



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CAMPUS TRINDADE
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA ELÉTRICA

Reginaldo Dias Soares Filho

**Proposta de Metodologia de um Sistema de Gestão Ubíqua com Análise Cognitiva em
Tecnologia da Atenção Primária à Saúde**

Florianópolis
2020

Reginaldo Dias Soares Filho

**Proposta de Metodologia de um Sistema de Gestão Ubíqua com Análise Cognitiva em
Tecnologia da Atenção Primária à Saúde**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Santa Catarina para a obtenção do título de mestre em engenharia elétrica Orientador: Prof. Jefferson Luiz Brum Marques, Ph.D. Coorientador: Prof. Renato Garcia Ojeda, Dr.

Florianópolis

2020

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Soares Filho, Reginaldo Dias Soares Filho
Proposta de Metodologia de um Sistema de Gestão Ubíqua
com Análise Cognitiva em Tecnologia da Atenção Primária
à Saúde / Reginaldo Dias Soares Filho Soares Filho ;
orientador, Jefferson Luiz Brum Marques Marques,
coorientador, Renato Garcia Ojeda Garcia, 2020.
120 p.

Dissertação (mestrado) - Universidade Federal de Santa
Catarina, Centro Tecnológico, Programa de Pós-Graduação em
Engenharia Elétrica, Florianópolis, 2020.

Inclui referências.

1. Engenharia Elétrica. 2. Gestão Ubíqua. Tecnologia em
Saúde. 3. Atenção Primária à Saúde. 4. Monitoramento Remoto.
5. Análise Cognitiva. I. Marques, Jefferson Luiz Brum
Marques. II. Garcia, Renato Garcia Ojeda. III.
Universidade Federal de Santa Catarina. Programa de Pós
Graduação em Engenharia Elétrica. IV. Título.

Reginaldo Dias Soares Filho

**PROPOSTA DE METODOLOGIA DE UM SISTEMA DE GESTÃO UBÍQUA COM
ANÁLISE COGNITIVA EM TECNOLOGIA DA ATENÇÃO PRIMÁRIA À SAÚDE**

O presente trabalho em nível de mestrado foi avaliado e aprovado por banca
examinadora composta pelos seguintes membros:

Prof. Carlos Rubén Dell’ Aquila, Dr.
Universidad Nacional de San Juan (UNSJ)

Prof. Gabriel Eduardo Cañadas Fragapane,
Universidad Nacional de San Juan (UNSJ)

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi
julgado adequado para obtenção do título de Mestre em Engenharia Elétrica pelo Programa de
Pós-Graduação em Engenharia Elétrica-UFSC.

Prof. Telles Brunelli Lazzarin, Dr
Coordenação do Programa de Pós-Graduação

Prof. Jefferson Luiz Brum Marques, Ph.D
Orientador

Florianópolis, 2020.

Este trabalho é dedicado à minha família e a Ana Paula Paixão Mendes, que incentivou o desenvolvimento e conclusão desse trabalho e sempre dando apoio.

AGRADECIMENTOS

Agradeço a Deus e a Nossa Senhora, minha mãe protetora, por estarem sempre comigo, me guiando, iluminando cada passo meu e me abençoando. Obrigada pela força necessária para lutar e enfrentar todos os obstáculos, sem nunca desistir

Agradeço aos meus pais Reginaldo e Luzinete, às minhas irmãs Luzitane e Meuryany meu avô Noé e à minha avó Dalva (in memoriam). A vocês, minha família, sou eternamente grata por tudo que sou, por tudo que consegui conquistar e pela felicidade que tenho.

Agradeço aos Professores do Instituto de Engenharia Biomédica pela dedicação e os conhecimentos transmitidos, sem os quais não seria possível a realização deste trabalho.

Aos membros da banca por disponibilizarem tempo e disposição para esta etapa importante em minha vida.

Agradeço aos estagiários Rafael Peixoto, Felipe Nascimento e aos Dr. Gabriel e Carlos colaboraram para o desenvolvimento desse projeto.

Agradeço ao Professor. Fabio de Araújo Leite, MSc, pela apresentação da academia e produções científicas sobre os temas de Internet das Coisas e Logica Fuzzy.

Agradeço ao IEB-UFSC no qual me proporcionou um estágio no qual foi de valia para desenvolvimento deste trabalho, financiamento do projeto e aprendizado na carreira acadêmica e profissional na área de engenharia clínica

A equipe do IEB-UFSC, em especial Juliano Martins, Maria Angélica, Flávio Garcia, Renato Zamboni.

Ao Professor Dr. Renato Garcia Ojeda que despertou meu interesse para o tema do trabalho, pela paciência como parceiro de pesquisa e sem as contribuições sem as quais este trabalho não seria possível, além de ter me dado oportunidade de acompanhá-lo como referência em estudo e pesquisa na engenharia clínica e me permitir parte da equipe da engenharia clínica no IEB-UFSC. Sempre discutindo ideias inovadoras no âmbito da engenharia clínica.

Finalmente queria agradecer ao Professor Jefferson Luiz Brum Marques pelas orientações, paciência e incentivo a fazer sempre o melhor, pensar e oferecer as melhores soluções e por ser solícito.

“O futuro tecnológico será caracterizado pela computação, não por computadores”.
(WEISER, 1991)

RESUMO

Dentre as atribuições da Engenharia Clínica (EC) pode-se reconhecer o desenvolvimento e emprego de soluções em gestão e gerenciamento de tecnologia em saúde, desenvolvimento e aplicação de ferramentas e metodologias que auxiliam os estabelecimentos assistenciais de saúde. Neste contexto, a Gestão Ubíqua de Tecnologia em Saúde (GUTS) refere-se a um modelo de gestão descentralizada que pode ser feita a partir de qualquer lugar e utiliza ferramentas para o aporte às ações da EC. Este trabalho consiste no desenvolvimento de uma metodologia de GUTS e sua implementação numa plataforma de monitoramento com uso de interconectividade e sistema de análise cognitiva para apoiar o processo de tomada de decisão no contexto das atribuições da EC, voltados para a Atenção Primária à Saúde (APS). O sistema de análise cognitiva se refere a processos capazes de decifrar, interpretar, organizar informações e explicá-las, cujo funcionamento se assemelha aos processos cognitivos humanos. A metodologia utilizada se baseia em três categorias: Operacional, Monitoramento e Decisão. A categoria operacional desenvolve técnicas de soluções em saúde através de ferramentas para controle e melhoria da qualidade na escolha da tecnologia em saúde e na definição dos parâmetros de monitoramento. A categoria de monitoramento apresenta uma arquitetura semelhante à *Internet of Things*, dividida em camadas de sensoriamento, rede e processamento, gerenciamento e padronização; estas camadas são responsáveis pela coleta, envio, processamento, armazenamento, integração dos dados e padronização dos sensores na plataforma. A categoria de decisão consiste na gestão em tempo real da tecnologia com apoio à tomada de decisão que utiliza um sistema de análise cognitiva para dar mais robustez à plataforma. Para ilustrar a aplicação desta metodologia de GUTS são apresentados e discutidos os resultados de um caso de estudo onde é implementada a Plataforma de Monitoramento em um compressor de ar comprimido odontológico de uma unidade de saúde na APS de Florianópolis-SC-Brasil. Através do monitoramento, esta metodologia adiciona confiabilidade, robustez e segurança aos gestores, operadores e usuários da APS. Além disso, pode nortear ações mais específicas para o gerenciamento do processo tecnológico em ambientes descentralizados e, com a incorporação de um sistema de análise cognitiva na plataforma, pode potencializar o conjunto de ações da engenharia clínica, pela possibilidade de fazer o gerenciamento remoto de várias tecnologias de saúde ao mesmo tempo. Para isso, integrou a plataforma da *Microsoft Machine Learning Studio* cujos resultados foram satisfatórios para o algoritmo *decision forest* que apresentou maior acurácia em relação aos outros algoritmos testados para o monitoramento da tecnologia sob estudo, em relação aos seus modos de falha.

Palavras-chave: Gestão Ubíqua. Tecnologia em Saúde. Atenção Primária à Saúde. Monitoramento Remoto. Análise Cognitiva. Engenharia Clínica.

ABSTRACT

Among the roles of Clinical Engineering (CE), there are the use of solutions in health technology management and the development and application of tools to assist health care establishments. In this sense, Ubiquitous Health Technology Management (UHTM) represents a decentralized management model that can be carried out from anywhere, and that employ tools to support clinical engineering tasks. The present work consists in the development of a UHTM methodology and its implementation in a monitoring platform using interconnectivity and cognitive analysis to support the CE decision-making process in Primary Health Care (PHC) establishments. The cognitive analysis systems refer to the process capable of reading, interpreting, organizing, and explaining information in which behaviour is similar to the human process. The procedure has three main categories: Operational, Monitoring, and Decision. The operational division develops health solutions techniques using tools to chose the most suitable healthcare technology for a facility and the right parameters for its monitoring. The monitoring category has an architecture similar to the one of the Internet of Things, divided into a sensing layer, network and processing, management, and standardization layers. These layers are responsible for collecting, sending, processing, storing and integrating the data, and standardizing sensors in the platform. The decision category consists of real-time technology management with a decision support system, using a cognitive analysis structure to make the platform more robust. The results of the methodology application are presented and discussed in a case study that includes the implementation of the Monitoring Platform in Florianópolis (SC - Brazil) PHC unit. Through supervision, this methodology can guide more specific actions of technological processes management in decentralized environments. It adds reliability, robustness, and security to the managers, operators, and users of the PHC system. It also includes a cognitive analysis system that can improve the set of predetermined actions in clinical engineering by managing different technologies at the same time. Thus, the project used the Microsoft Machine Learning Studio platform with the decision forest algorithm as it presented the most satisfactory results regarding the monitoring of technology failure modes.

Keywords: Health Technology Ubiquitous Management. Primary Health Care. Remote Monitoring. Cognitive Analysis. Clinical Engineering.

LISTA DE FIGURAS

Figura 1 – Figura 1 – Modelo Funcional de camadas da arquitetura IoT.....	32
Figura 2 – Modelo de Gestão Ubíqua de Tecnologia em Saúde.....	39
Figura 3 Etapas da Categoria Operacional	40
Figura 4 Etapas para definir a situação problema.....	41
Figura 5 – Etapas para categoria de Monitoramento.....	44
Figura 6 – Etapas para a Categoria de Decisão.....	47
Figura 7 – Estrutura para categoria Operacional.....	51
Figura 8 – Diagrama de Pareto da classe de equipamentos.....	54
Figura 9 – Gráfico do diagrama de Pareto das falhas do compressor de ar comprimido odontológico.....	56
Figura 10 – Estrutura da categoria de monitoramento.....	57
Figura 11 – Placa de Circuito Impresso.....	60
Figura 12 – Representação do módulo de aquisição de dados.....	60
Figura 13 – Diagrama do módulo coletor.....	61
Figura 14 – Módulo Concentrador.....	61
Figura 15 – Resumo do diagrama com entidade relacionamento e atributos.....	64
Figura 16 – Modelo Conceitual E-R com atributos.....	65
Figura 17 – Projeto lógico do diagrama de bloco do banco de dados.....	65
Figura 18 – Interface do pgAdmin4 na implementação do SGBD.....	67
Figura 19 – Interface gráfica de comunicação do módulo concentrador com a DB.....	68
Figura 20 – Interface gráfica para cadastrar a unidade de saúde e a tecnóloga a ser monitorada.....	69
Figura 21 – Interface gráfica para conectar ao sistema de monitoramento.....	70
Figura 22 – Interface gráfica para escolha da unidade de saúde.....	70
Figura 23 – Interface gráfica para visualização dos dados pelo usuário.....	71
Figura 24 – Estrutura da categoria de decisão.....	74
Figura 25 – Ponto de instalação do sensor de temperatura.....	75
Figura 26 – Ponto de instalação para fixar o sensor de temperatura.....	75
Figura 27 – Ponto de instalação do sensor de pressão.....	76
Figura 28 – Local de instalação do módulo de aquisição de dados.....	76
Figura 29 – <i>Front End</i> utilizada pela engenharia clínica realizar o monitoramento.....	77
Figura 30 – Matriz de Confusão de <i>decision forest</i>	82

Figura 31 – Matriz de confusão do <i>decisión jungle</i>	83
Figura 32 – Matriz de confusão de <i>logistic regression</i>	84
Figura 33 – Matriz de confusão da <i>neural networks</i>	85
Figura 34 – Aplicativo de visualização dos dados da análise cognitiva.....	86

LISTA DE QUADROS

Quadro 1 – Referências para montar a matriz GUT.....	30
Quadro 2 – Serviços de aprendizado de máquina na nuvem.....	37
Quadro 3 – Definição das Entidades e atributos para montagem do Diagrama ER.....	63
Quadro 4 – Entidade com suas <i>Primary Key</i>	64
Quadro 5 – Dicionário de dados de medição.....	66
Quadro 6 – Dicionário de Unidade de Saúde.....	66
Quadro 7 – Dicionário de dados para equipamentos.....	66
Quadro 8 – Analisadores utilizados no estudo.....	73

LISTA DE TABELAS

Tabela 1 – Resultados do diagrama de Pareto.....	53
Tabela 2 – Diagrama de Pareto do compressor odontológico de ar comprimido isento de o de óleo.....	56
Tabela 3 – Resultados do erro de medição e das incertezas de cada parâmetro.....	73
Tabela 4 – Amostragem de dados coletados para treinamento e validação dos algoritmos.....	80

LISTA DE ABREVIATURAS E SIGLAS

°C	Graus Celsius
3G	Padrão Terceira Geração
AM	Aprendizado de Máquinas
ANEEL	Agência Nacional de Energia
ANVISA	Agência Nacional de Vigilância Sanitária
APS	Atenção Primária à Saúde
ARM	Modelo de Arquitetura de Referência
AWS	<i>Amazon Web Service</i>
CAPS	Centros de Atenção Psicossocial
CELEC-APS	Centro Local de Engenharia Clínica da Atenção Primária à Saúde
CEO	Centro de Especialidades Odontológicas
CPS	Sistemas Médicos Ciber-Físicos
DB	<i>Data Base</i>
EAS	Estabelecimento Assistencial à Saúde
EC	Engenharia Clínica
EMHO	Equipamento Médico Hospitalar Odontológico
ER	Entidade-Relacionamento
ESF	Estratégia de Saúde da família
FE	<i>Front End</i>
FK	<i>Foreign Key</i>
FQ	Ferramentas de Qualidade
G	Gravidade
GTMH	Gestão de Tecnologia Médico-Hospitalar
gTMH	Gerenciamento de Tecnologia Médico-Hospitalar
GUT	Gravidade, Urgência e Tendência
HL7	<i>Health Level Seven</i>
HP	<i>Horse Power</i>
IBM	<i>International Business Machines</i>
IDE	<i>Integrated Development Environment</i>
IEB-UFSC	Instituto de Engenharia Biomédica-Universidade Federal de Santa Catarina

IoE	<i>Internet of Everything</i>
IoS	<i>Internet of Service</i>
IoT	<i>Internet of Things</i>
IoT-A	Arquitetura da <i>Internet of Things</i>
IP	<i>Internet Protocol</i>
ISSO	<i>International Organization for Standardization</i>
LTE	<i>Long Term Evolution</i>
MCPS	Sistemas Médicos Ciber-Físicos
ML	<i>Machine Learning</i>
ML Studio	<i>Machine Learning Studio</i>
MLaaS	<i>Machine Learning as a Service</i>
NASF	Núcleos de Apoio à Saúde da Família
OS	Ordem de Serviço
PK	<i>Primary Key</i>
POP	Procedimento Operacional Padrão
PRODIST	Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional
Psi	Libra por Polegada Quadrada
RF	Radiofrequência
RTC	<i>Real Time Clock</i>
SBC	<i>Single Board Computers</i>
SGBD	Sistema de Gerenciamento de Banco de Dados
SI-IEB-UFSC	Sistema de Informações do Instituto de Engenharia Biomédica- Universidade Federal de Santa Catarina
SQL	<i>Structured Query Language</i>
SUS	Sistema Único de Saúde
T	Tendência
TCP/IP	<i>Transmission Control Protocol/Internet Protocol</i>
TMH	Tecnologia Médico Hospitalar
U	Urgência
UBS	Unidade Básica de Saúde
UPA	Unidades de Pronto Atendimento e Apoio Diagnóstico

V	Volt
VA	<i>Volt-Amper</i>
WLAN	<i>Wireless Local Area Network</i>

SUMÁRIO

1	INTRODUÇÃO	21
1.2	PROPOSTA DO TRABALHO	21
1.3	OBJETIVOS	22
1.3.1	Objetivo Geral.....	22
1.3.2	Objetivos Específicos	22
1.4	JUSTIFICATIVA	22
1.5	ESTRUTURA DO TRABALHO	23
2	FUNDAMENTAÇÃO TEÓRICA.....	25
2.1	EVOLUÇÃO DO SISTEMA DE SAÚDE – SAÚDE UBÍQUA	25
2.1.1	e-health.....	25
2.1.2	m-health	26
2.1.3	u-health	26
2.1.4	Saúde 4.0.....	27
2.2	GESTÃO UBÍQUA DE TECNOLOGIA EM SAÚDE	28
2.2.1	Ferramentas para controle e melhoria da qualidade na gestão de tecnologia em saúde	28
2.2.1.1	<i>Folha de Verificação</i>	29
2.2.1.2	<i>Diagrama de Pareto</i>	29
2.2.1.3	<i>Matriz de Priorização.....</i>	30
2.2.2	Internet das coisas.....	31
2.2.3	Sistema de análise cognitiva.....	33
2.2.3.1	<i>Machine Learning.....</i>	34
2.2.3.1.1	Microsoft Azure.....	36
2.2.3.1.2	Amazon AWS.....	36
2.2.3.1.3	IBM Watson.....	36

2.2.3.1.4	Google Cloud.....	37
2.2.4	Engenharia clínica e gestão de tecnologia em saúde	37
3	METODOLOGIA.....	39
3.1	CATEGORIA OPERACIONAL	40
3.1.1	Primeira etapa: Definição da Situação Problema.....	40
3.1.1.1	<i>Definição da equipe multidisciplinar</i>	41
3.1.1.2	<i>Coleta de dados</i>	41
3.1.1.3	<i>Organização dos dados</i>	42
3.1.1.4	<i>Definição da tecnologia.....</i>	43
3.1.2	Segunda etapa: Parâmetros de Avaliação	43
3.1.3	Terceira etapa: Soluções Ubíquas.....	43
3.2	CATEGORIA DE MONITORAMENTO	44
3.2.1	Camada de Sensoriamento e Módulo de Aquisição de dados	44
3.2.2	Camada de Redes e Processamento	45
3.2.3	Camada de Gerenciamento.....	45
3.2.4	Camada de Padronização.....	45
3.3	CATEGORIA DE DECISÃO.....	46
3.3.1	Gestão em Tempo Real de Tecnologia em Saúde	47
3.3.2	Sistema de Apoio à Tomada de Decisão	48
3.3.3	Sistema de Análise Cognitiva para Gestão de Tecnologia em Saúde.....	48
4	APLICAÇÃO DA METODOLOGIA COMO CASO DE ESTUDO: IMPLEMENTAÇÃO DA PLATAFORMA DE GESTÃO UBÍQUA COM ANÁLISE COGNITIVA EM TECNOLOGIA DA ATENÇÃO PRIMÁRIA À SAÚDE	51
4.1	CATEGORIA OPERACIONAL	51
4.1.1	Primeira etapa: Definição da Situação Problema.....	52
4.1.2	Segunda Etapa Avaliação dos Parâmetros.....	55
4.1.3	Soluções Ubíquas	57
4.2	CATEGORIA DE MONITORAMENTO	57

4.2.1	Camada de Sensoriamento e Módulo de Aquisição de Dados.....	58
4.2.2	Camada de Rede e Processamento.....	61
4.2.3	Camada de Gerenciamento.....	69
4.2.4	Camada de Padronização.....	71
4.3	CATEGORIA DE DECISÃO.....	74
4.3.1	Gestão em Tempo Real de Tecnologia em Saúde	74
4.3.2	Sistema de Apoio à Tomada de Decisão	77
4.3.3	Sistema de Análise Cognitiva para Gestão de Tecnologia em Saúde.....	79
5	CONCLUSÃO.....	87
6	PROPOSTA DE TRABALHOS FUTUROS.....	90
	REFERÊNCIAS.....	91
	APÊNDICE A – Folha para coleta de dados dos equipamentos registrados no sistema de informações do IEB-UFSC na rede de APS do município de Florianópolis.....	99
	APÊNDICE B – Quantidade de OS por equipamento registrados no sistema de informações do IEB-UFSC da rede de Atenção Primária à Saúde do município de Florianópolis.....	100
	APÊNDICE C – Quantidade de equipamentos, média e mediana de equipamento por OS abertas registradas no sistema de informações do IEB-UFSC da rede de Atenção Primária à Saúde do município de Florianópolis.	103
	APÊNDICE D - Matriz de priorização com a mediana de OS aberta por equipamentos e a como fator de multiplicação com o GUT.	106
	APÊNDICE E – Características estruturais do compressor de ar comprimido odontológico	109
	APÊNDICE F – Características técnicas do compressor de ar comprimido odontológico	111
	APÊNDICE G – Folha para coleta e dados do compressor de ar comprimido odontológico.	113

APÊNDICE H – Organização dos tipos de falha do compressor de ar odontológico isento de óleo.....	114
APÊNDICE I – Características dos sensores que compõem o módulo coletor	115
APÊNDICE J – Características dos componentes que compõem o módulo concentrador	119

1 INTRODUÇÃO

A Atenção Primária à Saúde (APS), enquanto proposta descentralizada, desenvolve um papel fundamental no âmbito da saúde pública brasileira e responde a um modelo assistencial que integra ações e estratégias em serviços que atendem as necessidades de saúde da população (BARROS, 2011; BRASIL, 1990).

O avanço tecnológico voltado à APS melhora a qualidade dos serviços públicos de saúde no Brasil e repercute positivamente na qualidade de vida individual e da coletividade (BARROS, 2011), através de estratégias preventivas, diagnósticas e terapêuticas, utilizando infraestrutura de tecnologias de sistemas distribuídos que permitem a existência de cenários ubíquos no âmbito da saúde, com uma infraestrutura compartilhada, uso de dispositivos através dos quais o usuário do sistema de saúde pode ter acesso a essas informações independente da sua localização física e temporal (HAN; LEE; PARK, 2010; SNEHA, 2017).

Tais avanços tecnológicos demandam mais complexidade na gestão e maior necessidade de serviços especializados que atuem no gerenciamento dessa tecnologia, principalmente no âmbito da APS, que utiliza não só tecnologias avançadas, mas também faz uso de tecnologias mais simples dentro de uma rede compartilhada que compõe o cenário de saúde no qual se faz importante novas propostas de gestão, dentre as quais, a Gestão Ubíqua de Tecnologia em Saúde (GARCIA, 2011).

Gestão Ubíqua de Tecnologia em Saúde se refere a um modelo de gestão descentralizada que pode utilizar ferramentas para controle e melhoria da qualidade dos processos tecnológicos, interconectividade, ferramentas de tecnologias cognitivas, de modo a permitir que a gestão seja realizada a partir de qualquer lugar em tempo real e ofereça suporte às ações da engenharia clínica (CASTAÑEDA, 2016).

Os sistemas de análise cognitiva são projetados para dar conta de informações não estruturadas e toda a sua complexidade e imprevisibilidade. Assim, são capazes de decifrar, interpretar, organizar informações e explicá-las. Seu funcionamento se assemelha aos processos cognitivos humanos (AKABANE, 2018).

1.2 PROPOSTA DO TRABALHO

As demandas oriundas do crescimento do parque tecnológico das unidades de APS têm desafiado os modelos de gestão tradicionais devido às exigências das políticas públicas e

modelos assistenciais da saúde primária em constante evolução. Este trabalho apresenta a metodologia de um sistema de Gestão Ubíqua de Tecnologia em Saúde para monitoramento dessa tecnologia através de ferramentas para controle e melhoria da qualidade, interconectividade e análise cognitiva para apoio ao processo de tomada de decisão em Engenharia Clínica (EC).

1.3 OBJETIVOS

1.3.1 Objetivo Geral

Desenvolver uma metodologia de gestão ubíqua de tecnologia em saúde e aplicá-la através da implementação de uma plataforma de monitoramento com uso de interconectividade e sistema de análise cognitiva para apoiar o processo de tomada de decisão em engenharia clínica no ambiente da atenção primária à saúde.

1.3.2 Objetivos Específicos

- Escolher a tecnologia da atenção primária à saúde para aplicar o caso de estudo e definir os parâmetros de monitoramento através de ferramentas para controle e melhoria de qualidade;
- Definir as principais falhas da tecnologia estudada através de ferramentas para controle e melhoria da qualidade;
- Desenvolver uma plataforma de monitoramento em tempo real da tecnologia em saúde escolhida;
- Escolher uma plataforma de tecnologia cognitiva e integrá-la à plataforma de monitoramento;
- Aplicar a metodologia proposta no sistema de atenção primária à saúde através de um caso de estudo.

1.4 JUSTIFICATIVA

O tema está vinculado à EC e envolve a linha de pesquisa de Gestão de Tecnologia voltada para atenção primária à saúde, desenvolvido no Instituto de Engenharia Biomédica- Universidade Federal de Santa Catarina (IEB-UFSC).

Ao longo de anos, o Instituto vem desenvolvendo pesquisas cujo desafio é ampliar o foco da EC, deixando de ser somente uma área de apoio para se tornar parte integrada aos processos de tomada de decisão junto às equipes de assistência em saúde (MORAES, 2007).

Assim, o papel primordial do gerenciamento da tecnologia dentro dos Estabelecimentos Assistenciais à Saúde (EAS), inclusive na atenção primária à saúde, consiste na melhoria contínua dos serviços oferecidos, na utilização adequada dos recursos tecnológicos de maneira integral, durante todo o tempo de vida útil, através de uma correta instalação, manutenção adequada, dimensionamento, treinamento de pessoal para sua utilização e infraestrutura adequada (GARCIA 2011).

O aumento da complexidade da tecnologia em saúde na atenção primária, além de melhorar os serviços de saúde prestados, demandam a necessidade de serviços especializados para o seu gerenciamento e estratégias que melhor se adequem a esses desafios (GARCIA 2011).

Com isso, torna-se relevante o desenvolvimento de uma plataforma de gestão ubíqua de tecnologia em saúde, capaz de proporcionar mais robustez, confiança e segurança aos gestores, operadores e usuários do aparato tecnológico da APS. Essa modalidade de gestão resulta do monitoramento que utiliza a interconectividade e pode ser incrementada com sistemas de análise cognitiva, além disso, é utilizada como ferramenta que auxilia as ações na engenharia clínica. Por essas razões, é uma proposta inovadora de tecnologia em saúde na APS e permite otimizar os modelos de gestão para além dos fatores de tempo e espaço.

1.5 ESTRUTURA DO TRABALHO

Essa dissertação de mestrado está dividida em seis capítulos.

Capítulo 1: Introdução – capítulo com a proposta do trabalho de pesquisa, onde aborda os objetivos gerais e específicos, as justificativas que impulsionaram o desenvolvimento e finalmente a organização desta dissertação.

Capítulo 2: Fundamentação Teórica – capítulo teórico de fundamentação básica da evolução do sistema de saúde - saúde ubíqua, gestão ubíqua de tecnologia em saúde e engenharia clínica e gestão de tecnologia em saúde.

