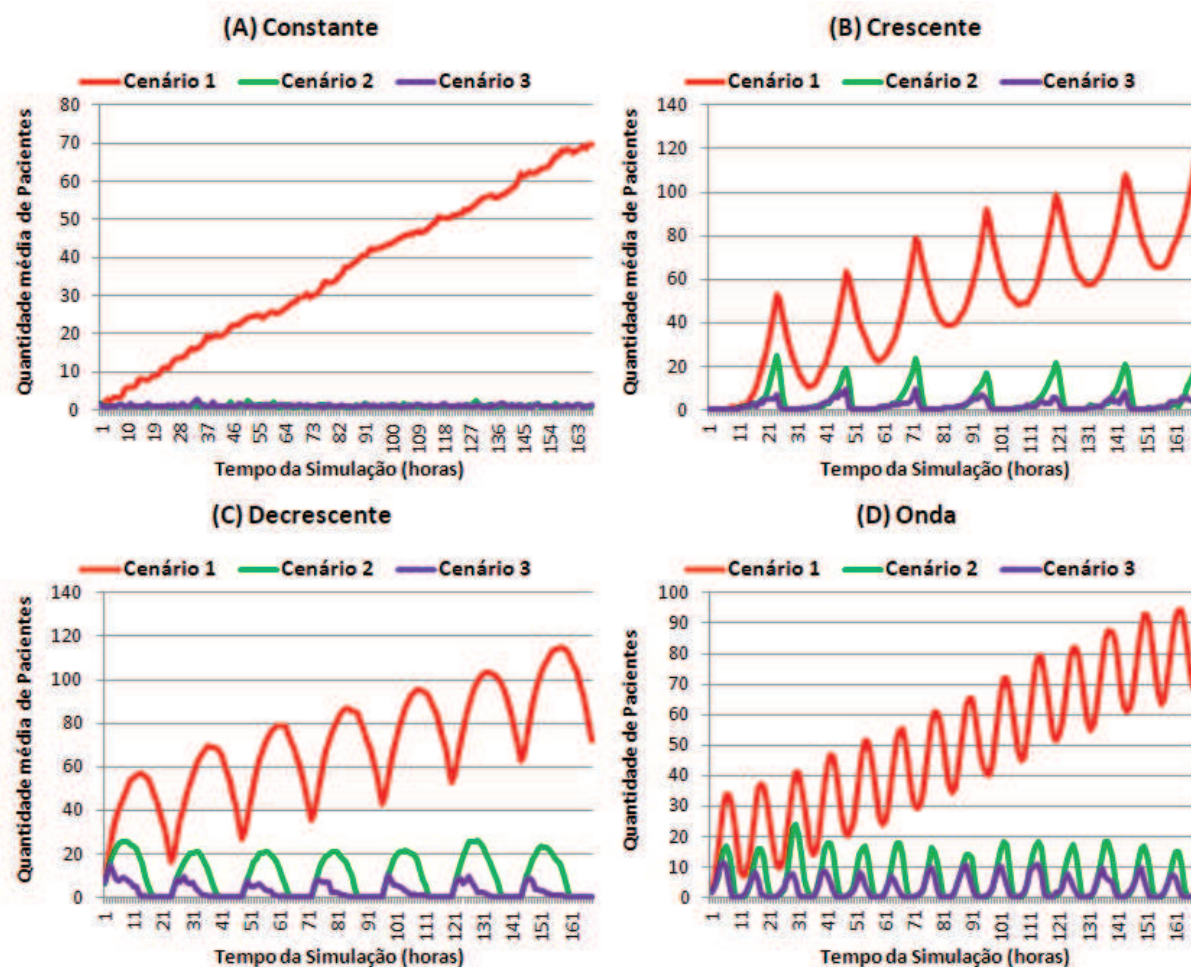


Fonte: Elaborada pelo autor.

Por fim, a Figura 47 apresenta a quantidade média de pacientes aguardando no hospital simulado no cenário C3, para cada uma das cargas de trabalho propostas ao longo do período simulado de uma semana. Foi possível observar que para as cargas Decrescente e Onda, houve uma diminuição do limite superior do padrão nos primeiros ciclos de 24 horas da semana simulada. Já para as cargas Constante e Crescente, a quantidade média de pessoas manteve-se entre limites mínimo e máximos constantes ao longo de todo o período. A maior quantidade média de pacientes identificada foi com o uso do padrão de carga Decrescente, com a média de 14,57 pessoas aguardando por atendimento.

A Figura 48 apresenta a quantidade média pacientes para cada um dos cenários propostos com relação ao padrão de carga utilizado ao longo do período simulado de uma semana. Conforme já analisado nos gráficos anteriores, é possível perceber uma queda significativa na quantidade de pessoas entre os cenários C1 e C2 e logo após, uma segunda queda entre os cenários C2 e C3, independente do padrão de carga utilizado. A Tabela 16 apresenta a quantidade média de pacientes observada em cada um dos cenários propostos para cada padrão de carga.

Figura 48 – Quantidade média de pacientes no hospital para cada um dos cenários propostos utilizando os padrões de carga (A) Constante, (B) Crescente, (C) Decrescente e (D) Onda



Fonte: Elaborada pelo autor.

Tabela 16 – Quantidade média de pessoas aguardando em um mesmo intervalo de tempo em cada padrão de carga nos cenários propostos

Cenário	Quantidade Média de Pacientes Aguardando			
	Constante	Crescente	Decrescente	Onda
C1	36,40	50,67	70,08	49,58
C2	1	4,46	10,34	6,92
C3	1	2,04	2,65	3,13

Fonte: Elaborada pelo autor.

Através dos dados levantados é possível identificar uma redução significativa na quantidade de pacientes aguardando por atendimento na unidade hospitalar com o uso da Elasticidade Preditiva Multinível de Recursos Humanos quando se compara com o hospital sem o uso da elasticidade. A Tabela 17 apresenta a porcentagem da diminuição da quantidade média de pacientes entre os cenários propostos em cada um dos padrões de carga utilizados na simulação.

