

Usando Dados de Sinais Vitais dos Cidadãos e a Técnica de Elasticidade para gerência de Hospitais no Contexto de Cidades Inteligentes

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

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

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

Resumo. *A pandemia de COVID-19 agravou a superlotação hospitalar. Em cidades inteligentes, a saúde das pessoas pode ser monitorada em tempo real para detectar situações que exijam suporte médico. Neste contexto, propomos o modelo CityHealth, baseado no conceito de elasticidade em Cloud Computing, onde é possível adicionar, migrar ou remover recursos de acordo com a necessidade. Ele monitora o uso dos ambientes de saúde e adapta a capacidade de atendimento de acordo com a demanda. Através de uma abordagem preditiva, o CityHealth antecipa a sobrecarga de ambientes de saúde e propõe ações para movimentação dos recursos humanos e otimizar o atendimento. Utilizando dados de uma policlínica como base para emulação de uma cidade inteligente com dois hospitais resultou em redução de até 95,6% no tempo de espera.*

1. Introdução

Cidades inteligentes integram infraestrutura física, tecnologia da informação e comunicação, serviços sociais e recursos empresariais para otimizar a tomada de decisões e melhorar as operações da cidade, aumentando a eficiência na utilização de recursos, otimizando a gestão e os serviços urbanos e melhorando a qualidade de vida dos cidadãos [Alshamaila et al. 2023, Lucic et al. 2023, Wang and Zhou 2023]. As cidades inteligentes utilizam várias tecnologias de informação e conceitos inovadores, como Internet of Things (IoT) e Cyber-Physical Systems (CPS), oferecendo várias aplicações e sistemas, como gerenciamento de resíduos, detecção ambiental, e assistência médica [Ali et al. 2023, Sidorov 2023, Pandya et al. 2023, Fischer et al. 2022].

A pandemia do COVID-19 teve um grande impacto global, resultando em mais de 6,8 milhões de mortes em três anos [Xiang et al. 2023, Google News 2023]. Apesar dos avanços tecnológicos, o mundo não estava preparado para essa doença que se espalhou rapidamente pelo globo. A prevenção e o controle de pandemias requerem novas tecnologias, e projetos para cidades inteligentes têm sido usados para isso. [Xiang et al. 2023]. Embora essas ideias tenham sido propostas para a pandemia do COVID-19, elas podem ser aplicadas a outras situações, como epidemias, pandemias e surtos.

Em cidades inteligentes, pacientes podem ser monitorados continuamente, permitindo a detecção e tratamento de situações de risco [Rodrigues and Righi 2022]. Nesse cenário, a alocação estática de profissionais de saúde é ineficiente, tornando fundamental a adaptação dos recursos humanos em tempo real. A elasticidade em

computação em nuvem é uma das principais estratégias para adaptar recursos sob demanda [Thakkar and Bhavsar 2023]. Uma abordagem proativa tenta antecipar o comportamento do sistema e decidir as ações de adaptação de recursos [Ahamed et al. 2023].

Baseado na elasticidade da computação em nuvem, é apresentado o modelo CityHealth como alternativa à alocação estática tradicional da equipe médica. O CityHealth funciona ajustando a alocação da equipe médica com base em uma abordagem proativa de elasticidade. Em particular, o CityHealth usa sensores vestíveis para acompanhar a demanda de pacientes. Essas estimativas permitem identificar situações onde é improvável que a disponibilidade de pessoal atenda à demanda. Em vez de ajustar a capacidade de atendimento dos hospitais com base na chegada de pacientes em emergências, é possível ajustar essa capacidade antecipadamente. Em vez de o paciente ir ao hospital e aguardar em ambientes superlotados, assim que o sistema identifica problemas de saúde, ele automaticamente insere esse paciente em uma fila virtual. Em seguida, ajusta a capacidade de atendimento do hospital de acordo com a demanda emergencial atual e futura nas filas virtuais. Por fim, o sistema chama o paciente ao hospital apenas quando a capacidade de atendimento já estiver ajustada à demanda. A ideia é sempre oferecer um tempo de espera razoável independente da quantidade de pacientes.

2. Trabalhos Relacionados

Algumas abordagens focaram na otimização do fluxo de pacientes para melhor alocar recursos. [Capocci et al. 2017] usaram a simulação discreta de eventos para propor algumas mudanças e balancear os níveis de ocupação dos profissionais de saúde e alcançar um tempo menor de espera pelos pacientes. [Vieira and Hollmén 2016] investigaram maneiras de minimizar gargalos no fluxo de pacientes devido a consultas, visitas, uso de recursos, etc. Na mesma linha de pensamento, [Graham et al. 2018] focaram em prever a chegada de pacientes na emergência de um hospital para preparar a alocação da equipe médica. [Franke et al. 2018] abordou a falta de recursos humanos, propondo o compartilhamento de funcionários entre hospitais usando uma *pool* de recursos humanos. [Hafezalkotob et al. 2022] focaram na falta de recursos para atendimento em situações de desastre e propuseram a realocação de recursos através do uso da teoria dos jogos e formulação linear robusta. Por fim, [Liao et al. 2022] focaram em identificar quantos enfermeiros são necessários para atendimento através do uso da teoria das filas.