Capítulo 3: Metodologia que norteou a aplicação do caso de estudo.

Capítulo 4: Aplicação da Metodologia: Implementação de uma plataforma de gestão ubíqua com análise cognitiva em tecnologia da atenção primária à saúde – capítulo de

desenvolvimento e aplicação da plataforma de Gestão Ubíqua de Tecnologia em Saúde com resultados e discussão da aplicação da metodologia.

Capítulo 5: Conclusão – são apresentadas as conclusões decorrentes da realização do projeto.

Capítulo 6: Propostas de Trabalho futuros – são sugeridos trabalhos futuros, que visam contribuir para o seguimento desta pesquisa.

Finalmente, encontram-se as referências bibliográficas utilizadas na realização do trabalho e os Apêndices.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 EVOLUÇÃO DO SISTEMA DE SAÚDE – SAÚDE UBÍQUA

No tocante à Saúde Pública no Brasil, a APS tem um papel fundamental no Sistema Único de Saúde (SUS), que responde a um modelo assistencial dentro da proposta de descentralização, através de ações de fortalecimento desse sistema com abrangência e resolutividade ampliadas para a Estratégia de Saúde da Família (ESF), Núcleos de Apoio à Saúde da Família (NASF), Centros de Atenção Psicossocial (CAPS), Unidades de Pronto Atendimento e Apoio Diagnóstico (UPA), Centro de Especialidades Odontológicas (CEO) e Policlínicas de Referência (GARCIA *et al*, 2011; BARROS, 2011, BRASIL, 1990).

Assim, a qualidade dos serviços de saúde no Brasil, principalmente na APS, tem acompanhado a evolução tecnológica. Neste sentido, a computação móvel e tecnologias de sistemas distribuídos permitem a existência de cenários ubíquos no âmbito da saúde, que contam com uma infraestrutura compartilhada a partir da qual possibilita o acesso dos usuários à informação, através de dispositivos móveis, independente da sua localização física e temporal (BUTZEN, 2018; CASTAÑEDA, 2016).

Ou seja, com a evolução tecnológica aplicada na APS, tem-se o aumento e facilidade do compartilhamento de informações e com isso, o alcance de melhores resultados, através da computação ubíqua ou pervasiva que torna possível o uso de novos dispositivos nos cuidados em saúde (GOULART, 2006; CASTAÑEDA, 2011).

Dessa forma, o uso adequado dessas tecnologias pode trazer mais eficiência aos processos de saúde, que resulta em segurança aos usuários, operadores e profissionais com uma dinâmica otimizada (TEIXEIRA; CASSIANI, 2010). Neste contexto, pode-se considerar alguns paradigmas que sustentam a arquitetura dos ambientes de saúde ubíqua, descritos nos tópicos a seguir.

2.1.1 e-health

A revolução digital na área da computação em conjunto com os avanços tecnológicos na saúde trouxe muitas inovações neste âmbito, que originou um termo para agregá-las, *e-health*, que diz respeito às ferramentas e soluções digitais capazes de melhorar os processos de saúde, inclusive na APS (CASTAÑEDA, 2016; GOULART, 2006).

Dessa forma, a *e-health* é entendida como a área em saúde que objetiva integrar informações e serviços através das tecnologias relacionadas e a internet que possibilita o compartilhamento dessas informações. Assim, tem como foco melhorar não só o fluxo de informações, mas os serviços e sistemas de saúde como um todo, otimizando tempo, garantindo eficácia e reduzindo custos (BUTZEN, 2018; FENGOU; MANTAS; LYMBEROPOULOS 2012).

Em suma, *e-health* reúne as tecnologias de informação e comunicação na área da saúde para diagnósticos, tratamento, monitoramento, prevenção e gerenciamento de dados gerados pela área da saúde, além disso, aplica-se ao usuário com objetivo de personalizar o tratamento individual (GEHRING; RACKEBRANDT; IMHOFF, 2018; FISCHER, KRÄMER, 2016)

2.1.2 m-health

O *m-health* é uma fonte de tecnologia da informação que utiliza tecnologias móveis de curta ou longa distância como *smartphones*, dispositivos de monitoramento de pacientes, assistentes pessoais digitais, dentre outras; portando-se como uma alternativa para comunicação entre o médico e paciente, sendo simplista e matemática como móvel (smartphone) + serviço de atendimento médico = *m-Health* (MINIMOL; SHAJI, 2015; WORLD HEALTH ORGANIZATION, 2010).

Com o *m-Health* é possível monitorar continuamente as condições de saúde e acessar informações fora dos hospitais e na casa do paciente, dessa forma, altera a forma de prestação tradicional de assistência à saúde. Assim, é capaz de expandir informações e serviços que promovam a saúde, com cuidados preventivos e gerenciamento de cuidados e de doenças crônicas, melhorando os resultados de saúde individuais e da população (MINIMOL; SHAJI, 2015).

O *e-health* e o *m-health* são tecnologias que se complementam (CASTAÑEDA, 2016), pois o *e-health* se refere à transformações de serviços e documentos tradicionais de saúde em digitais através de computadores, enquanto que o *m-health* possibilita o acesso aos dados dos pacientes através de dispositivos móveis (KAMPMEIJER *et al*, 2016).

2.1.3 u-health

Ubiquitous Healthcare (u-health) ou Saúde Ubíqua é um serviço de assistência em saúde que utiliza tecnologia de informações para possibilitar o acesso a esse serviço a qualquer hora e lugar (JUNG, *et al*, 2013).

Dessa forma, compreende informações referentes à serviços, comunicação e ações que contemplam estratégias preventivas, diagnósticas e terapêuticas para o usuário do sistema de saúde, e utiliza-se da infraestrutura de tecnologia da informação sem fio ou com fio e dispositivos, em ambientes ubíquos inteligentes, onde tais dispositivos exploram o ambiente para descobrir recursos e controlar serviços (HAN; LEE; PARK, 2010; JUNG, *et al*, 2013).

Para isso, utiliza sensores biomédicos capazes de capturar biosinais e informações que são transferidas ao sistema de informações para análise, cujos resultados tornam-se disponíveis ao usuário, numa modalidade de assistência personalizada, que evidencia o crescente interesse em saúde (HAN; LEE; PARK, 2010; SNEHA, 2017).

2.1.4 Saúde 4.0

Os princípios da saúde 4.0 se relaciona com os avanços tecnológicos, principalmente em software, hardware, tecnologias da informação e comunicação em evidência, que favoreceu o desenvolvimento de aplicações em diferentes domínios industriais, sobretudo no setor da saúde com o advento da Indústria 4.0 (MOHAMED; AL-JAROODI, 2019).

A Saúde 4.0 conecta usuários do sistema de saúde, dispositivos médicos, fornecedores de produtos, clínicas, sistemas médicos, hospitais e profissionais, além de outros componentes de saúde, através dos mesmos moldes da Indústria 4.0. Assim, conta com um sistema que pode oferecer suporte com interoperabilidade, orientação a serviços, descentralização, modularidade, capacidade em tempo real e virtualização, e por isso tende a resultar em otimização, melhoria e automação dos processos de saúde (MOHAMED; AL-JAROODI, 2019).

Além disso, utiliza outras tecnologias que contribuem para o desenvolvimento da Saúde 4.0, como: Internet das Coisas (IoT), *Internet of Everything* (IoE), *Internet of Service* (IoS), Sistemas Médicos Ciber-Físicos (CPS médico ou MCPS), *Health Cloud*, , *Health Data Analytics*, *Blockchain*, e no uso de sistemas Ciber-Físicos para conectar o mundo físico e o virtual (GRIGORIADIS *et al*, 2016; MOHAMED; AL-JAROODI, 2019).

Com a implantação desse sistema tem-se um aumento significativo na quantidade de dados coletados nos sistemas de saúde, que contemplam desde a produção de conhecimento para assistências personalizadas, tanto aos usuários quanto aos profissionais de saúde e auxiliam no bem-estar individual ou da população através do desenvolvimento de novos tratamentos, monitoramento e gestão dos recursos de unidades de saúde, em tempo real (SANTOS *et al*, 2018; LABUDA *et al*, 2017; MOHAMED; AL-JAROODI, 2019).

Vale ressaltar, que sua atuação pode ser por tecnologia assistida ou telemedicina. Onde o primeiro se refere a dispositivos, instrumentos, tecnologias, softwares, equipamentos para monitoramento e soluções em saúde, enquanto o segundo contempla áreas e produtos para prestação de serviços remotos em saúde, através de tecnologias de informação e comunicação (SANTOS *et al*, 2018).

2.2 GESTÃO UBÍQUA DE TECNOLOGIA EM SAÚDE

Gestão é o processo pelo qual se pode gerir processos e realizar ações para obtenção de resultados através de planejamento, direção e controle (MORAES, 2007), já o termo ubíquo tem origem no latim e significa que está ao mesmo tempo em toda parte ou onipresente (WEISER, 1991). Dessa forma, pode-se entender por gestão ubíqua um modelo de gestão remota que utiliza uma plataforma de monitoramento a partir da qual se pode acessar informações e gerenciar dados da tecnologia em qualquer lugar aonde se estiver através da interconectividade.

Trata-se de um modelo de gestão descentralizada voltado para tecnologia em saúde com o uso de ferramentas para controle e melhoria da qualidade (MACÊDO *et al*, 2001), de modo a permitir que a gestão seja realizada por monitoramento a partir de qualquer lugar através de uma plataforma ubíqua (CASTAÑEDA, 2016), que auxilie na tomada de decisão com a opção de utilizar análise cognitiva como aporte a esse processo (ANDRIOPOULOU; BIRKOS; LYMBEROPOULOS, 2013). Os tópicos a seguir tratam dos processos que viabilizam o desenvolvimento de um modelo de gestão ubíqua de tecnologia em saúde.

2.2.1 Ferramentas para controle e melhoria da qualidade na gestão de tecnologia em saúde

Trata-se de ferramentas estatísticas que servem para contribuir nos sistemas de gestão com a finalidade de melhorar produtos, serviços e processos. Para isso, se utiliza de técnicas para analisar, medir, mensurar, definir e solucionar problemas e demandas que possam ter interferências negativas nos processos de trabalho (MAGALHÃES, 2015).

As Ferramentas de Qualidade (FQ) lidam principalmente com dados numéricos e quanto maior for o volume destes, maior será a necessidade de empregá-las para o controle de processos e melhorar seus resultados (CARPINETTI, 2016). A escolha de uma FQ deve estar

de acordo com a demanda ou problema para o qual se busca uma solução. A seguir são citadas algumas utilizadas neste estudo, dentre elas:

2.2.1.1 Folha de Verificação

É uma ferramenta usada no planejamento da coleta de dados para análises futuras. Geralmente é realizada de forma simplificada e organizada e se apresenta como formulários, tabelas, planilhas (CARPINETTI, 2016) para facilitar a coleta e análise dos dados, economizar tempo e repetições desnecessárias, pois são planejados e podem permitir uma percepção mais apurada e rápida da realidade observada (MAGALHÃES, 2015).

A Folha de Verificação é flexível e se adequa às necessidades específicas da coleta e do usuário, tanto no que diz respeito à sua estruturação quanto na utilização e interpretação. Nela são registrados dados sobre o que é observado, período de coleta, amplitude dos dados, média, dentre outros (CARPINETTI, 2016; MAGALHÃES, 2015)

2.2.1.2 Diagrama de Pareto

O Diagrama de Pareto é uma das ferramentas preferidas em qualidade, devido a sua objetividade na análise e priorização dos fatores em relação ao problema. Permite aos seus usuários analisar, classificar e identificar a causa básica do problema, as condições em que eles ocorrem, priorizar soluções de maior importância e monitorá-los o êxito, podendo ser utilizado em vários processos tecnológicos (DANIEL; MURBACK, 2014; MAGALHÃES, 2015).

Os problemas identificados pelo Diagrama de Pareto com maior importância devem ser corrigidos primeiramente, após solucionar o primeiro problema, o segundo se torna mais importante, logo permite dedicar a maioria dos esforços na solução dos problemas mais importantes permitindo o uso adequado dos recursos na busca da melhoria da qualidade e dos processos tecnológicos (SELEMER E STADLER, 2010).

Trata-se de um diagrama de barras verticais, cujas informações são visualizadas de acordo com a ordem de importância dos problemas, causas, dentre outros. Tem como princípio, que um pequeno número de causas é responsável por uma grande quantidade de problemas, portanto, a partir da identificação de algumas dessas causas seja possível solucionar a maior parte dos problemas, pois ele permite identificar o impacto que o problema representa para o

todo, procurando as principais causas dos problemas e estabelecendo a prioridade das soluções (CARPINETTI, 2016; MAGALHÃES, 2015).

O Diagrama de Pareto pode ser utilizado em diversas aplicações, dentre elas (SALES, 2013):

- Para realizar uma análise dos resultados de antes e depois da alteração do processo;
- Quando tem uma necessidade de melhoria e precisa ser identificado um determinado problema;
- Analisar diferentes tipos dados que influenciam no processo tecnológico;
- Quando os dados são organizados em categorias e cada classificação dessa categoria é importante.

2.2.1.3 Matriz de Priorização

A matriz de priorização ou matriz GUT (Gravidade, Urgência e Tendência) serve para relacionar fatores e critérios para determinar a prioridade de ações de melhorias ou solução de problemas, bem como na análise de riscos, ocorrência e detecção de falhas. Os problemas são descritos de acordo com a prioridade de maneira ordenada, e analisados com base na Gravidade (G), Urgência (U) e Tendência (T) (CARPINETTI, 2016, RAMOS; SOUZA; LIMA, 2007), conforme a Quadro 1:

Quadro 1 – Referências para montar a matriz GUT

Peso	G - Gravidade Consequência se nada for feito	U - Urgência Prazo para uma tomada de ação	T – Tendência Proporção do problema no futuro
5	Extremamente grave	Precisa de ação imediata	Se nada for feito, pode piorar rapidamente
4	Muito grave	Muito Urgente	Pode piorar a curto prazo
3	Graves	Urgente, merece atenção no curto prazo	Pode piorar a médio prazo
2	Pouco graves	Pouco urgente	Pode a longo prazo
1	Sem gravidade	Pode esperar	Não vai piorar ou mudar

Fonte: RAMOS; SOUZA; LIMA (2007)

No diagrama, os valores obtidos na matriz GUT são multiplicados, para se obter um peso total para cada problema ou fator de risco analisados, assim os problemas que obtiverem

maior pontuação podem ser tratados como prioridade (CARPINETTI, 2016, RAMOS; SOUZA; LIMA, 2007).

2.2.2 Internet das coisas

Internet das coisas ou *Internet of Things* (IoT) pode ser entendida como a comunicação e conectividade de objetos diversos, integralizados e associados para reunir e transmitir dados, trocar informações, a fim de atingir um objetivo comum por meio de endereçamento único e protocolo de comunicação padronizado, de modo a permitir que as “coisas” se conectem a qualquer hora e em qualquer lugar (GIUSTO, 2010; ATZORI, 2010; JIANG, 2015). Assim, é simplista e matemática: serviço de *Internet* + Objeto Físico + Atuadores, Sensores e Controladores = IoT (MCEWEN; CASSIMALLY, 2013).

Além da capacidade de executar funções normais, tal como identificar informações do ambiente, a IoT também é capaz de tomar decisões com a mínima ou sem nenhuma intervenção humana. Por isso, novas abordagens podem ser utilizadas para aumentar sua eficiência e flexibilidade de adaptação às redes (LUONG, 2016).

Outra característica se refere a interconectividade, ou seja, tudo pode ser conectado com a infraestrutura universal de comunicação e informação, as mudanças dinâmicas que alteram o status dos dispositivos de ligado para desligado, ativado para desativado e o contexto do dispositivo como a localização e velocidade, cuja ligação interconectada permite a troca de dados significativos e resulta em algum benefício desejado (SECTOR; ITU, 2016).

Para isso, a IoT deve ser compreendida como um substrato de infraestrutura global que ajuda a conectar objetos explorando dados capturados e suas capacidades de comunicação, na qual, cada objeto possui uma identificação única e sua representação virtual como base para a independência no desenvolvimento de serviços e aplicações. Isso acontece mediante a captura de dados volumosos e autônomos, conectividade de rede e interoperabilidade (SARKAR, *et al* 2014).

Vale ressaltar que a interoperabilidade se refere ao trabalho conjunto de dois ou mais sistemas ou atores diversos, resultando em trocas de informações que melhorem seus processos e atividades. Assim, além das vantagens da utilização das soluções heterogêneas, também pode oferecer suporte para serviços e tecnologias em saúde (BENSON, 2012; LEITE, 2017).

Outro aspecto importante sobre a IoT é o seu Modelo de Arquitetura de Referência (ARM) que se deriva em dois: Modelo Funcional, conhecido como modelo de camadas e

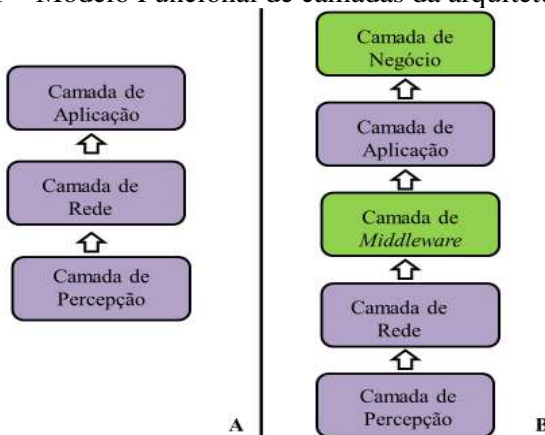
Modelo de Referência, subdividido em quatro partes: Informação, Domínio, Segurança e de Comunicação (BASSI *et al*, 2013). Neste trabalho, o monitoramento da tecnologia em saúde se assemelha à arquitetura IoT no modelo funcional, descrita nos tópicos seguintes.

O modelo funcional ou modelo de camadas apresenta duas versões da arquitetura da IoT, uma dividida em três camadas: de percepção, de rede e de aplicação (WU *et al*, 2010) e outra dividida em cinco camadas: de percepção, de rede, *middleware*, de aplicação e de negócio. Ambas são demonstradas na Figura 1 (KHAN 2012; AL-FUQAHA 2015; LEITE, 2017).

A camada de percepção também chamada de camada de dispositivo ou de sensoriamento é descrita como uma interação direta entre os dispositivos físicos e seus componentes com a rede de comunicação. Tem o objetivo de juntar, identificar, medir, carregar e coletar informações (SANTOS *et al*, 2016; KHAN, 2012; WU *et al*, 2010).

A camada de rede ou camada de transmissão tem a função de transmitir e processar com segurança as informações recebidas da camada de percepção. Além disso, controla a conectividade da rede, como funções de controle e recursos de transporte, contabilidade, autenticação, autorização e gestão da mobilidade. As informações vêm de tecnologias em comunicação que podem ser com ou sem fio e o protocolo IPV6 é usado para o endereçamento único de cada objeto (SANTOS *et al*, 2016; SECTOR; ITU 2016; KHAN, 2012).

Figura 1 – Modelo Funcional de camadas da arquitetura IoT.



Legenda: Modelos funcionais das camadas da IoT-A. A) três camadas; B) cinco camadas.

Fonte: KHAN (2012); AL-FUQAHA (2015)

Por sua vez, a arquitetura IoT dividida em 5 camadas acrescenta a camada de *Middleware* ou de processamento, que analisa, processa e armazena as informações recebidas da camada de rede em um banco de dados. Sua criação foi motivada pela grande quantidade de objetos passíveis de conexão à IoT, todos com informações carregadas, o que dificulta o armazenamento e o processamento dos dados (WU *et al*, 2010; KHAN 2010).

A terceira e última camada, para os que dividem a Arquitetura da *Internet of Things* (IoT-A) em 3 partes, ou a quarta camada para os que dividem em cinco, é a camada de aplicação, responsável pela gestão global das aplicações da IoT, recebe e realiza um *backup* dos dados provenientes da camada de percepção, analisando-os através de inteligência computacional, reconhecimento de padrões, sistemas de informações e computação em nuvem. (SONG *et al*, 2015).

A camadas de negócio ou de gerenciamento e a quinta camada para a divisão da IoT em cinco partes é responsável por gerenciar todas as atividades e serviços da IoT, inclusive pelo monitoramento e gestão de todas as camadas anteriores (AL-FUQAHA, 2015; KHAN, 2012; WU *et al*, 2010).

Vale ressaltar que o monitoramento da tecnologia em saúde neste estudo, se baseia na arquitetura IoT em cinco camadas. Esta arquitetura apresenta o potencial para permitir o monitoramento e controle remoto de uma ampla rede de dispositivos interconectados em um sistema complexo. Nesse contexto o monitoramento exige uma estrutura de hardware e software, tais como redes sem fio e sensores, *Front End* (FE) e sistema de precisão na tomada de decisões com capacidade de aprendizagem, para atender as demandas do armazenamento, transferência, processamento e gerenciamento de informações ou dados (BARROS, 2011).

2.2.3 Sistema de análise cognitiva

Os sistemas de análise cognitiva são probabilísticos, isto é, são projetados para darem conta de informações não estruturadas em toda a sua complexibilidade e imprevisibilidade. Desse modo, são capazes de decifrar, interpretar, organizar informações e explicá-las. No entanto, não oferecem respostas definitivas, pois o nível de confiança é atribuído de acordo com a resposta mais adequada a cada situação (AKABANE, 2018).

Nesse contexto, é importante entender o conceito de computação cognitiva que vem da combinação da ciência cognitiva - estudo da mente ou inteligência humana e da ciência da computação, ciência que estuda as técnicas, metodologias e instrumentos computacionais; dessa forma, os resultados da computação cognitiva tem impacto ao longo da vida nas áreas da saúde, negócio, cidades inteligentes, dentre outros (MARR, 2016).

Já, as tecnologias cognitivas são uma evolução da computação e funcionam de maneira similar aos processos de pensamento humano, cujo, raciocínio, aprendizagem e a inferência humana constituem um dos mais sofisticados sistemas de pensamento existente, que são

potencializados em volume de dados, informações e velocidade de processamento pelas tecnologias cognitivas (AKABANE, 2018).

Estas são necessárias porque abrangem grande variedade de tecnologias com uma amplitude de fontes que compartilham uma mesma solução, por isso podem realizar tarefas típicas da inteligência humana. É nesse contexto que se inclui o Aprendizado de Máquina (AM) ou *Machine Learning* (ML) enquanto produto da inteligência artificial (AKABANE, 2018), abordado neste trabalho como ferramenta cognitiva para o seu desenvolvimento do estudo.

2.2.3.1 *Machine Learning*

Como parte da inteligência artificial, o *Machine Learning* (ML) aplica algoritmos de maneira sistemática entre dados e informações, ou seja, processa um conjunto de dados e extrai um modelo capaz de explicá-los ou representá-los, bem como pode explicar ou representar um novo dado. Dessa forma, permite que os sistemas computacionais melhorem o seu desempenho em tarefas sem que necessariamente precisem seguir instruções programadas (IDOINE *et al*, 2018; BRUNIALTI, 2015).

Para isso, se utiliza das redes neurais enquanto modelos computacionais que imitam as funções do cérebro humano, com elementos que representam neurônios e suas interconexões; assim, ensinam os computadores a processarem as suas tarefas de forma mais eficiente (AKABANE, 2018).

Os métodos de ML são conhecidos como uma divisão da computação e estatística que reúnem uma série de métodos com dois objetivos principais. O primeiro é o desempenho preditivo de modelos e o segundo é a automatização do processo de modelagem das bases de dados observados, através do aprendizado dos dados (BRUNIALTI, 2015). Este aprendizado consiste num sistema que toma decisões baseadas em experiências acumuladas, dividindo-se em aprendizado supervisionado, semi-supervisionado e não-supervisionado (BATISTA, 2004).

O foco deste trabalho é o aprendizado supervisionado, no qual os algoritmos precisam de informações de entrada e saída necessariamente, além de *feedback* sobre a precisão da previsão no processo de treinamento, ou seja, utilizam o conhecimento adquirido dos dados anteriores e atuais para prever eventos, com o objetivo de produzir saídas corretas para novas entradas não apresentadas previamente (SARAVANAN; SUJATHA, 2018).

No aprendizado não supervisionado não é requerido nenhum processo de treinamento, pois o algoritmo aprende a representar as entradas submetidas segundo uma medida de qualidade (AWAD; KHAANNA, 2013; SARAVANAN; SUJATHA, 2018). Já o semi-

supervisionado utiliza dados rotulados e não rotulados em maior quantidade, com o objetivo de entender como essa combinação pode alterar o comportamento do aprendizado e projetar algoritmos que melhorem sua precisão (AWAD; KHAANNA, 2013; SARAVANAN; SUJATHA, 2018).

Além dos modos de aprendizagem, programas que usam ML podem variar de acordo com as técnicas e os algoritmos que são usados em cada código. As técnicas representam as funções que o código deve cumprir. Já os algoritmos representam a maneira que tal função pode desempenhar o código. A seguir, se encontram algumas das técnicas usadas e seus algoritmos:

- *Classification*: usada quando se deseja classificar um tipo de dado, como por exemplo, detectar se um *e-mail* é spam. Tem como algoritmos: *Naive Bayes*, *Decision Trees*, *Decision Forest*, *Decision Jungle*, *Decision Forest*, *Logistic Regression*, *Neural Networks*, entre outros (NOGARE; ZAVASCHI, 2016).

- *Regression*: usada quando o objetivo é prever um valor, como por exemplo, qual será o preço de determinada ação. Tem como algoritmos: *Linear Regression*, *Regression Trees*, dentre outros (NOGARE; ZAVASCHI, 2016).

- *Clustering*: usada quando se deseja organizar os dados em grupos a fim de detectar padrões, como por exemplo, no caso de recomendação de produtos. Tem como algoritmos: *K-Means Clustering*, *Mean-Shift Clustering*, *Density-Based Spatial Clustering of Applications With Noise*, dentre outros (NOGARE; ZAVASCHI, 2016).

- *Anomaly Detection*: usada na detecção de anomalias nos dados, como no caso de fraudes em bancos. Tem como algoritmos: *Classification and Regression Trees*, *exponential smoothing*, entre outros (NOGARE; ZAVASCHI, 2016).

O armazenamento de dados e o processamento dos códigos de inteligência artificial podem ser uma tarefa difícil para os computadores atuais, por isso, companhias disponibilizam plataformas online para resolver esse problema e facilitar a criação de programas com ML, conhecidas como *Machine Learning as a Service* (MLaaS). Nesse processo, chamado *cloud computing*, os dados são enviados para a nuvem e o processamento delegado a supercomputadores (PINTO; SILVA, 2018). Dentre as principais plataformas de MLaaS estão: *Google Cloud*, *Amazon AWS*, *IBM Watson*, *Microsoft Azure*.

2.2.3.1.1 Microsoft Azure

O *Azure Machine Learning Studio* (ML Studio) da Microsoft Azure tem disponível muitos algoritmos de aprendizado de máquina, além de módulos que ajudam na entrada, saída, preparação e visualização de dados (PINTO; SILVA, 2018, 2013; DOCUMENTAÇÃO AZURE, 2018). A plataforma *Azure Machine Learning* é produzida para cientistas de dados e oferece espaço para executar tarefas como exploração de dados, escolha de métodos, além de validação de pré processamento (BRUNIALTI *et al*, 2015; MICROSOFT, 2019).

