



UNIVERSIDADE FEDERAL DE SANTA CATARINA
DEPARTAMENTO DE INFORMÁTICA E ESTATÍSTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS DA COMPUTAÇÃO

René Nolio Santa Cruz

Estimativa de carga de trabalho de enfermeiros em uma UTI por meio de redes neurais e IoT-fog

Florianópolis
2022

René Nolio Santa Cruz

Estimativa de carga de trabalho de enfermeiros em uma UTI por meio de redes neurais e IoT-fog

Dissertação submetida ao Programa de Pós-Graduação em Ciências da Computação da Universidade Federal de Santa Catarina para a obtenção do título de mestre em ciências da computação.

Orientador: Prof. Carlos Becker Westphall, Dr.

Coorientador: Hugo Vaz Sampaio, Dr.

Florianópolis

2022

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

Santa Cruz, Rene Nolio

Estimativa de carga de trabalho de enfermeiros em uma
UTI por meio de redes neurais e IoT-fog / Rene Nolio Santa
Cruz ; orientador, Carlos Becker Westphall, coorientador,
Hugo Vaz Sampaio, 2023.

74 p.

Dissertação (mestrado) - Universidade Federal de Santa
Catarina, Centro Tecnológico, Programa de Pós-Graduação em
Ciência da Computação, Florianópolis, 2023.

Inclui referências.

1. Ciência da Computação. 2. recursos humanos de
enfermagem. 3. carga de trabalho. 4. hospital inteligente.
5. inteligência artificial. I. Westphall, Carlos Becker.
II. Sampaio, Hugo Vaz. III. Universidade Federal de Santa
Catarina. Programa de Pós-Graduação em Ciência da Computação.
IV. Título.

René Nolio Santa Cruz

Estimativa de carga de trabalho de enfermeiros em uma UTI por meio de redes neurais e IoT-fog

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

Prof. Elder Rizzon Santos, Dr.
Universidade Federal de Santa Catarina

Profa. Denise Tolfo Silveira, Dra.
Universidade Federal do Rio Grande do Sul

Prof. Mateus Grellert da Silva, Dr.
Universidade Federal de Santa Catarina

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do título de mestre em ciências da computação.

Coordenação do Programa de
Pós-Graduação

Prof. Carlos Becker Westphall, Dr.
Orientador

Florianópolis, 2022.

RESUMO

Para tratar pacientes em uma Unidade de Terapia Intensiva (UTI), é necessária uma equipe de enfermeiros nas 24 horas do dia, sendo necessário estimar a carga de trabalho dos mesmos e distribuir as tarefas de forma a evitar sobrecarregá-los. Visto que uma quantidade insuficiente de profissionais implica em uma baixa qualidade de atendimento aos pacientes, maiores riscos à saúde dos mesmos e aumento do tempo de internação. Uma das ferramentas para avaliar a carga de trabalho dos enfermeiros é o *Nursing Activities Score* (NAS), que pode identificar os casos em que existe uma alta carga de trabalho para os enfermeiros. Redes IoT-fog demonstraram ser eficientes para capturar e processar grandes quantidades de dados, possibilitando automatizar decisões em ambientes inteligentes, por meio do uso de técnicas de inteligência artificial. Este trabalho tem como objetivo desenvolver uma rede IoT-Fog, incluindo um protótipo de leito inteligente que será capaz de detectar quando um ou mais profissionais de enfermagem se aproximam dela, e enviará estes dados à fog, que irá utilizar técnicas de inteligência artificial para estimar a quantidade destes profissionais a ser alocada por dia de trabalho. Proporcionando, assim, uma alta qualidade de atendimento aos pacientes, ao considerar o NAS para calcular a carga de trabalho necessária. Os principais sistemas que foram desenvolvidos incluem o dispositivo IoT, que tem como função documentar a duração das atividades de enfermagem; um simulador, que gera dados sobre atividades de enfermagem com base em artigos publicados na área; e um módulo de inteligência artificial, que utiliza redes neurais para fazer estimativas de carga de trabalho diária com base no diagnóstico dos pacientes da UTI em questão.

Palavras-chave: Internet das coisas, redes neurais, inteligência artificial, hospital inteligente, Nursing Activities Score, recursos humanos de enfermagem no hospital, sistemas de informação em saúde, carga de trabalho, cuidado crítico.

ABSTRACT

In order to treat patients in an ICU, a nursing team is needed 24 hours a day, and it is necessary to estimate their workload and distribute tasks in order to avoid overloading them. An insufficient number of nurses implies in low-quality patient care, greater risks to their health and increased length of stay. One tool to assess nurses' workload is NAS, which can identify in which cases there is a high workload for nurses. IoT-fog networks have proven to be efficient in capturing and processing large amounts of data, enabling automated decisions in intelligent environments through artificial intelligence techniques. In this thesis, an IoT-Fog network is developed, including a prototype of an intelligent ICU bed that will be able to detect when one or more nurses approach it, and will send this data to a fog node, which will use artificial intelligence techniques to estimate the number of nurses to be allocated per working day, thus providing a high quality of patient care, when considering NAS to calculate the required workload. The main components that were developed include the IoT device, whose function is to document the duration of each nursing activity; a simulator, which generates data about nursing activities based on articles published in this area; and an artificial intelligence module, which uses neural networks to estimate the daily required workload, based on the diagnosis of patients in the ICU.

Keywords: Internet of Things. Neural networks. Artificial intelligence. Smart hospital. Nursing Activities Score. Hospital human resources in nursing. Health data systems. Workload. Intensive care.

LISTA DE FIGURAS

Figura 1 – Framework Fog-Cloud com suporte para dispositivos IoT.	19
Figura 2 – Modelo básico de um neurônio artificial.	21
Figura 3 – Modelo de uma rede neural rasa	22
Figura 4 – Arquitetura de referência do sistema proposto	32
Figura 5 – Diagrama do dispositivo IoT proposto.	34
Figura 6 – Frequência diária média de cada atividade NAS de acordo com o diagnóstico, para cada paciente.	39
Figura 7 – Comparação entre a carga de trabalho estimada e a simulada. . . .	48
Figura 8 – Comparação entre o valor da métrica <i>recall</i> entre os conjuntos de treinamento e teste, por época.	51
Figura 9 – Comparação entre o valor de perda entre os conjuntos de treinamento e teste, por época.	52
Figura 10 – Comparação entre a estimativa da rede neural de classificação com o valor teórico e o esperado, por dia.	52
Figura 11 – Comparação do erro quadrático médio entre os conjuntos de treinamento e teste, por época.	54
Figura 12 – Comparação entre a estimativa de ambas redes neurais propostas com o valor esperado e o simulado, por dia.	54
Figura 13 – Comparação entre o conjunto de treinamento e validação (ambos com a distribuição normal), considerando a duração da atividade de investigações laboratoriais.	56
Figura 14 – Comparação do resultado obtido pela rede neural com os dados simulados.	56
Figura 15 – Comparação entre o conjunto de treinamento (distribuição normal) e validação (distribuição T-Student), considerando a duração da atividade de investigações laboratoriais.	57
Figura 16 – Comparação do resultado obtido pela rede neural com os dados simulados.	58
Figura 17 – Comparação entre o conjunto de treinamento (distribuição normal) e validação (distribuição exponencial), considerando a duração da atividade de investigações laboratoriais.	59
Figura 18 – Comparação do resultado obtido pela rede neural com os dados simulados.	59

LISTA DE TABELAS

Tabela 1 – Sumário da revisão bibliográfica, indicando a quantidade de resultados por cada combinação de palavras chave.	26
Tabela 2 – Sumário dos artigos correlatos e a sua relação com a proposta atual.	30
Tabela 3 – Dataset utilizado para o treinamento da rede neural de classificação.	41
Tabela 4 – Dataset utilizado para o treinamento da rede neural de regressão. .	41
Tabela 5 – Comparação do impacto de cada tipo de erro de predição (fonte própria).	43
Tabela 6 – Comparação dos resultados obtidos na <i>crossvalidation</i>	60

LISTA DE ABREVIATURAS E SIGLAS

ARNP	<i>Advanced Registered Nurse Practitioner</i>
CATS	<i>Clinical Activities Tracking System</i>
CNA	<i>Certified Nursing Assistant</i>
COFEN	Conselho Federal de Enfermagem
CORENs	Conselhos Regionais de Enfermagem
HIPPA	<i>Health Insurance Portability and Accountability Act</i>
IA	Inteligência Artificial
IaaS	<i>Infrastructure as Service</i>
IoT	<i>Internet of Things</i>
LPN	<i>Licensed Practical Nurse</i>
LTE	<i>Long Term Evolution</i>
NAS	<i>Nursing Activities Score</i>
NEMS	<i>Nine Equivalents of Nursing Manpower use Score</i>
PaaS	<i>Platform as Service</i>
RFID	<i>Radio Frequency Identification</i>
RN	<i>Registered Nurse</i>
SaaS	<i>Software as Service</i>
SELU	Unidade Linear Exponencial Escalonada
SLA	<i>Service Level Agreement</i>
TISS	<i>Therapeutic Intervention Scoring System</i>
UTI	Unidade de Terapia Intensiva

SUMÁRIO

1	INTRODUÇÃO	11
1.1	MOTIVAÇÃO	12
1.2	JUSTIFICATIVA	12
1.3	OBJETIVOS	13
1.3.1	Objetivos Específicos	13
1.4	PRINCIPAIS CONTRIBUIÇÕES	14
1.5	METODOLOGIA DE PESQUISA	14
1.6	ESTRUTURA DO TRABALHO	15
2	FUNDAMENTAÇÃO TEÓRICA	16
2.1	CLOUD COMPUTING	16
2.2	INTERNET OF THINGS	17
2.3	FOG COMPUTING	18
2.4	INTELIGÊNCIA ARTIFICIAL	20
2.4.1	Redes neurais	21
2.5	GERENCIAMENTO DE RECURSOS HUMANOS NA ENFERMAGEM	23
2.5.1	Nursing Activities Score	24
3	REVISÃO BIBLIOGRÁFICA E ESTADO DA ARTE	26
4	PROPOSTA E DESENVOLVIMENTO	32
4.1	IOT	33
4.2	SIMULADOR	33
4.2.1	Escolha das atividades a serem executadas	38
4.3	REDES NEURAIS	40
4.3.1	Dataset	40
4.3.2	Rede Neural de Classificação	42
4.3.3	Rede Neural de Regressão	45
5	EXPERIMENTOS E RESULTADOS	47
5.1	SIMULAÇÃO	47
5.2	REDES NEURAIS	47
5.2.1	Rede de Classificação Multi-classe	48
5.2.2	Rede de Classificação Binária	50
5.2.3	Rede de Regressão	53
5.3	CROSSVALIDATION	55
5.3.1	Distribuição normal	55
5.3.2	Distribuição T-Student	57
5.3.3	Distribuição Exponencial	58
6	CONCLUSÕES	61
6.1	TRABALHOS FUTUROS	62

REFERÊNCIAS	63
ANEXO A – ESCORE DE ATIVIDADES DE ENFERMAGEM	70

1 INTRODUÇÃO

O paradigma de IoT consiste em adicionar uma interface de rede a objetos, permitindo que estes se comuniquem entre si e com outros dispositivos, possibilitando aos usuários não apenas obter dados diretamente do dispositivo, mas também enviar comandos a serem executados pelo dispositivo IoT, que pode ativar atuadores, luzes, motores e outros (LEE *et al.*, 2017).

Redes IoT-fog demonstraram ser eficientes para capturar e processar grandes quantidades de dados, e são utilizadas em diversas áreas, em particular possibilitando automatizar decisões em ambientes inteligentes. Chen *et al.* (2020) e Morales (2020), desenvolveram sistemas inteligentes IoT para monitorar sinais vitais de pacientes e disponibilizá-los às famílias dos pacientes e aos enfermeiros. Nursuwars e Rahmatulloh (2019), assim como Guo *et al.* (2015), propõem sistemas IoT que auxiliam no registro de atividades de atendimentos aos pacientes, e outras estatísticas que permitem avaliar a qualidade do atendimento no hospital.

De acordo com Camuci *et al.* (2014), para tratar pacientes em estado grave ou crítico é necessária uma equipe multiprofissional e um local apropriado, como uma Unidade de Terapia Intensiva (UTI). Estas UTIs requerem recursos humanos e tecnológicos de alto custo, incluindo enfermeiros e técnicos de enfermagem nas 24 horas do dia, logo é necessário avaliar a carga de trabalho requerida e distribuí-la de forma justa e eficiente entre estes profissionais para melhorar a qualidade do atendimento aos pacientes, visto que existe uma relação entre riscos à saúde do paciente e uma quantidade insuficiente de profissionais.

Um dos instrumentos para avaliar a carga de trabalho de enfermagem é o Nursing Activities Score (NAS), que permite gerenciar a carga de trabalho dos mesmos para garantir a qualidade de atendimento e a segurança dos pacientes. De acordo com Camuci *et al.* (2014), o NAS foi aplicado em uma UTI de Queimados em um hospital público de ensino e foi capaz de identificar corretamente os casos em que existe uma alta carga de trabalho nos profissionais de enfermagem.

No Brasil, de acordo com a lei N 7.498/86 de 25 de Junho de 1986 (BRASIL, 1986) e o decreto N 94.406/87 (BRASIL, 1987), as equipes de enfermagem podem ser compostas por enfermeiros, técnicos de enfermagem, auxiliares de enfermagem e parteiras; sendo que cada um destes profissionais possui competências e graus de habilitação distintos.

De acordo com Cesário *et al.* (2021), nos Estados Unidos da América, a prática clínica do enfermeiro é diferente ao se comparar com o Brasil, pois a equipe de enfermagem apresenta diversos níveis profissionais, sendo estes: *Certified Nursing Assistant* (CNA), *Licensed Practical Nurse* (LPN), *Registered Nurse* (RN) e *Advanced Registered Nurse Practitioner* (ARNP). Considerando as diferenças na formação e

atuação de equipes de enfermagem no Brasil e nos Estados Unidos, Queijo e Padilha (2009) desenvolveram uma adaptação e validação do NAS para a língua portuguesa, possibilitando o seu uso na enfermagem brasileira.

O NAS tem sido usado para medir a influência do tempo de execução de atividades dos profissionais de enfermagem em uma UTI, e é composto por 23 atividades de enfermagem, onde cada atividade é avaliada em relação ao tempo de assistência e a pontuação total é a soma das pontuações parciais (MIRANDA *et al.*, 2003).

Apesar das vantagens do NAS para a avaliação de carga de trabalho de enfermagem, esta ferramenta exige que os intervalos de tempo sejam medidos e anotados em uma tabela, o que geralmente é feito de forma manual. Esta tarefa de documentação pode ser onerosa, imprecisa, e causar stress e fadiga (KHANADE *et al.*, 2017) (CAMARGO *et al.*, 2021), pois nem sempre as atividades são documentadas de forma imediata, necessitando que os enfermeiros lembrem de detalhes de cada atividade ao longo do dia.

Desta forma, este trabalho procura integrar as vantagens de redes IoT-fog para calcular e documentar o tempo empregado em cada atividade de atendimento ao paciente, e utilizar redes neurais para estimar a quantidade de profissionais de enfermagem necessários por dia, evitando sobrecarregar os mesmos e oferecendo uma qualidade satisfatória de atendimento aos pacientes.

1.1 MOTIVAÇÃO

Um dos desafios mais importantes na área de enfermagem é como proporcionar a melhor qualidade de cuidado aos pacientes possível. Estes atendimentos influenciam diretamente no quadro clínico dos pacientes. Para alcançar este propósito, é necessário avaliar o tempo requerido para executar cada uma das diversas atividades de enfermagem, e mensurar a carga de trabalho, procurando alocar uma quantidade satisfatória de enfermeiros e técnicos de enfermagem para cada turno de trabalho.

Uma das ferramentas que permite fazer esta análise é o NAS, que é reconhecido a nível internacional, e foi traduzido e adaptado para o seu uso no Brasil por Miranda *et al.* (2003). Porém, surgem novos desafios ao aplicar esta ferramenta, como a necessidade de anotar o tempo empregado para cada atividade e o cálculo manual de pontuações. Possibilidades para resolver estes desafios incluem o uso de tecnologias como IoT e Inteligência Artificial (IA), podendo reduzir o tempo requerido ao empregar o NAS e oferecendo melhor precisão, segurança e praticidade.

1.2 JUSTIFICATIVA

A locação de uma quantidade insuficiente de profissionais de enfermagem pode gerar riscos à saúde dos pacientes, enquanto que uma quantidade excessiva

pode gerar gastos desnecessários. O NAS foi utilizado por Padilha *et al.* (2010) em um estudo em uma UTI com 25 macas e 68 pacientes durante um mês, e foi estimado que, em média, são requeridas 86.3 horas de trabalho por turno, porém o hospital aloca 102. Neste caso, havia um excesso de 15.7 horas de trabalho ou 2.6 profissionais durante cada turno de trabalho de 6 horas, em média.

Apesar das vantagens oferecidas pelo uso do NAS para a documentação de atividades e cálculo de carga de trabalho, a sua implementação prática possui limitações quando executada de forma manual, como a demora para o preenchimento da tabela, a necessidade de treinamento para o uso da mesma, a grande quantidade de registros a serem considerados, o cálculo de pontuações, inconsistências nos dados, e outros (CAMARGO *et al.*, 2021).

Desta forma, uma ferramenta automatizada pode ser capaz de resolver os desafios acima, oferecendo maior rapidez e precisão no cálculo de pontuações, armazenando os dados de forma mais segura e eficiente, reduzindo a quantidade de treinamento requerido e reduzindo o tempo empregado pelos profissionais de enfermagem nas atividades de documentação de atendimento aos pacientes.

1.3 OBJETIVOS

O objetivo principal deste projeto é desenvolver uma solução que possa ser utilizada em UTIs para automatizar a captura de dados sobre o atendimento aos pacientes por parte da equipe de enfermagem, auxiliando nas tarefas de documentação de cuidados aos pacientes. Para alcançar este objetivo, foi desenvolvido um sistema IoT-fog que irá documentar o tempo consumido em cada atividade de atendimento aos pacientes, e estes dados, assim como a tabela NAS, serão utilizados para treinar uma rede neural que determinará a quantidade de profissionais de enfermagem em uma UTI para cada dia de trabalho.

