

Combinando Elasticidade Proativa e Reativa para Gestão Multi-Hospitalar de Recursos Humanos no Contexto das Cidades Inteligentes

Gabriel Souto Fischer¹, Rodrigo da Rosa Righi¹, Cristiano André da Costa¹, Alex Roehrs¹

¹Software Innovation Lab - PPG em Computação Aplicada - Unisinos - RS, Brasil
Programa de Pós-Graduação em Computação Aplicada - Unisinos

gabriel.souto.fischer@gmail.com, {rrrighi, cac, alexr}@unisinos.br

Resumo. *A otimização da utilização de recursos em cidades inteligentes tem o potencial de melhorar o bem-estar dos cidadãos. Através do monitoramento contínuo da saúde das pessoas, é possível a identificação precoce de problemas médicos. No entanto, o problema dos hospitais superlotados persiste, conduzindo a longos períodos de espera para os pacientes que necessitam de tratamento. Trabalhos anteriores tentaram resolver esse problema, porém ainda existe a necessidade de uma solução que possa adequar de forma eficiente recursos humanos em múltiplos ambientes de saúde. Este trabalho apresenta o ElCareCity, um modelo focado em cidades inteligentes para monitorar o uso de ambientes de saúde pelos pacientes e adaptar a alocação de profissionais de saúde para atender às suas necessidades. ElCareCity introduz na literatura um algoritmo que combina abordagens de elasticidade reativa e proativa para alocar profissionais de saúde. O modelo foi avaliado por meio de emulações de uma cidade inteligente com quatro ambientes hospitalares e obteve resultados promissores que reduziram o tempo de espera por atendimento em até 86,8%.*

Abstract. *Optimizing the use of resources in smart cities has the potential to improve well-being of citizens. Through the continuous monitoring of people's health, it is possible to identify medical problems early. However, the problem of overcrowded hospitals persists, leading to long waiting times for patients needing treatment. Previous work has attempted to solve this problem, but there is still a need for a solution that can efficiently adapt human resources to multiple healthcare environments. This work presents ElCareCity, a model focused on smart cities to monitor patients' use of healthcare environments and adapt the allocation of healthcare professionals to meet their needs. ElCareCity introduces into the literature an algorithm that combines reactive and proactive elasticity approaches to allocate healthcare professionals. The model was evaluated through emulations of a smart city with four hospital environments and obtained promising results that reduced waiting time for care by up to 86.8%.*

1. Introdução

As cidades inteligentes aproveitam a integração da infraestrutura física e das tecnologias de informação e comunicação para otimizar a tomada de decisões e melhorar as operações da cidade [Fadhel et al. 2024], podendo melhorar a eficiência da utilização de recursos, otimizar a operação e os serviços urbanos e melhorar a qualidade de vida dos cidadãos

[Wang and Zhou 2023]. Várias aplicações e sistemas podem ser imaginados neste contexto, incluindo edifícios inteligentes, detecção ambiental, energia inteligente e saúde [Fadhel et al. 2024, Fischer et al. 2024].

Nessas cidades, sistemas de monitoramento de saúde em larga escala podem ser utilizados para monitorar pacientes em tempo real, permitindo a detecção precoce e adiantar a tomada de decisão relacionada à saúde dos cidadãos [Rodrigues et al. 2023]. Neste contexto, a alocação estática de profissionais de saúde acaba por ser ineficaz, destacando a necessidade de ajustar recursos humanos (RH) em tempo real. Na literatura, diversos trabalhos tentaram resolver esse problema, porém ainda existe a necessidade de uma solução para ajuste *on-the-fly* de RH em múltiplos ambientes de saúde. A elasticidade na computação em nuvem é uma das principais estratégias para adaptação dinâmica de recursos. As abordagens reativas são baseadas em limites estáticos e em regras *se-condição-então* para gerenciar a elasticidade, e as abordagens proativas tentam antecipar o comportamento do sistema para decidir as ações de adaptação de recursos [Ahamed et al. 2023].

Baseado nos conceitos de elasticidade e cidades inteligentes, foi proposto o modelo ElCareCity. Adicionando ao estado da arte um algoritmo que combina abordagens de elasticidade reativas e proativas, o ElCareCity oferece uma forma eficaz de alocar recursos humanos, propondo movimentações de pessoas e designando profissionais adicionais para as áreas com maior demanda, considerando suas limitações de tempo. A ideia é oferecer sempre um tempo de espera adequado à legislação independente do número de pacientes aguardando. A principal contribuição científica deste artigo é:

- (i) ElCareCity adiciona na literatura um algoritmo que combina as abordagens reativa e proativa da elasticidade em *cloud computing* para propor alocação dinâmica de profissionais de saúde em múltiplos hospitais.

2. Trabalhos Relacionados

Muitos estudos foram realizados para tentar resolver problemas relacionados com a alocação de recursos humanos em ambientes de saúde. Alguns artigos propõem o compartilhamento de recursos humanos entre hospitais [Hafezalkotob et al. 2022], outros propõem ajustes nos turnos de trabalho [Apornak et al. 2021a], outros apenas identificam o número de pessoas necessárias para atender a demanda de pacientes [Apornak et al. 2021b, Liao et al. 2022], e outros fazem ajustes *on-the-fly*, movimentando pessoas durante o dia de atendimento [Duma and Aringhieri 2023, Fischer et al. 2020, Lazebnik 2023]. A Tabela 1 fornece uma visão abrangente dos artigos coletados, apresentando alguns atributos-chave e destacando as lacunas existentes.

