



INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ  
PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Francisco de Sousa Junior

**Next-GISSA, um Sistema Inteligente para o Monitoramento e Predição  
de Hipertensão Arterial em uma Plataforma de Saúde Digital**

Fortaleza - CE

30 de novembro de 2022

Francisco de Sousa Junior

## Next-GISSA, um Sistema Inteligente para o Monitoramento e Predição de Hipertensão Arterial em uma Plataforma de Saúde Digital

Dissertação submetida ao Programa de Pós-Graduação em Ciência da Computação do Instituto Federal de Educação, Ciência e Tecnologia do Ceará, como requisito parcial para obtenção do grau de Mestre em Ciência da Computação.

Linha de Pesquisa: Informática na Saúde

Orientador: Prof. Dr. Antônio Mauro Barbosa de Oliveira

Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

Pró-Reitoria de Pesquisa, Pós-Graduação e Inovação (PRPI)

Programa de Pós-Graduação em Ciência da Computação (PPGCC)

Fortaleza – CE

30 de novembro de 2022

Dados Internacionais de Catalogação na Publicação  
Instituto Federal do Ceará - IFCE  
Sistema de Bibliotecas - SIBI

Ficha catalográfica elaborada pelo SIBI/IFCE, com os dados fornecidos pelo(a) autor(a)

---

SOUSA JUNIOR, Francisco de.

Next-GISSA, um Sistema Inteligente para o Monitoramento e Predição de Hipertensão Arterial em uma Plataforma de Saúde Digital : Informática na Saúde / Francisco de SOUSA JUNIOR. - 2022.

96 f. : il.

Dissertação (Mestrado) - Instituto Federal do Ceará, Mestrado em Ciência da Computação, Campus Fortaleza, 2022.

Orientação: Prof. Dr. Antônio Mauro Barbosa de Oliveira.

1. Hipertensão Arterial. 2. Aprendizagem de Máquina. 3. IoT. I. Título.

CDD 004

---

Francisco de Sousa Junior

## Next-GISSA, um Sistema Inteligente para o Monitoramento e Predição de Hipertensão Arterial em uma Plataforma de Saúde Digital

Dissertação submetida ao Programa de Pós-Graduação em Ciência da Computação do Instituto Federal de Educação, Ciência e Tecnologia do Ceará, como requisito parcial para obtenção do grau de Mestre em Ciência da Computação.

Linha de Pesquisa: Informática na Saúde.

### **BANCA EXAMINADORA**

---

Prof. Dr. Antônio Mauro Barbosa de Oliveira (Orientador)  
Instituto Federal do Ceará (IFCE)

---

Profª. Dra. Ivana Cristina Holanda Cunha Barreto  
Fundação Oswaldo Cruz Ceará (Fiocruz)

---

Prof. Dr. Antônio Wendell de Oliveira Rodrigues  
Instituto Federal do Ceará (IFCE)

## AGRADECIMENTOS

Agradeço primeiramente a Deus, por ter permitido chegar até esta estação. Quero externar minha gratidão aos meus pais (Eleusina Nunes de Oliveira e José Meneses de Sousa (in memorian)) que sempre acreditaram, incentivaram e investiram na minha formação. Tenho consciência que o melhor de vocês faz quem eu sou hoje. À minha esposa Alexsandra Muniz e aos meus filhos Rafael e Raquel pois muitas já foram às vitórias ao longo da minha caminhada, mas essa em especial é nossa. Aos meus colegas e amigos que estivemos juntos e muitas vezes distantes presencialmente devido o contexto da pandemia, mas que de algum modo corroboraram para o meu caminhar. Agradecimento especial aos colegas: Renato Alexandre, Joyce Quintino, Renato Freitas, Daniel Fiuza, Paulo Ericson, Tamara Arruda Pereira, Alan Jeferson, Renato Alves, José Quirino, Nicodemos Freitas, Oton Crispim e Matheus Oliveira. Aos professores do Instituto Federal do Ceará: Prof. Dr. Geraldo Luís Bezerra Ramalho, Prof. Fábio José e Prof. Romulo Cesar Cunha Lima pelo apoio durante a realização do mestrado. Agradecimento especial a Dra. Rochelle Ribeiro, Cardiologista, pelo apoio e notas de esclarecimentos. Ao meu orientador Prof. Dr. Mauro Barbosa de Oliveira por todo apoio com o conhecimento científico e o compartilhamento dos saberes e experiências de vida. A todos os demais que direta ou indiretamente participaram deste processo e contribuíram para este momento se concretizar, pois desde o ingresso na pós-graduação procurei transpor os obstáculos advindos do contexto ímpar resultante da pandemia da Covid 19 que assolou o mundo numa velocidade e extensão nunca vivenciada. Encarando o desafio de prosseguir mesmo em meio a perdas de entes próximos (meu pai) e ser um exemplo vivo do objeto de investigação, pois sou hipertenso, consegui concluir todas as disciplinas, procurando me reciclar com as limitações advindas do curso de graduação que já demandava atualizações para galgar níveis e objetivos maiores. Foi uma verdadeira superação tecer esta dissertação ainda em momento de muita tensão diante do caos em decorrência da pandemia somatizado à um turbilhão de demandas familiares e profissionais em virtude de ainda estar em busca de algo mais sólido no mercado de trabalho e o contexto de cortes de recursos na educação brasileira ter tido impacto direto nos projetos que estava envolvido.

Feliz aquele que transfere o que sabe e aprende o que ensina. O saber se aprende com mestres e livros. A Sabedoria, com o corriqueiro, com a vida e com os humildes. O que importa na vida não é o ponto de partida, mas a caminhada. Caminhando e semeando, sempre se terá o que colher.

(Cora Coralina)

## RESUMO

A Hipertensão Arterial (HA) é um problema de saúde pública em todo o mundo. No Brasil, ela atinge 36 milhões de pessoas adultas, mais de 60% dos idosos e contribui para o aumento do risco de doenças cardiovasculares e cerebrovasculares. Um diagnóstico casual ou tardio diante da falta de conhecimento da seriedade do problema ou mesmo assintomatologia de pacientes com comorbidade urge a tomada de medidas com um acompanhamento profícuo e contínuo. Esta pesquisa apresenta o Next-GISSA, um sistema inteligente para a predição de Hipertensão Arterial (HA), via monitoramento dos sinais vitais de saúde do paciente, de seu histórico clínico e de informações contextuais em tempo real do paciente. O Next-GISSA foi proposto como um componente adicional ao GISSA, uma plataforma de governança inteligente para a tomada de decisão em Saúde Digital, produto já operacional em vários municípios pela startup “Avicena Governança Inteligente”. Assim, o principal objetivo do Next-GISSA é a ampliação da arquitetura do GISSA com agregação de novas funcionalidades baseadas em IoT, Ontologia de Risco e Aprendizado de Máquina, no contexto da HA. Diante disto, tem-se a problemática: Como monitorar de forma preditiva e contínua em tempo real os pacientes hipertensos que constam no Relatório de Pessoas Adscritas do GISSA? Para tanto, foi proposta uma arquitetura conceitual junto ao GISSA no tocante a coleta de sinais vitais do paciente através de um dispositivo vestível (smartwatch), onde o Next-GISSA sugere o uso da plataforma “dojot”, uma solução criada pelo CPQD com o objetivo de acelerar o desenvolvimento de aplicações de Internet das Coisas (IoT). Para o contexto da predição da HA, esta pesquisa investigou possíveis soluções inteligentes disponíveis que melhor atendessem aos requisitos clínicos do caso, desde os clássicos algoritmos de Aprendizado de Máquina (AM) amparados por ontologias no auxílio aos processos cognitivos desenvolvidos na tomada de decisão. Esta análise se faz necessária devido, principalmente, a complexidade do cenário em estudo que envolve o cruzamento de dados on-line (sinais vitais) com o histórico clínico (off-line) do paciente. Este cruzamento de dados serve como um dispositivo de “gatilho”, baseado em conhecimento explícito (regras definidas por um especialista), no acionamento de um “bot” a dialogar com o paciente (informações em tempo real). Deste diálogo, contextualizado também no histórico do paciente, ter-se-iam atributos necessários para alimentar algoritmos supervisionados de aprendizagem de máquina na predição da HA. Esta dissertação respondeu à escassez de estudos com uma proposta de arquitetura conceitual. Desta forma, conclui-se que o Next-GISSA ampliou o leque de funcionalidades do GISSA ao incluir um módulo inteligente de monitoramento e predição de HA, além de inaugurar o uso da tecnologia IoT na plataforma.

**Palavras-chave:** IoT. Aprendizado de Máquina. Hipertensão Arterial.

## ABSTRACT

Arterial Hypertension (AH) is a public health problem worldwide. In Brazil, it affects 36 million adults, more than 60% of the elderly, and contributes to an increased risk of cardiovascular and cerebrovascular diseases. A casual or late diagnosis given the lack of knowledge of the seriousness of the problem or even asymptotology of patients with comorbidity urges the taking of measures with a continuous fruitful and follow-up. This research presents the Next-GISSA, an intelligent system for the prediction of Arterial Hypertension (AH), via monitoring of the patient's vital signs of health, of his clinical history and of contextual information in real time. Next-GISSA was proposed as an additional component to GISSA, an intelligent governance platform for decision-making in Digital Health, a product already operational in several municipalities by the startup “Avicena Governança Inteligente”. Thus, the main objective of Next-GISSA is the expansion of the GISSA architecture with the addition of new functionalities based on IoT, Risk Ontology and Machine Learning, in the context of HA. In view of this, there is the problem: How to monitor in real time in a predictive and continuous way the hypertensive patients that appear in the GISSA Enrolled Persons Report? To this end, a conceptual architecture was proposed with GISSA regarding the collection of patient vital signs through a wearable device (smartwatch), where Next-GISSA suggests the use of the “dojot” platform, a solution created by CPQD with the aim goal of speed up the development of Internet of Things (IoT) applications. For the context of AH prediction, this research investigated possible intelligent solutions available that best meet the clinical requirements of the case, from the classic Machine Learning (ML) algorithms supported by ontologies to aid cognitive processes developed in decision making. This analysis was necessary mainly due to the complexity of the scenario under study, which involves crossing online data (vital signs) with the clinical history (offline) of the patient. This data crossing serves as a “trigger” device, based on explicit knowledge (rules defined by an expert), in activating a “bot” to dialogue with the patient (real-time information). From this dialogue, also contextualized in the patient's history, there would be necessary attributes to feed supervised machine learning algorithms in the prediction of AH. This dissertation responded to the scarcity of studies with a conceptual architecture proposal. In this way, it is concluded that Next-GISSA expanded the range of GISSA functionalities by including an intelligent monitoring and HA prediction module, in addition to inaugurating the use of IoT technology on the platform.

**Keywords:** IoT. Machine Learning. High Blood Pressure.

## LISTA DE FIGURAS

|                    |                                                                                                                                    |    |
|--------------------|------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Figura 1 –</b>  | Percurso metodológico.....                                                                                                         | 16 |
| <b>Figura 2–</b>   | Smart City and Smart Health .....                                                                                                  | 28 |
| <b>Figura 3 –</b>  | Determinantes genéticos/epigenéticos, ambientais e sociais interagem para elevar a PA em hipertensos e na população em geral. .... | 31 |
| <b>Figura 4 –</b>  | Esfigmomanômetro(1) e estetoscópio (2).....                                                                                        | 34 |
| <b>Figura 5 –</b>  | Técnicas existentes, os tipos de medição e os métodos que as utilizam.....                                                         | 35 |
| <b>Figura 6 –</b>  | Fluxograma para diagnóstico de hipertensão arterial (modificado do Canadian Hypertension Education Program) .....                  | 36 |
| <b>Figura 7 –</b>  | Possibilidades de diagnóstico de acordo com a medida casual de PA, MAPA ou medidas domiciliares. ....                              | 37 |
| <b>Figura 8 –</b>  | Fluxograma de classificação de risco CV adicional no paciente hipertenso ...                                                       | 39 |
| <b>Figura 9 –</b>  | Arquitetura do modelo baseado em ontologia e Linked Data.....                                                                      | 51 |
| <b>Figura 10 –</b> | Mapeamento das ontologias.....                                                                                                     | 51 |
| <b>Figura 11 –</b> | Parte da Ontologia de Risco.....                                                                                                   | 52 |
| <b>Figura 12 –</b> | Arquitetura do Smart GISSA .....                                                                                                   | 59 |
| <b>Figura 13 –</b> | Aplicação do Smart GISSA .....                                                                                                     | 59 |
| <b>Figura 14 –</b> | Metodologia DMRisD (Análise de Risco de Morte) .....                                                                               | 60 |
| <b>Figura 15 –</b> | Metodologia DMEpi (Vigilância Epidemiológica).....                                                                                 | 60 |
| <b>Figura 16 –</b> | Cenário hipotético de aplicação do Next-GISSA .....                                                                                | 68 |
| <b>Figura 17 –</b> | Detalhamento do fluxo no cenário de aplicação do NextGISSA.....                                                                    | 69 |
| <b>Figura 18 –</b> | Contribuição: arquitetura, IoT, ontologia criando um alerta para o bot.....                                                        | 70 |
| <b>Figura 19 –</b> | Agregação do Next-GISSA à arquitetura GISSA .....                                                                                  | 75 |
| <b>Figura 20 –</b> | Arquitetura funcional do NextGISSA.....                                                                                            | 76 |
| <b>Figura 21 –</b> | Escopo de funcionamento do Next-GISSA .....                                                                                        | 79 |
| <b>Figura 22 –</b> | Diagrama de caso de uso do Next-GISSA .....                                                                                        | 80 |
| <b>Figura 23 –</b> | Metodologia de Reconhecimento de Padrões .....                                                                                     | 81 |
| <b>Figura 24 –</b> | Protótipo Arquitetura do NextGISSA .....                                                                                           | 83 |
| <b>Figura 25 –</b> | Arquitetura da Aplicação (Protótipo).....                                                                                          | 84 |
| <b>Figura 26 –</b> | Integração do modelo baseado em Ontologia Linked Data do Next-GISSA ..                                                             | 85 |
| <b>Figura 27 –</b> | Curva ROC.....                                                                                                                     | 88 |
| <b>Figura 28 –</b> | Artigo NextGISSA /3º colocado no Prêmio Luiz Fernando de Computação..                                                              | 89 |

## LISTA DE TABELAS

|                   |                                                                                                                                                                                                                                                                     |    |
|-------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Tabela 1 –</b> | Percentual de Adultos ( $\geq 18$ anos) que referiram diagnóstico médico de hipertensão arterial, por sexo, segundo as capitais dos estados brasileiros e o Distrito Federal. Vigitel 2021.....                                                                     | 32 |
| <b>Tabela 2–</b>  | Percentual de indivíduos que referiram diagnóstico médico de hipertensão arterial no conjunto da população adulta ( $\geq 18$ anos) das capitais dos estados brasileiros e do Distrito Federal, por sexo, segundo idade e anos de escolaridade. Vigitel, 2021 ..... | 33 |
| <b>Tabela 3–</b>  | Classificação da PA de acordo com a medição casual ou no consultório a partir de 18 anos de idade .....                                                                                                                                                             | 37 |
| <b>Tabela 4 –</b> | Estratificação de risco no paciente hipertenso de acordo com fatores de risco adicionais, presença de lesão em órgão-alvo e de doença cardiovascular ou renal.....                                                                                                  | 39 |
| <b>Tabela 5 –</b> | Fatores de risco cardiovascular adicionais aos pacientes com HAS.....                                                                                                                                                                                               | 40 |
| <b>Tabela 6 –</b> | Trabalhos relacionados .....                                                                                                                                                                                                                                        | 55 |
| <b>Tabela 7 –</b> | Classificação da Pressão Arterial segundo a Sociedade Brasileira de Cardiologia.....                                                                                                                                                                                | 74 |
| <b>Tabela 8 –</b> | Requisitos Funcionais do Next-GISSA .....                                                                                                                                                                                                                           | 78 |
| <b>Tabela 9 –</b> | Requisitos Não Funcionais do Next-GISSA.....                                                                                                                                                                                                                        | 78 |

## SUMÁRIO

|           |                                                                        |           |
|-----------|------------------------------------------------------------------------|-----------|
| <b>1</b>  | <b>INTRODUÇÃO .....</b>                                                | <b>12</b> |
| 1.1       | Objetivos Geral e Específicos .....                                    | 15        |
| 1.2       | Metodologia.....                                                       | 16        |
| 1.3       | Organização da Dissertação .....                                       | 17        |
| <b>2</b>  | <b>FUNDAMENTAÇÃO TEÓRICA.....</b>                                      | <b>18</b> |
| 2.1       | Tecnologias Digitais na Saúde .....                                    | 18        |
| 2.2       | E-Health-Saúde Eletrônica .....                                        | 20        |
| 2.3       | Hipertensão e Hipertenso .....                                         | 30        |
| 2.3.1     | Representatividade do hipertenso em Fortaleza.....                     | 31        |
| 2.3.2     | Monitoramento da Pressão Arterial.....                                 | 34        |
| 2.3.3     | Riscos associados a Hipertensão Arterial .....                         | 38        |
| 2.4       | Aprendizado de Máquina .....                                           | 41        |
| 2.5       | Ontologia: Conceito, Componentes, Tipos e Aplicação.....               | 45        |
| 2.5.1     | Ontologia e Linked Data .....                                          | 48        |
| <b>3.</b> | <b>TRABALHOS RELACIONADOS .....</b>                                    | <b>53</b> |
| 3.1       | Descrição dos trabalhos relacionados.....                              | 56        |
| <b>4</b>  | <b>RESULTADOS: Next-GISSA.....</b>                                     | <b>67</b> |
| 4.1       | Cenário de aplicação do Next-GISSA.....                                | 68        |
| 4.2       | Metodologia para a Integração da Ontologia de Risco do Next-GISSA..... | 73        |
| 4.3       | Arquitetura do Next-GISSA .....                                        | 75        |
| 4.4       | Requisitos funcionais e Requisitos não funcionais .....                | 78        |
| 4.5       | Especificação do processo de mineração de dados do Next-GISSA.....     | 80        |
| 4.6       | Aspectos de implementação do Protótipo NextGISSA.....                  | 83        |
| <b>5</b>  | <b>CONCLUSÕES E TRABALHOS FUTUROS.....</b>                             | <b>89</b> |
|           | <b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>                                | <b>91</b> |

## 1 INTRODUÇÃO

A Hipertensão Arterial (HA) ocorre quando a pressão do sangue causada pela força de contração do coração e das paredes das artérias para impulsionar o sangue para todo o corpo acontece de forma intensa, sendo capaz de provocar danos na sua estrutura. A HA é considerada uma “assassina silenciosa” por se tratar de condição frequentemente assintomática. A hipertensão costuma evoluir com alterações estruturais e/ou funcionais em órgãos alvo, como coração, cérebro, rins. É o principal fator de risco com associação para doenças cardiovasculares, entre elas o infarto agudo do miocárdio (IAM) e o acidente vascular cerebral (AVC), doença renal crônica e morte prematura. A sua identificação e o seu tratamento precoce reduzem a mortalidade por causas cardiovasculares, uma vez que pode estar relacionada a 80% dos casos de AVC e 60% dos casos de infarto.<sup>1</sup>

Segundo LESSA (2001), a HA é considerada o maior problema médico-social dos países desenvolvidos e em muitos dos emergentes. Mesmo conhecendo-se a eficácia, a efetividade e a eficiência de várias medidas preventivas, de controle disponíveis, sejam ou não farmacológicas, a hipertensão continua, por décadas, representando um dos maiores desafios em saúde e um dos maiores ônus para o próprio hipertenso e para a sociedade. (LESSA I., 2001).

Conforme a Sociedade Brasileira de Hipertensão (SBH), o hipertenso é todo indivíduo adulto, maior de 18 anos, com valores de pressão arterial sistólica igual ou maior do que 130 mmHg ou com pressão arterial diastólica igual ou superior a 85 mmHg, em pelo menos duas medidas realizadas em ocasiões diferentes.

A medição de pressão arterial é realizada através de aparelhos como o tensiômetro ou esfigmomanômetro e pode ter uma variação relativamente grande sem sair dos níveis de normalidade. Para algumas pessoas ter uma pressão abaixo de 12/8, como, por exemplo, 10/6, é normal. Já valores iguais ou superiores a 14 (máxima) e/ou 9 (mínima) são considerados como hipertensão para todo mundo.<sup>2</sup> De acordo com dados do Vigitel 25,2% dos brasileiros adultos afirmam hipertensão arterial, o que representa mais de 53 milhões de pessoas.

Segundo Pesquisa de Vigilância de Fatores de Risco e Proteção para Doenças Crônicas (Vigitel), realizada pelo Ministério da Saúde em 2017, 15,4% de homens e 22,6% de mulheres de Fortaleza são atingidos por hipertensão arterial, tornando 560 mil fortalezenses suscetíveis a um dos principais fatores de risco para a ocorrência do

---

<sup>1</sup> <https://agenciabrasil.ebc.com.br/saude/noticia/2021-04/cerca-de-30-dos-brasileiros-sao-hipertensos-aponta-sbc>

<sup>2</sup> <https://bvsms.saude.gov.br/17-5-dia-mundial-da-hipertensao-saiba-sua-pressao/>

Acidente Vascular Cerebral (AVC), enfarte, aneurisma arterial e insuficiência renal e cardíaca.<sup>3</sup>

No cotidiano dos serviços de saúde, o diagnóstico da hipertensão é feito frequentemente de forma casual, fato constatado no estudo de Santos ZMSA (1998). Essa atitude está relacionada com a falta de práticas adequadas de promoção da saúde da clientela, ou seja, esta procura habitualmente os serviços de saúde mediante queixas, e raramente como medida de prevenção.

Este trabalho diz respeito a ampliação da arquitetura do GISSA com agregação de novas funcionalidades baseadas IoT, Ontologia de Risco e Aprendizado de Máquina, no trato do problema da HA, ampliando as funcionalidades do GISSA, um produto de Governança em Saúde Pública já em funcionamento em vários municípios do Nordeste do Brasil (Manual GISSA, 2021). O GISSA é uma plataforma de computação que realiza coleta automática das bases de dados dos sistemas do Ministério da Saúde: E-SUS, CNES, SIM, SINASC, SI-PNI, SINAN através de robôs extratores de dados, analisa essas informações utilizando diversas tecnologias inteligentes e transformando-os em informações integradas, úteis para tomada de decisão nos diversos níveis de gestão em saúde.<sup>4</sup>

Machine Learning (Aprendizado de máquina – AM) é um campo da Inteligência Artificial (IA) que apresenta oportunidades para aplicação de técnicas (algoritmos) na resolução de problemas e promoção do conhecimento. O termo Inteligência Artificial foi apresentado por Marvin Minsky no ano de 1961. É “a ciência de criar máquinas para fazer coisas que requereriam inteligência se fossem feitas por homens”. Pode se dizer que é a “grande área”, da qual o aprendizado de máquina faz parte. (NETTO Amílca; MARCIEL Francisco, 2021)

Denominado Next-GISSA, a proposta aqui apresentada inclui um módulo inteligente na plataforma do GISSA para o monitoramento e predição de casos de hipertensão arterial.

O Next-GISSA é proposto como um componente adicional ao GISSA. Para a coleta de sinais vitais do paciente o Next-GISSA faz uso da plataforma “dojot”, uma solução criada pelo CPQD com o objetivo de acelerar o desenvolvimento de aplicações de Internet das Coisas (IoT). Para o contexto da predição da HA, este trabalho investiga possíveis soluções inteligentes disponíveis que melhor atendam aos requisitos clínicos do caso, desde os clássicos algoritmos

---

<sup>3</sup><https://www.fortaleza.ce.gov.br/noticias/prefeitura-de-fortaleza-elabora-estrategias-para-combater-a-hipertensao-arterial>

<sup>4</sup> Manual GISSA (2021): Manual\_GISSA\_AVICENA\_2021\_março

de Aprendizado de Máquina (AM) ao Raciocínio Não-Monotônico amparados por ontologias no auxílio aos processos cognitivos desenvolvidos na tomada de decisão.

A decisão de se fazer uma análise sobre o melhor sistema inteligente, ou um sistema híbrido, para predição da HA no Next-GISSA se deve, principalmente, a complexidade do cenário em estudo que envolve o cruzamento de dados on-line (sinais vitais) com o histórico clínico (off-line) do paciente. Este cruzamento serve como “gatilho” para uma atuação reativa do sistema, acionando um “bot” a dialogar com o paciente. Deste diálogo, contextualizado no histórico do paciente, ter-se-iam atributos necessários para alimentar tanto os algoritmos supervisionados de aprendizagem de máquina (KNN, NaiveBayes, SVM, redes neurais etc.) bem como os classificadores baseados em conhecimento explícito (regras que são definidas por um especialista).

O Next-GISSA é, portanto, de fundamental relevância à medida que agrega ao GISSA mecanismos inteligentes de monitoramento de dados vitais (pressão arterial, frequência cardíaca, oximetria, temperatura) do hipertenso e a checagem destes dados com o histórico do paciente através de algoritmos de inteligência artificial para a predição de casos de hipertensão deste paciente.

Na inclusão deste módulo de monitoramento inteligente no GISSA sugere-se a utilização de um dispositivo vestível (smartwatch) integrado para melhorar a interação do paciente com o sistema.

O desenvolvimento desta pesquisa se justifica no cenário em que um diagnóstico casual ou tardio diante da falta de conhecimento da seriedade do problema ou mesmo assintomatologia de pacientes com comorbidade urge a tomada de medidas com um acompanhamento profícuo e contínuo em tempo real. Com o desenvolvimento desta pesquisa são fornecidos subsídios para implementação de políticas de saúde que venham contribuir no uso das tecnologias digitais para eficácia das ações no que concerne a predição e monitoramento de hipertensos.

Além da relevância prática da pesquisa quanto a construção de uma arquitetura conceitual proposta para o sistema de monitoramento e predição da pressão arterial, o Next-GISSA pode ser direcionado a diferentes usuários com alguma comorbidade, no caso em estudo especificamente, o hipertenso. Já a importância científica diz respeito a escassez de estudos que aglutinem as tecnologias IoT e inteligência artificial voltadas para o público de hipertensos.

A contribuição científica deste trabalho também se evidencia no fornecimento de subsídios metodológicos científicos que permitem ao pesquisador investigar determinado problema, analisando fatos e fenômenos de determinada realidade com intervenções

propositivas. Destaca-se também a revisão de literatura acerca da dissertação que tem abordagem multidisciplinar, envolvendo as ciências exatas (computação) e as ciências da saúde (saúde pública e medicina).