O *ML Studio* tem uma interface gráfica para desenvolver o programa, com várias soluções disponíveis pela comunidade como também tem integração com os demais produtos da *Microsoft*. A plataforma disponibiliza quatro algoritmos *multiclasses* supervisionados e usados no modelo, dentre eles: *decision forest*, que faz a classificação pela combinação de árvores de decisão (TONG, *et al*, 2003), *decision jungle*, uma extensão do algoritmo de *decision forest* (SHOTTON, 2013), *logistic regression*, que classifica através de uma curva logística (KLEINBAUM, 2002), e *neural networks*, que faz a análise em camadas (GURESEN; KAYAKUTLU, 2011).

2.2.3.1.2 Amazon AWS

A plataforma *Amazon Machine Learning* da *Amazon Web Service* (AWS) recomendada para análise preditiva é automatizada, por si só trata os dados e seleciona o algoritmo, por isso, é indicada para operações rápidas e não suporta métodos de aprendizado não supervisionados (YEUNG, 2019).

A plataforma *SageMaker* é uma outra ferramenta da AWS que possui alguns algoritmos prontos e permite utilizar outros *frameworks*, que integra processos de análises de grandes dados de maneira eficiente (YEUNG, 2019).

2.2.3.1.3 IBM Watson

A *International Business Machines* (IBM) sugere uma única plataforma de aprendizado de máquina, a *Watson ML*, um supercomputador com duas abordagens, uma automatizada e outra manual. A primeira requer pouco conhecimento prévio, pois possui um modelo que faz a maior parte do processo, e a segunda abordagem pode utilizar outros

frameworks e linguagens de programação. Além disso, a *Watson ML* possui uma interface gráfica de blocos que facilita sua utilização (IBM, 2018)

2.2.3.1.4 Google Cloud

Google Cloud semelhante à AWS, oferece serviços de aprendizado de máquina em dois níveis: o *Google Cloud Machine Learning* para especialistas em dados de tecnologia e a plataforma *Cloud AutoML*. Esta última possui interface gráfica com modelos de treinamento em dados estruturados. Já na plataforma *Google Cloud Machine Learning* é necessário programar o código de ML e pode-se utilizar *frameworks*, principalmente o *TensorFlow* e linguagem de programação que geralmente é a *Python* (GOOGLE, 2019).

No Quadro 2, encontram-se os serviços de aprendizado de máquina na nuvem e plataformas para modelagem utilizadas por cada plataforma de ML.

Quadro 2 – Serviços de aprendizado de máquina na nuvem.

Técnicas de ML	<i>Amazon ML</i>	<i>Cloud AutoML</i>	<i>IBM Watson ML Model Builder</i>	<i>Microsoft Azure ML Studio</i>
<i>Classification</i>	V	V	V	V
<i>Regression</i>	V	V	V	V
<i>Clustering</i>	V	X	X	V
<i>Anomaly detection</i>	X	X	X	V

Legenda: V: O serviço possui e X: O serviço não possui.

Fonte: MICROSOFT (2019); IBM (2018); GOOGLE (2019); YEUNG (2019).

2.2.4 Engenharia clínica e gestão de tecnologia em saúde

A engenharia clínica é o ramo da engenharia biomédica que desenvolve atividades e ferramentas para Gestão da Tecnologia Médico-Hospitalar (BRONZINO, 2004). Dentre as suas atribuições pode-se reconhecer o desenvolvimento e emprego de soluções, gestão e gerenciamento de parques tecnológicos, desenvolvimento de ferramentas e metodologias que auxiliam os EAS (MCCARTHY *et al.*, 2014).

As atividades desenvolvidas na área da saúde pela engenharia clínica compreendem as ações em nível macro que diz respeito à Gestão da Tecnologia Médico-Hospitalar (GTMH) e

em nível micro que se refere ao gerenciamento da Tecnologia Médico-Hospitalar (gTMH) (SIGNORI, 2008).

A importância da gestão tecnológica no âmbito da engenharia clínica se destaca e se amplia em face da velocidade do desenvolvimento e aperfeiçoamento dos recursos tecnológicos presentes no contexto da saúde (GARCIA, 2011), não apenas para tecnologias avançadas, mas também no contexto da atenção primária à saúde com o maior uso de tecnologias simples.

Uma gestão eficiente das tecnologias em saúde proporciona um senso de confiança na equipe durante operações e execuções de tratamentos. E na perspectiva da segurança em saúde, os dispositivos utilizados são capazes de trabalhar continuamente, de forma precisa, estável, direta ou indireta reduzindo os erros técnicos e garantindo a integridade do usuário do sistema de saúde (CHU; LEE; WU, 2012).

Junto à gestão, o monitoramento de tecnologia é definido pela Política Nacional de Gestão de Tecnologias em Saúde como um processo sistêmico e constante de acompanhamento do uso da tecnologia, visando à obtenção de informações para contribuir na tomada de decisão, relativos à abandono, substituições ou à ampliação de cobertura (BRASIL, 2010).

Nesta perspectiva da gestão em saúde, o conceito de gTMH está vinculado à implementação ou operacionalização das melhorias identificadas, do ponto de vista de “como fazer” da GTMH (MORAES, 2007).

Assim, o papel primordial nas tecnologias em saúde, inclusive na atenção primária, consiste na melhoria contínua dos serviços oferecidos, na utilização adequada dos recursos tecnológicos de maneira integral, durante todo o tempo de vida útil, através da correta instalação, manutenção adequada, dimensionamento, treinamento de pessoal para sua utilização e infraestrutura adequada (GARCIA, 2011).

Neste contexto, a proposta do gerenciamento ubíquo pode ser inovadora para a gestão da tecnologia médico hospitalar por permitir otimizar modelos de gestão para além dos fatores de tempo e espaço.

3 METODOLOGIA

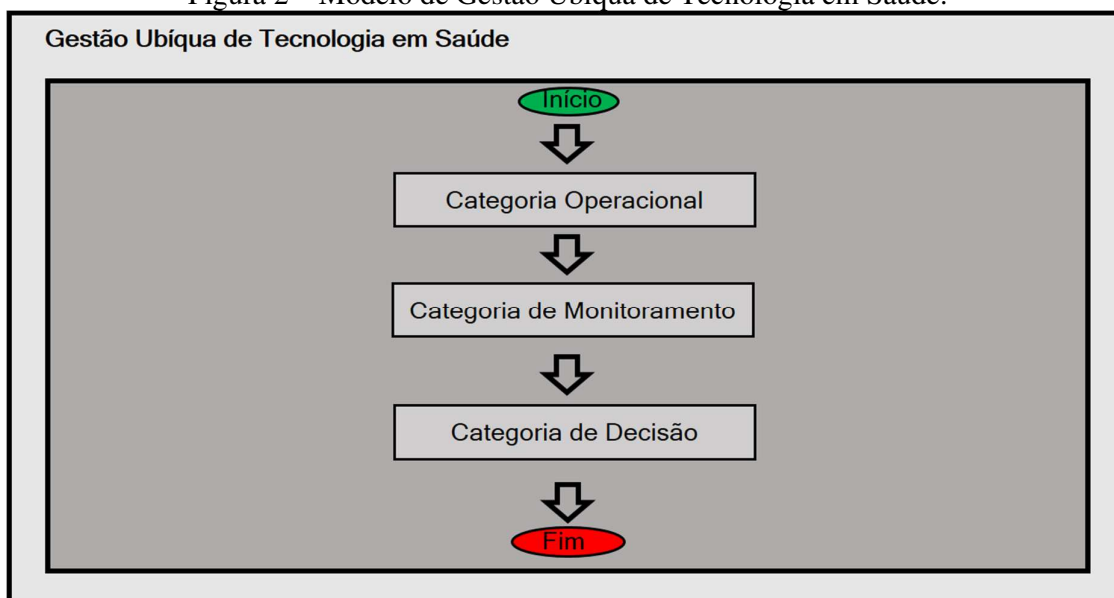
O gerenciamento da tecnologia em saúde tem exigido o desenvolvimento de plataformas que melhor se adequem aos seus desafios, com maior capacidade de gerenciamento e resolutividade dos problemas que afetam esse tipo de tecnologia. Dessa forma, proporciona mais robustez ao sistema de tecnologia em saúde e maior alcance ao público que utiliza o sistema de atenção primária à saúde. Neste contexto, esta metodologia foi desenvolvida para ser aplicada em um caso de estudo de gestão ubíqua em tecnologia de saúde.

Trata-se de um modelo de gestão descentralizada voltado para tecnologia em saúde, de modo a permitir que a gestão seja realizada por monitoramento a partir de qualquer lugar através de interconectividade numa plataforma ubíqua que utiliza análise cognitiva como suporte na tomada de decisões.

O método elaborado consiste no desenvolvimento de um sistema de Gestão Ubíqua de Tecnologia em Saúde para o gerenciamento de dados, que se baseia no uso de ferramentas para controle e melhoria da qualidade na gestão de tecnologia em saúde tais como: diagrama de priorização, diagrama de Pareto, também IoT e ML.

Esse método compreende três categorias principais: Operacional, Monitoramento e Decisão (GARCIA *et al*, 2018), conforme são detalhadas nas próximas sessões e demonstradas na Figura 2.

Figura 2 – Modelo de Gestão Ubíqua de Tecnologia em Saúde.



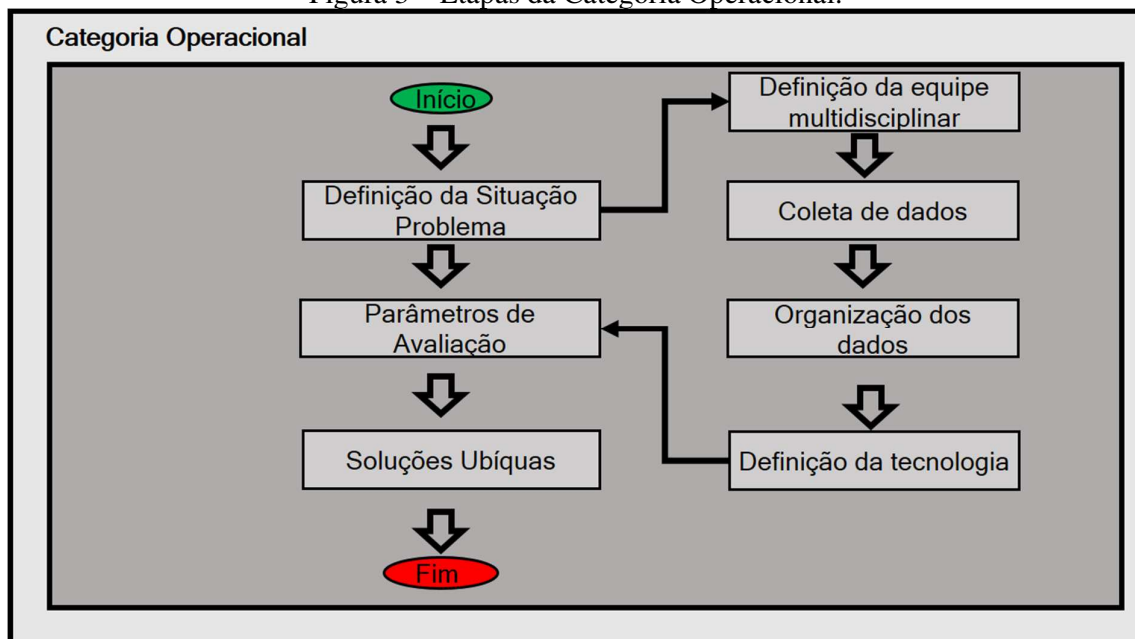
Fonte: Garcia *et al* (2018).

3.1 CATEGORIA OPERACIONAL

Esta categoria tem como objetivo, de modo que as informações encontradas possam ser aplicadas nas categorias de monitoramento e de decisão.

A categoria operacional divide-se em três etapas: definição da situação problema, parâmetros de avaliação e soluções ubíquas (SOARES FILHO; MARTINS; GARCIA; 2019), conforme mostra a Figura 3.

Figura 3 – Etapas da Categoria Operacional.

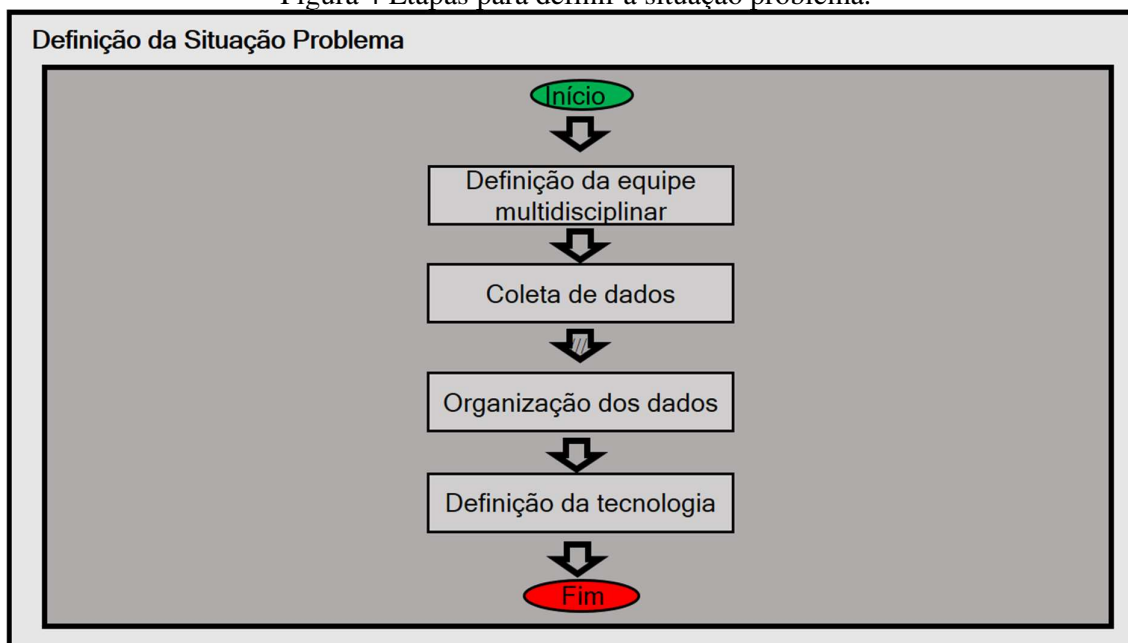


Fonte: Soares Filho; Garcia; Martins (2019).

3.1.1 Primeira etapa: Definição da Situação Problema

Essa etapa é a base para o desenvolvimento do projeto, onde define-se a equipe multidisciplinar, coleta, organiza os dados e define a tecnologia de estudo, através da matriz de priorização e diagrama de Pareto, conforme mostra a Figura 4. Assim, a equipe precisa coletar o máximo de informações possíveis em relação às tecnologias de saúde da APS, organizá-las e esgotar as possibilidades de evidências de falhas encontradas.

Figura 4 Etapas para definir a situação problema.



Fonte: Soares Filho; Garcia; Martins (2019).

3.1.1.1 Definição da equipe multidisciplinar

A equipe multidisciplinar deve ser composta de pessoas de diferentes áreas, com conhecimento relativo em gestão, gerenciamento e planejamento de tecnologia em saúde, que tenham interesse no objetivo em estudo, sejam inovadoras para ideias, analisadoras e implementadoras para realizar tarefas. É importante evitar que a análise seja tendenciosa, além disso, a equipe deve ter conhecimento sobre aplicações de ferramentas de controle e melhoria da qualidade, e caso algum membro não possua, é importante participar de capacitações sobre o tema.

3.1.1.2 Coleta de dados

A coleta de dados ou informações sobre as tecnologias deve contemplar os itens listados a seguir (CARPINETTI, 2016), não necessariamente deve-se utilizar todos os itens ou a sequência indicada, apenas os essenciais aos objetivos da coleta. Neste estudo, foi desenvolvido um modelo para coleta de dados no Sistema de Informações do IEB-UFSC (SI-IEB-UFSC).

- Coletar as evidências no sistema de informações, tais como as falhas ocorridas, peças que foram trocadas, períodos de parada, motivos das solicitações dos serviços realizados, manutenções anteriores, dentre outros quesitos;
- Realizar entrevistas com os operadores no intuito de compreender a rotina do uso dos equipamentos, observar se o manuseio está sendo realizado de acordo com o Procedimento Operacional Padrão (POP) estabelecido pela instituição regulamentadora, fabricantes ou metodologias desenvolvidas pelas instituições;
- Realizar pesquisas nos manuais técnicos fornecidos pelas empresas e pela Agência Nacional de Vigilância Sanitária (ANVISA) com objetivo de identificar desenhos, estrutura necessária para instalação e manuseio do equipamento;
- Realizar visitas no local para determinar as condições de funcionamento da tecnologia em saúde, como por exemplo: tempo de trabalho, temperatura, intensidade, tensão, acessórios, umidade do ambiente, vibração, pressão, lubrificação, procedimentos operacionais, corrosão, dentre outros;
- Comparar se a operação do equipamento está de acordo com as condições apresentadas no projeto, observar variáveis que poderiam ter um efeito sobre o funcionamento da tecnologia;
- Definir participantes da coleta de dados, treiná-los e acompanhá-los;
- Determinar o tamanho da amostra, equipamento utilizado para coleta, período e frequência da falha;
- Registrar todas as tecnologias disponíveis cadastrados no sistema de informação.

3.1.1.3 Organização dos dados

A organização dos dados coletados facilita a compreensão e a utilização das ferramentas para controle e melhoria da qualidade no processo de definição da tecnologia. Para isso, um dos métodos pode ser organizá-los de forma decrescente pela frequência de falha ou importância, conforme as observações dos registros; dados históricos; reparos anteriores; condições das operações; bases de dados; gráficos de processos; instrumentos de medição; características dos danos/falhas, tempo de parada da tecnologia e a quantidade de OS abertas de todos os equipamentos cadastrados no sistema de informações, dentre outros.

3.1.1.4 Definição da tecnologia

Dentre as possibilidades para definir a tecnologia a ser estudada, pode-se fazer o levantamento da quantidade de equipamentos com maior índice de falha, sejam elas ocasionados por fator humano, do próprio equipamento ou infraestrutura, com base no modelo de ¹três domínios, e então priorizar a escolha da tecnologia.

Esta seleção pode ser realizada utilizando métodos como matriz de priorização ou diagrama de Pareto, porém a definição da tecnologia não necessariamente precisa seguir a um padrão preestabelecido, pode-se escolher os critérios que se adequem aos objetivos de cada estudo. É importante conduzir uma coleta de dados adequada para não construir um quadro distorcido da situação real, evitar interpretações inapropriadas e ações inadequadas.

3.1.2 Segunda etapa: Parâmetros de Avaliação

É necessário realizar uma nova coleta de dados, sobre a tecnologia escolhida, considerando os parâmetros a serem estudados que se baseiam nos tipos de falhas de tecnologias em saúde, bem como na sua quantidade, priorização, frequência e a prevenção de efeitos adversos ou falhas, que podem ser definidas a partir do uso de ferramentas para controle e melhoria da qualidade, tais como: matriz de priorização diagrama de Pareto, diagrama de Ishikawa, entre outras. Com isso, é possível identificar quais parâmetros devem ser monitorados como por exemplo: temperatura, umidade, pressão, vibração, corrente, dentre outros, referentes ao equipamento.

3.1.3 Terceira etapa: Soluções Ubíquas

Com a definição dos parâmetros a serem analisados, a equipe especializada pode montar um plano de ação onde serão definidos quais sensores, câmeras, GPS, RFID, microfones, dentre outros dispositivos, devem ser instalados de maneira não invasiva na tecnologia para monitorar suas atividades. Caso não seja possível monitorar algum parâmetro, é necessário desenvolver estratégias que auxiliem num resultado positivo.

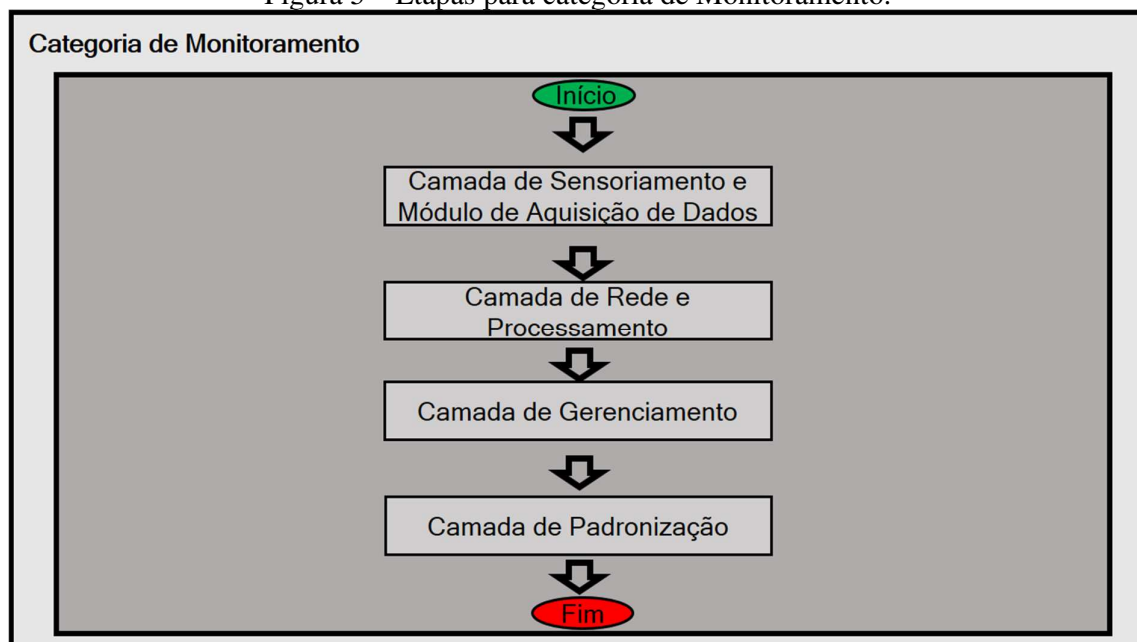
¹Modelo de gestão de tecnologia médico-hospitalar (GTMH), desenvolvido e aplicado no IEB-UFSC, no qual a Engenharia Clínica visa colaborar com o desenvolvimento de metodologias voltadas para garantir mais confiabilidade, efetividade e segurança, nos processos tecnológicos avaliados (SANTOS; SOUZA GARCIA, 2011).

Nesta etapa é possível determinar soluções ubíquas para desenvolver uma plataforma de monitoramento, na qual pode-se realizar a predição dos possíveis problemas. Com a ubiquidade é possível que esses dispositivos se comuniquem entre si, independente da sua localização (MISHRA; NAGPAL; SINGH, 2015).

3.2 CATEGORIA DE MONITORAMENTO

Como parte responsável pela coleta, envio, processamento, padronização dos parâmetros e integração dos dados, a categoria de monitoramento apresenta uma arquitetura semelhante à IoT, dividida em camadas com funções específicas: Camada de Sensoriamento; Camada de Rede e Processamento; Camada de Gerenciamento e Camada de Padronização. Conforme consta na Figura 5.

Figura 5 – Etapas para categoria de Monitoramento.



Fonte: Fonseca; Rosa; Garcia (2017); Santos; Rosa; Garcia (2017).

3.2.1 Camada de Sensoriamento e Módulo de Aquisição de dados

Nessa camada são escolhidos os sensores responsáveis pela captação dos dados com o objetivo juntar, identificar, medir e coletar informações, promovendo a interação direta entre os dispositivos físicos e a rede de comunicação. Os sensores são escolhidos baseados nos parâmetros, soluções ubíquas e devem apresentar requisitos mínimos para captação dos dados,

que são previamente definidos na categoria operacional, ou seja, é preciso avaliar o tipo do sensor com sua funcionalidade, e o conjunto destes compõem o módulo coletor.

3.2.2 Camada de Redes e Processamento

Nesta camada os dados captados pelos sensores devem ser enviados para um microcomputador (computador de placa única de tamanho reduzido) que processa e organiza as informações e as envia para o *database*. Ou seja, esta camada é responsável pela transmissão, análise, processamento e armazenamento seguro dos dados recebidos da camada de sensoriamento. A *database*, por sua vez, é uma técnica de armazenamento que pode ser utilizada nesta metodologia a partir do desenvolvimento de um modelo conceitual, lógico e físico.

A transmissão desses dados pode ser feita com recurso de tecnologias em comunicação com ou sem fio, como *bluetooth*, Padrão Terceira Geração (3G), *Wireless Local Area Network* (WLAN), *Transmission Control Protocol Internet Protocol* (TCP/IP), infravermelho, *ZigBee*, *Long Term Evolution* (LTE), dentre outras (SANTOS *et al*, 2016).

3.2.3 Camada de Gerenciamento

Esta camada contempla a construção do modelo de gestão dos dados, que pode ser feito através de gráficos e fluxogramas, bem como é encarregada pelo monitoramento de todas as camadas anteriores.

Nessa camada é desenvolvida uma *Front End* que gerencia todas as informações do projeto, ou seja, faz a gestão global das aplicações do sistema, recebe e realiza um backup dos dados provenientes da camada de sensoriamento, passados pela camada de rede e processamento e ficam disponíveis para serem analisados (BARROS, 2011). Assim, pode apoiar futuras ações e estratégias de gestão de tecnologia em saúde.

3.2.4 Camada de Padronização

Com o objetivo de validar os sensores, esta camada é responsável por verificar se as ações operacionais definidas no sistema, com base nos parâmetros apresentados no

monitoramento, estão de acordo com o padrão definido pelos valores encontrados. Geralmente esses valores estão disponíveis no manual técnico do equipamento.

Nesta etapa também podem ser realizados ensaios, calibração ou testes para encontrar as incertezas dos sensores e garantir que os mesmos estejam disponíveis para uso dentro das recomendações. Para tanto, é necessário que os equipamentos utilizados para realizar os estudos metrológicos estejam calibrados e rastreados para contribuir com os componentes da incerteza. A definição da metodologia para realizar o ensaio deve ser feita conforme o sensor.

3.3 CATEGORIA DE DECISÃO

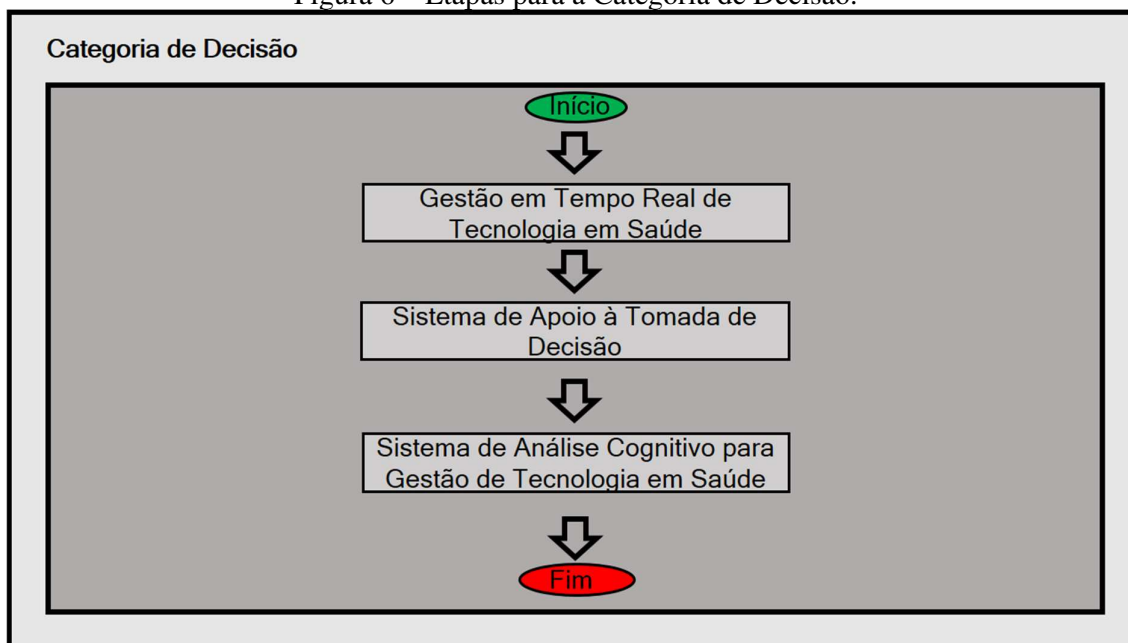
Esta categoria consiste na implementação do monitoramento em tempo real da tecnologia com base nos parâmetros preestabelecidos e disponíveis na *Front End*, que contemplam limites adequados, precários e críticos para os níveis de funcionamento dessa tecnologia.