Os trabalhos selecionados destacam a falta de recursos para o atendimento aos pacientes, que pode ser resolvido com tecnologias como IoT ou IA. Muitos sistemas de monitoramento de saúde dos pacientes foram desenvolvidos. Nesse contexto, podemos enumerar as principais lacunas na área da seguinte maneira:

- Embora possam identificar a demanda, faltam soluções concretas para resolver a deficiência de recursos hospitalares antes que o problema aconteça.
- É necessário otimizar processos de forma automatizada, integrando os sinais vitais captados com a capacidade dos hospitais e desenvolver propostas de cidades inteligentes que relacionem a admissão de pacientes com os sinais vitais da população.

A falta de recursos humanos na área da saúde é um problema antigo e que deve continuar no futuro próximo. É importante otimizar o uso dos recursos existentes e ajustar a capacidade dos hospitais para atender a demanda de pacientes. A Previsão de Dados e a Internet das Coisas são tecnologias que podem contribuir para a automação de processos na área da saúde, porém seu potencial está subaproveitado.

3. Modelo CityHealth

O CityHealth é um modelo preditivo para alocação eficiente de recursos humanos em cidades inteligentes. O CityHealth adapta o conceito de elasticidade da computação em nuvem ao contexto de recursos humanos, ajustando a capacidade de atendimento do hospital à demanda de pacientes, onde os profissionais são alocados, desalocados e realocados de acordo com as necessidades da cidade inteligente. O modelo agrupa informações de várias fontes: chegadas e necessidades de pacientes (usando sensores espalhados pela cidade, sensores junto aos paciente e um conjunto de dados da cidade), movimentação de pacientes (usando sensores) e disponibilidade da equipe médica (usando sensores e um conjunto de dados). Usando essas informações, é mensurada a demanda de pacientes dentro e fora dos ambientes de saúde para antecipar a demanda futura.

O modelo assume que cada pessoa deve usar um dispositivo vestível e monitorar seu estado de saúde em tempo real na cidade inteligente, dentro ou fora dos ambientes de saúde. Leitores espalhados pela cidade recebem dados dos sensores dos cidadãos, que podem identificar variações nos sinais vitais como frequência cardíaca, variação da frequência cardíaca, frequência respiratória, temperatura e saturação de oxigênio. Esses leitores também podem localizar com precisão as pessoas e encaminham os dados de anomalias para a nuvem da cidade, que analisa esses dados e identifica a necessidade de atendimento hospitalar. O modelo deve ser transparente para os pacientes, no sentido de que eles não precisam relatar nenhuma condição relacionada a sua movimentação no ambiente hospitalar, sendo uma atividade realizada automaticamente pelo sistema.

Assim, o CityHealth usa duas abordagens para obter informações do paciente: uma infraestrutura de sensores nos ambientes hospitalares para identificar a localização dos pacientes e aquisição de dados através do serviço MinhaHistoriaDigital [Rodrigues and Righi 2022]. Este serviço usa dispositivos vestíveis para monitorar e processar em tempo real os dados de pacientes, fornecendo alarmes para situações críticas de saúde através da aplicação de algoritmos de previsão e agregação de dados.

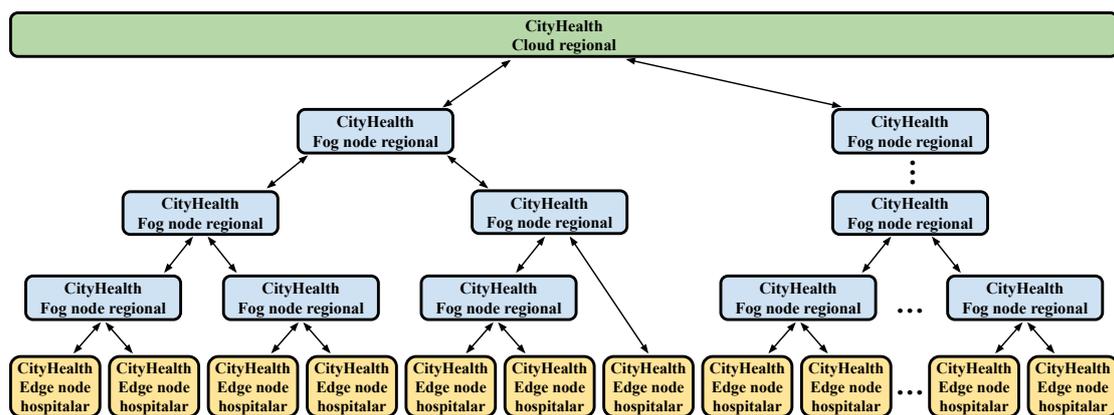


Figura 1. Solução hierárquica escalável da CityHealth.

CityHealth propõe uma solução hierárquica escalável onde têm-se Edge nodes em hospitais, que fazem seu processamento e tomam decisões de alocação localmente. Estes se comunicam com um Fog node mais alto na hierarquia. Os Fog nodes não precisam saber se abaixo existe um Edge node de um hospital ou se é outro Fog node, e eles nem sabem se o node acima é o último nível. Assim, na cloud executa-se o mesmo algoritmo

dos Fog nodes, só que sabendo que não existem níveis acima. A Figura 1 mostra a solução hierárquica escalável da HealCity onde podemos adicionar mais hospitais sob qualquer Fog node e quantos Fog nodes forem necessários.