Quanto a escolha do universo da pesquisa - população hipertensa, é sabido que este público é uma das prioridades no atendimento dentro da política de atenção básica da rede pública de Saúde.

Diante disso, tem-se a problematização através do seguinte questionamento norteador desta pesquisa: Como a construção de uma arquitetura conceitual para um sistema de inteligência computacional pode contribuir no monitoramento de forma preditiva dos pacientes hipertensos que constam no Relatório de Pessoas Adscritas do GISSA?

### **1.1 Objetivos Geral e Específicos**

Esta pesquisa de mestrado tem como **objetivo geral** propor uma arquitetura conceitual chamada: NextGISSA, baseada em IoT, Ontologia de Risco e Aprendizado de Máquina, voltada ao monitoramento e predição de casos de Hipertensão Arterial como uma funcionalidade a ser adicionada à plataforma do GISSA, um sistema de Governança em Saúde Digital.

#### **Objetivos Específicos**

- a) Realizar revisão da literatura no monitoramento e predição da HA, utilizando IoT e Sistemas Inteligentes (Ontologia e Machine Learning);
- b) Propor um cenário híbrido baseado nas fases de Diagnóstico do paciente com HA; Coleta de Sinais Vitais; Cruzamento de dados; Uso de Ontologia; Chat bot; Mecanismo de Machine Learning e Alerta;
- c) Construir a arquitetura conceitual do Next-GISSA para posterior implementação nos pacientes hipertensos que constam no Relatório de Pessoas Adscritas na plataforma GISSA;
- d) Especificar a arquitetura do Next-GISSA, descrevendo suas principais funcionalidades a luz do cenário proposto;
- e) Identificar atributos e algoritmos para a Classificação de Risco;
- f) Especificar o módulo ontologia para disparo do Chatbot.


## 1.2 Metodologia

Esta pesquisa exploratória de natureza quali-quantitativa se constituiu de um estudo de caráter propositivo (NEXT-GISSA) de uma arquitetura de ampliação do GISSA voltada para pessoas com comorbidades, no caso os Hipertensos, visando definir a melhor forma de utilizar a Internet of Things (IoT), ao conectar dispositivos utilizados no monitoramento do hipertenso, e a inteligência artificial, integrando dados de uma plataforma de computação que realiza a coleta automática das bases de dados dos sistemas do Ministério da Saúde: E\_SUS, CNES, SIM, SINASC, SI-PNI, SINAN.

A plataforma GISSA opera em datacenter, na nuvem, fornecida pela empresa Avicena Software e Serviços Ltda. Ela pode ser acessada através da web, por terminais de computadores, smartphones e tablets e se comunicando de forma proativa através do uso do sistema, acessando Painéis (dashboards), com acesso a informações resumidas e analíticas, filtráveis, ponderadas, classificadas quanto a riscos e cumprimento de padrões de qualidade dos serviços prestados, relatórios e enviando alertas e mensagens categorizadas.

Na arquitetura conceitual proposta, NEXT-GISSA, sugere-se a utilização de mecanismos inteligentes de monitoramento de dados vitais (peso, pressão arterial, frequência cardíaca) do hipertenso e a checagem destes dados com o histórico do paciente através de algoritmos de inteligência artificial.

Figura 1 – Percurso metodológico



Fonte: Próprio autor.

Conforme figura 1, de início, foi realizado um estudo teórico dos elementos que norteiam a temática proposta. Para isso, contou-se com um levantamento bibliográfico em livros,

artigos, dissertações, teses e outros materiais de autores que discutem sobre o assunto ou temas relacionados.

Ressalta-se que a pesquisa ocorre a partir da atuação do GISSA, tendo como delimitação temporal os últimos 10 anos, a partir de 2012 se estendendo ao presente.

Para a coleta de sinais vitais do paciente o Next-GISSA sugere o uso da plataforma “dojot”, uma solução criada pelo CPQD com o objetivo de acelerar o desenvolvimento de aplicações de Internet das Coisa (IoT).

Para o contexto da predição da HA, este trabalho investiga possíveis soluções inteligentes disponíveis que melhor atendam aos requisitos clínicos do caso, desde os clássicos algoritmos de Aprendizado de Máquina (AM) ao Raciocínio Não-Monotônico amparados por ontologias no auxílio aos processos cognitivos desenvolvidos na tomada de decisão.

A decisão de se fazer uma proposta de arquitetura conceitual para um sistema inteligente, ou um sistema híbrido, para predição da HA no Next-GISSA se deve, principalmente, a complexidade do cenário em estudo que envolve o cruzamento de dados on-line (sinais vitais) com o histórico clínico (off-line) do paciente. Este cruzamento serve como “gatilho” para uma atuação reativa do sistema, acionando um “bot” a dialogar com o paciente.

Deste diálogo, contextualizado no histórico do paciente, ter-se-iam atributos necessários para alimentar tanto os algoritmos supervisionados de aprendizagem de máquina (KNN, NaiveBayes, SVM, redes neurais etc.) bem como os classificadores baseados em conhecimento explícito (regras que são definidas por um especialista).

### **1.3 Organização da Dissertação**

Esta dissertação está estruturada em oito seções. Esta seção faz uma introdução ao tema de pesquisa, contextualizando e evidenciando sua importância, problemática, os objetivos, a metodologia e ao final desta seção consta a organização da dissertação. A seção 2 trata da fundamentação teórica, na qual são descritos os conceitos-base para o entendimento desta pesquisa, já na seção 3 estão também apresentados os trabalhos relacionados. Já na seção 4, como parte integrante dos resultados, é descrita a proposta do trabalho com destaque para as soluções de IoT e de sistemas inteligentes. Na seção 5 constam as conclusões e trabalhos futuros, seguido das referências bibliográficas.

## **2 FUNDAMENTAÇÃO TEÓRICA**

O desenvolvimento científico e tecnológico tem proporcionado meios de utilização das tecnologias digitais de informação e comunicação (TDIC), amplamente difundidas nas mais diversas instâncias da sociedade. Assim, se recorre de forma crescente aos sistemas de gestão, avaliação e análise estando muitas áreas, como a da saúde, por exemplo, a aproveitar os benefícios do crescimento, evolução e difusão destas tecnologias, a exemplo da Internet das Coisas (IoT) e Sistemas Inteligentes.

O desenvolvimento dos sistemas de informação em saúde (SIS) no Brasil vem crescendo, especialmente a partir de 1990, com a entrada de novas tecnologias em saúde no país estimuladas pela redemocratização nacional e a criação de um sistema de saúde universal e público. Na era da informação a tecnologia cada vez mais faz parte do nosso cotidiano. A utilização das TDICs gera reflexos importantes em diferentes setores, sobretudo naqueles que dizem respeito à qualidade do atendimento médico ao cidadão, à eficiência na gestão dos estabelecimentos hospitalares e ao uso inteligente das informações disponíveis (PANORAMA SETORIAL DA INTERNET, 2014).

A utilização das tecnologias digitais na área da saúde vem transformando diversos setores envolvidos, tanto nas esferas públicas como nas esferas privadas, apresentando melhoria em diversos cenários e impactando principalmente na qualidade do serviço prestado. Novos arranjos institucionais baseados em inovações tecnológicas visam garantir maior acesso aos diversos tipos de serviços, desde os mais simples, como agendamento de consultas e visualização de exames direcionados para gerar maior praticidade aos pacientes, até as formas mais sofisticadas de diagnósticos, de tratamentos e de monitoramento de doenças (COMITÊ GESTOR, 2017).

### **2.1 Tecnologias Digitais na Saúde**

Nesta seção serão abordados conceitos de Tecnologias da Informação e da Comunicação (TICs), bem como Tecnologias Digitais da Informação e da Comunicação (TDICs) e considerações acerca das Tecnologias Digitais na Saúde, perpassando a atuação do GISSA para, na sequência, adentrar na proposta de ampliação de sua plataforma.

As tecnologias compreendem “[...] a totalidade de coisas que a engenhosidade do cérebro humano conseguiu criar em todas as épocas, suas formas de uso, suas aplicações” (KENSKI, 2012a, p. 28), ou seja, não correspondem somente às máquinas criadas pelo ser humano para facilitar a sua vida. Dada a sua integração e a sua proximidade às atividades

desempenhadas pelo ser humano diariamente, tecnologias como a lâmpada, o ventilador, a eletricidade, o encanamento de água, a lousa, o pincel, a caneta, enfim, diversas tecnologias habituais passam, por vezes, despercebidas pelos olhos menos atentos, consideradas como o resultado de um processo natural de evolução humana e não como fruto de um desenvolvimento técnico artificial.

Nas palavras de Kenski tecnologia é todo o “[...] o conjunto de conhecimentos e princípios científicos que se aplicam ao planejamento, à construção e à utilização de um equipamento em um determinado tipo de atividade [...]” (KENSKI, 2012a, p. 30), ao passo que quando se refere às novas tecnologias, fala-se sobre os processos e produtos provenientes dos conhecimentos e dos avanços em eletrônica, microeletrônica e comunicação. Elas não são apenas objetos materializados, mas também possuem uma feição imaterial, representada pela virtualidade da informação. Elas estão, ainda, em constantes transformações, que diferentemente dos tempos passados, ocorrem com uma velocidade cada vez maior.

Segundo Kenski (2012a, p. 26) a evolução tecnológica não se finda com o surgimento de novos equipamentos e produtos:

Ela altera comportamentos. A ampliação e a banalização do uso de determinada tecnologia impõem-se à cultura existente e transformam não apenas o comportamento individual, mas o de todo o grupo social. A descoberta da roda, por exemplo, transformou radicalmente as formas de deslocamento, redefiniu a produção, a comercialização e a estocagem de produtos e deu origem a inúmeras outras descobertas. A economia, a política e a divisão social do trabalho refletem os usos que os homens fazem das tecnologias que estão na base do sistema produtivo em diferentes épocas. O homem transita culturalmente mediado pelas tecnologias que lhe são contemporâneas.

Investigações sobre tecnologia tem se difundido, mas nos ateremos às tecnologias digitais, ou seja, aquelas que dependem do processamento eletrônico dos dados, cujos dispositivos mais comuns são computadores, tablets e smartphones.

Existem diferenças entre as Tecnologias da Informação e da Comunicação (TICs) e as Tecnologias Digitais da Informação e da Comunicação (TDICs). Segundo Kenski (2012a, n. p.)

o avanço tecnológico das últimas décadas garantiu novas formas de uso das TICs para a produção e propagação de informações, a interação e a comunicação em tempo real, ou seja, no momento em que o fato acontece. Surgiram, então, as novas tecnologias de informação e comunicação, as NTICs. Nessa categoria é possível ainda considerar a televisão e, mais recentemente, as redes digitais, a internet. Com a banalização do uso dessas tecnologias, o adjetivo “novas” vai sendo esquecido e todas são chamadas de TICs, independentemente de suas características.

Com o advento da internet, as tecnologias passaram a ser denominadas tecnologias de informação e comunicação (TIC). Como as TIC abrangem tecnologias mais antigas como a

televisão, o jornal e o mimeógrafo, pesquisadores têm utilizado o termo Novas Tecnologias para se referir às tecnologias digitais (KENSKI, 2012a) ou Tecnologias Digitais da Informação e Comunicação – TDIC – (VALENTE, 2018a) referindo-se a computador, *tablet*, celular, *smartphone* etc.

Ainda de acordo com Kenski (2012a, p. 21), “os vínculos entre conhecimento, poder e tecnologias estão presentes em todas as épocas e em todos os tipos de relações sociais”. Na contemporaneidade, uma dada sociedade tecnológica se estrutura de acordo com os avanços das Tecnologias Digitais da Informação e da Comunicação (TDICs) e pela microeletrônica (KENSKI, 2012a). Referidas TDICs alteram a forma como os seres humanos vivem, trabalham, informam-se e se comunicam entre si. Com a difusão tecnológica, “[...] já não importa o lugar onde cada um habita, mas as suas condições de acesso às novas realidades tecnológicas” (KENSKI, 2012a, p. 22). Desta forma, é basilar a apropriação crítica e reflexiva das tecnologias digitais.

É neste contexto, que se inserem as TDIC’s – Tecnologias Digitais de informações e comunicação. Conforme Ponte (2002) as TDIC’s constituem uma linguagem de comunicação e um instrumento de trabalho fundamental para a sociedade atual no tocante ao conhecer e dominar. Entretanto, as tecnologias digitais de informações e comunicações representam um suporte do desenvolvimento humano em várias nuances, passando desde uma ordem pessoal, social, cultural, lúdica, cívica, até a profissional.

Diante do exposto, o que vem a ser as Tecnologias Digitais de Informação e Comunicação (TDICs)? Ponte (2000) afirma que as TDICs,

Representam uma força determinante do processo de mudança social, surgindo como a trave-mestra de um novo tipo de sociedade, a sociedade da informação. Estas tecnologias referem-se a três domínios distintos embora interligados entre si: (I) o processamento, armazenamento e pesquisa realizados pelo computador; (II) o controle e automatização das máquinas, ferramentas e processos, incluindo em particular, a robótica, e: (III) a comunicação, nomeadamente a transmissão e circulação da informação.

## 2.2 E-Health - Saúde Eletrônica

No contexto da pandemia de COVID 19, ficou mais do que nunca evidenciado a necessidade de interação entre os profissionais da saúde e as tecnologias digitais. As aplicações envolvem cenários de atendimento, de planejamento de curto prazo, bem como de avaliação de políticas públicas e ações de longo prazo.

O vírus surgiu em dezembro de 2019, na cidade de Wuhan, província de Hubei, na China, e em curto espaço de tempo se tornou um problema mundial, sendo declarado como

doença pandêmica pela Organização Mundial da Saúde (OMS) em janeiro de 2020. Acredita-se que o tráfego aéreo foi o principal meio de propagação da doença em diferentes países, resultado de um mundo globalizado.

Com o aumento do número de casos e os cuidados para barrar sua disseminação, alterou-se o comportamento das pessoas, as formas de se relacionar, o aumento do uso das tecnologias a distância e uma diminuição brutal dos fluxos de pessoas. Na busca por mitigar os efeitos que o distanciamento social nos impõe, as ferramentas digitais passaram a ser usadas incessantemente como forma de manter a comunicação em meio a uma geração tão imersa nas tecnologias.

Não obstante, na área da saúde, as tecnologias digitais têm também se difundido, tendo como consequência, reflexos no atendimento médico, na gestão dos estabelecimentos hospitalares e no uso inteligente das informações disponíveis.

Segundo CAMARGO e ITO (2012) a utilização das TICs avança na área médica, produzindo setores de especialização denominados: Telemedicina, Cibermedicina e a Informática em Saúde.

- **Telemedicina:** especialidade médica que disponibiliza serviços à distância para o cuidado com a saúde, com o uso de modernas tecnologias digitais que promovem a assistência médica *online* aos pacientes, clínicas, hospitais e profissionais da saúde. O seu grande potencial é melhorar o atendimento em saúde dos pacientes.
- **Cibermedicina:** estuda a relação entre saúde e Internet, uso de inovações tecnológicas, denominadas de *e-health* e de outros recursos da Internet, como exemplo o uso de *e-mail*, *chats* e consultas *online*.
- **Informática em Saúde:** trata da aplicação de conceitos de TIC para a melhoria e transformação dos sistemas, serviços e processos de saúde. Uma área interdisciplinar que abrange conhecimento da ciência da informação, da engenharia, da comunicação e das ciências da saúde, indo desde a biologia molecular à saúde global, tendo como objetivo aumentar a qualidade e ampliar o acesso à atenção primária e secundária por meio da adoção das TICs (SHORTLIFEE; KULIKOWSKI, 2014).

A saúde eletrônica (e-saúde) é a contribuição da implementação (TIC) no setor de saúde. O e-Health(saúde eletrônica) é um termo utilizado dentro da área da saúde, que consiste na aplicação das tecnologias digitais da informação e comunicação de modo a aproveitar os benefícios disponíveis através da convergência da Internet e cuidados de saúde.

Considerando e-health mais que desenvolvimento tecnológico Eysenbach, G.(2001)<sup>5</sup> assim a define :

A e-saúde é um campo emergente na interseção de informática médica, saúde pública e negócios, referindo-se a serviços de saúde e informações fornecidas ou aprimoradas por meio da Internet e tecnologias relacionadas. Em um sentido mais amplo, o termo caracteriza não apenas um desenvolvimento técnico, mas também um estado de espírito, uma maneira de pensar, uma atitude e um compromisso com o pensamento global em rede, para melhorar os cuidados de saúde local, regional e mundial, usando tecnologia de informação e comunicação.

A letra "e" em E-Health não significa apenas "eletrônico",) mas implica em vários outros "e". Os 10 e's em "e-saúde" conforme segundo Eysenbach, G.(2001) são:

- Efficiency(*Eficiência*)
- Enhancing quality of care (*Melhoraria na qualidade do atendimento*)
- Evidence based(*Decisões baseadas em evidências*)
- Empowerment(*Fortalecimento*)
- Encouragement(*Encorajamento*)
- Education(*Formação continuada*)
- Enabling information Exchange(*Troca de informações*)
- Extending(*Estender a saúde para além as fronteiras*)
- Ethics(*Ética*)
- Equity(*Capital próprio*)

Além desses 10 e's essenciais, a e-saúde também deve ser easy-to-use fácil de usar, entertaining divertido e exciting emocionante (GUNTHER, 2001).

Uma subárea do e-Health é o m-Health<sup>6</sup> que trata de soluções que utilizam recursos móveis, como por exemplo: Apps, Dispositivos Móveis e Wearables Computing (computação vestível). Vale ressaltar que na maioria das vezes as soluções m-Health não são isoladas, pois trocam informações com outros sistemas e-health.

a telemedicina sem fio (ou “m-saúde”) é hoje considerada uma área importante e emergente em telemedicina e sistemas de teleatendimento. M-health envolve a exploração do telecomunicações móveis e tecnologias multimídia e a sua integração em novos sistemas móveis de prestação de cuidados de saúde.(ISTEPANIAN; LACAL, p.1, 2003)

---

<sup>5</sup> Eysenbach G. What is e-health? Journal of medical Internet Research 2001. URL: <https://www.jmir.org/2001/2/e20> DOI: 10.2196/jmir.3.2.e20

<sup>6</sup> ISTEPANIAN, Robert S.H. and LACAL, Jose C. Emerging Mobile Communication Technologies for Health: Some Imperative notes on m-health. Conference: Engineering in Medicine and Biology Society, 2003. Proceedings of the 25th Annual International Conference of the IEEE. October, 2003.

A consolidação da e-saúde é seguida pela preferência generalizada de dispositivos móveis com capacidades como os telefones inteligentes, o que levou à evolução do conceito de saúde móvel (m-saúde). Pode-se entender m-health como a prestação de serviços de saúde usando dispositivos de comunicação móvel. Os recentes desenvolvimentos nas tecnologias digitais móveis (e seu impacto sobre problemas de mobilidade em diferentes aplicações de telemedicina e teleassistência) estão claramente refletidas em rápido crescimento da telemedicina de serviços móveis, como por exemplo: transmissões móveis de ECG; imagens de vídeo e telerradiologia; serviços de ambulância sem fio para prever morbidade de emergência e acidente vascular cerebral; dentre outros móveis integrados.

O Smart-Health<sup>7</sup>, também chamada de S-Health pode ser medido apenas como uma expansão da melhoria na noção de m-health, integra a saúde inteligente que é um sistema de serviços de saúde que usa tecnologia como dispositivos vestíveis, IoT e internet móvel para acessar informações, conectar pessoas, materiais e instituições relacionados aos cuidados de saúde.

Envolve múltiplas dimensões, incluindo prevenção de doenças e monitoramento, diagnóstico e tratamento, gestão hospitalar, decisão em saúde, fabricação e pesquisa médica. As tecnologias da informação, por exemplo, IoT, Internet móvel, computação em nuvem, big data, 5G, nanoeletrônica e inteligência artificial, juntamente com a biotecnologia moderna constituem a pedra angular da saúde inteligente. Do ponto de vista dos pacientes, eles podem usar dispositivos vestíveis para monitorar sua saúde o tempo todo, procurar atendimento médico por meio de assistentes virtuais e usar residências remotas para implementar serviços remotos; da perspectiva dos médicos, uma variedade de sistemas de apoio à decisão clínica são usados para auxiliar e melhorar o diagnóstico.

Os médicos podem gerenciar informações médicas por meio de um sistema integrado de informações como uma plataforma que inclui Sistema de Gerenciamento de Informações Laboratoriais, Sistemas de Comunicação e Arquivamento de Imagens (PACS), Medicina Eletrônica, etc. Uma cirurgia mais precisa pode ser alcançada por meio de robôs e tecnologia de realidade mista. Do ponto de vista dos hospitais, a tecnologia de identificação por radiofrequência (RFID) pode ser usada para gerenciar materiais de pessoal e a cadeia de suprimentos, usando gestão integrada a plataformas para coletar informações e auxiliar na tomada de decisões. O uso de plataformas médicas biliares podem melhorar as experiências dos pacientes. No âmbito das instituições de pesquisa científica é possível utilizar técnicas como

---

<sup>7</sup> AL-AZZAM, M. K.; ALAZZAM, M. B. Smart city and Smart-Health framework, challenges and opportunities. *International Journal of Advanced Computer Science and Applications*, v. 10, n. 2, p. 171–176, 2019.

aprendizado de máquina em vez de triagem manual de drogas e para encontrar sujeitos capazes usando big data.

Com o uso dessas tecnologias, cuidados de saúde podem efetivamente reduzir o custo e o risco de procedimentos médicos, melhorar a eficiência de utilização de recursos médicos, promover intercâmbios e cooperação em diferentes regiões, impulsionar o desenvolvimento da telemedicina e atendimento médico de autoatendimento e, em última análise, fazer atendimento médico personalizado.

Conforme Tian, Yang, Grange, Wang, Huang, Ye(2019)<sup>8</sup> a aplicação da saúde inteligente pode ser dividida da seguinte forma, com base nas diferentes necessidades:

**Auxiliar no diagnóstico e tratamento:** Com a aplicação de tecnologias como inteligência artificial, cirurgia robôs, e realidade mista, o diagnóstico e tratamento de doenças tem se tornado mais inteligente.

Através do uso do sistema de apoio à decisão clínica, os médicos pode dar conselhos de especialistas com base em algoritmos para melhorar a precisão do diagnóstico reduzir a incidência de diagnósticos errados.

**Gestão da saúde:** O novo modelo de gestão da saúde sob o sistema de saúde inteligente dá mais atenção ao autogerenciamento do paciente. Ele enfatiza o automonitoramento em tempo real de pacientes, feedback imediato de dados de saúde e intervenção oportuna do comportamento médico. Dispositivos vestíveis/implantáveis podem combinar sensores avançados, microprocessadores e módulos sem fio para detectar e monitorar continuamente vários indicadores fisiológicos de pacientes de maneira inteligente, permitindo que os dados sejam combinados com informações de saúde de outros canais. Essa abordagem envolve um salto do monitoramento do cenário para a percepção contínua e o cuidado integrado. Reduz ainda mais os riscos associados causados pela doença, ao mesmo tempo em que torna mais fácil para as instituições médicas monitorar o prognóstico da doença. O surgimento de telefones inteligentes, relógios inteligentes, etc., fornece um novo veículo para esse tipo de monitoramento. Tentativas foram feitas para integrar biossensores em smartphones. Além de melhorar ainda mais a portabilidade, os usuários podem usar um smartphone de alto desempenho para monitorar o ambiente e seu corpo com mais facilidade. Os pacientes podem auto gerenciar sua condição por meio de aplicativos e uma plataforma de informações de saúde. Por exemplo, o sistema de Detecção e Alívio de Estresse usa um sensor médico vestível para

---

<sup>8</sup> Smart healthcare: making medical care more intelligent. Shuo Tian, Wenbo Yang, Jehane Michael Le Grange, Peng Wang, Wei Huang, Zhewei Ye (2019).

monitorar continuamente os níveis de pressão do corpo humano e automaticamente ajudar o corpo a reduzir o estresse. Também é possível integrar dados de saúde de vários dispositivos portáteis em um sistema de apoio à decisão clínica para criar um sistema hierárquico de apoio à decisão de saúde que possa fazer pleno uso dos dados coletados para um diagnóstico eficaz da doença. Ao auxiliar na tomada de decisão clínica, pode prever possíveis riscos para os pacientes e dar conselhos através da calculadora em nuvem e big data com antecedência. Outra ideia é criar uma estrutura aberta de m-Health que permita aos médicos, pacientes, pesquisadores e outros, reduzindo as barreiras à entrada. Ele permite que os pacientes acessem facilmente conselhos e serviços de telemedicina, enquanto os médicos podem monitorar dinamicamente o status do paciente. Arquiteturas móveis como m-Health podem ajudar a reduzir erros médicos, reduzir a dificuldade de tratamento médico, melhorar a pontualidade dos serviços médicos e fornecer uma opção econômica para serviços de saúde.

O uso de tecnologias móveis e TIC para questões relacionadas à saúde tem levado ao surgimento do monitoramento do paciente e dos cuidados de saúde de forma ubíqua, usando e-saúde e m-saúde.

Segundo Majed Al-Azzam e Malik Alazzam (p.174, 2019) é preciso “**envolver os doentes e as famílias na gestão da sua saúde:** Na abordagem s-saúde, os cidadãos são substancialmente empoderados e assistidos de forma eficiente para participarem ativamente na gestão da sua saúde”.

**Prevenção de doenças e monitoramento de risco:** A previsão tradicional de risco de doenças é baseada na iniciativa das autoridades de saúde para coletar informações do paciente, comparar essas informações com as diretrizes da organização competente e, finalmente, divulgar os resultados da previsão. Este método tem um certo atraso no tempo e não fornece conselhos precisos aos indivíduos. A previsão de risco de doenças no smarthealthcare é dinâmica e personalizada. Ele permite que pacientes e médicos participem, monitorem proativamente seu risco de doença e conduzam a prevenção direcionada com base em seus próprios resultados de monitoramento. O novo modelo de previsão de risco de doenças coleta dados por meio de dispositivos vestíveis e aplicativos inteligentes, carrega-os na nuvem por meio de uma rede e analisa os resultados com base em algoritmos baseados em big data para fornecer os resultados previstos aos usuários em tempo real por meio de curto serviço de mensagens. Essas medidas provaram ser eficazes. Elas ajudam médicos e pacientes a ajustar seus comportamentos médicos e estilos de vida a qualquer momento e também ajudam os

tomadores de decisão a desenvolver estratégias regionais de saúde para atingir a meta de reduzir o risco de doenças. (TIAN , YANG, GRANGE, WANG, HUANG, YE, 2019)

Segundo Majed Al-Azzam e Malik Alazzam (2019) “os sistemas de s-Saúde envolvem também a melhoria das decisões políticas, uma vez que também podem possibilitar a gestão da saúde pública. As leis e preferências também podem ser “modificadas” para avaliar cada distrito ou cidade, com base nos dados resultantes de riscos à saúde, população, clima, meio ambiente e infraestrutura acessível. Há um potencial ilimitado que surge da mineração desses dados para otimizar a tomada de decisões relacionadas à saúde pública”.