1.3.1 Objetivos Específicos

- Desenvolvimento de um protótipo IoT com uma antena *Radio Frequency Identification* (RFID) de proximidade, que será instalado no leito de cada paciente e captura continuamente sinais RFID, de forma a detectar acessos da equipe de enfermagem aos leitos.
- Desenvolvimento de uma aplicação que com base nos acessos da equipe de enfermagem aos leitos é capaz de computar o tempo total gasto na atividade e determinar quais são os profissionais envolvidos. Posteriormente, os profissionais podem adicionar uma breve descrição das atividades exercidas neste horário por meio de um website.

- Desenvolvimento de um módulo de inteligência artificial que, a partir dos dados registrados e da tabela NAS, seja capaz de computar a quantidade de profissionais de enfermagem que deve ser alocada para cada dia de trabalho, e proporcionar melhor qualidade no atendimento aos pacientes.
- Desenvolvimento de um simulador capaz de gerar dados que possam ser usados para o treinamento do módulo de inteligência artificial. Estes dados correspondem aos atendimentos aos pacientes por parte da equipe de enfermagem, assim como informações sobre a quantidade de horas trabalhadas por dia.

1.4 PRINCIPAIS CONTRIBUIÇÕES

Será desenvolvido um protótipo IoT-fog que será capaz de computar o tempo que os enfermeiros empregam para desenvolver cada uma de suas atividades de atendimento a pacientes, e irá calcular a pontuação NAS para cada atividade e para cada turno de trabalho de cada enfermeiro. Também será implementado um módulo de inteligência artificial que seja capaz de estimar a carga de trabalho necessária para os profissionais de enfermagem em uma UTI, considerando a pontuação NAS como métrica.

Com o fim de obter dados para o treinamento do módulo de inteligência artificial, será desenvolvido um simulador que registre o tempo empregado em cada uma das atividades de enfermagem consideradas no NAS, todos os dias, para todos os pacientes, assim como os profissionais de enfermagem envolvidos.

Espera-se que este sistema seja capaz de estimar a carga de trabalho dos profissionais de enfermagem em uma UTI de forma satisfatória, evitando sobrecarregá-los, de forma a proporcionar maior qualidade no atendimento aos pacientes e, por extensão, uma melhoria no quadro clínico.

1.5 METODOLOGIA DE PESQUISA

Para o desenvolvimento deste trabalho, os principais métodos de pesquisa e trabalho são:

- Pesquisa de artigos recentes (preferencialmente a partir de 2016) nas áreas de IoT, IA, fog e demais áreas relevantes, no contexto de hospitais inteligentes, e considerando o NAS como métrica.
- Análise detalhada dos artigos mais correlatos e focados nesta proposta, de modo a compreender corretamente os conceitos e empregá-los na dissertação.
- Desenvolvimento e validação da solução proposta através de um protótipo, utilizando dados obtidos por meio de simulações ou dados reais, se possível.

- Realização de testes com o protótipo e análise dos resultados obtidos.
- Desenvolvimento de um módulo de inteligência artificial capaz de estimar a quantidade de profissionais de enfermagem necessária para o atendimento adequado dos pacientes em uma UTI.
- Realização de testes e validação dos resultados apresentados pelo módulo de inteligência artificial.

1.6 ESTRUTURA DO TRABALHO

Este trabalho está organizado da seguinte maneira: A seção 2 apresenta os tópicos da fundamentação teórica, a seção 3 apresenta a revisão bibliográfica e o estado da arte, assim como uma breve síntese dos artigos correlatos; a seção 4 apresenta a proposta e o seu desenvolvimento, a seção 5 detalha os experimentos realizados e os resultados obtidos, e a seção 6 apresenta as conclusões obtidas. Por fim, são apresentadas as referências bibliográficas consultadas para a confecção deste relatório, assim como os anexos.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são brevemente apresentados os conceitos base considerados para o desenvolvimento deste trabalho.

2.1 CLOUD COMPUTING

Cloud computing ou computação em nuvem é um paradigma computacional que consiste no agrupamento de máquinas virtuais com o objetivo de oferecer recursos computacionais de forma dinâmica para um usuário ou cliente, contando com um *Service Level Agreement* (SLA) ou termo de serviço entre o provedor da nuvem e o cliente (BASU *et al.*, 2018). A principal vantagem deste paradigma é o acesso a recursos computacionais que podem ser alocados rapidamente e com pouco esforço por parte do cliente, enquanto que o provedor da nuvem gerencia a instalação e manutenção das máquinas físicas, aumentando a eficiência e reduzindo custos para o cliente. De acordo com Hussein e Khalid (2016) e Basu *et al.* (2018), existem 3 principais modelos de infraestrutura a nível de serviço:

- *Software as Service* (SaaS) ou software como serviço, onde usuários acessam pela internet aplicativos que rodam na nuvem. Neste modelo o usuário final tem controle mínimo sobre a infraestrutura da nuvem.
- *Platform as Service* (PaaS) ou plataforma como serviço, proporciona um ambiente computacional que suporta o desenvolvimento, execução e gerenciamento de aplicativos. O provedor da nuvem tem controle sobre recursos como servidores, sistemas operacionais, armazenamento e rede, entre outros, enquanto que o cliente final apenas necessita configurar algumas opções no ambiente.
- *Infrastructure as Service* (IaaS) ou infraestrutura como serviço, consiste em oferecer recursos computacionais a nível de hardware, de forma virtual. O cliente tem controle sobre aspectos de baixo nível como sistemas operacionais ou partes da infraestrutura de rede. Este modelo oferece maior controle do que os modelos anteriores.

De acordo com Basu *et al.* (2018), nuvens também podem ser classificadas pelo modelo de implementação em quatro tipos:

- Nuvem pública, onde os recursos computacionais são oferecidos por uma entidade diretamente ao usuário. Enquanto este modelo proporciona vantagens como escalabilidade e confiabilidade, também proporciona desafios, especialmente de segurança, pois o cliente não tem conhecimento sobre aspectos de

armazenamento de dados, como a localização física destes ou as medidas de criptografia utilizadas.

- Nuvem privada, onde os recursos são oferecidos para uma determinada organização e a nuvem é operada pela mesma organização. Este modelo resolve os problemas de segurança da nuvem pública, mas também introduz novos desafios no gerenciamento da nuvem, como gerenciamento de armazenamento.
- Nuvem comunitária, onde os recursos são oferecidos para uma comunidade de organizações que compartilham algum interesse, e a nuvem é gerenciada pelas próprias organizações ou por uma empresa terceirizada. Entre os desafios deste modelo está o gerenciamento da nuvem e ainda questões de segurança ao ter dados espalhados por múltiplos domínios.
- Nuvem híbrida, que consiste na união de dois dos modelos anteriores, oferecendo vantagens como escalabilidade e baixo custo, e ao mesmo tempo atendendo a questões de segurança; porém ainda existem desafios de privacidade e integridade de dados quando os mesmos transicionam de um modelo privado para um público ou vice-versa.

2.2 INTERNET OF THINGS

De acordo com Lee *et al.* (2017), dispositivos *Internet of Things* (IoT) ou “coisas” (*things*) podem ser definidos como objetos munidos de uma interface de rede que permite a comunicação entre eles, com cada um destes possuindo um identificador de rede, como por exemplo, um endereço IP. Este paradigma é simples mas possui capacidades ilimitadas; pois dados de sensores podem ser acessados diretamente e utilizados para computar comandos para atuadores.

Apesar das múltiplas vantagens oferecidas, o paradigma IoT também introduz uma grande quantidade de desafios que devem ser resolvidos ao desenvolver uma infraestrutura IoT, como a heterogeneidade: Aplicativos e serviços IoT são desenvolvidos sem considerar padrões a serem seguidos pelas diversas empresas que os produzem. De forma semelhante, os protocolos de rede também não são padronizados, e entre eles podemos mencionar Wi-Fi, Bluetooth, ZigBee, Z-wave, e *Long Term Evolution* (LTE)

Outro dos desafios é a imensa quantidade de dados gerados pelos dispositivos sensores IoT, que deve ser processada e armazenada. Redes IoT também podem considerar estes dados para automatização ou otimização de algum sistema, por exemplo, para o controle ou otimização de recursos. Exemplos de serviços IoT existentes incluem casas inteligentes, cidades inteligentes, monitoramento de saúde, grids inteligentes e sistemas de trânsito inteligentes.


De acordo com Neshenko *et al.* (2019), outros desafios na área de IoT incluem:

- Segurança física: um adversário poderia obter acesso e controle sobre o dispositivo, ou danificar o firmware ou os dados armazenados no mesmo.
- Energia: dispositivos IoT geralmente possuem fontes limitadas de energia, e o processamento de uma alta quantidade de requisições pode drenar a energia disponível rapidamente.
- Autenticação inadequada: tendo em vista as limitações de processamento e energia, as implementações de sistemas de autenticação nestes dispositivos podem não ser suficientemente robustas.
- Criptografia inadequada: De forma semelhante à autenticação, as limitações dos dispositivos IoT podem não garantir um nível de segurança apropriado para a proteção de dados.
- Portas abertas desnecessariamente: Uma configuração inapropriada de uma rede IoT pode deixar portas acessíveis que um adversário pode utilizar para implementar ataques na rede.
- Controle de acesso insuficiente: A maioria dos dispositivos IoT não exigem o uso de senhas suficientemente seguras e após a instalação dos mesmos, também não requerem que a senha padrão seja mudada. Muitas vezes os usuários possuem permissões elevadas, permitindo que um adversário ataque toda a rede a partir de um único dispositivo.
- Gerenciamento de atualizações inapropriado: dispositivos IoT devem permitir atualizações frequentes para melhorar a segurança e oferecer melhor serviço, porém uma grande quantidade de fabricantes não garantem a atualização de software dos seus dispositivos.
- Programação insegura: Em múltiplos casos, *firmware* é implementado com vulnerabilidades conhecidas, usuários *root* como ponto de acesso principal, e outros; permitindo acesso a dispositivos para adversários maliciosos.

2.3 FOG COMPUTING

De acordo com Iorga *et al.* (2018), o paradigma de Fog computing, ou computação na névoa, é um modelo que facilita a implementação de aplicativos e serviços distribuídos e com baixa latência, e consiste em um conjunto de nós fog físicos e/ou virtuais localizados entre dispositivos IoT e a nuvem, conforme ilustrado na Fig. 1. Os nós fog podem ser organizados em clusters verticalmente, horizontalmente ou considerando a distância ou latência até os dispositivos IoT.

Figura 1 – Framework Fog-Cloud com suporte para dispositivos IoT.



Fonte – Iorga *et al.* (2018)

Uma das principais vantagens deste paradigma é que possibilita reduzir a latência entre requisições e respostas para os dispositivos IoT e proporciona recursos computacionais de forma local, podendo também acessar a nuvem quando necessário. Outras características que definem fog computing incluem:

- Baixa latência: Os nós fog possuem conhecimento sobre a sua própria localização e a latência de comunicação com outros nós, e geralmente estão localizados próximo dos dispositivos IoT, possibilitando baixa latência de rede.
- Distribuição geográfica: Enquanto o paradigma de computação na nuvem é geograficamente centralizado, fog conta com nós distribuídos fisicamente.
- Heterogeneidade: Fog suporta múltiplos protocolos de rede assim como o processamento e armazenamento de diferentes padrões de dados.
- Interoperabilidade: Fog suporta diferentes dispositivos e permite a cooperação entre os mesmos.
- Tempo real: Fog geralmente considera aplicativos de tempo real em lugar de processamento por lote.
- Escalabilidade, agilidade e adaptabilidade, considerando medidas como compartilhamento de recursos, mudanças na topologia da rede, e outras.

2.4 INTELIGÊNCIA ARTIFICIAL

Luger (2008) define inteligência artificial como sendo o ramo de ciências da computação que estuda a automatização do comportamento inteligente. Para Russell e Norvig (2009), IA tem como objetivo entender e construir entidades inteligentes, ou “máquinas com mentes”; assim como a automação de atividades geralmente associadas com a inteligência humana, ou seja, atividades que requerem inteligência quando realizadas por seres humanos.

O estudo de inteligência artificial inclui diversas áreas como lógica, probabilidade, matemática contínua, percepção, raciocínio, aprendizado e outras. De acordo com Goodfellow *et al.* (2016), os primeiros tipos de problemas a serem estudados são aqueles que são difíceis para seres humanos mas relativamente simples para computadores, estes problemas podem ser descritos por meio de regras lógico-matemáticas, e não requerem que a máquina tenha muito conhecimento sobre o mundo, por exemplo, para jogar xadrez.

O desafio está em problemas que são simples para os seres humanos, mas que são difíceis de descrever, como reconhecimento de palavras ou detecção de certas características em imagens. Para isto, o computador deve obter uma grande quantidade de conhecimento subjetivo e intuitivo, que pode ser difícil de articular em termos formais ou lógico-matemáticos.


De acordo com Došilović *et al.* (2018), na última década, sistemas de inteligência artificial obtiveram resultados em atividades antes consideradas impossíveis, como reconhecimento de imagens e voz, e jogos clássicos de tabuleiro, assim como nas áreas de medicina, finança, carros autônomos, bioinformática, e outras. Došilović *et al.* (2018) classificam os métodos de inteligência artificial em três categorias:

1. Interpretabilidade integrada ou transparentes: São os métodos que podem ser expressados claramente por meio de um diagrama do próprio modelo, e contempla os modelos de baixa complexidade e flexibilidade, como modelos lineares, árvores de decisão e modelos baseados em regras lógicas ou estatísticas.
2. Métodos post-hoc ou opacos: Devido a sua complexidade, estes modelos são considerados opacos (ou *black boxes*) e é difícil compreender a lógica empregada pelo sistema ao observar um diagrama ou descrição do mesmo. Esta classe de modelos inclui redes neurais artificiais, máquinas de vetor, *boosted trees*, florestas aleatórias e outros.
3. Métodos híbridos: combinam modelos transparentes com opacos para manter a interpretabilidade do sistema e alta performance. Exemplos incluem regressão logística com máquinas de vetor, ou árvores híbridas onde certas folhas podem ser substituídas por modelos opacos, entre outros.

2.4.1 Redes neurais

De acordo com Parveen *et al.* (2016), redes neurais artificiais são modelos matemáticos inspirados pelas redes neurais biológicas, e consistem em uma rede de neurônios artificiais interconectados em camadas. A Fig. 2 apresenta um diagrama de um neurônio artificial, destacando as três funções principais do mesmo: multiplicação, soma e ativação.

Figura 2 – Modelo básico de um neurônio artificial.




Fonte – Parveen *et al.* (2016)

Na fase de multiplicação, as entradas “*input*” são multiplicadas pelos seus pesos “*W*”, estes resultados parciais são então somados na próxima etapa e finalmente é aplicada uma função de ativação para gerar a saída do neurônio.

Dentre os modelos mais simples, podemos destacar as redes com uma única camada intermediária, denominadas redes neurais rasas, ou *Shallow Neural Networks*. Conforme ilustrado na Fig. 3, estas camadas possuem 5 componentes básicos:

- Sinais de entrada: São dados que serão utilizados para computar a saída, como por exemplo dados capturados por sensores.
- Camada de entrada: Cada neurônio desta camada recebe um sinal de entrada e o repassa para todos os neurônios da próxima camada.

Figura 3 – Modelo de uma rede neural rasa



Fonte – Parveen *et al.* (2016)

- Camada intermediária ou oculta: Recebe os sinais da camada de entrada, os processa e os envia aos neurônios da próxima camada.
- Camada de saída: Gera os sinais de saída da rede neural a partir dos sinais da camada intermediária.
- Sinais de saída: São os dados gerados pela rede neural.

Enquanto redes neurais rasas possuem apenas uma camada intermediária, redes neurais profundas, ou *Deep Neural Networks*, podem possuir múltiplas camadas intermediárias. De acordo com Capra *et al.* (2020), redes neurais profundas foram utilizadas em diversas áreas como visão computacional, estimativas no mercado financeiro, detecção de diversos tipos de câncer, robótica e gerenciamento de energia.

Uma das principais vantagens das redes neurais é que são capazes de aprender atividades inteligentes sem a necessidade de serem programados explicitamente, mas aprendem com base em exemplos. No aprendizado supervisionado, é fornecido um conjunto de treinamento, que consiste em uma lista de entradas e as suas saídas correspondentes. A rede neural utiliza as entradas para calcular as suas próprias saídas, que logo são comparadas com as saídas esperadas, e a discrepância entre elas é usada como base para adaptar os pesos dos neurônios da rede, com o objetivo de diminuir a discrepância durante o próximo ciclo de aprendizado.

Aprendizado não supervisionado consiste em encontrar padrões similares nos dados e agrupá-los com base em tais padrões. Esta técnica é especialmente útil quando não é possível determinar as saídas com base nas entradas, ou para realizar o *clustering* de dados.

De acordo com Parveen *et al.* (2016), Redes neurais foram utilizadas para diagnósticos médicos, devido à sua habilidade de aprender e aplicar conhecimentos humanos, como a classificação de *Plasmodium* para classificar a gravidade de casos

de malária. Também demonstraram ser altamente eficientes para diagnosticar casos onde o paciente tem vários sintomas desconexos.

2.5 GERENCIAMENTO DE RECURSOS HUMANOS NA ENFERMAGEM

O uso de indicadores para avaliar objetivamente a condição clínica de pacientes e os cuidados necessários é indispensável para melhorar a relação custo-benefício em modelos de assistência à saúde, e em particular na área de enfermagem, onde uma quantidade excessiva de profissionais alocados pode gerar gastos desnecessários, e uma quantidade insuficiente pode aumentar o tempo que os pacientes permanecem internados e reduzir a qualidade do tratamento dos mesmos.

Gonçalves *et al.* (2007) realiza uma análise detalhada das ferramentas desenvolvidas para avaliar a carga de trabalho dos profissionais de enfermagem, e em particular na aplicação do NAS (Nursing Activities Score) no Brasil, assim como os diversos problemas encontrados.

No Brasil, os órgãos responsáveis por normatizar e fiscalizar as atividades de enfermagem são: o Conselho Federal de Enfermagem (COFEN) e os seus respectivos Conselhos Regionais de Enfermagem (CORENs). É responsabilidade dos CORENs disciplinar, fiscalizar e propor medidas para melhorar o exercício da profissão de enfermagem (COFEN, 2022).

As atividades que devem ser documentadas são regulamentadas pela resolução COFEN Nº 429/2012, que especifica (COFEN, 2012):

Art. 1º É responsabilidade e dever dos profissionais da Enfermagem registrar [...] as informações inerentes ao processo de cuidar e ao gerenciamento dos processos de trabalho, necessárias para assegurar a continuidade e a qualidade da assistência.