3.1. Arquitetura

A arquitetura contempla três serviços: (i) um web service, responsável pela camada de visualização; (ii) um serviço de inferência, responsável pelo processamento de dados, registros de movimentação, medição e predição da demanda de pacientes, e tomada de decisão da alocação de recursos humanos; e (iii) um serviço de banco de dados. Ainda, o CityHealth é subdividido em cinco módulos principais. A Figura 2 apresenta os módulos propostos, detalhando a arquitetura do modelo.

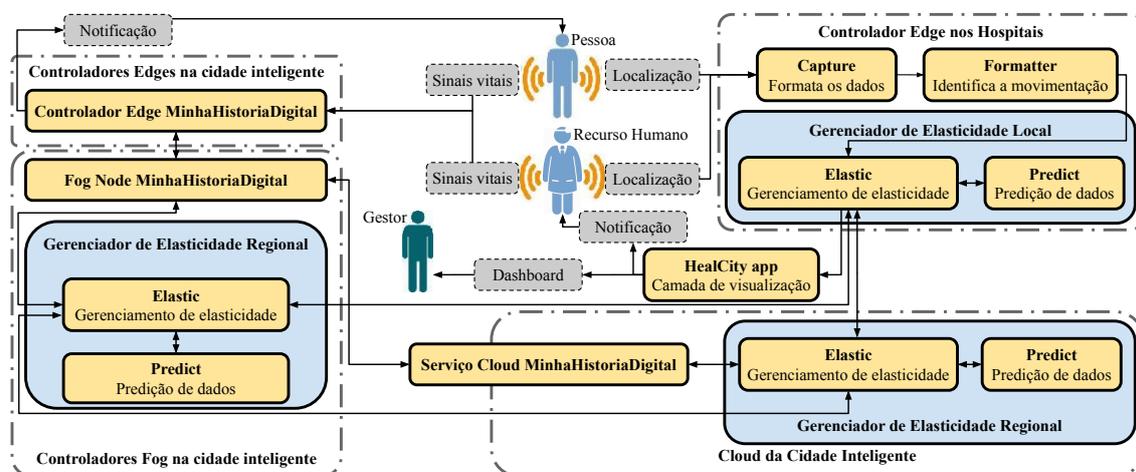


Figura 2. Detalhamento da arquitetura do modelo.

O módulo *Capture* recebe e processa os dados capturados pelos sensores espalhados pelo hospital e encaminha para o módulo *Formatter*, responsável por identificar a movimentação das pessoas. Após, o módulo *Predict*, identifica os padrões relacionados a chegadas de pacientes em cada ambiente do hospital, e os padrões relacionados ao tempo de espera por atendimento, e utiliza essa informação para prever a chegada futura de pacientes em cada sala do hospital. O módulo *Elastic* faz o gerenciamento de elasticidade do sistema, verificando a alocação de recursos humanos em cada ambiente e a movimentação dos pacientes, e compara com as previsões feitas pelo módulo anterior. Este módulo gera uma alocação inteligente e automática dos recursos humanos para atender melhor à demanda dos pacientes. Esses dois módulos podem ser executados tanto na Edge, na Fog e na Cloud. Por fim, o módulo de *HealCity app* exibe as informações processadas, enviando notificações de elasticidade para recursos humanos, ou gerando dashboards para gestores.

3.2. Elasticidade Multinível de Recursos Humanos em Cidades Inteligentes

O CityHealth emprega o termo *elasticidade* como a capacidade do sistema de alocar/relocar/desalocar recursos humanos, a fim de se adaptar às diferentes demandas de pacientes em tempo real. Assim, a elasticidade refere-se a: (i) **Alocação**, que é a capacidade de requisitar profissionais de saúde que não estão no hospital para atender a demanda de pacientes; (ii) **Realocação**, que é a capacidade de migrar profissionais alocados em um ambiente hospitalar específico para outro ambiente; (iii) **Desalocação** que é a capacidade de liberar recursos humanos não mais necessários para atender a demanda.

O modelo usa uma abordagem multinível, onde (i) No *nível de sala*, ele deve identificar o uso futuro das salas e checar se há atendentes suficientes para a demanda de pacientes; (ii) no *nível de hospital*, ele deve checar se há atendentes suficientes para a demanda de pacientes em todas as salas do hospital, com atendentes se deslocando entre as salas; e (iii) no *nível regional*, ele deve verificar se há atendentes suficientes para atender à demanda em regiões da cidade inteligente, com atendentes se movimentando entre hospitais e propondo movimentação de pacientes para hospitais mais adequados. Um diagrama desses três níveis é apresentado na Figura 3. Ainda, é adaptada a estratégia de elasticidade proativa usando limites superiores e inferiores para o contexto de pessoas. A Figura 4 ilustra este uso, onde o modelo prevê que o limite superior será atingido (adicionando recursos humanos para atender a necessidade) e logo após o modelo prevê que o limite inferior será atingido (ou seja, liberando pessoas para outros setores).



Figura 3. Elasticidade proativa de recursos humanos.