Dessa forma, oferece auxílio à gestão, no que diz respeito à tomada de decisão, com base nos parâmetros predefinidos. Inclusive, pode ser utilizada uma plataforma de gestão cognitiva como a *ML Studio*, utilizada neste estudo, ou outra, conforme os critérios de cada pesquisa, tais como: *Amazon AWS Studio*, *IBM Watson*, *Google Cloud* e *Microsoft Azure Machine Learning Studio*.

Dessa forma, embora a gestão da tecnologia em saúde possa ser feita a partir da central de monitoramento, o seu potencial resolutivo e efetividade em todos os seus processos pode ser melhorado com uma plataforma de análise cognitiva. Tudo isso, integra o modelo de Gestão Ubíqua de Tecnologia em Saúde, isto é, um modelo de gestão descentralizada onde é possível monitorar e gerenciar a tecnologia a partir de qualquer lugar onde se estiver através da interconectividade.

A categoria de decisão divide-se em etapas: Gestão em Tempo Real da Tecnologia, Sistema de Apoio à Tomada de Decisão e Sistema de Análise Cognitiva para Gestão de Tecnologia. Conforme a Figura 6:

Figura 6 – Etapas para a Categoria de Decisão.



Fonte: Elaborada pelo próprio autor (2018).

3.3.1 Gestão em Tempo Real de Tecnologia em Saúde

Esta etapa utiliza o monitoramento em tempo real com auxílio das informações visualizadas na *Front End*, que contém os indicadores, ou seja, os parâmetros de monitoramento definidos na categoria operacional, acrescidos de valores que estabelecem limites como adequados, precários e críticos para os níveis funcionamento da tecnologia, e são destacados caso estejam fora do padrão definido. Uma das formas de fazer isso pode ser estabelecendo uma cor para cada valor disponível na *Front End*.

Ao fim do processo é necessário verificar se a plataforma instalada na unidade de saúde está apresentando os indicadores para realizar a gestão, caso esteja, mantém o processo, se não, é necessário retornar para etapa de escolha dos sensores até garantir seu funcionamento adequado.

Essa modalidade de gestão apresenta dois pontos cruciais: o sistema de apoio à tomada de decisão que pode ser feito a partir do monitoramento e também pode ser incrementado com outra plataforma de gestão cognitiva, conforme os tópicos a seguir.

3.3.2 Sistema de Apoio à Tomada de Decisão

De posse das informações disponíveis na *Front End* pode-se montar um plano de gestão da tecnologia, a partir do monitoramento, no qual já é possível o apoio à tomada de decisão.

A partir de então, com as informações obtidas pelo *feedback* da análise dos dados na plataforma de monitoramento, o profissional responsável pela gestão de tecnologia em saúde poderá tomar decisões baseadas em evidências de dados coletados nos sistemas de informações, porém, existe a possibilidade de implementar uma plataforma de análise cognitiva, e com isso ampliar o potencial resolutivo e a efetividade da gestão da tecnologia em saúde em todos os seus processos.

3.3.3 Sistema de Análise Cognitiva para Gestão de Tecnologia em Saúde

O desenvolvimento do trabalho usa uma plataforma de ML como ferramenta de análise cognitiva. Foram verificadas algumas plataformas de análise cognitiva, tais como: *Amazon AWS Studio*, *IBM Watson*, *Google Cloud* e *Microsoft Azure Machine Learning Studio*, optando-se por esta última, neste estudo, devido a sua flexibilidade, quantidade de algoritmos e método para validação de modelo (IDOINE *et al*, 2018), além disso, a UFSC disponibiliza ferramenta gratuita para uso, embora em quantidade limitada. Contudo, pode-se optar por qualquer outra plataforma que se adeque aos critérios de cada estudo.

Neste estudo, pretende-se utilizar uma plataforma de ML semelhante às funções cognitivas humanas. Uma tecnologia cognitiva cujo manejo dos dados seja capaz de direcionar a tomada de decisão não apenas com base nas experiências armazenadas, mas também através de *insight*, manipulando todos os dados do processo para dar suporte na tomada de decisão e gestão da tecnologia em saúde (AKABANE, 2018).

A plataforma ML Studio apresenta os blocos com funções, algoritmos e processamento de dados que podem ser ligados para obtenção do código. A criação do algoritmo de ML é dividida em sete passos: coleta de dados, pré-processamento dos dados, transformação dos dados, treinamento, teste do algoritmo, aprendizagem por reforço e execução (AWAD, KHANNA, 2015).

1. Coleta dos dados: onde é criado e selecionado o subconjunto de todas as características dos dados disponíveis para resolução do problema, sendo que em alguns casos pode ser

feito um pré-processamento estatístico das informações para melhor desempenho do algoritmo.

2. No pré-processamento dos dados, estes são apresentados de forma a serem reconhecidos pela plataforma de ML e divide-se em três etapas - formatação: os dados devem ser filtrados num formato compatível com a plataforma; limpeza: nesta etapa os dados são limpos, através da correção, remoção ou substituição dos dados corrompidos ou ausentes; amostragem: devem ser coletados num intervalo regular ou adaptativos para minimizar a redundância e para que não haja perda de informações pelos canais de comunicação.
3. Transformação dos dados: onde é possível converter um atributo numérico em uma categoria ou converter atributos categorizados em numéricos. Assim, eles são decompostos para extrair os componentes úteis incorporados aos dados ou agregados para formar várias combinações em um único recurso.
4. Treinamento do algoritmo: é selecionado o conjunto de dados de treinamento, no qual é aplicado um algoritmo para o treinamento, com isso, é possível realizar a extração de conhecimento ou informação. São armazenadas como modelo a ser usado para validação cruzada e uso real.
5. Teste do algoritmo, onde é avaliada sua eficácia e desempenho, assim permite verificar se os dados conseguem identificar algum comportamento. Aplica-se o modelo treinado no conjunto de dados de testes que será medido em relação a acurácia² feita nesse conjunto, sendo um indicativo de desempenho. Caso necessite melhorar o desempenho do modelo é necessário repetir as etapas anteriores alterando o fluxo de dados, taxa de amostragem, transformações, modelo de linearização, dentre outros.
6. Aprendizagem por reforço: este passo envolve aprender pelas consequências da interação com o ambiente e não é aplicado, pois não há *feedback* entre a predição e o modelo.
7. Execução: consiste na aplicação do modelo validado para executar no modelo de gestão de tecnologia em saúde e caso novos dados sejam encontrados, é necessário treinar o modelo seguindo as etapas anteriores.

Ao fim do processo é necessário verificar se a plataforma está funcionando corretamente. Caso esteja, mantém-se o processo, se não, é necessário retornar para etapa de

² Também conhecida como taxa de erro, que corresponde a taxa de previsões (corretas ou incorretas) do modelo em um conjunto de dados. (AWAD, KHANNA, 2015).

escolha dos sensores ou para a etapa em que foi identificado o erro, a fim de garantir o funcionamento adequado. Dependendo da plataforma de tecnologia cognitiva que for escolhida a implementação pode variar de acordo com a tecnologia a ser monitorada.

4 APLICAÇÃO DA METODOLOGIA COMO CASO DE ESTUDO: IMPLEMENTAÇÃO DA PLATAFORMA DE GESTÃO UBÍQUA COM ANÁLISE COGNITIVA EM TECNOLOGIA DA ATENÇÃO PRIMÁRIA À SAÚDE

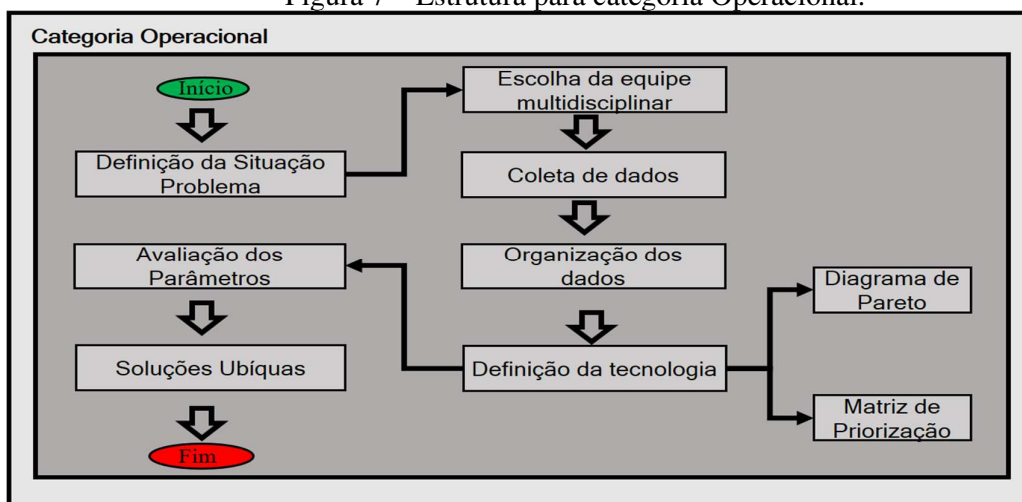
Este estudo apresenta os processos da metodologia de gestão ubíqua de tecnologia em saúde na APS, através dos quais se implementou uma plataforma voltada para a gestão de tecnologia em saúde. Essa proposta de gestão descentralizada com a metodologia definida foi aplicada como caso de estudo num sistema de APS da rede pública na cidade de Florianópolis-Santa Catarina-Brasil.

Neste cenário, vale salientar que a APS do Brasil é o primeiro recurso procurado pela população para o acesso aos cuidados em saúde. Esta estrutura conta com um sistema formado por policlínicas, Centros de Especialidades Odontológicas (CEO), Unidades Básicas de Saúde (UBS), Unidades de Apoio Imediato e Diagnóstico (UPA) (AVELAR; SILVA; GARCIA, 2017).

No âmbito da Atenção Primária à Saúde (APS) há um crescente aumento das instalações de Tecnologia Médico Hospitalar (TMH) e conseqüentemente uma maior necessidade de serviços especializados para atuar na sua gestão e no seu gerenciamento. A implementação da metodologia contempla as categorias operacional, de monitoramento e decisão.

4.1 CATEGORIA OPERACIONAL

Figura 7 – Estrutura para categoria Operacional.



Fonte: Soares Filho; Garcia; Martins (2019).

4.1.1 Primeira etapa: Definição da Situação Problema

Na metodologia aplicada neste trabalho, a primeira etapa consiste na definição da situação problema. Para isso, teve apoio da equipe composta por engenheiro clínico, técnico especializado em tecnologia em saúde e suporte administrativo.

Os dados foram coletados no Sistema de Informações do Instituto de Engenharia Biomédica da Universidade Federal de Santa Catarina - (SI-IEB-UFSC) em equipamentos médico-hospitalares e odontológicos que compõem a APS da cidade de Florianópolis. O levantamento dos dados é referente ao período de 2014 a 2018 e o parque tecnológico quantificado com: 61 classes de equipamentos, 17264 OS referentes a 3053 equipamentos médico-hospitalares e odontológicos.

Os critérios adotados para coleta de dados são: nome dos equipamentos, quantidade de OS abertas, número de equipamentos, média e mediana do número de equipamentos por OS no período em estudo, conforme apresentado no Apêndice A. Além disso, foram excluídas OS abertas referentes a backups³, instalações, capacitações, sendo considerados apenas relacionados a falhas ou quebras.

A organização dos dados, facilitou a aplicação das ferramentas para controle e melhoria da qualidade. Para isso, categorizou-se conforme pode-se verificar nos Apêndices B e C respectivamente: primeiro, os dados dos equipamentos foram divididos por quantidade de OS abertas em ordem decrescente e posteriormente número de equipamento em ordem alfabética com as médias e medianas de número de equipamento por OS abertas.

Com a categorização dos dados foi aplicado o diagrama de priorização na classe de equipamentos médico-hospitalares e odontológicos para determinar a prioridade na solução dos problemas e a análise dos riscos, conforme Apêndice D (CARPINETTI, 2016).

Tendo em vista que a matriz de priorização utiliza fatores qualitativos como um peso para cada item em gravidade, tendência e urgência, acrescentou-se mais um fator de multiplicação através da mediana para resultar numa representação quantitativa, tendo como base o número de OS abertas por equipamentos.

³ Substituto temporário de tecnologias que falham ou quebram

Vale ressaltar, que utilizou-se a mediana⁴ ao invés da média⁵, porque existe uma grande discrepância na quantidade de OS abertas por equipamentos, ou seja, algumas tecnologias apresentam grande quantidade e outras baixa quantidade.

Com o resultado da multiplicação da matriz de priorização com a mediana, aplicou-se o diagrama de Pareto, no qual foram priorizadas as tecnologias de acordo com a ordem de importância. Tais resultados são vistos na Tabela 1 e Figura 8.

Tabela 1 – Resultados do diagrama de Pareto.

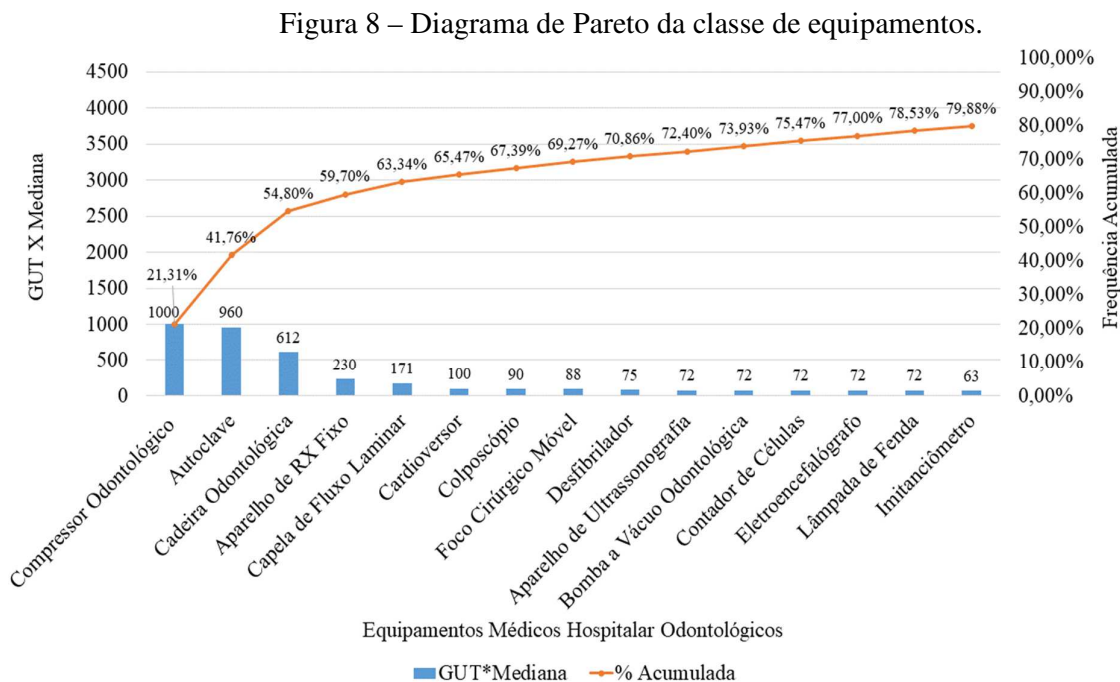
Equipamento	GUT*Mediana	% Parcial	% Acumulada
Compressor de ar comprimido Odontológico	1000	21,31%	21,31%
Autoclave	960	20,45%	41,76%
Cadeira Odontológica	612	13,04%	54,80%
Aparelho de RX Fixo	230	4,90%	59,70%
Capela de Fluxo Laminar	171	3,64%	63,34%
Cardioversor	100	2,13%	65,47%
Coloscópio	90	1,92%	67,39%
Foco Cirúrgico Móvel	88	1,87%	69,27%
Desfibrilador	75	1,60%	70,86%
Aparelho de Ultrassonografia	72	1,53%	72,40%
Bomba a Vácuo Odontológica	72	1,53%	73,93%
Contador de Células	72	1,53%	75,47%
Eletroencefalógrafo	72	1,53%	77,00%
Lâmpada de Fenda	72	1,53%	78,53%
Imitanciômetro	63	1,34%	79,88%

Fonte: Fonte: Soares Filho; Garcia; Martins (2019).

⁴ Mediana é utilizada para retornar à tendência central para distribuições numéricas distorcidas (THURMAN, 2017.)

⁵ Média é usada para distribuições numéricas normais, com baixa quantidade de valores discrepantes. (THURMAN, 2017.)

A figura 8 representa o gráfico dos dados do diagrama de Pareto da classe de equipamentos.



Fonte: Soares Filho; Garcia; Martins (2019).

Pode-se observar que das 61 classes de equipamentos, 15 precisam ser priorizadas, e o compressor de ar comprimido odontológico aparece como prioridade tanto com o resultado da matriz de priorização, como quando se acrescenta a mediana como um peso e também no diagrama de Pareto, por isso, foi a tecnologia escolhida como caso de estudo.

O compressor de ar comprimido odontológico escolhido neste estudo tem o motor isento de óleo, 1 *Horse-Power* (HP) cujas características estruturais técnicas estão descritas no Apêndice E as técnicas no Apêndice F. Sua escolha justifica-se pelo fato de ser o mais utilizado na rede de APS da Secretaria Municipal de Saúde de Florianópolis.

Os compressores de ar odontológicos são os equipamentos responsáveis pelo fornecimento de ar comprimido através de um processo eletromecânico no qual aspira ar à pressão atmosférica e o comprime até a pressão pretendida por meio de um motor elétrico (SANTOS, 2002).

Essa tecnologia pode ser considerada crítica dentro do EAS porque com sua quebra ou falha todos os atendimentos na odontologia da APS podem ser interrompidos completamente. Isso ocorre devido a interrupção do fornecimento de ar comprimido tornar inviável o uso dos equipamentos odontológicos, tais como: equipo para acionamento e controle de turbinas,

micromotores, seringa tríplice, sugador de saliva tipo Venturi e outras peças de mão (RODRIGUES 2019).

4.1.2 Segunda Etapa Avaliação dos Parâmetros

Para definição dos parâmetros foi realizada uma nova coleta de dados no SI-IEB-UFSC em compressores de ar comprimido isentos de óleo. Esses dados seguiram a folha de dados do Apêndice G na qual, foram excluídas O.S abertas para instalação, treinamento, mudança de EAS e equipamento para *backup*. Além disso, foram verificados os registros de manutenções, modo de falhas, modo de operação, esquemáticos de desenhos nos manuais do usuário e técnico, e posteriormente conduzidos para análise.

Assim, foram categorizados os dados de 75 compressores de ar comprimido cadastrados no sistema de informações do Centro Local de Engenharia Clínica (CELEC) da APS do IEB-UFSC, divididos em 177 OS referentes a 177 falhas de 17 tipos específicos, conforme pode ser visto no Apêndice H. Algumas dessas falhas foram divididas em grupos de acordo com o modo de falha (MARTINS; VIEIRA; GARCIA, 2017):

- Vazamento externo composto por: vazamento pela mangueira, engate rápido e regulador;
- Falhas na válvula, anéis e juntas do pistão do motor foram agrupadas devido ter-se observado nas OS que sempre que é feita a manutenção em alguma dessas peças é necessário trocar o conjunto completo, preventivamente.

Ao aplicar o diagrama de Pareto foram priorizados: vazamento pela mangueira, engate rápido e regulador com 45 falhas; defeito nos anéis, válvulas e juntas do pistão com 38 falhas; vazamento pelo purgador com 34 falhas; vazamento pela serpentina com 11 falhas e pistão travado com 10 falhas, conforme a tabela 2 e figura 9.

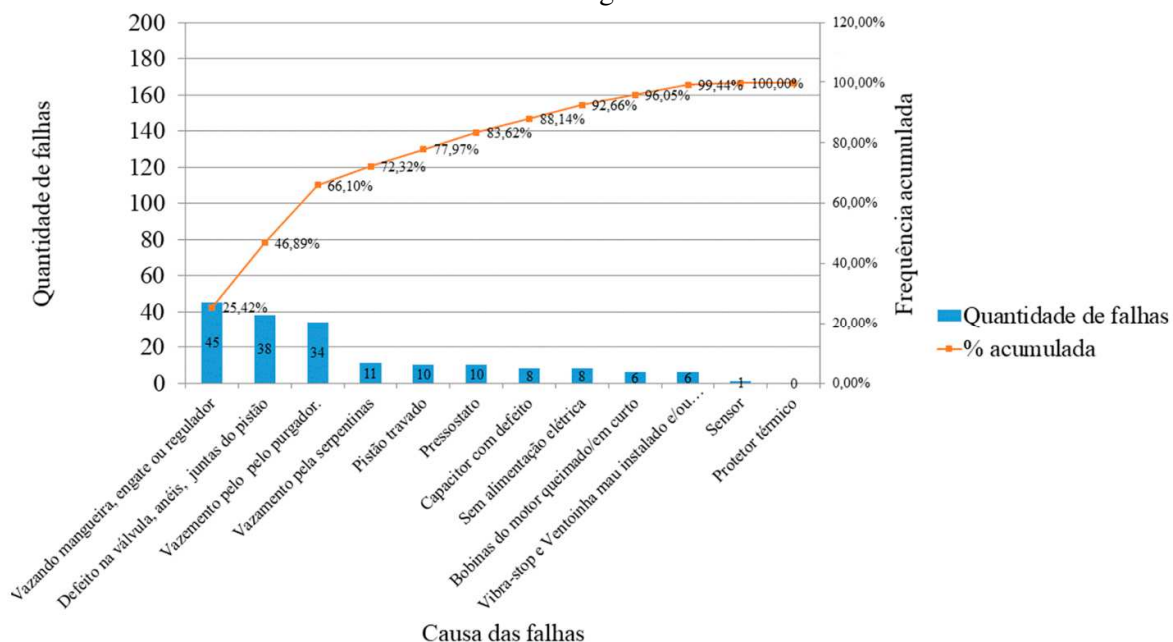
Tabela 2 – Diagrama de Pareto do compressor de ar comprimido odontológico isento de óleo.

Causa das falhas	Quantidade de Falhas	% Parcial	% Acumulada
Vazando pela mangueira, pelo engate ou Regulador	45	25,42	25,42
Defeito na válvula, anéis, juntas do pistão	38	21,47	46,89
Vazamento pelo purgador	34	19,21	66,10
Vazamento pela Serpentina	11	6,21	72,32
Pistão travado	10	5,65	77,97

Fonte: Soares Filho; Garcia; Martins (2019).

A figura 9 representa graficamente os resultados do diagrama de Pareto das falhas do compressor de ar comprimido odontológico.

Figura 9 – Gráfico do diagrama de Pareto das falhas do compressor de ar comprimido odontológico.



Fonte: Soares Filho; Garcia; Martins (2019).

Com base nessas informações a equipe realizou um *Brainstorming* (ou discussão) e definiu os parâmetros de monitoramento observados, dentre eles:

- Pressão e temperatura – a pressão no sistema da rede de ar comprimido que leva a cadeira odontológica e a temperatura no bloco do compressor, a partir dos quais foram identificadas algumas falhas: vazamento pela mangueira, pelo

engate ou regulador; defeitos na válvula, anéis e juntas do pistão; vazamento pelo purgador e pela serpentina;

- Corrente - o monitoramento da corrente do motor ajuda a identificar problemas relacionados ao pistão travado e na identificação de falhas por vazamento de ar;
- Tensão elétrica - a tensão elétrica de alimentação deve ser monitorada a fim de identificar as flutuações da rede fornecidas pela concessionária de energia elétrica. Tanto subtensões, quanto sobretensões tendem a alterar as características elétricas do motor, provocando defeito no travamento do pistão e desgaste precoce nos anéis, juntas e válvulas.

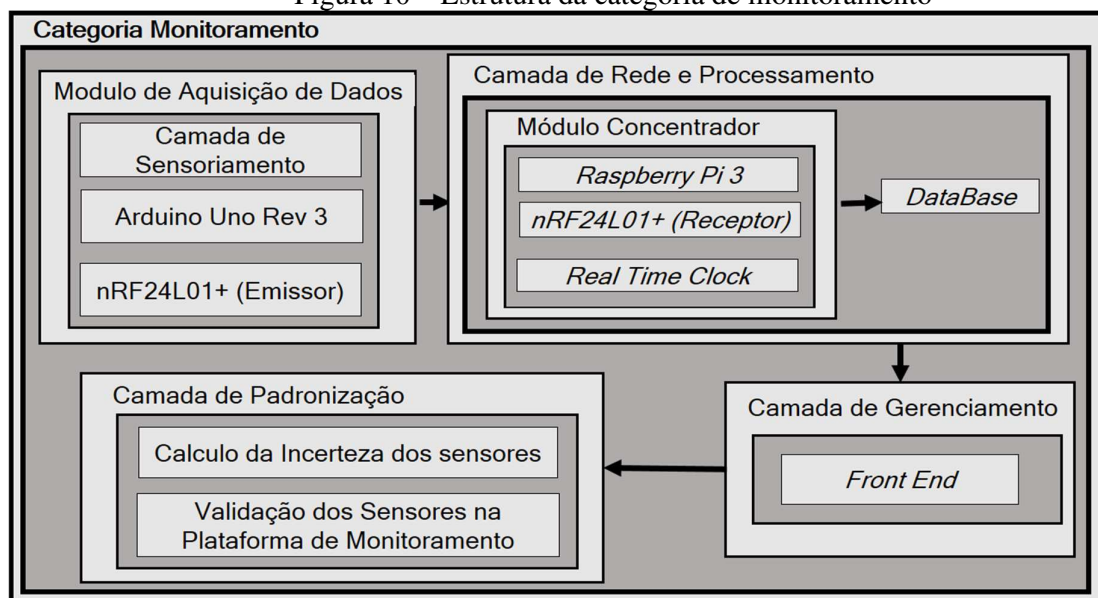
4.1.3 Soluções Ubíquas

As soluções ubíquas para o monitoramento foram desenvolvidas baseadas na escolha dos sensores de pressão, corrente, temperatura e tensão.

4.2 CATEGORIA DE MONITORAMENTO

Na categoria de monitoramento o sistema desenvolvido no laboratório de gestão ubíqua de tecnologia em saúde do IEB-UFSC se apresenta na figura 10

Figura 10 – Estrutura da categoria de monitoramento



Fonte: Fonseca; Rosa; Garcia (2017); Santos; Rosa; Garcia (2017).

4.2.1 Camada de Sensoriamento e Módulo de Aquisição de Dados

A priorização dos sensores, está de acordo com a plataforma de prototipação, e esta tem como base microcontroladores, compatíveis com tensão de 3,3 Volts (V) ou 5V, com alimentação oriunda efetivamente da plataforma, além disso, exclui o uso de circuitos externos para baterias e circuito de fonte de tensão externa.