Art. 2º Relativo ao processo de cuidar, e em atenção ao disposto na Resolução nº 358/2009, deve ser registrado no prontuário do paciente:

[...]

§c) as ações ou intervenções de enfermagem realizadas face aos diagnósticos de enfermagem identificados.

Em relação às ferramentas que podem ser utilizadas, a resolução COFEN 543/2017 resolve (COFEN, 2017):

Art. 1º Estabelecer [...] os parâmetros mínimos para dimensionar o quantitativo de profissionais das diferentes categorias de enfermagem para os serviços/locais em que são realizadas atividades de enfermagem.

Parágrafo único – Os referidos parâmetros representam normas técnicas mínimas, constituindo-se em referências para orientar os gestores, gerentes e enfermeiros dos serviços de saúde, no planejamento do quantitativo de profissionais necessários para execução das ações de enfermagem.

Art. 2º O dimensionamento do quadro de profissionais de enfermagem deve basear-se em características relativas:

[...]

II – ao serviço de enfermagem: aspectos técnico-científicos e administrativos: dinâmica de funcionamento das unidades nos diferentes turnos; modelo gerencial; modelo assistencial; métodos de trabalho; jornada de trabalho; carga horária semanal; padrões de desempenho dos profissionais; índice de segurança técnica (IST); proporção de profissionais de enfermagem de nível superior e de nível médio e indicadores de qualidade gerencial e assistencial;

2.5.1 Nursing Activities Score

De acordo com Queijo e Padilha (2009), uma das ferramentas mais reconhecidas na literatura internacional para medir objetivamente a carga de trabalho de enfermagem em uma UTI é o *Therapeutic Intervention Scoring System* (TISS), que foi desenvolvida por Cullen et al. do *Massachusetts General Hospital* de Boston em 1974, e era composta por uma lista de 57 intervenções terapêuticas.

Em 1983, o TISS foi expandido para 76 intervenções terapêuticas, passando a ser conhecido como TISS-76. 16 anos depois, Miranda et al. do *University Hospital of Groningen* da Holanda modificaram o TISS-76 com o objetivo de tornar este instrumento mais prático e atualizado. O resultado é o TISS-28, que consiste de uma lista de 28 itens distribuídos em sete categorias: atividades básicas, suporte ventilatório, cardiovascular, renal, neurológico, metabólico e intervenções específicas.

Uma das principais críticas do TISS-28 é que esta ferramenta considera apenas as atividades essenciais para os pacientes, não contemplando outras tarefas, como atividades administrativas e de suporte às famílias. Tendo estas críticas em mente, o TISS-28 foi novamente modificado, passando a ser conhecido como *Nursing Activities Score* (NAS).

Desta forma, o NAS é um instrumento que permite avaliar a carga de trabalho dos profissionais de enfermagem em uma UTI, constituído por 23 itens. De acordo com Queijo e Padilha (2009), esta ferramenta foi validada por um estudo de 99 UTIs (Unidades de Terapia Intensiva) em 15 países.

O NAS considera itens pontuados e mede o tempo de execução de diversas atividades de atendimento ao paciente por parte da equipe de enfermagem, e a soma da pontuação destes itens corresponde ao tempo empregado pelos enfermeiros para executar as funções da UTI durante o dia, sendo que 100 pontos correspondem a 24 horas de trabalho de um profissional. De acordo com Gonçalves *et al.* (2007), NAS é capaz de explicar como 81% do tempo de cada enfermeiro é empregado, enquanto que modelos anteriores como o TISS-28 apenas conseguem 43%.

De acordo com Queijo e Padilha (2009), NAS foi traduzido e adaptado para a língua portuguesa, e aplicado em 200 pacientes de UTI. Após uma detalhada análise estatística, foi demonstrado que os 23 itens do NAS se comportam de forma independente entre si, e esta ferramenta demonstrou ser confiável e válida, podendo ser implementada em UTIs brasileiras. A tabela NAS pode ser encontrada no anexo A.

No Brasil, a resolução COFEN 543/2017 exige que os enfermeiros utilizem instrumentos para medir a quantidade de trabalho de atendimento necessário para cada paciente, e indica parâmetros mínimos que devem ser cumpridos.

O COREN de São Paulo foi consultado sobre a recomendação de ferramentas para auxiliar nesta tarefa, como o TISS, NAS e *Nine Equivalents of Nursing Manpower use Score* (NEMS); e respondeu com o parecer COREN-SP Nº 062/2011, que recomenda (COREN-SP, 2011):

O resultado dos escores TISS, TISS-28, NEMS, NAS, são obtidos por meio de pontos, quanto maior o número obtido indica que mais intervenções terapêuticas foram empregadas, maior gravidade do paciente e a necessidade de trabalho de enfermagem. [...] Vale lembrar, que atualmente observa-se na literatura especializada uma tendência para utilização do NAS quando comparado com o TISS e NEMS, sendo considerado um índice capaz de estimar o quantitativo de pessoal, como também, de auxiliar no cálculo orçamentário do Serviço de Enfermagem, ou seja, se quiser investir nessa área, trabalhe com o NAS, este escore contempla 80,8% das atividades de enfermagem, superando a abrangência de 43,3% do TISS-28.

3 REVISÃO BIBLIOGRÁFICA E ESTADO DA ARTE

A fim de avaliar a relevância da pesquisa nesta área, uma revisão bibliográfica foi realizada com auxílio das ferramentas de pesquisa *Google Scholar*, *IEEE Explorer* e *ScienceDirect*, considerando as palavras chave deste trabalho e resultados entre 2016 e 2021. Os resultados desta pesquisa são ilustrados na Tab. 1.

Palavras-chave	Google Scholar	IEEE Explorer	ScienceDirect
IoT	264,000	53,596	27,251
NN	627,000	187,906	128,508
N	741,000	2,542	108,894
SH	2,630	90	204
NAS	1,150	1	55
IoT, NN	29,000	1,847	5,931
IoT, N	13,700	67	5,931
IoT, NAS	4	0	0
NN, N	16,700	0	1,205
NN, SH	343	2	59
NN, NAS	3	0	0
IA, N	19,000	278	1,368
IA, NAS	9	0	0
N, SH	557	4	43
SH, NAS	1	0	0
IoT, NN, N	1,830	0	128
IoT, NN, SH	223	6	45
IoT, NN, NAS	0	0	0
IoT, IA, N	5,780	17	0
IoT, IA, NAS	0	0	0
IA, N, NAS	4	0	0
N, SH, NAS	1	0	0
IoT, NN, N, NAS	0	0	0
IoT, NN, N, NAS	0	0	0
IoT, NN, SH, NAS	0	0	0
IoT, IA, N, NAS	0	0	0

Tabela 1 – Sumário da revisão bibliográfica, indicando a quantidade de resultados por cada combinação de palavras chave.

Fonte – De autoria própria.

Legenda para a Tab. 1:

- IoT = *Internet of Things* ou Internet das Coisas
- NN = *Neural Networks* ou redes neurais
- AI = *Artificial Intelligence* ou inteligência artificial

- N = *Nursing* ou enfermagem
- SH = *Smart Hospital* ou hospital inteligente
- NAS = *Nursing Activities Score*

Dentre estes artigos, foram selecionados os mais correlatos para a sua posterior leitura, priorizando aqueles que se encaixam em uma combinação de palavras chave, e foram considerados como base teórica para a redação desta dissertação. Estes artigos são brevemente sintetizados a seguir:

Em Yu *et al.* (2012) é proposto um modelo de hospital inteligente que tem como objetivo mitigar as desvantagens dos sistemas de informação dos hospitais, como pontos fixos de informação, registro de informações de forma manual, rede não flexível, sistemas relativamente independentes em cada departamento, entre outros. Este sistema consiste em três camadas: a primeira captura dados sobre médicos, enfermeiros e pacientes, assim como farmacêuticos e equipamento. Estes dados são capturados por meio de sensores IoT e RFID (*Radio Frequency Identification*) e repassados para a camada de rede, que os disponibiliza para funcionários e pacientes. Finalmente, a camada de aplicativos apresenta à gerência análises de doenças, pacientes, dados clínicos, consumo de medicamentos, e outros.

Guinard (2006) apresenta estatísticas de como sistemas inadequados causam erros médicos e mortes de pacientes, e como sistemas RFID podem ser utilizados para prevenir estas fatalidades. É proposto aplicar uma tag RFID nos equipamentos médicos, funcionários do hospital (crachá inteligente), pacientes (pulseira inteligente), históricos de pacientes, medicamentos e bolsas de sangue. Leitores RFID são aplicados nas entradas e saídas dos hospitais, em galerias e escritórios, e em cada funcionário (por exemplo, no celular dos mesmos). Este sistema de tags RFID evita erros de identificação dos pacientes, que poderiam causar diagnósticos errados, erros de medicação, transfusões de sangue de tipo incompatível com o paciente, assim como cirurgias erradas ou no paciente incorreto. Também facilita a localização de um funcionário ou dos arquivos de histórico do paciente, e dificulta o furto de equipamentos médicos.

Khanade *et al.* (2017) apresentam uma análise do nível de stress e fadiga de enfermeiros em uma UTI, por meio de medidas subjetivas como questionários, entrevistas ou pesquisas, além de medidas fisiológicas como frequência cardíaca. Os autores observam que apesar destas ferramentas, não existem sistemas validados para monitorar ou mitigar os efeitos do stress e fadiga dos enfermeiros. São realizadas entrevistas para detectar as situações com alto nível de stress, e entre estas, as tarefas de documentação foram nominadas de forma unânime, devido à quantidade de detalhes a serem registrados em pouco tempo, sendo necessário interromper estes processos para realizar outras atividades; assim como lembrar detalhes de atividades de enfermagem ao longo do dia para a sua posterior documentação. Em relação à carga de trabalho,

os enfermeiros comentaram ser forçados a priorizar certas atividades e pospor outras quando a carga de trabalho é alta.

Em Padilha *et al.* (2010) é apresentado um estudo sobre a carga de trabalho em uma UTI com 25 macas e 68 pacientes, durante um mês, nas 24 horas do dia, conforme sugerido por Miranda *et al.* (2003). Os dados são coletados de forma manual sobre as diferentes atividades realizadas pelos enfermeiros, considerando turnos de trabalho de 6 horas e 17 enfermeiros em cada turno. Após uma análise dos dados por meio de um software estatístico, o número de pacientes variou de 18 a 25, com média de 22.7 pacientes por dia. De acordo com o NAS, são necessárias 86.3 horas de trabalho em média; porém foram alocadas 102 horas de trabalho em cada turno. Desta forma, foi concluído que, em média, havia um excesso de 15.7h de trabalho ou 2.6 profissionais durante cada turno de trabalho de 6 horas.

Em Wüller *et al.* (2018) é proposto um aplicativo para óculos inteligentes (ou *Smart Glass*) que tem como objetivo auxiliar na documentação de tratamento de feridas por parte de enfermeiros. *Smart Glasses* foram escolhidos pois possibilitam documentar as atividades sem ser necessário pausá-las e de forma higiênica. Foi observado que esta ferramenta é útil para documentar imagens mas não é prática para a digitação de dados, pois a tela e as teclas são pequenas; e desta forma é sugerido utilizar outro dispositivo para complementar este sistema, como um tablet ou computador. Também é mencionada a possibilidade de integrar um sistema de anotações para auxiliar a memória e a comunicação com outros profissionais por meio deste dispositivo.

Morales (2020) apresenta o desenvolvimento de um sistema inteligente em uma UTI que utiliza sensores médicos IoT para capturar dados sobre os pacientes, como o pulso, taxa de respiração e pressão arterial. Estes dados são enviados a um “concentrador de sinais” e apresentados em um display inteligente para a fácil consulta. Os dados são agregados, analisados e priorizados, e somente os dados mais relevantes são apresentados aos enfermeiros, facilitando tomar decisões sobre o atendimento aos pacientes. Em total, são apresentadas 30 variáveis relacionadas à saúde do paciente, e o projeto é desenvolvido com especial atenção a boas práticas de usabilidade como interfaces simples, o que reduz a carga de trabalho mental executado pelos enfermeiros, reduzindo o stress e aumentando a eficiência dos mesmos.

Em Guo *et al.* (2015) é considerado um sistema *Clinical Activities Tracking System* (CATS), que foi desenvolvido para registrar atividades de enfermagem nos leitos de UTI automaticamente, por meio de 4 sensores que detectam a presença e a localização de enfermeiros. O TISS-28 (*Therapeutic Intervention Score System*) e o NAS (*Nursing Activities Score*) são usados para calcular a carga de trabalho dos enfermeiros em uma UTI; porém, estes cálculos foram realizados de forma manual por um pesquisador. O foco principal deste artigo é a validação deste sistema, na UTI do *Christchurch Hospital*.

Tendo em consideração que o monitoramento contínuo de sinais vitais é essencial para oferecer uma alta qualidade de atendimento ao paciente mas estas medições requerem uma alta quantidade de tempo, Chen *et al.* (2020) desenvolveram um sistema IoT para monitorar sinais vitais de pacientes por meio de 3 dispositivos Raspberry pi. Estes dispositivos capturam os dados e os enviam a uma página web por meio de TCP/IP ou Wifi, e os disponibiliza às famílias dos pacientes e aos enfermeiros. Também são usadas tecnologias como VoIP e TLS/SSL para prover serviços de comunicação de voz e segurança de dados. Este sistema é portátil, econômico, seguro e energeticamente eficiente, tendo como objetivo principal facilitar a execução das atividades de monitoramento de dados vitais, tornando este processo mais simples e conveniente para os profissionais de saúde e, desta forma, melhorando a eficiência e a qualidade de atendimento, e reduzindo a carga de trabalho dos enfermeiros.

Leitos de hospitais geralmente possuem um sistema que permite aos pacientes chamar enfermeiros ou outros profissionais remotamente. Tendo em consideração este sistema, Nursuwars e Rahmatulloh (2019) propõem um sistema IoT com RFID que armazena estatísticas sobre os atendimentos, como número de chamadas, tempo entre a chamada e o atendimento, e o nome do enfermeiro envolvido; estes dados podem ser usados para avaliar a qualidade do atendimento no hospital. O sistema consiste em dois nós IoT para cada paciente, instalados um próximo ao leito e o outro no banheiro, onde uma chamada partindo do nó do banheiro é considerado como um alerta de emergência, e uma chamada no leito é considerado um atendimento de rotina. Ao atender a uma chamada, o enfermeiro aproxima o seu cartão RFID ao dispositivo IoT, permitindo identificar o enfermeiro e desabilitando o alarme, e estes dados são enviados a um servidor web.

Tendo em consideração que os principais desafios do uso da ferramenta NAS de forma manual incluem a demora no preenchimento da tabela, a quantidade insuficiente de profissionais treinados para preenchê-la, a necessidade de realizar cálculos de forma manual e a presença de inconsistências; Camargo *et al.* (2021) desenvolvem o sistema NAS Tecnologia em Nuvem[®]. Este sistema consiste em uma planilha eletrônica e na coleta e armazenamento de dados, considerando os requisitos de proteção de dados descritos pela *Health Insurance Portability and Accountability Act* (HIPPA). Este sistema é *cross-browser* e que tem como objetivo otimizar a alocação de recursos humanos em uma UTI e, por sua vez, diminuir estresse, *burnout* e conflitos internos entre os enfermeiros. Foi validado nas unidades de cuidados críticos do Hospital de Clínicas de Porto Alegre (HCPA), onde a versão piloto foi implementada na Unidade de Recuperação Pós-Anestésica, com 5 leitos e 7 enfermeiros, durante o primeiro semestre de 2013. Até o final de 2015 o serviço foi expandido para 12 unidades de atendimento a pacientes críticos, contando com mais de 200 enfermeiros e centenas de dados por dia.

Moraes *et al.* (2016) descrevem uma implementação do NAS em uma UTI de recuperação pós-anestesia do Hospital de Clínicas de Porto Alegre (HCPA). Este sistema consiste de um módulo gerencial, utilizado para a coleta de dados de forma manual, e um operacional, que pode ser instalado em dispositivos móveis com Wi-Fi. Estes aplicativos foram desenvolvidos utilizando as ferramentas Google® Apps (Google Forms, Google Spreadsheets, Google Groups and Google sites). Como resultado, este estudo obteve que a carga de trabalho média nesta UTI nas primeiras 24 horas monitoradas é de 91.75 ± 18.2 pontos NAS, o que corresponde aproximadamente a 22 horas de trabalho.

Com o fim de obter estatísticas relevantes sobre a execução de cada uma das atividades de enfermagem do NAS, foram considerados estudos sobre a aplicação do NAS em UTIs, estes sendo: Reich (2015), que considera três UTIs; Carmona-Monge (2013), com duas UTIs; Conishi e Gaidzinski (2007), com uma UTI; Bruyneel *et al.* (2021), em uma UTI de Covid-19; Camuci *et al.* (2014), em uma UTI de queimados; e Nogueira (2015), em uma UTI de trauma.

A Tab. 2 apresenta um sumário dos artigos correlatos acima.

Artigo	IoT	LOC	Métrica	Doc	IA	
Yu <i>et al.</i> (2012)	X	X	Subjetiva NAS	X	X	
Guinard (2006)	X	X				
Khanade <i>et al.</i> (2017)						
Padilha <i>et al.</i> (2010)						
Wüller <i>et al.</i> (2018)	X		NAS/TISS-28	X		
Morales (2020)	X				X	X
Guo <i>et al.</i> (2015)	X	X			X	
Chen <i>et al.</i> (2020)	X		NAS	X		
Nursuwars e Rahmatulloh (2019)	X				X	X
Camargo <i>et al.</i> (2021)					X	
Moraes <i>et al.</i> (2016)			NAS	X	X	
Proposta atual	X	X	NAS	X	X	

Tabela 2 – Sumário dos artigos correlatos e a sua relação com a proposta atual.

Fonte – De autoria própria.