A análise dos trabalhos relacionados destaca um foco na insuficiência de recursos para atendimento aos pacientes ou resolução de problemas na área da saúde. Porém, nenhuma dessas abordagens buscou identificar o estado de saúde dos pacientes e ajustar a capacidade de atendimento antes que esse paciente chegue aos hospitais. Neste contexto, podemos evidenciar algumas das principais lacunas da área, que incluem:

- Esses modelos não possuem estratégias para lidar com o aumento da carga de recursos humanos *antes que ela ocorra*;
- Nenhuma dessas abordagens propõe um sistema para ajustes *on-the-fly* em múltiplos ambientes de saúde; e
- Faltam abordagens que avaliem o uso da elasticidade para a gestão de recursos humanos para múltiplos ambientes de saúde em Cidades Inteligentes.

Tabela 1. Trabalhos Relacionados

Trabalho	Foco	Solução proposta	Análise de sinais vitais	Alocação em tempo real
[Fischer et al. 2020]	Falta e RH para atendimento	Alocação adaptativa de recursos humanos usando predição e elasticidade	Não	Sim
[Apornak et al. 2021b]	Otimizar o custo de RH	Propõe ajustes de RH para diminuir custos usando algoritmo Bat	Não	Não
[Apornak et al. 2021a]	Otimizar o uso de RH	Propõe ajustes dos turnos de trabalho de RH usando algoritmos genéticos	Não	Não
[Hafezalkotob et al. 2022]	Falta de recursos em situações de desastre	Realocação de RH entre hospitais utilizando teoria dos jogos e otimização linear robusta	Não	Não
[Liao et al. 2022]	Falta de enfermeiros para atendimento	Identifica a quantidade necessária de enfermeiros usando teoria de filas	Não	Não
[Duma and Aringhieri 2023]	Otimizar o uso de RH	Propõe uma alocação adaptativa de RH usando predição e <i>Hybrid Activity Trees</i>	Não	Sim
[Lazebnik 2023]	Alocação de RH	Propõe alocação adaptativa de RH usando <i>Deep Reinforcement Learning</i>	Não	Sim

Com base nestes trabalhos, ficou evidente que melhorar a eficiência no uso dos recursos humanos é capaz de fazer a diferença na qualidade do atendimento ao paciente. Portanto, estratégias para adequar antecipadamente a capacidade de atendimento às necessidades dos ambientes hospitalares são importantes e necessárias. Embora os conceitos de cidades inteligentes sejam promissores para futuras soluções na área da saúde e automação de processos, o seu potencial continua a ser subutilizado, uma vez que é possível aproveitar estas tecnologias para propor soluções, otimizar e maximizar a utilização dos recursos humanos já existentes.

3. Modelo ElCareCity

ElCareCity aplica o conceito de elasticidade da computação em nuvem ao contexto de recursos humanos, permitindo ajustes na capacidade de atendimento hospitalar em resposta à demanda dos pacientes. Isso envolve alocação, desalocação e realocação dinâmicas de profissionais com base nas necessidades dos hospitais e das cidades inteligentes. ElCareCity consolida dados de várias fontes: entradas e sinais vitais de pacientes (usando sensores espalhados pela cidade, sensores conectados às pessoas e um conjunto de dados), movimento de pacientes (usando sensores) e disponibilidade de equipe médica (usando sensores e um conjunto de dados). Esses dados servem como base para a implementação da alocação de recursos baseada na elasticidade. Através deste modelo, ElCareCity calcula uma alocação otimizada de recursos humanos, o que contribui para a redução do tempo de espera dos pacientes, fator crítico em tempos de pandemias ou surtos virais.

O modelo se baseia na ideia de que cada indivíduo deve possuir um dispositivo vestível capaz de monitorar seu estado de saúde em tempo real. Esses sensores devem ser capazes de detectar alterações nos sinais vitais, como frequência cardíaca, variação da frequência cardíaca, frequência respiratória, temperatura e saturação de oxigênio [Rodrigues et al. 2023]. Além de coletar os sinais vitais, esses leitores devem ser capazes de indicar a localização dessas pessoas. Portanto, os dados que indicam anomalias nesses sinais são compactados e depois enviados para a nuvem da cidade, que é responsável por analisar esses dados e determinar se o paciente necessita de atendimento hospitalar.

Este modelo fornece uma infraestrutura de monitoramento abrangente para cidades inteligentes que pode ser usada para melhorar vários aspectos da saúde pública. ElCareCity usa duas abordagens diferentes para adquirir informações do paciente: uma infraestrutura de sensores nos ambientes hospitalares para identificar a localização dos

pacientes e aquisição de dados através do serviço VitalSense [Rodrigues et al. 2023] para cidades inteligentes, que é responsável por identificar as pessoas com sinais vitais alterados que estão na cidade e sua localização. VitalSense é uma solução escalável baseada em Fog para monitoramento e processamento em tempo real de dados de pacientes usando dispositivos vestíveis [Rodrigues et al. 2023].