As principais características de funcionamento do compressor de ar comprimido odontológico estão disponíveis no manual técnico e foram observadas antes da escolha dos sensores. Os testes para identificar o melhor local de fixação do sensor de temperatura contou com a identificação do melhor local em relação a temperatura e um brainstorming com a equipe técnica para escolher a forma mais adequada de instalação dos sensores no equipamento.

O sensor de temperatura deve ter como característica necessária um *range* de detecção entre 0 e 120 Graus Celsius (°C), pois no resultado dos testes para identificar o melhor ponto de fixação do sensor, observou-se que o bloco do compressor atinge uma temperatura máxima de 112 °C, além disso, não invasivo no equipamento e de fácil implementação.

Assim, o sensor de temperatura escolhido foi o LM35, fabricado pela *National Semiconductor*, com tensão de saída proporcional à temperatura de detecção de entrada, portanto sem necessidade de calibração externa. Dessa forma, reduz a complexidade do uso e a necessidade de um circuito extra de condicionamento de sinal, com alcance de detecção de -40 a 150°C, não invasivo e atende às características do projeto (DATASHEET, 2000). Suas características técnicas podem ser vistas no Apêndice I.

De acordo com as especificações dos parâmetros do estudado, para medir a pressão no sistema de ar comprimido foi escolhido o transmissor de pressão (transdutor de pressão ou sensor de pressão) K1100C. Sua escolha justifica-se principalmente pelo alcance de medição entre 0-174 psi, compatível com os dados do compressor, que desliga automaticamente quando a pressão alcançar 110 psi e volta a religar quando a pressão diminui para 80 psi, mantendo o intervalo entre 80-110 psi em uso (DATASHEET, 2018,). As características deste sensor estão disponíveis no Apêndice I.

O monitoramento da corrente utiliza um transformador de corrente como sensor, cuja corrente no motor do compressor de ar comprimido pode variar de 0-10Ampere (A), com o pico de 10 A na partida do motor e duração de 1 a 2 segundos, em seguida, a corrente em funcionamento do motor se estabiliza entre 6,5 a 7A. O modelo escolhido ZMCT103C,

apresenta faixa de trabalho entre 0-10A (DATASSHEET,2018,), cujas características são vistas no Apêndice I.

Além deste, foi testado o sensor ACS712, que apresentou limitação ao projeto por ser invasivo no circuito do equipamento, por necessitar da abertura do circuito para sua conexão.

O primeiro sensor de tensão testado no funcionamento do sistema foi GBK-P8 que apresentou saída digital *on* ou *off*, indicando a presença de tensão ou não, mas não mediu a tensão em funcionamento, por isso, não atendeu as medições desejadas.

Para desenvolver uma solução adequada utilizou-se um transformador abaixador compatível com a plataforma de prototipagem e com tensão adequada a leitura analógica. Assim, optou-se por um transformador no qual a tensão de pico no seu secundário fosse de no máximo 5V, que de acordo com as especificações dessa plataforma, é o valor máximo permitido.

Dessa forma, ao invés do sensor de tensão, foi escolhido um transformador abaixador de 220V para 3V com potência de 0,3 Volt Ampere (VA). A escolha da potência priorizou o baixo custo do transformador, já que não havia especificação restringindo seus valores de potência (DATASSHEET, 2018). Conforme visto no Apêndice I. Com o transformador abaixador, a variação de tensão para o monitoramento dos valores com base no módulo VIII do Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIG), atendeu as necessidades da plataforma.

Para a prototipagem dos sensores no módulo de aquisição de dados, a plataforma *Arduino*, especificamente a placa *Arduino Uno Rev 3, Integrated Development Environment*⁶ (IDE) apresenta ampla compatibilidade em sensores/transdutores priorizados no trabalho, e conta um *microcontrolador* embutido (*ATmega328*). Suas características são vistas no Apêndice I.

A escolha desta plataforma está alinhada aos parâmetros característicos para a coleta e envio dos dados à camada de processamento. Dentre eles, a taxa de amostragem do sistema E velocidade de processamento.


Por sua vez, a placa *Arduino Rev 3* agilizou o tempo de prototipagem, pois apresenta grande variedade de bibliotecas prontas, como também possui software livre e projeto disponível para replicação. Além disso, sua placa de desenvolvimento possui uma interface relativamente compacta, que proporciona boa ergonomia nas aplicações (ARDUINO, 2012).

⁶ Software com características e ferramentas para o desenvolvimento da aplicação com objetivo de agilizar o processo da programação.

Vale ressaltar que o foco do trabalho não é o desenvolvimento do protótipo em si e sim a implementação da plataforma de gestão ubíqua de tecnologia em saúde como metodologia.

Uma placa de circuito impresso que utiliza trilhas é responsável pela conexão elétrica dos componentes e sensores, conforme visto na figura 11.

Figura 11 – Placa de Circuito Impresso.



Fonte: Fonseca; Rosa; Garcia (2017); Santos; Rosa; Garcia (2017).

Na figura 12 tem-se a demonstração da implementação do módulo de aquisição de dados.


Figura 12 – Representação do módulo de aquisição de dados.



Fonte: Fonseca; Rosa; Garcia (2017); Santos; Rosa; Garcia (2017).

A figura 13 apresenta o diagrama do processo de funcionamento do módulo coletor.

Figura 13 – Diagrama do módulo coletor.




Fonte: Fonseca; Rosa; Garcia (2017); Santos; Rosa; Garcia (2017).

4.2.2 Camada de Rede e Processamento

Após a coleta, os dados foram transmitidos por comunicação de rádio frequência (RF) para o módulo concentrador (*Single Board Computers + nRF24L01+Real Time Clock*) através de dois transceptores (nRF24L01+) um com função de emissor no módulo de aquisição de dados e outro com função de receptor no módulo concentrador, a Figura 14 demonstra o módulo concentrador.

Figura 14 – Módulo Concentrador



Fonte: Fonseca; Rosa; Garcia (2017).

Nesta etapa, o módulo concentrador desenvolvido com *Single Board Computers* (SBC), *Raspberry Pi 3*, modelo B, cuja a finalidade é receber os dados do módulo coletor ou de outros módulos conectados em sua área de abrangência, processá-los e enviá-los para *DataBase* (DB), cujas características podem ser vistas no Apêndice J.

O sistema operacional apoiado pela *Raspberry Pi Foundation*, o *Raspbian*, foi utilizado como sistema operacional do módulo concentrador, com a maioria dos tutoriais e suportes oferecidos por ela, bem como por terceiros. Além disso, é totalmente gratuito, baseado no *Debian* e otimizado para *Raspberry Pi*. Ademais, utilizou *Python* como linguagem de programação devido a recomendação da *Raspberry Pi Foundation* (RASPBERRYPI, 2019).

Ao instalar a plataforma de monitoramento, foi necessário adicionar um *Real Time Clock* (RTC) DS3231 ao módulo concentrador devido ao *firmware* não permitir a conexão externa com *internet*, apenas a rede local, que não atualiza data e horário, e conseqüentemente não permite comunicação com a DB. As características do RTC DS3231 podem ser vistas no Apêndice J.

A definição da DB nem sempre é uma tarefa simples, já que existem diversos banco de dados que são projetados para tarefas distintas. Sua escolha justifica-se como boa alternativa de armazenamento de dados a longo prazo ao invés de mantê-los em arquivos de texto ou planilhas.

Para facilitar o acesso aos dados, foram desenvolvidas duas formas de armazenamento, uma com a DB e outra no próprio módulo concentrador. Contudo, esta última solução não será abordada neste projeto, porque foi desenvolvida como uma alternativa para a possibilidade de instalar a plataforma numa unidade de saúde isolada e sem conexão com a internet. Sua principal limitação é a necessidade de retirar os dados no local, o que impossibilita o acompanhamento em tempo real. Já a DB garante o acesso remoto aos dados.

Dentre os tipos de banco de dados usados atualmente, o relacional foi escolhido para o projeto, por apresentar estrutura básica na forma de uma tabela com linhas não ordenadas e colunas, permitindo o relacionamento entre as mesmas com capacidade de armazenar os dados estruturados (VYAWAHARE; KARDE; THAKARE, 2018).

Essa relação entre duas ou mais entidades possuem características como a possibilidade de alterar a estrutura de dados sem alterar a aplicação que a utiliza. Assim, para acessar, inserir, excluir, atualizar e consultar dados utilizou-se a linguagem de consulta *Structured Query Language* (SQL) (PUANGSAIJAI; PUNTHEERANURAK, 2017).

O projeto da DB foi realizado em três fases: modelagem conceitual, projeto lógico e projeto físico. Na primeira fase foram registrados os requisitos de informação da DB. Na

segunda fase foram definidas as estruturas de dados que implementaram os requisitos identificados na primeira fase. Já na terceira fase foram definidos parâmetros físicos de acesso à BD, para aperfeiçoar a performance do sistema como um todo.

O modelo conceitual foi estruturado na forma de diagrama entidade-relacionamento (ER), capturando os requisitos do usuário em termos de armazenamento dos dados. Para atender os requisitos exigidos pelo sistema foram definidos as entidades e seus atributos que compõem a tabela.

Neste sentido, foi desenvolvida uma DB simplificada para reter o máximo de informações e auxiliar no desenvolvimento do projeto, cujas informações necessárias para montar o modelo conceitual foram:

- Cadastro da unidade de saúde com o nome, telefone, endereço;
- Cadastro do equipamento com as informações como: tipo, número de série e unidade de saúde cadastrada;
- Armazenamento dos dados coletados separados por corrente, tensão, temperatura e pressão.

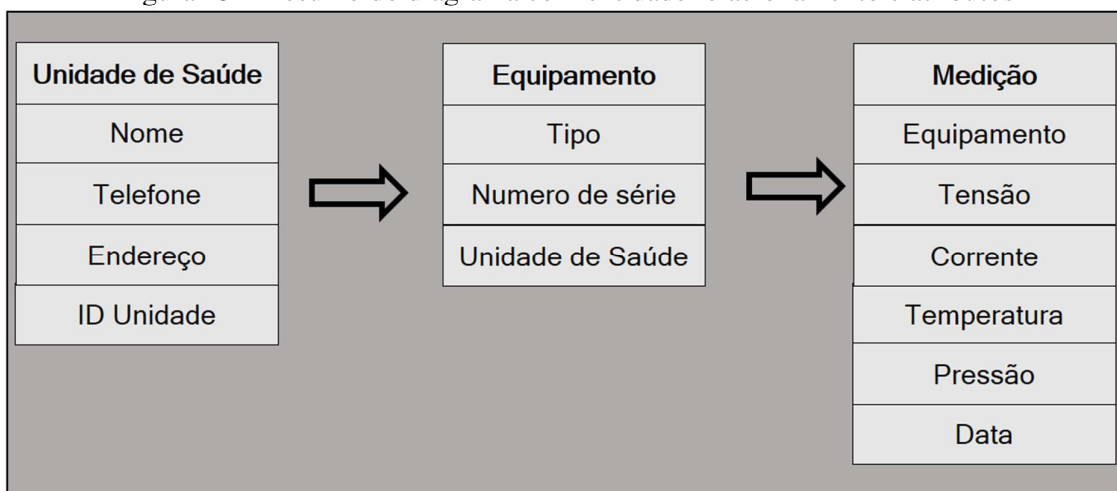
O quadro 3 e a Figura 15 apresentam o resumo das entidades, relacionamentos e atributos utilizados para montar o modelo conceitual.

Quadro 3 – Definição das Entidades e atributos para montagem do Diagrama ER

Entidade	Atributos
Unidade Saúde	Nome, Endereço, Telefone, Unidade ID
Equipamentos	Tipos, Número Série e Unidade Saúde
Medição	Equipamento, Tensão, Pressão, Corrente e Temperatura

Fonte: Fonseca; Rosa; R. Garcia (2017).

Figura 15 – Resumo do diagrama com entidade relacionamento e atributos



Fonte: Fonseca; Rosa; R. Garcia (2017).

Nesta etapa também foram definidas as Chaves Primárias⁷ ou *Primary Key* (PK) conforme visto no Quadro 4 e o modelo Conceitual E-R na figura 16.

Quadro 4 – Entidade com suas *Primary Key*

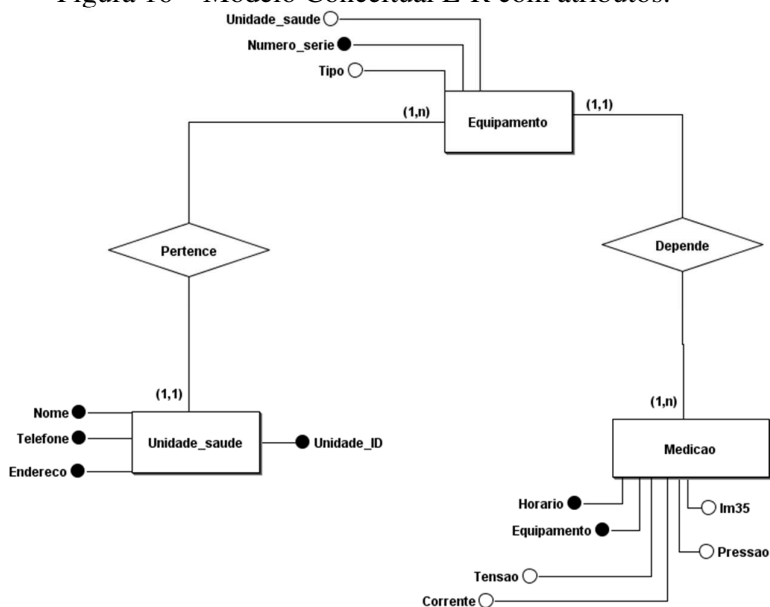
Entidade	<i>Primary Key</i>
Unidade de Saúde	Nome, telefone, Endereço e Unidade ID
Equipamento	Número Série
Medição	Horário e equipamento

Fonte: Fonseca; Rosa; R. Garcia (2017).

Na segunda fase foi executado o modelo lógico, no qual os dados obtidos na primeira fase foram convertidos em tabelas. Cada tabela se comporta como uma entidade, cujas colunas são atributos que contém restrições no modelo, como o *not null*, *Foreign Key* (FK) e PK.

⁷ A chave primária ou *primary key* é o identificador único para cada entrada cada entrada na tabela, que evita ambiguidade no momento da pesquisa das informações na DB (ELMASRI; NAVATHE 2011)

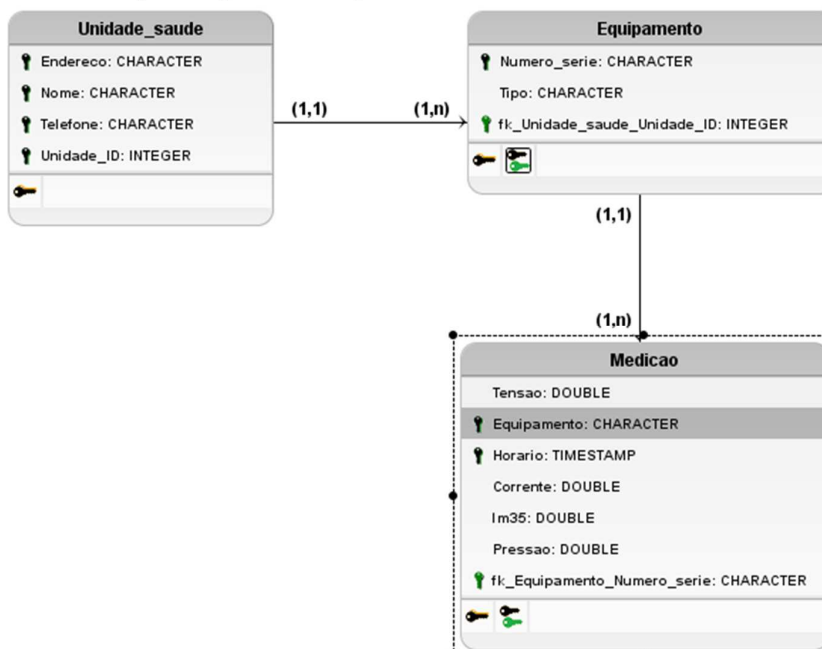
Figura 16 – Modelo Conceitual E-R com atributos.



Fonte: Fonseca; Rosa; R. Garcia (2017).

Esse modelo foi responsável por preparar os dados e aplicá-los no Sistema de Gerenciamento de Banco de Dados (SGBD). Os quadros 5 a 7 demonstram o dicionário dos dados com atributos, as restrições e os tipos que auxiliaram na montagem do modelo lógico, conforme a figura 17.

Figura 17 – Projeto lógico do diagrama de bloco do banco de dados



Fonte: Fonseca; Rosa; R. Garcia (2017).

Quadro – 5 Dicionário de dados de medição

Atributo	Tipo de Dados	Restrições
Horário	<i>Timestamp</i>	PK
Equipamento	<i>Character</i>	PK, FK, <i>NOT NULL</i>
Tensão	<i>Double</i>	<i>NOT NULL</i>
Corrente	<i>Double</i>	<i>NOT NULL</i>
Lm35	<i>Double</i>	<i>NOT NULL</i>
Pressão	<i>Double</i>	<i>NOT NULL</i>

Fonte: Fonseca; Rosa; Garcia (2017)

Quadro 6 – Dicionário de Unidade de Saúde

Atributo	Tipo de Dados	Restrições
Nome	<i>Character</i>	PK, <i>NOT NULL</i>
Endereço	<i>Character</i>	PK, <i>NOT NULL</i>
Telefone	<i>Inteiro</i>	PK, <i>NOT NULL</i>
Unidade ID	<i>Integer</i>	PK

Fonte: Fonseca; Rosa; Garcia (2017)

Quadro 7 – Dicionário de dados para equipamentos

Atributo	Tipo de Dados	Restrições
Tipo	<i>Character</i>	<i>NOT NULL</i>
Número série	<i>Character</i>	PK, FK, <i>NOT NULL</i>
Unidade ID	<i>Integer</i>	<i>NOT NULL</i>

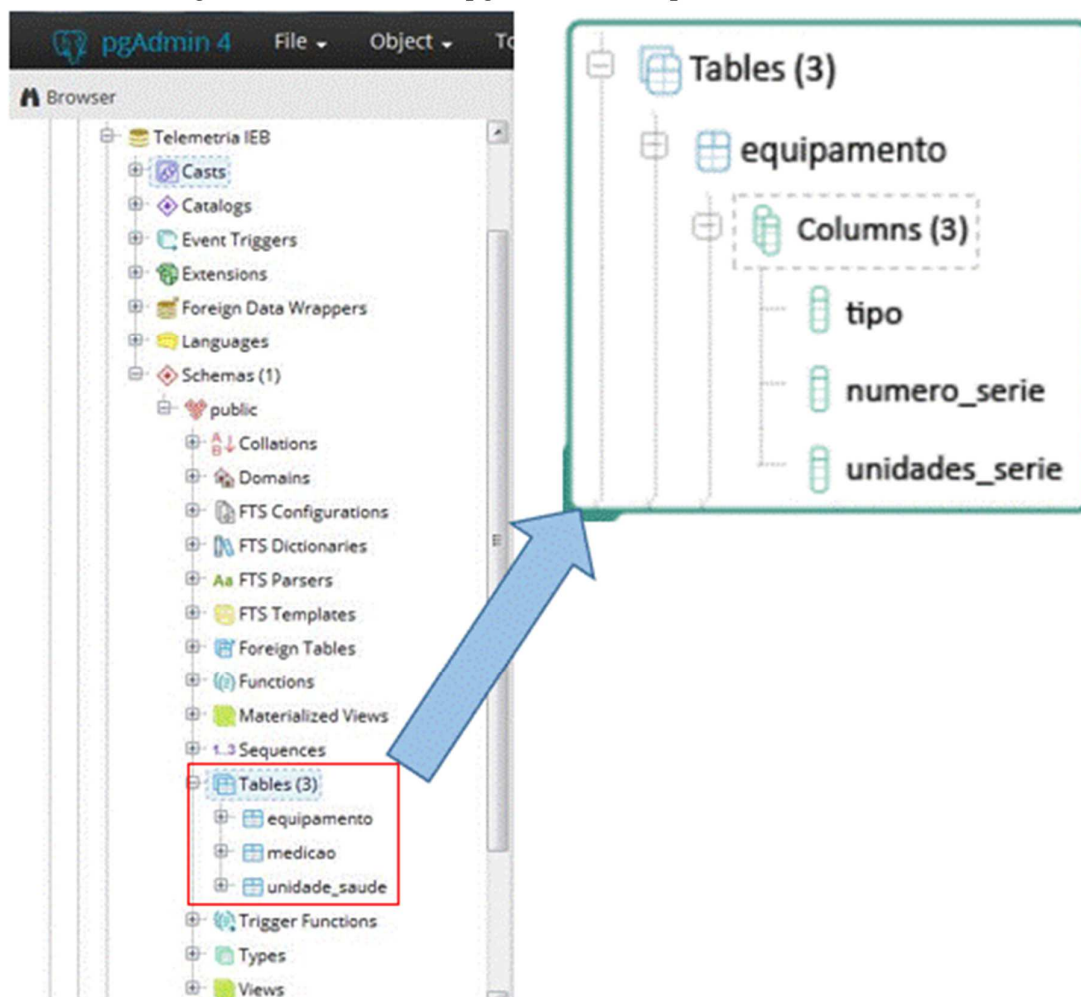
Fonte: Fonseca; Rosa; Garcia (2017)

Com a criação do modelo físico foram detalhados os componentes de estrutura de armazenamento, tabelas, campos, caminhos de acesso ao banco de dados, tipos e restrições. Com isso, foi implementado o SGBD, responsável pelo gerenciamento, armazenamento e disponibilidade dos dados.

O SGBD escolhido foi o *PostgresSQL*, um sistema de gerenciamento objeto-relacional baseado em *POSTGRES*, com as características de um sistema cliente/servidor, robusto, eficiente, com código aberto e muitos materiais de suporte disponíveis. Além disso, foi desenvolvido através do gerenciador de banco de dados *pgAdmin4* que facilitou o

desenvolvimento da DB através de uma interface gráfica, vista na Figura 18, que agilizou a sua programação.

Figura 18 – Interface do pgAdmin4 na implementação do SGBD



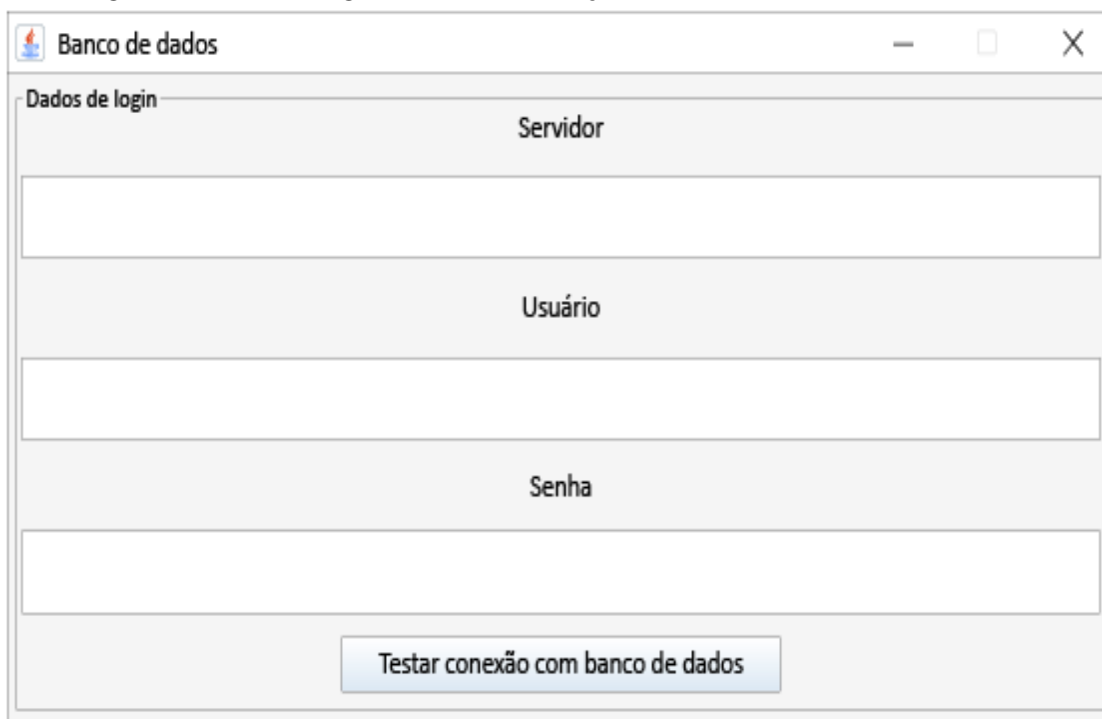
Fonte: Fonseca; Rosa; Garcia (2017).

Em conjunto com a implementação da DB foram criados 3 aplicativos com orientação ao objeto para realizar a conexão do módulo concentrador a DB utilizando a linguagem Java.

Esta linguagem foi escolhida por permitir que os programas desenvolvidos sejam executados em qualquer computador independente do sistema operacional, com a exigência de ter apenas a versão mínima do Java instalado, permitindo que o seu desenvolvimento seja realizado em um computador com Windows e facilmente exportado para o *Raspberry Pi* Modelo B.

O primeiro aplicativo permitiu a comunicação da DB com o módulo concentrador via TCP/IP, com a finalidade de alterar as informações da DB sem alterar o código fonte, realizar teste de conexão da DB com o módulo conectado, através de um arquivo executável localizado no módulo. Trata-se de uma janela que contém o endereço do servidor com usuário, senha e um botão para testar a conectividade. Assim, pode-se verificar se os dados de *login*, senha e a conexão da DB estão corretos e caso não estejam é exibida uma mensagem de erro. A interface gráfica de comunicação do módulo concentrador com a DB está apresentada na figura 19.

Figura 19 – Interface gráfica de comunicação do módulo concentrador com a DB.



The image shows a graphical user interface window titled "Banco de dados". The window has a standard Windows-style title bar with a minimize button, a maximize button, and a close button. Below the title bar, the text "Dados de login" is displayed. There are three input fields stacked vertically, each with a label above it: "Servidor", "Usuário", and "Senha". At the bottom of the window, there is a button labeled "Testar conexão com banco de dados".

Fonte: Fonseca; Rosa; Garcia (2017).

O segundo aplicativo é responsável pelo cadastramento das unidades de saúde e equipamentos na DB, conforme a figura 20. Pode-se acessá-lo a partir de qualquer computador com *internet*. O terceiro aplicativo é abordado na camada de gerenciamento.

Figura 20 – Interface gráfica para cadastrar a unidade de saúde e a tecnologia a ser monitorada.

The image shows a graphical user interface for a database editor. The window title is "Editor Banco de dados". It is divided into three main sections:

- Unidade de Saúde:** Contains four text input fields labeled "Nome", "Endereço", "Telefone", and "ID". Below these fields is a button labeled "Incluir Unidade de Saúde".
- Equipamento:** Contains three text input fields labeled "Tipo", "Número de série", and "Unidade de Saúde (ID)". Below these fields is a button labeled "Incluir Equipamento".
- Dados de login:** Contains three text input fields labeled "Servidor", "Usuário", and "Senha".

Fonte: Fonseca; Rosa; Garcia (2017).