**Controle de epidemias:** os dados de saúde e as metodologias também aumentam radicalmente a competência do Estado na detecção e controle de epidemias. Os sinais vitais, atividades e locais dos cidadãos podem ser utilizados para a detecção de possivelmente novos casos durante uma epidemia, reconhecendo efetivamente os campos de maior risco e gerenciando um surto de maneira eficaz. (AL-AZZAM e ALAZZAM , 2019)

Segundo Al-Azzam e Alazzam (p.175, 2019) envolve ainda economia de custos: “Setores identificados que são explorados anteriormente podem impor um impacto substancial na redução do custo dos cuidados de saúde. Tal redução de custo também será contemplada com o aumento simultâneo da eficiência do esquema e melhoria na prestação de serviços. Oportuna, a otimização da prevenção e manejo da doença pode levar ainda à diminuição de visitas desnecessárias aos hospitais e ao desenvolvimento de eventos agudos devido ao mau manejo dos pacientes com condições crônicas. Além disso, a redução do tempo de ação e a gestão eficaz da saúde pública também podem oferecer ótimos resultados, ao mesmo tempo em que oferecem redução de custos em escala nacional”.

**Assistentes virtuais:** Um assistente virtual não é uma entidade, mas um algoritmo. Os assistentes virtuais se comunicam com os usuários por meio de técnicas como reconhecimento de fala, contam com big data para obter fontes de informação e respondem de acordo com as preferências ou necessidades do usuário após os cálculos. Microsoft Cortana (Redmond, WA, EUA), Google Assistant (Mountain View, CA, EUA) e Apple Siri (Cupertino, CA, EUA) são todos assistentes virtuais. Os assistentes virtuais usam a experiência da sessão e a tecnologia de compreensão do idioma para ajudar os usuários a concluir várias tarefas, desde a criação de lembretes até a automação residencial. No smarthealth, os assistentes virtuais assumem principalmente o papel de uma ponte para se comunicar com médicos, pacientes e instituições médicas. Eles tornam os serviços médicos mais convenientes. Para os pacientes, o assistente virtual pode facilmente converter a linguagem comum do dia-a-dia em uma usando terminologia médica através do dispositivo inteligente, de modo a buscar o serviço médico


correspondente com mais precisão. Para os médicos, o assistente virtual pode responder automaticamente a informações relevantes com base nas informações básicas do paciente, ajudando os médicos a gerenciar pacientes e coordenar procedimentos médicos de forma mais conveniente, para que os médicos economizem mais tempo. Para as instituições médicas, a aplicação de assistentes virtuais pode economizar bastante mão de obra e recursos materiais e responder às necessidades de todas as partes com mais eficiência. (TIAN , YANG, GRANGE, WANG, HUANG, YE, 2019).

**Problemas e soluções:** Atualmente, a saúde inteligente carece de macroorientação e documentos programáticos, o que leva a objetivos de desenvolvimento pouco claros e, em última análise, a um desperdício de recursos. Além disso, as instituições médicas carecem de padrões uniformes entre diferentes regiões e diferentes organizações, e melhorias são necessárias para garantir a integridade dos dados. A quantidade de dados é muito complicada e muito grande, o que leva a dificuldades no compartilhamento de dados e na comunicação. Há também problemas de compatibilidade entre diferentes plataformas e dispositivos. Do ponto de vista do paciente, a saúde inteligente carece de normas legais relevantes, e há riscos em relação a informações pessoais e violações de privacidade. Alguns usuários têm até dificuldade em usar a tecnologia. Tecnicamente falando, algumas tecnologias relacionadas à saúde inteligente ainda estão em fase experimental e exigem uma grande quantidade de financiamento para serem mantidas e atualizadas. Há também um risco desconhecido se aplicado precipitadamente. (TIAN , YANG, GRANGE, WANG, HUANG, YE, 2019).

As perspectivas para a saúde inteligente são vastas. Para usuários individuais, a saúde inteligente pode facilitar um melhor autogerenciamento da saúde. Serviços médicos oportunos e apropriados podem ser acessados quando necessário, e o conteúdo dos serviços médicos será mais personalizado. Para instituições médicas, a assistência médica inteligente pode reduzir custos, aliviar a pressão do pessoal, obter um gerenciamento unificado de materiais, informações e melhorar a experiência médica do paciente. Para instituições de pesquisa, a saúde inteligente pode reduzir o custo da pesquisa, reduzir o tempo de pesquisa e melhorar a eficiência geral da pesquisa. No que diz respeito à tomada de decisões macro, a saúde inteligente pode melhorar o status quo da desigualdade de recursos médicos, impulsionar o processo de reforma médica, promover a implementação de estratégias de prevenção e reduzir os custos médicos. No entanto, ainda existem alguns problemas no processo de desenvolvimento. A solução para esses problemas depende não apenas do progresso tecnológico, mas também do esforço conjunto de pacientes, médicos, instituições de saúde e empresas de tecnologia. (TIAN , YANG, GRANGE, WANG, HUANG, YE, 2019).

Majed Al-Azzam e Malik Alazzam (2019) são bem elucidativos quanto a interrelação entre m-health, s-Health e e-Health, apresentando o seguinte esquema explicativo:

Figura 2 - Smart City and Smart Health



Fonte: Majed Al-Azzam e Malik Alazzam (2019)

Onde: **Caso 1**—Saúde clássica explicada como atividade geralmente relacionada à saúde, o que significa um médico que visita pacientes com as ferramentas tradicionais especificadas, que não envolvem essencialmente as TIC.

**Caso 2** - e-Health envolve o uso de bancos de dados e registros eletrônicos de saúde (EHR) que ajudam a salvar ou armazenar informações médicas dos pacientes.

**Caso 3** - m-Saúde. O exemplo desse tipo de atividade é quando o paciente consegue consultar suas prescrições em seus dispositivos móveis pessoais para garantir a adesão aos medicamentos. Este m-health explicado como um subconjunto de e-health, uma vez que faz uso de dispositivos médicos para acessar dados médicos relacionados.

**Caso 4** - s-Saúde. O paciente recebe informações ou dados de um polo interativo de informações para verificação do nível de poeira, pólen e poluição para o qual o indivíduo tem alergia. As informações ajudam ainda mais os pacientes na prevenção de áreas que podem ser perigosas para suas condições de saúde. O polo de informação ajuda a fornecer ao paciente informações sobre o melhor caminho ou direção que ele pode tomar para chegar a um destino e sobre as farmácias mais próximas onde ele pode comprar anti-histamínicos.

**Caso 5** - m-Health amplificado com s-Health. Isso pode ser explicado com um ciclista que está usando uma pulseira ou pulseira que possui acelerômetros embutidos e acidente

é o principal recurso de monitoramento do dispositivo. A rede de sensores corporais ajudará na detecção da queda do indivíduo e enviará uma notificação para a infraestrutura da cidade. Assim que o sistema receber a notificação, as circunstâncias do trânsito estão sendo avaliadas e uma ambulância será despachada pela melhor rota selecionada. Além disso, é possível ajustar os semáforos da cidade de forma dinâmica para minimizar o tempo gasto antes da chegada da ambulância ao local.

Segundo Majed Al-Azzam e Malik Alazzam (p.174, 2019) é necessário destacar a diferença de s-saúde com a de m-saúde. As principais diferenças entre os dois conceitos incluem:

1. **Distinções nas fontes de informação:** Os dados ou informações que são usados no conceito de m-health são geralmente provenientes dos pacientes. No entanto, os dados usados no conceito s-health não são apenas provenientes do paciente, mas de fontes independentes.
2. **Distinções no fluxo de informações:** m-Health é geralmente uma abordagem focada no usuário ou personalizada, enquanto a s-health também é centrada na cidade. Isso é comprovado pela face em que no m-health, as informações são coletadas através dos pacientes e processos e os resultados finais voltam apenas para os pacientes. Ao contrário, no caso da s-saúde, que não é centrada no usuário, as informações obtidas pelos pacientes também alteram o comportamento da cidade, o que significa que o conceito é centrado na cidade. Como exemplo, pode se referir o exemplo 5 acima, a queda do ciclista no exemplo mostra mudanças no comportamento de toda a cidade e também leva a mudanças nos semáforos da cidade que também ajudam na chegada mais fácil da ambulância (o que claramente é fora do escopo da m-health).
3. **Pesquisa e interação multidisciplinar:** As áreas exploradas que foram explicadas anteriormente geralmente estão sendo estudadas em todo o mundo por diferentes profissionais e pesquisadores. No entanto, é muito incomum que os pesquisadores realizem estudos ou trabalhem na mesma instituição ou organizações; portanto, isso torna extremamente difícil para eles compartilhar suas informações para levar mutuamente a uma solução integrada como o conceito s-health. Uma vez que a noção de s-saúde é muito nova, há uma necessidade crescente de colaboração, cooperação e interação entre diversos atores, incluindo pesquisadores, profissionais, governos, médicos, etc.

4. **Segurança e privacidade:** Mesmo quando a abordagem s-health pode ajudar a mitigar várias preocupações relacionadas à saúde, mas sua capacidade de obter dados incomparáveis pode comprometer a privacidade dos cidadãos. A proteção da privacidade e segurança da infraestrutura é uma questão inevitável que a comunidade de pesquisa ainda está tentando corrigir.

É neste contexto que se insere esta pesquisa, já que investiga possíveis soluções inteligentes disponíveis que melhor atendam aos requisitos clínicos do caso, desde os clássicos algoritmos de Aprendizado de Máquina (AM) ao Raciocínio Não-Monotônico amparados por ontologias no auxílio aos processos cognitivos desenvolvidos na tomada de decisão, tendo como público, o paciente com hipertensão.

### 2.3 Hipertensão e Hipertenso

A Hipertensão Arterial trata-se de uma doença crônica e degenerativa, caracterizada pelos níveis elevados da pressão sanguínea nas artérias.

Conforme Schmidt et al. (2011)<sup>9</sup>, define-se uma doença crônica não transmissível como um problema de saúde global, e que ameaça a qualidade de vida e desenvolvimento humano, onde apresentam-se uma evolução lenta, em que o indivíduo convive com essa condição por anos. As doenças crônicas agem frequentemente de forma silenciosa, entretanto, com o passar do tempo pode trazer uma série de complicações, comprometendo a qualidade de vida.

No Brasil, 40% da população adulta dispõe ao menos de uma doença crônica não transmissível, o que representa cerca de 57 milhões de pessoas, são elas responsáveis por 72% das mortes dos brasileiros. Hipertensão arterial e diabetes estão entre as de maior prevalência no país (CONTE, 2020)<sup>10</sup>.

Segundo as Diretrizes Brasileiras de Hipertensão Arterial (2020) a Hipertensão Arterial (HA) é uma condição clínica, caracterizada pelos níveis elevados da pressão sanguínea nas artérias.


---

<sup>9</sup> SCHMIDT, Maria Inês; DUNCAN, Bruce Bartholow; MENDONÇA, Gulnar Azevedo e Silva; et al. Doenças crônicas não transmissíveis no Brasil: carga e desafios atuais. **The Lancet**. London, p.61-74, maio. 2011. Disponível em: <http://download.thelancet.com/flatcontentassets/pdfs/brazil/brazilpor4.pdf>

<sup>10</sup>CONTE, Juliana. **Quase 60 milhões de brasileiros têm alguma doença crônica**. [S. l.], 11 ago. 2020. Disponível em: <https://drauziovarella.uol.com.br/saude-publica/quase-60-milhoes-de-brasileiros-tem-alguma-doenca-cronica/>.

Segundo a OMS (Organização Mundial da Saúde), uma pessoa é considerada hipertensa quando sua pressão sistólica (contração do coração) é maior que 140 milímetros de mercúrio (mmHg) e/ou a diastólica (relaxamento entre um batimento cardíaco e outro) igual ou maior que 90 mmHg para adultos maiores de 18 anos. Trata-se de uma condição multifatorial, que depende de fatores genéticos/ epigenéticos, ambientais e sociais (Figura 3):

Figura 3 - Determinantes genéticos/epigenéticos, ambientais e sociais interagem para elevar a PA em hipertensos e na população em geral.



Fonte: CAREY et al. 2018.

A Sociedade Brasileira de Cardiologia (SBC) alerta para conscientização da população sobre a importância do diagnóstico preventivo e do tratamento da doença, que mata mais de 10 milhões de pessoas por ano no mundo, considerando ainda que cerca de 30% dos brasileiros são hipertensos.

A HA é uma doença que atinge aproximadamente 30 milhões de brasileiros, aponta a sociedade brasileira de Cardiologia (SBC).

Só no Brasil, um em cada cinco indivíduos sofrem da doença., segundo o Ministério da Saúde, apenas 10% fazem o controle adequado. Além de ser considerada a doença de maior prevalência na população brasileira e é a principal causa de morte no Brasil.<sup>11</sup>

### 2.3.1 Representatividade do hipertenso em Fortaleza

De acordo com a campanha de detecção de casos de HA realizada no período de janeiro a abril de 2002 com a população alvo maior de 40 anos, através de uma única medida de pressão arterial, foi constatado que: em Fortaleza, das 137.363 pessoas atendidas, 38%

<sup>11</sup> <https://soces.org.br/noticias/area-medica/hipertensao-atinge-mais-de-30-milhoes-de-pessoas-no-brasil/>

apresentaram pressão arterial elevada, sendo uma incidência maior no sexo feminino. No Estado do Ceará, foram realizadas 586.041 medidas, onde 35% apresentaram pressão alta, prevalecendo o sexo feminino; e no Brasil, nesse mesmo período foram realizadas 8.327.235 medidas onde 30% apresentaram pressão arterial elevada, 21% eram mulheres e 15% homens<sup>12</sup>.

Conforme últimos dados da pesquisa Vigitel (2021), do Ministério da Saúde, a frequência de adultos que referiram diagnóstico médico de hipertensão arterial em 2021 em Fortaleza foi de 22,8%, sendo a maior frequência no sexo feminino de 25,3%, acompanhado do sexo masculino com 19,8%. Conforme dados das demais capitais a frequência variou entre 19,3% em São Luís e 32,0% no Rio de Janeiro.

Tabela 1 – Percentual de Adultos ( $\geq 18$  anos) que referiram diagnóstico médico de hipertensão arterial, por sexo, segundo as capitais dos estados brasileiros e o Distrito Federal. Vigitel 2021

| Capitais/DF      | Sexo  |             |           |             |          |             |
|------------------|-------|-------------|-----------|-------------|----------|-------------|
|                  | Total |             | Masculino |             | Feminino |             |
|                  | %     | IC 95%      | %         | IC 95%      | %        | IC 95%      |
| Aracaju          | 26,5  | 22,1 - 30,8 | 23,9      | 16,2 - 31,7 | 28,5     | 23,8 - 33,3 |
| Belém            | 23,0  | 19,5 - 26,5 | 22,7      | 17,2 - 28,2 | 23,3     | 18,7 - 27,8 |
| Belo Horizonte   | 29,3  | 25,7 - 32,9 | 25,7      | 20,2 - 31,3 | 32,2     | 27,6 - 36,9 |
| Boa Vista        | 20,3  | 17,3 - 23,2 | 18,3      | 13,7 - 23,0 | 22,0     | 18,4 - 25,7 |
| Campo Grande     | 22,6  | 18,9 - 26,4 | 20,9      | 14,6 - 27,2 | 24,2     | 19,8 - 28,6 |
| Cuiabá           | 27,8  | 23,6 - 32,0 | 28,6      | 21,5 - 35,7 | 27,0     | 22,4 - 31,7 |
| Curitiba         | 28,1  | 24,2 - 31,9 | 24,1      | 18,2 - 29,9 | 31,5     | 26,3 - 36,7 |
| Florianópolis    | 23,3  | 19,8 - 26,8 | 20,6      | 15,1 - 26,1 | 25,7     | 21,3 - 30,2 |
| Fortaleza        | 22,8  | 19,1 - 26,4 | 19,8      | 14,0 - 25,6 | 25,3     | 20,7 - 29,9 |
| Goiânia          | 22,5  | 19,2 - 25,8 | 22,6      | 17,2 - 28,0 | 22,4     | 18,4 - 26,5 |
| João Pessoa      | 27,3  | 22,9 - 31,7 | 25,7      | 18,5 - 32,9 | 28,7     | 23,3 - 34,1 |
| Macapá           | 21,5  | 18,3 - 24,6 | 23,8      | 18,4 - 29,2 | 19,3     | 16,0 - 22,6 |
| Maceió           | 26,4  | 21,9 - 30,9 | 26,0      | 18,9 - 33,0 | 26,8     | 20,9 - 32,6 |
| Manaus           | 22,6  | 18,3 - 26,9 | 21,2      | 13,7 - 28,7 | 23,9     | 19,3 - 28,5 |
| Natal            | 25,0  | 21,1 - 29,0 | 19,7      | 14,4 - 25,0 | 29,6     | 24,1 - 35,1 |
| Palmas           | 23,1  | 18,6 - 27,6 | 23,9      | 15,8 - 32,0 | 22,4     | 17,8 - 26,9 |
| Porto Alegre     | 26,7  | 22,8 - 30,5 | 22,2      | 17,1 - 27,2 | 30,3     | 24,7 - 36,0 |
| Porto Velho      | 20,9  | 17,3 - 24,5 | 19,1      | 13,4 - 24,8 | 22,9     | 18,6 - 27,2 |
| Recife           | 30,9  | 26,3 - 35,5 | 30,2      | 22,7 - 37,7 | 31,4     | 25,7 - 37,1 |
| Rio Branco       | 23,1  | 19,2 - 27,1 | 23,5      | 16,5 - 30,5 | 22,8     | 18,8 - 26,9 |
| Rio de Janeiro   | 32,0  | 27,5 - 36,4 | 32,2      | 24,7 - 39,6 | 31,8     | 26,6 - 37,0 |
| Salvador         | 24,3  | 21,0 - 27,7 | 19,9      | 14,8 - 25,0 | 28,0     | 23,7 - 32,3 |
| São Luís         | 19,3  | 15,7 - 23,0 | 13,8      | 8,1 - 19,5  | 23,8     | 19,2 - 28,4 |
| São Paulo        | 26,4  | 22,5 - 30,4 | 28,2      | 22,1 - 34,3 | 24,9     | 19,9 - 30,0 |
| Teresina         | 24,9  | 21,2 - 28,7 | 25,2      | 18,9 - 31,5 | 24,7     | 20,2 - 29,2 |
| Vitória          | 26,6  | 22,9 - 30,4 | 29,0      | 22,4 - 35,7 | 24,6     | 20,6 - 28,6 |
| Distrito Federal | 24,7  | 20,7 - 28,7 | 23,5      | 16,7 - 30,2 | 25,8     | 21,1 - 30,5 |

\*Percentual ponderado para ajustar a distribuição sociodemográfica da amostra Vigitel à distribuição da população adulta da cidade projetada para o ano de 2021 (ver Aspectos Metodológicos).  
Nota: IC = Intervalo de Confiança.

Fonte: Vigitel (2021).

<sup>12</sup> Lessa I. Não adesão ao tratamento da hipertensão arterial - consequências econômicas para o indivíduo e para a sociedade. In: Nobre F, Pierin AMG, Mion Jr D. Adesão ao tratamento - o grande desafio da hipertensão. São Paulo: Lemos; 2001. p. 86-106.

Quanto ao perfil do hipertenso, tem-se conforme os dados Vigitel(2021) que a maior frequência de diagnóstico de hipertensão se concentra no público feminino com idade entre 55 a 64 anos e 64 anos ou mais. Já quanto a escolaridade se sobressaem os do grupo de hipertensos entre 0 a 8 anos de escolaridade, com destaque para o gênero feminino.

Tabela 2 - Percentual de indivíduos que referiram diagnóstico médico de hipertensão arterial no conjunto da população adulta ( $\geq 18$  anos) das capitais dos estados brasileiros e do Distrito Federal, por sexo, segundo idade e anos de escolaridade. Vigitel, 2021

| Variáveis                   | Sexo        |                    |             |                    |             |                    |
|-----------------------------|-------------|--------------------|-------------|--------------------|-------------|--------------------|
|                             | Total       |                    | Masculino   |                    | Feminino    |                    |
|                             | %           | IC 95%             | %           | IC 95%             | %           | IC 95%             |
| <b>Idade (anos)</b>         |             |                    |             |                    |             |                    |
| 18 a 24                     | 3,8         | 2,5 - 5,1          | 3,1         | 1,5 - 4,7          | 4,5         | 2,5 - 6,6          |
| 25 a 34                     | 12,2        | 8,8 - 15,7         | 13,9        | 8,6 - 19,3         | 10,8        | 6,4 - 15,2         |
| 35 a 44                     | 18,6        | 15,7 - 21,4        | 19,9        | 14,9 - 24,8        | 17,6        | 14,4 - 20,8        |
| 45 a 54                     | 30,9        | 28,1 - 33,7        | 32,8        | 28,1 - 37,5        | 29,3        | 26,0 - 32,5        |
| 55 a 64                     | 49,4        | 46,6 - 52,2        | 46,4        | 41,5 - 51,2        | 51,7        | 48,5 - 55,0        |
| 65 e mais                   | 61,0        | 59,0 - 63,0        | 57,1        | 53,4 - 60,7        | 63,7        | 61,6 - 65,8        |
| <b>Anos de escolaridade</b> |             |                    |             |                    |             |                    |
| 0 a 8                       | 44,6        | 41,8 - 47,3        | 41,7        | 37,1 - 46,2        | 47,2        | 43,8 - 50,5        |
| 9 a 11                      | 21,9        | 20,0 - 23,7        | 20,3        | 17,3 - 23,3        | 23,3        | 21,0 - 25,5        |
| 12 e mais                   | 17,1        | 15,1 - 19,1        | 18,0        | 15,5 - 20,5        | 16,4        | 13,4 - 19,4        |
| <b>Total</b>                | <b>26,3</b> | <b>25,1 - 27,6</b> | <b>25,4</b> | <b>23,4 - 27,4</b> | <b>27,1</b> | <b>25,5 - 28,7</b> |

\*Percentual ponderado para ajustar a distribuição sociodemográfica da amostra Vigitel à distribuição da população adulta da cidade projetada para o ano de 2021 (ver Aspectos Metodológicos).

Nota: IC = Intervalo de Confiança.

Fonte: Vigitel (2021).

É válido ressaltar ainda conforme dados da tabela 2 que em ambos os sexos, esta frequência aumentou com a idade e diminuiu com o nível de escolaridade. A manchete do Jornal o Povo, de Fortaleza, em 27 de abril de 2019 (Fortaleza teve quase 4 mil mortes relacionadas à hipertensão em 2018) só vem ratificar a hipertensão como a doença mais prevalente, assim em todo o mundo e com altos índices de óbitos.

Doenças relacionadas à hipertensão foram responsáveis por 3.944 mortes somente em Fortaleza no ano passado. Segundo a Secretaria Municipal de Saúde (SMS), as principais razões são acidentes vasculares cerebrais e problemas cardiovasculares. (...) 50% da população com pressão alta desconhece que tem a enfermidade. (...) 20% das pessoas, entre 18 e 60 anos, apresentam a doença. O número salta para 50% entre 60 e 69 anos e, acima de 70 anos, atinge a 50% da população. (...) como é uma doença silenciosa, um diagnóstico precoce e tratamento adequado são imprescindíveis para evitar eventos cardíacos como infarto, AVC, problemas renais.<sup>13</sup>

<sup>13</sup> <https://mais.opovo.com.br/jornal/cidades/2019/04/26/capital-teve-quase-4-mil-mortes-relacionadas-a-hipertensao.html>

### 2.3.2 Monitoramento da Pressão Arterial

O esfigmomanômetro de coluna de mercúrio é o ideal para medida de pressão Arterial segundo o III Consenso Brasileiro de Hipertensão Arterial. Os aparelhos do tipo aneroide, quando usados, devem ser periodicamente testados e devidamente calibrados.

Muitos médicos incentivam o monitoramento casual, exterior ao consultório, da pressão arterial, visto que sem este procedimento não é possível avaliar adequadamente a PA (SOUSA et al., 2011). O monitoramento de rotina no consultório médico é indispensável para verificar a PA, mas, ainda assim, é muito recomendado que as pessoas realizem um acompanhamento diário para poder monitorar o tratamento, melhorar a adesão e o controle da PA.

O método mais comumente utilizada em consultórios médicos é o auscultatório. Os instrumentos que utilizam essa técnica determinam a pressão arterial pelo monitoramento dos sons de Korotkoff. Esta técnica é realizada se utilizando de um manômetro acoplado a uma bolsa inflável (manguito) e um estetoscópio. O objetivo é interromper a passagem do fluxo sanguíneo, na artéria braquial, insuflando o manguito para, então, liberar lentamente o ar da bolsa e, utilizando o estetoscópio, perceber o ruído produzido no retorno do fluxo. Quando o sangue começa a fluir pela artéria, seu fluxo cria uma pulsação sincrônica do pulso (primeiro som de Korotkoff). A pressão arterial sistólica é associada com a primeira detecção deste som, visto que a pressão do fluxo conseguiu vencer a pressão imposta pelo manguito, sendo assim a pressão máxima. Quando o silêncio volta a ocorrer, indicasse que não há nenhuma força se opondo à passagem do sangue, logo é aferida a pressão arterial diastólica (SBH, 2017)<sup>14</sup>. Alguns dos instrumentos que utilizam essa técnica são o esfigmomanômetro de mercúrio e um esfigmomanômetro em conjunto com um estetoscópio, como o visto na Figura 4.

Figura 4 – Esfigmomanômetro(1) e estetoscópio (2)



Fonte: TELEDIU. 2022<sup>15</sup>

<sup>14</sup> SOCIEDADE BRASILEIRA DE HIPERTENSÃO. O que é hipertensão. Disponível em: <http://www.sbh.org.br/geral/oque-e-hipertensao.asp>.