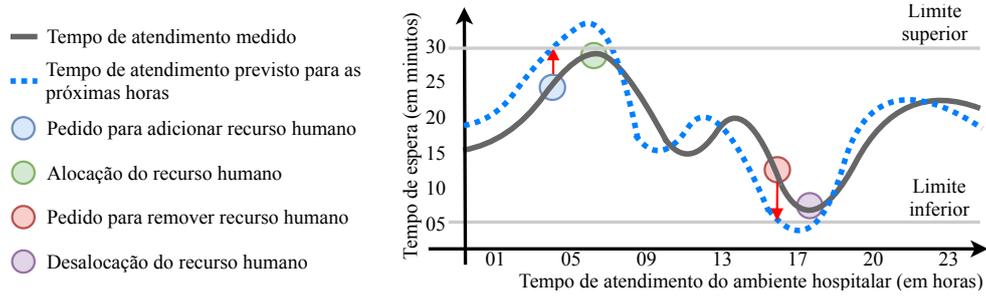


Figura 4. Elasticidade protiva baseada nos tempos de espera.

No nível de sala, o modelo precisa prever a taxa de chegada de pacientes com base em chegadas passadas e presentes. O modelo ARIMA é usado com o tempo médio de atendimento e tempo de espera na fila. Quando o tempo de espera excede os limites definidos pelo gerente do hospital, o CityHealth calcula o número de recursos necessários propondo alguns formalismos matemáticos. Esses formalismos usam uma abordagem proativa para determinar a demanda futura e ajustar o número de atendentes.

$CV(r, t_i, t_f)$ é o vetor de atendimentos na sala r entre t_i e t_f e $size(x)$ é o tamanho de qualquer vetor. O tempo médio de atendimento em uma sala r entre t_i e t_f pode ser calculado usando a Equação 1, onde $CDT(x[i])$ é o tempo de um atendimento $x[i]$ e $x[] = CV(r, t_i, t_f)$ é o vetor de atendimentos na sala r .

$$ACT(r, t_i, t_f) = \frac{1}{size(x)} \sum_{i=0}^{size(x)-1} CDT(x[i]) \quad (1)$$

A quantidade de atendentes em cada sala do hospital varia com o tempo, tornando a alocação elástica. A média de atendentes em uma sala r entre t_i e t_f é calculada usando a Equação 2, com $NA(r, t_n)$ sendo a quantidade de atendentes na sala r no instante n .

$$ANA(r, t_i, t_f) = \frac{1}{t_f - t_i} \sum_{t_n=t_i}^{t_f-1} NA(r, t_n) \quad (2)$$

Em diferentes momentos, há diferentes quantidades de pacientes aguardando atendimento em cada sala. A Equação 3 estima a quantidade de pacientes aguardando atendimento em uma sala r entre t_i e t_f , onde $NWP(r, t_i)$ é a quantidade de pacientes aguardando atendimento na sala r no instante t_i e $NIP(r, t_n)$ é a quantidade de pacientes entrando na sala r a cada instante t_n .

$$ENP(r, t_i, t_f) = NWP(r, t_i) + \sum_{t_n=t_i+1}^{t_f-1} NIP(r, t_n) \quad (3)$$

Com base nas equações anteriores, o CityHealth calcula o tempo estimado de atendimento para pacientes em espera e estima o tempo de espera para um novo paciente que chega ao hospital. A Equação 4 define a função $ECT(r, t_i, t_f)$, onde $ACT(r, t_i, t_f)$ é o tempo médio de atendimento para a sala r entre t_i e t_f , e $ENP(r, t_i, t_f)$ é o número estimado de pacientes aguardando atendimento na sala r entre t_i e t_f .

$$ECT(r, t_i, t_f) = ACT(r, t_i, t_f) \cdot ENP(r, t_i, t_f) \quad (4)$$

Conhecendo o $ECT(r, t_i, t_f)$, é possível analisar o tempo de espera de pacientes aguardando em uma sala r entre os tempos t_i e t_f . Porém, essa análise considera apenas uma sala com um atendente, enquanto na realidade existem salas com mais de um atendente, tornando necessário identificar o tempo médio de atendimento com diferentes quantidades de atendentes. Nesse sentido, o CityHealth usa uma alocação *paralela* de recursos humanos, em contrapartida a alocação paralela de máquinas virtuais usada em sistemas de elasticidade. Para tanto, a Equação 5 é introduzida para representar o *Speedup Elástico de Recursos Humanos*.

$$HRES(r, t_i, t_f) = \frac{ECT(r, t_i, t_f)}{ANA(r, t_i, t_f)} \quad (5)$$

$HRES(r, t_i, t_f)$ é a função que estima o tempo de atendimento em uma sala r entre t_i e t_f , considerando a alocação paralela de atendentes, conforme indicado pela função $ANA(r, t_i, t_f)$. Quanto maior for a quantidade média de atendentes alocados, menor será o tempo estimado de atendimento, em proporção inversa. Com o objetivo de antecipar a ocorrência de sobrecargas no fluxo de pacientes, propomos a Equação 6, que permite realizar uma alocação proativa e elástica de recursos humanos, ajustando a quantidade de atendentes em cada sala com base nas estimativas de demanda futura.