A maior diminuição na métrica M4 entre os cenários C1 e C3 ocorreu com o uso da carga Constante, com uma queda de 97,3%, e a menor diminuição ocorreu com o uso da carga Onda,

Tabela 17 – Diminuição da quantidade média de pacientes aguardando para cada padrão de carga entre os cenários propostos

Carga	Cenário	Diminuição na quantidade média de pacientes	
		C2	C3
Constante	C1	97,3%	97,3%
	C2	-	0,0%
Crescente	C1	91,2%	96,0%
	C2	-	54,3%
Decrescente	C1	85,2%	96,2%
	C2	-	74,4%
Onda	C1	86,0%	93,7%
	C2	-	54,8%

Fonte: Elaborada pelo autor.

com uma queda de 93,7%. A diminuição da quantidade média de pacientes entre os cenários C1 e C2 varia entre 85,2%, para carga Crescente e 97,3%, para carga Constante. Entre os cenários C2 e C3, a diminuição da quantidade média de pacientes varia entre 0,0%, com o uso da carga Constante, e 74,4%, com o uso da carga Decrescente. Assim, o padrão de carga Constante apresentou o melhor desempenho na diminuição de custo entre os cenários C1 e C3 e o padrão de carga Decrescente apresentou a maior diminuição de custo entre os cenários C2 e C3. É possível observar que o uso da elasticidade com alocação, realocação e desalocação possui um melhor desempenho para redução do custo de atendimento do que a elasticidade apenas com realocação para os padrões de carga Crescente, Decrescente e Onda. Já para o padrão Constante, não houve diminuição da média de pacientes entre os cenários C2 e C3.


## 6.6 Testes do Sistema RTLS

Baseado na metodologia de testes proposta para o sistema RTLS, o primeiro teste a ser executado foi verificar se com uma antena localizada acima de uma porta, seria possível identificar a movimentação de pessoas. Notou-se para esse cenário que o leitor foi capaz de captar uma *tag* entrando na sala em toda a largura da porta, entretanto não em toda a sua altura. Em função disso, o mesmo teste foi executado com a antena remanejada para a lateral da porta, onde os resultados foram mais satisfatórios, uma vez que a *tag* pode ser capturada em quase toda a altura da porta. Com a antena do leitor localizada dessa forma, pode-se notar que a *tag* só é lida ao adentrar a na sala. Se uma pessoa ficasse parada na entrada, mas não passasse pelo arco, não seria capturada pelo leitor. Dessa forma, apenas ao adentrar na sala que o leitor identificaria a pessoa. Isto ocorreu pois na parte traseira da antena existe uma chapa de material que impede a transmissão do sinal.

Para então identificar a localização ideal para cobrir todo e qualquer ponto de qualquer porta onde fosse instalada, foram feitos novos testes para identificar qual a área em torno da antena capaz de captar *tags*-RFID. Para tanto, a antena foi instalada em um local a aproximadamente

1,1 metro de altura. Com base nos testes, pode-se notar que lateralmente o limite de captura da antena é em torno de 80 centímetros. Já diagonalmente, esse limite aumenta para em torno de 90 centímetros, o que indica que o raio de sinal não é circular. A Figura 49 apresenta o raio estimado de sinal para a antena.


Figura 49 – Área de leitura de *tags*-RFID em torno da antena do leitor Intermecc IF2



Fonte: Elaborada pelo autor.

A área de captura frontal da antena provou-se ser extremamente superior quando comparado à área lateral. Nos testes executados, pode-se notar que em linha reta é possível identificar com precisão uma *tag* localizada até 4,2 metros de distância da antena. A partir de 70 centímetros da antena, o raio de captura chega ao chão e se estende até 3,7 metros de distância. A Figura 50 apresenta o raio frontal estimado de sinal para a antena.


Figura 50 – Área de leitura frontal de *tags*-RFID da antena do leitor Intermecc IF2



Fonte: Elaborada pelo autor.

Assim sendo, propõe-se para a melhor precisão de captura a instalação de quatro antenas, o limite máximo disponível para o leitor IF2, em torno da porta ao qual se deseja registrar a passagem de pessoas. As antenas devem estar localizadas o mais próximo possível do marco da porta, e igualmente espaçadas com relação a altura da mesma, conforme proposto na Figura 33. Utilizando-se o raio de captura medido anteriormente, pode-se estimar o raio de cobertura para uma porta simples e em uma porta dupla, utilizando as quatro antenas em conjunto, conforme pode ser visto na Figura 51.

Figura 51 – Instalação proposta das antenas do leitor Intermec IF2 em dois cenários: (A) com uma porta simples e (B) com uma porta dupla, onde em ambos os exemplos as portas possuem 2,1 metros de altura



Fonte: Elaborada pelo autor.

Conforme pode ser visto na Figura 51, com o uso das quatro antenas em torno de uma porta simples, não existem pontos em que as mesmas não são capazes de captar uma *tag*, tornando a alocação das mesmas ideal a esse cenário. Já para o uso em porta duplas, existem alguns pontos em que as mesmas não são capazes de ler *tags*, entretanto, como mostrado na Figura 50, conforme o paciente for adentrando o ambiente, o ponto cego de leitura vai diminuindo gradativamente, fazendo com que o mesmo seja identificado.

## 6.7 Discussão

Com base nas métricas estabelecidas, pôde-se notar que o modelo EIHealth foi capaz de melhorar o desempenho do ambiente hospitalar simulado em todos os padrões de carga utilizados. A Tabela 18 apresenta todos os resultados encontrados em cada uma das quatro métricas de avaliação propostas. Conforme proposto na metodologia de avaliação, esperava-se que os resultados para as métricas M1, M2 e M4 apresentassem uma diminuição gradativa entre os cenários C1, C2 e C3, e isso de fato ocorreu, cumprindo os objetivos para essas métricas. Para a métrica M2, esperava-se um aumento no resultado entre os cenários C2 e C3, e o modelo mais uma vez foi capaz de cumprir o objetivo estabelecido. Dessa forma, os resultados esperados na metodologia de avaliação foram alcançados através do uso do modelo EIHealth no ambiente hospitalar proposto.