<sup>15</sup> Aparelho de pressão Arterial Esfigmomanômetro Fecho em Velcro com Estetoscópio. 2022. Disponível em: <http://www.telediu.com.br/produto/37/aparelho-de-pressao-arterial-esfigmomanometro-fecho-em-velcro-com-estetoscopio>> Acesso em: 3 fev.2022.

Dos métodos utilizados para o controle contínuo da pressão arterial, o mais utilizado é o M.A.P.A., mas existe também um que utiliza a técnica de fotopletismografia, o primeiro é um exame realizado em períodos de 24 horas, e procura auxiliar os médicos na avaliação de sintomas, assim como palpitações, arritmias, episódios de desmaios e também para acompanhamento pós-cirurgias.

O M.A.P.A. (Monitoração Ambulatorial da Pressão Arterial) é um exame cardiológico que pode ser realizado por dois métodos, sendo estes o oscilométrico ou o Holter, para a obtenção das pressões arteriais continuamente. Este exame permite o estudo do padrão da pressão arterial e a realização da análise da eficácia das drogas anti-hipertensivas. O MAPA Holter é realizado através de eletrodos colados no peito do paciente que são conectados a um monitor. Devido ao uso desses eletrodos a técnica utilizada aqui é parecida com a do eletrocardiograma.

A fotopletismografia realiza a medição da PA batimento a batimento, porém este método ainda envolve a utilização de um manguito preso ao dedo do paciente. Aqui, um feixe de luz infravermelha identifica a Pressão Transmural<sup>7</sup>, e o equipamento infla o manguito até que sua pressão anule a transmural, obtendo assim a PA, visto que a pressão transmural é a PA menos a pressão exercida pelo manguito (SBH, 2017). Na Figura 5 é possível observar as três técnicas existentes de monitoramento da pressão arterial, em quais contextos cada uma é usada e por quais métodos. Por exemplo, o método oscilométrico é usado para realizar medidas casuais ou intermitentes, sendo considerado casual a realização da medida em algum momento do dia por um indivíduo.


Figura 5 – Técnicas existentes, os tipos de medição e os métodos que as utilizam



Fonte: Sociedade Brasileira de Hipertensão (2015)

Para o diagnóstico da hipertensão tem-se o fluxograma abaixo como basilar segundo a SBH:

Figura 6 - Fluxograma para diagnóstico de hipertensão arterial (modificado do Canadian Hypertension Education Program)



Fonte: Sociedade Brasileira de Cardiologia. Arquivos Brasileiros de Cardiologia. ISSN-0066-782X. Volume 107, Nº 3, Suppl. 3, September 2016.

Conforme a Figura 6:

**Normotensão** : Considera-se normotensão quando as medidas de consultório são  $\leq 120/80$  mmHg e as medidas fora dele (MAPA ou MRPA) confirmam os valores considerados normais referidos [na Figura 13](#). Define-se HA controlada quando, sob tratamento anti-hipertensivo, o paciente permanece com a PA controlada tanto no consultório como fora dele.

**Pré-hipertensão:** A PH caracteriza-se pela presença de PAS entre 121 e 139 e/ou PAD entre 81 e 89 mmHg. Os pré-hipertensos têm maior probabilidade de se tornarem hipertensos e maiores riscos de desenvolvimento de complicações CV quando comparados a indivíduos com PA normal,  $\leq 120/80$  mmHg, necessitando de acompanhamento periódico.

**Efeito do avental branco:** O EAB é a diferença de pressão entre as medidas obtidas no consultório e fora dele, desde que essa diferença seja igual ou superior a 20 mmHg na PAS e/ou 10 mmHg na PAD. Essa situação não muda o diagnóstico, ou seja, se o indivíduo é normotenso,

permanecerá normotenso, e se é hipertenso, continuará sendo hipertenso; pode, contudo, alterar o estágio e/ou dar a falsa impressão de necessidade de adequações no esquema terapêutico.

**Hipertensão do avental branco:** É a situação clínica caracterizada por valores anormais da PA no consultório, porém com valores considerados normais pela MAPA ou MRPA (Figura 6). Com base em quatro estudos populacionais, a prevalência global da HAB é de 13% (intervalo de 9-16%) e atinge cerca de 32% (intervalo de 25-46%) dos hipertensos, sendo mais comum (55%) nos pacientes em estágio 1 e 10% no estágio 3. Se, em termos prognósticos, a HAB pode ser comparada à normotensão é uma questão ainda em debate, porque alguns estudos revelam que há risco Cardiovascular em longo prazo.

Tabela 3 – Classificação da PA de acordo com a medição casual ou no consultório a partir de 18 anos de idade


| Quadro 3.4 – Classificação da pressão arterial de acordo com a medição no consultório a partir de 18 anos de idade |            |  |            |
|--------------------------------------------------------------------------------------------------------------------|------------|--|------------|
| Classificação*                                                                                                     | PAS (mmHg) |  | PAD (mmHg) |
| PA ótima                                                                                                           | < 120      |  | < 80       |
| PA normal                                                                                                          | 120-129    |  | 80-84      |
| Pré-hipertensão                                                                                                    | 130-139    |  | 85-89      |
| HA Estágio 1                                                                                                       | 140-159    |  | 90-99      |
| HA Estágio 2                                                                                                       | 160-179    |  | 100-109    |
| HA Estágio 3                                                                                                       | ≥ 180      |  | ≥ 110      |

HA: hipertensão arterial; PA: pressão arterial; PAS: pressão arterial sistólica; PAD: pressão arterial diastólica. \*A classificação é definida de acordo com a PA no consultório e pelo nível mais elevado de PA, sistólica ou diastólica. \*\*A HA sistólica isolada, caracterizada pela PAS ≥ 140 mmHg e PAD < 90 mmHg, é classificada em 1, 2 ou 3, de acordo com os valores da PAS nos intervalos indicados. \*\*\*A HA diastólica isolada, caracterizada pela PAS < 140 mmHg e PAD ≥ 90 mmHg, é classificada em 1, 2 ou 3, de acordo com os valores da PAD nos intervalos indicados.

Fonte: Diretrizes Brasileiras de Hipertensão Arterial - Barroso et al (2020)

A figura 7 ilustra as possibilidades de diagnóstico:

Figura 7 - Possibilidades de diagnóstico de acordo com a medida casual de PA, MAPA ou medidas domiciliares.



Fonte: Sociedade Brasileira de Cardiologia. Arquivos Brasileiros de Cardiologia. ISSN-0066-782X. Volume 107, Nº 3, Supl. 3, September 2016.

### 2.3.3 Riscos associados a Hipertensão Arterial

Em 2017, dados completos e revisados do Datasus mostraram a ocorrência de 1.312.663 óbitos no total, com um percentual de 27,3% para as Doenças Cardiovasculares<sup>16</sup>. A HA estava associada em 45% destas mortes cardíacas e de 51,0% das mortes por doença cerebrovascular (DCV) e um percentual muito pequeno de mortes diretamente relacionadas com a HA (13,0%). Vale ressaltar que a HA mata mais por suas lesões nos órgãos-alvo.<sup>17</sup>

A hipertensão é importante questão de saúde pública e o principal fator de risco para doenças cardiovasculares, acidente vascular cerebral e doença renal crônica, sendo que estes estão entre os problemas de saúde mais prevalentes e onerosos do mundo. O controle da PA é a intervenção mais eficaz para salvar vidas, prevenindo comorbidades deletérias, mas apenas aproximadamente metade dos indivíduos apresentam controle pressórico mesmo nos países em desenvolvimento.<sup>18</sup>

A PA é um dos parâmetros de monitorização mais importantes na clínica médica. A medida adequada da PA é ponto crucial no diagnóstico e na conduta da hipertensão arterial na prática clínica, em consultórios ou fora deles. A monitorização residencial da PA com dispositivos automáticos validados torna-se uma alternativa à monitorização ambulatorial da pressão arterial (MAPA), recomendada como o método preferencial de medida da PA fora do consultório na maioria das diretrizes devido à sua maior precisão, capacidade ímpar de medir a PA noturna, identificando hipertensos Non-dippers e Risers (Reverse dippers), detecta a variabilidade circadiana e parece correlacionar-se melhor com prognóstico. Em contraste com o MAPA, a monitorização residencial da pressão arterial (MRPA) é bem tolerada, mais facilmente disponível, de menor custo, apresentando também uma associação mais forte com o risco renal e cardiovascular, em comparação com a pressão medida no consultório. Além disso, a MRPA pode conferir maior autonomia ao paciente, além de um papel mais ativo no tratamento de sua doença crônica, sendo útil para monitorar a eficácia do tratamento anti-hipertensivo, melhorando assim o controle da PA, diminuindo a inércia terapêutica. No entanto, as evidências científicas atuais demonstraram que a MRPA, embora seja custo efetiva e se constitua em boa abordagem, é subutilizada.<sup>19</sup>

---

<sup>16</sup> 2017. Lancet. 2016;390:1151–210. Causes of Death 2008 [online database]. Geneva, World Health Organization. [Cited in 2020 Mar 10] Available from:[http://www.who.int/healthinfo/global\\_burden\\_disease/cod\\_2008\\_sources\\_methods.pdf](http://www.who.int/healthinfo/global_burden_disease/cod_2008_sources_methods.pdf)

<sup>17</sup> <http://departamentos.cardiol.br/sbc-dha/profissional/pdf/Diretriz-HAS-2020.pdf>

<sup>18</sup> <https://www.scielo.br/j/abc/a/wTq5dgLkrSgsjNWjWHmT6gN/?lang=pt&format=pdf>

<sup>19</sup> <https://www.scielo.br/j/abc/a/wTq5dgLkrSgsjNWjWHmT6gN/?lang=pt&format=pdf>

Diante do exposto importante atentar para a estratificação de risco no paciente hipertenso segundo os fatores de riscos adicionais, conforme tem-se na tabela 3.

Tabela 4 – Estratificação de risco no paciente hipertenso de acordo com fatores de risco adicionais, presença de lesão em órgão-alvo e de doença cardiovascular ou renal


|                                 | PAS 130-139 ou PAD 85-89 | HAS Estágio 1 PAS 140-159 ou PAD 90-99 | HAS Estágio 2 PAS 160-179 ou PAD 100-109 | HAS Estágio 3 PAS ≥ 180 ou PAD ≥ 110 |
|---------------------------------|--------------------------|----------------------------------------|------------------------------------------|--------------------------------------|
| Sem fator de risco              | Sem Risco Adicional      | Risco Baixo                            | Risco Moderado                           | Risco Alto                           |
| 1-2 fatores de risco            | Risco Baixo              | Risco Moderado                         | Risco Alto                               | Risco Alto                           |
| ≥ 3 fatores de risco            | Risco Moderado           | Risco Alto                             | Risco Alto                               | Risco Alto                           |
| Presença de LOA, DCV, DRC ou DM | Risco Alto               | Risco Alto                             | Risco Alto                               | Risco Alto                           |

PAS: pressão arterial sistólica; PAD: pressão arterial diastólica; HAS: hipertensão arterial sistêmica; DCV: doença cardiovascular; DRC: doença renal crônica; DM: diabetes melito; LOA: lesão em órgão-alvo.

Fonte: [http://publicacoes.cardiol.br/2014/diretrizes/2016/05\\_HIPERTENSAO\\_ARTERIAL.pdf](http://publicacoes.cardiol.br/2014/diretrizes/2016/05_HIPERTENSAO_ARTERIAL.pdf)

O fluxograma da figura 8 elucida o exposto quanto a classificação de risco adicional no paciente hipertenso.

Figura 8 – Fluxograma de classificação de risco CV adicional no paciente hipertenso.



Fonte: [http://publicacoes.cardiol.br/2014/diretrizes/2016/05\\_HIPERTENSAO\\_ARTERIAL.pdf](http://publicacoes.cardiol.br/2014/diretrizes/2016/05_HIPERTENSAO_ARTERIAL.pdf)

Considerada um dos principais fatores de riscos de morbidade e mortalidade cardiovasculares, seu alto custo social é responsável por cerca de 40% dos casos de aposentadoria precoce e de absenteísmo no trabalho em nosso meio. Devido a magnitude do problema, tem sido constante a preocupação mundial em ampliar e aperfeiçoar os métodos para

diagnóstico e tratamento de hipertensão arterial. (III Consenso Brasileiro de Hipertensão Arterial).

Devido ao que foi supramencionado quanto aos riscos cardiovasculares adicionais aos pacientes com HAS, apresenta-se a tabela 5:

Tabela 5 – Fatores de risco cardiovascular adicionais aos pacientes com HAS

| <b>Fatores de Risco Cardiovascular</b>                                                                               |
|----------------------------------------------------------------------------------------------------------------------|
| <b>Idade (em anos)</b>                                                                                               |
| Homem > 55<br>Mulheres > 65                                                                                          |
| <b>Tabagismo</b>                                                                                                     |
| <b>Dislipidemias</b>                                                                                                 |
| Triglicérides $\geq$ 150 mg/dl<br>LDL colesterol > 100 mg/dl<br>HDL < 40 mg/dl para homens<br>HDL < 46 para mulheres |
| <b>Diabetes mellitus</b>                                                                                             |
| <b>História familiar de DCV prematura (em anos)</b>                                                                  |
| Homens < 55<br>Mulheres < 65                                                                                         |
| <b>Glicemia de jejum: 100-125 mg/dl</b>                                                                              |
| <b>Teste de tolerância à glicose: anormal</b>                                                                        |
| <b>Obesidade: IMC <math>\geq</math>30 Kg/m<sup>2</sup></b>                                                           |
| <b>Circunferência da cintura</b>                                                                                     |
| > 102 cm para homens<br>> 88 cm para mulheres                                                                        |
| <b>Sexo masculino</b>                                                                                                |

Fonte: (III Consenso Brasileiro de Hipertensão Arterial)

No Brasil, aproximadamente 35% da população tem a enfermidade, segundo dados do Ministério da Saúde, mas metade nem sabe disso. Das pessoas que têm conhecimento, 50% fazem uso de medicação, e, dessas, apenas 45% têm a pressão controlada.

No cenário da saúde uma grande quantidade de dados (HEALTH, 2019; OLIVEIRA, 2019) é produzida diariamente e, na sua maioria, oriundos da assistência ofertada ao paciente. Extrair informação dos conjuntos de dados para produção de novos conhecimentos ou promoção de melhores decisões exige o uso de infraestrutura tecnológica, técnicas computacionais e estatísticas, resultando em um grande desafio. Uma discussão relevante para a construção de cenários mais favoráveis a transformação do conjunto de dados em informação é a promoção de uma cultura para adesão, a padronização e interoperabilidade para que o fluxo

e processamento de dados entre sistemas e agentes de saúde sejam mais fluídos, permitindo trocas e integração.

As tecnologias baseadas em IA utilizando serviços de Aprendizado de Máquina (AM) possuem potencial de transformar a assistência em saúde.

## **2.4 Aprendizado de Máquina**

Na prática, as aplicações utilizando AM são voltadas para o diagnóstico mais preciso, na identificação de padrões fisiológicos, no apoio à decisão para os processos em medicina personalizada entre outras. A grande vantagem do uso das técnicas de AM reside em sua capacidade de aprender com experiências do mundo real, seguida pela capacidade de melhoria do seu desempenho por aprendizado. As técnicas de AM são amplamente conhecidas pelo seu uso na automação de processos. Como exemplo, reconhecimento de padrões visuais em que a partir desse reconhecimento, é possível sugerir ou apoiar as decisões dos profissionais de saúde. A eficácia das técnicas é resultado direto da quantidade e qualidade dos dados disponíveis associados aos modelos de aprendizagem aplicados.

O desenvolvimento e teorização das técnicas de AM inicia-se com Arthur Samuel (HANDELMAN et al., 2018) em 1959, um importante cientista da computação de sua época. Suas aplicações práticas para a área da saúde começam na década de 70 e prevalecem em expansão. Pode-se observar que no ramo da medicina diagnóstica o uso das técnicas encontra-se em processo de amadurecimento. O AM foi aplicado pela primeira vez na medicina com o uso de registros eletrônicos de saúde na década de 1950 e desempenhou um papel essencial na formação da informática em saúde (HOLDER et al., 2017). A técnica de AM utiliza recursos extraídos dos dados como entrada e retorna o conhecimento adquirido como saída. As aplicações na saúde utilizam desde algoritmos de redes neurais artificiais (RNAs), principalmente para medicina diagnóstica, como também outras técnicas: árvores de decisão (decision trees), SVM, Knearest neighbors, classificadores Naïve Bayes e modelos de Markov ocultos (Hidden Markov Mode) (LIU; SALINAS, 2015; ANVISA, 2018)

Diante disso, um novo contexto em saúde, pautado em informações assertivas, previsões e processos inteligentes, podem ser embasados por informações resultantes da aplicação das técnicas de AM com o propósito de inspirar caminhos para a resolução de problemas práticos. THEODORIDIS; KOUTROUMBAS, 2009; MOHRI et al., 2018). O algoritmo faz previsões para os dados não vistos. Clusterização e redução de dimensionalidade são problemas comumente encontrados nesses cenários.

Como supramencionado, a plataforma GISSA tem passado por contínua evolução desde sua concepção, em 2009, como resultado de pesquisas, desenvolvimento e inovação. Assim, pesquisas têm sido incorporadas ao GISSA, notadamente no recente trabalho doutoral “Smart-GISSA” (COSTA FILHO, 2021). A arquitetura do Smart-GISSA além de extrair, transformar e carregar os dados em dashboards, inclui modelos de aprendizado de máquina para especializar a tomada de decisão em saúde pública.

Na era digital, assim como as demais áreas da sociedade, a área da saúde passa por crescente inserção das tecnologias digitais da informação e comunicação, diante da produção e armazenamento de um grande número de informações, o que tem resultado em uma maior demanda pela progressiva informatização do setor de saúde.

A era da informação trouxe consigo uma avalanche nunca vista na criação de informação digital. Um estudo de 2012 da consultoria EMC previu que entre 2005 e 2020 a quantidade de dados produzidos eletronicamente aumentaria de 130 exabytes para 40 mil exabytes, ou 40 trilhões de gigabytes. (NETTO; MARCIEL, 2021).

Com a crescente demanda por informações atualizadas e acuradas sobre o paciente, os Registros Eletrônicos em Saúde (RES) têm sido amplamente utilizados por possibilitar registro, organização, pesquisa e apoio às decisões em saúde.

Extrair informação dos conjuntos de dados para produção de novos conhecimentos ou promoção de melhores decisões exige o uso de infraestrutura tecnológica, técnicas computacionais e estatísticas.

Para a construção de cenários mais favoráveis a transformação de um conjunto de dados em informação, o grande desafio é a padronização e interoperabilidade para que o fluxo e processamento de dados entre sistemas e agentes de saúde sejam mais fluidos, permitindo trocas e integração.

As tecnologias baseadas em IA utilizando AM possuem potencial de transformar a assistência em saúde. Na prática, as aplicações são utilizadas para o diagnóstico mais preciso, na identificação de padrões fisiológicos, no apoio à decisão para os processos em medicina personalizada, etc. No caso em estudo, propõe-se a utilização voltada ao paciente hipertenso a partir dos dados coletados do GISSA.

O desenvolvimento e teorização das técnicas e AM inicia-se com Arthur Samuel (HANDELMAN<sup>20</sup> et al., 2018) em 1959 e suas aplicações práticas para a área da saúde começam na década de 70 e continuam em expansão.

---

<sup>20</sup> HANDELMAN, G. S. et al. EDoctor: Machine Learning and the Future of Medicine. **Journal of Internal Medicine**, v. 284, n. 6, p. 603–619, 2018.

De acordo com Nelli<sup>21</sup> (2015), Aprendizado de Máquina é a disciplina que faz uso de toda uma série de procedimentos e algoritmos para identificar padrões, agrupamentos ou tendências e, então, extrair informação útil para análise de dados, de maneira totalmente automatizada. Pode-se dizer que são métodos matemáticos usados para treinar algoritmos que identificam padrões.

Após as etapas supramencionadas da metodologia de Ramos (2016) que envolvem preparação e transformação dos dados, começa uma das fases cruciais diretamente ligada a implementação da proposta em curso que é a etapa da escolha do algoritmo.

Esta etapa é também conhecida como modelagem preditiva que é o processo pelo qual é escolhido um modelo estatístico que possa prever a probabilidade de um resultado.

Após ter ocorrido a exploração dos dados, será selecionado um modelo matemático que consiga identificar se existem e quais são as relações entre os atributos dos dados ligados ao hipertenso.

O AM aplica de forma sistemática algoritmos para sintetizar os relacionamentos subjacentes entre dados e informações. Dentre os principais métodos de AM pode-se citar o não supervisionado e o supervisionado, destaque para esse último, que será utilizado nesta pesquisa.

Os algoritmos de aprendizagem supervisionada são aqueles em que os dados têm atributos relacionados e nos quais se deseja prever quais atributos influenciam a variável independente (que são aquelas que são modificadas ou controladas para testar os efeitos em uma variável dependente). Esses algoritmos usam dados que já foram previamente separados em atributos com os quais se pode comparar e validar o resultado.

Os algoritmos de aprendizagem supervisionada podem ser de Classificação ou de Regressão. Nesta pesquisa utilizaremos o de Classificação que tratam de problemas em que os dados têm uma classificação prévia e se deseja prever a qual categoria um dado não classificado pertence. “Por exemplo, o problema da classificação dos e-mails legítimos e dos spams. Nesse caso, treinamos o algoritmo de classificação para identificar quais são as características de um email legítimo e quais as de um spam. Treinado, o algoritmo pode testar se o e-mail (ou um conjunto de palavras) pertence a uma das duas classes”. (NETTO; MARCIEL, 2021).

No caso em análise do estudo de caso no hipertenso o intuito da classificação é prever o risco do paciente hipertenso e no caso de risco Alto de sofrer infarto e vir a óbito. Assim, os algoritmos que poderão ser analisados nesta pesquisa são: Random Forest, Naive Bayes e SVM.

---

<sup>21</sup> NELLI, F. **Python Data Analytics**. Nova York: Apress. Springer Science + Business, 2015.

### **1.Random Forest:**

O algoritmo Random Forest é um método de aprendizado do tipo ensemble learning, o qual utiliza múltiplos métodos de aprendizagem buscando obter uma performance maior do que a que seria obtida utilizando apenas um método. Random Forest opera construindo um conjunto de árvores de decisão na etapa de treinamento e na etapa de predição retorna como resultado final a média do resultado de múltiplas árvores.

Árvores de decisão são ferramentas de aprendizado supervisionado para problemas de classificação, comumente utilizados em data mining. Como o próprio nome da técnica sugere, esta possui como objetivo a construção de uma árvore que represente explicitamente a estrutura do conjunto de dados (ROKACH Lior; MAIMON Oded, 2005)<sup>22</sup>.

### **2.Naive Bayes:**

Um dos algoritmos de classificação mais populares na área de mineração de dados. Um classificador Naive Bayes é uma técnica básica baseada em probabilidade, que pode prever as probabilidades de pertinência da classe. Como calcula a probabilidade de adesão para cada classe, ele também pode manipular facilmente os valores de atributos ausentes simplesmente omitindo as probabilidades correspondentes para esses atributos. Em um classificador Naive Bayes, o efeito de um atributo em uma determinada classe também é independente daqueles de outros atributos, que é conhecido como independência condicional de classe. Este classificador calcula facilmente a probabilidade de classificar ou prever a classe em um determinado conjunto de dados. Embora possa causar o problema de probabilidade zero, ele pode desempenhar um papel importante ao prever o usuário móvel classes de atividades em contextos multidimensionais <sup>23</sup>

### **3. Support Vector Machines (SVM):**

É outra técnica de classificação popular usada amplamente para várias análises preditivas. Na maioria dos casos, o SVM é utilizado como classificador binário, ou seja, isolar os focos de informação no espaço de variáveis de informação por suas classes, seja classe 0 ou classe 1. Para fazer isso, um hiperplano é escolhido na máquina de vetores, que é uma linha que pode

---

<sup>22</sup> <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.458.7031&rep=rep1&type=pdf>. ROKACH, L.; MAIMON, O. Top-down induction of decision trees classifiers - A survey. IEEE Transactions on Systems, Man and Cybernetics Part C: Applications and Reviews, v. 35, n. 4, p. 476-487, 2005. ISSN 10946977.

<sup>23</sup> Iqbal H. Sarker\*, A. S. M. Kayes and Paul Watters: Effectiveness analysis of machine learning classification models for predicting personalized context-aware smartphone usage

fazer parte do espaço variável. Trata-se de mais um algoritmo de classificação, cujo objetivo é traçar uma ou mais retas, que dividam de maneira equitativa, com margem máxima, um conjunto de pontos de um plano vetorial, que representam os dados do problema em análise. Ele trabalha apenas com dados linearmente superáveis, o que pode eventualmente limitar sua aplicação. (NETTO; MARCIEL, 2021).

## **2.5 Ontologia: Conceito, Componentes, Tipos e Aplicação**

Em seu sentido filosófico, ontologia possui diversas definições. A palavra é derivada do grego ‘*ontos*’, ser, e ‘*logos*’, palavra. Entretanto, seu termo de origem é a palavra aristotélica categoria, termo este utilizado no sentido de classificação.

Na ciência da computação também podemos encontrar várias definições para este termo. Segundo Guarino (1995;1998) ontologia é uma técnica de organização de informações que vem recebendo especial atenção nos últimos anos, principalmente no que diz respeito à representação formal de conhecimento. Geralmente criadas por especialistas, tendo sua estrutura baseada na descrição de conceitos e dos relacionamentos semânticos entre eles, as ontologias geram uma especificação formal e explícita de uma conceitualização compartilhada.

Apesar de apresentarem diferentes definições, como afirma Gruber (2005) as ontologias têm sido desenvolvidas para facilitar o compartilhamento e reutilização de informações. As ontologias permitem que máquinas processem e integrem recursos de Internet de maneira inteligente, possibilitando buscas rápidas, acuradas e facilitando a comunicação entre dispositivos heterogêneos na rede.

Conforme Almeida (2003) na prática, uma ontologia define uma “linguagem”, conjunto de termos, que será utilizada para formular consultas. A ontologia define as regras de combinação entre os termos e seus relacionamentos, estes relacionamentos são criados por especialistas, e os usuários formulam consultas usando os conceitos especificados.

Quanto aos componentes de uma ontologia com suas características, apresenta-se o Quadro 1.