$$PHRES(r, a, f_i, f_f) = \frac{ECT(r, f_i, f_f)'}{a}, \quad (6)$$

onde a é a quantidade de atendentes alocados entre os tempos futuros f_i e f_f , e $ECT(r, f_i, f_f)'$ é a predição do tempo futuro de atendimento dessa sala usando ARIMA. ECT' pode ser definida como:

$$ECT(r, f_i, f_f)' = ACT(r, f_i, f_f)' \cdot ENP(r, f_i, f_f)', \quad (7)$$

onde $ACT(r, f_i, f_f)'$ e $ENP(r, f_i, f_f)'$ são as predições do tempo médio de atendimento e da quantidade de pacientes futuros na sala r , respectivamente. Uma série temporal para $ACT(r, t_i, t_f)$ e $ENP(r, t_i, t_f)$ é gerada para cada sala r e usada para prever $ACT(r, f_i, f_f)'$ e $ENP(r, f_i, f_f)'$. Com a variação do atributo a na equação $PHRES$,

o modelo pode identificar quantos atendentes seriam necessários para ajustar o tempo de espera de qualquer sala aos limites propostos.

No nível de hospital, o modelo precisa testar diferentes alocações de atendentes para garantir que todas as salas identificadas na etapa anterior tenham atendentes suficientes. O CityHealth considera a possibilidade de mover profissionais de saúde entre diferentes ambientes do hospital para otimizar o tempo de atendimento médico. O modelo utiliza estratégias conhecidas de outros contextos da computação para redistribuir esses atendentes entre diferentes salas. O Algoritmo 1 apresenta a elasticidade proativa no nível de hospital. Cada sala possui uma especialidade específica, e o processo de realocação ou alocação de recursos humanos é realizado apenas entre profissionais que possuem a especialidade da sala de destino. As salas que necessitem de uma especialidade que nenhum outro profissional do hospital possui exigem a alocação de novos recursos humanos.

Algoritmo 1: Elasticidade proativa no nível de hospital

Entrada: Lista de salas h , vetor v com os atendentes, tempo inicial f_i , tempo final f_f