Tabela 18 – Métricas para avaliação e resultados encontrados em cada um dos cenários propostos, utilizando os padrões de carga Constante, Crescente, Decrescente e Onda

Carga	Cenário	M1 (em minutos)		M2	M3	M4
		Médio	Maior			
Constante	C1	279,27	529	11	280,00	36,40
	C2	8,97	39	11	13,27	1
	C3	8,91	28	11,13	13,31	1
Crescente	C1	388,81	868	11	383,13	50,67
	C2	25,32	117	11	46,79	4,46
	C3	12,88	50	11,36	21,07	2,04
Decrescente	C1	531,01	880	11	527,03	70,08
	C2	61,11	184	11	117,81	10,34
	C3	16,22	75	12,16	27,18	2,65
Onda	C1	384,18	711	11	376,67	49,58
	C2	39,15	126	11	73,87	6,92
	C3	17,21	77	11,68	29,82	3,13

Fonte: Elaborada pelo autor.

Para a métrica de tempo máximo de espera, haviam dois objetivos: a diminuição do tempo e o enquadramento do mesmo dentro do limite superior de 30 minutos estabelecido. Conforme já mostrado, o modelo EIHealth foi capaz de diminuir significativamente o tempo de espera para o ambiente hospitalar proposto. Entretanto, apesar de a média dos tempos máximos de espera para o cenário C3 estarem dentro do limite estabelecido, variando entre 8,91 minutos com a carga Constante e 17,21 com a carga Onda, quando analisamos o maior tempo de espera identificado em todo o período de simulação, apenas a carga Constante manteve-se dentro do limite estabelecido, com 28 minutos. Nos demais casos houve uma superação do limite superior, variando entre 50 minutos com a carga Crescente e 77 minutos com a carga Onda. Acredita-se que isto ocorreu em função das limitações do ambiente hospitalar real utilizado como base para essa simulação. Como não haviam muitos postos de atendimento disponíveis para serem alocados novos Recursos Humanos, o modelo não foi capaz de alcançar o objetivo nesse ambiente hospitalar.

Para a métrica M2, esperava-se um aumento da quantidade média de recursos humanos entre os cenários C2 e C3, e isso também de fato ocorreu. Para a métrica M3, esperava-se uma diminuição do custo total de atendimento entre os cenários propostos. Entre C1 e C2 houve uma diminuição expressiva do custo independente do padrão de carga utilizado. Já entre C2 e C3, houve uma diminuição do custo apenas para os padrões de carga Crescente, Decrescente e Onda. Para o padrão Constante houve um aumento do custo. Entretanto pode-se notar que o aumento foi irrisório, sendo de apenas 0,3%. Isto deve-se ao fato de que o aumento do número de recursos humanos, apesar de diminuir o tempo médio de espera, acabou por diminuir este tempo muito pouco, fazendo com o que o custo de manter mais recursos humanos acabasse pesando mais na métrica. Mesmo assim, pode-se notar que o modelo EIHealth foi capaz de diminuir significativamente o custo total de atendimento para o ambiente hospitalar proposto.

Por fim, para a métrica M4, esperava-se a diminuição da quantidade média de pacientes aguardando no ambiente hospitalar proposto. Assim como para as métricas anteriores, esse objetivo também foi cumprido. Entre C1 e C2 houve uma diminuição expressiva na quantidade média de pessoas aguardando nas filas para todos os padrões de carga utilizados. Já entre C2 e C3, houve uma diminuição da quantidade de pacientes apenas para os padrões de carga Crescente, Decrescente e Onda. Para o padrão Constante, a quantidade média de pessoas manteve-se a mesma entre C2 e C3. Dessa forma, pode-se notar que o modelo ElHealth foi capaz de diminuir significativamente a quantidade média de pacientes nas filas para o ambiente hospitalar proposto.

Com relação ao uso de sensores RFID para o modelo proposto, também existem evidências de que com o uso de um leitor *Intermec* IF2, equipado de quatro antenas, é possível identificar a entrada de pessoas em um ambiente se as antenas forem instaladas ao lado de portas simples ou duplas, com a mesma distância entre elas. Com base nos dados levantados através das simulações e testes, podemos notar que existem evidências do funcionamento do modelo ElHealth e da sua capacidade de ajustar a força de trabalho de um ambiente hospitalar à demanda de pacientes, diminuindo o tempo de espera por atendimento e a quantidade média de pacientes aguardando nas filas de espera. Entretanto, levando em conta que os testes foram baseados em um ambiente simulado, é importante salientar que os resultados obtidos não podem ser generalizados. Assim, podemos dizer que para uma validação absoluta do sistema seria necessária a sua efetiva implantação em um hospital, de forma a se capturar dados reais da demanda de pacientes para serem analisados. Então, do ponto de vista técnico, existem evidências do protótipo desenvolvido ser funcional, mas não podemos provar apenas com simulação a sua efetividade no mundo real.



## 7 CONCLUSÃO

Todos os dias, cada vez mais tecnologias vão sendo desenvolvidas para nos auxiliar em nossas atividades cotidianas. O conceito de Internet das Coisas nos mostra que até nossos objetos estão se tornando parte do mundo virtual. As tecnologias RFID, NFC, Wi-Fi, Bluetooth, UWB, ZigBee, entre outras, utilizadas pelos sistemas IoT, permitem comunicação eficiente entre os mais diversos objetivos e identificação automática de praticamente qualquer coisa. Além disso, o avanço das pesquisas permitem que informações captadas através de sensores físicos transmitam dados para os sistemas computacionais de forma cada vez mais rápida, precisa e transparente ao usuário. Outro conceito bastante interessante que vêm ganhando cada vez mais destaque com o avanço das tecnologias, e que tem potencial incalculável, é a predição computacional. Através de sistemas computacionais cada vez mais potentes e robustos, uso de redes neurais mais complexas, várias técnicas de inteligência artificial, estudos probabilísticos e estatísticos, análise de grande volumes de dados através do conceito de *Big Data*, entre várias outras abordagens, os sistemas são capazes de analisar as informações passadas e prever com uma confiança muito alta, as informações futuras para todo tipo de aplicação.