Quadro 1 - Componentes de uma ontologia.

| COMPONENTES     | DESCRIÇÃO                                                                                                                               |
|-----------------|-----------------------------------------------------------------------------------------------------------------------------------------|
| Conceitos       | Ideias básicas para a formalização: classes de objetos, métodos, planos, estratégias, processos de raciocínio entre outros.             |
| Relacionamentos | Representam a interação e enlace entre os conceitos do domínio, a taxonomia: subclasses                                                 |
| Funções         | Tipo concreto de relação em que se identifica um elemento mediante a cálculo de uma função que considera vários elementos da ontologia. |
| Instâncias      | Se utilizam para representar objetos determinados de um conceito.                                                                       |
| Axiomas         | São teoremas sobre os relacionamentos. Que devem cumprir os elementos da ontologia.                                                     |

Fonte: Autor com base em GRUBBER (1993)

Segundo Guarino (1997) e Guizzardi (2000) quanto à sua função, as ontologias podem ser classificadas em cinco categorias

### 1.Ontologias Genéricas

São consideradas ontologias “gerais”. Descrevem conceitos mais amplos, como elementos da natureza, espaço, tempo, coisas, estados, eventos, processos ou ações, independente de um problema específico ou domínio particular. De acordo com Guizzardi (2000), pesquisas enfocando ontologias genéricas procuram construir teorias básicas do mundo, de caráter bastante abstrato, aplicáveis a qualquer domínio (conhecimento de senso comum).

### 2. Ontologias de Domínio

Descrevem conceitos e vocabulários relacionados a domínios particulares, tais como medicina ou computação, por exemplo. Este é o tipo de ontologia mais comum, geralmente construída para representar um “micro-mundo”.

### **3. Ontologias de Tarefas**

Descrevem tarefas ou atividades genéricas, que podem contribuir na resolução de problemas, independente do domínio que ocorrem, por exemplo, processos de vendas ou diagnóstico. Sua principal motivação é facilitar a integração dos conhecimentos de tarefa e domínio em uma abordagem mais uniforme e consistente, tendo por base o uso de ontologias.

### **4. Ontologias de Aplicação**

Descrevem conceitos que dependem tanto de um domínio particular quanto de uma tarefa específica. Devem ser especializações dos termos das ontologias de domínio e de tarefa correspondentes. Estes conceitos normalmente correspondem a regras aplicadas a entidades de domínio enquanto executam determinada tarefa.

### **5. Ontologias de Representação**

Explicam as conceituações que fundamentam os formalismos de representação de conhecimento, procurando tornar claros os compromissos ontológicos embutidos nestes formalismos.

Ressalta-se que ao invés de genérica Eunice Silva (2006, p. 15) usa o termo ontologia de “alto-nível: descrevem conceitos muito gerais como espaço, tempo, matéria, objeto, evento, ação, etc., os quais são independentes de um problema ou domínio particular. Sendo assim, é bem razoável ter-se uma ontologia de alto-nível compartilhada por grandes comunidades de usuários”.

Para se tornarem computacionais, além de toda sua estruturação informacional, como decidir seu tipo, critérios de construção, uso de metodologias adequadas, Santarem e Coneglian (2015, p. 227) afirmam que as ontologias “precisam passar de uma estrutura conceitual para implementação através de uma linguagem”.

São inúmeras as linguagens existentes para implementação de ontologias: CycL, Loom, Ontolingua/KIF, Flogic, RDF(S), SHOE, XOI, DAML+OIL, OWL, etc.

Para possibilitar uma recuperação da informação com eficácia a fim de suprir as necessidades do usuário em qualquer contexto é fundamental que os dados estejam disponibilizados de forma organizada. No contexto da Web Semântica, tal ação significa compartilhar dados e fatos em vez de somente o texto de uma página.

O rápido crescimento na quantidade de dados disponíveis tornou a Web Semântica uma necessidade e, para viabilizar sua implantação, assim como tecnologias existentes foram

aplicadas de modo mais eficiente (ontologias, bases semânticas), novas tecnologias foram desenvolvidas (como por exemplo, o Linked Data).

A falta de interoperabilidade ainda é uma problemática que se impõe, por isso descobrir e usar de maneira adequada os dados ainda é um desafio. Exemplos de bases de dados de saúde pública, heterogêneas e distintas, disponibilizadas pelo Departamento de Informática do SUS – DATASUS são SINASC (Sistema de Informações sobre Nascidos Vivos) e e-SUS (SUS eletrônico).

### **2.5.1 Ontologia e Linked Data**

Para que um gestor tenha uma visão completa de um problema em saúde pública, os dados das diversas bases disponíveis devem passar por uma integração, i.e., tornarem-se um conjunto homogêneo. Contudo, integrar dados não é um processo trivial. Faz-se, portanto, necessário se dispor de mecanismos computacionais mais elaborados, capazes de integrar dados e extrair informações relevantes que auxiliem gestores de saúde a tomarem boas decisões. Sistemas baseados em ontologias e Linked Data e suas tecnologias associadas, tais como RDF e SPARQL, são capazes de integrar fontes de dados e inferir novas informações a partir de bases heterogêneas de conhecimento. (FREITAS et al, 2017)

O conceito de Linked Data (dados ligados) surgiu para auxiliar a descoberta, acesso e utilização dos dados presentes na Internet. Linked Data são dados semiestruturados que permitem a especificação de relacionamentos semânticos com outros dados que seguem o conceito Linked Data, ou seja, devido à utilização de relacionamentos semânticos para associar os dados e assim melhorar seu compartilhamento, o conceito de Linked Data tem sido sugerido.

As tecnologias da Web Semântica incluem diferentes formatos para troca de dados, como por exemplo, Turtle, Resource Description Framework (RDF), Extensible Markup Language (XML), Notation3 (N3) (2011), NTriples, linguagens de consulta SPARQL (Protocol and RDF Query Language), ontologias e notações como RDF Schema e Web Ontology Language (OWL), que fornecem uma descrição formal de entidades e correspondências dentro de um determinado domínio do conhecimento. As tecnologias são úteis para alcançar o principal objetivo de desempenho da Web Semântica, uma vez que os dados conectados (Linked Data) podem ser entendidos como “[...] um conjunto de boas práticas para publicação e conexão de dados estruturados na Web, usando padrões internacionais recomendados pelo W3C [...]”, que fornecem informações em larga escala para a integração e raciocínio sobre os dados (ISOTANI; BITTENCOURT, 2015, p. 14).

O termo Linked Data, ou dados conectados, foi criado por Berners-Lee em 2006, e segue os princípios da Web Semântica. Berners-Lee (2006a) refere-se a um estilo de publicar e interligar dados estruturados na Web e que tem como objetivo permitir que pessoas compartilhem dados com semântica bem definida de forma tão fácil quanto os documentos são compartilhados na Web.

Os dados são disponibilizados na Web de tal forma que são facilmente processados por máquinas, sendo o seu significado/semântica definido de forma explícita. Além disso, esses dados são ligados bidirecionalmente a outros conjuntos de dados externos (BIZER; HEATH; BERNERS-LEE, 2009).

Sendo assim, visa à partilha e reutilização de informação de modo massivo, num espaço de dados global, permitindo também a descoberta de novos dados (AZEVEDO, 2014). Quanto mais um dado for interligado com outros dados maior é o seu valor e sua utilidade.

Um dos formatos mais empregados para estruturação de Linked Data é o formato Resource Description Framework (RDF). RDF é um modelo genérico de dados baseado na estrutura de grafos que descreve as coisas do mundo. O modelo RDF codifica dados na forma de triplas: sujeito, predicado, objeto. O sujeito e o objeto de uma tripla são ambos Uniform Resource Identifiers (URI) que identificam cada recurso, podendo o objeto assumir o valor de uma string. O predicado especifica como o sujeito e o objeto estão relacionados, e também é representado por um URI de um recurso que descreve tal relacionamento (BIZER; HEATH; BERNERS-LEE, 2009).

Para alcançar e criar dados no estilo Linked Data, as tecnologias devem estar disponíveis para um formato comum (RDF), para fazer qualquer conversão ou acesso em tempo real para bancos de dados existentes (relacionais, XML, HTML) (DIMA, 2013).

Alguns princípios de Linked Data foram introduzidos por Berners-Lee et al. (2006), sendo eles: usar URI como nome para recursos; usar URIs com HTTP para que as pessoas possam encontrar esses nomes; quando alguém procura por uma URI, garantir que informações úteis possam ser obtidas por meio dessas URIs, as quais devem estar representadas no formato RDF; e incluir links para outras URIs de forma que outros recursos possam ser descobertos.

Segundo Berners-Lee et al. (2009), Linked Data devem ser publicados com metadados, auxiliando sua descoberta e sua utilização. É sugerido por Hartig (2009) que os metadados relacionados à Linked Data devem conter, no mínimo, o criador, a data de criação e o método de criação.

Como exemplo de estudos baseado em Ontologia e linked data que propõem soluções computacionais de suporte à tomada de decisão em sistemas de saúde tem-se o de

Freitas et al (2017) que, usando dados clínicos e sociais do DATASUS, promove a integração de dados e calcula a probabilidade do risco de óbito materno e infantil para o GISSA, ou seja, apresentam uma ontologia de risco desenvolvida a partir das heurísticas de especialistas em saúde onde estão os fatores de riscos relevantes para o cálculo da probabilidade de óbito materno-infantil.

A criação do modelo baseado em ontologia e linked data no estudo de Freitas et al (2017) envolveu cinco etapas:

1. Selecionar as fontes de dados que alimentarão a aplicação.
2. Extrair e transformar os dados das fontes selecionadas, possivelmente heterogêneos, em grafos RDF.
3. Identificar links semânticos entre as fontes de dados.
4. Combinar e fundir representações do mesmo objeto em fontes distintas numa visão homogeneizada.
5. Realizar consultas parametrizadas a fonte de dados integrada usando o vocabulário da OD e obter o cálculo da probabilidade do risco de óbito-infantil.


Foi baseando-se na metodologia desenvolvida em Lopes et al (2016) que o estudo de Freitas et al (2017) apresentou um modelo baseado em ontologias e Linked Data Mashup que integra bases de dados distintas e heterogêneas do SUS.

O modelo proposto neste artigo está estruturado numa arquitetura de 5 camadas, exibida na Figura 10.

A camada Bases de Dados é formada pelas bases de dados SIM, e-SUS, SINASC E SINAN, todas disponibilizadas pelo do DATASUS.

Cada base de dados dbi é descrita por uma ontologia fonte Odbi, conforme a Figura 9. Na camada de Acesso e Transformação de Dados é realizado o mapeamento das bases de dados relacionais para RDF, através dos frameworks D2RQ5 e R2RML. Na camada de Integração dos Dados, a interligação das fontes RDF é realizada por links semânticos através do SILK - Link Discovery Framework. Na camada de Processamento de Dados é utilizada a linguagem SPARQL para realizar consultas parametrizadas à fonte de dados integrada. Na camada de Apresentação, uma aplicação web usa dashboards para exibir as informações inferidas pela camada de processamento de dados.


Figura 9 - Arquitetura do modelo baseado em ontologia e Linked Data



Fonte: FREITAS et all(2017)

Conforme Freitas et all (2017) modelos baseados em ontologias possuem, geralmente, base de conhecimento composta por ontologia de domínio, ontologias de aplicação e regras de inferência. Para a base de conhecimento do GISSA não foram especificadas regras de inferência. Foram criadas, como pode ser visto na Figura 10, uma ontologia de domínio OD para representar uma demanda de governança e uma ontologia de risco ORisk (figura 11) para representar as heurísticas dos especialistas.


Figura 10 - Mapeamento das ontologias



Fonte: FREITAS et all(2017)

Ontologia de Domínio. A ontologia de domínio OD trata-se de uma ontologia de referência. Ela especifica todos os conceitos necessários ao modelo. Essa ontologia contém o vocabulário geral para integrar os dados exportados em RDF através dos mapeamentos e links semânticos. Na figura 11 é apresentada parte da ORisk, os riscos clínicos do bebê.

Figura 11 - Parte da Ontologia de Risco



Fonte: FREITAS et al(2017)

Ontologia de Risco (ORisk): Essa ontologia, ORisk, foi desenvolvida a partir das heurísticas dos especialistas em saúde materno-infantil (Figura 11). Ela é dividida em dois domínios: clínico e social. Nesses domínios, usando-se Linked Data na integração de dados, estão os fatores de risco relevantes para o cálculo da probabilidade para risco de óbito materno-infantil. Além disso, também são descritos os eventos relacionados a gestação e ao parto. Assim, a Ontologia de Risco ORisk representa uma coleção de riscos, tais como, “uma mãe que tenha baixa escolaridade, que não recebe bolsa-família (riscos sociais), que teve rubéola (risco clínico)”, etc. Levando em consideração que alguns tipos de riscos materno têm influência direta no bebê, essa correlação está representada na ORisk. Por exemplo, se uma mãe teve rubéola ou tétano neonatal, se o parto foi induzido, se a gestação foi múltipla, então o risco de óbito do bebê aumenta consideravelmente. Essa ontologia tem 51 tipos de riscos e cada risco tem um peso. Esse peso foi definido por especialistas, mediante o relato de suas experiências e pesquisas, em conformidade com a gravidade do risco.

As etapas seguintes do trabalho desenvolvido por Freitas et al(2017) envolveu a transformação e integração dos dados, bem como o cálculo dos riscos. Apesar da probabilidade ter sido validada pelos especialistas em saúde, não existe ainda uma ferramenta matemática, na validação de algoritmos para validar as ontologias neste trabalho, ou vice-versa. Assim, a expectativa é de que o modelo final de inteligência do framework GISSA seja espelhado em um modelo híbrido onde sejam determinantes às pesquisas em curso.

Paralelamente, tem-se também o trabalho de Silva (2017) com objetivo similar usando mineração de dados que foi implementado no projeto GISSA.

A pesquisa de mestrado de Cristiano Silva (2017) propõe o LAIS (Laboratório Avançado de Inteligência Integrada para Sistemas de Saúde), uma solução baseada em Mineração de Dados com o objetivo de tornar inteligentes os alertas do sistema GISSA. O LAIS utiliza uma metodologia de reconhecimento de padrões para escolha do algoritmo de classificação. Utilizou-se algoritmos de balanceamento de dados (Spread Subsample, SMOTE e Resample) com o objetivo de melhorar os resultados do modelo utilizado no LAIS, pois o número de crianças que nasce é bem superior ao número de crianças que morre antes de completar um ano de idade. Os testes mostram que o algoritmo de balanceamento Resample proporciona melhores resultados, e o classificador Random Forest é o mais adequado para este fim, apresentando área da curva ROC de 0,99. Para a implementação do LAIS utilizou-se o WEKA, uma ferramenta que procede à análise computacional e estatística dos dados fornecidos. Assim, o LAIS fornece a probabilidade de um recém-nascido vir à óbito, com base nos seus atributos e os de sua mãe, permitindo que os profissionais de saúde possam identificar e agir mais rapidamente dando mais atenção para os casos de crianças que apresentem maior risco de sofrerem óbito.

Atualmente, o GISSA busca a definição de seu modelo de inteligência onde os trabalhos em desenvolvimento têm papel relevante.

### **3. TRABALHOS RELACIONADOS**

Foi realizada pesquisa bibliográfica com o intuito de fazer um levantamento dos principais trabalhos desenvolvidos referente a IoT e AM (Aprendizado de Máquina), dando ênfase aos trabalhos em IAM (Inteligência Artificial em Medicina) e no contexto das doenças crônicas, com ênfase nos trabalhos focados em hipertensão Arterial, seu monitoramento e predição. Para tanto, foram selecionadas pesquisas dos últimos 10 anos (2012 a 2022).

Durante a pesquisa bibliográfica foi realizada busca pela utilização das seguintes bases:

- Banco de dados PubMed/Medline
- Institute of Electrical and Electronics Engineers (IEEE),
- Association for Computing Machinery (ACM),
- Springer International Publisher Science, Technology, Medicine (Springer) e Science Direct.
- Scielo

- Google Acadêmico
- Biblioteca Digital Brasileira de Teses e Dissertações

Na Biblioteca Digital Brasileira de Teses e Dissertações usando todas as palavras chave: Hipertensão Arterial + Aprendizado de Máquina + IoT + Monitoramento + Predição, não aparece resultados. Já inserindo as palavras-chave: Hipertensão + Monitoramento + Predição foram encontrados 4 trabalhos, mas somente um estava mais relacionado ao que está sendo desenvolvido.

Durante a pesquisa bibliográfica no Google Acadêmico foram utilizadas as palavras chaves: Hipertensão Arterial + Aprendizado de Máquina + IoT+ Predição + Monitoramento foram encontrados aproximadamente 802 resultados.

Verificou-se, nos trabalhos relacionados, que, geralmente, as palavras chaves ligadas a temática em estudo eram tratadas de forma isolada. Diante disso, esta pesquisa foi desenvolvida observando a possibilidade de convergir esses subtemas dentro de uma mesma arquitetura.

Estratégia de Pesquisa: Do total de estudos relacionados a temática em desenvolvimento foram selecionados 15. Esta seleção se justifica, uma vez que o processo de pesquisa bibliográfica foi sistematicamente organizado em três etapas, a saber:

- Identificação: Busca nas bases com execução da expressão de busca em cada uma das bases selecionadas;
- Triagem: leitura do título, resumo e palavras-chave dos artigos, bem como uma breve revisão a fim de verificar o atendimento aos critérios de elegibilidade;
- Elegibilidade: avaliação minuciosa do estudo por meio da leitura na íntegra, resultando na seleção dos estudos incluídos para a análise dos resultados.

Na fase da identificação, o resultado total identificado na busca foi de mais de 800 artigos no Google acadêmico, como supramencionado. Na fase de triagem após o processo de remoção dos duplicados e uma posterior filtragem após leituras dos títulos e/ou resumos, já na etapa da elegibilidade restaram ao final 15 arquivos que foram lidos na íntegra e incluídos na revisão.

Na seleção dos artigos foram construídos critérios de elegibilidade:

- Utilizar dispositivos móveis;
- Possuir um mecanismo de interação entre paciente e profissional;
- Contribuir para um monitoramento contínuo do hipertenso.
- Processo de seleção dos estudos

Tabela 6 – Trabalhos relacionados

| Nº | Autor/Título /Local/Ano                                                                                                                                                                                                                                                                                                                                                               |
|----|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| 1  | FREITAS, Nicodemos. Predição de Casos de Arboviroses na Cidade de Fortaleza-CE. Utilizando Internet das Coisas e Aprendizado de Máquina/ Nicodemos Freitas. – 2021. Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Ciências, Programa de Pós-Graduação em Ciência da Computação, Fortaleza, 2021.                                                                  |
| 2  | COSTA FILHO, Raimundo Valter. Smart-Gissa, Um Sistema Para Governança em Saúde Digital Baseado em Aprendizado de Máquina. Tese apresentada ao Programa de Pós-Graduação em Engenharia de Teleinformática do Centro de Ciências e Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Doutor em Engenharia de Teleinformática. FORTALEZA.2021. |
| 3  | MELO, Emilson Richardson Rocha. Vite Das Coisas, Uma Solução Para Urgência e Emergência em Sistemas de Saúde. Dissertação (Mestrado Profissional em Computação Aplicada do Programa de Pós-graduação em Ciência da Computação do Centro de Ciências e Tecnologia), UECE (Universidade Estadual do Ceara), Fortaleza - Ceara, Brasil. 2017.                                            |
| 4  | SILVA, Kátia Cilene Neles da. Monitoramento da saúde humana através de sensores: análise de incertezas contextuais através da teoria de Dempster- Shafer / K.C.N. da Silva. -- ed.rev. -- São Paulo, 2013. 141 p. Tese (Doutorado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Computação e Sis- temas Digitais.                                 |
| 5  | OLIVEIRA, Ari Barreto de. Um módulo de protocolo para aplicações de IoT em saúde. 2020. 68f. Dissertação (Mestrado Profissional em Tecnologia da Informação) - Instituto Metrópole Digital, Universidade Federal do Rio Grande do Norte, Natal, 2020.                                                                                                                                 |
| 6  | VEIGA, Jeangrei Emanoelli. Um sistema d-Health para auxiliar na promoção de um estilo de vida saudável em hipertensos. 2017. 69 f. Dissertação (Mestrado em Computação Aplicada) - Universidade de Passo Fundo, Passo Fundo, 2017.                                                                                                                                                    |
| 7  | SANTOS, Zélia Maria de Sousa Araújo; FROTA, Mirna Albuquerque; CRUZ, Daniele Moraes; HOLANDA, Samanta Daisy O. Adesão do cliente hipertenso ao tratamento: análise com abordagem interdisciplinar, Fortaleza, 2005.                                                                                                                                                                   |
| 8  | BARROCA FILHO, I. M. Architectural design of IoT-based healthcare applications. 2018. 96 f. Tese (Doutorado em Ciência da Computação) - DIMAp, Universidade Federal do Rio Grande do Norte, Natal, 2018.                                                                                                                                                                              |
| 9  | VALTER, R.; OLIVEIRA, M.; SILVA, F. G. S.; ANDRADE, D. Intelligent Epidemiological Surveillance in the Brazilian Semiarid. 2020.                                                                                                                                                                                                                                                      |
| 10 | BARBOSA Vinícius; FERREIRA Helen; GOMES Leonardo; GOMES Fabio; BARRETO Ivana; MONTEIRO Odorico; OLIVEIRA, Mauro. SmartRES - Uma                                                                                                                                                                                                                                                       |

|           |                                                                                                                                                                                                                                                                                                                                                                                           |
|-----------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
|           | plataforma IoT para Monitoramento Inteligente em Saúde e sua Aplicação no Contexto da COVID-19 , Anais do Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS): 2020: Anais do XX Simpósio Brasileiro de Computação Aplicada à Saúde                                                                                                                                                |
| <b>11</b> | VALTER, R., SANTIAGO, S., RAMOS, R., OLIVEIRA, M., ANDRADE, L. O. M., and de HC Barreto, I. C. (2019). Data mining and risk analysis supporting decision in brazilian public health systems. In 2019 IEEE International Conference on E-health Networking, Application & Services (HealthCom), pages 1–6. IEEE                                                                            |
| <b>12</b> | JUNG, E.-Y. et al. Mobile healthcare application with EMR interoperability for diabetes patients. Cluster Computing, Sep. 2014. Volume 17, PP 871-880.                                                                                                                                                                                                                                    |
| <b>13</b> | JUNG, E.-Y. et al. Development of U-healthcare monitoring system based on context-aware for knowledge service. Multimedia Tools and Applications , April 2015. Volume 74, pp 2467-2482.                                                                                                                                                                                                   |
| <b>14</b> | BRAGA, Oton Crispim. Solução Inteligente Baseada em Aprendizado de Máquina para a Classificação de Doenças transmitidas pelo vetor Aedes Aegypti. Trabalho de Conclusão de Curso (TCC) apresentado ao curso de Bacharelado em Ciência da Computação do Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE - Campus Aracati. 2017                                         |
| <b>15</b> | SOUZA, Fabio. José. Gomes. de. Marcia, Uma metodologia para o manejo de registro clínico com uso de arquétipos para interoperabilidade em sistemas de saúde. Dissertação (Mestrado Profissional em Computação Aplicada do Programa de Pós-graduação em Ciência da Computação do Centro de Ciências e Tecnologia), UECE (Universidade Estadual do Ceará), Fortaleza - Ceara, Brasil. 2017. |

Fonte: Próprio autor.

O que se observou foi que nos trabalhos diretamente relacionados a temática em estudo, IoT, aprendizado de máquina são tratados de forma isolada, sendo cada um voltado a uma especificidade em estudo de caso, quando não voltados diretamente ao hipertenso. Assim, este estudo surgiu da necessidade e possibilidade de convergir IoT, Aprendizado de Máquina e Hipertensão ou outra comorbidade em uma plataforma já existente, agregando valor a arquitetura, no caso, do GISSA, em uma arquitetura ampliada.

### 3.1 Descrição dos trabalhos relacionados

**1. FREITAS(2021):** apresenta uma contribuição na área de e-health, mais especificamente dentro do escopo de cidades inteligentes, e utiliza, para isso, ferramentas de IoT e aplicação de aprendizado de máquina para prever casos de dengue em semanas do futuro. A cidade de Fortaleza (CE) foi utilizada como estudo de casos. Assim, como os estudos desenvolvidos por (TAVARES; RODRIGUES, 2018) (VALTER et al., 2020), o de Freitas

(2021) também tem correlações de variáveis meteorológicas com casos de dengue, e ambos utilizaram dados da capital cearense, mas, além do uso de ML para predição de casos de dengue, a nossa abordagem abrange a área de IoT na geração, na transferência e no armazenamento de dados, bem como a notificação de eventos utilizando um Middleware de IoT.

Freitas (2021) propõe uma integração entre uma estação meteorológica com sensores embarcados, um Middleware de IoT e uma aplicação Back-End, com o objetivo de prever casos de dengue que podem ocorrer. Um dispositivo físico é utilizado como estação meteorológica para enviar dados ao Middleware. O Middleware é utilizado para armazenar os dados coletados da estação meteorológica, disponibilizar de forma escalável esses dados, desencadear eventos e disparar notificações de previsões de casos de dengue. A aplicação é utilizada para tratar dados consumidos do Middleware e fazer predição de casos de dengue para a quinta semana à frente.

Os resultados obtidos com o funcionamento da arquitetura proposta no que diz respeito à coleta de dados e à predição de casos de dengue usando diferentes modelos de ML. Uma análise exploratória dos dados foi realizada com objetivo de selecionar variáveis relacionadas a casos de dengue para semanas futuras. Sua principal contribuição foi a integração entre uma aplicação back-end e um middleware de IoT. Durante a realização deste trabalho foi feito um estudo sobre os dados meteorológicos, populacionais e casos de dengue para a 1ª, 5ª, 10ª e 15ª semanas à frente. Foram selecionados os dados que apresentaram correlações mais fortes com o alvo, utilizando para isso o CCP. Uma comparação com modelos de aprendizado de máquina foi realizada com objetivo de selecionar entre todos um modelo que apresentasse os melhores resultados de assertividade. Levando em consideração o melhor modelo nos testes, foi possível prever casos de dengue para a 5ª semana no futuro com MAE de 105 e coeficiente de determinação  $R^2$  de 87. Outra comparação também foi feita com os modelos de ML. Desta vez, o objetivo foi observar o tempo que cada modelo leva para ser treinado. Foi observado que, com exceção das redes neurais, o modelo SVR levou mais tempo na fase de treino.