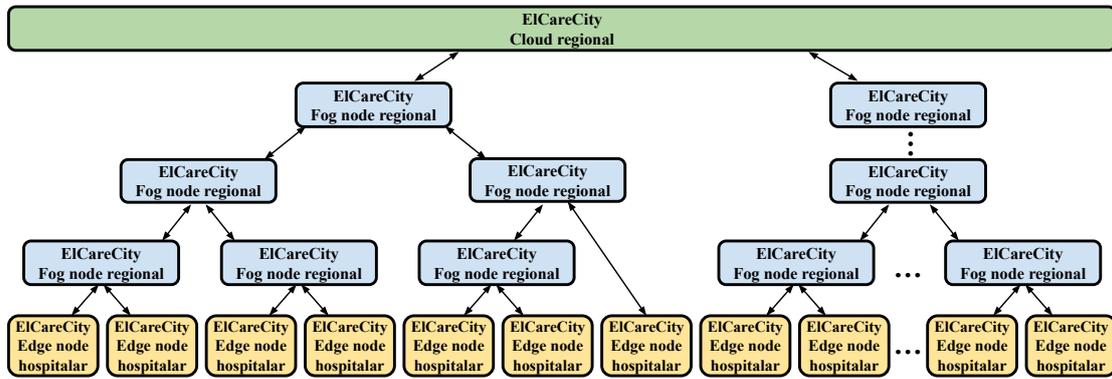


Figura 1. Solução hierárquica escalável do EICareCity.

EICareCity propõe uma solução hierárquica escalável (Figura 1) em que existem Edge nodes em hospitais que realizam seu processamento e tomam decisões de alocação localmente. Eles se comunicam com um Fog node mais alto na hierarquia. Os Fog nodes não precisam saber se o que está abaixo é o Edge node de um hospital ou se é outro Fog node, e nem sabem se o acima é o último nível. Desta forma, é possível adicionar mais hospitais em qualquer Fog node e quantos Fog nodes forem necessários.

3.1. Arquitetura

A arquitetura contempla dois serviços: (i) um serviço de *tomada de decisão*, responsável pelas decisões de gestão de recursos humanos; e (ii) um serviço Web, denominado EICareCity app, responsável pela camada de *visualização* para uso dos gestores hospitalares, recursos humanos, pacientes e pessoas em geral. Além disso, o EICareCity é subdividido em cinco módulos principais (Figura 2).

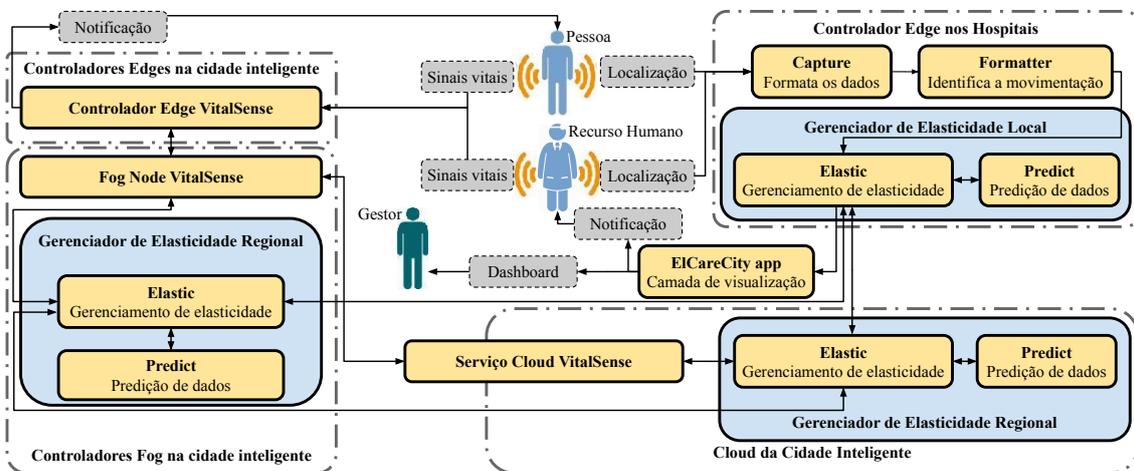


Figura 2. Arquitetura do modelo que combina elasticidade reativa e proativa.

Capture recebe e processa dados capturados por sensores espalhados pela cidade e envia para *Formatter*, responsável por identificar a movimentação dos pacientes. Posteriormente, *Predict* identifica o caminho que os pacientes percorrem pelo hospital e o tempo gasto em cada ambiente. Utilizando esses dados, *Predict* identifica padrões relacionados à chegada de pacientes nesses ambientes e ao tempo de espera pelo atendimento, utilizando essas informações para prever as chegadas futuras de pacientes. *Elastic* verifica a disponibilidade de recursos humanos em cada ambiente hospitalar e gera uma alocação otimizada de recursos humanos. *Elastic* e *Predict* podem ser executados tanto na Edge, na Fog e na Cloud. Por fim, o *ElCareCity app* exibe informações processadas, enviando notificações de elasticidade para recursos humanos ou gerando dashboards para gestores.

3.2. Elasticidade Multinível de Recursos Humanos em Cidades Inteligentes

ElCareCity apresenta uma abordagem multinível para realizar alocação, desalocação e realocação de recursos humanos em múltiplos hospitais de uma cidade inteligente. Com base nesta abordagem, o modelo considera a elasticidade de recursos humanos de forma diferente: (i) No *nível da sala*, onde deve identificar o uso futuro de uma determinada sala, e verificar se o número de atendentes é suficiente para atender a demanda dos pacientes, em (ii) No *nível de hospital*, onde deve verificar se há atendentes suficientes para atender a demanda dos pacientes em todos as salas do ambiente hospitalar, com os atendentes se movimentando entre as salas, e (iii) No *nível regional*, onde deve verificar se há atendentes suficientes para atender a demanda dos pacientes nas regiões da cidades inteligentes, com os atendentes se movimentando entre hospitais, e também propondo movimentação de pacientes para hospitais mais adequados. Um diagrama desses três níveis é apresentado na Figura 3. Ainda, o modelo adapta uma estratégia de elasticidade proativa utilizando limites superiores e inferiores, com base no tempo de espera por atendimento em cada uma das filas de espera de uma cidade inteligente, conforme ilustrado na Figura 4.