Legenda para a Tab. 2:

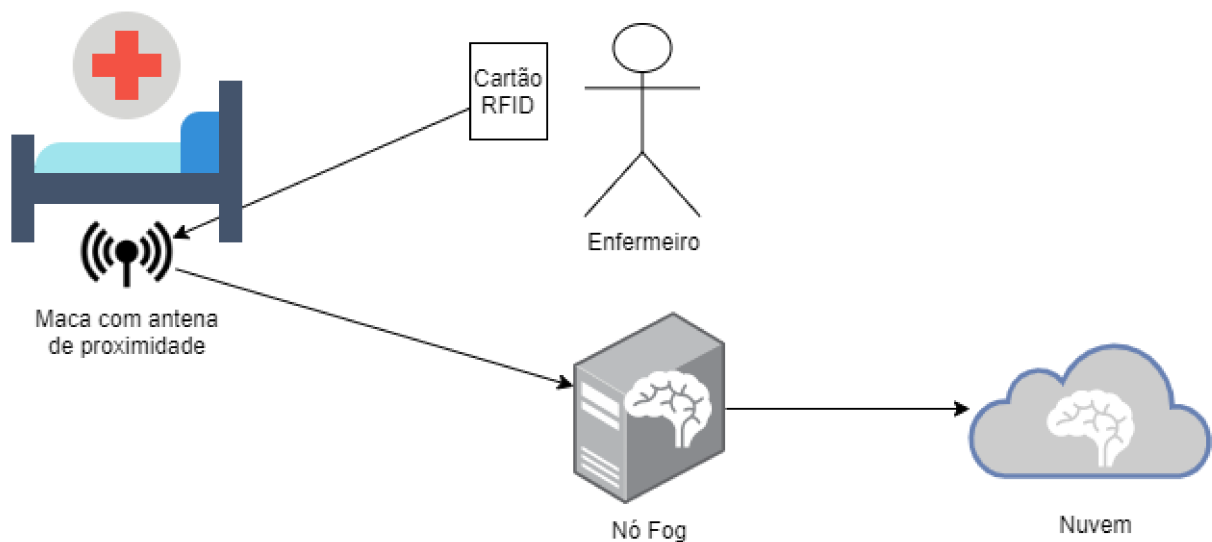
- IoT: Indica se internet das coisas é considerada.
- LOC: Indica se *location awareness* é considerado.
- Métrica: Indica se é considerada uma métrica para a carga de trabalho dos enfermeiros, onde:
 - Subjetiva: Indica que são consideradas apenas medidas subjetivas, como entrevistas e questionários.

- NAS e/ou TISS-28: Indica o uso de métricas objetivas: NAS e/ou TISS-28.
- Doc: Indica se são considerados métodos para automatizar a documentação de procedimentos de enfermagem ou atendimentos aos pacientes.
- IA: Indica se são propostas técnicas de IA para o análise dos dados e/ou a tomada automatizada de decisões.

4 PROPOSTA E DESENVOLVIMENTO

É proposta uma rede IoT-fog para a captura de dados sobre o atendimento aos pacientes por parte dos enfermeiros, considerando um dispositivo IoT em cada leito que detecta atendimentos aos pacientes e os comunica a um módulo fog, que preprocessa estes dados e os envia à nuvem, onde redes neurais são usadas para gerar uma estimativa da quantidade ideal de enfermeiros a serem alocados para o funcionamento ideal de uma UTI. A Fig. 4 apresenta uma arquitetura de referência do sistema proposto.

Figura 4 – Arquitetura de referência do sistema proposto



Fonte – De autoria própria.

Será fornecido para cada profissional de enfermagem um cartão RFID (que pode ser o próprio crachá do funcionário), e cada leito terá um dispositivo IoT munido de uma antena RFID que detecta quando a equipe de enfermagem se aproxima do leito para realizar uma atividade de atendimento ao paciente. Este dispositivo IoT irá detectar o ID dos enfermeiros e técnicos de enfermagem por meio do cartão RFID, assim como os horários em que se aproximaram e se afastaram do leito, e irá enviar estes dados para o nó Fog.

O nó fog, por sua vez, irá utilizar os dados enviados pelo dispositivo IoT do leito para computar o tempo empregado para realizar a tarefa, considerando que algumas atividades podem demandar que os profissionais de enfermagem se afastem do leito e se aproximem novamente, ou demandar mais de um profissional de enfermagem. Uma vez computado o tempo e os profissionais envolvidos na atividade, estas informações são repassadas à nuvem.

Considerando que cada leito possui um dispositivo IoT e, a cada certo intervalo de tempo (100 ms, por exemplo), este envia um pacote informando quais profissionais de enfermagem se encontram dentro do raio de leitura, um único dispositivo pode gerar uma alta quantidade de dados. Este problema é mais pronunciado considerando que UTIs geralmente possuem múltiplos leitos. Desta forma, o objetivo do dispositivo fog é sintetizar estes dados, reduzindo a quantidade de pacotes a serem enviados à nuvem para armazenamento.

Finalmente, a nuvem recebe e armazena uma série de registros de atendimento ao paciente, e os utiliza para computar a pontuação diária de cada paciente, considerando o NAS como métrica. Um módulo de inteligência artificial na nuvem irá utilizar o histórico destas atividades pontuadas para estimar a quantidade de profissionais de enfermagem que precisam ser alocados por dia para oferecer um atendimento satisfatório aos pacientes.

4.1 IOT

Com o objetivo de auxiliar na documentação de atendimentos aos pacientes por parte da equipe de enfermagem, foi desenvolvido um protótipo de leito inteligente IoT, cujo diagrama é apresentado na Fig. 5.

Este protótipo possui uma antena RFID de 900 MHz de frequência, que é capaz de ler cartões RFID em um determinado raio. Ao alterar a potência do sinal, é possível modificar o raio de coleta de dados, até o máximo de 6 metros. Considerando a possível proximidade dos leitos entre si, para este protótipo foi escolhido um raio de 2 metros.

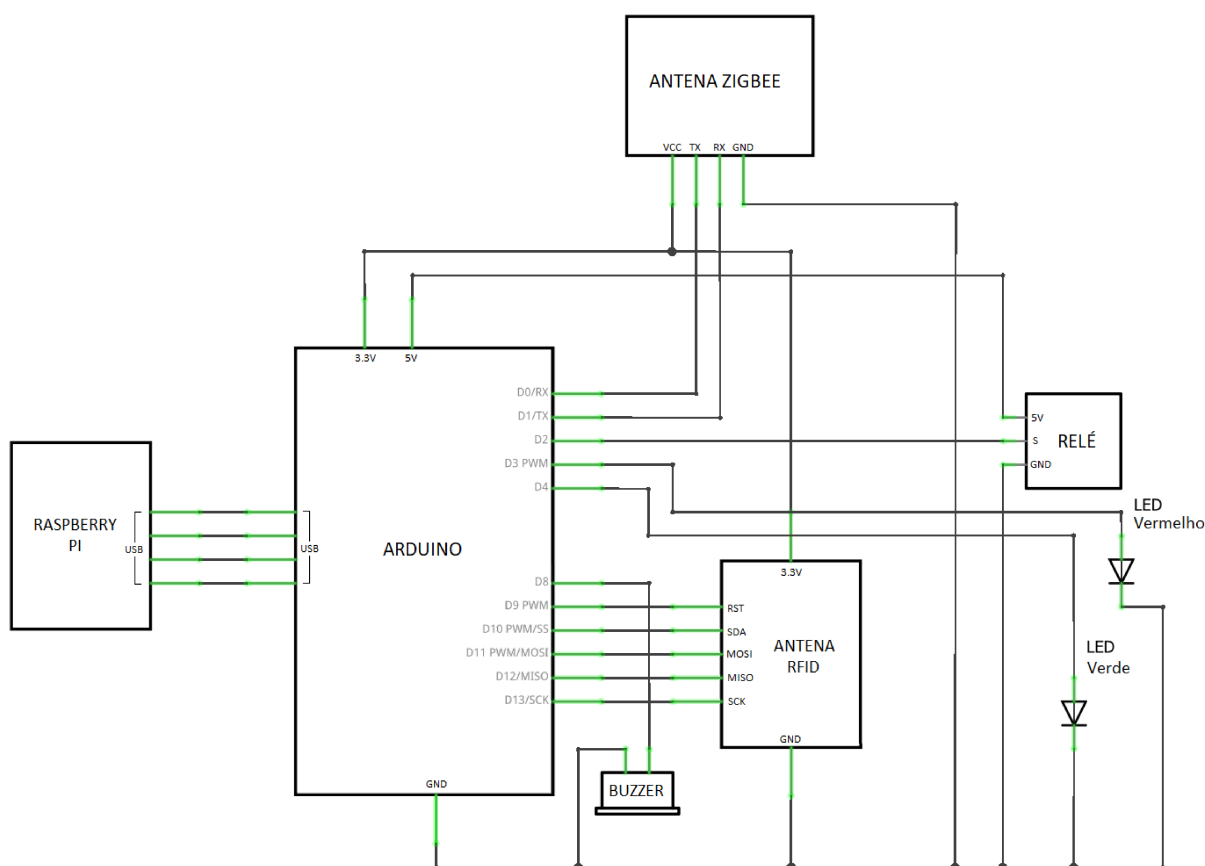
Ao detectar que um cartão de um profissional de enfermagem está dentro do raio de leitura, é considerado que um atendimento ao paciente está em processo, e um buzzer e um LED verde são acionados para informar audiovisualmente ao enfermeiro que esta atividade está sendo documentada. Também é acionado um relê, que pode ser utilizado para acionar automaticamente outros dispositivos que podem auxiliar durante o atendimento ao paciente, como uma lâmpada, por exemplo.

Finalmente, é considerado um LED vermelho que indica que o dispositivo está ligado e aguardando; assim como um Raspberry Pi, Arduino e uma antena Zigbee, que são utilizados para o processamento e envio de dados ao nó Fog.

4.2 SIMULADOR

Considerando que para treinar a rede neural é necessária uma boa quantidade de dados, foi desenvolvido um sistema para simular atendimentos aos pacientes. Para implementar a simulação dos dados, foi utilizada a linguagem Python, por possuir uma excelente gama de pacotes que facilitam significativamente o desenvolvimento de

Figura 5 – Diagrama do dispositivo IoT proposto.



Fonte – De autoria própria.

simulações, e ao mesmo tempo mantendo uma boa performance. Os pacotes utilizados incluem:

- *math*, utilizado para funções matemáticas simples como raiz quadrada.
- *scipy.stats*, utilizado para gerar números aleatórios segundo diferentes distribuições estatísticas, como T-Student, normal e exponencial.
- *random*, para gerar números segundo a distribuição uniforme e tomar decisões aleatórias simples.
- *datetime*, que permite realizar manipular e realizar cálculos com dados de data e hora de forma simples.
- *pickle*, utilizado para salvar as simulações em arquivos.
- *numpy*, para manipular grandes quantidades de dados de forma eficiente.

O algoritmo 4.2.1 apresenta o algoritmo principal da simulação, onde, se o *flag* da linha 1 receber o valor *False*, será carregada uma simulação já existente no *path* especificado na linha 2; mas se este *flag* receber o valor *True*, será criada uma nova simulação com os parâmetros especificados nas linhas 4 a 9, e será salva no *path* da linha 2.

```
1 nova_simulacao = False
2 simulacao_path = 'simulacoes/simulacao1'
3 if nova_simulacao:
4     pacientes = simular_pacientes(50)
5     data_inicio_sim = datetime.datetime(year=2022, month=1, day=1)
6     total_dias = 365
7     enfermeiros = simular_enfermeiros(7*50)
8     tecnicos = simular_tecnicos(10*50)
9     horas_turno = 12
10    atendimentos = simular_atendimentos(distribuicao='norm')
11    salvar_simulacao(simulacao_path)
12
13 else:
14    carregar_simulacao(simulacao_path)
15
16 exportar_ativs_por_diag() # usado pra nn_classification
17 exportar_duracao_ativs_por_diag() # usado pra nn_regression
18 calcular_resultados()
```

Algoritmo 4.2.1 – Código principal do simulador. Fonte: De autoria própria.

A função da linha 4 cria uma lista de pacientes com nomes genéricos: paciente1, paciente2, e assim por diante. O argumento desta função é a quantidade de pacientes a serem criados. A linha 5 define a data de início da simulação, neste caso o primeiro de janeiro de 2022, e a linha 6 define a quantidade total de dias que serão simulados, começando na data definida na linha anterior.

As linhas 7 e 8 criam uma lista de enfermeiros e uma de técnicos de enfermagem, com nomes genéricos e um tag RFID que identifica cada um deles. Esta tag RFID é um número hexadecimal de 8 dígitos, onde o primeiro dígito é 0 para os enfermeiros e 1 para os técnicos de enfermagem, e os demais 7 dígitos são gerados aleatoriamente. Este tag RFID corresponde ao número do crachá RFID que é fornecido a cada profissional.

A linha 9 indica a quantidade de horas que correspondem a um turno de trabalho. Para esta simulação foi considerado uma jornada de trabalho 12x36, ou seja, 12 horas de trabalho seguidas de 36 horas de descanso; este modelo de jornada de trabalho foi escolhido por ser comum para profissionais de enfermagem no Brasil.

A linha 10 simula os atendimentos aos pacientes, considerando os parâmetros definidos acima e a distribuição estatística que é passada como parâmetro. Esta função é detalhada no algoritmo 4.2.2, e a linha 11 salva esta simulação no *path* definido na linha 2. Por outro lado, caso tenha sido optado por carregar uma simulação existente, a linha 14 representa as funções que realizam esta tarefa.

A linha 16 exporta as atividades simuladas para um arquivo CSV. Para cada atendimento é exportado o código do paciente, o dia em que foi realizado o atendimento, o diagnóstico do paciente, e as atividades que foram executadas. Este arquivo será ser usado posteriormente para o treinamento da primeira rede neural proposta, que é detalhado na seção 4.3.2.

A linha 17 exporta as atividades de forma simular à linha 16, porém, em lugar de exportar quais atividades foram executadas, é exportada a duração de cada atividade; e aquelas que não foram executadas são salvas como tendo duração zero. Este arquivo CSV será utilizado para o treinamento da segunda rede neural abordada neste trabalho, que é detalhada na seção 4.3.3.

A linha 18 realiza uma comparação dos dados simulados com as estimativas obtidas pelas duas soluções de redes neurais consideradas. Estes diagramas são detalhados no capítulo 5. Também foram implementadas funções para exportar os demais dados em formato CSV, e também para calcular resultados e criar os gráficos apresentados no capítulo 5.

O algoritmo 4.2.2 apresenta uma versão simplificada do algoritmo do método `simular_atendimentos`, onde a linha 6 seleciona quais atividades da lista NAS serão executadas no dia em questão, para o paciente em questão; a seção 4.2.1 esclarece como esta seleção é feita. A linha 7 simula a execução das atividades selecionadas na linha 6, e a duração destas atividades segue a distribuição estatística passada como argumento.

A linha 8 computa uma lista de enfermeiros e técnicos que estão disponíveis para trabalhar naquele dia, considerando um dia de descanso para cada dia trabalhado; conforme a jornada de trabalho 12x36. Nas linhas 9 e 10 é calculado o tempo até a próxima pausa para o almoço e o tempo até o final do expediente, e as linhas 13 e 14 proporcionam 30 minutos de pausa para o almoço, se necessário. As linhas 16 e 17 escolhem um novo enfermeiro e técnico de enfermagem quando o expediente dos atuais chega ao fim. Estes novos profissionais devem estar marcados como disponíveis, segundo a linha 8.

As linhas 19, 20 e 21 consideram que algumas atividades somente podem ser executadas por enfermeiros e não por técnicos de enfermagem; desta forma, para a atividade atual, o técnico não é considerado.

As linhas 23 a 31 escolhem aleatoriamente se a atividade atual será executada somente por um enfermeiro, somente por um técnico de enfermagem, ou por ambos

```
1 def simular_atendimentos(distribuicao):
2
3     for paciente in pacientes:
4         for dia in dias:
5
6             atividades = escolher_atividades(paciente.get_diagnostico())
7             lista_nas = simular_nas(atividades, distribuicao)
8             determinar_enfermeiros_e_tecnicos_disponiveis()
9             prox_almoco = data_inicio_turno + (horas_turno/2)
10            fim_turno = data_inicio_turno + horas_turno
11
12            for atividade in atividades:
13                if data_inicio_atividade > prox_almoco:
14                    data_inicio_atividade += 30 minutos
15
16                if data_inicio_atividade > fim_turno:
17                    selecionar_enfermeiro_e_tecnico_novos()
18
19                if atividade in ['7a', '7b', '8a', '8b']:
20                    # atividades executadas somente pelo enfermeiro
21                    enfermeiro = enfermeiro_atual
22
23                else: # enfermeiro, tecnico ou ambos
24                    aux = random.randint(0, 3)
25                    if aux == 0:
26                        enfermeiro = enfermeiro_atual # somente o
27                        ↪ enfermeiro
28                    elif aux == 1:
29                        tecnico = tecnico_atual # somente o tecnico
30                    else: # enfermeiro e tecnico
31                        enfermeiro = enfermeiro_atual
32                        tecnico = tecnico_atual
33
34                atendimento = Atendimento(paciente, data_inicio_atividade,
35                ↪ data_fim_atividade, atividade, pontos_nas(atividade),
36                ↪ enfermeiro, tecnico)
37                atendimentos.append(atendimento)
38
39            return atendimentos
```

Algoritmo 4.2.2 – Pseudocódigo para simular os atendimentos. Fonte: De autoria própria.

simultaneamente.

A linha 33 cria um novo atendimento, considerando o nome do paciente, data e hora do inicio e de fim do atendimento, o identificador da atividade executada segundo a tabela NAS, a quantidade de pontos correspondentes à duração desta atividade con-

forme computado na linha 7, e o código do enfermeiro e/ou do técnico de enfermagem que realizaram o atendimento; logo, a linha 34 adiciona o atendimento recém criado na lista de atendimentos executados.

Finalmente, a execução do código retorna à linha 12, repetindo a execução para as demais atividades do dia, e uma vez concluídas, volta às linhas 3 e 4, repetindo o algoritmo para todos os dias e todos os pacientes; e no final da execução destes laços, a lista de atendimentos completa é retornada.

4.2.1 Escolha das atividades a serem executadas

Primeiramente, é considerado que algumas atividades da tabela NAS são mutualmente exclusivas (por exemplo, 1a, 1b e 1c), enquanto outras não possuem esta restrição, podendo ser executadas se a equipe médica considerá-las necessárias. Posteriormente, é necessário considerar que algumas atividades podem ser escolhidas com maior frequência do que outras pela própria natureza da atividade, por exemplo, a atividade 3 (medicação) presumivelmente é executada com mais frequência do que a atividade 15 (reanimação cardiopulmonar).

Para as atividades de múltipla escolha, são consideradas três opções dependendo do tempo empregado: a opção “a” indica que a atividade demorou menos de duas horas, a opção “b” indica entre 2 e 4 horas, e “c” mais de 4 horas, conforme especificado na tabela NAS.