Durante o levantamento bibliográfico, foram estudadas e levantadas características das tecnologias utilizadas para Internet das Coisas de forma a verificar se seria possível utilizá-las para melhorar os processos na área da saúde. Também foram estudados os processos hospitalares mais conhecidos e técnicas utilizadas para a predição computacional. Com base nesse levantamento foi possível ver que o IoT não se restringe apenas a uma tecnologia, mas a centenas, talvez milhares de abordagens e tecnologias diferentes para capturar dados do mundo real, transmitir através da rede e realizar os mais diversos tipos de tratamentos sobre eles para solucionar as mais variadas situações-problemas. Com o levantamento de algumas abordagens existentes foi possível notar que não só a tecnologia tem o potencial necessário para ajudar as aplicações na área da saúde, prevendo e antecipando situações indesejadas, como já existem diversas abordagens para monitorar pacientes, analisar dados capturados através de sensores localizados junto a eles ou no ambiente hospitalar, e prever quando possíveis situações de risco à vida vão acontecer. Entretanto nenhuma das abordagens estudadas tenta otimizar a alocação dos recursos humanos nos hospitais.

Depois de estudadas as várias tecnologias e analisadas as abordagens existentes, pode-se vislumbrar que seria possível a construção de um sistema capaz de cumprir os objetivos deste trabalho. Assim é possível concluir que o IoT e a predição computacional são conceitos emergentes, com grande potencial, e que são capazes de analisar o uso dos recursos humanos em ambientes hospitalares, examinando os dados capturados de forma a se identificar possíveis padrões, e antecipar situações que fujam aos interesses dos gestores para que elas sejam tratadas e resolvidas antes mesmos de acontecerem.

Nesse contexto esse trabalho propôs o modelo EIHealth para gerenciamento elástico de recursos humanos em um hospital inteligente. Na Seção 1.2 foi definida a seguinte questão de

pesquisa: *Como seria um modelo para controlar um hospital de forma mais eficiente, garantindo um registro fidedigno do uso de recursos humanos nos processos hospitalares e permitindo identificar e prever possíveis gargalos que podem vir a ocorrer no atendimento clínico, de forma a se realizar uma alocação adaptável dos recursos para atendimento?* Após o desenvolvimento do modelo EIHealth, ela pode ser respondida da seguinte forma: Um modelo capaz de garantir um registro fidedigno do uso de recursos humanos em processos hospitalares pode ser obtido através do uso da IoT, com a proposição de um RTLS, capaz de identificar a movimentação de profissionais de saúde e pacientes em um ambiente hospitalar. Através do registro da movimentação de pacientes e tempos de permanência em cada ponto de atendimento, é possível identificar a demanda por tratamento médico, e os possíveis gargalos no sistema de atendimento. Utilizando desses dados, um modelo de previsão pode estimar a demanda futura de pacientes, de forma a identificar quando ocorrerão novos gargalos no atendimento clínico. Com base nesses dados, esse modelo pode estimar a capacidade de atendimento futura dos profissionais de saúde e propor soluções para movimentação de pessoal que se ajuste a demanda futura por atendimento.

Quanto aos resultados alcançados através da simulação de um ambiente hospitalar, destaca-se que o sistema foi capaz de identificar a movimentação de pessoas, bem como os tempos de permanência em cada um dos ambientes, sendo capaz de utilizar esses dados para definição de séries temporais utilizadas para prever a demanda futura de pacientes. Além disso, destaca-se que com o uso da Elasticidade Preditiva Multinível de Recursos Humanos, o tempo de espera por atendimento, bem como o custo de atendimento e a quantidade média de pessoas aguardando nas filas diminuiu consideravelmente, mostrando a existência de evidências do funcionamento do modelo proposto.

## 7.1 Contribuições

O modelo EIHealth tem como objetivo atender as lacunas identificadas no estado da arte através da pesquisa dos trabalhos relacionados. Nesse sentido, o presente trabalho espera resultar em contribuições tanto científicas, como contribuições para a sociedade através de hospitais inteligentes que utilizem o modelo EIHealth. Com base nisso, o modelo EIHealth traz três contribuições no âmbito científico, listadas abaixo:

- (I) Com o objetivo de desenvolver ambientes hospitalares adaptados a flutuações na demanda de pacientes, o presente trabalho introduz um modelo com novos formalismos matemáticos e algoritmos para propor o conceito de “**Elasticidade Preditiva Multinível de Recursos Humanos**” para hospitais inteligentes que combina dados referentes a chegadas de pacientes no passado com os dados atuais para alocar, realocar e desalocar, de forma otimizada, recursos humanos para atendimento dos pacientes;
- (II) Com o propósito de identificar o ganho de tempo de atendimento com a alocação paralela

e dinâmica de recursos humanos em um ambiente hospitalar, o presente trabalho introduz o conceito de “**Speedup Elástico Proativo de Recursos Humanos**” que utiliza de uma abordagem preditiva para estimar a demanda futura de pacientes e dinamicamente definir a quantidade adequada de atendentes;

- (III) Este trabalho propõe um algoritmo preditivo para analisar a demanda de atendimento e identificar de forma proativa a necessidade de recursos humanos para prestar o atendimento, propondo um processo de realocação de profissionais, em um primeiro momento, para otimizar os recursos existentes sem o aumento dos custos, e em um segundo momento se a realocação não for o suficiente, analisa e propõe a alocação de novos profissionais.

Por fim, com relação as contribuições para a sociedade, podem ser destacadas:

- (I) Diminuição do tempo de espera por atendimento de saúde;
- (II) Otimização dos processos em ambientes hospitalares;
- (III) Possibilidade de melhoria do planejamento hospitalar com base nos dados fornecidos pelo modelo.