Figura 3. Níveis para elasticidade proativa e reativa de recursos humanos.

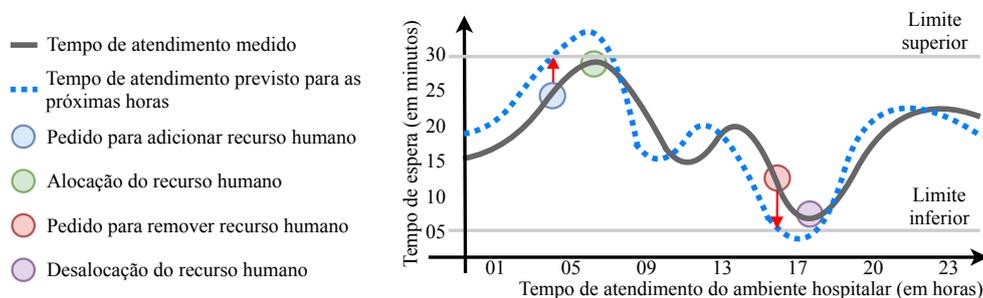


Figura 4. Elasticidade proativa baseada nos tempos de espera.

No nível de sala, em cada ciclo de monitoramento, é gerada uma série temporal para o número de pacientes chegando e para o tempo de atendimento. Essas séries temporais servem como entrada para o modelo de previsão ARIMA [Sharma et al. 2024]. Consequentemente, quando o modelo prevê tempos de espera que não estão de acordo com os

limites estabelecidos, o ElCareCity deve calcular a quantidade de recursos humanos necessários para atender a demanda de pacientes, identificando a necessidade de ajustes em determinada sala. O modelo utiliza uma alocação paralela de recursos humanos, inspirada em estratégias semelhantes usadas em sistemas elásticos [Rodrigues et al. 2023].

A Equação 1 define o *Speedup Proativo de Recursos Humanos* para uma sala r entre dois tempos f_i e f_f , considerando uma alocação proativa de a atendentes. Dessa forma, é possível estimar o tempo de atendimento dos pacientes antes que ocorra qualquer sobrecarga, permitindo que o hospital ajuste seus recursos de forma proativa para garantir um bom nível de atendimento ao paciente.

$$PHRS(r, a, f_i, f_f) = \frac{ACT(r, f_i, f_f)' \cdot ENP(r, f_i, f_f)'}{a} \quad (1)$$

onde a é o número de atendentes alocados entre os tempos futuros f_i e f_f , e $ACT(r, f_i, f_f)'$ e $ENP(r, f_i, f_f)'$ são previsões do tempo médio de atendimento e da quantidade estimada de pacientes em uma sala r , respectivamente, usando ARIMA e uma análise dos sinais vitais alterados das pessoas em suas casas que possivelmente precisarão de atenção médica num futuro próximo. Alterando o atributo a na equação $PHRS$, com aumento e diminuição do número de profissionais de saúde presentes, o modelo pode identificar quantos atendentes seriam necessários para ajustar o tempo de espera de qualquer sala aos limites propostos pelos gestores da cidade inteligente. O Algoritmo 1 apresenta o método para verificar a necessidade de alocar ou desalocar recursos humanos em qualquer sala r de um hospital inteligente.

Algoritmo 1: Elasticidade proativa no nível de sala

Entrada: Sala r , a atendentes, tempo inicial futuro f_i , tempo final futuro f_f

Saída: Quantidade de atendentes para alocar ou desalocar

```

1  início
2  upper ← limite superior de tempo de espera em r;
3  lower ← limite inferior de tempo de espera em r;
4  n ← 0;
5  a' ← a;
6  se PHRS(r, a, f_i, f_f) > upper então
7      enquanto a' < limit(r) e PHRS(r, a', f_i, f_f) > upper faça
8          n ← n + 1;
9          a' ← a + n;
10     fim
11  senão se PHRS(r, a, f_i, f_f) < lower então
12     enquanto a' > 0 e PHRS(r, a', f_i, f_f) < lower faça
13         n ← n - 1;
14         a' ← a + n;
15     fim
16  fim
17  retorna n;
18 fim

```

Além disso, foi observado que confiar apenas em métodos preditivos pode ser vulnerável à circunstâncias imprevisíveis. Como resultado, o modelo também sugere a adoção de uma estratégia reativa, onde é avaliado periodicamente se há salas desocupadas. Caso existam tais salas, os profissionais de saúde podem ser redirecionados para a sala com maior necessidade naquele determinado momento (dentro do mesmo hospital). O Algoritmo 2 apresenta o método reativo para verificar a necessidade de alocar ou desalocar recursos humanos em qualquer sala r de um hospital inteligente.

Algoritmo 2: Elasticidade reativa no nível de sala

Entrada: Sala r
Saída: Quantidade de atendentes para alocar ou desalocar

```
1 início
2    $awaiting \leftarrow$  Número de atendentes aguardando na sala  $r$ ;
3    $hr \leftarrow$  Número de recursos humanos alocados na sala  $r$ ;
4   se  $awaiting < 1$  e  $hr > 0$  então
5      $n \leftarrow 1$ ;
6   senão se  $awaiting > 1$  e  $hr < limit(r)$  então
7      $n \leftarrow -1$ ;
8   senão
9      $n \leftarrow 0$ ;
10  fim
11  retorna  $n$ ;
12 fim
```

Outro ponto observado é que a utilização de limites fixos na elasticidade preditiva pode ocasionar momentos em que ela é ultrapassada mesmo com as ações de elasticidade. Assim, foi proposta uma estratégia de *live thresholding* [Rodrigues et al. 2017] em que, sempre que o limite superior é ultrapassado, ele é reduzido em 5 minutos, limitado a metade do limite original da sala.

