

HealCity: Usando Dados de Sinais Vitais dos Cidadãos e a Técnica de Elasticidade para gerência de Ambientes de Saúde no Contexto de Cidades Inteligentes

Gabriel Souto Fischer¹, Rodrigo da Rosa Righi¹

¹PPG em Computação Aplicada - Unisinos - RS, Brasil
Programa de Pós-Graduação em Computação Aplicada - Unisinos
gabriel.souto.fischer@gmail.com, rrrighi@unisinos.br

Resumo. *Cidades inteligentes podem melhorar a qualidade de vida dos cidadãos otimizando a utilização de recursos. Em um ambiente conectado à IoT, a saúde das pessoas pode ser monitorada constantemente, o que pode ajudar a identificar problemas médicos antes que se tornem sérios. No entanto, hospitais superlotados podem levar a longos tempos de espera para que os pacientes recebam tratamento. Este trabalho apresenta o HealCity, um modelo focado em cidades inteligentes que pode monitorar o uso de ambientes de saúde pelos pacientes e adaptar a alocação de profissionais de saúde para atender às suas necessidades. O HealCity usa dados de sinais vitais (IoT) em técnicas de previsão para antecipar quando a demanda por um determinado ambiente excederá sua capacidade e sugere ações para alocar profissionais de saúde de acordo. Além disso, introduzimos o conceito de Elasticidade Multinível de Recursos Humanos em Cidades Inteligentes, gerenciando assim os recursos humanos em diferentes níveis de uma cidade inteligente. Um algoritmo também é desenvolvido para gerenciar e identificar automaticamente o hospital apropriado para um possível paciente futuro. O HealCity foi avaliado com quatro ambientes hospitalares e obteve resultados promissores: comparado a hospitais com alocações estática de profissionais, ele reduziu o tempo de espera para atendimento em até 87,62%*

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].

1.1. Motivação

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, pois alguns profissionais podem ser mal alocados em setores de baixa demanda, levando à falta de profissionais em setores de alta demanda, 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. Além disso, em cidades inteligentes, sinais vitais capturados das pessoas ininterruptamente podem ser utilizados para identificar a demanda futura de atendimento. Neste contexto, surge a necessidade dos sistemas dos ambientes de saúde interagirem entre si, para identificar a disponibilidade e uso dos profissionais de saúde alocados na rede de atendimento, de forma a propor ajustes baseados tanto na demanda já existente nos hospitais, como na demanda futura baseada nos sinais vitais em declínio sendo capturados da população.

Dessa forma, a motivação científica para o presente trabalho está na necessidade de se propor alternativas e soluções a esse problema, uma vez que o mesmo não é tratado de forma eficiente em trabalhos científicos considerados estado da arte, tais como os propostos por [Graham et al. 2018], [Apornak et al. 2021] e [Hafezalkotob et al. 2022]. Dada a situação, isso justifica a criação de um novo modelo para gerenciamento dinâmico da capacidade de atendimento de múltiplos ambientes de saúde.

1.2. Objetivos e Contribuições

Este trabalho tem como principal objetivo desenvolver um modelo que compreenda arquitetura, definição de *players* e funções, bem como novos algoritmos e conceitos, para **controle de recursos humanos** em ambientes de saúde localizados em cidades inteligentes, utilizando-se de sensores para **medir sinais vitais** considerados estado da arte, e para **registrar a relação entre a capacidade de atendimento** de pacientes dos hospitais com a **quantidade de funcionários** que estão prestando atendimento.

Baseado nos conceitos de elasticidade e cidades inteligentes, foi proposto o modelo HealCity que 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. As principais contribuições científicas desta tese são:

- (i) A introdução da *Elasticidade Multinível de Recursos Humanos em Cidades Inteligentes*, que inclui um algoritmo para gerenciamento dinâmico de distribuição de recursos humanos em ambientes de saúde, fazendo uso de sensores de IoT para monitorar a demanda de distúrbios de saúde dos pacientes;
- (ii) A definição de *arquitetura hierárquica escalável para sistemas de gerenciamento de recursos humanos de hospitais em cidades inteligentes*; e
- (iii) Nós introduzimos um novo algoritmo para gerenciamento automático e identificação do hospital apropriado para um possível paciente, propondo alguns novos formalismos matemáticos.