## 7.2 Limitações

Nesta seção serão elencadas algumas das limitações que podem ser encontrados para implementação do modelo EIHealth em um ambiente hospitalar real.

- Antes de implementar o modelo em um ambiente real, é necessária uma discussão sobre o que representa a elasticidade de recursos humanos com relação a legislação trabalhista;
- Os funcionários e pacientes precisam obrigatoriamente carregar suas respectivas *tags* de identificação durante todo o seu tempo de permanência nas dependências do hospital inteligente;
- Funcionários podem considerar o sistema invasivo, uma vez que mantém um monitoramento constante das atividades realizadas pelos profissionais de saúde;
- o EIHealth apenas gera notificações para os recursos humanos se realocarem, mas a movimentação efetiva dos funcionários nos ambientes do hospital depende da decisão individual dos mesmos em seguir a orientação;
- A instalação de um sistema RTLS com o nível de precisão necessária em todos os ambientes do hospital, bem como a distribuição de *tags* de identificação a todos os pacientes podem ter um alto custo, tanto em tempo como financeiramente.

### 7.3 Trabalhos Futuros

A título de trabalhos futuros vislumbra-se o desenvolvimento de um sistema que implemente todos os módulos e algoritmos propostos pelo modelo EIHealth, de forma que o mesmo possa ser implantando em um ambiente hospitalar real. Dessa forma, seria possível realizar testes em um cenário real, de forma a averiguar a eficácia das notificações de elasticidade quando aplicadas em profissionais de saúde em seu ambiente de trabalho. Outra possibilidade de trabalhos futuros seria a adaptação do modelo para o uso de outros algoritmos preditivos em substituição, ou complementarmente, ao ARIMA. Dessa forma, a análise de séries temporais poderia ser feita através do uso de redes neurais artificiais ou *Random Forests*, ambas amplamente utilizadas no meio científico com resultados que provam a sua eficácia. Por fim, pretende-se utilizar o conceito de elasticidade preditiva multinível de recursos humanos para domínios diferentes do atendimento hospitalar. Assim, espera-se que o algoritmo seja adaptado e expandido de forma que o mesmo possa ser aplicado em outros ambientes empresariais que prestem atendimento à pessoas.

### 7.4 Publicações

Ao longo de todo o período de pesquisa do mestrado, foram produzidos alguns artigos científicos para publicação em periódicos e anais de eventos. Além dos artigos referentes a essa dissertação, foram produzidos outros artigos através da colaboração com outros pesquisadores do grupo de pesquisa em outros projetos na universidade. A seguir são listados os artigos publicados e os artigos que foram submetidos para avaliação.

- Artigos publicados em **revistas**:

1. **FISCHER, G. S.** *Modelagem e Simulação de Filas de Atendimento em uma Agência Bancária no Rio Grande do Sul*. REVISTA TECNOLÓGICA (UEM), v.26, p.121 - 135, 2017.

- Artigos publicados em **anais de eventos**:

2. MORAIS, F.; **FISCHER, G. S.**; SMIDERLE, R.; RIGO, S. J. *WiTi-Lex: Uma ferramenta para extração de informações sobre pessoas e análise de sentimentos de opiniões*. In: Computer on The Beach, 2018, Florianópolis. Anais do XV Computer on the Beach. Itajaí: Universidade do Vale do Itajaí, 2018. p.374 - 383.

- Artigos aprovados para publicação:

3. **FISCHER, G. S.**; RIGHI, R. R.; RODRIGUES, V. F.; COSTA, C. A. *Use of Internet of Things with Data Prediction on Healthcare Environments: a Survey*. International Journal of E-Health and Medical Communications (IJEHMC).

- Artigos submetidos para avaliação:

4. **FISCHER, G. S.**; MORAIS, F.; SMIDERLE, R.; RIGO, S. J.; RIGHI, R. R.; JACQUES, P. M. *WiTi-Lex: Integrating information extraction and sentiment analysis in a semantic platform*. International Journal of Computers and Applications (IJCA).

- Artigos em preparação:

5. **FISCHER, G. S.**; RIGHI, R. R.; COSTA, C. A.; RAMOS, G. O. *ElHealth: Using Internet of Things and Data Prediction for Elastic Management of Human Resources in Smart Hospitals*.