Algoritmo 3: Elasticidade proativa no nível de hospital

Entrada: Lista de salas h , vetor v com os atendentes, tempo futuro inicial f_i , tempo futuro final f_f
Saída: Vetor de salas e quantidade de atendentes por alocar ou desalocar l

```
1 início
2    $l \leftarrow$  um novo vetor de salas e quantidade de atendentes para alocar e desalocar;
3   para cada sala  $r$  na lista de salas  $h$  faça
4      $a \leftarrow$  quantidade de atendentes alocados em  $r$ ;
5      $q \leftarrow$  executa o Algoritmo de Elasticidade proativa no nível de sala usando  $r$ ,  $a$ ,  $f_i$  e  $f_f$  como entrada;
6      $l.add(r, q)$ ;
7   fim
8   sort  $l$ , pela quantidade de atendentes disponíveis;
9    $l \leftarrow$  executa o Algoritmo de Desalocação de RH usando  $l$  e  $a$  os atendentes alocados de  $v$  como entrada;
10  sort  $l$ , pela quantidade de atendentes disponíveis;
11  para cada sala  $r$  na lista  $l$  faça
12     $l_r \leftarrow$  sort  $l$ , pela quantidade de atendentes disponíveis com a especialidade da sala  $r$ ;
13    executa o Algoritmo de Realocação de Recursos Humanos usando  $r$  e  $l_r$  como entrada;
14  fim
15   $h \leftarrow$  salas do vetor  $l$ ;
16  retorna  $l$ ;
17 fim
```

No nível de hospital, o modelo precisa lidar com as solicitações à nível de sala de todo o hospital que está sendo analisado. O objetivo é garantir que cada sala tenha o número necessário de atendentes, considerando apenas a realocação de profissionais de saúde entre diferentes setores ou a desalocação de recursos humanos que já não são necessários. No modelo proposto, cada sala tem uma especialidade necessária aos recursos humanos que nela estão alocados. Paralelamente, cada profissional de saúde possui uma lista com todas as suas especialidades. O processo de realocação de recursos humanos é realizado apenas entre profissionais que possuam a especialidade de sala de destino. O algoritmo também identifica situações em que a demanda por atendimento em todos os quartos do hospital é baixa o suficiente para desalocar alguns atendentes sem afetar a qualidade do atendimento ao paciente. Nesses casos, o EICareCity identifica quais atendentes estão trabalhando além do horário normal de trabalho e os desaloca. Algoritmo 3 apresenta o pseudocódigo para elasticidade proativa no nível de hospital, enquanto o Al-

goritmo 4 apresenta o pseudocódigo para a elasticidade reativa no nível de hospital.

Algoritmo 4: Elasticidade reativa no nível de hospital

Entrada: Lista de salas h , vetor v com todos os atendentes do hospital
Saída: Vetor de salas e quantidade de atendentes por alocar ou desalocar l

```

1 início
2    $l \leftarrow$  um novo vetor de salas e quantidade de atendentes para alocar e desalocar;
3   para cada sala  $r$  na lista de salas  $h$  faça
4      $a \leftarrow$  quantidade de atendentes alocados em  $r$ ;
5      $q \leftarrow$  executa o Algoritmo de Elasticidade reativa no nível de sala usando  $r$  como entrada;
6      $l.add(r, q)$ ;
7   fim
8   sort  $l$ , pela quantidade de atendentes disponíveis;
9   para cada Sala  $r$  na lista  $l$  faça
10     $l_r \leftarrow$  sort  $l$ , pela quantidade de atendentes disponíveis com a especialidade da sala  $r$ ;
11    executa o Algoritmo de Realocação de Recursos Humanos usando  $r$  e  $l_r$  como entrada;
12  fim
13   $h \leftarrow$  salas do vetor  $l$ ;
14  retorna  $l$ ;
15 fim

```

Sistemas elásticos estão sujeitos à *histerese*, a tendência do sistema de retornar ao estado anterior na ausência do impulso que causou a mudança. No contexto do ElCareCity, a histerese ocorre quando um recurso humano volta a ser necessário na sala que o liberou anteriormente. Para evitar a histerese de recursos humanos, empregamos uma estratégia de *cooldown-period*. Quando um recurso é realocado entre hospitais diferentes, ele não pode retornar imediatamente à sala anterior. Desta forma, a necessidade de uma sala só será atendida se houver recursos livres em outro local.

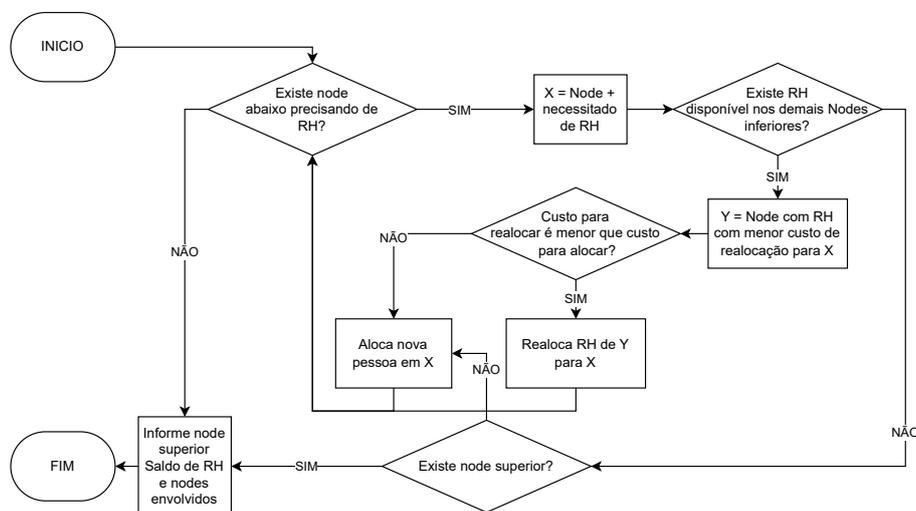


Figura 5. Fluxograma da elasticidade de recursos humanos no nível regional.