Naturalmente, existem inúmeras variáveis que possam alterar a probabilidade de cada atividade ser escolhida. Para esta dissertação foi realizado o levantamento de três diagnósticos: Covid-19, queimaduras e trauma, de forma a obter uma estimativa mais precisa do tempo de atendimento dos pacientes. O impacto de outras variáveis pode ser explorado em potenciais trabalhos futuros, conforme descrito na seção 6.1.

Desta forma, é necessário definir um caso “padrão” que será usado como referência para avaliar o efeito do diagnóstico na seleção das atividades a serem executadas. Com este fim, é definido um diagnóstico “desconhecido”, onde são considerados os resultados que foram obtidos pela aplicação do NAS em seis UTIs: três delas realizadas por Reich (2015), duas por Carmona-Monge (2013) e uma por Conishi e Gaidzinski (2007). Desta forma, a probabilidade de cada atividade ser escolhida é definida como a média das obtidas nestas 6 UTIs; onde cada uma destas probabilidades é calculada pela equação 1.

$$P(\text{atividade}) = \frac{\text{vezes_executada}}{\text{total_tabelas_NAS_registradas}} \quad (1)$$

Onde:


- $P(\text{atividade})$ representa a probabilidade de uma atividade específica ser escolhida.

- *vezes_executada* é o total de vezes que esta atividade foi executada de acordo com o registrado no artigo em questão.
- *total_tabelas_NAS_registradas* é o total de vezes que a tabela NAS foi aplicada em sua totalidade, no estudo em questão.

Além do diagnóstico “desconhecido”, foram considerados três estudos para definir outros três diagnósticos: Bruyneel *et al.* (2021), que comparam a escolha das atividades NAS e a duração das mesmas entre pacientes que foram admitidos com Covid-19 e os que foram admitidos por outros motivos; Camuci *et al.* (2014), que realizam um estudo similar em uma UTI para queimados; e Nogueira (2015), que considera pacientes com trauma, mais especificamente, vítimas de acidentes de transporte.

Uma vez que foram definidas as probabilidades, elas são utilizadas na simulação para escolher quais atividades serão executadas para cada paciente, a cada dia. A Fig. 6 apresenta uma comparação da frequência em que cada atividade foi escolhida dependendo do diagnóstico em uma simulação obtida com os parâmetros do algoritmo 4.2.1. Por exemplo, a frequência da atividade 1a para pacientes com diagnóstico desconhecido é de 0,8, o que significa que esta atividade é efetuada com estes pacientes 8 vezes a cada 10 dias, em média.

Figura 6 – Frequência diária média de cada atividade NAS de acordo com o diagnóstico, para cada paciente.



Fonte – De autoria própria.

Desta forma, para algumas atividades o diagnóstico não influenciou consideravelmente a frequência em que estas foram escolhidas, por exemplo, para as atividades

2, 3, 14 e 15; mas em outros casos existe uma diferença significativa, como na atividade 1 (monitorização e controles): para os pacientes com diagnóstico desconhecido, aproximadamente 80% das vezes esta atividade demora menos de duas horas (opção 1a), enquanto que aproximadamente 70% pacientes com queimaduras e trauma necessitam entre 2 e 4 horas para a mesma atividade (opção 1b).

4.3 REDES NEURAIS

Após gerar os dados por meio de simulações, e observando que o diagnóstico pode influenciar significativamente a escolha de algumas atividades de atendimento aos pacientes por parte dos enfermeiros, foram propostos dois modelos de redes neurais: a primeira abordagem realiza uma tarefa de classificação, tomando como entrada o diagnóstico do paciente e gerando uma lista das atividades mais frequentemente executadas para o mesmo; e a segunda abordagem proposta é uma rede neural de regressão, que toma como entrada o diagnóstico do paciente e calcula a quantidade média de tempo necessário para cada atividade.

É importante destacar que a escolha de atividades NAS a serem executadas, em ambas abordagens, será utilizada somente para a estimativa de pessoas-hora e, por extensão, a quantidade de enfermeiros necessários por turno para fornecer uma qualidade de atendimento satisfatória de acordo com a ferramenta NAS; estas abordagens não têm como objetivo estimar se pacientes específicos necessitam de certos cuidados, pois estas decisões são de responsabilidade da equipe médica responsável pelo paciente.

Para a implementação destas redes neurais, as ferramentas escolhidas foram Keras e Tensorflow. Keras é uma API de alto nível que roda sobre do Tensorflow, foi desenvolvida com foco em experimentação e produtividade; e é simples, flexível, robusta e poderosa (CHOLLET *et al.*, 2015). Tensorflow é uma plataforma de aprendizado de máquina que é *open-source*, escalável, flexível e robusta; e permite executar operações de baixo nível em CPUs, GPUs e TPUs de forma eficiente (ABADI *et al.*, 2015). Keras e Tensorflow também possuem uma grande quantidade de documentação e tutoriais, e são utilizados por empresas multinacionais.

4.3.1 Dataset

A partir dos dados gerados por uma simulação, foram separados dois datasets, sendo o primeiro para a rede neural de classificação e o segundo para a de regressão. Ambos datasets possuem uma entrada por atendimento ao paciente, totalizando 18250 dados cada.

A Tab. 3 apresenta as duas primeiras linhas do primeiro dataset, armazenado no arquivo `ativs_diag.csv`, onde para cada atendimento é registrado o código do paciente,

o dia em que foi efetuado, o diagnóstico do paciente, e uma lista indicando quais atividades NAS foram executadas. Para o preprocessamento de dados, o diagnóstico é codificado como um número inteiro, e para as atividades executadas é criada uma tabela com as 23 atividades NAS, codificadas segundo o esquema *one-hot*, onde o dígito 1 representa que a atividade foi executada, e 0 em caso contrário.

codPaciente	Dia	Diagnostico	Atividades								
			1a	1b	1c	2	3	4a	4b	4c	5
1	2022-01-01	trauma	0	1	0	1	1	1	0	0	1
1	2022-01-02	trauma	0	1	0	1	1	0	1	0	1

Atividades																	
6a	6b	6c	7a	7b	8a	8b	8c	9	10	11	12	13	14	15	16	17	18
0	1	0	1	0	1	0	0	1	1	1	1	0	0	0	0	1	0
0	1	0	1	0	1	0	0	1	1	1	1	0	0	0	0	1	0

Atividades				
19	20	21	22	23
0	0	0	1	0
1	0	0	0	1

Tabela 3 – Dataset utilizado para o treinamento da rede neural de classificação.

Fonte – De autoria própria.

codPaciente	Dia	Diagnostico	Duração das atividades					
			1	2	3	4	5	6
1	2022-01-01	trauma	12,42	4,37	5,29	4,93	2,67	12,61
1	2022-01-02	trauma	12,43	3,64	5,72	16,15	3,58	12,79

Duração das atividades													
7	8	9	10	11	12	13	14	15	16	17	18	19	20
4,67	3,30	1,46	2,05	3,37	0,29	0	0	0	0	8,03	0	0	0
4,03	4,19	2,52	3,16	4,96	1,03	0	0	0	0	4,51	0	1,40	0

Duração		
21	22	23
0	2,66	0
0	0	0,34

Tabela 4 – Dataset utilizado para o treinamento da rede neural de regressão.

Fonte – De autoria própria.

O segundo dataset considerado é apresentado na Tab. 4, e é armazenado no arquivo `duracao_ativs_diag`. Para cada atendimento é registrado o dia, o paciente, e

a duração das 23 atividades NAS efetuadas naquele dia. As atividades que possuem subcategorias “a”, “b” e “c” foram integrados como uma única atividade, e as atividades não efetuadas são registradas como tendo duração zero. Após codificar os diagnósticos como valores numéricos, estes são normalizados.

4.3.2 Rede Neural de Classificação

Para o treinamento da rede neural, é utilizado o primeiro dataset, ilustrado na Tab. 3, disponível no arquivo `ativs_diag.csv`. Após codificar o diagnóstico e remover as colunas `codPaciente` e `Dia`, a rede neural é treinada conforme o algoritmo 4.3.1. Na linha 3, é feita a normalização dos dados, de forma a obter um treinamento melhor e mais rápido. As linhas 4 e 5 separam os dados de entrada dos de saída da rede, sendo a entrada (X) o diagnóstico e as saídas as atividades a serem realizadas (Y).

```

1  if __name__ == '__main__':
2
3      data_norm = normalize(dataset, axis=0, norm='max')
4      X = data_norm[:, 0] # diagnosticos
5      Y = data_norm[:, 1:] # ['1' se executada, se nao'0']
6
7      model = Sequential()
8      model.add(Dense(150, input_dim=1, activation='tanh'))
9      model.add(Dense(150, activation='tanh'))
10     model.add(Dense(32, activation='sigmoid'))
11
12     model.compile(loss='BinaryCrossentropy', optimizer='adam',
13     ↪ metrics=['Recall'], loss_weights=list(PontosNAS.values()))
14     history = model.fit(X, Y, epochs=50, batch_size=100,
15     ↪ validation_split=0.2)
16
17     _, accuracy = model.evaluate(X, Y)
18     model.save('modelo_classificacao')
```

Algoritmo 4.3.1 – Código simplificado do treinamento da rede neural de classificação.
Fonte: De autoria própria.

Na linha 7 é definido que o modelo da rede será sequencial, ou seja, as camadas serão empilhadas uma encima da outra, e a saída de uma camada será a entrada da próxima camada. na linha 8 é criada a camada de entrada, com uma variável de entrada, 150 neurônios e com a função de ativação sendo a tangente hiperbólica. A linha 9 especifica a camada intermediária, com 150 neurônios e função de ativação tangente hiperbólica; e a linha 10 cria a camada de saída da rede neural com 32

neurônios, sendo cada um deles correspondente a um dos dados da saída da rede, e com função de ativação sigmoidal, por se tratar de um modelo de classificação binária.

A linha 12 especifica como o modelo será compilado: a função de perda é definida como *crossentropia* binária e é escolhido o algoritmo de otimização Adam, que é um método de gradiente descendente estocástico com momento. Antes de escolher uma métrica, foi feito um análise sobre o impacto de cada tipo de erro, conforme detalhado na Tab. 5. Os quatro tipos de de erros são:

Tipo de erro	Impacto	Efeito
Verdadeiro Positivo	Alto	Positivo
Falso Positivo	Baixo	Negativo
Verdadeiro Negativo	Baixo	Positivo
Falso Negativo	Alto	Negativo

Tabela 5 – Comparação do impacto de cada tipo de erro de predição (fonte própria).

Fonte – De autoria própria.

- Verdadeiros Positivos, correspondem ao caso em que a rede neural estimou que uma atividade será executada e, de fato, a atividade foi executada.
- Falsos Positivos, correspondem a atividades previstas, mas que não foram executadas.
- Verdadeiros Negativos, correspondem a atividades não previstas, que realmente não foram executadas.
- Falsos Negativos, correspondem a atividades que ocorreram, mas a rede neural estimou que não ocorreriam.

Conforme a Tab. 5, alguns tipos de erros de predição possuem impacto maior do que outros, e podem possuir um efeito positivo - isto é, quando estimativa se aproxima do valor real - ou um efeito negativo em caso contrário. Os verdadeiros positivos e falsos negativos possuem um impacto alto, sendo que o primeiro caso melhora a estimativa da rede, e o segundo causa que a rede subestime a carga de trabalho requerida. Desta forma, a métrica escolhida foi *Recall*, que é definida pela equação 2.

$$Recall = \frac{Verdadeiros_Positivos}{Verdadeiros_Positivos + Falsos_Negativos} \quad (2)$$

Onde *Verdadeiros_Positivos* representa a taxa de verdadeiros positivos e *Falsos_Negativos* representa a taxa de falsos negativos. Esta métrica foi escolhida procurando-se desta forma simultânea maximizar a quantidade de verdadeiros positivos e minimizar a de falsos negativos. Esta métrica varia entre zero, quando não há verdadeiros positivos, e um, quando não há falsos negativos.

Considerando que as atividades podem requerer quantidades diferentes de tempo, os pesos para a perda são definidos como a pontuação da tabela NAS. Desta forma, o modelo irá “prestar maior atenção” durante o aprendizado para as atividades que requerem mais tempo.

A linha 13 realiza o treinamento da rede neural, utilizando a entrada X, a saída Y, 50 épocas, um tamanho de *batch* de 100, e separando 20% dos dados para teste e validação. De forma a validar o modelo de forma mais sólida, posteriormente foram realizados testes de *crossvalidation*, conforme será descrito na seção 5.3. Finalmente, o modelo treinado é salvo.

O método utilizado para realizar as predições na rede neural é apresentado no algoritmo 4.3.2. Para obter melhor performance, é enviada uma lista de diagnósticos (*batch*) por vez para a rede neural. Este método recebe como entrada uma lista de diagnósticos (e o path da simulação atual), e retorna uma lista com as atividades estimadas por diagnóstico.

```
1 def evaluate_batch(diagnosticos, simulacao_path):
2     model = keras.models.load_model('modelo_classificacao')
3     diagnosticos_fl = [diagnostico_str_to_float(d, simulacao_path) for
4     ↪ d in diagnosticos]
5     atividades_fl = model.predict(numpy.array(diagnosticos_fl),
6     ↪ verbose=0)
7
8     for x in range(0, len(atividades_fl)):
9         for y in range(0, len(atividades_fl[0])):
10             if atividades_fl[x][y] < 0.5:
11                 atividades_fl[x][y] = 0
12             else:
13                 atividades_fl[x][y] = 1
14
15     all_atividades = []
16     for i in atividades_fl:
17         all_atividades.append(atividades_fl_to_str(i))
18     return all_atividades
```

Algoritmo 4.3.2 – Código simplificado do algoritmo de treinamento da rede neural de classificação. Fonte: De autoria própria.

Após carregar o modelo, a linha 3 converte a lista de diagnósticos para valores numéricos *float*, logo esta lista é passada para a rede neural na linha 4, retornando uma lista de atividades estimadas para cada um dos diagnósticos. Considerando que este modelo é um classificador binário, as linhas 6 a 11 convertem os resultados obtidos para os valores 0 ou 1. As linhas 13 a 15 convertem estes valores numéricos para

nomes de cada atividade, desfazendo a conversão feita na linha 3, e logo esta lista é retornada.

Uma das principais vantagens deste sistema é a simplicidade, porém uma desvantagem é que esta rede costuma selecionar as atividades mais frequentemente executadas para cada diagnóstico e, desta forma, obtendo uma precisão não ideal. Por exemplo, um paciente com trauma recebe o atendimento “4a” aproximadamente 65% das vezes, e o atendimento “4b” 35% das vezes; portanto a rede neural irá escolher a atividade “4a” para este diagnóstico, subestimando a carga de trabalho requerida quando a atividade efetuada é “4b”, ou seja, aproximadamente 35% das vezes.

4.3.3 Rede Neural de Regressão

Tendo em vista as limitações do modelo anterior, foi desenvolvida uma rede neural de regressão que irá receber como entrada o dataset descrito na Tab. 4, mas como saída irá produzir uma estimativa de tempo médio para executar cada atividade. A definição e o treinamento desta rede são apresentados no algoritmo 4.3.3.

```
1  if __name__ == '__main__':
2
3      X = data_norm[:, 0] # diagnosticos
4      Y = data_norm[:, 1:] # [duracao por atividade]
5
6      model = Sequential()
7      model.add(Dense(150, input_dim=1, activation='tanh'))
8      model.add(Dense(150, activation='tanh'))
9      model.add(Dense(23))
10
11     model.compile(loss='mean_squared_error', optimizer='adam')
12     history = model.fit(X, Y, epochs=50, batch_size=100,
13     ↪ validation_split=0.2)
14     model.save('modelo_regressao')
```

Algoritmo 4.3.3 – Código simplificado do algoritmo de treinamento da rede neural de regressão. Fonte: De autoria própria.

A topologia desta rede neural é similar à rede de classificação, seguindo um modelo sequencial; 150 neurônios e modo de ativação tangente hiperbólica na camada de entrada e na intermediária, e 23 neurônios na camada de saída, uma para cada atividade da lista NAS. É importante notar que neste caso a camada de saída não possui uma função de ativação, por se tratar de uma rede de regressão.

Na linha 11, o modelo é compilado. A métrica de perda utilizada foi o erro quadrático médio e o otimizador foi o Adam. O treinamento foi efetuado durante 50 épocas, com *batch size* de 100, e separando 20% dos dados para a validação e testes.

O método utilizado para realizar as previsões na rede neural é apresentado no algoritmo 4.3.4, e é mais simples do que o método equivalente para a rede de classificação. Recebe como entrada uma lista de diagnósticos e o *path* da simulação, carrega a rede neural, converte os diagnósticos em valores *float* na linha 3, e os envia à rede neural na linha 4, a qual retorna uma lista composta da duração de cada atividade, para cada um dos diagnósticos passados como argumento para este método.

```
1 def evaluate_batch(diagnosticos, simulacao_path):
2     model = keras.models.load_model('modelo_regressao')
3     diagnosticos_fl = [diagnostico_str_to_float(d, simulacao_path) for
4     ↪ d in diagnosticos]
5     duracao_ativs = model.predict(numpy.array(diagnosticos_fl),
6     ↪ verbose=0)
7
8     return duracao_ativs
```

Algoritmo 4.3.4 – Código simplificado de previsão da rede neural de regressão. Fonte: De autoria própria.

A principal vantagem desta abordagem é que ela gera uma duração média para cada atividade segundo o diagnóstico do paciente, e estes dados podem ser utilizados para estimar a quantidade de pessoas-hora (representadas por pontos NAS) requerida por dia. A principal desvantagem desta abordagem é que ela não estima quais atividades poderiam ocorrer, e atividades que são raramente executadas mas demandam uma alta carga de trabalho podem exceder a estimativa nos casos em que realmente são executadas.

5 EXPERIMENTOS E RESULTADOS

Nesta seção são apresentados os experimentos conduzidos e os resultados obtidos.

5.1 SIMULAÇÃO

Conforme detalhado na seção 4.2, o simulador desenvolvido permite modificar os seguintes parâmetros: número de pacientes, enfermeiros e técnicos; data de início, quantidade de dias a serem simulados, e a distribuição estatística que será utilizada para gerar os dados.