4.2.3 Camada de Gerenciamento

Nesta camada foi desenvolvido o aplicativo no qual o usuário pode acompanhar em tempo real⁸ os dados disponíveis e acessá-lo de qualquer computador com acesso à internet. A Figura 21 mostra a interface gráfica de comunicação do aplicativo com a DB, onde são inseridos os dados do servidor, usuário e senha para se conectar a DB.

⁸ O tempo real nesse estudo se refere ao intervalo de tempo de 2 segundos, no qual, os dados são coletados, processados e disponibilizados, que é um intervalo de tempo insuficiente para detecção de falha mesmo que haja variação.

Figura 21 – Interface gráfica para conectar ao sistema de monitoramento

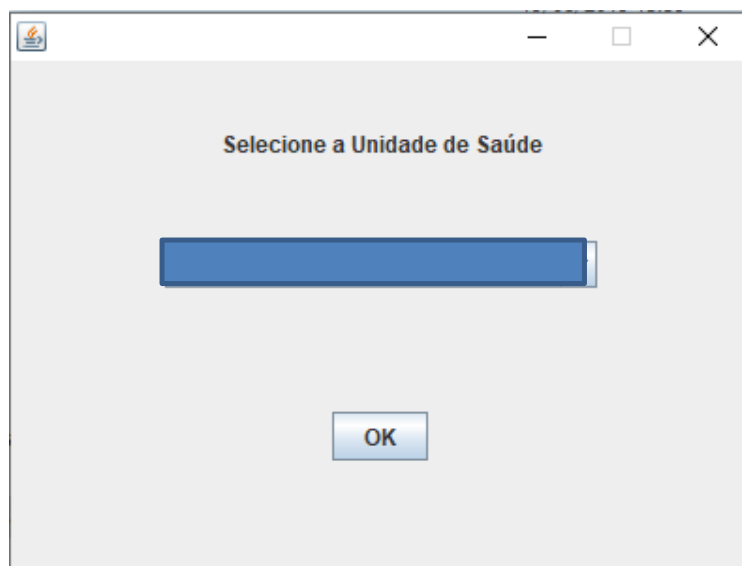


The image shows a graphical user interface for connecting to a monitoring system. It consists of a window with a title bar containing a small icon and standard window controls (minimize, maximize, close). The main content area is divided into three sections, each with a label and a corresponding input field: 'Servidor' (Server), 'Usuário' (User), and 'Senha' (Password). Below these input fields is a 'Conectar' (Connect) button.

Fonte: Fonseca; Rosa; R. Garcia (2017).

Após a conexão com a DB, é disponibilizado ao usuário uma lista das unidades de saúde monitoradas, que foram previamente cadastradas no sistema. Esta interface pode ser vista na figura 22.

Figura 22 – Interface gráfica para escolha da unidade de saúde



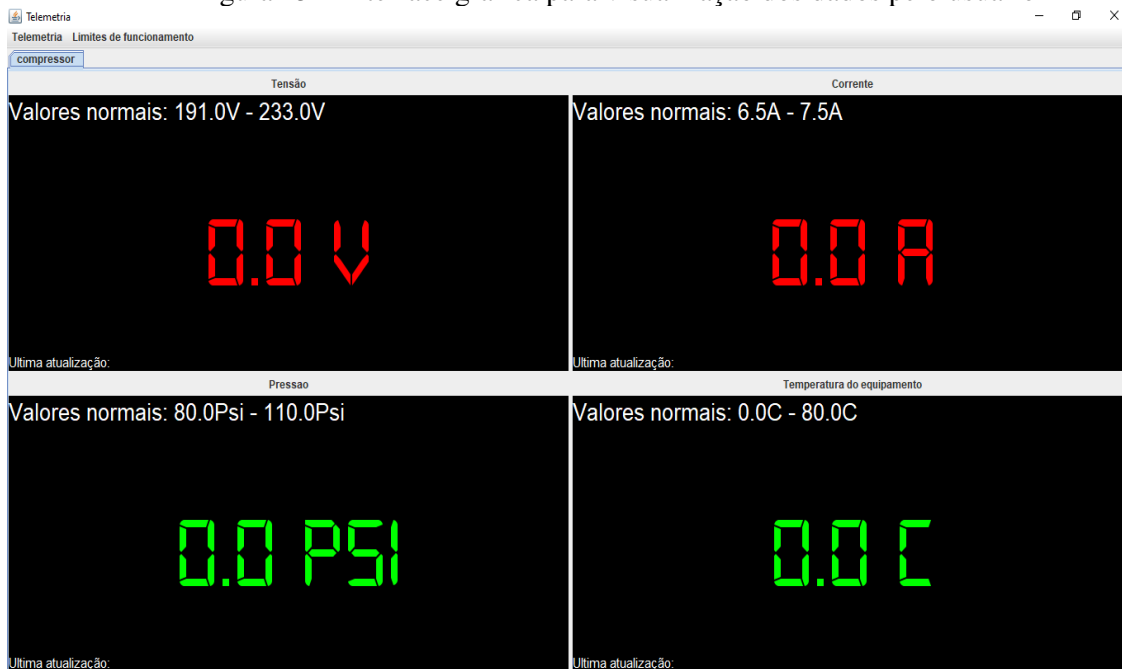
The image shows a graphical user interface for selecting a health unit. It consists of a window with a title bar containing a small icon and standard window controls (minimize, maximize, close). The main content area is light gray and contains the text 'Selecione a Unidade de Saúde' (Select the Health Unit) centered at the top. Below the text is a large, solid blue rectangular button. At the bottom center of the window is an 'OK' button.

Fonte: Fonseca; Rosa; R. Garcia (2017).

Com a escolha da unidade de saúde, é exibida uma FE, conforme pode ser visto na figura 23, que disponibiliza os dados para visualização ao usuário com as seguintes informações:

- Tensão da rede, corrente, temperatura e pressão do compressor de ar comprimido odontológico com seus limites de funcionalidade, sendo que seus limites podem ser configurados;
- Data e horário de coleta dos dados;
- Possibilidade de trocar o servidor ou modificar a unidade de saúde.

Figura 23 – Interface gráfica para visualização dos dados pelo usuário



Fonte: Fonseca; Rosa; R. Garcia (2017).

4.2.4 Camada de Padronização

A fim de trazer confiabilidade aos resultados de monitoramento para o valor de cada parâmetro, foram encontrados o erro de medição⁹ e declaração da incerteza de medição através da incerteza expandida (U95¹⁰). Sendo assim, o resultado da medição = valor corrigido¹¹ ± incerteza expandida.

⁹ Resultado de uma medição menos o valor verdadeiro do mensurando. Uma vez que o valor verdadeiro não pode ser determinado, utiliza-se, na prática, um valor verdadeiro convencional (SOARES, 2017; SPALL; SIMIONI, 2014).

¹⁰ Grandeza que define um intervalo em torno do resultado de uma medição com a qual se espera abranger uma grande fração da distribuição dos valores que possam ser razoavelmente atribuídos ao mensurando. A incerteza expandida U95 corresponde a um nível de confiança de aproximadamente 95% (SOARES, 2017; SPALL; SIMIONI, 2014).

¹¹ Valor corrigido = valor lido pelo módulo coletor +/- o erro de medição (SOARES, 2017; SIMIONI, 2014).

Para o cálculo da incerteza expandida foram adotados os passos a seguir (SPALL; SIMIONI, 2014).

- Incerteza do Tipo A (u_{Ap}) dos valores medidos pelo analisador: $u_{Ap} = \frac{s}{\sqrt{n}}$;
onde s é o desvio padrão e n o número de medidas.
- Incerteza do Tipo A (u_{Aa}) dos valores monitorados pelo equipamento sob análise: $u_{Aa} = \frac{s}{\sqrt{n}}$; onde s é o desvio padrão e n o número de medidas.
- Incerteza da calibração do padrão (U_p): a incerteza padrão devido à incerteza da calibração do simulador utilizado no ensaio é $U_p = \frac{U}{k}$; onde U é a incerteza da calibração do simulador e k o fator de abrangência, que define o nível de confiança da calibração.
- Resolução do analisador (u_{rp}): a incerteza padrão neste caso é $u_{rp} = \frac{a}{2\sqrt{3}}$; onde a é a resolução do equipamento analisador.
- Resolução do equipamento sob análise (u_{ra}): a incerteza padrão neste caso é $u_{ra} = \frac{a}{2\sqrt{3}}$; onde a é a resolução do equipamento de ensaio.
- A determinação da incerteza padrão combinada de medições diretas (u_c) é obtida como sendo a raiz quadrada da soma quadrática das diversas incertezas padrão (u_i), não correlacionadas, envolvidas no processo de medição
$$u_c = \sqrt{u_1^2 + u_2^2 + u_3^2 + \dots + u_{n-1}^2 + u_n^2}$$
- A incerteza expandida é obtida pela multiplicação do fator de abrangência (K^{12}) pela incerteza padrão. $U_{95} = k \cdot u_c$.

Os analisadores utilizados como o padrão são do laboratório Metrologia em Saúde do IEB-UFSC, seguem a norma de qualidade da *International Organization for Standardization* (ISO) 17025, e tem algumas medições acreditadas pelo Instituto Nacional de Metrologia, Qualidade e Tecnologia (INMETRO). Os analisadores utilizados estão descritos na Quadro 8:

¹² Para definição do k , utilizou-se o grau de liberdade infinito, então a partir da Distribuição – t de Student, foi definido o k como 2 (SOARES, 2017; SPALL; SIMIONI, 2014).

Quadro 8 – Analisadores utilizados no estudo

Parâmetro	Analisadores	Fabricante	Modelo	Número de cadastro do laboratório
Temperatura	12 Channel datalogging thermometer	Extech	TM500	LAT 085
Corrente	Analisador de energia	Instrutherm	AE-200	LAT 083
Tensão	Analisador de energia	Instrutherm	AE-200	LAT 083
Pressão	3-Channel Pressure Datalogger	Extech	SD750	LAT 084

Fonte: Elaborada pelo autor (2019)

Sendo assim, os resultados são vistos na tabela 3, na qual os dados são expressos como resultado da medição = valor corrigido +/- incerteza expandida. Com os resultados apresentados, o usuário da plataforma pode ter mais confiabilidade no monitoramento, pois as medidas vêm acompanhadas da incerteza de medição com nível de confiança de 95% (SOARES, 2017).

Tabela 3 – Resultados do erro de medição e das incertezas de cada parâmetro.

Parâmetros	Valores dos sensores do protótipo
Corrente	Valor lido + 0,01 (\pm 0,20) A
Pressão	Valor lido - 3 (\pm 1,05) psi
Temperatura	Valor lido + 0,09 (\pm 0,89) °C
Tensão	Valor lido + 1 (\pm 0,10) V

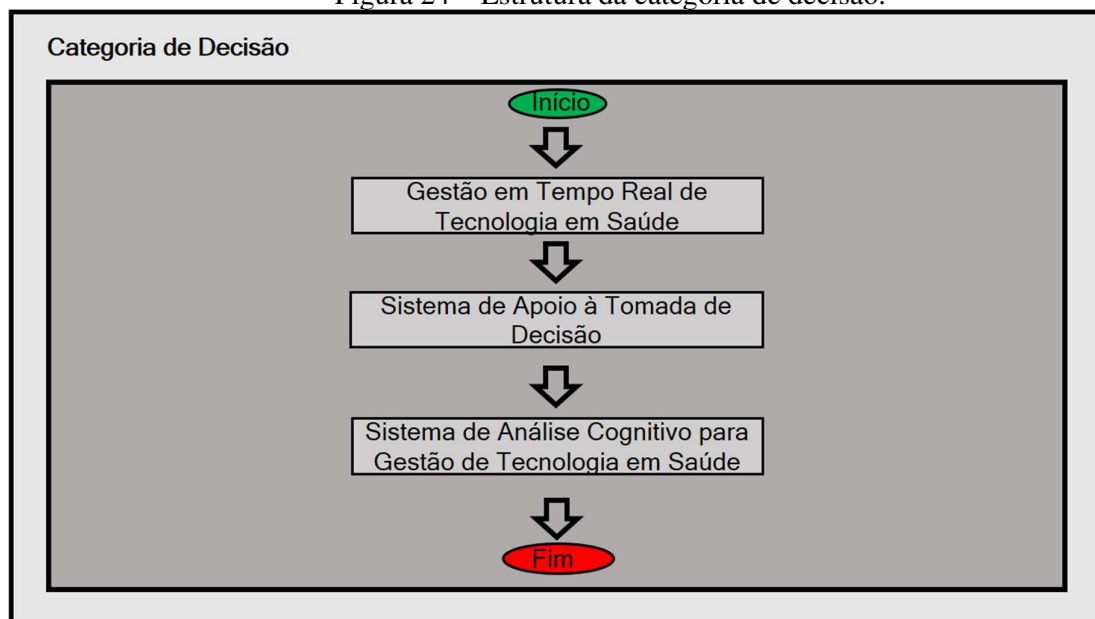
Fonte: Spall; Simioni (2014)

A plataforma de monitoramento foi testada no laboratório Centro Local de Engenharia Clínica da Atenção Primária à Saúde do IEB-UFSC antes da sua instalação na unidade de saúde, onde foram instalados os sensores no compressor odontológico com as mesmas características apontadas na situação problema. Assim, foi cadastrada uma unidade de saúde fictícia e acompanhado o comportamento do compressor através da FE. Bem como, foram feitas algumas simulações de desligamento do protótipo, desconexão do sensor, dentre outras, através das quais o funcionamento da plataforma foi validado.

4.3 CATEGORIA DE DECISÃO

A categoria de decisão foi desenvolvida no laboratório de gestão ubíqua de tecnologia em saúde e no CELEC-APS do IEB-UFSC, sua estrutura é apresentada na figura 24.

Figura 24 – Estrutura da categoria de decisão.



Fonte: Elaborada Pelo Autor (2019).

4.3.1 Gestão em Tempo Real de Tecnologia em Saúde

A gestão em tempo real realiza-se através de uma plataforma de monitoramento da tecnologia que é capaz de oferecer auxílio à engenharia clínica no processo de tomada de decisão.

A plataforma foi instalada em uma unidade de saúde da APS na cidade de Florianópolis-Santa Catarina-Brasil, a cerca de 5 km do Centro de Gestão e Desenvolvimento de Tecnologia Médico-Hospitalar do IEB-UFSC (CEGED). O monitoramento da tecnologia durou um período de dois meses e a escolha da unidade de saúde se justifica por possuir um compressor odontológico no modelo do estudo, além disso, funciona apenas no turno matutino, que permitiu realizar ajustes na plataforma durante o turno sem atendimento.

Os locais de instalação dos sensores no compressor foram escolhidos conforme as simulações realizadas no laboratório CELEC-APS do IEB-UFSC. No caso do sensor de temperatura, foram realizados testes nos quais foram fixados 12 sensores em pontos diferentes do compressor, para verificar o ponto de maior temperatura, utilizando o analisador 12-Channel

datalogging thermometer. A partir dos resultados, foi escolhido o segundo ponto com maior temperatura (conforme a figura 25 e 26) já que o ponto de maior temperatura na tampa do bloco do compressor, apresentou dificuldade na fixação do sensor.

Figura 25 – Ponto de instalação do sensor de temperatura.



Fonte: Santos; Rosa; Garcia (2017).

Figura 26 – Ponto de instalação para fixar o sensor de temperatura.



Fonte: Santos; Rosa; Garcia (2017).

O sensor de pressão é instalado na saída do vaso de pressão, conforme figura 27. E os demais sensores não precisam ser conectados diretamente na tecnologia, pois esta deve ser ligada no módulo coletor para captar os dados de tensão e corrente, no qual se encontram os respectivos sensores. Para posicionar o roteador foi escolhido um local próximo ao equipamento e o módulo concentrador foi posicionado sobre o módulo coletor.

Após a instalação do protótipo foram feitas inspeções quinzenais para a limpeza dos módulos. Bem como, a checagem do protótipo para verificar se estava no local em que foi instalado, se não houve queda e se o mesmo se encontrava limpo e seco, principalmente o *Raspberry Pi 3*, por ficar fora da case.

Figura 27 – Ponto de instalação do sensor de pressão



Fonte: Elaborado pelo Autor (2019)

Mesmo com os cuidados de inspeção, o primeiro *Raspberry Pi 3* quebrou devido a infiltração de água da chuva no abrigo do compressor, sendo comum erros referentes à instalação do compressor por inadequações de infraestrutura do sistema. A figura 28 mostra o compressor e o protótipo instalados na unidade de saúde escolhida.

Figura 28 – Local de instalação do módulo de aquisição de dados na unidade de saúde.



Fonte: Elaborada pelo Autor (2019).

Após a instalação do módulo coletor e concentrador foi realizado o acompanhamento do comportamento da tecnologia através da *FE* em um computador do IEB-USFC, conforme a figura 29.

Figura 29 – *Front End* utilizada pela engenharia clínica para realizar o monitoramento.



Fonte: Fonseca; Rosa; Garcia (2017).

Nesse contexto, o sistema de apoio à tomada de decisão aborda as medidas que devem ser tomadas em caso de alteração no comportamento da tecnologia. Vale ressaltar que durante o período de uso não houve nenhuma intercorrência, apenas a queda do sensor de temperatura do compressor, que foi percebida e reparada no mesmo dia, pois durante o incidente o equipamento não apresentava a variação de temperatura normal em funcionamento.

4.3.2 Sistema de Apoio à Tomada de Decisão

De posse das informações obtidas pelo *feedback* da análise dos dados coletados de corrente, tensão, temperatura e pressão na plataforma de monitoramento, a engenharia clínica pode montar um plano de gestão da tecnologia em saúde e tomar decisões baseadas nas evidências de dados.

Para melhorar o processo de gestão existe a possibilidade de implementar uma plataforma de sistema de análise cognitiva, e com isso ampliar o potencial resolutivo e a

efetividade da gestão da tecnologia em saúde em todos os seus processos, conforme descrito no tópico a seguir.

Com o monitoramento em tempo real através da plataforma, pode-se identificar as oscilações previstas conforme os parâmetros de monitoramento estabelecidos e assim, auxiliar na tomada de decisão, ou seja, a partir da identificação de um valor fora do parâmetro ou que represente risco de falha, o gestor pode decidir pelo plano de ação que pode incluir: manutenção corretiva, preditiva e preventiva, isto é, agir antes mesmo que a falha ocorra, de modo a minimizar os danos ou impedi-los de acontecer. Além disso, pode-se fazer uma análise da causa raiz do problema, se necessário.

A partir dos dados coletados, a engenharia clínica pode usar informações para identificar parâmetros de monitoramento, tais como:

- Vazamento de ar comprimido: quando esta falha é identificada, a pressão pode demorar de atingir o valor máximo¹³, então a engenharia clínica pode ter como plano de ação abrir uma OS, na qual já identifica o possível problema com os parâmetros monitorados e a equipe técnica pode realizar o Procedimento Operacional Padrão (POP) de acordo com as falhas de vazamento (vazamento pelo sistema de ar comprimido, podendo ser vazamento na rede, ou na serpentina do compressor ou pelo purgador).
- Se os valores lidos apontarem oscilação na rede elétrica fora dos limites estabelecidos pela Agência Nacional de Energia Elétrica (ANEEL), o plano de ação estabelecido pela engenharia clínica deve ser ligar para unidade de saúde, solicitar o desligamento da tecnologia e notificar a concessionária responsável pela rede.
- Em relação a falha nas válvulas, anéis, e juntas do pistão, a engenharia clínica identifica quando a pressão não atinge 110 psi e a temperatura fica elevada. O plano de ação neste caso consiste em abrir uma OS notificando a eventual falha e enviar um técnico ao local de posse do POP, para solucioná-lo.
- Quando o pistão se encontra travado a corrente permanece no máximo por mais de 10s, neste caso, o plano de ação da engenharia clínica deve ser ligar para

¹³ A pressão interna de funcionamento do compressor deve variar de 80 a 100 psi, por recomendação dos fabricantes de boa parte das cadeiras odontológicas, no entanto, o CEGED adota uma variação de 80 a 110 psi na rede e se justifica principalmente pela perda de pressão na rede. Contudo, é feita a regulagem no filtro de ar, para que a cadeira odontológica tenha o fornecimento entre 80 a 100 psi.

unidade de saúde, solicitar o desligamento da tecnologia, abrir uma OS com a possível falha e enviar a equipe técnica com POP para solucionar o problema.

Vale ressaltar, que com a plataforma de monitoramento é possível identificar os parâmetros previstos, porém, pode ser implementada uma plataforma com uso ML para ir além do previsto e garantir mais assertividade e resolutividade a esse processo de gestão.

4.3.3 Sistema de Análise Cognitiva para Gestão de Tecnologia em Saúde

Para auxiliar na gestão Ubíqua de Tecnologia em Saúde utilizou-se ferramentas cognitivas através da plataforma *ML Studio*, escolhida devido à sua flexibilidade, suporte operacional da *Microsoft*, quantidade de algoritmos que são testados ao mesmo tempo, bem como, devido a UFSC ter parceria com a *Microsoft* disponibilizar uma licença estudantil.

Dessa forma, a implementação do módulo de análise cognitiva seguiu os seguintes passos: coleta de dados, pré-processamento, transformação, treinamento, teste do algoritmo, aplicação de aprendizado por reforço e execução (AWAD; KHANNA, 2015).

Coleta de dados

Os dados de funcionamento normal do compressor odontológico foram coletados através da plataforma de monitoramento na unidade de saúde escolhida. Os demais dados sobre as falhas foram obtidos através de simulações controladas com a equipe técnica no laboratório CELEC-APS do IEB-UFSC num compressor com as mesmas características do instalado na unidade de saúde.

As falhas simuladas foram as mesmas escolhidas na etapa operacional e mantiveram os mesmos parâmetros: corrente do equipamento, tensão da rede, temperatura no bloco, pressão na rede de ar comprimido.

Vale ressaltar que nas simulações, cada falha foi convertida em comportamento:

- Vazamento de ar pela mangueira, engate rápido, regulador, purgador e serpentina foram classificados como vazamentos pequeno, médio e grande. Por ser difícil de identificar o comportamento de cada tipo de vazamento nas simulações e todos eles fazem com que o compressor leve mais tempo para atingir a pressão de desligamento;
- Defeito nos anéis, válvulas e juntas do pistão foram classificados como sem anéis, pois a remoção dos anéis foi necessária, devido não ter sido encontrado

esse conjunto de estruturas desgastadas e ao retirar os anéis do pistão apresenta o mesmo efeito da falha que faz com que o compressor não consiga atingir a pressão de desligamento;

- Pistão travado e capacitor com defeito foram classificados como falha no motor. O capacitor contou como falha no estudo porque apresentou o mesmo comportamento do pistão travado que foi manter a corrente elevada e o motor sem dar a partida.

A amostragem de falhas para composição do algoritmo de ML é exibida na tabela 9, onde pode-se observar que falha no motor obteve 7 amostras, pois quando o pistão trava e o capacitor apresenta defeito, o motor não dar partida, assim a corrente atinge o pico máximo e conseqüentemente, após alguns segundos, o disjuntor residual é acionado, desligando a rede de alimentação.

Tabela 4 – Amostragem de dados coletados para treinamento e validação dos algoritmos.

Comportamento	Amostragem
Comportamento Normal	353357
Vazamento pequeno de ar comprimido	180744
Vazamento grande de ar comprimido	57521
Anéis removidos	11444
Falha no motor	7

Fonte: Elaborada Pelo Autor (2019).

Pré-processamento de dados

Depois dos dados coletados, foram removidas as unidades dos valores medidos, e feita a verificação de dados ausentes ou de operação do equipamento através de filtros de busca. Além disso, os arquivos foram separados de acordo com a simulação e é adicionada uma coluna para classificação de cada comportamento da tecnologia.

Transformação de dados

A princípio foi acrescentado aos dados o atributo de operação (ligado ou desligado) cuja definição deu-se em relação ao valor da corrente, ou seja, quando está abaixo de 500 mA o aparelho está desligado, acima disso, refere-se à operação ligado.

A partir de então, gerou-se uma coluna com o tempo decorrido desde a última mudança de operação. Sendo possível, relacionar o tempo que o equipamento esteve ligado no intervalo e analisar o comportamento de vazamentos de ar comprimido e o pistão sem os anéis, que faz com que a tecnologia leve mais tempo para desligar. Para isso, foram criadas duas colunas para variação de temperatura e pressão, a partir da subtração do dado anterior ao dado atual e pela divisão do tempo entre eles.

Assim, é possível obter uma aproximação da derivada pelo Método Backward de Euler (Equação 1), onde $f(k)$ é o valor da função no instante k e Δt é a diferença de tempo entre os instantes k e $k-1$.

$$f'(k) = \frac{f(k) - f(k - 1)}{\Delta t} \quad (1)$$

Treinamento do Algoritmo

Depois de transformados, os dados seguiram para a plataforma ML Studio, na qual foram utilizados os algoritmos: *neural networks*, *decision jungle*, *decision forest*, *logistic regression*. Estes dados se dividiram de modo aleatório em duas partes, uma correspondente a 70% foi usada para o treinamento do modelo atual e a outra para a validação do algoritmo.

Teste do Algoritmo

Os 30% dos dados que foram usados para validação do modelo geraram uma matriz de confusão ou matriz de erro para cada categoria de falha. Caso os dados não sejam adequados é necessário refazer os passos anteriores do ML Studio e alterar a transformação aplicada.

Assim, os resultados da matriz de confusão para o para o algoritmo de *decision forest* (Figura 30) demonstra que o algoritmo faz a classificação majoritariamente correta dos dados. Grande parte dos valores encontram-se na diagonal, exceto pelos dados referentes à falha do motor, que são classificados como normal em 33% dos casos, devido à sua baixa quantidade de dados. Vazamento grande, que se refere a comportamentos classificados como normal em 21,4% dos casos, tem como possibilidade ser devido a não apresentar influência significativa no comportamento da tecnologia, pois mesmo com a falha o motor continua ligado.

Figura 30 – Matriz de Confusão de *decision forest*.
Predicted Class

Actual Class	Predicted Class					
	vazamento grande	vazamento médio	falha no motor	sem anéis	normal	vazamento pequeno
vazamento grande	100.0%					
vazamento médio		100.0%			0.0%	0.0%
falha no motor			66.7%		33.3%	
sem anéis				100.0%		0.0%
normal		0.0%			96.9%	3.0%
vazamento pequeno					21.4%	78.6%

Fonte: Elaborada Pelo Autor (2019).

O algoritmo de *decisión jungle* (Figura 31) apresenta comportamento similar ao de *decision forest*, entretanto apresenta discrepâncias nos dados no comportamento de falha do motor não são classificados corretamente, pois classifica 66,7% como sendo sem os anéis do pistão e 33,3% como normal, por fim, no comportamento de vazamento grande classifica 54,1% e 45,8% como normal.

Figura 31 – Matriz de confusão do *decisión jungle*.
Predicted Class

	vazamento grande	vazamento médio	falha no motor	sem anéis	normal	vazamento pequeno
vazamento grande	100.0%					
vazamento médio		100.0%			0.0%	0.0%
falha no motor				66.7%	33.3%	
sem anéis		0.0%		100.0%		0.0%
normal		0.0%			99.4%	0.6%
vazamento pequeno	0.0%	0.0%			45.8%	54.1%

Fonte: Elaborada Pelo Autor (2019).

Os algoritmos de *logistic regression* (Figura 32) e *neural networks* (figura 33) não apresentaram bons resultados, porque há grande dispersão na classificação tendendo a classificação no comportamento normal.

Figura 32 – Matriz de confusão de *logistic regression*.