Saída: Vetor se 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 List Scheduling para Realocação de RH usando  $r$  e  $l_r$  como entrada;
14  fim
15   $h \leftarrow$  salas do vetor  $l$ ;
16  retorna  $l$ ;
17 fim

```

Foi desenvolvido um algoritmo baseado em *List Scheduling* [Pillareddy and Karri 2023] para obter uma realocação balanceada de recursos humanos. O algoritmo ordena todas as salas em uma lista de acordo com o número de atendentes disponíveis para realocação. Quando uma sala precisa de mais atendentes, o modelo busca por atendentes disponíveis na primeira sala da lista. Se os atendentes estiverem disponíveis, eles são realocados, e a lista é ordenada novamente. O algoritmo verifica a primeira sala da lista novamente se forem necessários mais atendentes, até que a sala obtenha todos os atendentes necessários. A Figura 5 ilustra o algoritmo proposto.

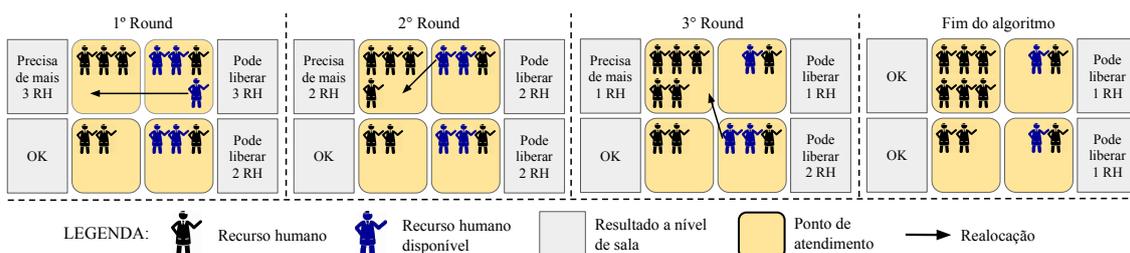


Figura 5. Realocação através do algoritmo de *List Scheduling* adaptado.

No contexto da elasticidade de recursos humanos, a *histerese* pode ser um problema, pois o sistema pode retornar ao estado anterior na ausência do estímulo que causou a mudança. Isso pode levar a uma realocação contínua entre salas, impedindo que os recursos sejam alocados de forma eficaz. Para evitar esse problema, foi empregada uma estratégia baseada em *cooldown period*, em que o recurso realocado não pode retornar para a sala anterior imediatamente. Dessa forma, a necessidade de uma sala só será atendida se houver recursos livres em outros lugares.

No nível regional, o CityHealth precisa testar diferentes alocações para os atendentes para garantir que todas as salas de todos os hospitais tenham atendentes suficientes. Para isso, o algoritmo considera a possibilidade de movimentação de profissionais de saúde entre diferentes hospitais, utilizando uma nova definição para o custo de alocação ou realocação de pessoas. Esse custo é o tempo estimado para a movimentação fornecida em tempo real pela *API Distance Matrix* do *Google Cloud*, adicionando o tempo médio do processo de alocação interna. A Figura 6 apresenta o fluxograma executado em cada node regional. Como no nível anterior, apenas profissionais com a especialidade da sala de destino são realocados ou alocados.

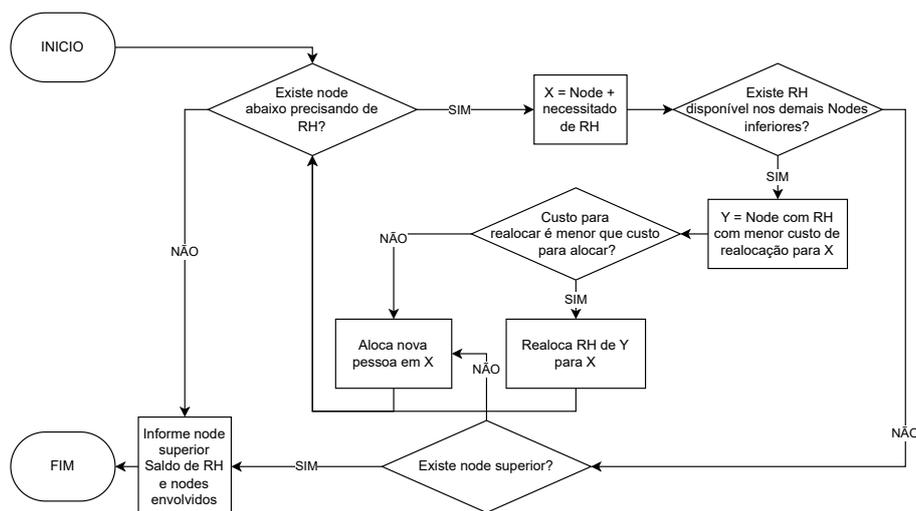


Figura 6. Fluxograma da Elasticidade Proativa no nível regional.

A cidade inteligente precisa ter uma estratégia para definir quais recursos humanos estão disponíveis para alocação. Se a demanda futura de atendimento dos hospitais for baixa e a desalocação de atendentes não prejudicar o todo, o modelo propõe a desalocação de atendentes fora do seu horário normal de trabalho. As operações de alocação e desalocação também são protegidas pelo *cooldown period*.

4. Metodologia de Avaliação

Para avaliar o desempenho do modelo, foi realizada uma emulação de uma cidade com dois hospitais, considerando a falta de dados disponíveis. Ambos os ambientes hospitalares foram definidos com base em cargas de trabalho sintéticas, que de acordo com [Rostirolla et al. 2018], podem ser consideradas uma forma representativa para avaliar a elasticidade em nuvens computacionais. O modelo foi implementado principalmente em Java, com exceção do método ARIMA, que foi implementado em Python. Foi utilizado um relógio com incrementos discretos de dez segundos para emulação das filas

hospitalares. A cada avanço no relógio de emulação, o emulador verifica os pacientes em atendimento e os que devem deixar o atendimento. Além disso, a chegada de novos pacientes é verificada a cada ciclo de monitoramento.

Para o procedimento de emulação da cidade, foram considerados dois cenários diferentes: **C1: Cidade sem o modelo (não-elástico)**; e **C2: Cidade com o uso do modelo CityHealth**. Foram utilizados os dados do estudo de [Capocci et al. 2017] realizado em uma policlínica de Guarulhos, em São Paulo, para a emulação de cada ambiente hospitalar. Isso permitiu que todos os parâmetros utilizados, como as distribuições de tempos de atendimento, movimentação de pacientes entre as salas e alocação de profissionais, fossem baseados em dados reais disponíveis em [Capocci et al. 2017].

No Brasil, o modelo adotado para ambientes hospitalares é o 12x36. Sob esse regime, um funcionário trabalha por doze horas consecutivas e descansa por trinta e seis horas antes de um novo turno [Brasil 1943]. Quatro profissionais em turnos alternados são suficientes para garantir o atendimento de um mesmo posto de trabalho de forma ininterrupta. Enquanto um recurso humano trabalha, outros três estão no período de descanso. Dessa forma, no modelo, para um funcionário em repouso estar disponível para alocação deve seguir as seguintes regras: **Regra 1:** O período mínimo de descanso para alocação é de onze horas e um funcionário alocado deve ser desalocado no máximo 11 horas antes do seu próximo turno de trabalho normal em função da determinação que exige esse tempo entre jornadas na lei [Brasil 1943]; **Regra 2:** Um funcionário alocado não pode trabalhar mais de doze horas consecutivas, conforme regulamentado por lei [Brasil 1943]; e **Regra 3:** Funcionários devem ter pelo menos um período de descanso remunerado de pelo menos 24 horas por semana, como exigido na lei [Brasil 1943].