2. Modelo HealCity

HealCity 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. Através deste modelo, HealCity 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.

Este modelo fornece uma infraestrutura de monitoramento abrangente para cidades inteligentes que pode ser usada para melhorar vários aspectos da saúde pública. HealCity 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.

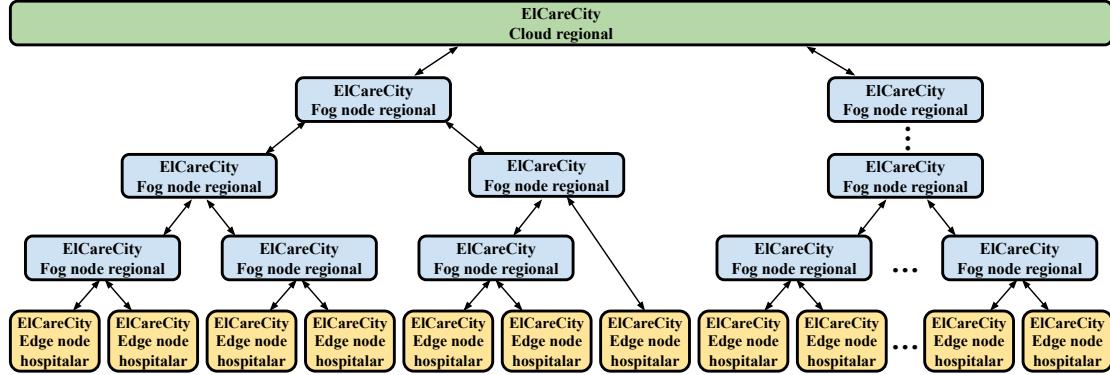


Figura 1. Solução hierárquica escalável do HealCity.

HealCity 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.

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 HealCity app, responsável pela camada de *visualização* para uso dos gestores hospitalares, recursos humanos, pacientes e pessoas em geral. Além disso, o HealCity é subdividido em cinco módulos principais (Figura 2).

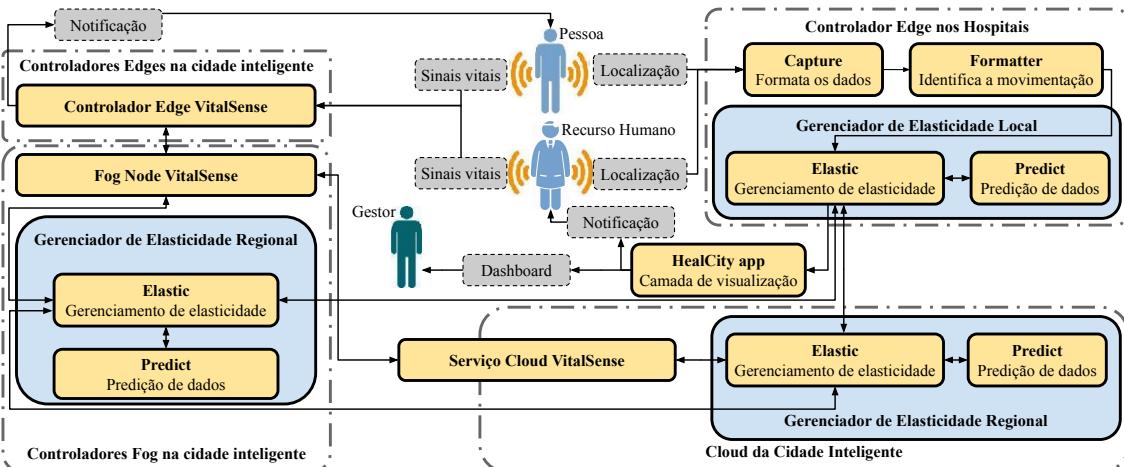


Figura 2. Detalhamento da arquitetura do modelo.