A plataforma de IoT dojot teve uma participação muito significativa no objetivo final deste trabalho. A dojot foi responsável pelo armazenamento, pela disponibilização dos dados e pela notificação de casos de dengue preditos. Com ela foi possível realizar todos os experimentos, sendo suficiente em desempenho, funcionalidades e baixo nível de aprendizagem para realização das tarefas. Para o envio dos dados, uma estação meteorológica foi simulada utilizando uma Raspberry Pi e os dados foram enviados via protocolo MQTT para a plataforma dojot. Os dados meteorológicos, juntamente com dados de agravo de casos de dengue, constituem o set de informações utilizado pelo modelo de ML selecionado.

## 2. COSTA FILHO (2021): Smart GISSA

O Smart GISSA é uma arquitetura construída a partir do sistema de Governança Inteligente em Sistemas de Saúde - GISSA<sup>24</sup>, uma solução inovadora na área de saúde já destacada neste trabalho. Esta solução fornece aos gestores, servidores e usuários governança inteligente ao promover a integração sistêmica das informações.

É válido ressaltar que a Associação das Empresas Brasileiras de Tecnologia da Informação (ASSESPRO) certificou a plataforma GISSA como detentora de tecnologia única na tomada de decisão em sistemas de saúde, uma vez que o desenvolvimento de um framework específico e a incorporação de Machine Learning ao GISSA, conferem ao mesmo fortes características de inovação e ineditismo em se tratando de plataformas para tomada de decisão em saúde.

Concebido em 2009 por dois pesquisadores em estágio pós-doutoral em saúde (UFC) e computação (IFCE) nas universidades de Montreal e Ottawa, respectivamente, o GISSA teve em sua evolução conceitual e tecnológica o envolvimento de pesquisadores da Fiocruz Ceará, Instituto Federal do Ceará e Universidade Federal do Ceará, tendo a modelagem e prototipação de seu framework desenvolvido pelo Instituto Atlântico (<https://www.atlantico.com.br/>), com o suporte financeiro da FINEP. Deste processo evolutivo institucional resultou o produto GISSA, comercializado desde 2015 pela empresa Avicena Software e Serviços Ltda (<https://avicena.in/>)


A plataforma GISSA tem passado por contínua evolução desde sua concepção, em 2009, como resultado de pesquisas, desenvolvimento e inovação. Desta forma, pesquisas tem sido incorporadas ao GISSA, notadamente no recente trabalho doutoral “Smart-GISSA” (COSTA FILHO, 2021).

A arquitetura do Smart GISSA (Figura 12) além de extrair, transformar e carregar os dados em dashboards, inclui modelos de aprendizado de máquina para especializar a tomada de decisão em saúde pública.

---

<sup>24</sup> O GISSA é uma plataforma de computação que realiza coleta automática das bases de dados do Sistema Único de Saúde (SUS): E-SUS, CNES, SIM, SINASC, SI-PNI, SINAN através de robôs extratores de dados, analisa essas informações utilizando diversas tecnologias inteligentes e transformando-os em informações integradas, úteis para tomada de decisão nos diversos níveis de gestão em saúde.


Figura 12 – Arquitetura do Smart GISSA



Fonte: VALTER *et al.*, 2020

Costa Filho (2021) utiliza um modelo arquitetural em camadas baseado na cadeia de captação, condicionamento, manutenção e disponibilização da informação para propiciar o surgimento de aplicações baseadas em aprendizado de máquina utilizando a abordagem de microserviços. Na Figura 13 consta aplicação do Smart GISSA.


Figura 13 – Aplicação do Smart GISSA



Fonte: VALTER *et al.*, 2020


O Smart GISSA propõe uma metodologia de mineração de dados no contexto da análise de Risco de morte (Figura 14), demonstrando-se por meio da implementação de dois micros serviços de análise de risco, o materna e o infantil. Ele também propõe um segundo padrão de processo para mineração de dados em saúde para criação de sistema de vigilância epidemiológica, especificamente para predição de epidemias.

Figura 14 – Metodologia DMRisD (Análise de Risco de Morte)



Fonte: VALTER *et al.*, 2020

Figura 15 – Metodologia DMEpi (Vigilância Epidemiológica)



Fonte: VALTER *et al.*, 2020

Como estudo de caso, para exemplificar a adoção das práticas preconizadas pela metodologia, foi construído um modelo de predição de epidemias de dengue para a cidade de Fortaleza (Ce) inferindo o número de casos de infecção na região metropolitana. Os resultados demonstraram ser possível detectar a tendência do número de novas infecções com um horizonte de previsão de 15 semanas.

Os modelos propostos podem ser adaptados a outros tipos de epidemia causada por arbovírus como febre chikungunya, febre amarela e Zica. Adicionalmente, o processo metodológico pode modelar matematicamente qualquer epidemia (tuberculose, cólera, COVID-19, etc.), bastando escolher variáveis suficientes que se correlacionem às condições de presença do vírus em circulação e contaminação da população.

Dentre as limitações da pesquisa desenvolvida o autor apontou:

Mesmo partindo do pressuposto de que modelos foram adequadamente implementados, ainda assim é possível que falhas de cômputo dos dados dos SIS (perda e/ou falhas de preenchimento de formulários) incorram em falsas análises. Ressalta-se, ainda, que os modelos gerados são dependentes da região onde serão aplicados. (COSTA FILHO, 2021).

Diante disto, o GISSA tem experimentado tecnologias inteligentes acompanhando a revolução científica tecnológica advindas do espaço global conectado em redes, com crescente simbiose da inteligência artificial e IoT. Neste contexto, surge como extensão e agregação de valor ao GISSA, o Sistema de monitoramento inteligente em saúde: NEXT-GISSA utilizando Internet das Coisas e aprendizado de máquina na predição de casos de Hipertensão Arterial na cidade de Fortaleza-Ceará, conforme será melhor explicado na seção 3 – Arquitetura Next –GISSA.

3. **MELO (2017)** apresenta o VITE das Coisas, uma solução inteligente constituída de hardware, software embarcado, servidor Web e aplicativo, para situações de urgência e emergência de pacientes acamados e em mobilidade.

Este estudo tem como objetivo Geral especificar e implementar uma solução de baixo custo, baseada em IoT, constituída de hardware, software embarcado, servidor Web e aplicações, para auxílio a pacientes acamados e pessoas em situações de urgência e emergência em mobilidade.

Neste trabalho é apresentado um protótipo como prova de conceito do uso de IoT em saúde, em que são implementadas partes da Arquitetura Health OpenIoT, em especial a aquisição de dados com sensores de sinais vitais, a reutilização de ontologias do OpenIoT no modelo de inteligência proposto, serviços de monitoramento e tomada de decisão implementados em servidor web e plataforma Android.

A principal contribuição deste trabalho consiste na especificação e implementação de uma solução de baixo custo, baseada em IoT, constituída de hardware, software embarcado, servidor Web e aplicações, para auxílio a pacientes acamados e pessoas em situações de urgência e emergência em mobilidade. Para tanto, esta solução segue um "approach" baseado na arquitetura Health OpenIoT (LOPES, 2017).

A arquitetura do sistema VITE das Coisas foi desenvolvida para fornecer modularização, escalabilidade e flexibilidade ao projeto. Tal arquitetura se divide em quatro camadas: Aquisição de dados, Persistência de dados/Modelagem, Processamento e Serviços.

O sistema VITE das Coisas é composto por um dispositivo de *Hardware* vestível com software embarcado, uma aplicação para *smartphone* e servidor Web de processamento e monitoramento. O VITE das Coisas é o sistema que reúne entre os estudados do estudo comparativo mais funcionalidades entre os sistemas destinados à assistência em saúde

O VITE das Coisas é parte do NextSAUDE (OLIVEIRA *et al.*, 2010), um projeto mais amplo da área de saúde que tem sua origem no LARIISA, uma plataforma inteligente para a tomada de decisão em sistemas de Saúde. Enquanto o projeto GISSA (OLIVEIRA *et al.*, 2009), também originário do LARIISA, tratou de problemas envolvendo o acesso a bancos de dados legados de sistemas públicos de saúde do DATASUS (SIM, SINASC, eSUS, etc.) para fornecimento de alertas e outras informações importantes para a tomada de decisão no âmbito da gestão integrada nos cinco domínios da saúde (clínico epidemiológico, normativo, administrativo, gestão do conhecimento, conhecimento compartilhado), o Next-GISSA focou a captura de informações em tempo real, associada mais diretamente a sinais vitais de pacientes.

Os dois cenários do NextSAÚDE, internação hospitalar e usuário em mobilidade, são atendidos pelos projetos TV Health das Coisas (LOPES, 2017) e VITE das Coisas, respectivamente. Ambos são suportados pela arquitetura Health OpenIoT, baseada na plataforma OpenIoT.

Enquanto o VITE das Coisas cumpre sua missão de coleta de dados via sensores de sinais vitais e equipamentos específicos associados ao paciente, o TV Health das Coisas se prestaria ao papel de "hub" de comunicação, uma espécie de "gateway" entre os dados captados pelos sensores (front-ends) e os sistemas finais (back-ends) onde estes dados seriam processados de forma inteligente para apoiar a tomada de decisão em vários níveis de granularidade.

Os sinais vitais coletados pelo VITE das Coisas, associados ao histórico do paciente e a sistemas inteligentes (data mining, por exemplo) poderia ativar alertas em *dashboards* em salas de situação, prevenindo situações crônicas e sequelas que possam comprometer a vida de

um paciente. Finalmente, há de se registrar a característica marcante do VITE das Coisas como uma tecnologia IoT. Mecanismos ainda não disponíveis, tais como “machine learning”, poderiam ser agregados que é o que se propõe no presente trabalho.

**4. SILVA (2013):** essa investigação apresenta uma arquitetura para assegurar o monitoramento remoto e contínuo de pacientes considerando a existência de restrições inerentes ao hardware de sensores. Segundo os autores, essa arquitetura poderá permitir que pacientes com doenças crônicas e ou em cuidados no pós-operatório sejam monitorados remotamente no conforto de seus lares. Aspectos relacionados à segurança e comunicação entre sensores também são discutidos.

O objetivo deste trabalho é apresentar um processo para a análise das incertezas contextuais presentes no monitoramento da saúde humana através de sensores. Três classes de incertezas contextuais foram especificadas: as incertezas provenientes da tecnologia empregada na transmissão dos dados capturados por sensores; as incertezas relacionadas aos próprios sensores, que estão sujeitos a erros e defeitos; e, as incertezas associadas à influência mútua entre as variáveis observadas. O método foi empregado a partir da realização de experimentos sobre arquivos com dados fisiológicos de pacientes reais, aos quais foram adicionados elementos comportamentais e ambientais. Como resultado, foi possível confirmar que o contexto influencia nos dados repassados pelo sistema de monitoramento, e que as incertezas contextuais podem influenciar na qualidade das informações fornecidas, devendo estas serem consideradas pelo especialista.

**5. OLIVEIRA (2020):** Esta dissertação teve como objetivo propor um módulo de protocolo que possa, através de dados oriundos de sensores de IoT em saúde, ajudar a equipe de saúde a obter informações úteis, trazendo, desta forma, benefícios diretos para a saúde do paciente e agilidade do atendimento hospitalar e redução de custos. Foi realizada a implementação de um Módulo de Protocolo e de um Módulo de Verificação, indicando possíveis benefícios da utilização de tal arquitetura no monitoramento da COVID-19.

**6. VEIGA (2017):** Este trabalho relata o desenvolvimento de um sistema e-Health denominado Sistema e-Lifestyle que tem como objetivo integrar e monitorar pacientes hipertensos a distância, permitindo a avaliação de risco e a mudança de comportamento. Foram utilizadas tecnologias como o desenvolvimento web e mobile, nuvem computacional, dispositivo móvel e vestível. O Sistema e-Lifestyle foi dividido em um sistema Web (Server Lifestyle) disponibilizado em nuvem computacional; um conjunto de interfaces Web (App Web) para interação do profissional da saúde e administrador e um aplicativo Android (App Lifestyle) para interação do paciente, incluindo a integração com um relógio inteligente

(Smartwatch) para o recebimento de alertas e confirmação de itens da agenda. O processo de desenvolvimento foi acompanhado por profissionais da saúde com o objetivo de garantir o funcionamento do sistema de acordo com o propósito inicial do projeto, de contribuir com os princípios da Medicina do Estilo de Vida. Ao final do processo de desenvolvimento da primeira versão do sistema foi realizado um estudo de caso a partir de uma entrevista semiestruturada com médico cardiologista de um Hospital da região sul do país. Como conclusão, o profissional apontou que o sistema está apto para a realização de testes com pacientes hipertensos, os quais serão realizados como trabalhos futuros.

**7. SANTOS; FROTA; CRUZ; HOLANDA (2005):** O objetivo deste estudo que resultou no artigo tendo como objeto de estudo o hipertenso foi analisar a adesão do cliente hipertenso ao tratamento com abordagem interdisciplinar. Foi desenvolvido com 50 clientes acompanhados na Liga de Hipertensão Arterial do Hospital de Messejana, em Fortaleza-Ceará. Os dados foram coletados através da entrevista. Na amostra investigada, somente 6 (12%) entrevistados revelaram algum conhecimento sobre a hipertensão arterial e 28 (56%) conheciam parcialmente as suas consequências. A adesão ao tratamento foi considerada insatisfatória, principalmente em relação às condutas higienodietéticas. A irregularidade no esquema medicamentoso esteve associada ao custo e aos efeitos colaterais. Os resultados demonstram a necessidade de atuação interdisciplinar da equipe de saúde, junto à clientela hipertensa, contribuindo para a adesão às condutas de manutenção e promoção da saúde.

**8. BARROCA FILHO (2018):** Para contribuir com a solução dos desafios supracitados, esta tese tem como objetivo melhorar a compreensão e sistematização da arquitetura de software das aplicações de saúde baseadas em IoT. Ela propõe uma arquitetura de referência de software, chamada Arquitetura de Referência para Aplicações de Cuidados de Saúde baseadas em IoT (RAH), para organizar sistematicamente os principais elementos dessas aplicações, suas responsabilidades e interações, promovendo uma compreensão comum da arquitetura dessas aplicações. Para estabelecer RAH, um mapeamento sistemático de publicações sobre aplicações de saúde baseadas em IoT foi realizado, bem como um estudo sobre atributos de qualidade, táticas, padrões arquiteturais e estilos usados na eng. de software.

Como resultado, RAH apresenta conhecimento de domínio e soluções de arquitetura de software (ou seja, padrões arquiteturais e táticas) documentado usando visões arquiteturais. Para avaliar a RAH, foi realizado um estudo de caso instanciando-a para projetar a arquitetura de software de uma plataforma computacional baseada na infraestrutura da

Internet das Coisas (IoT) para permitir monitoramento remoto inteligente dos dados de saúde do paciente (biometrias).

Com esta plataforma, a equipe clínica pode ser alertada dos eventos de saúde que requerem intervenção imediata e então evitar complicações indesejáveis. Os resultados evidenciaram que RAH é uma arquitetura de referência viável para o desenvolvimento de aplicações de saúde baseadas em IoT seguras, interoperáveis, disponíveis e eficientes, trazendo contribuições para as áreas de e-Health e arquitetura de software.

**9. VALTER ET AL. (2020):** apresentou uma proposta para um sistema de vigilância epidemiológica aplicado a arboviroses que está sendo utilizado em um projeto chamado GISSA TM Avicena (2021). A proposta apresenta um modelo de ML que é utilizado para prever quantitativamente o número de pessoas infectadas por arboviroses e para detectar epidemias causadas por *Aedes aegypti* (vetor para dengue, chikungunya, febre amarela e zika). O estudo foi realizado com dados da cidade de Fortaleza (CE) e algumas cidades do interior do Ceará.

**10. BARBOSA ET ALL (2020):** o SmartRES propõe uma plataforma inteligente de gestão em saúde, que permitirá a interoperabilidade de diferentes RES públicos e privados. Com o SmartRES as informações clínicas de um usuário poderão ser acessadas a qualquer hora e lugar. Serviços inteligentes do SmartRES poderão alertar o usuário na prevenção e predição de problemas clínicos a partir do cruzamento de seu histórico, com dados em tempo real. Finalmente, o trabalho apresenta o uso da plataforma SmartRES no contexto da COVID-19.

**11. VALTER ET ALL (2019):** Dados disponíveis em Bases de dados de saúde brasileira apontam que é possível prever risco de morte nas fases iniciais da gestação e desenvolvimento do recém-nascido. Nesta pesquisa, se considera a disponibilidade de informações ainda no período gestacional para propor diferentes predições de risco de morte modelos para este público de interesse. Também se detalhou a mineração de dados processo para aplicar técnicas baseadas em aprendizado de máquina na morte classificação de risco para pacientes maternos, neonatais e infantis. Foi apresentado um pipeline de experimentos para estimar o desempenho médio e avaliou modelos de aprendizado de máquina com diferentes combinações de recursos. Além disso, é mostrado um serviço web que fornece vários modelos preditivos por disponibilidade de informações. Os resultados mostram Random Forest obtendo melhor desempenho quando em comparação com os outros métodos de aprendizado de máquina.

12. **JUNG (2014):** Um aplicativo de saúde móvel para sistema operacional Android foi desenvolvido para fornecer gerenciamento de autodiabetes. O aplicativo consiste em gerenciamento de diabetes, controle de peso, avaliação de risco cardio-cerebrovascular, avaliação de estresse e depressão e gerenciamento de exercícios. O aplicativo sincroniza os dados com o banco de dados EMR do hospital para fornecer dados precisos com processo minimizado de entrada de dados. Este artigo apresenta a estrutura e funcionalidades detalhadas do aplicativo com aspecto de sincronização de dados EMR.

13. **JUNG (2015):** Com o desenvolvimento da TI, o aumento do número de pacientes hipertensos provocou um aumento no número de serviços que oferecem monitoramento e análise inteligente, independentemente da localização do paciente. Este trabalho desenvolve um sistema de monitoramento u-healthcare que oferece um serviço de alarme para medição e notificação em caso de níveis incomuns de indicadores de pacientes, com base nos dados de biossinal do usuário e sensível ao contexto. Este sistema fornece um valor de medição mais preciso do que os serviços de monitoramento anteriores, pois considera a condição de cada usuário e, portanto, pode reduzir os riscos à saúde do usuário, usando os valores de gerenciamento de vida do paciente e de medição de estilo de vida. Isso permite a prestação de serviços precisos e específicos, e mais personalizados para cada usuário. Ele também inclui um terminal de usuário portátil para aumentar a precisão do reconhecimento de contexto e aumentar a conveniência do usuário.

14. **BRAGA, Oton Crispim (2017):** Este trabalho propõe uma solução inteligente baseada em classificadores como mecanismo de inferência, capaz de auxiliar profissionais de saúde durante o processo de manejo clínico das doenças transmitidas pelo mosquito *Aedes Aegypti*, identificando qual o provável diagnóstico baseado em sintomas e resultado de exames. Dividiu-se o trabalho em dois passos: um voltado para o pré-diagnóstico, considerando sintomas e histórico clínico, anamnese; e outro focado no diagnóstico final, considerando também resultado de exames específicos, como exames de sorologia. O estudo utiliza uma metodologia baseada na Mineração de Dados para extração de conhecimento numa base de exemplos. Após diversos testes e ajustamentos em algoritmos de aprendizado de máquina, pôde-se definir dois modelos de aprendizado capazes de inferir a probabilidade de um paciente estar infectado com uma determinada doença, tendo precisão de até 91, 6%. A partir desses modelos, pôde-se construir uma API inteligente de apoio a tomada de decisão durante o manejo clínico de dengue e chikungunya. A solução permite que diversas aplicações acessem os modelos de aprendizado. Entre elas um aplicativo móvel de consulta popular para identificação

de dengue e chikungunya, o MARCIA, sistema interoperável de manejo clínico de chikungunya.

15. **SOUZA (2017):** Este trabalho apresenta um estudo de caso de interoperabilidade, na qual propõe o sistema MARCIA (Manejo de Registro Clínico Aplicado) para registrar e acompanhar o manejo clínica da chikungunya na UBS, auxiliando profissionais da atenção básica na melhoria do atendimento. Este sistema foi construído seguindo a especificação do padrão OpenEHR que usa arquétipos e templates para representar dados clínicos. Este padrão foi adotado pelo Ministério da Saúde, através da portaria 2.073/2011, como modelo de referência para Registro Eletrônico de Saúde (RES). Durante a etapa de desenvolvimento do MARCIA foi proposta uma metodologia, usando o framework EHRServer. Na fase de escolha de arquétipos para compor a template do sistema, foi desenvolvido o arquétipo que representa o hemograma e sorologia do resultado de um exame laboratorial e compartilhado no CKM (Clinical Knowledge Manager). Em seguida, a template do manejo clínico da chikungunya foi gerada e também compartilhada no CKM. Finalmente, o sistema foi construído usando o framework grails. As informações colhidas no processo de manejo no MARCIA são enviadas, em tempo real, para serem compiladas por um outro sistema de informação epidemiológica (denominado DENGOSA) na Secretaria Municipal de Saúde (SMS), auxiliando profissionais e gestores de saúde no apoio a tomada de decisão. Portanto, o objetivo geral deste trabalho é otimizar o processo de registro, acompanhamento e notificação através de sistemas de informações para auxiliar profissionais e gestores de saúde nos cuidados de saúde e controle da epidemia chikungunya. Este modelo está sendo implantado como projeto piloto em uma UBS na Secretaria Municipal de Saúde do Município de Aracati-CE.

#### **4. RESULTADOS: Next-GISSA**

Neste trabalho, como extensão e agregação de valor à plataforma GISSA, é proposta a arquitetura conceitual do Next-GISSA, um sistema que utiliza Internet das Coisas (IoT) e Sistemas Inteligentes (Ontologias e Aprendizagem de Máquina) no monitoramento e predição de casos de Hipertensão Arterial (HA) de pacientes do GISSA, em Fortaleza-Ceará.

Para a coleta de sinais vitais do paciente, o Next-GISSA sugere uso da plataforma “dojot”, uma solução criada pelo Centro de Pesquisa e Desenvolvimento em Telecomunicações (CPQD) com o objetivo de acelerar o desenvolvimento de aplicações IoT.

Para o contexto da predição da HA, esta pesquisa investiga soluções inteligentes disponíveis que melhor atendam aos requisitos clínicos do caso, desde os clássicos algoritmos de Aprendizado de Máquina (AM) ao Raciocínio Não-Monotônico amparados por ontologias

no auxílio aos processos cognitivos desenvolvidos na tomada de decisão, como mostrado no item 4.2. Esta análise se fez necessária devido, principalmente, a complexidade do cenário em estudo que envolve o cruzamento de dados on-line (sinais vitais) com o histórico clínico (off-line) do paciente.


Em consequência, é proposto um sistema híbrido para o Next-GISSA. Este cruzamento de dados acima descrito serve como um dispositivo de “gatilho”, baseado em conhecimento explícito (regras definidas por um especialista), no acionamento de um “bot” a dialogar com o paciente. Como discutido a seguir, deste diálogo, contextualizado também no histórico do paciente, ter-se-á atributos necessários para alimentar algoritmos supervisionados de aprendizagem de máquina (KNN, NaiveBayes, SVM, redes neurais etc.) na predição da HA.

Assim, a etapa seguinte do Next-GISSA é a predição que começa com a estratificação da situação clínica do paciente, a partir do resultado desses cruzamentos em: risco Baixo, risco Médio e risco Alto. Em resumo, o Next-GISSA amplia o leque de funcionalidades do GISSA ao incluir um módulo inteligente de monitoramento e predição de HA, além de inaugurar o uso da tecnologia IoT na plataforma.

#### 4.1 Cenário de aplicação do Next-GISSA

Com o objetivo de facilitar a compreensão do que é proposto pelo Next-GISSA, a Figura 16 apresenta um cenário hipotético de aplicação para os casos de pacientes do GISSA diagnosticados com hipertensão arterial.


Figura 16 – Cenário hipotético de aplicação do Next-GISSA



Fonte: Próprio autor.

Na sequência a Figura 17 apresenta o detalhamento do Fluxo no Cenário de aplicação do Next-GISSA.

Figura 17 – Detalhamento do Fluxo no Cenário de aplicação do NextGISSA.



Fonte: Próprio autor.

### **Passo 1 – Paciente em consulta médica é diagnosticado com Hipertensão Arterial (HA).**

**Contexto:** Essa condição do paciente como hipertenso é registrada em seu cadastro do Registro Eletrônico de Saúde (RES) do GISSA, onde se encontra o seu histórico clínico. Como já comentado, o RES consiste em um ou mais repositórios de informações relevantes sobre a saúde e bem-estar do paciente. O acesso à informação deverá sempre ser feito de forma segura e disponível para múltiplos usuários autorizados e apenas para eles. A informação de saúde está representada de acordo com modelos lógicos padronizados, definidos e/ou selecionados entre os existentes.

**Ação:** o paciente recebe uma pulseira com sensores capazes de coletar seus sinais vitais como: pressão arterial, frequência cardíaca, Saturação de oxigênio no sangue – SPO2 e temperatura.

### **Passo 2 – O sistema Next-GISSA tem acesso ao RES do paciente no GISSA.**

**Contexto:** Uma vez diagnosticado como hipertenso, este paciente passa a ser monitorado de forma diferenciada pelo sistema GISSA, sendo agora objeto de cuidados do Next-GISSA. Para tanto, uma plataforma em nuvem por meio de uma conexão direta com um servidor back-end, utilizando API com arquitetura REST, será responsável por obter informações do histórico clínico do paciente, disponibilizadas no RES do GISSA.

**Ação:** Criação de um novo modelo de dados pelo Next-GISSA, específico para o paciente em questão, contendo informações pertinentes do histórico clínico (off-line). Essas informações

são enviadas ao componente CloudNEXT do Next-GISSA que também receberá informações em tempo real (on-line), sinais vitais no próximo passo, a serem usadas no processo de predição.

### **Passo 3 – A aplicação mobileNEXT coleta sinais vitais do paciente**


Contexto: Após ser objeto de monitoramento no Next-GISSA, o paciente passa a ter os seus sinais vitais (pressão arterial, frequência cardíaca, Saturação de oxigênio no sangue – SPO2 e temperatura), coletados via sensores acoplados a uma pulseira (Passo 1), tratados pelo aplicativo mobileNEXT.

Ação: a aplicação mobileNEXT coleta os sinais vitais e os envia para o componente CloudNext onde já se encontram os dados do histórico clínico dos pacientes obtidos no RES (Passo 2).