		Predicted Class					
		vazamento grande	vazamento médio	falha no motor	sem anéis	normal	vazamento pequeno
Actual Class	vazamento grande	8.7%	25.1%		16.3%	47.1%	2.8%
	vazamento médio	8.1%	26.3%		16.2%	46.6%	2.8%
	falha no motor				33.3%	66.7%	
	sem anéis	8.4%	24.9%		17.0%	46.9%	2.9%
	normal	8.1%	25.3%		15.9%	47.9%	2.8%
	vazamento pequeno	8.2%	25.5%		16.1%	47.1%	3.1%

Fonte: Elaborada Pelo Autor (2019).

Deste modo, o algoritmo escolhido para a criação do modelo foi o *decision forest* que tem como base a união de algoritmos da árvore de decisão. O algoritmo funciona porque cada árvore de decisão possui uma predição melhor que uma tentativa aleatória e quando um grande número de árvores é combinado a probabilidade de acerto aumenta (ROKACH, 2016). Além disso, o resultado obtido no algoritmo de *decision forest* demonstra que esse método pode ser usado para classificação de aplicações onde a importância de cada variável é inicialmente desconhecida (OZA; TUMER, 2008).

Mesmo com uma boa acurácia do algoritmo *decision forest*, são necessários mais dados de comportamentos normais e de simulações para realizar o treinamento dos algoritmos da plataforma ML Studio, possibilitando uma melhor análise ou até aumentar sua acurácia.

Figura 33 – Matriz de confusão da *neural networks*.
Predicted Class

		vazamento grande	vazamento médio	falha no motor	sem anéis	normal	vazamento pequeno
Actual Class	vazamento grande	8.8%	25.2%	0.0%	16.3%	43.0%	6.8%
	vazamento médio	8.1%	26.4%		16.2%	42.1%	7.2%
	falha no motor				33.3%	66.7%	
	sem anéis	8.4%	24.9%		16.9%	42.5%	7.2%
	normal	8.1%	25.3%		15.9%	43.6%	7.1%
	vazamento pequeno	8.2%	25.5%	0.0%	16.0%	42.5%	7.8%

Fonte: Elaborada Pelo Autor (2019).

Aprendizagem por Reforço

Este passo envolve aprender pelas consequências da interação com o ambiente e não foi aplicado neste estudo pois não há feedback entre a predição e o modelo.

Execução

Para executar o sistema foi criado um programa em Python que coleta as informações do banco de dados e transforma-as seguindo o padrão estabelecido no treinamento, envia-as para o *webservice* na plataforma ML Studio e em seguida, a classificação retornada é exibida no computador.

Essa metodologia de análise cognitiva faz parte da plataforma de Gestão Ubíqua de Tecnologia em Saúde aplicada no compressor de ar comprimido odontológico e mostra-se eficiente na classificação de falhas, como visto no algoritmo *decision forest*.

Todos os testes deste módulo foram feitos com dados off-line e apresentou resultados positivos para classificação de falhas nas simulações realizadas no laboratório, contudo, é importante implementar a plataforma de análise cognitiva na tecnologia em funcionamento real. Seus resultados estão demonstrados na figura 34.

Figura 34 – Aplicativo de visualização dos dados da análise cognitiva.

Executa Periodicamente

```
[221.6, 97.0, 0.02, 74.78, 'off', 0, 8, 0.0, 0.0, '']
s leak
[221.6. 96.0, 0.02, 74.78, 'off', 0, 10, -0.5, -0.5, '']
s leak
[221.6. 96.0, 0.02, 74.78, 'off', 0, 12, 0.0, 0.0, '']
s leak
[221.6. 95.0, 0.02, 74.78, 'off', 0, 14, 0.0, 0.0, '']
s leak
[221.6. 95.0, 0.02, 74.78, 'off', 0, 16, 0.0, 0.0, '']
s leak
[221.6. 94.0, 0.02, 74.78, 'off', 0, 18, -0.5, -0.5, '']
s leak
[221.6. 94.0, 0.02, 74.78, 'off', 0, 20, 0.0, 0.0, '']
s leak
[221.6. 93.0, 0.02, 74.78, 'off', 0, 22, 0.0, 0.0, '']
s leak
[221.6. 93.0, 0.02, 74.78, 'off', 0, 24, 0.0, 0.0, '']
s leak
[221.6. 92.0, 0.02, 74.29, 'off', 0, 26, 0.0, 0.0, '']
s leak
[221.6. 92.0, 0.02, 74.29, 'off', 0, 28, 0.0, 0.0, '']
s leak
[221.6. 91.0, 0.02, 74.29, 'off', 0, 30, -0.5, -0.5, '']
s leak
```

Legenda: Os dados referem-se respectivamente a tensão, pressão, corrente, temperatura, operação (ligado ou desligado), tempo decorrido, variação de temperatura e pressão e comportamento da tecnologia.

Fonte: Elaborada pelo Autor (2019).

5 CONCLUSÃO

Este trabalho apresentou uma proposta de gestão descentralizada de tecnologia em saúde que utiliza ferramentas para controle e melhoria da qualidade, *internet of things* e sistema de análise cognitiva na gestão de tecnologia da atenção primária à saúde, com caráter inovador nesta área. Dentre as contribuições deste trabalho, tem-se a pesquisa para a definição e aplicação de uma plataforma de Gestão Ubíqua de Tecnologia em Saúde preditiva e com processamento cognitivo.

A aplicação da metodologia estruturada nas categorias operacional, monitoramento e decisão facilita a implementação da metodologia deste trabalho, bem como permite sua aplicação para outras tecnologias de saúde.

As ferramentas para controle e melhoria da qualidade são fundamentais no processo de gestão da tecnologia em saúde e na montagem da plataforma, usadas na categoria operacional tanto para definir as classes de equipamentos, na escolha da tecnologia em saúde na qual foi aplicada a metodologia, na identificação das falhas priorizadas no processo de gestão, bem como, na definição dos parâmetros de monitoramento incorporados na plataforma, que oferece aporte ao gerenciamento da tecnologia em saúde.

A escolha das ferramentas de qualidade pode se adaptar à demanda ou problema para o qual se busca uma solução. Nesta metodologia foram usadas tanto de forma isolada como combinadas de acordo com os objetivos de cada etapa do trabalho.

Na aplicação desta metodologia em outras tecnologias de saúde, existem diferentes possibilidades de uso e combinação dessas ferramentas, cuja escolha deve estar de acordo com a demanda ou problema para qual se busca uma solução.

O monitoramento em tempo real da tecnologia em saúde oferece suporte para engenharia clínica no processo de tomada de decisão, na gestão da tecnologia em saúde, aporta melhoria aos serviços, assistência em saúde, redução de tempo e recursos necessários para a gestão do processo tecnológico.

É fundamental a escolha, testagem e utilização de sensores compatíveis com os parâmetros de monitoramento, de acordo com a faixa de trabalho da tecnologia. A metrologia em saúde deve contribuir para a validação dos sensores e garantir a confiabilidade e qualidade dos dados. Neste caso, foram feitos ensaios com analisadores do laboratório de metrologia em saúde do IEB-UFSC e realizado o monitoramento em tempo real com a coleta de dados da tecnologia em saúde para que fossem utilizados como parâmetros na análise cognitiva.

Além dos sensores utilizados para desenvolver a plataforma, no início do trabalho foi utilizado o sensor de umidade e temperatura ambiente, verificar a umidade e temperatura do abrigo do compressor (local de instalação) é de suma importância para o bom funcionamento da tecnologia e do fornecimento adequado de ar comprimido ao processo tecnológico. Sua aplicação pode ser importante para determinar os tempos de enchimento do compressor. Mas com a utilização do sensor de pressão no sistema e transformador de corrente não foi mais necessário a sua utilização no sistema.

A estrutura do monitoramento é baseada nos conceitos de IoT que aplicados na plataforma através da interconectividade resulta no monitoramento em tempo real da tecnologia.

A adição da plataforma de análise cognitiva desenvolvida na categoria de decisão ao monitoramento é inovadora para o sistema, principalmente pela possibilidade de gerenciar várias tecnologias de saúde ao mesmo tempo, com autonomia e dispensando a presença de um operador. Apenas com a plataforma de monitoramento, requer um operador para visualizar as informações na *Front End* e tomar decisão em caso de alteração no comportamento da tecnologia, por isso, pode perder a eficiência no monitoramento de múltiplas tecnologias.

O desenvolvimento da plataforma de análise cognitiva contou com integração da plataforma *Machine Learning Studio* com resultados satisfatórios para o algoritmo *decision forest*, contudo, viu-se a necessidade de captar mais dados sobre o comportamento normal de modelos diferentes de compressores odontológicos, para treinar o algoritmo, pois cada modelo pode apresentar discrepância leve de comportamento. Também é importante realizar mais simulações de falhas, para melhorar a plataforma de análise cognitiva.

Esta proposta adiciona a possibilidade do uso de mais algoritmos de *machine learning* ao sistema de análise cognitiva para gestão de tecnologia em saúde, com melhorias nos processos operacionais da atenção primária à saúde. Vale ressaltar, que a incorporação de um sistema de análise cognitiva na plataforma pode potencializar o conjunto de ações da engenharia clínica.

A implementação da plataforma numa unidade de saúde funcionou durante um período de dois meses com monitoramento satisfatório da tecnologia em saúde, com a adição da análise cognitiva em funcionamento por simulações em laboratório.

No processo tecnológico da odontologia é fundamental que as demandas e ocorrências sejam atendidas rápida e efetivamente, o que é compatível com a gestão ubíqua de tecnologia em saúde. A escolha do compressor de ar odontológico como exemplo está baseada na análise de impacto, onde ele tem papel crucial em relação aos atendimentos, que em sua maioria

dependem do funcionamento deste equipamento. Sua quebra ou falha pode comprometer os atendimentos, causar perdas para usuários, gestores e operadores dessa tecnologia, por isso, a importância de sua escolha para o caso de estudo analisado e a sua identificação pelas ferramentas de controle e melhoria da qualidade utilizadas.

Este estudo evidenciou a importância do desenvolvimento de novos modelos de gestão de tecnologia na atenção primária à saúde, onde o uso de tecnologia é crescente, especificamente na odontologia, com investimentos de programas governamentais para promover a saúde bucal através de estratégias como o Consultório de Rua, PMAQ-AB, Brasil Sorridente (BRASIL, 2018) e a consequente ampliação de tecnologias na área.

A plataforma desenvolvida mostra-se como ferramenta para gestão descentralizada voltada para tecnologias no âmbito da atenção primária à saúde, que dispõe de recursos e metodologia de gestão e gerenciamento limitados para o processo tecnológico.

Com esta plataforma, a partir dos dados coletados pode ser possível propor planos de ação mais objetivos, baseados nas evidências para o gerenciamento do processo tecnológico, aportando confiança, robustez e segurança aos gestores, operadores e usuários do sistema de atenção primária à saúde.

Assim, demonstra a importância da metodologia apresentada no trabalho como alternativa de gestão descentralizada no processo tecnológico da saúde, na qual possibilita que as tecnologias sejam monitoradas em tempo real e com o uso de ferramentas cognitivas que possibilitam identificação da falha sem a necessidade de um operador e num tempo hábil e auxiliando a equipe na tomada de decisão baseado em evidências e na solução dos problemas baseado em procedimentos operacionais padrão.

Esta metodologia pode ser replicável e expansível para mais tecnologias da atenção primária à saúde. Bem como, permite à a engenharia clínica continuar a desenvolver futuros procedimentos e metodologias de gestão ubíqua de tecnologia em saúde para o aperfeiçoamento da gestão e melhorar seu aporte na atenção primária à saúde.

6 PROPOSTA DE TRABALHOS FUTUROS

Como proposta para trabalhos futuros em decorrência do desenvolvimento deste estudo surgiram vários desafios considerados relevantes:

- Aplicação desta metodologia a outras tecnologias da atenção primária à saúde, como o caso das tecnologias apontadas na categoria operacional, onde autoclave se apresenta como a segunda tecnologia a ser priorizada;
- A implementação e teste de outros algoritmos de *machine learning* para o desenvolvimento de novos modelos que possam melhorar a análise cognitiva no processo de gestão da tecnologia em saúde;
- Incorporação desta plataforma no sistema de informações de gestão em engenharia clínica;
- Desenvolvimento de indicadores de gestão baseados no sistema ubíquo de gestão de tecnologia em saúde;
- Adicionar testes para melhorar a validação da plataforma e ampliar a quantidade de dados com possível formatação em *health level seven* (HL7) para aumentar interoperabilidade e usabilidade da plataforma.

REFERÊNCIAS

AKABANE, G. K. **Gestão estratégica das tecnologias cognitivas: conceitos, metodologias e aplicações**. 1. ed. Érica, 2018.

AL-FUQAHA, A. *et al.* Internet of things: a survey on enabling technologies, protocols, and applications. **IEEE Communications Surveys and Tutorials**, v. 17, n. 4, p. 2347–2376, 2015. Disponível em: <<https://ieeexplore.ieee.org/Xplore/home.jsp>> Acesso em: Ago. 2018

ANDRIOPOULOU, F. G.; BIRKOS, K. D.; LYMBEROPOULOS, D. K. **u-MCHC: A predictive framework for ubiquitous management of exacerbations in chronic diseases**. 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)...Osaka, Japan: 2013. Disponível em: <<https://ieeexplore.ieee.org/Xplore/home.jsp>> Acesso em: Dez. de 2018.

ARDUINO. **Arduino Uno**. Disponível em: <<https://store.arduino.cc/usa/arduinouno-rev3>>. Acesso em: 18 jul. 2020.

ATZORI, L.; IERA, A.; MORABITO, G. The internet of things: a survey. **Computer Networks**, v. 54, p. 2787–2805, 2010.

AVELAR, P. S.; SILVA, C. A. J.; GARCIA, R. **Clinical engineering impacts in primary healthcare**. 3th WHO Global Forum on Medical Devices. **Anais...**Geneva, Switzerland: 2017.

AWAD, M.; KHANNA, R. **Efficient learning machines: theories, concepts, and applications for engineers and system designers**. 1. ed. Berkeley: Aprres, 2015.

BARROS, V. F. A. *et al.* Aplicativo móvel para automação e monitoração do sistema de atenção primária a saúde. **Cadernos de Informática**, v. 6, n. 1, p. 241–244, 2011.

BASSI, A. *et al.* **Enabling things to talk: designing IoT solutions with the IoT architectural reference model**. Berlin: Springer, 2013. Disponível em: <<https://link.springer.com/>> Acesso em: Jan. 2020.

BATISTA, G. E. A. P. A.; MONARD, M. C. **Sniffer: um ambiente computacional para gerenciamento de experimentos de aprendizado de máquina supervisionado**. Proceedings of the I WorkComp Sul...Florianópolis: 2004.

BENSON, T. **Principles of health interoperability HL7 and SNOMED**. 2. ed. Springer, 2012.

BRASIL. Ministério da Saúde. ANVISA. RDC n. 2, de 25 de jan. de 2010. Dispõe sobre o gerenciamento de tecnologias em saúde em estabelecimentos de saúde. **Diário Oficial da União**, Brasília, DF, 25 jan. 2010. Disponível em: <<http://portal.anvisa.gov.br/>>. Acessado em: Fev. 2020.

BRASIL. Ministério da Saúde. **Política Nacional de Saúde Bucal**. 2018. Disponível em: <<http://www.saude.gov.br/acoes-e-programas/politica-nacional-de-saude-bucal/sobre-o-programa>>. Acessado em: Fev 2019.

_____. Lei n. 8.080, de 19 de set. de 1990. Dispõe sobre as condições para a promoção, proteção e recuperação da saúde, a organização e o funcionamento dos serviços correspondentes e dá outras providências. **Diário Oficial da União**, Brasília, DF, 17 set. 1990. Disponível em: <www.planalto.gov.br> Acesso em: Out. 2019.

BRONZINO, J. D. **Management of medical technology: a primer for clinical engineers**. Butterworth-Heinemann, 1992.

BRUNIALTI, L. F. *et al.* **Aprendizado de máquina em sistemas de recomendação baseados em conteúdo textual: uma revisão sistemática**. XI Brazilian Symposium on Information System...Goiânia, Goiás: 2015. Disponível em: <<https://sol.sbc.org.br/index.php/sbsi/article/view/5818>>. Acesso em: Jan. 2020.

BUTZEN, E. **ChronicProfile: um modelo de gerenciamento de perfis dinâmicos orientado a doenças crônicas não transmissíveis**. [Dissertação] Universidade Unisinos, 2018. Disponível em: <<http://www.repositorio.jesuita.org.br/handle>>. Acesso em: Dez. de 2019.

CARPINETTI, L. C. R. **Gestão da qualidade: conceitos e técnicas**. 3. ed. São Paulo: Atlas, 2016.

CASTAÑEDA, W. A. C. **Novo paradigma de engenharia clínica na integração de TIC's para criação de ambientes ubíquos e de interoperabilidade na saúde**. [Dissertação] Universidade Federal de Santa Catarina (UFSC), 2011.

CASTAÑEDA, W. A. C. **Metodologia de gestão ubíqua para tecnologia médico-hospitalar utilizando tecnologias pervasivas**. [Tese] Universidade Federal de Santa Catarina (UFSC), 2016.

CHU, L. C.; LEE, C. L.; WU, C. J. **Applying QR code technology to facilitate hospital medical equipment repair management**. International Conference on Control Engineering and Communication Technology...Liaoning, China: 2012. Disponível em: <<https://ieeexplore.ieee.org/Xplore/home.jsp>>. Acesso em jul. 2018.

DA FONSECA, G. L. O.; ROSA, F. S.; GARCIA, R. **Ubiquitous Management Module for Dental Chair Unit in Clinical Engineering Structure for Primary Health Care**. 2017.

DANIEL, É. A.; MURBACK, F. G. R. Levantamento bibliográfico do uso das ferramentas da qualidade. **Gestão & Conhecimento**, n. 8, p. 43, 2014.

DATASHEET. **LM35**. National Semiconductor. 2000. Disponível em: <<https://www.jameco.com/Jameco/Products/ProdDS/1276463.pdf>> Acesso em Abr. 2018.

DATASHEET. **Sensor de Pressão K1100C**. ISWEEK. 2018.

DATASHEET.**ZMCT103C**. Qingxian Zeming Langxi Electronic. 2018. Disponível em: <<https://datasheet4u.com/datasheet-pdf/ZeMing/ZMCT103C/pdf.php?id=1408475>> Acesso em Abr. 2018.

DATASHEET. **Transformador de tensão 3 +3v**. *Unitel*, 2018.

- ELMASRI, R; NAVATHE, S. B. **Database systems**. Boston, MA: Pearson Education, 2011.
- FENGOU, M. A.; MANTAS, G.; LYMBEROPOULOS, D. **Group profile management in ubiquitous healthcare environment**. 34th Annual International Conference of the IEEE Engineering in Medicine and Biology Society...San Diego, California: 2012. Disponível em: <<https://ieeexplore.ieee.org/Xplore/home.jsp>>. Acesso em Set. 2018.
- FISCHER, F.; AUST, V.; KRÄMER, A. **eHealth in Deutschland**. Heidelberg: Springer, 2016.
- GARCIA, S. J. A. *et al.* **Health care technology management applied to public primary care health**. Pan American Health Care Exchanges....Rio de Janeiro: 2011.
- GEHRING, H.; RACKEBRANDT, K.; IMHOFF, M. E-Health und die Realität – was sehen wir heute schon in der Klinik? **Bundesgesundheitsbl**, v. 61, p. 252–262, 2018. Disponível em: <<https://link.springer.com/>> Acesso em: Mar. 2020
- GIUSTO, D. *et al.* **The internet of things: 20th tyrrhenian workshop on digital communications**. Sardinia, Italy: Springer, 2010.
- GOOGLE. **GOOGLECLOUD**. Disponível em:< <https://cloud.google.com/>>. Acesso em: 17 jul. 2019.
- GOULART, L. J. *et al.* **Saúde e tecnologia da informação: convergência e mobilidade**. Congresso Brasileiro de Informática em Saúde...Bauru: Sociedade Brasileira de Informática em Saúde, 2006.
- GRIGORIADIS, N. *et al.* **Health 4.0: the case of multiple sclerosis**. IEEE 18th International Conference on e-Health Networking, Applications and Services (Healthcom)...Munich, Germany: IEEE, 2016. Disponível em: <<https://ieeexplore.ieee.org/Xplore/home.jsp>> Acesso em: Abr. 2019
- GURESEN, E.; KAYAKUTLU, G. Definition of artificial neural networks with comparison to other networks. **Procedia Computer Science**, v. 3, p. 426–433, 2011.
- HAN, D.; LEE, M.; PARK, S. THE-MUSS: Mobile u-health service system. **Computer Methods and Programs in Biomedicine**, v. 97, n. 2, p. 178–188, 2010.
- IBM. **Watson**. Disponível em:< <https://www.sciencedirect.com/>>. Acesso em: 18 jul. 2019.
- IDOINE, C. *et al.* **Magic quadrant for data science and machine learning platforms**. Gartner, Inc., 2018.
- JIANG, J. *et al.* **Research on the fire warning program of cotton warehousing based on IoT technology**. International Conference on Logistics, Informatics and Service Sciences...Barcelona, Spain: IEEE, 2015. Disponível em: <<https://ieeexplore.ieee.org/Xplore/home.jsp>> Acesso em:
- JUNG, E. Y. *et al.* Home health gateway based healthcare services through U-health platform. **Wireless Personal Communications**, v. 73, p. 207–218, 2013. . Disponível em: <<https://link.springer.com/>> Acesso em: Jan. 2020

KAMPMEIJER, R. *et al.* The use of e-health and m-health tools in health promotion and primary prevention among older adults: A systematic literature review. **BMC Health Services Research**, v. 16, n. Suppl 5, p. 290, 2016.

KHAN, R. *et al.* **Future internet: the internet of things architecture, possible applications and key challenges**. 10th International Conference on Frontiers of Information Technology Future...Islamabad, India: IEEE, 2012. Disponível em: <<https://ieeexplore.ieee.org/Xplore/home.jsp>> Acesso em: Fev. 2019.

KLEINBAUM, D. G.; KLEIN, M. **Logistic regression: a self-learning text**. 2. ed. Springer-Verlag New York, 2002.

LABUDA, N. *et al.* Medical 4.0: medical data ready for deep and machine learning. **Journal of Bioanalysis & Biomedicine**, v. 09, n. 6, p. 283–287, 2017.

LEITE, F. A. **Aplicação de Internet das Coisas e Domótica Para Auxílio às Pessoas com Necessidades Especiais**. [Dissertação] Universidade Paulista- UNIP, 2017. Disponível em: <http://repositorio.unip.br/wp-content/uploads/tainacanitem/198/10903/eng_fabiodearaujoleite.pdf>. Acesso em: Dez. de 2019.

LUONG, N. C. *et al.* Data collection and wireless communication in internet of things (IoT) using economic analysis and pricing models: a survey. **IEEE Communications Surveys and Tutorials**, v. 18, n. 4, p. 2546–2590, 2016. Disponível em: <<https://ieeexplore.ieee.org/Xplore/home.jsp>> Acesso em: Mai. 2018.

MACÊDO, R. M. P. R. *et al.* **O uso das ferramentas da qualidade no gerenciamento do lixo hospitalar**. Anais do XXI Encontro Nacional de Engenharia de Produção (ENEGEP)...Salvador: 2001.

MAGALHÃES, J. M. **Modelos de gestão: qualidade e produtividade**: As 7 ferramentas da qualidade, 2015. Disponível em: <http://siseb.sp.gov.br/arqs/9%20-%207_ferramentas_qualidade.pdf>. Acesso em: 18 jul. 2019.

MARR, B. What everyone should know about cognitive computing. **Forbes**, 2016.

MARTINS, J.; VIEIRA, A. V.; GARCIA, R. O. Use of the HFMEA tool for decision making processes in management of maintenance contracts and equipment management in Primary Health Care. XXI Congresso Argentino de Bioingeniería y X Jornada de Ingeniería Clínica (SABI)... Argentina: 2017.

MCCARTHY, J. P. *et al.* Health technology management. In: **Clinical Engineering: a handbook for clinical and biomedical engineers**. 1. ed. Academic Press, 2014. p. 43–57.

MCEWEN, A.; CASSIMALLY, H. **Designing the internet of things**. 1. ed. United Kingdom: John Wiley & Sons, 2014.

MICROSOFT. **What is machine learning studio (classic)?** Disponível em: <<https://docs.microsoft.com/en-us/azure/machinelearning/studio/what-is-ml-studio>>. Acesso em: 18 jul. 2019.

_____. **Documentação Azure.** Disponível em: <<https://docs.microsoft.com/pt-br/azure/?product=featured>>. Acesso em: 18 jul. 2020.

MINIMOL, V. K.; SHAJI, R. S. **Body area network: the driving technology for M-health with a novel scheduling scheme.** Global Conference on Communication Technologies (GCCT)...Thuckalay, India: IEEE, 2015. Disponível em: <<https://ieeexplore.ieee.org/Xplore/home.jsp>> Acesso em: Nov. 2018.

MISHRA, A. K.; NAGPAL, D.; SINGH, L. **Characteristics showing the ubiquity of software projects.** International Conference on Computing, Communication and Automation (ICCCA 2015)...Noida, India: IEEE, 2015. Disponível em: <<https://ieeexplore.ieee.org/Xplore/home.jsp>> Acesso em: Dez. 2019.

MOHAMED, N.; AL-JAROODI, J. **The impact of industry 4.0 on healthcare system engineering.** IEEE International Systems Conference (SysCon)...Orlando, USA: IEEE, 2019.

MORAES, L. **Metodologia para auxiliar na definição de indicadores de desempenho para a gestão da tecnologia médico-hospitalar.** [Tese] Universidade Federal de Santa Catarina (UFSC), 2007.

NOGARE, D.; ZAVASCHI, T. **Análise preditiva com azure machine learning e R.** São Paulo: B2U, 2016.

GARCIA, R; PEZZOLLA, F. M. G.; FILHO, R. D. S. **Health technology ubiquitous management model for primary health care.** 4th WHO Global Forum on Medical Devices...Visakhapatnam: 2018.

OZA, N. C.; TUMER, K. Applications of ensemble methods. **Information Fusion**, v. 9, p. 2–3, 2008.

PALMA, J. M. B. **As tecnologias ubíquas aplicadas na área da saúde: uma análise dos requisitos do u-healthcare.** [Dissertação] Universidade Estadual de Campinas (Unicamp), 2019.

PINTO, D. M. R.; LOPES, N.; SILVA, J. P. Study and comparison of automatic learning tools: Tensorflow with google cloud and azure machine learning. **2018 Proceedings**, n. 13, 2018.

PUANGSAIJAI, W.; PUNTHEERANURAK, S. **A comparative study of relational database and key-value database for big data applications.** 5th International Electrical Engineering Congress...Pattaya, Thailand: IEEE, 2017. Disponível em: <<https://ieeexplore.ieee.org/Xplore/home.jsp>> Acesso em: Mar. 2020.

RAMOS, A.; SOUZA, S. A.; LIMA, C. J. **Ferramentas da qualidade aplicadas na acreditação hospitalar.** XI Encontro Latino Americano de Iniciação Científica e VII Encontro Latino Americano de Pós-Graduação...São José dos Campos: Univap, 2007.

RASPBERRYPI. **Raspberry Pi 3 Model B**. Disponível em <<https://www.raspberrypi.org/>>. Acesso em: 02 de Janeiro 2018.