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 *HealCity app* exibe informações processadas, enviando notificações de elasticidade para recursos humanos ou gerando dashboards para gestores.

HealCity 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, (ii) No *nível de hospital*, onde deve verificar se há atendentes suficientes para atender a demanda em todas 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 nas diferentes regiões da cidades inteligentes, com os atendentes se movimentando entre hospitais, e também propondo movimentação de pacientes para hospitais mais adequados.

No nível de sala, quando o modelo prevê tempos de espera que não estão de acordo com os limites estabelecidos, o HealCity deve calcular a quantidade de recursos humanos necessários para atender a demanda de pacientes, identificando a necessidade de ajustes em determinada sala.

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. 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.

A nível regional, o modelo HealCity precisa testar diferentes alocações para os atendentes para garantir que todos as salas de todos os ambientes de saúde identificados na etapa anterior (nível de ambiente de saúde) tenham atendentes suficientes, para minimizar a superlotação. Aqui, o modelo segue a mesma ideia do nível anterior, mas considerando a possibilidade de movimentar profissionais de saúde entre ambientes de saúde diferentes e também alocar novos profissionais se necessário. Maiores detalhes na tese completa.

3. Resultados e Discussão

Para avaliar o modelo HealCity, foi simulado um conjunto de hospitais localizados em uma cidade inteligente hipotética. Levando em consideração a inacessibilidade de dados reais para um conjunto de hospitais, para cada hospital, definimos o uso dos mesmos parâmetros usados por um ambiente de saúde real localizado em Guarulhos, Brasil [Capocci et al. 2017]. Em relação à carga de trabalho do paciente, definimos cargas de trabalho sintéticas com base na carga real deste mesmo ambiente. Para avaliar o modelo proposto, forma considerados três cenários distintos: **C1:** Cidade inteligente sem

nenhuma abordagem de gestão de recursos humanos, **C2**: Cidade inteligente com abordagem de Capocci et al. [Capocci et al. 2017] e **C3**: Cidade inteligente com modelo de elasticidade da HealCity.

Para avaliar o modelo HealCity, foram consideradas as seguintes métricas: **M1**: Tempo máximo de espera para atendimento; **M2**: Custo de recursos humanos; e **M3**: Número elástico de recursos humanos utilizados. Para M1 foi observado a diferença entre o tempo máximo de espera nos diferentes cenários. Para M2 o custo de recursos humanos foi definido com base no que a legislação brasileira determina como custo de um profissional trabalhando fora do seu período normal de trabalho. Por fim, para M3 foi proposta uma métrica para comparar a alocação elástica e não elástica de profissionais de saúde em termos do número de recursos humanos.

Com base nas métricas estabelecidas, pôde-se notar que o modelo foi capaz de melhorar o desempenho dos ambientes de saúdes simulados na cidade inteligente proposta. A Tabela 1 apresenta todos os resultados encontrados. Conforme proposto para M1, esperava-se que o tempo máximo de espera apresentasse uma diminuição entre os cenários C1, C2 e C3, e isso de fato ocorreu, cumprindo os objetivos para essa métrica. Além disso, o custo de recursos humanos e o número elástico de recursos humanos usados aumentaram entre os cenários C1/C2 e C3, conforme esperado. Dessa forma, pode-se afirmar que os resultados esperados foram alcançados através do uso do modelo HealCity na cidade inteligente proposta.

Tabela 1. Métricas de avaliação e resultados encontrados.