Considerando a necessidade de gerar uma quantidade suficiente de dados para o treinamento das redes neurais, os parâmetros utilizados para as simulações foram de 50 pacientes, 350 enfermeiros, 500 técnicos de enfermagem, e 365 dias; desta forma, para cada simulação são gerados aproximadamente 18500 atendimentos aos pacientes. As simulações consideradas utilizaram os parâmetros descritos anteriormente, exceto para a distribuição de dados, onde foram consideradas opções diferentes para cada simulação, visando a realizar os testes de *crossvalidation*, que são descritos na seção 5.3.

É importante notar que, para este estudo, foi considerado que todos os diagnósticos possuem a mesma probabilidade de serem escolhidos, e portanto a quantidade de pacientes (e por extensão, a quantidade de atendimentos) que seguem cada um dos diagnósticos será similar, enquanto que na prática se esperaria encontrar mais pacientes com diagnósticos mais comuns, o que deve ser considerado durante o pré-processamento de dados.

5.2 REDES NEURAIS

De forma a cumprir o objetivo de desenvolver um sistema inteligente que seja capaz de estimar a quantidade de enfermeiros e técnicos necessários para cada dia de trabalho em uma UTI, foram exploradas três modelos de redes neurais, que são apresentados nesta seção.

De forma a avaliar a precisão das soluções propostas, foram computados os totais de pontos NAS esperados por dia, que são calculados pela equação 3, onde:

$$VE_{dia} = \sum_{Pacientes} \left(\sum_{Atividades} P(atividade) \times Pontos(atividade) \right) \quad (3)$$


- VE_{dia} : Valor Esperado por dia, representa a quantidade total de pontos NAS requeridos para atender satisfatoriamente todos os pacientes da UTI, no dia

em questão. Doravante, este valor também é chamado de estimativa teórica ou resultado teórico.

- $P(\text{atividade})$: indica a probabilidade de que a atividade em questão seja selecionada. Os métodos utilizados para definir como estas probabilidades são calculadas são apresentados na seção 4.2.1.
- $\text{Pontos}(\text{atividade})$: Indica a quantidade de pontos indicada na tabela NAS para a atividade em questão. A tabela NAS pode ser encontrada no Anexo A.

A Fig. 7 mostra uma comparação entre os valores esperados e os obtidos na simulação, onde o eixo vertical à esquerda indica a quantidade total de pontos NAS necessários, e o eixo vertical da direita representa o mesmo dado, porém expresso como porcentagem em relação à estimativa teórica. A diferença entre estes dois dados é devido à aleatoriedade considerada durante a simulação.

Figura 7 – Comparação entre a carga de trabalho estimada e a simulada.



Fonte – De autoria própria.

5.2.1 Rede de Classificação Multi-classe

A primeira abordagem considerada foi uma rede que recebe como entrada um diagnóstico e como saída retorna um *array* de tamanho 23, onde cada item representa uma das 23 atividades NAS. Para aquelas atividades que possuem subitens “a”, “b” ou “c”, a rede neural irá adicionar um destes subitens no campo correspondente, e para as demais atividades será gravado o valor 1 se é estimado que a atividade será

executada, e 0 em caso contrário. Esta lista representa as atividades previstas, ou seja, as atividades que a rede neural determinou que são comumente efetuadas quando um paciente possui o diagnóstico que foi passado como entrada.

O treinamento desta rede foi insatisfatório. Ao fazer uma análise dos dados, foi observado que os dados utilizados para o treinamento possuem uma quantidade significativa de zeros; este problema é conhecido na literatura como um modelo *zero-inflated*, ou um modelo inflado de zeros. O principal problema encontrado ao utilizar estes dados para o treinamento é que a rede neural consegue uma alta acurácia ao simplesmente retornar uma lista de zeros.

Existem duas características que são responsáveis pela grande quantidade de zeros: considerando que a tabela NAS é uma ferramenta que pode ser aplicada a qualquer paciente, uma parte da lista NAS não será executada por não se encaixar nos cuidados requeridos pelo paciente. O outro aspecto encontrado é que os subitens “a” geralmente são mais comuns do que os itens “b” e “c”; ou em outras palavras, as atividades costumam demorar até duas horas para serem executadas, raramente demandando mais tempo. O problema com este último aspecto é na codificação destas atividades: itens “a” são representados com o valor zero, o item “b” por 0,5 e “c” por 1.

Uma estimativa composta somente de zeros implica que apenas as atividades 1a, 4a, 6a, 7a e 8a serão executadas, independente do diagnóstico do paciente. Naturalmente, este modelo não é útil para calcular a estimativa de carga de trabalho dos enfermeiros de forma aceitável. Desta forma, foram executados testes modificando parâmetros, com o objetivo de resolver este desafio.

A função de perda escolhida foi *categorical crossentropy*, ou crossentropia categórica, por se tratar de uma rede de classificação multi-classe. Como peso, foram adicionadas as durações de cada atividade expressas em pontos NAS, e foram efetuados testes modificando a topologia de rede, mas estas mudanças não foram suficientes para melhorar a acurácia. Ao modificar as funções de ativação, somente a Unidade Linear Exponencial Escalonada (SELU) retornou alguns valores não nulos como saída, e obteve uma acurácia melhor, chegando a 24%.

Considerando a função SELU, foram efetuados testes com os otimizadores disponibilizados pelo Keras, sendo que otimizadores como o RMSprop, Adam, Nadam e Adamax obtiveram acurácia de 14%; enquanto Adagrad e Ftrl obteram 38%. Também foram efetuados experimentos variando a taxa de aprendizado e o momento destes algoritmos, porém não obtendo uma diferença significativa na acurácia. É importante notar que alguns otimizadores, como o Adam, possuem taxa de aprendizado adaptativa, logo a escolha inicial da taxa de aprendizado pode não ser sempre significativa.

Considerando estas limitações, a próxima solução explorada consiste em um modelo de classificação binária, visando a resolver alguns dos desafios encontrados no desenvolvimento do modelo multi-classe.

5.2.2 Rede de Classificação Binária

Considerando os desafios no treinamento de uma rede multi-classe, e considerando que somente um dos subitens pode ser escolhido por atividade, a próxima solução considerada foi codificar cada um dos subitens de cada atividade seguindo o esquema *one-hot*; e desta forma a saída esperada é uma lista de valores binários, totalizando 32 itens, que correspondem às 23 atividades NAS.

Desta forma, é possível implementar uma rede binária, considerando o diagnóstico como entrada e como saída a lista descrita acima. Este modelo solucionou os principais desafios encontrados na implementação do modelo multi-classe, e o treinamento desta rede foi rápido e obteve uma acurácia de aproximadamente 70% já nos primeiros testes preliminares.

Com o objetivo de melhorar a acurácia e a performance da rede, para cada camada a quantidade de neurônios foi modificada e foram testadas diversas funções de ativação nas camadas, com exceção da camada de saída, que permaneceu com a função sigmoideal, pois deve retornar valores binários.


De forma geral, a escolha de funções de ativação não apresentou uma diferença significativa na acurácia ou performance da rede, mas algumas apresentaram certas peculiaridades: a função de tangente hiperbólico, de forma infrequente, não é capaz de realizar o aprendizado de forma satisfatória, obtendo uma acurácia de 4%; porém este problema pode ser resolvido ao reiniciar o treinamento da rede. Também foi observado que certas funções de ativação como *relu*, *softplus* e exponencial podem gerar erros durante o treinamento, representados pelo valor NaN; este problema pode ocorrer se o otimizador não for capaz de lidar com certas características numéricas, por exemplo, *relu* pode gerar valores muito grandes, que correspondem a probabilidades muito pequenas, levando ao problema de explosão da gradiente e gerando um *overflow* numérico, que neste caso é armazenado como o valor NaN.

Da mesma forma em que no modelo apresentado na seção 5.2.1, alguns otimizadores consideram taxa de aprendizado adaptativa, e muitos consideram algum tipo de momento, logo testes modificando estes parâmetros não obtiveram melhorias. A separação de dados foi feita em dois grupos, com 80% dos dados para o treinamento e 20% para teste e validação. De forma a validar este sistema de forma mais sólida, foram feitos experimentos com *crossvalidation*, que são descritos na seção 5.3.

Como métrica, foi escolhido o *recall*, cujo valor é apresentado na Fig. 8 em função da época de treinamento. É interessante notar que a rede obteve um valor relativamente alto já na primeira época, e se mantém aproximadamente constante a partir da 15^{ta} época. O conjunto de teste também se mantém aproximadamente constante, e acompanha os resultados obtidos no treinamento, com uma pequena variação. O valor de *recall* obtido no final do treinamento foi de 0,7775.

A Fig. 9 apresenta a perda obtida em cada época. De forma similar ao caso da

Figura 8 – Comparação entre o valor da métrica *recall* entre os conjuntos de treinamento e teste, por época.



Fonte – De autoria própria.

métrica de *recall*, os valores se estabilizam rapidamente a partir da 10^{ma} época; e a curva de teste acompanha a de treinamento.


De forma a avaliar a precisão deste modelo, foram computadas estimativas de quais atividades são executadas para cada um dos pacientes por dia, e é considerado que cada atividade consome a quantidade de tempo documentada na tabela NAS. A Fig. 10 compara este resultado com o resultado esperado e o simulado.

Desta forma, o modelo subestima a carga de trabalho requerido por dia em 457,19 pontos NAS, ou 14% em relação à estimativa teórica. Considerando que 50 pontos NAS correspondem a 12 horas de trabalho, a rede estima que serão necessários 9,14 enfermeiros a menos do que a média esperada, logo esta solução não é ideal.

A principal vantagem deste modelo é a sua simplicidade, e rapidez no treinamento; enquanto que a principal desvantagem deste modelo é que a carga de trabalho requerida para cada paciente não é calculada de forma direta: o modelo seleciona uma lista de atividades comumente efetuadas para pacientes de cada diagnóstico, e para cada atividade é considerada que a duração da mesma segue a indicação da tabela NAS; e desta forma, o modelo pode subestimar o tempo requerido quando a execução de atividades demandar mais tempo do que o previsto no NAS.

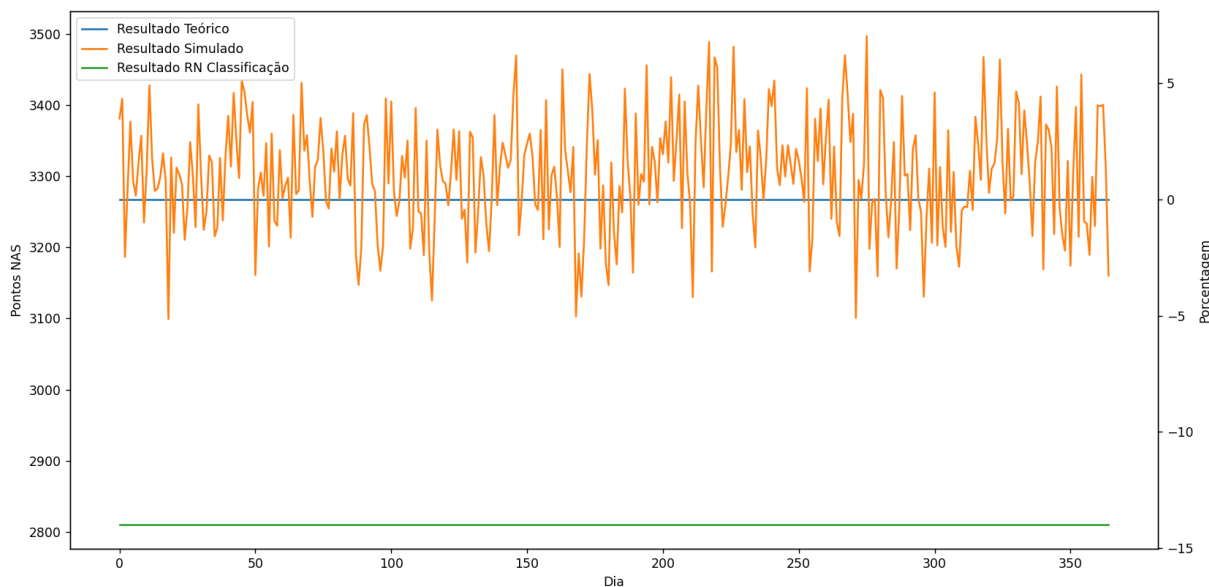
Outra desvantagem ocorre quando a distribuição de dados é similar para cada atividade, isto é, se uma atividade é executada 30% das vezes, a rede provavelmente

Figura 9 – Comparação entre o valor de perda entre os conjuntos de treinamento e teste, por época.



Fonte – De autoria própria.

Figura 10 – Comparação entre a estimativa da rede neural de classificação com o valor teórico e o esperado, por dia.



Fonte – De autoria própria.

irá considerar que esta atividade geralmente não é executada e, desta forma, irá subestimar a carga de trabalho para esta atividade em aproximadamente 30% dos

casos. Esta limitação pode ser ainda mais pronunciada em atividades que possuem subitens, por exemplo, se a atividade “1a” for executada 60% das vezes, “1b” 10% das vezes e “1c” 30% das vezes; e considerando que a pontuação NAS destas atividades é de 4,5 pontos, 12 pontos e 19,6 pontos respectivamente; a rede provavelmente irá escolher a atividade “1a” (4,5 pontos) por ser a mais frequentemente efetuada. Neste exemplo, a rede estimaria 4,5 pontos NAS, enquanto que a média seria de 9,78 pontos.

5.2.3 Rede de Regressão

Tendo em vista as limitações do modelo anterior, é proposta uma rede neural de regressão, que toma como entrada o diagnóstico dos pacientes e como saída retorna a duração estimada para cada uma das 23 atividades NAS. Para isto, as atividades que possuem subitens (1, 4, 6, 7 e 8) são consideradas como sendo uma única atividade, e para escolher o subitem correspondente, a saída da rede neural é comparada com a tabela NAS: se a duração da atividade é menor a 2 horas, é considerada a opção “a”, entre 2 e 4 horas corresponde à “b”, e para mais de 4 horas é considerado como “c”. Para as demais atividades, o tempo estimado é a saída da rede, diretamente.


De forma similar ao modelo anterior, foram efetuados testes variando a quantidade de neurônios em cada camada e a função de ativação da camada de entrada e a camada intermediária; a camada de saída não possui função de ativação, por ser uma rede de regressão. Desta forma, foram considerados 150 neurônios na camada de entrada e na intermediária, e 23 neurônios na camada de saída, onde cada neurônio corresponde a uma saída da rede.

Também foram testadas múltiplas funções de perda e otimizadores, e as opções escolhidas foram erro quadrático médio como função de perda, e Adam como otimizador. De forma idêntica à rede de classificação, foram separados 80% dos dados para treinamento e 20% para teste, e o treinamento durou 50 épocas com um *batch size* de 100.

A Fig. 11 apresenta a variação na função de perda para os conjuntos de treinamento e teste, por época. A similaridade nestas duas curvas sugere que o modelo foi capaz de aprender corretamente a duração média de cada atividade NAS, considerando o diagnóstico do paciente.


Finalmente, é feita uma comparação dos resultados desta rede com os da rede de classificação, com os resultados teóricos e com os simulados; esta comparação é sintetizada na Fig. 12. A diferença entre a estimativa da rede neural e a teórica é de 11,48 pontos NAS, ou 0,35%, o que é equivalente a 2,76 horas de trabalho. Desta forma, os valores estimados pela rede neural são uma boa aproximação para o valor teórico, e a diferença para com o resultado simulado varia entre aproximadamente -5% e 5%. É importante destacar que estes resultados são obtidos utilizando um único *dataset*, logo uma validação mais sólida será explorada na seção 5.3.

Figura 11 – Comparação do erro quadrático médio entre os conjuntos de treinamento e teste, por época.



Fonte – De autoria própria.

Figura 12 – Comparação entre a estimativa de ambas redes neurais propostas com o valor esperado e o simulado, por dia.



Fonte – De autoria própria.

A principal vantagem desta solução é que ela aproxima o comportamento médio de um paciente, considerando valores diferentes para diagnósticos diferentes. A prin-

principal vantagem do uso de redes neurais neste caso é que é possível adicionar mais entradas para a rede neural, isto é, considerar novas variáveis que possam afetar a quantidade de tempo requerido para cada atividade de atendimento ao paciente, como a idade do paciente, a presença ou ausência de certas doenças, e outros. Este caso, conforme detalhado na seção 6.1, pode ser explorado como trabalhos futuros.

A principal desvantagem deste modelo é que não é capaz de estimar exatamente quais atividades poderiam ser necessárias para cada paciente, mas apenas a duração média de cada uma das atividades. Por outro lado, a rede neural de classificação é capaz de estimar uma lista de atividades a serem executadas, mas não obtém uma estimativa ideal da duração de cada atividade.

5.3 CROSSVALIDATION

De forma a avaliar o comportamento do sistema proposto em ambientes para os quais não foi treinado, foi utilizada a técnica de *cross-dataset validation*, ou seja, foram efetuadas uma série de comparações onde uma rede neural é treinada com os dados gerados por uma simulação, mas a sua performance é avaliada sobre os dados gerados em outra simulação.

Desta forma, foram criadas quatro simulações com os mesmos parâmetros, variando apenas a distribuição de dados: as simulações 1 e 2 utilizam a curva normal, a simulação 3 segue a distribuição de T-Student, e a simulação 4 segue a distribuição exponencial. As redes neurais foram treinadas com os dados gerados pela simulação 1 e, nesta seção, serão validados contra as demais simulações.