ROCHA, T. *et al.* Tutorial sobre Fuzzy-c-Means e Fuzzy learning vector quantization: abordagens híbridas para tarefas de agrupamento e classificação. **Revista de Informática Teórica e Aplicada**, v. 19, n. 1, p. 120–163, 2012.

RODRIGUES, L. O. **Manual do usuário linha odontológica**. 8. ed. Palhoça, Brasil: OLSEN, 2019. 40 p. Disponível em: <http://olsen.odo.br/upload/ManualdoUsuarioLinhaOdonto_5409170_R08_20190826.pdf>. Acesso em: 18 jul. 2019.

SHULZ. Manual de instrução. **Compressor de pistão acionamento direito e por correia isento de óleo**. 11. ed. Joinville, Brasil: SHULZ, 2011. 19 p.

ROKACH, L. Decision forest: Twenty years of research. **Information Fusion**, v. 27, p. 111–125, 2016.

SALES, M. Diagrama de Pareto. 2013. Disponível em: <https://www.academia.edu/23719178/Diagrama_de_Pareto>. Acesso em: 24 nov. 2020.

SANTOS, B. *et al.* Controle de uma plataforma reconfigurável de tecnologia assistiva incorporada à saúde 4.0. In: **Tecnologia Assistiva. Pesquisa e Conhecimento II**, v. 2p. 92–113.

SANTOS, B. P. *et al.* **Internet das coisas: da teoria à prática**. XXXIV SBRC...Salvador: 2016.

SANTOS, I.; ROSA, F.; GARCIA, R. **Development of na ubiquitous management platform in air compressors used in primary healthcare**. In: International Clinical Engineering and Health Technology Management Congress...São Paulo: 2017.

SANTOS, R. A. L. **Sistemas centralizados de gases e vácuo medicinais: uma abordagem para o gerenciamento da tecnologia médico-hospitalar**. [Dissertação] Universidade Federal de Santa Catarina (UFSC), 2002.

SANTOS, R.; SOUZA, R. E. H.; GARCIA, R. **Health care technology management applied to public hospitals in Santa Catarina - Brazil**. First WHO Global Forum on Medical Devices. **Anais**.Bangkok, Thailand: 2011.

SARAVANAN, R.; SUJATHA, P. **Algorithms: a perspective of supervised learning approaches in data classification**. Second International Conference on Intelligent Computing and Control Systems (ICICCS)...Madurai, India: IEEE, 2018. Disponível em: <<https://ieeexplore.ieee.org/Xplore/home.jsp>> Acesso em: Jul. 2020.

SARKAR, C. *et al.* A scalable distributed architecture towards unifying IoT applications. **IEEE World Forum on Internet of Things, WF-IoT**, p. 508–513, 2014. Disponível em: <<https://ieeexplore.ieee.org/Xplore/home.jsp>> Acesso em: Mai. 2019.

SECTOR, S.; ITU, O. **Series y: Global information infrastructure, internet protocol**

aspects and next-generation networks, internet of things and smart cities -Next generation networks – Enhancements to NGN. Y.2340 ed. Geneva, Switzerland: International Telecommunication Union, 2016.

SELEME, R.; STADLER, H. Controle da Qualidade - As Ferramentas Essenciais. 2. ed. Curitiba - Pr: Xibpex, 2010. 180 p.

SHOTTON, J. *et al.* **Decision jungles: compact and rich models for classification supplementary material.** Neural Information Processing Systems Conference...2013.

SIGNORI, M. R. **Contribuição da engenharia clínica para programa de qualidade em laboratórios clínicos.** [Dissertação] Universidade Federal de Santa Catarina, 2008.

SINGH, K.; SINGH TOMAR, D. D. Architecture, enabling technologies, security and privacy, and applications of internet of things: A survey. **Proceedings of the International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud), I-SMAC 2018**, v. 4, n. 5, p. 642–646, 2019.

SNEHA, Sweta; STRAUB, Detmar. E-Health: Value proposition and technologies enabling collaborative Healthcare. In: **Proceedings of the 50th Hawaii International Conference on System Sciences.** 2017. Disponível em: <<https://scholarspace.manoa.hawaii.edu/handle/10125/41260>>. Acesso em 20 jul. 2019

SOARES FILHO, R. D.; MARTINS, J.; GARCIA, R. Methodology for Defining Ubiquitous Management Indicators in Primary Health Care. In: **Latin American Conference on Biomedical Engineering.** Springer, Cham, 2019. p. 1298-1305.

SOARES, G. G. **Programa de formação em metrologia.** Cálculo de incerteza de medição para ensaios. Florianópolis: Fundação Certi, 2017. Disponível em: <<https://www.certi.org.br/pt/servicoseprodutos-treinamentos>>. Acesso em: 01 dez. 2018.

SOMBRA, E. L. **Mobilehealth: um ambiente de apoio à saúde 2.0.** [Dissertação] Universidade Federal Rural Semi-Árido, 2015.

SONG, Y. E. *et al.* Research on applications of the internet of things in the smart grid. **Proceedings - 2015 7th International Conference on Intelligent Human-Machine Systems and Cybernetics, IHMSC 2015**, v. 2, p. 178–181, 2015.

SOUZA, M. A.; SILVA, M. A. M.-A. **Adequação de ferramentas de gestão da qualidade às clínicas de saúde.** Seminário Estudantil de Produção Acadêmica...Salvador: 2008.

SPALL, D. S.; SIMIONI, M. B. R. **Procedimento da qualidade.** Determinação da incerteza da medição. 6. ed. Florianópolis: Instituto de Engenharia Biomédica (UFSC), 2014. 20 p. (PQ-007).

TEIXEIRA, T. C. A.; CASSIANI, S. H. B. Root cause analysis: evaluation of medication errors at a university hospital. **Revista da Escola de Enfermagem da USP**, v. 44, n. 1, p. 137–144, 2010.

THURMAN, P. W. **Estatística**. 1. ed. Saraiva, 2017.

TONG, W. *et al.* Decision forest: combining the predictions of multiple independent decision tree models. **Journal of Chemical Information and Computer Sciences**, v. 43, n. 2, p. 525–531, 2003.

VYAWAHARE, H. R.; KARDE, P. P.; THAKARE, V. M. **A hybrid database approach using graph and relational database**. International Conference on Research in Intelligent and Computing in Engineering (RICE)...San Salvador, El Salvador: IEEE, 2018. Disponível em: <<https://ieeexplore.ieee.org/Xplore/home.jsp>> . Acesso em 15:jul 2019.

WEISER, M. The computer for the 21st century. **Scientific American**, p. 94–104, 1991.

WORLD HEALTH ORGANIZATION. **mHealth: New Horizons for Health through mobile technologies: based on the findings of the second global survey on eHealth (Global observatory for eHealth series)**. 1. ed. Switzerland: World Health Organization, 2010.

WU, M. *et al.* Research on the architecture of Internet of things. In: **Advanced Computer Theory and Engineering (ICACTE)**, 2010 3rd International Conference on. IEEE, 2010. P. V5-484-V5-487. Disponível em: <<http://ieeexplore.ieee.org/search/advsearch.jsp>>. Acesso em: 13 fev. 2018.

YEUNG, J. *et al.* Integrating Machine Learning Technology to Data Analytics for E-Commerce on Cloud. In: **2019 Third World Conference on Smart Trends in Systems Security and Sustainability (WorldS4)**. IEEE, 2019. p. 105-109. Disponível em: <<http://ieeexplore.ieee.org/search/advsearch.jsp>> Acesso em 23 Mar. 2020. Acesso em: 13 nov. 2019.

APÊNDICE A – Folha para coleta de dados dos equipamentos registrados no sistema de informações do IEB-UFSC na rede de APS do município de Florianópolis.

Planilha 1 Folha para coleta de dados geral

Nome do Equipamento	Quantidade de OS	Número de equipamentos	Média de OS	Mediana de OS

Fonte: Elaborada pelo próprio autor (2018)

APÊNDICE B – Quantidade de OS por equipamento registrados no sistema de informações do IEB-UFSC da rede de Atenção Primária à Saúde do município de Florianópolis.

Planilha 2 Quantidade de OS pôr equipamentos

Equipamentos	Quantidade de OS
Cadeira Odontológica	5287
Balança eletrônicas	2239
Autoclave	1889
Seladora de CME	1522
Compressor Odontológico	1338
Detector de Batimento Fetal	1122
Fotopolimerizador	728
Eletrocardiógrafo	458
Aparelho de Profilaxia Odontológico	419
Foco Clínico	282
Oxímetro de Pulso	227
Amalgamador	189
Nebulizador	178
Aparelho de RX Fixo	115
Monitor Multiparâmetro	104
Colposcópico	98
Aparelho de Ultrassonografia	95
Negatoscópico	94
Centrífuga de Laboratório	79
Aparelho de RX Odontológico	72
Bisturi eletrônico	71
Foco Cirúrgico Móvel	67
Cardioversor	64
Estufa de Laboratório	51
Desfibrilador	46
Aspirador Cirúrgico	43
Estimulador Elétrico Transcutâneo	42

Monitor Cardíaco	42
Aparelho de ondas curtas	36
Processador de Filmes Radiológicos	32
Esteira Ergométrica	30
Ventilador Pulmonar	24
Microscópio Biológico	22
Capela de Fluxo Laminar	19
Eletroencefalógrafo	17
Bomba a Vácuo Odontológica	16
Localizador Apical	10
Deionizado	9
Lâmpada de Fenda	8
Cronômetro	7
Imitanciômetro	7
Aparelho de infravermelho de fisioterapia	6
Lensômetro	6
Turbidímetro	6
Agitador Orbital	5
Banho Maria	5
Berço Aquecido	5
Cabine Audiometria	5
Bomba de infusão	4
Retinoscópio	4
Calorímetro	3
Refrator de Greens	3
Contador de Células	2
Foco Cirúrgico Fixo	2
Fluorímetro	2
Mesa cirúrgica	2
Turbilhão	2
Coluna oftalmológica	1
Espectrofotométrico	1

Oftalmoscópio Binocular Indireto	1
Oftalmoscópio Direto	1
Total	17264

Fonte: Elaborada pelo próprio autor (2018)

APÊNDICE C – Quantidade de equipamentos, média e mediana de equipamento por OS abertas registradas no sistema de informações do IEB-UFSC da rede de Atenção Primária à Saúde do município de Florianópolis.

Planilha 3 Número de equipamentos individuais com a média e mediana de OS registrados.

Equipamentos	Número de equipamentos	Média de OS	Mediana de OS
Agitador Orbital	5	1,00	2
Amalgamador	117	1,62	2
Aparelho de Infravermelho de Fisioterapia	13	0,46	1
Aparelho de Ondas Curtas	11	3,27	3
Aparelho de Profilaxia Odontológico	93	4,51	4,5
Aparelho de RX Fixo	2	57,50	57,5
Aparelho de RX Odontológico	15	4,80	4
Aparelho de Ultrassonografia	9	10,56	8
Aspirador Cirúrgico	19	2,26	2
Autoclave	142	13,30	12
Balança	723	3,10	3
Banho Maria	6	0,83	1
Berço Aquecido	3	1,67	2,5
Bisturi Eletrônico	36	1,97	2
Bomba a Vácuo Odontológica	3	5,33	4
Bomba de Infusão	2	2,00	2
Cabine Audiometria	1	5,00	5
Cadeira Odontológica	142	37,23	34
Calorímetro	2	1,50	1,5
Capela de Fluxo Laminar	1	19,00	19
Cardioversor	14	4,57	4
Centrífuga de Laboratório	21	3,76	4
Colposcópico	11	8,91	10
Coluna oftalmológica	1	1,00	2

Compressor Odontológico	154	8,69	8
Contador de Células	1	2,00	2
Cronômetro	2	3,50	3,5
Deionizado	3	3,00	6
Desfibrilador	21	2,19	3
Detector de Batimento Fetal	347	3,23	3
Eletrocardiógrafo	22	20,82	10
Eletroencefalógrafo	3	5,67	8
Espectrofotométrico	6	0,17	1
Esteira Ergométrica	2	15,00	6
Estimulador Elétrico Transcutâneo	9	4,67	6
Estufa de Laboratório	49	1,04	1
Fluorímetro	1	2,00	2
Foco Cirúrgico Fixo	1	2,00	2
Foco Cirúrgico Móvel	23	2,91	5,5
Foco. Clínico	196	1,44	1
Fotopolimerizador	160	4,55	4
Imitanciômetro	1	7,00	7
Lâmpada de Fenda	1	8,00	8
Lensômetro	1	6,00	6
Localizador apical	3	3,33	4
Mesa Cirúrgica	2	1,00	1
Microscópio Biológico	24	0,92	1
Monitor Cardíaco	11	3,82	5
Monitor Multiparâmetro	12	8,67	6
Nebulizador	123	1,45	2
Negatoscópio	272	0,35	1
Oftalmoscópio Binocular Indireto	1	1,00	1
Oftalmoscópio Direto	1	1,00	2
Oxímetro de Pulso	52	4,37	4
Processador de Filmes Radiológicos	4	8,00	1
Refrator de Greens	1	3,00	1
Retinoscópio	2	2,00	1

Seladora de CME	142	10,72	1
Turbidímetro	3	2,00	1
Turbilhão	1	2,00	1
Ventilador Pulmonar	4	6,00	1

Fonte: Elaborada pelo próprio autor (2018)

APÊNDICE D - Matriz de priorização com a mediana de OS aberta por equipamentos e a como fator de multiplicação com o GUT.

Planilha 4 Matriz de priorização, mediana e a multiplicação do valor da mediana com a matriz de priorização.

Equipamento	G	U	T	Total (GUT)	Mediana	Mediana*GUT
Agitador Orbital	2	2	1	4	2	8
Amalgamador	3	3	1	9	2	18
Aparelho de Infravermelho de Fisioterapia	3	3	1	9	1	9
Aparelho de Ondas Curtas	3	3	1	9	3	27
Aparelho de Profilaxia	1	2	1	2	4,5	9
Aparelho de RX Fixo	2	2	1	4	57,5	230
Aparelho de RX Odontológico	3	3	1	9	4	36
Aparelho de Ultrassonografia	3	3	1	9	8	72
Aspirador Cirúrgico	2	2	1	4	2	8
Autoclave	4	4	5	80	12	960
Balança	1	1	1	1	3	3
Banho Maria	2	2	1	4	1	4
Berço Aquecido	5	5	1	25	2,5	62,5
Bisturi eletrônico	3	3	1	9	2	18
Bomba a Vácuo Odontológica	2	3	3	18	4	72
Bomba de infusão	3	3	1	9	2	18
Cabine Audiometria	3	3	1	9	5	45
Cadeira Odontológica	3	3	2	18	34	612
Calorímetro	3	3	1	9	1,5	13,5
Capela de Fluxo Laminar	3	3	1	9	19	171
Cardioversor	5	5	1	25	4	100
Centrífuga de Laboratório	3	3	1	9	4	36


Coloscópio	3	3	1	9	10	90
Coluna Oftalmológica	3	3	1	9	2	18
Compressor Odontológico	5	5	5	125	8	1000
Contador de Células	3	3	4	36	2	72
Cronômetro	1	1	1	1	3,5	3,5
Deionizado	2	2	1	4	6	24
Desfibrilador	5	5	1	25	3	75
Detector de Batimento	1	2	1	2	3	6
Electrocardiógrafo	2	2	1	4	10	40
Electroencefalógrafo	3	3	1	9	8	72
Espectrofotométrico	3	3	1	9	1	9
Esteira Ergométrica	3	3	1	9	6	54
Estimulador Elétrico Transcutâneo	3	3	1	9	6	54
Estufa de laboratório	2	2	1	4	1	4
Fluorímetro	2	2	1	4	2	8
Foco Cirúrgico Fixo	5	5	1	25	2	50
Foco Cirúrgico Móvel	4	4	1	16	5,5	88
Foco Clínico	1	1	1	1	1	1
Fotopolimerizador	3	3	1	9	4	36
Imitanciômetro	3	3	1	9	7	63
Lâmpada de Fenda	3	3	1	9	8	72
Lensômetro	3	3	1	9	6	54
Localizador apical	2	2	1	4	4	16
Mesa cirúrgica	4	4	1	16	1	16
Microscópio Biológico	3	3	1	9	1	9

Monitor Cardíaco	3	3	1	9	5	45
Monitor Multiparâmetro	3	3	1	9	6	54
Nebulizador	2	3	1	6	2	12
Negatoscópico	2	1	1	2	1	2
Oftalmoscópio Binocular Indireto	3	3	1	9	1	9
Oftalmoscópio Direto	3	3	1	9	2	18
Oxímetro de Pulso	2	2	1	4	4	16
Processador de Filmes Radiológicos	3	3	1	9	1	9
Refrator de Greens	3	3	1	9	1	9
Retinoscópico	3	3	1	9	1	9
Selador CME	3	2	1	6	1	6
Turbidímetro	2	2	1	4	1	4
Turbilhão	3	3	1	9	1	9
Ventilador Pulmonar	5	5	1	25	1	25

Fonte: Elaborada pelo próprio autor (2018)

APÊNDICE E – Características estruturais do compressor de ar comprimido odontológico

Figura 1: Compressor de ar odontológico



Fonte: SHULZ, 2011

1. Bloco Compressor - aspira e comprime o ar atmosférico;
2. Reservatório de Ar - acumula o ar comprimido;
3. Motor Elétrico com Protetor Térmico - aciona o bloco compressor;
5. Pressostato - controla o funcionamento do compressor sem exceder a pressão máxima de trabalho permitida;
6. Válvula de Segurança - despressuriza o reservatório em uma eventual elevação da pressão acima da máxima permitida;
8. Purgador - utilizado para retirar o condensado (água) contido no interior do reservatório;
9. Manômetro - indica a pressão manométrica no interior do reservatório em lbf/pol², barg, psig ou kgf/cm²;
10. Registro/Regulador de Pressão - utilizado para ajustar a pressão de trabalho e liberar o ar comprimido;
11. Serpentina (s) de Descarga - conduz e resfria o ar comprimido;
12. Filtro de Ar - retém as impurezas contidas no ar atmosférico aspirado pelo compressor operando em condições normais;
13. Plaqueta de Identificação/Adesivo informativo - indica os dados técnicos do compressor;

15. Conexão para rede de ar 1/4" NPT - utilizado para conectar à rede pneumática através de mangueira, para atuar o pressostato;
16. Cabo elétrico - utilizado para conectar o compressor à rede elétrica 127V e 220V;
18. Vibra *Stop* ou Pé de borracha - isolar a vibração produzidas pelo compressor do solo;
20. Protetor Térmico - protege o motor elétrico contra sobrecarga;
21. Carenagem/Protetor de correia - permite melhor refrigeração do bloco compressor e segurança para o usuário da parte girante.

APÊNDICE F – Características técnicas do compressor de ar comprimido odontológico

Planilha 5 – Características técnicas do compressor odontológico

<p>1.NOME: Compressor de Ar Odontológico Isento de Óleo</p>
<p>2. DESCRIÇÃO TÉCNICA:</p> <p>Compressor odontológico isento de óleo, para atender 1 consultórios odontológicos e clínicas médicas, que necessitem ar isento de óleo padrão medicinal.</p>
<p>3. CARACTERÍSTICAS TÉCNICAS / ACESSÓRIOS:</p> <p>Compressor odontológico isento de óleo, atende 1 consultórios odontológicos e clínicas médicas, ar isento de óleo padrão medicinal.</p> <ul style="list-style-type: none"> • Volume do vaso de pressão 25 litros; • Vaso de pressão deve ter tratamento anticorrosivo internamente; • Potência do motor de 1HP; • Rotação máxima 1700 RPM; • Nível de ruído Máximo 70 dB (A); • Deslocamento teórico mínimo 6PCM – 170l/min; • Pistões lubrificadas com anéis grafitados ou outro <i>método isento de óleo</i>; • Pressão Máx. de Operação 120 Lbf/pol²; • Pressão de Operação: Mínima - 80 lbf/pol²; • Possuir válvula de segurança; • Possuir manômetro de pressão; • Possuir filtro de aspiração; • Possuir pressostato com chave liga/desliga automático; • Acessórios: <ul style="list-style-type: none"> ○ Válvula reguladora de saída; ○ Conjunto de filtros (partículas 5 micras e coalescente 98,5 a 99,99% na remoção de partículas maiores que 0,3 a 0,6 micra); ○ Purgador automatizado: ○ Intervalo de drenagem: 1.0 a 59 min, Duração de drenagem: 1.0 a 59 seg., Vazão máxima de condensado: 576 l/h - 16 bar; ○ Conjunto de plataformas, vibra stop; ○ Cabo de alimentação;

<ul style="list-style-type: none">• Características elétrica do equipamento;<ul style="list-style-type: none">○ Tensão nominal: 220V - 60Hz;	
Insumos Diretos:	<ul style="list-style-type: none">• Filtros de admissão;• Filtros de saída;• Vibra-<i>stop</i>;• Mangueiras;

Fonte: Elaborada pelo próprio autor (2018)

**APÊNDICE G – Folha para coleta e dados do compressor de ar comprimido
odontológico.**

Planilha 6 – Folha de coleta de dados

Nome do Equipamento	Número de registro	Número de O.S abertas	Falha

Fonte: Elaborada pelo próprio autor (2018)


APÊNDICE H – Organização dos tipos de falha do compressor de ar odontológico isento de óleo

Planilha 7 - Tipos e quantidade de falhas no compressor odontológico.

Causa Efeito	Quantidade de Falha
Vazando pela mangueira, pelo engate ou pelo regulador	45
Defeito na válvula, anéis e juntas do pistão	38
Vazamento pelo purgador.	34
Vazamento pelas serpentinas	11
Pistão travado	10
Pressostato	10
Capacitor com defeito	8
Sem alimentação elétrica	8
Bobinas do motor queimado/em curto	6
Vibra-stop e Ventoinha maus instalado e/ou desbalanceada;	6
Sensor	1
Protetor térmico	0
Vibração causada por “vibras-stop” e/ou coxim do motor desgastados, desgaste de peças internas.	0
Umidade poderá trancar o eixo e a mola da válvula.	0
Total de Falhas	177


Fonte: Elaborada pelo próprio autor (2018)

Planilha 9 - Características do Transformador de Corrente (ZMCT103C)

Transformador de Corrente (ZMCT103C)	Características	Valor Típico
	Alcance de Detecção	0 – 10 A 0-10A (50Ω)
	Corrente nominal de saída	5 mA
	Material do sensor	Epoxi
	Proporção de voltagens:	$N_p: N_s = 1: 2.500$
	Precisão	2%
	Relação atual	5A: 2mA
	Resistência D.C. do enrolamento a 20 ° C	155 Ω
	Temperatura de Trabalho	-40 a 85°C
	Tensão de Isolamento	3000V
	Material de vedação	Resina epóxi
	Tensão Dielétrica Suportável Tensão de saída	4000 V/1 mA/ 1s


Fonte: *Datasheet* Transformador de Corrente (ZMCT103C) (Qingxian Zeming Langxi Electronic)

Planilha 10 - Transformador de Tensão

Transformador de Tensão 3V+3V	Características	Valor Típico
	Tipo	Abaixador
	Tensões do primário	110 / 220V
	Tensões do secundário	3+3 Voltage Current Alternated (VAC)
	Corrente do secundário	300mA
	Comprimento x largura x altura	6.6 cm x 3.7 x cm x 3.5 cm

Fonte: *Datasheet* Transformador de Tensão 3V+3V (UNITEL)

Planilha 11 - Características da placa Arduino UNO Rev

Arduino UNO Rev 3	Características	Valores típicos
	Arquitetura	AVR – 8 bits
	Memória RAM	2 KB
	Memória <i>Flash</i> Programável	32 KB
	Velocidade	16 MHz
	Portas Digitais	14
	Resolução A/D	10 bits
	Portas A/D	6
	Consumo de energia (mA)	30 mA

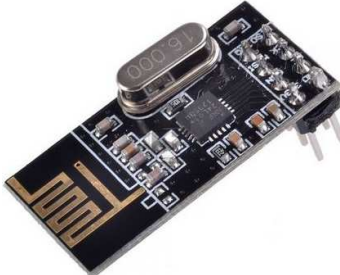
Fonte: *Datasheet* Arduino UNO Rev 3 (ATMEL Corporation)

Planilha 12 - Características do microcontrolador *ATmega328* embutido no *Arduino UNO*

Características	Valor típico
Voltagem de Operação	1.8 a 5.5 V, padrão 5V DC
Velocidade	1 – 20 MHz @ 1.8 a 5.5 V
Pinos digitais de I/O	14 (6 com saída PWM)
Pinos de Entrada Analógica	6
Corrente DC por pino	40 mA
Memória <i>Flash</i>	32KB (0.5 KB usado para o <i>bootloader</i>)

Fonte: *Datasheet* Arduino UNO Rev 3 (ATMEL Corporation)


Planilha 13 - Transceptores de radiofrequência nRF24L01+

Modulo transceptor RF nrf24l01+	Características	Valores típicos
	Velocidade de comunicação	2Mbps
	Alcance	10 m em ambientes fechados e 50 em abertos
	Modo de uso	Emissor e Receptor
	Tensão de alimentação	1,9 a 3,6 V
	Taxa de transmissão	Velocidade de comunicação: 2Mbps
	Alcance	10 m em ambientes fechados e 50 em abertos
	Modo de uso	Emissor e Receptor
	Frequência de operação	2,4 GigaHertz
	Corrente durante a transmissão	11,3 mA;
	Corrente durante a recepção	12,3mA;
	<i>Buffer:</i>	1 até 32 bytes de dados por vez;
	<i>Dimensões:</i>	15 x 29mm.
	Temperatura de trabalho	-40 85°C
	Número de comunicações	Até 6

Fonte: *Datasheet* Modulo transceptor RF nrf24l01+ (Arrow Electronics)


APÊNDICE J – Características dos componentes que compõem o módulo concentrador

Planilha 14 - Características do *Raspberry Pi 3 Model B*

<i>Raspberry Pi 3 Model B</i>	Características
	Processador <i>Broadcom</i> BCM2837B0, <i>Cortex-A53</i> (ARMv8) 64-bit SoC @ 1.4GHz
	Memória RAM 1GB LPDDR2 SDRAM
	<i>Gigabit Ethernet over USB 2.0</i>
	40-pin GPIO
	Conector de interface HDMI
	4 portas USB 2.0
	Conector CSI para câmera <i>Raspberry Pi</i>
	Conector DSI para display capacitivo <i>Raspberry Pi</i>
	Saída de vídeo composto e áudio através do <i>plug P4</i>
	Slot cartão micro SD para carregamento do sistema operacional e armazenamento de arquivos
	Entrada de fonte DC micro USB 5V/2.5 ^a
	Adaptador <i>Wifi</i> 802.11n integrado
	<i>Clock</i> 1.2 GHz
	Dimensões: 85 x 56 x 17mm

Fonte: *Datasheet Raspberry Pi 3 Model B (Raspberry Pi Foundation)*

Planilha 15 - Características do RTC DS 3231

RTC DS 3231	Chip:	DS1307
	Computa	Segundos, minutos, horas, dias da semana, dias do mês, meses e anos (de 2000 a 2099).
	Interface.	I2C – 2 fios
	Circuito Interno	Detecção de falha de energia.
	Dimensões	27 x 28 x 8,4mm
	Faixa de trabalho	Faixa de temperatura: -40°C a +85°C.
	Tensão de Operação	3,3-5V

Fonte: *Datasheet* RTC DS 3231 (Dallas Semiconductor)