Como forma utilizados dados coletados em um hospital brasileiro, forma estabelecidos limites realistas para o projeto. Adotou-se como referência o Projeto de Lei de 14 de junho de 2018 [Goiânia 2018], que propõe um tempo máximo de espera de 30 minutos para atendimento em hospitais, clínicas e laboratórios. A partir disso, foi definido que a carga máxima do CityHealth seria de 30 minutos e o limite inferior seria de 9 minutos (equivalente a 30% do tempo máximo de espera). Para considerar a possibilidade de ajustes, foram definidos 10 minutos para o processo de realocação (movimentação de recursos humanos entre salas) e 60 minutos para o processo de alocação (simulando a movimentação de um novo recurso humano até o hospital) e realocação entre hospitais.

Em relação à carga dos pacientes, foi modelada uma carga em onda que seria a mais próxima da realidade hospitalar. Para cada hospital emulado utilizou-se uma onda inversamente proporcional. Esse comportamento de carga de trabalho é baseado no proposto por [Rostirolla et al. 2018]. Para avaliar o desempenho do 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 modelo proporcione uma redução no tempo médio de espera. Em relação à elasticidade da alocação de recursos humanos, o objetivo é que o CityHealth faça uso otimizado dos profissionais disponíveis no hospital. Portanto, será comparada a alocação estática com a alocação elástica.

5. Avaliação e Análise dos Resultados

Com base na metodologia de avaliação, foram realizadas duas emulações da cidade proposta, a fim de coletar resultados para análise. Para cada cenário proposto, entre C1 e C2,

foi realizada uma emulação de dois hospitais, gerando quatro resultados para comparação. Para a primeira métrica, esperava-se uma diminuição no tempo de espera por atendimento. A Figura 7 mostra o tempo máximo de espera identificado nos cenários propostos durante o período de uma semana emulado. Percebeu-se uma redução significativa no tempo máximo de espera entre C1 e C2, em ambos os ambientes hospitalares. Graças aos procedimentos de realocação e alocação, o CityHealth demonstrou diminuir o tempo de espera em 90,97% e 95,60% em cada hospital, em comparação com os hospitais não elásticos.

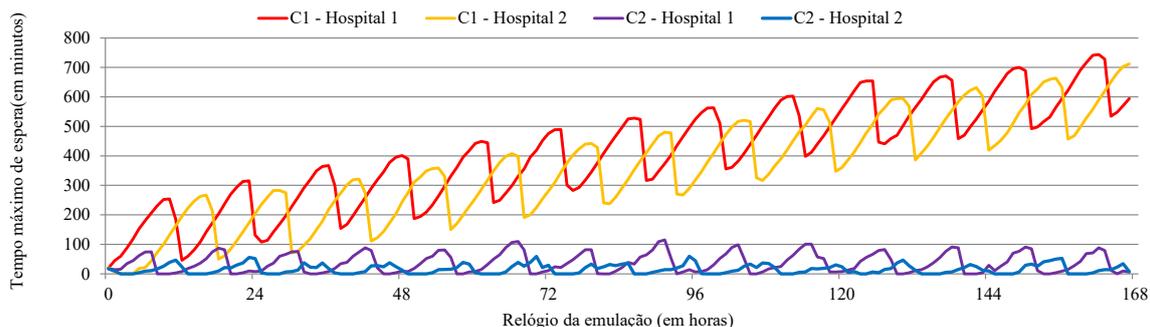


Figura 7. Tempo máximo de espera aferido na emulação.

Esperava-se um aumento na quantidade de profissionais no hospital, bem como uma variação desse número ao longo do período de atendimento, para a quantidade elástica de recursos humanos utilizados. A Figura 8 apresenta a quantidade elástica de recursos humanos utilizados no C2, o único cenário em que o número de funcionários pode variar. Observa-se que a quantidade de recursos humanos variou de 22 a 26 por hora, considerando ambos os hospitais. Além disso, a Figura 8 mostra que sempre que o modelo realoca ou aloca profissionais para o atendimento, o tempo de espera diminui. Com base nas métricas estabelecidas, pode-se concluir que o CityHealth melhorou o desempenho dos hospitais da cidade emulada. O tempo máximo de espera apresentou uma diminuição entre os cenários C1 e C2, cumprindo o objetivo dessa métrica, como proposto na metodologia de avaliação. Já para a quantidade elástica de recursos humanos utilizados, o aumento esperado entre os cenários foi alcançado pelo CityHealth. Dessa forma, os resultados esperados foram atingidos.

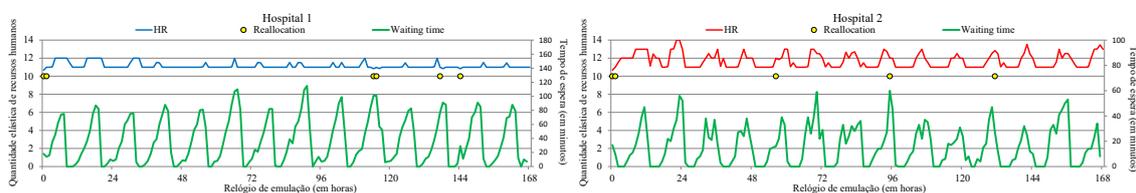


Figura 8. Quantidade elástica de recursos humanos utilizados em comparação com o tempo máximo de espera nos hospitais no Cenário C2.

Ao contrário do estado da arte, o CityHealth apresenta um modelo capaz de gerenciar recursos humanos e pacientes de forma a reduzir a sobrecarga nos ambientes de saúde, analisando o estado de saúde de pessoas fora dos hospitais, propondo ajustes proativos na capacidade de atendimento, e automatizando a tomada de decisão. Embora tenham sido alcançado resultados animadores, é importante destacar que existem limitações que devem ser abordadas na implementação do modelo em uma cidade real. É preciso garantir

que os funcionários e pacientes carreguem seus dispositivos vestíveis, para que o modelo possa funcionar adequadamente. Além disso, o modelo apenas gera notificações 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 dos hospitais, bem como pela cidade inteligente. Portanto, essas limitações devem ser abordadas para garantir a eficácia do modelo em uma cidade real.

6. Conclusão