4. Metodologia de Avaliação

No nível regional, o modelo precisa lidar com os pedidos de elasticidade a nível de hospital de todos os hospitais vinculados àquela região da cidade inteligente que está sendo analisada. O objetivo é garantir que cada sala de cada hospital tenha o número necessário de atendentes. Neste nível, o algoritmo segue a mesma ideia do nível anterior, mas considerando a possibilidade de movimentar profissionais de saúde entre hospitais diferentes e também alocar novos profissionais se necessário. Para este processo, foi proposta uma

nova definição para o custo de alocação ou realocação de pessoas. Este custo é o tempo estimado de movimentação fornecido em tempo real pela *Distance Matrix API* do *Google Cloud*¹, somando o tempo médio do processo de alocação interna. A Figura 5 apresenta o fluxograma para elasticidade de recursos humanos executado em cada node regional. Como no nível anterior, apenas profissionais com a especialidade da sala de destino são realocados ou alocados.

Para avaliar o modelo, foi realizada uma emulação de um conjunto de quatro hospitais localizados em uma cidade inteligente hipotética. Levando em consideração a inacessibilidade de dados reais de um conjunto de hospitais, para cada ambiente de saúde, foram utilizados os parâmetros de um ambiente de saúde real localizado em Guarulhos, Brasil [Capocci et al. 2017]. Em relação à carga de pacientes, definimos cargas de trabalho sintéticas com base na carga real deste mesmo ambiente mencionado acima. Cargas de trabalho sintéticas são amplamente utilizadas na comunidade acadêmica para avaliar a eficácia de abordagens de elasticidade [Rodrigues et al. 2017]. Para avaliar o modelo proposto, consideramos dois cenários distintos: **C1**: *Cidade sem nenhuma estratégia de gestão de recursos humanos*; e **C2**: *Cidade com o uso do modelo elástico ElCareCity*.

No Brasil, o modelo adotado para ambientes hospitalares é o 12x36. Assim, com base no Decreto-Lei nº 5.452 [Brazilian government 1943], algumas condições devem ser atendidas para que um profissional seja considerado para alocação: **Regra 1**: O período mínimo de descanso para que um recurso humano esteja disponível para alocação é de onze horas; **Regra 2**: Um funcionário alocado não está autorizado a trabalhar fora do seu turno normal por mais de doze horas; **Regra 3**: Os funcionários alocados deverão ser desalocados no máximo 11 horas antes do próximo turno normal de trabalho; e **Regra 4**: Cada funcionário deverá ter um período de descanso de trinta e seis horas na mesma semana.

Foram estabelecidos limites adequados para dados hospitalares brasileiros neste estudo de caso. O limite superior (100%) foi definido em 30 minutos, conforme Projeto de Lei de 14 de junho de 2018 [Fabio 2018] e o limite inferior foi definido em 9 minutos (30% do limite superior). Para as ações de elasticidade, foi estabelecido um processo de realocação a nível de hospital de 10 minutos (movimentação de recursos humanos entre salas do mesmo hospital), um processo de realocação a nível regional de 60 minutos (movimentação de recursos humanos entre hospitais) e um processo de alocação de 60 minutos (simulando a movimentação de um novo recurso humano para o hospital).

O modelo utilizou uma alocação de 11 recursos humanos por turno e por hospital, conforme encontrado em [Capocci et al. 2017]. Em relação à carga de pacientes, foram modeladas diferentes cargas de ondas para cada hospital na cidade inteligente proposta. O comportamento da carga em onda é baseado no proposto por [Rodrigues et al. 2017].

Para avaliar o modelo, foram consideradas as seguintes métricas: (i) *Tempo máximo de espera*; e (ii) *Quantidade elástica de recursos humanos*. Para a primeira métrica, esperava-se que o ElCareCity proporcione uma redução no tempo médio de espera. Já para a segunda métrica, o objetivo é que o ElCareCity otimize o uso dos profissionais disponíveis no hospital. Dessa forma, a alocação estática normalmente empregada nos hospitais será comparada com a alocação elástica proposta nesse trabalho.

¹<https://developers.google.com/maps/documentation/distance-matrix/overview>

5. Avaliação e Discussão dos Resultados

Duas emulações da cidade proposta foram realizadas para coleta de dados. Cada cenário proposto, C1 e C2, envolveu a emulação de quatro hospitais, resultando em um total de oito conjuntos de dados para comparação. O objetivo da primeira métrica era reduzir o tempo de espera pelo tratamento. A Figura 6 ilustra o tempo máximo de espera observado nos cenários sugeridos. Foi observada uma diminuição substancial no tempo máximo de espera em ambientes hospitalares quando comparados C1 e C2. O modelo provou ser eficaz na redução do tempo de espera em 80,79%, 88,32%, 89,11% e 89,11% para Hospital 1, Hospital 2, Hospital 3 e Hospital 4, respectivamente, totalizando uma redução de 86,8% na média da cidade inteligente, em comparação aos hospitais não elásticos.