Cenário	Tempo máximo de espera			Quantidade elástica de RH
		Média	Maior	
C1	Ambiente de Saúde 1	197.56 (± 92.7)	361	-
	Ambiente de Saúde 2	186.56 (± 112.9)	377	-
	Ambiente de Saúde 3	212.31 (± 97.2)	390	-
	Ambiente de Saúde 4	180.43 (± 107.4)	360	-
	Média da cidade inteligente	194.21 (± 73.9)	305.7	44
C2	Ambiente de Saúde 1	49.77 (± 34.4)	104	-
	Ambiente de Saúde 2	38.48 (± 28.2)	99	-
	Ambiente de Saúde 3	40.25 (± 26.4)	92	-
	Ambiente de Saúde 4	36.70 (± 30.9)	108	-
	Média da cidade inteligente	41.30 (± 14.3)	48	44
C3	Ambiente de Saúde 1	38.85 (± 35.1)	111	-
	Ambiente de Saúde 2	23.04 (± 26.2)	117	-
	Ambiente de Saúde 3	18.00 (± 17.8)	79	-
	Ambiente de Saúde 4	16.27 (± 15.2)	54	-
	Média da cidade inteligente	24.04 (± 10.3)	46.7	48.26
				46,15

Para a métrica de tempo máximo de espera, haviam dois objetivos: a diminuição do tempo de espera nos ambientes de saúde e o enquadramento do mesmo dentro do limite superior de 30 minutos estabelecido na metodologia de avaliação. Conforme já mostrado, o modelo HealCity foi capaz de diminuir significativamente o tempo de espera para a cidade inteligente proposta, com um tempo médio máximo de espera de 24,04 minutos para C3 (com desvio-padrão de 10,3 minutos). No entanto, quando observamos

os tempos de espera mais longos encontrados durante o período de simulação, o limite superior foi excedido (111, 117, 79, 54 e 46,75 minutos nos Ambientes de Saúde 1, 2, 3 e 4, respectivamente). Isso provavelmente ocorreu devido ao número limitado de estações de atendimento disponíveis para a alocação de novos recursos humanos. Entretanto, pode-se dizer que os objetivos para a métrica foram alcançados, visto que o modelo HealCity foi capaz de diminuir consideravelmente o tempo de espera (87,62% na média da cidade inteligente) e na média da cidade inteligente o tempo máximo de espera ficou abaixo dos 30 minutos estabelecidos como objetivo.

Para a métrica de custo de recursos humanos, esperava-se que entre os cenários propostos houvesse um aumento deste custo, e foi exatamente isso que ocorreu. O objetivo da métrica é justamente mostrar qual o aumento de custo necessário para atingir determinada redução no tempo de espera por atendimento de saúde em uma cidade inteligente. Dessa forma, os resultados mostram que o custo de recursos humanos aumentou de forma *inversamente proporcional* à diminuição do tempo de espera, conforme esperado. Além disso, era esperado que a proporção de redução do tempo de espera fosse superior a proporção do aumento de custo, e isso de fato ocorreu. Assim, ficou evidente que um mero aumento de 9,68% no custo resultou em uma diminuição de até 87,62% na média do tempo máximo de espera. Por fim, para a métrica de quantidade elástica de recursos humanos era previsto que número médio de profissionais de saúde utilizados na cidade inteligente aumentaria entre os cenários C1/C2 e C3, e esse foi de fato o caso. Assim, o modelo teve resultados animadores, adicionando uma nova visão para a gestão de recursos humanos no contexto da saúde em cidades inteligentes. A título de trabalhos futuros vislumbra-se uma validação mais robusta em uma ambiente real.

Referências

- Apornak, A., Raissi, S., Keramati, A., and Khalili-Damghani, K. (2021). Optimizing human resource cost of an emergency hospital using multi-objective bat algorithm. *International Journal of Healthcare Management*, 14(3):873–879.
- 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.
- Fadhel et al. (2024). Comprehensive systematic review of information fusion methods in smart cities and urban environments. *Information Fusion*, 107:102317.
- 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).
- 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.
- 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.
- Wang, M. and Zhou, T. (2023). Does smart city implementation improve the subjective quality of life? evidence from china. *Technology in Society*, 72:102161.