Este artigo apresentou o modelo CityHealth, que visa solucionar o problema da alocação estática de recursos humanos em ambientes de saúde de uma cidade inteligente. Ao contrário de trabalhos relacionados, o modelo não apenas utiliza técnicas de predição para antecipar problemas, mas também propõe um modelo para alocar, realocar e desalocar profissionais em hospitais de uma cidade inteligente. Assim, o conceito de elasticidade da computação em nuvem foi estendido para o contexto de gerenciamento de recursos humanos, apresentando novos formalismos matemáticos, algoritmos e definições para fornecer uma alocação dinâmica e elástica de profissionais. Espera-se que o modelo possa ajudar a diminuir o tempo de espera dos pacientes em atendimento à saúde, como comprovado no estudo de caso, em que o tempo de espera diminuiu em mais de 95%.

A título de trabalhos futuros, espera-se implementar um protótipo que compreenda todos o modelo proposto, permitindo a sua instalação em ambientes hospitalares reais, para uma melhor avaliação dos resultados. Outra possibilidade de melhoria seria a adaptação do modelo para utilizar outros algoritmos de predição tais como redes neurais ou *random forests*. Espera-se também identificar que impacto a alocação dinâmica de profissionais possui sobre os próprios profissionais e como a qualidade do serviço seria impactada ao usar tal metodologia.

Agradecimentos

Os autores agradecem à CAPES (Código Financeiro 001), FAPERGS (projeto 21/2551-0000118-6) e ao CNPq (Projeto No 309537/2020-7 e 404572/2021-9).

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).
- Ali, Z., Mahmood, A., Khatoon, S., Alhakami, W., Ullah, S. S., Iqbal, J., and Hussain, S. (2023). A generic internet of things (iot) middleware for smart city applications. *Sustainability*, 15(1).
- Alshamaila, Y., Papagiannidis, S., Alsawalqah, H., and Aljarah, I. (2023). Effective use of smart cities in crisis cases: A systematic review of the literature. *International Journal of Disaster Risk Reduction*, 85:103521.
- Brasil (1943). Decreto-Lei No 5.452, de 1 de maio de 1943. Aprova a Consolidação das Leis do Trabalho.
- Capocci, N. R., Nascimento, B. S., Lopes, F. B., Rodrigues, E. F., and Maiellaro, J. R. (2017). Simulation as a hospital management support tool. *Independent Journal of Management & Production*, 8(5):798–811.

- Fischer, G. S., Rodrigues, V. F., da Rosa Righi, R., da Costa, C. A., Policarpo, L. M., and Silva, R. G. G. (2022). Looking at smart cities through the lens of a pandemic era: A systematic literature review. *International Journal of Technology Management*.
- Franke, H., Hasseler, M., Dick, D., and Krebs, S. (2018). A sustainable approach for a smart human resource management in healthcare. *Eur. J. Sustainable Dev.*, 7(3):403.
- Goiânia (2018). Projeto de Lei no 2018/000159, de 11 de novembro de 2018. dispõe sobre o tempo máximo de espera para atendimento nos estabelecimentos que especifica.
- Google News (2023). Coronavírus (covid-19). <https://news.google.com/covid19/map>, 2023 (accessed 22 February 2023).
- Graham, B., Bond, R., Quinn, M., and Mulvenna, M. (2018). Using data mining to predict hospital admissions from the emergency department. *IEEE Access*, 6:10458–10469.
- 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.
- 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).
- Lucic, M. C., Bouhamed, O., Ghazzai, H., Khanfor, A., and Massoud, Y. (2023). Leveraging uavs to enable dynamic and smart aerial infrastructure for its and smart cities: An overview. *Drones*, 7(2).
- Pandya et al. (2023). Federated learning for smart cities: A comprehensive survey. *Sustainable Energy Technologies and Assessments*, 55:102987.
- Pillareddy, V. R. and Karri, G. R. (2023). Monws: Multi-objective normalization workflow scheduling for cloud computing. *Applied Sciences*, 13(2).
- Rodrigues, V. and Righi, R. (2022). MinhaHistoriaDigital: An Scalable Fog-Based Architecture for Efficient Vital Signs Monitoring over Smart Cities. In *Anais da XXII Escola Regional de Alto Desempenho da Região Sul*, pages 117–118.
- Rostirolla, G., Righi, R., Barbosa, J., and Costa, C. (2018). Elcity: An elastic multilevel energy saving model for smart cities. *IEEE Trans. Sustain. Comput.*, 3(1):30–43.
- Sidorov, D. (2023). Preface to model predictive control and optimization for cyber-physical systems. *Mathematics*, 11(4).
- Thakkar, R. and Bhavsar, M. (2023). Naarprec: A novel approach for adaptive resource prediction in cloud. In *Soft Computing and Its Engineering Applications*, pages 3–16.
- Vieira, D. and Hollmén, J. (2016). Resource frequency prediction in healthcare: Machine learning approach. In *2016 IEEE 29th Int. Symp. on Comp. Med. Sy.*, pages 88–93.
- Wang, M. and Zhou, T. (2023). Does smart city implementation improve the subjective quality of life? Evidence from china. *Technology in Society*, 72:102161.
- Xiang, W., Chen, L., Yan, X., Wang, B., and Liu, X. (2023). The impact of traffic control measures on the spread of covid-19 within urban agglomerations based on a modified epidemic model. *Cities*, 135:104238.