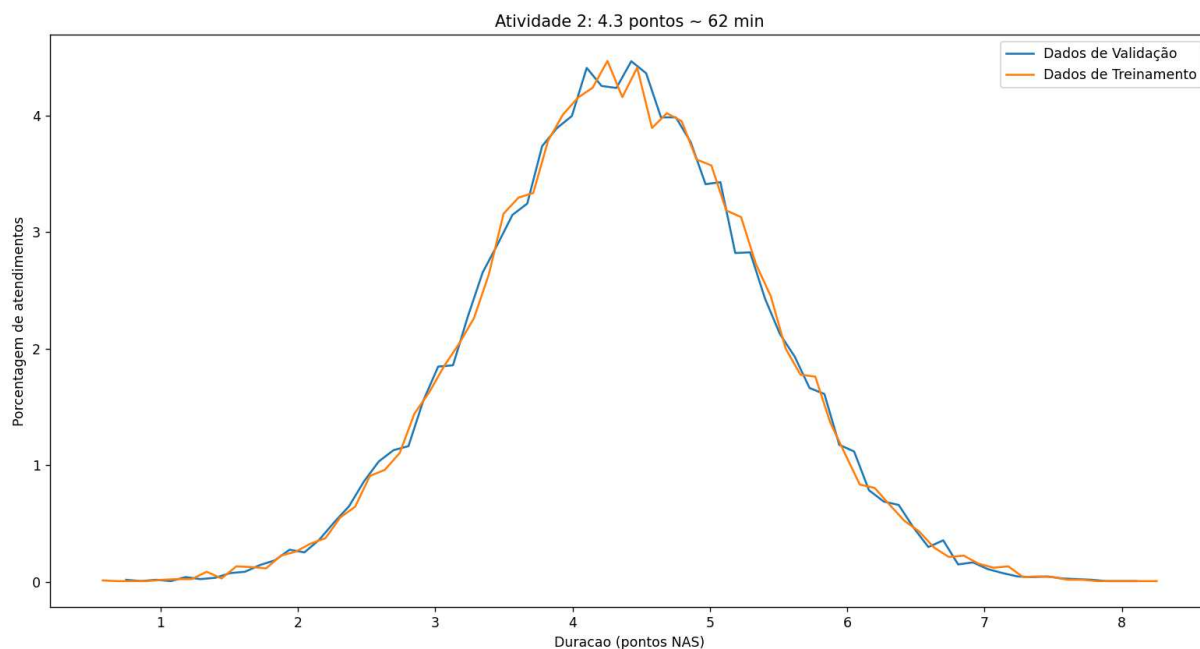
5.3.1 Distribuição normal

Antes de validar com outras distribuições, é definido um caso ideal, onde a distribuição de dados de treinamento e de validação são estatisticamente equivalentes. Desta forma, além da simulação utilizada para o treinamento (simulação 1), foi criada outra simulação para a validação (simulação 2), sendo que ambas seguem a distribuição normal, com a média sendo a pontuação NAS da atividade e o desvio padrão de 1 ponto NAS.

A Fig. 13 apresenta uma comparação da duração da atividade 2, para ambas simulações. É importante destacar que os gráficos de todas as atividades são semelhantes, variando apenas a posição das curvas, cuja média corresponde àquela indicada na tabela NAS; desta forma, a atividade 2 foi escolhida para representar os resultados de forma sucinta e não repetitiva.


A Fig. 14 apresenta uma comparação da estimativa obtida pelas redes neurais com os valores simulados. Por se tratar de duas distribuições idênticas, este gráfico é idêntico ao obtido na seção 5.2.3; e a diferença entre o resultado da rede de regressão

Figura 13 – Comparação entre o conjunto de treinamento e validação (ambos com a distribuição normal), considerando a duração da atividade de investigações laboratoriais.



Fonte – De autoria própria.

Figura 14 – Comparação do resultado obtido pela rede neural com os dados simulados.



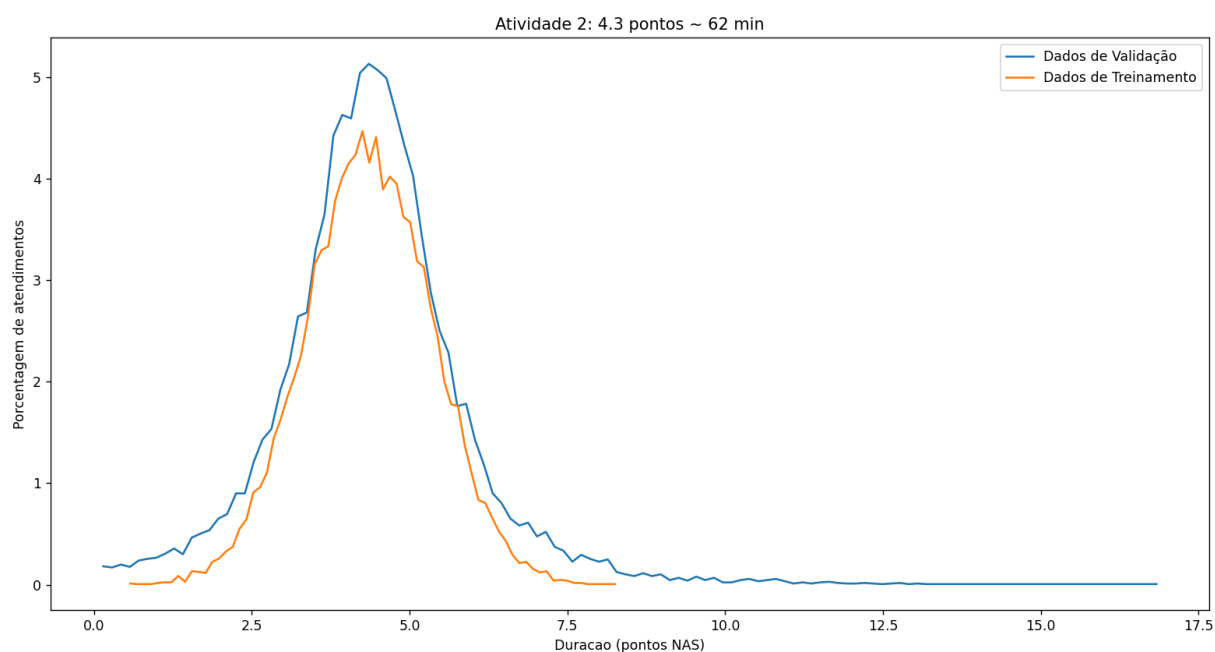
Fonte – De autoria própria.

e a estimativa teórica é de 8,82 pontos NAS, ou 0,26%, o que é equivalente a 2,12 horas de trabalho.

5.3.2 Distribuição T-Student

Para este caso, foi considerada uma distribuição de dados similar àquela utilizada para o treinamento: uma curva T-Student, considerando 3 graus de liberdade e como ponto central (ou localização) o valor da pontuação NAS. A Fig. 15 apresenta uma comparação desta distribuição com a curva normal utilizada para o treinamento.

Figura 15 – Comparação entre o conjunto de treinamento (distribuição normal) e validação (distribuição T-Student), considerando a duração da atividade de investigações laboratoriais.




Fonte – De autoria própria.

A distribuição T-Student escolhida geralmente produz uma curva com caudas mais longas do que a curva normal tanto à direita quanto à esquerda, ou seja, irá possuir uma quantidade maior de *outliers* do que a curva normal. Em alguns casos, considerando que uma atividade não pode ter duração negativa, a cauda à esquerda é “cortada” ao chegar em 0 pontos, deixando uma cauda maior à direita, o que implica em um aumento leve da média de tempo requerido pela atividade.

A Fig. 16 apresenta uma comparação dos resultados obtidos. Este gráfico é similar à figura 14, conforme é esperado ao utilizar uma distribuição de dados similar à do treinamento. Porém, como a curva T-Student escolhida possui uma cauda à direita para as atividades com pontuação baixa, a rede neural irá subestimar levemente a

carga de trabalho requerida nestas atividades e, por extensão, a carga de trabalho da UTI como um todo.

Figura 16 – Comparação do resultado obtido pela rede neural com os dados simulados.



Fonte – De autoria própria.

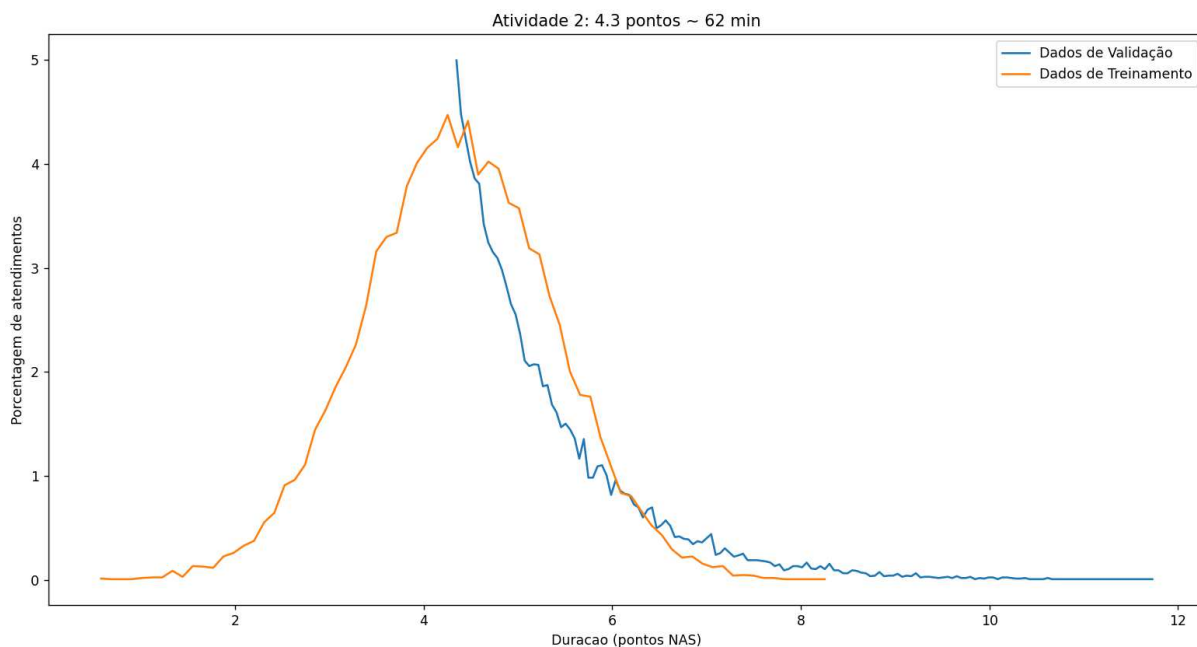
Desta forma, a maioria dos dados se encontram entre aproximadamente -3% e 10% da estimativa da rede neural de regressão. A diferença entre o resultado da rede de regressão e o esperado é de 56,26 pontos NAS, ou 1,62%, o que é equivalente a 13,5 horas de trabalho, ou 1,12 enfermeiros.

5.3.3 Distribuição Exponencial

De forma a avaliar o comportamento das redes neurais ao encontrar dados que seguem uma distribuição muito diferente àquela utilizada no treinamento, foi desenvolvida uma simulação utilizando a curva exponencial, com os parâmetros sendo o valor 1 para lambda e como localização o valor correspondente à atividade em questão, segundo a tabela NAS. Uma comparação entre os dados que seguem a normal e os que seguem a exponencial é apresentada na Fig. 17.


A principal característica desta distribuição é a sua cauda pronunciada à direita, e considerando que o valor de localização (início da curva) é a média da curva normal, os atendimentos geralmente demandam mais tempo do que na curva normal. Naturalmente, à medida que a curva cresce à direita, a quantidade de atendimentos diminui exponencialmente, sendo que 63% dos atendimentos demoram entre 4,3 e 5,3 pontos NAS.

Figura 17 – Comparação entre o conjunto de treinamento (distribuição normal) e validação (distribuição exponencial), considerando a duração da atividade de investigações laboratoriais.



Fonte – De autoria própria.

Figura 18 – Comparação do resultado obtido pela rede neural com os dados simulados.



Fonte – De autoria própria.

Finalmente, são calculadas as estimativas das redes neurais, que são apresentados na Fig. 18. A diferença entre o valor estimado pela rede e o valor esperado é de 597,53 pontos NAS, ou 15,68%, o que é equivalente a 11,95 enfermeiros por dia.

A Tab. 6 apresenta uma síntese dos resultados obtidos em cada um dos experimentos de *crossvalidation*, considerando a distribuição de dados, a quantidade de pontos NAS esperada por dia, a estimativa obtida pela rede neural de regressão, a diferença entre estes dois valores expresso em termos absolutos e em porcentagem, e a quantidade de enfermeiros que correspondem à diferença.

Distribuição	Esperado	Obtido	Diferença	Porcentagem	Enfermeiros
Normal	3355,74	3364,56	8,82	0,26	0,18
T-Student	3531,02	3474,76	56,26	1,62	1,12
Exponencial	3976,23	3378,69	597,53	15,68	11,95

Tabela 6 – Comparação dos resultados obtidos na *crossvalidation*.

Fonte – De autoria própria.

6 CONCLUSÕES

De forma a cumprir os objetivos propostos, os principais sistemas que foram desenvolvidos incluem o dispositivo IoT, que tem como função documentar a duração das atividades de enfermagem; um simulador, que gera dados sobre atividades de enfermagem com base em artigos publicados na área; e um módulo de inteligência artificial, que utiliza redes neurais para fazer estimativas de carga de trabalho diária com base no diagnóstico dos pacientes da UTI em questão. É importante destacar que este módulo de IA não tem como objetivo realizar diagnósticos de pacientes ou avaliar as necessidades médicas destes.

Foram desenvolvidas 4 simulações, cada uma com 18500 atendimentos aos pacientes, considerando 3 distribuições de dados diferentes e 4 diagnósticos. Em relação ao módulo de IA, foram feitos experimentos avaliando a performance das redes neurais quando encontram dados diferentes àqueles que foram utilizados para o treinamento. De forma a representar o comportamento do sistema após passar algum tempo sem ser retreinado, foi escolhida a distribuição T-Student; e a rede obteve uma boa aproximação, porém poderia obter resultados melhores ao retreinar as redes de forma contínua.

A outra distribuição de dados escolhida foi a exponencial, que representa um caso diferente àquele considerado durante o treinamento: este exemplo foi escolhido para representar um caso similar ao ocorrido durante o início da pandemia de COVID-19, onde os cuidados de enfermagem necessários excederam os valores estimados, e a taxa de ocupação de leitos aumentou. Por outro lado, este caso também pode representar o que se esperaria ao encontrar uma diferença significativa de recursos disponíveis entre duas UTIs, onde aquela que possui menos recursos pode apresentar uma demora maior para o cumprimento de certas atividades.

Desta forma, os experimentos com *crossvalidation* sugerem que é necessário retreinar continuamente as redes neurais, de forma que as estimativas se mantenham em sincronia com a carga de trabalho real. Outro aspecto a ser considerado é que ao aplicar os conhecimentos obtidos em uma UTI para outra UTI, estes podem não se alinhar corretamente com a realidade: por exemplo, poderia ser que duas UTIs tratem grupos similares de pacientes, mas uma delas se especialize em casos mais graves ou mais raros; ou uma delas receba pacientes de uma faixa etária muito diferente da outra.

Entre as duas soluções propostas, a rede neural de classificação indica quais são as atividades geralmente efetuadas, mas não oferece uma aproximação adequada da carga de trabalho diária requerida. Por outro lado, a rede de regressão oferece uma boa aproximação da quantidade de trabalho necessária, indicando a duração esperada de cada atividade separadamente, mas não indica quais atividades são esperadas.

Trabalhos futuros poderiam integrar as vantagens destas duas abordagens de forma complementar.

6.1 TRABALHOS FUTUROS

Para este estudo, foi considerado que o diagnóstico do paciente pode alterar a quantidade de tempo de cuidado requerido a cada dia. Trabalhos futuros poderiam explorar o efeito que outras variáveis poderiam ter na carga de trabalho, como por exemplo a idade e a gravidade do quadro médico do paciente, assim como a presença de doenças renais, respiratórias, cardíacas, e outras. Uma das vantagens de utilizar redes neurais é que a solução proposta pode ser expandida para considerar estas novas variáveis.

De forma a validar este projeto de forma mais sólida, e tendo em mente as limitações ao utilizar simulações na validação, outro possível trabalho futuro é a implementação deste sistema em uma UTI. Esta tarefa pode ser complexa ao considerar os desafios que surgem nas áreas de segurança de computadores e privacidade de dados. Outros desafios podem surgir durante a implementação dos dispositivos IoT, considerando que o *layout* das macas dentro da UTI pode ser não ideal, pois macas muito próximas uma das outras podem dificultar identificar o paciente que está recebendo os cuidados.

Também será necessário considerar o tratamento de dados incorretos ou ruidosos, que podem surgir em diversos casos, como por exemplo, se as macas estiverem posicionadas de forma que os enfermeiros precisem passar entre elas, é possível que os dispositivos IoT delas registrem um “atendimento” errôneo com duração de alguns milissegundos. Da mesma forma, é possível que durante a execução de certas atividades os enfermeiros necessitem se afastar da maca múltiplas vezes, e desta forma seriam registrados múltiplos atendimentos de duração curta, que posteriormente deveriam ser unificados como uma única atividade.

Outra forma de validar parcialmente este projeto com dados reais poderia considerar outras soluções para a coleta de dados, como tabelas eletrônicas ou registros manuais. Estes dados podem ser utilizados para a validação do módulo de IA caso não seja possível ou prático implementar a rede IoT-Fog em uma UTI.

REFERÊNCIAS

ABADI, Martín *et al.* **TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems**. [S.l.: s.n.], 2015. Disponível em:

<https://www.tensorflow.org/>.

BASU, Srijita; BARDHAN, Arjun; GUPTA, Koyal; SAHA, Payel; PAL, Mahasweta; BOSE, Manjima; BASU, Kaushik; CHAUDHURY, Saunak; SARKAR, Pritika. Cloud computing security challenges & solutions-A survey. *In*: 2018 IEEE 8th Annual Computing and Communication Workshop and Conference (CCWC). [S.l.: s.n.], 2018. P. 347–356. DOI: 10.1109/CCWC.2018.8301700.

BRASIL. Decreto N 94.406/87. Subchefia para Assuntos Jurídicos, Casa Civil, Presidência da República [Federativa do Brasil], jun. 1987. Disponível em:

https://www.planalto.gov.br/ccivil_03/decreto/1980-1989/d94406.htm.

BRASIL. Lei N 7.498/86, de 25 de Junho de 1986. Subchefia para Assuntos Jurídicos, Casa Civil, Presidência da República [Federativa do Brasil], jun. 1986. Disponível em:

https://www.planalto.gov.br/ccivil_03/leis/17498.htm.

BRUYNEEL, Arnaud; GALLANI, Maria-Cécillia; TACK, Jérôme; D'HONDT, Alain; CANIPEL, Sebastien; FRANCK, Stéphane; REPER, Pascal; PIRSON, Magali. Impact of COVID-19 on nursing time in intensive care units in Belgium. **Intensive and Critical Care Nursing**, v. 62, p. 102967, 2021. ISSN 0964-3397. DOI:

<https://doi.org/10.1016/j.iccn.2020.102967>. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S0964339720301701>.

CAMARGO, Maximiliano Dutra de; SILVEIRA, Denise Tolfo;

LAZZARI, Daniele Delacanal; RODRIGUES, Alisson Francisco Vargas;

MORAES, Katia Bottega; DUARTE, Erica Rosalba Mallmann. Nursing Activities Score: trajectory of the instrument from paper to cloud in a university hospital. **Revista da Escola de Enfermagem da USP [online]**, v. 55, p. 6, set. 2021. ISSN 1980-220X.