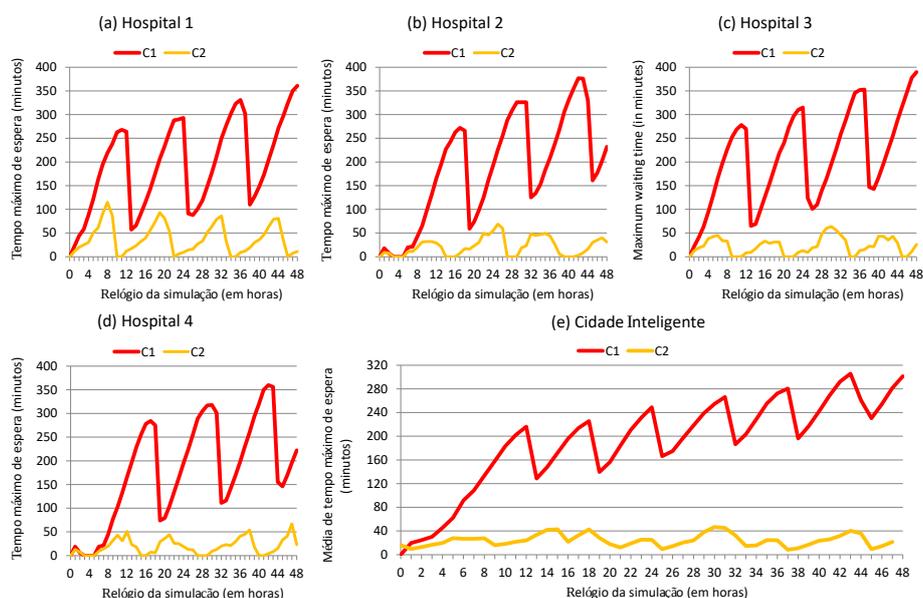


Figura 6. Tempo máximo de espera aferido na emulação combinando elasticidade reativa e proativa.

Esperava-se que a segunda métrica mostrasse um aumento no número de recursos humanos no hospital, bem como flutuações nesse número durante o período de atendimento. A Figura 7 mostra a quantidade elástica de recursos humanos utilizados em C2, único cenário em que o número de funcionários pode variar. Observou-se que o número de recursos humanos variava de 22 a 26 por hora, considerando toda a cidade inteligente. Além disso, a Figura 7 mostra que sempre que o modelo realoca ou aloca profissionais para o serviço, o tempo de espera diminui. Com base nas métricas estabelecidas, pode-se concluir que o modelo melhorou o desempenho dos hospitais da cidade emulada. O tempo máximo de espera diminuiu entre os cenários C1 e C2, cumprindo o objetivo desta métrica, conforme proposto na metodologia de avaliação. Quanto à quantidade elástica de recursos humanos utilizados, o aumento esperado entre os cenários também foi alcançado.

Diferentemente do estado da arte, ElCareCity é capaz de gerenciar recursos humanos e pacientes para reduzir a sobrecarga nos ambientes de saúde, analisando o estado de saúde das pessoas fora dos hospitais, propondo ajustes proativos na capacidade de atendimento e automatizando a tomada de decisões. Assim, nosso modelo teve resultados animadores, agregando uma nova visão de Gestão de Recursos Humanos para o contexto de saúde em cidades inteligentes. Embora tenham sido alcançados resultados encorajadores, é importante salientar que existem limitações que devem ser abordadas ao

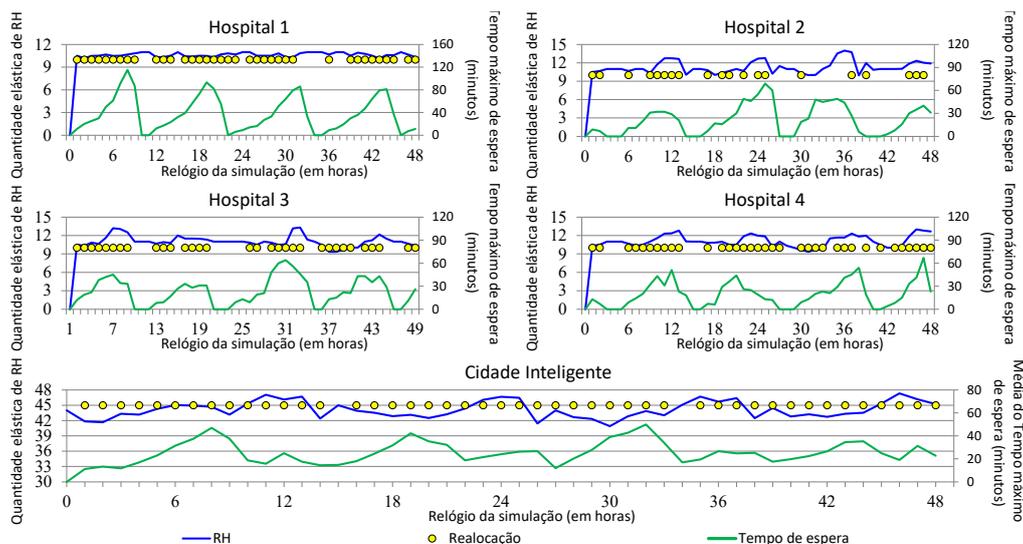


Figura 7. Quantidade elástica de recursos humanos utilizados em comparação com o tempo máximo de espera nos hospitais no Cenário C2, combinando elasticidade reativa e proativa.

implementar o modelo numa cidade real. É necessário garantir que funcionários e pacientes carreguem seus dispositivos vestíveis para que o modelo funcione corretamente. Além disso, o modelo gera notificações apenas para os recursos humanos, sendo necessário que eles sigam as recomendações. Outra limitação é a instalação prévia do sistema de sensores em todos os ambientes hospitalares e em toda a cidade inteligente. Portanto, estas limitações devem ser abordadas para garantir a eficácia do modelo numa cidade real.