### **Passo 4 – O Módulo de Inferências recebe dados on-line e off-line.**

Contexto: este é o componente mais complexo do Next-GISSA. O tratamento e análise dos dados off-line (histórico clínico) e on-line (sinais vitais) são feitos pelo Módulo de Inferências que faz uso do módulo “Ontologia Domínio de Risco”, como mostrado pela Figura 27. Este módulo serve como um dispositivo de “gatilho”, baseado em conhecimento explícito (regras definidas por um especialista), no acionamento ou não de um “chat bot” a dialogar com o paciente, caso se configure como uma anormalidade o estado do paciente. Deste diálogo, contextualizado também no histórico do paciente, ter-se-iam atributos necessários para alimentar algoritmos supervisionados de aprendizagem de máquina na predição da HA (Figura 18). Em casos mais graves no estado de saúde do paciente esse módulo poderá acionar a sala de situação sem passar pelo módulo de Machine Learning.

Figura 18 – Contribuição: Arquitetura, IoT, Ontologia e Aprendizado de Máquina.



Fonte: Próprio autor

Os módulos Ontologia domínio de Risco e Chat Bot são inovações advindas desta pesquisa ao GISSA, que por sua vez nunca operou em tempo real na coleta de dados, os sinais vitais do paciente em tempo real nunca foram levados em consideração, pois sempre se buscou

essas informações em bases de dados para serem mostradas em um dashboard, ou seja, esta pesquisa está inovando no GISSA à medida que leva em consideração os sinais vitais do paciente em tempo real.

Com os sinais vitais em tempo real e levando em consideração o histórico do paciente, os dados coletados podem representar risco ou não atinente ao paciente com algum tipo de comorbidade, sendo necessário uma avaliação feita por um médico. Como não se tem um médico ou enfermeira disponível para cada paciente, a solução nesse caso, será a utilização de um mecanismo inteligente capaz de cruzar as informações coletadas do histórico do paciente com os sinais vitais para acionar um sistema de alarme. Para isso foi idealizado os seguintes mecanismos: Ontologia de domínio de Risco e Chat Bot.

A opção por uma Ontologia de Domínio de Risco se deve ao fato de nessa fase preliminar no momento que se obtém a heurística vindo de regras dos especialistas é possível criar uma ontologia que representa o conhecimento desse especialista (médico) e essa ontologia será capaz de inferir se aqueles dados vindos do paciente podem ser ou não um indício de que aquele paciente merece ser monitorado. Seria um filtro largo pois muitas coisas passam e para poder refinar essas informações surgiu a ideia de colocar um chat bot. E qual é a ideia desse bot? Essa ontologia indica que aquele paciente poderá estar em risco e ao invés de já acionar o sistema de alarme, o “chat bot” vai fazer algumas perguntas porque antes de utilizar o mecanismo clássico de aprendizado de máquina visto que os sinais vitais não são suficientes para se poder tomar decisões, então essas perguntas do Chatbot, e, evidentemente, as informações coletadas a partir daí ao paciente, irão ajudar os especialistas na sala de decisão de modo a ser realizada uma melhor avaliação.

Já o mecanismo de aprendizagem de máquina vai pegar o histórico do paciente, os sinais vitais, essas respostas às perguntas do Chat bot e agora sim se terá um ambiente mais rico de informações para poder então tomar a melhor decisão. Então a decisão de realmente fazer uma análise de risco passou por 2 filtros, o primeiro filtro foi a ontologia de domínio que só dispara o “chat bot” se achar que o paciente é candidato, depois aumenta o universo de perguntas para um mecanismo inteligente decidir se para aquele paciente se deve:

1. Enviar uma ambulância;
2. Avisar a família;
3. Orientar o paciente a buscar uma unidade de saúde ou médico o mais breve possível;
4. Acionar outro Chatbot que vai orientar o paciente.

Ação: o módulo “Ontologia Domínio de Risco” dispara a ação do “chat bot” (caso constata uma anormalidade nos dados cruzados). O módulo “Bloco de Inferências” realiza uma espécie de

pré-processamento de dados na preparação dos atributos para alimentar o módulo “Mecanismo de Aprendizado de Máquinas”, levando em consideração o histórico do paciente. A partir daí, é possível ao módulo de Machine Learning classificar o risco desse paciente: Baixo, Médio ou Alto.

### **Passo 5 – Uso do “Chat Bot”**

Contexto: O cruzamento de dados ocorrido no item 4 serve como um dispositivo de “gatilho”, baseado em conhecimento explícito (regras definidas por um especialista), no acionamento de um “Chat Bot” a dialogar com o paciente.

Ação: Deste diálogo, contextualizado também no histórico do paciente, ter-se-iam atributos necessários para alimentar algoritmos supervisionados de AM na predição da HA.

### **Passo 6 – Cenários possíveis**

Contexto: Como resultado da ação do módulo de Machine Learning, o nível de risco da paciente será classificado em Alto, Médio ou Baixo.

Ação: Conforme o resultado da classificação do módulo de Machine Learning, serão tomadas as respectivas providências, como mostrado nas Figuras 18 e 19.

### **Passo 7 – Procedimentos na Sala de Situação do Next-GISSA**

Contexto: uma vez concluída a avaliação do paciente pelo módulo de Machine Learning, as ações a serem tomadas pelo Next-GISSA dependerão, obviamente, do grau de risco detectado.

Ações: Seguem os três tipos de riscos e respectivos procedimentos do Next-GISSA.

**Risco Baixo:** O sistema automaticamente conectará o paciente com “bots assistentes” que poderão enviar-lhe alertas e recomendações sistematicamente ou, eventualmente, responder perguntas do paciente.

**Risco Médio:** A partir deste nível de avaliação do módulo de Machine Learning, o paciente passa a ser monitorado por um “assistente humano” capaz de avaliar com maior acurácia aspectos não apenas clínicos (sinais vitais, por ex.) como psicológicos (ansiedade, stress, por ex.) e pessoais (idade, mobilidade, por ex.) do paciente em foco. As ações neste nível vão desde reclassificar o caso para risco Baixo ou para risco Alto, ou ainda mandar alerta e/ou mensagens para o paciente com orientações do tipo: ficar próximo de farmácia, não se afastar de regiões longe de hospitais, não esquecer determinados medicamentos, por ex.

**Risco Alto:** Este nível aciona imediatamente um alerta de emergência na Sala de Situação requerendo a presença de uma equipe de especialistas humanos de plantão na unidade de atendimento. Esta equipe deverá iniciar uma série de procedimentos de rotina médica compatível com o caso (enviar ambulância ao local, comunicação com a família, por ex.)

#### **Passo 8 – Reavaliação do Paciente**

Contexto: O procedimento lógico que suporta essa reavaliação do paciente pelo sistema Next-GISSA será o mesmo utilizado desde o início do cenário mostrado na Figura 21, agora enriquecido em um novo histórico do paciente.

Ação: Em caso de riscos Alto e Médio, o paciente será reavaliado em intervalo regulares pela equipe médica com o objetivo de checar seu estado de saúde e reavaliar o risco associado. Sua evolução temporal será registrada no sistema.

#### **Passo 9 – Diminuição do Número de Infartos**

O principal objetivo do Next-GISSA é a diminuição do número de casos de infartos dos usuários da plataforma GISSA. Neste passo observa-se a melhoria dos processos desde estatísticas dos resultados obtidos, otimizando a ação de cada componente tanto tecnologicamente quanto processual.

### **4.2 Metodologia para a Integração da Ontologia de Risco do Next-GISSA**

O módulo “Ontologia Domínio de Risco” do módulo de Inferências do Next-GISSA é capaz de inferir, a partir de raciocinadores, se o chatbot será acionado ou não a partir dos dados integrados. Para a sua concepção, será necessário primeiramente decidir-se sobre uma metodologia para o seu desenvolvimento. Optou-se pelo modelo baseado em ontologias e Linked Data Mashup que integra bases de dados distintas e heterogêneas do SUS utilizada no estudo de Freitas et al (2017) que teve como base a metodologia desenvolvida em Lopes et al (2016).

Serão definidas questões para delimitação do escopo da ontologia proposta. Ou seja, essas questões devem ser usadas para descobrir os requisitos da ontologia. Esses requisitos referem-se ao conhecimento a ser representado pela ontologia. Ao final do levantamento dos requisitos, deve-se ter todos os conceitos, propriedades e seus relacionamentos para criar a ontologia.

Para formular e responder a estas questões serão feitas entrevistas com os médicos tendo como parâmetro inicial a identificação de cinco sinais vitais, quais sejam: Frequência cardíaca, pressão arterial, frequência respiratória, temperatura e saturação de oxigênio.

A seguir, alguns exemplos ilustram estas questões em que se baseará a Ontologia de Domínio de Risco:

1. Que sinais humanos que são classificados na literatura médica como sinais vitais no contexto da HA?
2. Para classificar como normal ou anormal cada sinal vital identificado, quais seriam as faixas de valores?
3. Seria possível determinar faixas de valores personalizadas para cada sinal vital de um indivíduo?
4. Quais são as medições de sinal vital de um paciente em um período de tempo?
5. Qual foi o instante de tempo que um paciente teve uma medição de sinal vital fora da sua normalidade?

Assim, para cada sinal vital serão coletados valores de referência utilizados pela comunidade médica. A tabela 7 mostra os valores de pressão arterial sistólica e pressão diastólica para os estágios de hipertensão arterial.

Tabela 7 – Classificação da Pressão Arterial segundo a Sociedade Brasileira de Cardiologia.

| <b>Classificação</b>          | <b>Pressão sistólica (mmHg)</b> | <b>Pressão diastólica(mmHg)</b> |
|-------------------------------|---------------------------------|---------------------------------|
| Normal                        | < 120                           | <= 80                           |
| Pré-hipertensão               | 121-139                         | 81-89                           |
| Hipertensão estágio 1         | 140-159                         | 90-99                           |
| Hipertensão estágio 2         | 160-179                         | 100-109                         |
| Hipertensão estágio 3         | >=180                           | >= 110                          |
| Hipertensão sistólica isolada | >=140                           | < 90                            |


Fonte: Sociedade Brasileira de Cardiologia. Arquivos Brasileiros de Cardiologia. ISSN-0066-782X. Volume 107, Nº 3, Suppl. 3, September 2016.

A construção do modelo proposto para o módulo Ontologia de Domínio de Risco no Next-GISSA será adaptada da arquitetura utilizada em (FREITAS et al, 2017).

### 4.3 Arquitetura do Next-GISSA

O principal objetivo do Next-GISSA é a ampliação da arquitetura do GISSA com agregação de novas funcionalidades baseadas em IoT, Ontologia de Risco e Aprendizado de Máquina, no contexto da HA, como mostrado na Figura 19 (O módulo IoT/IA).

Figura 19 – Agregação do Next-GISSA à arquitetura GISSA



Fonte: VALTER et al., 2020 modificado pelo Autor.


Já a Figura 20 apresenta a arquitetura funcional do Módulo Next-GISSA.

A seguir, são descritas as funcionalidades das camadas desta arquitetura:

Para aquisição de dados dos sensores será utilizado o protocolo MQTT para comunicação com o middleware dojot que possui um broker MQTT. Esta camada irá permitir a integração dos sensores.

- **Módulo Sensores** – O paciente do Next-GISSA será monitorado por meio de sensores para obtenção de quatro sinais vitais: pressão arterial, frequência cardíaca, oxigenação e temperatura. Esses dados serão coletados em tempo real por uma pulseira e enviados para a aplicação mobileNEXT (Módulo Serviços), para serem visualizados pelo paciente em um dashboard.

Figura 20 – Arquitetura Funcional do Next-GISSA



Fonte: Próprio autor

- **Módulo Obter Dados** - O RES é um repositório de informações processáveis sobre o cuidado em saúde do indivíduo, armazenadas e transmitidas de forma segura e acessível por múltiplos usuários autorizados. Seu objetivo é oferecer apoio a cuidados de saúde de qualidade, eficazes, eficientes, efetivos, seguros e integrados, ao longo de toda a vida do paciente [Atenção à Saúde 2015]. Assim, o componente RES no Next-GISSA irá funcionar como um sistema completo para registro de todas as etapas de atendimento de pacientes, que permite a criação de um arquivo do histórico clínico. Quando utilizado de forma correta, um RES pode diminuir consideravelmente a incidência de erros médicos, sobretudo nos casos em que os pacientes migram de um profissional para outro.
- **Módulo Nível de Risco** - O componente cloudNEXT será responsável pelo cruzamento dos dados do RES do paciente e dos seus dados coletados em tempo real pelos sensores (Módulo Sensores). Assim, será possível analisar qual o nível de risco desse paciente através da predição (padrões apreendidos). Para classificar o nível de risco (Módulo Nível de Risco) o Next-GISSA possui três níveis:
  - **Normal:** Indica situação estável. Os dados do paciente serão enviados para

aplicação Back-End e também salvos na aplicação mobileNEXT. As ações decorrentes desta classificação junto ao paciente são realizadas por “bots assistentes”;

- **risco Baixo:** Envia alerta ao paciente, via o mobileNEXT. Os dados do paciente serão enviados para aplicação Back-End e também salvos na aplicação mobileNEXT. As ações decorrentes desta classificação junto ao paciente também são realizadas por “bots assistentes”;
- **risco Médio:** Primeiro será feita uma análise por uma equipe de saúde humana. Os dados do paciente serão enviados para aplicação Back-End e também salvos na aplicação mobileNEXT. Assim, todas as análises preventivas e ações reativas decorrentes desta classificação junto ao paciente também são realizadas por um assistente humano.
- **risco Alto:** Considerado como situação crítica, necessitando de procedimentos imediatos, sendo acionado contatos de urgência (médicos, familiares), envio de ambulância ao local, se necessário, após avaliação médica, conforme melhor explicado no item Cenários do Next-GISSA (item 4.1)
- **A plataforma dojot** - Esta plataforma foi escolhida para uso nessa arquitetura por permitir e facilitar o desenvolvimento de soluções IoT. No Next-GISSA ela é responsável por armazenamento dos dados com sinais vitais coletadas do usuário por sensores em um único domínio facilitando a coleta, consulta e integração com outras plataformas por meio do módulo *Flowbroker*. No caso, as informações enviadas a plataforma dojot são originadas de sensores presentes em uma pulseira utilizada pelos usuários que são acompanhados pelo sistema NEXT-GISSA e são enviadas via protocolo MQTT. Esses dados contêm informações como temperatura, pulso, respiração e pressão arterial dos usuários que serão organizados por data e enviados para aplicação NextRES (*Back-End*) via requisição HTTP. Os dados de sinais vitais do usuário são enviados no formato Json.

Na Figura 20 observa-se ainda as fontes de dados obtidas a partir de sensores e da base de dados do GISSA, além dos serviços como tratamento de dados, servidor Back-End e cloudNext. No tocante a interoperabilidade da comunicação do Next-GISSA com sistemas externos, ela será feita via HTTP usando tecnologia RESTful para formalizar as rotas das requisições e a disponibilização das informações.

O Next-GISSA também comporta uma Sala de Situação, conforme descrita nos Cenários (item 4.1) necessárias às ações a serem tomadas, nos casos de Médio e Alto riscos.

#### 4.4 Requisitos funcionais e requisitos não funcionais

Os requisitos funcionais e não funcionais do sistema Next-GISSA foram descritos a partir de reuniões e observações realizadas durante a concepção do projeto. Isso possibilitou a criação de um documento de requisitos.

Tabela 8– Requisitos Funcionais do NEXT-GISSA

| CÓDIGO | REQUISITOS FUNCIONAIS                                                              |
|--------|------------------------------------------------------------------------------------|
| RF1    | O sistema deverá estabelecer a conexão com o sistema local.                        |
| RF2    | O sistema deverá estabelecer conexão com a base de dados remota.                   |
| RF3    | O sistema deverá selecionar a base de dados do GISSA.                              |
| RF4    | O sistema deverá selecionar tabela RES.                                            |
| RF5    | O sistema deverá obter dados dos pacientes hipertensos.                            |
| RF6    | O sistema deverá gerar modelo de banco de dados.                                   |
| RF7    | O sistema deverá inserir informações dos pacientes hipertensos no modelo de dados. |
| RF8    | O sistema deverá editar informações do paciente no modelo de dados.                |
| RF9    | O sistema deverá excluir informações do paciente no modelo de dados.               |
| RF10   | O sistema deverá listar informações do paciente do modelo de dados.                |

Fonte: Próprio autor.


Tabela 9 – Requisitos Não Funcionais do NEXT-GISSA

| CÓDIGO | REQUISITOS NÃO FUNCIONAIS                                                                                                               |
|--------|-----------------------------------------------------------------------------------------------------------------------------------------|
| RNF1   | O sistema deverá funcionar com versões modernas dos principais navegadores: Google Chrome, Mozilla Firefox, Internet Explorer e Safari. |
| RNF2   | O sistema deverá oferecer uma interface gráfica que facilita a usabilidade.                                                             |
| RNF3   | O sistema deverá manter a segurança das informações enviadas/recebidas usando a tecnologia Rest.                                        |
| RNF4   | O sistema deverá funcionar em ambientes da Web nos sistemas operacionais Windows e Linux                                                |
| RNF5   | O sistema deverá ser desenvolvido baseado na arquitetura cliente-servidor.                                                              |

Fonte: Próprio autor.

Na Figura 21 se observa o escopo de funcionamento do Next-GISSA onde se percebe as interações do sistema Next-GISSA com outros atores envolvidos no compartilhamento de informações entre os sistemas.


Figura 21 – Escopo de funcionamento do Next-GISSA



Fonte: Próprio autor.

Na Figura 22 o diagrama de caso de uso do Next-GISSA descreve outras funcionalidades do sistema e suas interações com o paciente, assim como suas atuações dentro do sistema. O termo <<extend>> significa que a busca, a listagem, a visualização de pacientes será feita de acordo com a inclusão de dados na tabela criada no modelo de dados quando acessa a base de dados do GISSA de forma remota. Já o termo <<include>> significa que só será gerado o relatório se o paciente foi cadastrado.

Figura 22 – Diagrama de caso de uso do Next-GISSA




Fonte: Próprio autor.

#### 4.5 Especificação do processo de Mineração de Dados do Next-GISSA

O presente estudo utiliza-se da metodologia de Reconhecimento de Padrões e Aprendizagem de Máquina que foi desenvolvida pelo Laboratório Centauro da UFC (Universidade Federal do Ceará). Seu objetivo é selecionar os melhores algoritmos de aprendizagem de máquina de acordo com o contexto do problema onde se pretende buscar o melhor modelo preditivo, como mostra a Figura 23.

Figura 23 – Metodologia de Reconhecimento de Padrões



Fonte: (RAMOS *et al.* 2016)

### Prospecção inicial

Utilizando a metodologia da Figura 23 foi decidido analisar os casos de hipertensão arterial baseando-se em dados do GISSA (Histórico do paciente) com dados coletados em tempo real (dispositivo IoT).

### Seleção inicial

Nessa etapa são selecionadas as ferramentas e os algoritmos que serão utilizados durante o processo de Mineração de dados. Para composição da aplicação Back-End serão incluídas tecnologias como a linguagem de programação Python 3.8, módulos Python como Pandas e Numpy para tratamento de dados e Keras, TensorFlow, Flask e Sklearn para aprendizado de máquina. Para tarefa de Mineração de dados foi decidido utilizar a classificação, pois o objetivo é prever o risco do paciente sofrer algum tipo de problema com pressão arterial elevada. Como exemplos de algoritmos que poderão ser utilizados na implementação da arquitetura podem ser citados:

- Floresta Aleatória - Randon Forest (BREIMAN, 2001)
- Árvore de Decisão - Decision Tree (Breiman et al. 1984)
- Support Vector Machine (SVM) - (Moe, Z. H. et al., 2018)
- Naive Bayes – (Moe, Z. H. et al., 2018)

## **Preparação dos Dados**

Para essa etapa serão selecionados dados do GISSA e dados do dispositivo IoT de pacientes classificados no GISSA como hipertensos. Dados vindos do dispositivo IoT precisarão de tratamento das informações antes que sejam enviadas para camada superior.

## **Transformações dos Dados**

Essa etapa envolve a configuração do recebimento de dados de diferentes fontes, dos sensores IoT em diferentes formatos. O principal objetivo é que a aquisição dos dados seja feita de modo a permitir que a ferramenta de Mineração de Dados a ser utilizada possa receber esses dados já tratados para processar.

As modificações dos dados serão necessárias pois dados vindos do dojot estão no formato JSON, e os dados a serem enviados para a ferramenta de predição utiliza o Comma-Separated Values (CSV).

Foram selecionados os seguintes sinais vitais: Pressão Sistólica(mmHg), Pressão Diastólica(mmHg), Frequência Cardíaca, Saturação de oxigênio, temperatura, peso(kg), além de outros dados tais quais data de nascimento, sexo, data da visita, local de nascimento.

Com acesso aos dados históricos do paciente se pode treinar um algoritmo, e conceber modelos matemáticos que definam risco de hipertensão arterial no indivíduo e depois apresentar novos dados onde serão extraídos desse modelo as previsões de risco de morte para esse paciente.

## **Experimento I**

Nessa etapa serão aplicados os algoritmos de Aprendizagem de Máquina na base de dados que será construída.

## **Ganhadora**

Essa etapa será responsável por selecionar o algoritmo de classificação que conseguiu atingir os melhores resultados durante todo o processo de Aprendizagem de Máquina.

## Construção

Nessa etapa será construída um sistema contendo a solução para o problema proposto inicialmente. Serão feitas análises dos resultados que guiarão a melhor escolha do algoritmo de classificação que tenha apresentado mais eficiência para o problema apresentado. Partindo de um processo de análise e comparação dos algoritmos será escolhido o melhor algoritmo que se adaptar aos dados.


### 4.6 Aspectos de implementação do Protótipo Next-GISSA

O Protótipo Next-GISSA consiste de quatro implementações: duas em desenvolvimento (Machine Learning e Ontologia de Risco) a serem integradas e adaptadas a duas existentes (plataforma IoT dojot e chatbot Gissa).

Na Figura 24 vemos desde os módulos sensores de sinais vitais do usuário, conectados à aplicação mobileNext, ao módulo cloudNEXT que finaliza a funcionalidade master do Next-GISSA: nível de risco do paciente. Nela é mostrada apenas a sequência temporal de acionamento deles (não são mostradas as interações entre os módulos).

Como comentado, o módulo Ontologia de Risco usa heurísticas para ativar (ou não) um “bot” a partir dos sinais vitais coletados do paciente (via plataforma dojot) e de seu histórico clínico. Uma vez ativado, o “bot” obtém informações contextuais do paciente de forma a parametrizar o mecanismo de AM, treinado para tarefa de determinar o Nível de Risco do paciente em relação a HA.

Figura 24 – Protótipo Arquitetura do NextGISSA




Fonte: Próprio autor.

## 1. Sobre a Aplicação Next-GISSA

Na Figura 25 percebe-se a aplicação do protótipo, sendo implementada, que será disponibilizada ao usuário Next-GISSA.

Figura 25 – Arquitetura da Aplicação (Protótipo)



Fonte: Próprio autor.

1 – Interface onde serão visualizadas informações relativas ao paciente. Após o sistema obter informações do GISSA e também dos sensores que captura os dados do paciente

em tempo real, essas informações disponibilizadas serão utilizadas por um modelo matemático para classificar cada novo paciente inserido na base de dados.


2 – Módulo inteligente que fará uso de alguns algoritmos que foram treinados a partir da base de dados a ser utilizada neste trabalho. Após treinamento será gerado um modelo que irá prever os casos de pressão arterial alta em pacientes classificados no GISSA como hipertensos.

3 – Tela de resultado para o risco do paciente está sofrendo alguma intercorrência de risco\_Alto

## 2. Sobre o módulo Ontologia de Risco

A Figura 26 mostra o esquema conceitual da arquitetura de integração do modelo baseado em Ontologia e Linked Data.

Figura 26 – Integração do modelo de Ontologia e Linked Data do Next-GISSA.



Fonte: Próprio autor adaptado de Freitas et all. (2017)

Esta construção envolve cinco etapas:

**a. Selecionar as fontes de dados que alimentarão a aplicação.**

A camada referente a base de dados é composta por duas bases: Next-GISSA e Dados IoT. A primeira é relacionada ao RES do paciente e a segunda base são dados obtidos de forma online através de dispositivos IoT.

**b. Extrair e transformar os dados das fontes selecionadas em grafos RDF.**

O objetivo dessa camada é exportar uma visão da fonte de dados como ontologia (RDF), também chamado de Grafo de Conhecimento Local. Nela se relacionam os metadados das bases de dados utilizadas com elementos de ontologia. Para isso será realizado um mapeamento objetivando criar um gráfico RDF a partir dos dados existentes nas bases de dados, identificando as correspondências entre os metadados das bases e os elementos de ontologia com suas propriedades ontológicas. Será utilizado o framework D2RQ<sup>25</sup>.

**c. Identificar links semânticos entre as fontes de dados.**

A interligação das fontes de dados será realizada com o SILK – Link Discovery Framework. O arquivo RDF será submetido à camada superior usando a linguagem SPARQL para consultar o arquivo de instâncias.

O SILK realiza o link semântico entre duas fontes de dados. Como resultado, ele gera um RDF com as triplas no seguinte formato:

gissa:paciente\_1 owl:sameAs <iot:usuario\_a>

gissa:paciente\_11 owl:sameAs <iot:usuario\_c>

**d. Combinar e fundir representações do mesmo objeto em fontes distintas numa visão homogeneizada.**

Diferenças encontradas nessas estruturas de banco de dados podem ser superadas considerando-se que a consulta será realizada no arquivo RDF de instâncias originados de mapeamentos nas bases de dados distintas usando uma ontologia como um vocabulário comum, estando a estrutura de dados e metadados mapeadas para uma ontologia existente.

Essa etapa é realizada usando o framework SIEVE numa abordagem materializada (quando os RDF são armazenados em um Triple Store dentro da aplicação).

---

<sup>25</sup> <http://d2rq.org/>

**d. Realizar consultas parametrizadas a fonte de dados integrada usando o vocabulário da OD.**

Após a geração do arquivo RDF com o conjunto de instâncias, ou “grafos de conhecimento”, que correspondem aos dois bancos de dados utilizados na proposta, os dados podem ser consultados usando uma consulta-SPARQL diretamente das bases geradas e os resultados podem ser visualizados no NextWeb

### **3. Sobre a plataforma dojot**

A arquitetura do sistema será do tipo cliente-servidor na qual o processamento dessas informações será constituído de vários módulos com funções e objetivos específicos que reunidos se complementam para manutenção e obtenção das informações.