## REFERÊNCIAS

- AKEJU, O.; BUTAKOV, S.; AGHILI, S. Main factors and good practices for managing BYOD and IoT risks in a K-12 environment. **International Journal of Internet of Things and Cyber-Assurance**, Olney, England, v. 1, n. 1, p. 22–39, Jan. 2018.
- AL-DHURAIBI, Y.; PARAISO, F.; DJARALLAH, N.; MERLE, P. Elasticity in Cloud Computing: state of the art and research challenges. **IEEE Transactions on Services Computing**, USA, v. PP, n. 99, p. 1–1, 2017.
- AL-HAIDARI, F.; SQALLI, M.; SALAH, K. Impact of CPU Utilization Thresholds and Scaling Size on Autoscaling Cloud Resources. In: IEEE 5TH INTERNATIONAL CONFERENCE ON CLOUD COMPUTING TECHNOLOGY AND SCIENCE, 2013., 2013, Bristol, UK. **Anais...** IEEE, 2013. v. 2, p. 256–261.
- ALHARBE, N.; ATKINS, A. S.; AKBARI, A. S. Application of ZigBee and RFID Technologies in Healthcare in Conjunction with the Internet of Things. In: INTERNATIONAL CONFERENCE ON ADVANCES IN MOBILE COMPUTING & MULTIMEDIA, 2013, Vienna, Austria. **Proceedings...** ACM, 2013. p. 191:191–191:195. (MoMM '13).
- ALI, F.; ISLAM, S. R.; KWAK, D.; KHAN, P.; ULLAH, N.; YOO, S. jo; KWAK, K. Type-2 fuzzy ontology–aided recommendation systems for IoT–based healthcare. **Computer Communications**, Guildford, England, v. 119, p. 138 – 155, 2018.
- ALVES, T. M.; COSTA, C. A. da; ROSA RIGHI, R. da; BARBOSA, J. L. V. Exploring the social Internet of Things concept in a univeristy campus using NFC. In: LATIN AMERICAN COMPUTING CONFERENCE (CLEI), 2015., 2015, Arequipa, Peru. **Anais...** IEEE, 2015. p. 1–12.
- AMDAHL, G. M. Validity of the Single Processor Approach to Achieving Large Scale Computing Capabilities. In: APRIL 18-20, 1967, SPRING JOINT COMPUTER CONFERENCE, 1967, New York, NY, USA. **Proceedings...** ACM, 1967. p. 483–485. (AFIPS '67 (Spring)).
- ATZORI, L.; IERA, A.; MORABITO, G. The Internet of Things: a survey. **Computer Networks**, New York, NY, USA, v. 54, n. 15, p. 2787–2805, Oct. 2010.
- AZEVEDO, A. L.; PEREIRA, A.; LEMOS, C.; COELHO, M.; CHAVES, L. Organização de serviços de emergência hospitalar: uma revisão integrativa de pesquisas. **Revista Eletrônica de Enfermagem**, Goiânia, GO, Brasil, v. 12, n. 4, p. 736–45, 2010.
- BITTAR, O. J. N. V. Gestão de processos e certificação para qualidade em saúde. **Revista da Associação Médica Brasileira**, São Paulo, SP, Brazil, v. 46, p. 70 – 76, Mar. 2000.
- BOULOS, M. N. K.; BERRY, G. Real-time locating systems (RTLS) in healthcare: a condensed primer. **International Journal of Health Geographics**, England, v. 11, n. 25, p. 1–8, 2012.
- BRASIL. **Decreto-Lei nº 5.452, de 1º de maio de 1943**. Aprova a Consolidação das Leis do Trabalho. Disponível em: <[http://www.planalto.gov.br/ccivil\\_03/Decreto-Lei/Del5452.htm](http://www.planalto.gov.br/ccivil_03/Decreto-Lei/Del5452.htm)>. Acesso em: 11 nov. 2018.



BRASIL. **Lei nº 13.467, de 13 de julho de 2017**. Altera a Consolidação das Leis do Trabalho (CLT), aprovada pelo Decreto-Lei no 5.452, de 1º de maio de 1943, e as Leis nº 6.019, de 3 de janeiro de 1974, 8.036, de 11 de maio de 1990, e 8.212, de 24 de julho de 1991, a fim de adequar a legislação às novas relações de trabalho. Disponível em:

<[http://www.planalto.gov.br/ccivil\\_03/\\_ato2015-2018/2017/lei/L13467.htm](http://www.planalto.gov.br/ccivil_03/_ato2015-2018/2017/lei/L13467.htm)>. Acesso em: 11 nov. 2018.

BUTEAN, A.; DAVID, A.; BUDULECI, C.; DAIAN, A. Auxilium Medicine: a cloud based platform for real-time monitoring medical devices. In: INTERNATIONAL CONFERENCE ON CONTROL SYSTEMS AND COMPUTER SCIENCE, 2015., 2015, Bucharest, Romania. **Anais...** IEEE, 2015. p. 874–879.

CAPOCCI, N. R.; NASCIMENTO, B. S.; LOPES, F. B.; BUENO, M. J. C. Simulação de Eventos Discretos Aplicado em uma Policlínica. **INOVAE - Journal of Engineering, Architecture and Technology Innovation**, São Paulo, SP, Brasil, v. 4, n. 1, p. 11–22, 2016.

COSKUN, V.; OZDENIZCI, B.; OK, K. A Survey on Near Field Communication (NFC) Technology. **Wireless Personal Communications**, Hingham, MA, USA, v. 71, n. 3, p. 2259–2294, Aug. 2013.

COSTA, N.; SILVA, J. C.; SILVA, J. L. Real-Time App Development Approach for Indoor Monitoring. In: IBERIAN CONFERENCE ON INFORMATION SYSTEMS AND TECHNOLOGIES (CISTI), 2017., 2017, Lisbon, Portugal. **Anais...** IEEE, 2017. p. 1–4.

COUTINHO, A. A. P.; CECÍLIO, L. C. d. O.; MOTA, J. A. C. Classificação de risco em serviços de emergência: uma discussão da literatura sobre o Sistema de Triagem de Manchester. **Revista Médica de Minas Gerais**, Belo Horizonte, MG, Brasil, v. 22, n. 2, p. 188–198, Mar. 2012.

DARSHAN, K. R.; ANANDAKUMAR, K. R. A comprehensive review on usage of Internet of Things (IoT) in healthcare system. In: INTERNATIONAL CONFERENCE ON EMERGING RESEARCH IN ELECTRONICS, COMPUTER SCIENCE AND TECHNOLOGY (ICERECT), 2015., 2015, Mandya, India. **Anais...** IEEE, 2015. p. 132–136.

FÁBIO, Z. **Projeto de Lei, de 14 de junho de 2018**. Estipula o tempo máximo de espera para atendimento em hospitais, clínicas e laboratórios da iniciativa privada estabelecidos em Goiânia. Disponível em: <<http://goiania.go.leg.br/sala-de-imprensa/noticias/projeto-estipula-tempo-maximo-de-espera-para-atendimento-em-hospitais>>. Acesso em: 31 dez. 2018.

GRAHAM, B.; BOND, R.; QUINN, M.; MULVENNA, M. Using Data Mining to Predict Hospital Admissions From the Emergency Department. **IEEE Access**, New York, NY, USA, v. 6, p. 10458–10469, Feb. 2018.

GRUPO PORTUGUÊS DE TRIAGEM. **Triagem no Serviço de Urgência: Protocolo de Triagem de Manchester**. 2. ed. Lisboa, Portugal: Blackwell Publishing Ltd., 2010.