6. Conclusão

Este artigo apresentou o modelo ElCareCity, que visa resolver o problema de alocação estática de recursos humanos em ambientes de saúde em uma cidade inteligente. Diferentemente de trabalhos relacionados, o modelo não utiliza apenas técnicas de previsão para antecipar problemas, mas também propõe um modelo para alocar, realocar e desalocar profissionais em hospitais. Assim, o conceito de elasticidade da computação em nuvem foi estendido ao contexto da gestão de recursos humanos, apresentando novos algoritmos para proporcionar uma alocação dinâmica e elástica de profissionais. Espera-se que o modelo ajude a reduzir o tempo de espera dos pacientes para atendimento de saúde, conforme mostrado no estudo de caso, no qual o tempo de espera diminuiu mais de 86,8%.

Para implementar um modelo neste nível de compartilhamento de recursos humanos, devem existir políticas públicas que permitam a captura de dados a este nível e o compartilhamento dos mesmos entre os envolvidos, e que permitam o compartilhamento de profissionais. O grande incentivo para as políticas públicas é a possibilidade de salvar vidas. Inicialmente, prevê-se a implementação do modelo em uma rede pública municipal de saúde, desta forma todos os profissionais de saúde são funcionários públicos municipais. Pretende-se implementar o modelo proposto na cidade de Porto Alegre.

Em trabalhos futuros espera-se adaptar o modelo para utilizar outros algoritmos de predição, como redes neurais ou *florestas aleatórias*. Espera-se também identificar qual o impacto que a alocação dinâmica de profissionais tem sobre os próprios profissionais e como a qualidade do serviço seria impactada ao utilizar tal metodologia.

Referências

- Ahamed, Z., Khemakhem, M., Eassa, F., Alsolami, F., and Al-Ghamdi, A. S. A.-M. (2023). Technical study of deep learning in cloud computing for accurate workload prediction. *Electronics*, 12(3).
- Apornak, A., Raissi, S., Keramati, A., and Khalili-Damghani, K. (2021a). Human resources optimization in hospital emergency using the genetic algorithm approach. *International Journal of Healthcare Management*, 14(4):1441–1448.
- Apornak, A., Raissi, S., Keramati, A., and Khalili-Damghani, K. (2021b). Optimizing human resource cost of an emergency hospital using multi-objective bat algorithm. *International Journal of Healthcare Management*, 14(3):873–879.
- Brazilian government (1943). Decreto-Lei No 5.452, de 1 de maio de 1943.
- Capocci, N., Nascimento, B., Lopes, F., Rodrigues, E., and Maiellaro, J. (2017). Simulation as a hospital management support tool. *Indep. J. Manag. Prod.*, 8(5):798–811.
- Duma, D. and Aringhieri, R. (2023). Real-time resource allocation in the emergency department: A case study. *Omega*, 117:102844.
- Fabio, Z. (2018). Projeto de Lei, de 14 de junho de 2018.
- Fadhel et al. (2024). Comprehensive systematic review of information fusion methods in smart cities and urban environments. *Information Fusion*, 107:102317.
- Fischer, G. S., da Costa, C. A., and da Rosa Righi, R. (2020). Usando IoT e Conceitos de Elasticidade em Cloud para Análise de Recursos Humanos em Hospitais Inteligentes. In *Anais do XX Simpósio Brasileiro da Computação Aplicada à Saúde (SBCAS 2020)*.
- Fischer, G. S., Rodrigues, V. F., da Rosa Righi, R., da Costa, C. A., Policarpo, L. M., and Silva, R. G. G. (2024). Looking at smart cities through the lens of a pandemic era: A systematic literature review. *Int. J. Technol. Manage.*, 94(3-4).
- Hafezalkotob, A., Fardi, K., Aickelin, U., Chaharbaghi, S., and Akbarzadeh Khorshidi, H. (2022). A cooperative robust human resource allocation problem for healthcare systems for disaster management. *Computers & Industrial Engineering*, 170:108283.
- Lazebnik, T. (2023). Data-driven hospitals staff and resources allocation using agent-based simulation and deep reinforcement learning. *Eng. Appl. Artif. Intel.*, 126:106783.
- Liao, P.-H., Chu, W., and Ho, C.-S. (2022). An analysis of waiting time for emergency treatment and optimal allocation of nursing manpower. *Healthcare*, 10(5).
- Rodrigues, V. F., Righi, R. D. R., Rostirolla, G., Barbosa, J. L. V., da Costa, C. A., Alberti, A. M., and Chang, V. (2017). Towards enabling live thresholding as utility to manage elastic master-slave applications in the cloud. *J. Grid Comput.*, 15(4):535–556.
- Rodrigues, V. F., Righi, R. R., Costa, C. A., Zeiser, F. A., Eskofier, B., Maier, A., and Kim, D. (2023). Digital health in smart cities: Rethinking the remote health monitoring architecture on combining edge, fog, and cloud. *Health Technol.*, 13(3):449–472.
- Sharma, A., Punj, P., Kumar, N., Das, A., and Kumar, A. (2024). Lifetime prediction of a hydraulic pump using arima mode. *Arab J Sci Eng*, 49:1713–1725.
- Wang, M. and Zhou, T. (2023). Does smart city implementation improve the subjective quality of life? evidence from china. *Technology in Society*, 72:102161.