DOI: <https://doi.org/10.1590/1980-220X-REEUSP-2020-0233>. Disponível em:

<https://doi.org/10.1590/1980-220X-REEUSP-2020-0233>.

CAMUCI, Marcia Bernadete; MARTINS, Júlia Trevisan;

CARDELI, Alexandrina Aparecida Maciel; ROBAZZI, Maria Lúcia Do Carmo Cruz.

Nursing Activities Score: carga de trabalho de enfermagem em Unidade de Terapia

Intensiva de queimados. **Revista Latino-Americana de Enfermagem**, v. 02, n. 22, abr. 2014. DOI: 10.1590/0104-1169.3193.2419.

CAPRA, Maurizio; BUSSOLINO, Beatrice; MARCHISIO, Alberto; MASERA, Guido; MARTINA, Maurizio; SHAFIQUE, Muhammad. Hardware and Software Optimizations for Accelerating Deep Neural Networks: Survey of Current Trends, Challenges, and the Road Ahead. **IEEE Access**, v. 8, p. 225134–225180, 2020. DOI: 10.1109/ACCESS.2020.3039858.

CARMONA-MONGE, Francisco Javier et al. Usage analysis of the Nursing Activities Score in two Spanish ICUS. **Revista da Escola de Enfermagem da USP [online]**, v. 47, n. 05, p. 1106–1113, 2013. ISSN 1980-220X. DOI: <https://doi.org/10.1590/S0080-623420130000500014>.

CESÁRIO, Jonas Magno dos Santos; FLAUZINO, Victor Hugo de Paula; HERNANDES, Luana de Oliveira; GOMES, Daiana Moreira; VITORINO, Priscila Gramata da Silva. Prática clínica do enfermeiro: diferenças entre Brasil e Estados Unidos da América. **Revista Científica Multidisciplinar Núcleo do Conhecimento**, v. 15, p. 40–55, mai. 2021. ISSN 2448-0959. DOI: 10.32749/nucleodoconhecimento.com.br/saude/pratica-clinica. Disponível em: <https://www.nucleodoconhecimento.com.br/saude/pratica-clinica>.

CHEN, Pei-Jarn; WENG, Jui-Yu; CHIOU, Yi-Kai. Implement an IOT Platform of Biosignal Monitoring for Nurse Station. *In*: 2020 IEEE 2nd Eurasia Conference on Biomedical Engineering, Healthcare and Sustainability (ECBIOS). [S.l.: s.n.], 2020. P. 219–222. DOI: 10.1109/ECBIOS50299.2020.9203686. Disponível em: <https://ieeexplore.ieee.org/document/9203686>.

CHOLLET, François *et al.* **Keras**. [S.l.: s.n.], 2015. Disponível em: <https://keras.io>.

COFEN, Conselho Federal de Enfermagem. **O COFEN**. [S.l.: s.n.], 2022. Disponível em: <http://www.cofen.gov.br/o-cofen>.

COFEN, Conselho Federal de Enfermagem. Resolução COFEN 543/2017, mai. 2017. Disponível em: http://www.cofen.gov.br/resolucao-cofen-5432017_51440.html.

COFEN, Conselho Federal de Enfermagem. Resolução COFEN Nº 429/2012, jun. 2012. Disponível em: http://www.cofen.gov.br/resoluo-cofen-n-4292012_9263.html.

CONISHI, Regina Maria Yatsue; GAIDZINSKI, Raquel Rapone. Nursing Activities Score (NAS) como instrumento para medir carga de trabalho de enfermagem em UTI adulto. **Revista da Escola de Enfermagem da USP [online]**, v. 41, n. 03, p. 346–354, 2007. ISSN 1980-220X. DOI: <https://doi.org/10.1590/S0080-62342007000300002>.

COREN-SP, Conselho Regional de Enfermagem de São Paulo. Parecer COREN-SP Nº 062/2011, ago. 2011. Disponível em: https://portal.coren-sp.gov.br/sites/default/files/parecer_coren_sp_2011_62.pdf.

DOŠILOVIĆ, Filip Karlo; BRČIĆ, Mario; HLUPIĆ, Nikica. Explainable artificial intelligence: A survey. *In*: 2018 41st International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO). [S.l.: s.n.], 2018. P. 210–215. DOI: 10.23919/MIPRO.2018.8400040.

GONÇALVES, Leilane Andrade; PADILHA, Katia Grillo; CARDOSO SOUSA, Regina M. Nursing activities score (NAS): A proposal for practical application in intensive care units. **Intensive and Critical Care Nursing**, v. 23, n. 6, p. 355–361, 2007. ISSN 0964-3397. DOI: <https://doi.org/10.1016/j.iccn.2007.04.009>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S096433970700047X>.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning**. [S.l.]: MIT Press, jan. 2016. P. 775. <http://www.deeplearningbook.org>. ISBN 978-0262035613.

GUINARD, Patrik Fuhrer Dominique. Building a smart hospital using RFID technologies. *In*: STORMER, Henrik; MEIER, Andreas; SCHUMACHER, Michael (Ed.). **European Conference on eHealth 2006**. Bonn: Gesellschaft für Informatik e.V., 2006. P. 131–142.

GUO, Peng; CHIEW, Yeong Shiong; SHAW, Geoff; CHASE, Geoff. Validation of clinical activity tracking system in Intensive Care Unit to assess nurse workload distribution. *In*: 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). [S.l.: s.n.], 2015. P. 458–461. DOI: 10.1109/EMBC.2015.7318398. Disponível em: <https://ieeexplore.ieee.org/document/7318398>.

HUSSEIN, Nidal Hassan; KHALID, Ahmed. A survey of Cloud Computing Security challenges and solutions. **International Journal of Computer Science and Information Security (IJCSIS)**, v. 14, n. 1, jan. 2016. ISSN 1947-5500.

IORGA, Michaela; MARTIN, Michael J; FELDMAN, Larry. Fog Computing Conceptual Model: Recommendations of the National Institute of Standards and Technology. **NIST Special Publication 500-325**, p. 11, 2018. Disponível em:

<https://nvlpubs.nist.gov/nistpubs/SpecialPublications/NIST.SP.500-325.pdf>.

KHANADE, Kunal; SASANGO HAR, Farzan; SADEGHI, Mahnoosh; SUTHERLAND, Steven; ALEXANDER, Karen. Deriving Information Requirements for a Smart Nursing System for Intensive Care Units. **Proceedings of the Human Factors and Ergonomics Society Annual Meeting**, v. 61, n. 1, p. 653–654, 2017. DOI:

10.1177/1541931213601649. eprint: <https://doi.org/10.1177/1541931213601649>.

Disponível em: <https://doi.org/10.1177/1541931213601649>.

LEE, Suk Kyu; BAE, Mungyu; KIM, Hwangnam. Future of IoT Networks: A Survey. **Applied Sciences**, v. 7, n. 10, 2017. ISSN 2076-3417. DOI: 10.3390/app7101072.

Disponível em: <https://www.mdpi.com/2076-3417/7/10/1072>.

LUGER, George. **Artificial Intelligence: Structures and Strategies for Complex Problem Solving**. 6. ed. Estados Unidos da América: Pearson, fev. 2008. P. 792.

ISBN 978-0321545893.

MIRANDA, Dinis Reis; NAP, Raoul; RIJK, Angelique; SCHAUFELI, Wilmar; IAPICHINO, Gaetano; WORKING GROUP, TISS; ØYRI, Karl. Nursing Activities Score. **Critical Care Medicine**, v. 31, p. 374, fev. 2003. DOI:

10.1097/01.CCM.0000045567.78801.CC.

MORAES, Kátia; MARTINS, Fabiana; CAMARGO, Maximiliano; VIEIRA, Debora; MAGALHÃES, Ana; SILVEIRA, Denise. Nursing Activities Score: Cloud Computerized Structure. **Studies in health technology and informatics**, v. 225, p. 836–7, jan. 2016.

MORALES, Pau Garcia i. **THE RISE OF SMART HOSPITALS: Design and implementation of a decision-making support tool for the SMART ICU of the Vall d’Hebron University Hospital**. Jul. 2020. Bachelor’s Thesis of Biomedical Engineering – Universitat Pompeu Fabra.

NESHENKO, Nataliia; BOU-HARB, Elias; CRICHIGNO, Jorge; KADDOUM, Georges; GHANI, Nasir. Demystifying IoT Security: An Exhaustive Survey on IoT Vulnerabilities and a First Empirical Look on Internet-Scale IoT Exploitations. **IEEE**

Communications Surveys Tutorials, v. 21, n. 3, p. 2702–2733, 2019. DOI: 10.1109/COMST.2019.2910750.

NOGUEIRA, Lilia de Souza et al. Padrão de intervenções de enfermagem realizadas em vítimas de trauma segundo o Nursing Activities Score. **Revista da Escola de Enfermagem da USP [online]**, v. 49, spe, p. 29–35, 2015. ISSN 1980-220X. DOI: <https://doi.org/10.1590/S0080-623420150000700005>.

NURSUWARS, Firmansyah; RAHMATULLOH, Alam. RFID for nurse activity monitoring in the hospital's nurse call system with Internet of Thing (IoT) concept. **IOP Conference Series: Materials Science and Engineering**, v. 550, p. 012025, ago. 2019. DOI: 10.1088/1757-899X/550/1/012025. Disponível em: https://www.researchgate.net/publication/335366708_RFID_for_nurse_activity_monitoring_in_the_hospital's_nurse_call_system_with_Internet_of_Thing_IoT_concept.

PADILHA, Katia Grillo; DE SOUSA, Regina Márcia Cardoso; GARCIA, Paulo Carlos; BENTO, Sheila Tosta; FINARDI, Eva Maria; HATARASHI, Regina H.K. Nursing workload and staff allocation in an intensive care unit: A pilot study according to Nursing Activities Score (NAS). **Intensive and Critical Care Nursing**, v. 26, n. 2, p. 108–113, 2010. ISSN 0964-3397. DOI: <https://doi.org/10.1016/j.iccn.2009.12.002>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0964339709001128>.

PARVEEN, R.; NABI, M.; MEMON, F. A.; ZAMAN, S.; ALI, M. A Review and Survey of Artificial Neural Network in Medical Science. **Journal of Advanced Review on Scientific Research**, v. 22, n. 1, p. 12–21, 2016. ISSN 2289-7887. Disponível em: https://www.akademiabaru.com/doc/ARSRV22_N1_P12_21.pdf.

QUEIJO, Alda Ferreira; PADILHA, Katia Grillo. Nursing Activities Score (NAS): adaptação transcultural e validação para a língua portuguesa. **Revista da Escola de Enfermagem da USP**, Universidade de São Paulo, Escola de Enfermagem, v. 43, p. 1018–1025, 2009.

REICH, Rejane et al. Nursing workload in a coronary unit according to the Nursing Activities Score. **Revista Gaúcha de Enfermagem [online]**, v. 36, n. 3, p. 28–35, 2015. ISSN 1983-1447. DOI: <https://doi.org/10.1590/1983-1447.2015.03.51367>.

RUSSELL, Stuart; NORVIG, Peter. **Artificial Intelligence: A Modern Approach**. 3. ed. Estados Unidos da América: Pearson, dez. 2009. P. 1152. ISBN 978-0136042594.

WÜLLER, Hanna; BEHRENSA, Jonathan; KLINKER, Kai; WIESCHE, Manuel; KRCMARB, Helmut; REMMERSA, Hartmut. Smart Glasses in Nursing – Situation Change and Further Usages Exemplified on a Wound Care Application. **German Medical Data Sciences: A Learning Healthcare System: Proceedings of the 63rd Annual Meeting of the German Association of Medical Informatics, Biometry and Epidemiology**, IOS Press, p. 191–195, set. 2018. DOI: 10.3233/978-1-61499-896-9-191.

YU, Lei; LU, Yang; ZHU, XiaoJuan. Smart Hospital based on Internet of Things. **JOURNAL OF NETWORKS**, ACADEMY PUBLISHER, v. 7, n. 10, p. 1654–1661, out. 2012. DOI: 10.4304/jnw.7.10.1654-1661.

Anexos

ANEXO A – ESCORE DE ATIVIDADES DE ENFERMAGEM

Abaixo a versão final do NAS na língua portuguesa extraída de Queijo e Padilha (2009).

Atividades básicas	Pontuação
1. MONITORIZAÇÃO E CONTROLES	
1a. Sinais vitais horários, cálculo e registro do balanço hídrico	4,5
1b. Presença à beira do leito e observação ou atividade contínua por 2 horas ou mais em algum plantão por razões de segurança, gravidade ou terapia, tais como: ventilação mecânica não invasiva, desmame, agitação, confusão mental, posição prona, procedimentos de doação de órgãos, preparo e administração de fluidos ou medicação, auxílio em procedimentos específicos.	12
1c. Presença à beira do leito e observação ou atividade contínua por 4 horas ou mais em algum plantão por razões de segurança, gravidade ou terapia, tais como os exemplos acima.	19,6
2. INVESTIGAÇÕES LABORATORIAIS: bioquímicas e microbiológicas.	4,3
3. MEDICAÇÃO, exceto drogas vasoativas.	5,6
4. PROCEDIMENTOS DE HIGIENE	
4a. Realização de procedimentos de higiene tais como: curativo de feridas e cateteres intravasculares, troca de roupa de cama, higiene corporal do paciente em situações especiais (incontinência, vômito, queimaduras, feridas com secreção, curativos cirúrgicos complexos com irrigação), procedimentos especiais (ex. isolamento), etc.	4,1
4b. Realização de procedimentos de higiene que durem mais do que 2 horas, em algum plantão.	16,5
4c. Realização de procedimentos de higiene que durem mais do que 4 horas em algum plantão.	20,0

5. CUIDADO COM DRENOS - Todos (exceto sonda gástrica)	1,8
6. MOBILIZAÇÃO E POSICIONAMENTO incluindo procedimentos tais como: mudança de decúbito, mobilização do paciente; transferência da cama para a cadeira; mobilização do paciente em equipe (ex. paciente imóvel, tração, posição prona).	
6a. Realização do(s) procedimento(s) até 3 vezes em 24 horas.	5,5
6b. Realização do(s) procedimento(s) mais do que 3 vezes em 24 horas ou com 2 enfermeiros em qualquer frequência	12,4
6c. Realização do(s) procedimento(s) com 3 ou mais enfermeiros em qualquer frequência.	17,0
7. SUPORTE E CUIDADOS AOS FAMILIARES E PACIENTES incluindo procedimentos tais como telefonemas, entrevistas, aconselhamento. Frequentemente, o suporte e cuidado, sejam aos familiares ou aos pacientes permitem a equipe continuar com outras atividades de enfermagem (ex: a comunicação com o paciente durante procedimentos de higiene, comunicação com os familiares enquanto presente à beira do leito observando o paciente).	
7a. Suporte e cuidado aos familiares e pacientes que requerem dedicação exclusiva por cerca de uma hora em algum plantão, tais como: explicar condições clínicas, lidar com a dor e angústia, lidar com circunstâncias familiares difíceis.	4,0
7b. Suporte e cuidado aos familiares e pacientes que requerem dedicação exclusiva por 3 horas ou mais em algum plantão, tais como: morte, circunstâncias trabalhosas (ex. grande número de familiares, problemas de linguagem, familiares hostis).	32,0
8. TAREFAS ADMINISTRATIVAS E GERENCIAIS	
8a. Realização de tarefas de rotina tais como: processamento de dados clínicos, solicitação de exames, troca de informações profissionais (ex. passagem de plantão, visitas clínicas).	4,2

8b. Realização de tarefas administrativas e gerenciais que requerem dedicação integral por cerca de 2 horas em algum plantão, tais como: atividades de pesquisa, aplicação de protocolos, procedimentos de admissão e alta.	23,2
8c. Realização de tarefas administrativas e gerenciais que requerem dedicação integral por cerca de 4 horas ou mais de tempo em algum plantão, tais como: morte e procedimentos de doação de órgãos, coordenação com outras disciplinas.	30,0
SUPORTE VENTILATÓRIO	
9. Suporte respiratório: Qualquer forma de ventilação mecânica/ventilação assistida com ou sem pressão expiratória final positiva, com ou sem relaxantes musculares; respiração espontânea com ou sem pressão expiratória final positiva (ex. CPAP ou BiPAP), com ou sem tubo endotraqueal; oxigênio suplementar por qualquer método.	1,4
10. Cuidado com vias aéreas artificiais. Tubo endotraqueal ou cânula de traqueostomia.	1,8
11. Tratamento para melhora da função pulmonar. Fisioterapia torácica, espirometria estimulada, terapia inalatória, aspiração endotraqueal.	4,4
SUPORTE CARDIOVASCULAR	
12. Medicação vasoativa independente do tipo e dose.	1,2
13. Reposição intravenosa de grandes perdas de fluídos. Administração de fluídos >31/m /dia, independente do tipo de fluído administrado.	2,5
14. Monitorização do átrio esquerdo. Cateter da artéria pulmonar com ou sem medida de débito cardíaco.	1,7
15. Reanimação cardiorrespiratória nas últimas 24 horas (excluído soco precordial).	7,1
SUPORTE RENAL	
16. Técnicas de hemofiltração. Técnicas dialíticas.	7,7

17. Medida quantitativa do débito urinário (ex. Sonda vesical de demora).	7,0
SUORTE NEUROLÓGICO	
18. Medida da pressão intracraniana	1,6
SUORTE METABÓLICO	
19. Tratamento da acidose/alcalose metabólica complicada.	1,3
20. Hiperalimentação intravenosa.	2,8
21. Alimentação enteral. Através de tubo gástrico ou outra via gastrointestinal (ex: jejunostomia).	1,3
INTERVENÇÕES ESPECÍFICAS	
22. Intervenções específicas na unidade de terapia intensiva. Intubação endotraqueal, inserção de marca-passo, cardioversão, endoscopia, cirurgia de emergência no último período de 24 horas, lavagem gástrica. Intervenções de rotina sem consequências diretas para as condições clínicas do paciente, tais como: Raio X, ecografia, eletrocardiograma, curativos ou inserção de cateteres venosos ou arteriais não estão incluídos.	2,8
23. Intervenções específicas fora da unidade de terapia intensiva. Procedimentos diagnósticos ou cirúrgicos.	1,9

Os sub-itens dos itens 1, 4, 6, 7 e 8 são mutuamente exclusivos.