GS1. **EPCGlobal**. Brussels, 2018. Disponível em: <<https://www.gs1.org/epcglobal>>. Acesso em: 03 maio 2018.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO); INTERNATIONAL ELECTROTECHNICAL COMMISSION (IEC). **ISO/IEC 24730: information technology: real-time locating systems (RTLS)**. 2th ed. Geneva, 2014.

IOT. In: GOOGLE IMAGENS. Mountain View: Google, 2017. Disponível em: <[ISHIKAWA, T.; FUJIWARA, K.; OHBA, H.; SUZUKI, T.; OGASAWARA, K. Forecasting the regional distribution and sufficiency of physicians in Japan with a coupled system dynamics—geographic information system model. \*\*Human Resources for Health\*\*, London, England, v. 15, n. 1, p. 64, Sep. 2017.](http://google.com.br/search?q=iot&source=lnms&tbm=isch&sa=X&ved=0ahUKEwj0qvnJ0sHWAhUDhZAKHQaUB2kQ_AUICygC&biw=1366&bih=599#imgrc=g8Y6bkJcP4TFcM:>.>. Acesso em: 25 set. 2017.</p>
</div>
<div data-bbox=)

ISLAM, S.; LEE, K.; FEKETE, A.; LIU, A. How a Consumer Can Measure Elasticity for Cloud Platforms. In: ACM/SPEC INTERNATIONAL CONFERENCE ON PERFORMANCE ENGINEERING, 3., 2012, New York, NY, USA. **Proceedings...** ACM, 2012. p. 85–96. (ICPE '12).

ISLAM, S. M. R.; KWAK, D.; KABIR, M. H.; HOSSAIN, M.; KWAK, K. S. The Internet of Things for Health Care: a comprehensive survey. **IEEE Access**, New York, NY, USA, v. 3, p. 678–708, 2015.

LANDT, J. The history of RFID. **IEEE Potentials**, New York, NY, USA, v. 24, n. 4, p. 8–11, Oct. 2005.

LIU, J. X.; GORYAKIN, Y.; MAEDA, A.; BRUCKNER, T.; SCHEFFLER, R. Global Health Workforce Labor Market Projections for 2030. **Human Resources for Health**, London, England, v. 15, n. 1, p. 11, Feb 2017.

MOREIRA, P. A. T. **Gestão de Controlo DE Acessos**. 2008. 241 p. Dissertação (Mestrado Integrado em Engenharia Electrotécnica e de Computadores) — Faculdade de Engenharia da Universidade de Porto, Portugal, 2008.

NASSAR, V.; VIEIRA, M. L. H. A Internet das Coisas com as Tecnologias RFID e NFC. **Blucher Design Proceedings**, São Paulo, Brasil, v. 1, n. 4, p. 3238–3250, 2014.

NEIVA, J. P. B. **Localização e Orientação Indoor com recurso à Tecnologia RFID**. 2012. 78 p. Dissertação (Mestrado Integrado em Engenharia Electrotécnica e de Computadores) — Faculdade de Engenharia da Universidade de Porto, Portugal, 2012.

NETO, J. P. **Uma Comparação Empírica do Desempenho Preditivo das Análises Fundamentalista, Gráfica e Econométrica no Mercado Acionário Brasileiro**. 2011. 593 p. Tese (Doutorado em Administração - Linha de pesquisa: Finanças) — Programa de Pós-Graduação em Administração, Faculdade de Economia, Administração, Contabilidade e Ciência da Informação e Documentação, Universidade Federal de Brasília, Brasília, 2011.

NISHA, K. G.; SREEKUMAR, K. A Review and Analysis of machine Learning and Statistical Approaches for Prediction. In: INTERNATIONAL CONFERENCE ON INVENTIVE COMMUNICATION AND COMPUTATIONAL TECHNOLOGIES (ICICCT), 2017., 2017, Thondamuthur coimbatore, India. **Anais...** IEEE, 2017. p. 135–139.

ORIMAYE, S. O.; LEONG, F. C.; LEE, C. H.; NG, E. C. H. Predicting proximity with ambient mobile sensors for non-invasive health diagnostics. In: IEEE 12TH MALAYSIA INTERNATIONAL CONFERENCE ON COMMUNICATIONS (MICC), 2015., 2015. **Anais...** IEEE, 2015. p. 6–11.

PEDRAZA, G.; GARCÍA, I.; DEBBABI, B. An RFID Architecture Based on an Event-oriented Component Model. In: **FOURTH ACM INTERNATIONAL CONFERENCE ON DISTRIBUTED EVENT-BASED SYSTEMS**, 2010, New York, NY, USA.

**Proceedings...** ACM, 2010. p. 87–88. (DEBS '10).

PEREIRA, C. L. A. **Dispositivos de Identificação**. 2012. 127 p. Dissertação (Mestrado em Sistemas e Tecnologias de Informação para as Organizações). — Instituto Politécnico de Viseu, Escola Superior de Tecnologia e Gestão de Viseu, Portugal, 2012.

PINTO, S.; CABRAL, J.; GOMES, T. We-care: an iot-based health care system for elderly people. In: **IEEE INTERNATIONAL CONFERENCE ON INDUSTRIAL TECHNOLOGY (ICIT)**, 2017., 2017, Toronto, ON, Canada. **Anais...** IEEE, 2017. p. 1378–1383.

RFID for health sector. In: **GOOGLE IMAGENS**. Mountain View: Google, 2018. Disponível em: <[https://www.google.com/search?biw=1024&bih=654&tbm=isch&sa=1&ei=MLAOW9TmBYePwgTzkbzABg&q=rfid+for+health+sector&oq=rfid+for+health+sector&gs\\_l=img.3..19615.22684.0.22853.11.11.0.0.0.117.975.9j2.11.0...0...1c.1.64.img..1.1.104...0i19k1.0.2iLBSaAQO2s#imgrc=2YF6UOpb6MWgTM:>](https://www.google.com/search?biw=1024&bih=654&tbm=isch&sa=1&ei=MLAOW9TmBYePwgTzkbzABg&q=rfid+for+health+sector&oq=rfid+for+health+sector&gs_l=img.3..19615.22684.0.22853.11.11.0.0.0.117.975.9j2.11.0...0...1c.1.64.img..1.1.104...0i19k1.0.2iLBSaAQO2s#imgrc=2YF6UOpb6MWgTM:>)>. Acesso em: 30 maio 2018.