Uma plataforma será criada em nuvem rodando um servidor de banco de dados online por meio de uma conexão direta com o servidor Back-End, utilizando API com arquitetura Rest, também em nuvem com Node.js para conexão com o MongoDB, um servidor de banco de dados que será responsável por obter informações clínicas dos pacientes disponibilizados pelo GISSA na tabela RES.

Essa plataforma será desenvolvida em duas etapas fazendo uso de dois diferentes dispositivos de hardware:

1. Raspberry Pi 4 que faz uso de um sistema embarcado para transferência de dados de sinais vitais usando o padrão Health Level 7 (Gabriel Muniz, et al.). Sua configuração: Processador Broadcom BCM2711 Quad core 64-bit SoC, Memória RAM 1 GB, Cartão micro SD 16GB, OS Raspberry Pi OS Lite.


2. Um notebook com aplicação dojot instalada. O notebook é um DELL, Processador Intel I7 10ª Geração, Memória RAM 16GB, Armazenamento SSD 256GB e HD 1TB. Sistema Operacional Windows 10. A comunicação com o Middlawere dojot ocorrerá de duas formas distintas: uma via MQTT, um protocolo de comunicação entre máquinas que permite o envio de mensagens entre dispositivos que falam MQTT por meio de TCP/IP. A outra será com HTTP sendo realizada a partir do notebook via Módulo Obter Dados.

### **4. Classificação dos dados**

A Figura 28 evidência a curva ROC, considerando os algoritmos random forest, decision tree e knn. Aguardava-se a liberação de um conjunto de dados de pessoas diagnosticadas com HA junto a Secretaria de Saúde do Estado do Ceará, entretanto como este processo envolve outras questões ligadas ao comitê de ética e considerando o contexto de

pandemia não obtivemos sucesso. Como alternativa ainda conseguimos acesso aos dados estruturados em um dataset<sup>26</sup> no formato CSV contendo 70.000 registros com informações/dados em que a continuidade no trato científico destes acredita-se que terão certa influência no desfecho de casos de problemas de pressão.

Figura 27 – Curva ROC




Fonte: Próprio autor

## 5. Artigo do NextGISSA

Artigo científico submetido SBC abordando esta pesquisa de mestrado com ênfase na arquitetura conceitual do NextGISSA foi aceito, obtendo 3.º lugar no Prêmio Luiz Fernando de Computação promovido pela comissão Especial da SBC para Sistemas Multimídia e Web (CE-WebMedia) realizado em Curitiba-PR de 07 a 11 de novembro de 2022 e tinha o objetivo de agraciar professores e estudantes de Tecnologia da Informação e Comunicação (TIC) envolvidos em projetos de inovação, completos ou em andamento, que tivessem impacto social e contribuíssem para a melhoria da sociedade.

<sup>26</sup> <https://www.kaggle.com/datasets/sulianova/cardiovascular-disease-dataset>

Figura 28 – Artigo NextGISSA – 3º Colocado no Prêmio Luiz Fernando de Computação



Fonte <https://webmedia.org.br/2022/premiacao-wfa-lf/>  
 Acesso ao site em 23/11/2022 - (qualis do CACC-CAPES avaliado nível A)

## 5 CONCLUSÕES E TRABALHOS FUTUROS

Nesta pesquisa de mestrado foi apresentado o NextGISSA, um sistema inteligente para predição de Hipertensão Arterial (HA), via monitoramento dos sinais vitais de saúde do paciente, de seu histórico clínico e de informações contextuais em tempo real com proposta de uma arquitetura conceitual original de aplicações de IoT, Ontologias e Aprendizado de Máquina, no contexto de Hipertensão Arterial.

Desta forma, o Next-GISSA através da construção de uma arquitetura conceitual ampliou o leque de funcionalidades do GISSA ao incluir um módulo inteligente de monitoramento e predição de HA, além de inaugurar o uso da tecnologia IoT na plataforma. O desenvolvimento de uma plataforma inteligente como o NextGISSA é um desafio complexo, principalmente no contexto da saúde pública brasileira, onde o tratamento de dados para diferentes etapas se dá por diferentes fontes e metodologias, o que dificulta na obtenção de resultados convergentes.

Além do objetivo maior ao qual está pesquisa de mestrado se propôs, destaca-se que todos os objetivos específicos propostos foram alcançados uma vez que realizou-se a revisão da literatura no monitoramento e predição da HA, utilizando IoT e Sistemas Inteligentes (Ontologia e Machine Learning); propôs-se um cenário híbrido baseado nas fases de Diagnóstico do paciente com HA; construiu-se a arquitetura conceitual do Next-GISSA para

posterior implementação nos pacientes hipertensos que constam no Relatório de Pessoas Adscritas na plataforma GISSA; especificou-se a arquitetura do Next-GISSA, descrevendo suas principais funcionalidades a luz do cenário proposto; identificou-se atributos e algoritmos para a Classificação de Risco e especificou-se o módulo ontologia para disparo do Chat bot.

O NextGISSA, como supramencionado trouxe uma contribuição tanto científica quanto prática, resultado de sucessivas pesquisas de graduação, mestrado, doutorado e pós-doutorado no contexto de saúde digital tendo a sua origem na proposta de Oliveira et al. (2010).

A importância científica diz respeito a escassez de estudos que aglutinem as tecnologias IoT e inteligência artificial voltadas para o público de hipertensos com ampliação de uma plataforma digital ativa e validada. Ademais, tem-se a relevância prática da pesquisa quanto a construção de uma arquitetura conceitual proposta para o sistema de monitoramento e predição da pressão arterial.

Considerando que o Next-GISSA pode ser direcionado a diferentes usuários com alguma comorbidade, ressalta-se novos projetos de mestrados que estão surgindo a partir do NextGISSA sendo eles: 1. IoTNextGISSA e 2. SmartNextGISSA com foco em pacientes com qualquer tipo de comorbidade.

Ademais, o Projeto de pesquisa Embrapii liderado pela startup “Avicena Governança Inteligente” tem como fonte o NextGISSA.

Assim, com o desenvolvimento desta pesquisa são fornecidos subsídios para implementação de políticas de saúde que venham contribuir no uso das tecnologias digitais como aliadas nas formas de avaliação para eficácia das ações em andamento no que concerne ao monitoramento de comorbidades.

Importante destacar como trabalhos futuros a ampliação da experimentação de novas metodologias para IoT como também ampliar o universo da experimentação para novos algoritmos de Aprendizagem de Máquina em uma abordagem mais genérica para uso da arquitetura, permitindo que qualquer indivíduo portador de alguma comorbidade possa ser monitorado.

## REFERÊNCIAS BIBLIOGRÁFICAS

AL-AZZAM, M. K.; ALAZZAM, M. B. **Smart city and Smart-Health framework, challenges and opportunities**. International Journal of Advanced Computer Science and Applications, v. 10, n. 2, p. 171–176, 2019.

ALMEIDA, M; BAX, M. Uma visão geral sobre ontologias: pesquisa sobre definições, tipos, aplicações, métodos de avaliação e de construção. Revista Ciência da Informação, 32(3), 2003.  
 AVICENA. **Governança Inteligente Em Sistemas De Saúde Gissa**. 2021. Disponível em: <https://avicena.in/>

AZEVEDO, P. C. N. **Uma proposta para visualização de linked data sobre enchentes na bacia do Rio Doce**. Dissertação de Mestrado Profissional, Universidade FUMEC, Belo Horizonte, 2014.

BARBOSA Vinícius; FERREIRA Helen; GOMES Leonardo; GOMES Fabio; BARRETO Ivana; MONTEIRO Odorico; OLIVEIRA, Mauro. **SmartRES - Uma plataforma IoT para Monitoramento Inteligente em Saúde e sua Aplicação no Contexto da COVID-19**, Anais do Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS): 2020: Anais do XX Simpósio Brasileiro de Computação Aplicada à Saúde

BARROSO et al. **Diretrizes Brasileiras de Hipertensão Arterial – 2020**. <https://diretrizes.cardiol.online/>

BARROCA FILHO, I. M. **Architectural design of IoT-based healthcare applications**. 2018. 96 f. Tese (Doutorado em Ciência da Computação) - DIMAp, Universidade Federal do Rio Grande do Norte, Natal, 2018.

BERNERS-LEE, T.; HENDLER, J.; LASSILA, O. **The semantic web: a new form of Web content that is meaningful to computers will unleash a revolution of new possibilities**. v. 284, n. 5, p. 28-37, 2001. Disponível em: [https://www.researchgate.net/publication/225070375\\_The\\_Semantic\\_Web\\_A\\_New\\_Form\\_of\\_Web\\_Content\\_That\\_is\\_Meaningful\\_to\\_Computers\\_Will\\_Unleash\\_a\\_Revolution\\_of\\_New\\_Possibilities](https://www.researchgate.net/publication/225070375_The_Semantic_Web_A_New_Form_of_Web_Content_That_is_Meaningful_to_Computers_Will_Unleash_a_Revolution_of_New_Possibilities).

BERNERS-LEE, T. **Linked data: design issues**. W3C, 2006a. Disponível em: <http://www.w3.org/DesignIssues/LinkedData.html>.

BIZER, C.; HEATH, T.; BERNERS-LEE, T. Linked Data: the story so far. **International Journal on Semantic Web and Information Systems**, v. 5, n. 3, p. 01-22, 2009. DOI: 10.4018/978-1-60960-593-3.ch008. Disponível em: <http://tomheath.com/papers/bizer-heath-berners-lee-ijswis-linked-data.pdf>.

BRASIL. **Sociedade Brasileira de Cardiologia; Sociedade Brasileira de Hipertensão; Sociedade Brasileira de Nefrologia**. [VI Brazilian Guidelines on Hypertension]. Arq Bras Cardiol. 2010;95(1 Suppl):1-51. Erratum in: Arq Bras Cardiol, v. 95, n. 4 p. 553, 2010.

BRAGA, Oton Crispim. Solução Inteligente Baseada em Aprendizado de Máquina para a Classificação de Doenças transmitidas pelo vetor Aedes Aegypti. Trabalho de Conclusão de

Curso (TCC) apresentado ao curso de Bacharelado em Ciência da Computação do Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE - Campus Aracati. 2017

BREIMAN, L. **Random forests. Machine Learning**, Kluwer Academic Publishers, v. 45, n. 1, p. 5–32, 2001. ISSN 0885-6125. Disponível em: <http://dx.doi.org/10.1023/A%3A1010933404324>.

BREIMAN, L.; FRIEDMAN, J.; STONE, C.; OLSHEN, R. **Classification and Regression Trees**. Taylor & Francis, 1984. ISBN 9780412048418. Disponível em: <https://books.google.com.br/books?id=JwQx-WOmSyQC>.

CAMARGO, A.L., ITO, M. **Utilização das tecnologias de informação e comunicação na área da saúde: uso das redes sociais pelos médicos**. J. Health Inform, 2012; 4(4):164-9.

CAREY RM, Muntner P, Bosworth HB, Whelton PK. **Prevention and Control of Hypertension**. JACC Health Promotion Series. J Am Coll Cardiol. 2018;71(19):2199-269

CERQUEIRA, Gabriel Muniz; PINHEIRO, Isabelle Matos; LIMA, Igor Alexandre de; JESUS, Raimundo Jorge Abreu de; SOUZA, Antonio Carlos dos Santos. **Sistema Embarcado para transferência de sinais vitais usando o padrão Health Level 7 (HL7)** / Embedded System for transferring vital signs using the Health Level 7 (HL7) standard. Brazilian Journal of Health Review. 2019

COMITÊ GESTOR. Pesquisa sobre o uso das tecnologias de informação e comunicação nos estabelecimentos de saúde brasileiros. TIC Saúde, 2017.

COSTA FILHO, Raimundo Valter. Smart-Gissa, **Um Sistema Para Governança em Saúde Digital Baseado em Aprendizado de Máquina**. Tese apresentada ao Programa de Pós-Graduação em Engenharia de Teleinformática do Centro de Ciências e Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Doutor em Engenharia de Teleinformática. FORTALEZA. 2021.

COSTA, P. M. B. d. P. **Sistema de Internet das Coisas para o apoio aos cuidados de saúde da população idosa**. Master's thesis, Universidade de Evora. (2018).

DIMA, C. Intui2: A Prototype System for Question Answering over Linked Data. In **CLEF (Working Notes)**. 2013.

EAGLE, K., GINSBURG, G., MUSUNURU, K., Aird, W., Balaban, R., Bennett, S., Blumenthal, R., Coughlin, S., Davidson, K., Frohlich, E., et al. (2010). **Identifying patients at high risk of a cardiovascular event in the near future**. Circulation, 121(12):1447–1454.

FREITAS, Nicodemos. **Predição de Casos de Arboviroses na Cidade de Fortaleza-CE Utilizando Internet das Coisas e Aprendizado de Máquina**/ Nicodemos Freitas. – 2021. Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Ciências, Programa de Pós-Graduação em Ciência da Computação, Fortaleza, 2021.

FREITAS, Renato; LIMA, Cleilton; BRAGA, Oton; LOPES, Gabriel; ANDRADE, Odorico; OLIVEIRA, Mauro. **Using Linked Data in the Data Integration for Maternal and Infant Death Risk of the SUS in the GISSA Project**. Conference: the 23rd Brazillian Symposium.

October

2017.

[https://www.researchgate.net/publication/320391384\\_Using\\_Linked\\_Data\\_in\\_the\\_Data\\_Integration\\_for\\_Maternal\\_and\\_Infant\\_Death\\_Risk\\_of\\_the\\_SUS\\_in\\_the\\_GISSA\\_Project](https://www.researchgate.net/publication/320391384_Using_Linked_Data_in_the_Data_Integration_for_Maternal_and_Infant_Death_Risk_of_the_SUS_in_the_GISSA_Project)

GIL, A. C. Como elaborar projetos de pesquisa. 4. ed. São Paulo: Atlas, 2009. 175 p.

GUNTHER. Eysenbach **What is e-health?** Journal of medical Internet Research 2001. URL: <https://www.jmir.org/2001/2/e20> DOI: 10.2196/jmir.3.2.e20

GUARINO, N. Formal ontology, conceptual analysis and knowledge representation. **International Journal of Human and Computer Studies**, 43(5/6):625–640, 1995.

GUARINO, N. **Understanding, building and using ontologies**. International Journal of Human and Computer Studies, 45(2/3), 2 1997.

GUARINO, N. **Formal ontology in information systems**. In: IOS Press, A, editor, FOIS'98, TRENTO, ITALY, p. 3–15, 06 1998 GRUBER, T. What is an ontology. <http://www-ksl.stanford.edu/kst/what-is-an-ontology.html>

GUIZZARDI, G. **Desenvolvimento para e com reuso: Um estudo de caso no domínio de vídeo sob demanda**. Master's thesis, Universidade Federal do Espírito Santo, 2000.

HANDELMAN, G. S. et al. EDoctor: Machine Learning and the Future of Medicine. **Journal of Internal Medicine**, v. 284, n. 6, p. 603–619, 2018.

Health & Fitness AI Lab. **Diário de Pressão Arterial**. 2020. Disponível em: [https://play.google.com/store/apps/details?id=com.bluefish.bloodpressure&hl=pt\\_BR&gl=US](https://play.google.com/store/apps/details?id=com.bluefish.bloodpressure&hl=pt_BR&gl=US)

ISOTANI, S.; BITTENCOURT, I. **Dados abertos conectado**. Ibert Bittencourt. São Paulo: Novatec, 2015. Disponível em: [http://www.pgcl.uenf.br/arquivos/dadosabertosconectados\\_011120181613.pdf](http://www.pgcl.uenf.br/arquivos/dadosabertosconectados_011120181613.pdf).

ISTEPANIAN, Robert S.H. and LACAL, Jose C. Emerging **Mobile Communication Technologies for Health: Some Imperative notes on m-health**. Conference: Engineering in Medicine and Biology Society, 2003. Proceedings of the 25th Annual International Conference of the IEEE. October, 2003.

JUNG, E.-Y. et al. **Mobile healthcare application with EMR interoperability for diabetes patients**. Cluster Computing, Sep. 2014. Volume 17, PP 871-880.

JUNG, E.-Y. et al. **Development of U-healthcare monitoring system based on context-aware for knowledge service**. Multimedia Tools and Applications, April 2015. Volume 74, pp 2467-2482.

KENSKI, V. M. **Educação e tecnologias: o novo ritmo da informação**. Campinas: Editora Papirus. 2012a.

LESSA I. **Não adesão ao tratamento da hipertensão arterial - consequências econômicas para o indivíduo e para a sociedade.** In: Nobre F, Pierin AMG, Mion Jr D. Adesão ao tratamento - o grande desafio da hipertensão. São Paulo: Lemos; 2001. p. 86-106.

LOPES, V. C. M. **TV Health das Coisas: uma arquitetura IoT para assistência domiciliar à saúde.** [S.l.:s.n.], 2017.

LOPES. Gabriel; VIDAL, Vânia; OLIVEIRA; Mauro. 2016. **A Framework for Creation of Linked Data Mashups: A Case Study on Healthcare.** In Proceedings of the 22Nd Brazilian Symposium on Multimedia and the Web (Webmedia '16). ACM, New York, NY, USA, 327–330. <https://doi.org/10.1145/2976796.2988213>

MANUAL GISSA (2021): **Manual\_GISSA\_AVICENA\_2021\_março**

MALACHIAS, M. V. B. (Org.). **7ª Diretriz Brasileira de Hipertensão Arterial.** Arq Bras Cardiol, v.107, n.3, p. 1-103, 2016

MELO, Emilson Richardson Rocha. **Vite Das Coisas, Uma Solução Para Urgencia e Emergencia em Sistemas de Saude.** Dissertação (Mestrado Profissional em Computação Aplicada do Programa de Pós-graduação em Ciência da Computação do Centro de Ciências e Tecnologia), UECE (Universidade Estadual do Ceara), Fortaleza - Ceara, Brasil. 2017

MONARD, M. C.; BARANAUSKAS, J. A. **Conceitos sobre Aprendizado de Máquina. Sistemas inteligentes: fundamentos e aplicações,** p. 89–114, 2003.

MOE, Z. H. et al., (2018) ‘**Comparison Of Naive Bayes And Support Vector Machine Classifiers On Document Classification**’, in 2018 IEEE 7th Global Conference on Consumer Electronics (GCCE), pp. 466–467. doi: 10.1109/GCCE.2018.8574785.

NETTO, Amilcar; MACIEL, Francisco. **Python para Data Science e Machine Learning.** Descomplicado/ - Rio de Janeiro: Alta Books. 2021. 416 p. ISBN: 978-655520-337-0

OLIVEIRA, M.; HAIRON, C.; ANDRADE, O.; MOURA, R.; SICOTTE, C.; DENIS, J.; FERNANDES, S.; GENSEL, J.; BRINGEL, J.; MARTIN, H. **A context-aware framework for health care governance decision-making systems: A model based on the brazilian digital tv.** In: \_\_\_\_\_. World of Wireless Mobile and Multimedia Networks (WoWMoM), 2010 IEEE International Symposium on a. [S.l.]: IEEE, 2010. p. 1–6.

OLIVEIRA, M.; CUNHA, P. R.; SANTOS, M. E. da S.; BEZERRA, J. C. C. **Implementing home care application in brazilian digital tv.** In: \_\_\_\_\_. Information Infrastructure Symposium, 2009. [S.l.]: Global, 2009. p. 1–7.

OLIVEIRA, Ari Barreto de. **Um módulo de protocolo para aplicações de IoT em saúde.** 2020. 68f. Dissertação (Mestrado Profissional em Tecnologia da Informação) - Instituto Metrópole Digital, Universidade Federal do Rio Grande do Norte, Natal, 2020.

OLIVEIRA, L. **Coletor de Dados para Aplicações de Saúde Baseadas na Infraestrutura de IoT.** 2018. 45 f. Dissertação (Bacharelado em Engenharia de Software) DIMAp, Universidade Federal do Rio Grande do Norte, Natal, 2018.

PONTE, J. P. **Tecnologias de informação e comunicação na educação e na formação de professores: Que desafios?** Revista Ibero-Americana de Educação, 24, 63-90. (2000). Disponível em: < <http://redalyc.uaemex.mx/pdf/800/80002404.pdf>>.

SANTOS, Zélia Maria de Sousa Araújo; FROTA, Mirna Albuquerque; CRUZ, Daniele Morais; HOLANDA, Samanta Daisy O. **Adesão Do Cliente Hipertenso Ao Tratamento: Análise Com Abordagem Interdisciplinar**, Fortaleza, 2005.

SANTAREM SEGUNDO, J. E.; CONEGLIAN, C. S. **Tecnologias da web semântica aplicadas a organização do conhecimento: padrão SKOS para construção e uso de vocabulários controlados descentralizados**. In: GUIMARÃES, J. A. C.; DODEBEI, V. (orgs.). Organização do conhecimento e diversidade cultural. Marília: Fundepe, v. 3, p. 224-233, 2015.

SILVA, Cristiano; ALVES, Joyce; BRAGA, Oton; JÚNIOR, José; ANDRADE, Luiz; OLIVEIRA, Antônio. **Usando o Classificador Naive Bayes para Geração de Alertas de Risco de Óbito Infantil**. Revista Eletrônica de Sistemas de Informação. 2017/08/31.

SILVA, Eunice Palmeira da. **Classificação de informação usando ontologias**. Dissertação de Mestrado. Universidade Federal de Alagoas. Instituto de Computação. Maceió, 2006.

SILVA, Cristiano; QUINTINO, Joyce; RAMOS Ronaldo, MONTEIRO, Odorico; OLIVEIRA, Mauro. 2017. **LAÍS, um Analisador Baseado em Classificadores para a Geração de Alertas Inteligentes em Saúde**, Victoria E. Herscovitz, Cesar A. Z. Vasconcellos, and Erasmo Ferreira (Eds.). XXXV Simpósio Brasileiro de Redes de Computadores (SBRC) - I Workshop de Computação Urbana (CoUrb), Belém, Pará, Brasil, 1–13.

SILVA, Kátia Cilene Neles da. **Monitoramento da saúde humana através de sensores: análise de incertezas contextuais através da teoria de Dempster- Shafer / K.C.N. da Silva**. -- ed.rev. -- São Paulo, 2013. 141 p. Tese (Doutorado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Computação e Sistemas Digitais.

SIDI. A relação entre IoT e IA. outubro. 2020. Disponível em: <https://www.sidi.org.br/a-relacao-entre-iot-e-ia/>

Sociedade Brasileira de Cardiologia. Arquivos Brasileiros de Cardiologia. ISSN-0066-782X. Volume 107, Nº 3, Suppl. 3, September 2016.

SOUZA, F. J. G. de. Marcia, **Uma Metodologia para O Manejo de Registro Clínico com Uso de Arquétipos para Interoperabilidade em Sistemas de Saúde**. Dissertação (Mestrado Profissional em Computação Aplicada do Programa de Pós-graduação em Ciência da Computação do Centro de Ciências e Tecnologia), UECE (Universidade Estadual do Ceará), Fortaleza - Ceara, Brasil. (2017).

SOUSA, J. P. P.; CARRAPATOSO, E.; FONSECA, B.; PIMENTEL, M. G. C.; BULCÃO NETO, R. F. Composition of contextaware mobile services using a semantic context model. International Journal on Advances in Software, Volume 2, pp. 275-287, 2009.

SCHMIDT, Maria Inês; DUNCAN, Bruce Bartholow; MENDONÇA, Gulnar Azevedo e Silva; et al. **Doenças crônicas não transmissíveis no Brasil: carga e desafios atuais**. The Lancet.

London, p.61-74, maio. 2011. Disponível em: <http://download.thelancet.com/flatcontentassets/pdfs/brazil/brazilpor4.pdf>

SHORTLIFEE, E. H., KULIKOWSKI, C.A. AMIA Board white paper: **Definition of biomedical informatics and specification of core competencies for graduate education in the discipline**, 2014.

SOCIEDADE BRASILEIRA DE CARDIOLOGIA. Departamento de Hipertensão Arterial. VI Diretrizes brasileira de hipertensão. Rev Bras Hipertens. 2010.

TAVARES, P. D. S.; RODRIGUES, E. B. IoT-Based Architecture for Data Analytics of Arboviruses in Smart Cities. **Proceedings - IEEE Symposium on Computers and Communications**, v. 2018-June, n. Mdcc, p. 952–957, 2018. ISSN 15301346.

TIAN, Shuo; YANG, Wenbo; GRANGE, Jehane Michael Le; WANG, Peng; HUANG Wei; YE, Zhewei. **Smart healthcare: making medical care more intelligent**. (2019).

VALENTE, J. A. (1998a). Diferentes usos do computador na educação. Em J. A. Valente (Org.), **Computadores e conhecimento: repensando a educação** (pp. 1-27, 2ª ed.). Campinas: UNICAMP.

[https://eadcampus.spo.ifsp.edu.br/pluginfile.php/176745/mod\\_resource/content/1/Diferentes%20usos%20do%20computador%20na%20educa%C3%A7%C3%A3o.pdf](https://eadcampus.spo.ifsp.edu.br/pluginfile.php/176745/mod_resource/content/1/Diferentes%20usos%20do%20computador%20na%20educa%C3%A7%C3%A3o.pdf)

VALTER, R.; OLIVEIRA, M.; SILVA, F. G. S.; ANDRADE, D. **Intelligent Epidemiological Surveillance in the Brazilian Semi-arid**. 2020.

VALTER, R., SANTIAGO, S., RAMOS, R., OLIVEIRA, M., ANDRADE, L. O. M., and de HC Barreto, I. C. (2019). **Data mining and risk analysis supporting decision in brazilian public health systems**. In 2019 IEEE International Conference on E-health Networking, Application & Services (HealthCom), pages 1–6. IEEE

VEIGA, Jeangrei Emmanoelli. **Um sistema d-Health para auxiliar na promoção de um estilo de vida saudável em hipertensos**. 2017. 69 f. Dissertação (Mestrado em Computação Aplicada) - Universidade de Passo Fundo, Passo Fundo, 2017.

VIGITEL, Brasil. **Vigilância de Fatores de Risco e Proteção para Doenças Crônicas por Inquérito Telefônico**. Brasília : Ministério da Saúde, 2021.

ZMSA, Santos. **Estilo de vida da mulher hipertensa e a relação com o autocuidado** - [dissertação]. Fortaleza (CE): Programa de Pós-graduação em Enfermagem/UFC; 1998.