RIGHI, R. R.; RODRIGUES, V. F.; COSTA, C. A. da; GALANTE, G.; BONA, L. C. E. de; FERRETO, T. AutoElastic: automatic resource elasticity for high performance applications in the cloud. **IEEE Transactions on Cloud Computing**, New York, NY, USA, v. 4, n. 1, p. 6–19, Jan 2016.

ROEHRS, A.; COSTA, C. A. da; ROSA RIGHI, R. da; OLIVEIRA, K. S. F. de. Personal Health Records: A Systematic Literature Review. **Journal of medical Internet research**, Bethesda, MD, USA, v. 19, n. 1, 2017.

ROSA RIGHI, R.; COSTA, C. A.; RODRIGUES, V. F.; ROSTIROLLA, G. Joint-analysis of Performance and Energy Consumption when Enabling Cloud Elasticity for Synchronous HPC Applications. **Concurrency and Computation : Practice and Experience**, Chichester, UK, v. 28, n. 5, p. 1548–1571, Apr. 2016.

ROSSI, D. J. **Previsão da Velocidade dos Ventos por Redes Neurais Artificiais e ARIMA de Box & Jenkins**. 2013. 76 p. Dissertação (Mestrado em Engenharia Elétrica - Área de conhecimento: Automação) — Programa de Pós-Graduação em Engenharia Elétrica, Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista, Ilha Solteira, 2013.

ROSTIROLLA, G.; ROSA RIGHI, R. da; BARBOSA, J. L. V.; COSTA, C. A. da. ElCity: an elastic multilevel energy saving model for smart cities. **IEEE Transactions on Sustainable Computing**, Piscataway, NJ, USA, v. PP, n. 99, p. 1–1, 2017.

RYU, W.; KWON, J.; HONG, B. Generation of RFID Test Datasets Using RSN Tool. **Personal Ubiquitous Computing**, London, UK, UK, v. 17, n. 7, p. 1409–1419, Oct. 2013.

SARHAN, Q. I. Internet of things: a survey of challenges and issues. **International Journal of Internet of Things and Cyber-Assurance**, Olney, England, v. 1, n. 1, p. 40–75, Jan. 2018.

SEDGEWICK, R.; WAYNE, K. **Class StdRandom**. 2017. Disponível em: <<https://introcs.cs.princeton.edu/java/stdlib/javadoc/StdRandom.html/>>>. Acesso em: 12 jan. 2018.

SILBERSCHATZ, A.; GALVIN, P. B.; GAGNE, G. **Operating System Concepts**. 9. ed. Hoboken, NJ, USA: Wiley Publishing, 2012.

SINGH, K. J.; KAPOOR, D. S. Create Your Own Internet of Things: a survey of iot platforms. **IEEE Consumer Electronics Magazine**, New York, NY, USA, v. 6, n. 2, p. 57–68, Apr. 2017.

SUPERLOTADA, emergência do Hospital Conceição acomoda pacientes no chão. Diário Gaúcho, Porto Alegre, 11 ago. 2017. Disponível em: <<http://diariogaucho.clicrbs.com.br/rs/dia-a-dia/noticia/2017/08/superlotada-emergencia-do-hospital-conceicao-acomoda-pacientes-no-chao-9866813.html>>. Acesso em: 25 set. 2017.

THIESSE, F.; FLOERKEMEIER, C.; HARRISON, M.; MICHAHELLES, F.; RODUNER, C. Technology, Standards, and Real-World Deployments of the EPC Network. **IEEE Internet Computing**, New York, NY, USA, v. 13, n. 2, p. 36–43, Mar. 2009.

UMA emergência está lotada e seis estão superlotadas na Capital. Zero Hora, Porto Alegre, 16 ago. 2011. Disponível em: <<https://gauchazh.clicrbs.com.br/geral/noticia/2011/08/uma-emergencia-esta-lotada-e-seis-estao-superlotadas-na-capital-3450406.html>>. Acesso em: 25 set. 2017.

VIEIRA, D.; HOLLMÉN, J. Resource Frequency Prediction in Healthcare: machine learning approach. In: IEEE 29TH INTERNATIONAL SYMPOSIUM ON COMPUTER-BASED MEDICAL SYSTEMS (CBMS), 2016., 2016, Dublin, Ireland. **Anais...** IEEE, 2016. p. 88–93.

WANG, H.; SINNEN, O. List-Scheduling versus Cluster-Scheduling. **IEEE Transactions on Parallel and Distributed Systems**, USA, v. 29, n. 8, p. 1736–1749, Aug. 2018.

WANJARI, N. D.; PATIL, S. C. Wearable devices. In: IEEE INTERNATIONAL CONFERENCE ON ADVANCES IN ELECTRONICS, COMMUNICATION AND COMPUTER TECHNOLOGY (ICAECCT), 2016., 2016, Pune, India. **Anais...** IEEE, 2016. p. 287–290.

WANT, R. An introduction to RFID technology. **IEEE Pervasive Computing**, New York, NY, USA, v. 5, n. 1, p. 25–33, Jan. 2006.

WANT, R. Near field communication. **IEEE Pervasive Computing**, New York, NY, USA, v. 10, n. 3, p. 4–7, July 2011.

WILKINSON, B.; ALLEN, C. **Parallel programming**: techniques and applications using networked workstations and parallel computers. Upper Saddle River, NJ, USA: Pearson/Prentice Hall, 2005.

ZAMANIFAR, A.; NAZEMI, E.; VAHIDI-ASL, M. DMP-IOT: A distributed movement prediction scheme for IOT health-care applications. **Computers & Electrical Engineering**, New York, NY, USA, v. 58, n. Supplement C, p. 310 – 326, 2017.