

# HEALFUL - Internet of Health Things Platform to Monitor Quality of Life

Pedro Almir Martins de Oliveira<sup>1,3</sup>, Rossana Maria de Castro Andrade<sup>1</sup>,  
Pedro de Alcântara dos Santos Neto<sup>2</sup>

<sup>1</sup> Grupo de Redes de Computadores, Engenharia de Software e Sistemas (GREat)  
Universidade Federal do Ceará (UFC)  
Fortaleza – CE – Brasil

<sup>2</sup>Laboratório de Otimização e Teste de Software (LOST)  
Universidade Federal do Piauí (UFPI)  
Teresina – PI – Brasil

<sup>3</sup>Instituto Federal de Educação, Ciência e Tecnologia do Maranhão (IFMA)  
Pedreiras – MA – Brasil

pedro.oliveira@ifma.edu.br, rossana@ufc.br, pasn@ufpi.edu.br

**Abstract.** *Monitoring people's Quality of Life (QoL) has attracted interest due to the health benefits of an accurate QoL analysis, such as early healthcare interventions. However, most instruments to assess QoL are questionnaires, and their application is time-consuming, intrusive, and error-prone. This work proposes an Internet of Health Things (IoHT) platform called Healful that applies Machine Learning to infer users' QoL. A case study with 44 participants was conducted for six months, and during this evaluation, health data were collected daily through smartphones and wearables. These data were processed and compiled into two datasets with 1,373 instances each. Next, five Machine Learning models were built using 10-fold cross-validation to estimate participants' QoL. Random Forest (RF) had the best results considering the Root Mean Squared Error (RMSE). RF got an RMSE of 7.8618 for the physical domain and 7.4591 for the psychological domain.*

**Resumo.** *Monitorar a Qualidade de Vida (QV) das pessoas tem atraído interesse devido aos benefícios associados, por exemplo, intervenções preventivas de promoção à saúde. No entanto, a maioria dos instrumentos para avaliar QoL são questionários, os quais tendem a ser custosos, invasivos e propensos a erros. Então, este trabalho apresenta a plataforma Healful cujo foco é a inferência da Qualidade de Vida dos usuários usando aprendizagem de máquina. Um estudo de caso com 44 participantes foi conduzido ao longo de seis meses nos quais dados de saúde foram coletados diariamente por meio de smartphones e dispositivos vestíveis. Os dados foram processados e compilados em dois datasets com 1.373 instâncias cada. Então, cinco modelos de Aprendizagem de Máquina foram construídos usando a técnica 10-fold cross-validation para estimar a Qualidade de Vida dos participantes. O Random Forest (RF) obteve os melhores resultados considerando a raiz do erro médio quadrático (RMSE). RF obteve um RMSE de 7,8616 para o domínio físico e 7,4591 para o domínio psicológico, após um longo processo de refinamento.*

## 1. Introdução

A sociedade global tem experienciado ao menos dois fenômenos que requerem adaptações nos sistemas de saúde: o envelhecimento populacional e o aumento de cidadãos residindo em grandes cidades [Nations 2018, Nations 2019]. Tais processos, em especial o envelhecimento populacional, são positivos uma vez que indicam avanços na promoção da longevidade. No entanto, é inegável que esse novo cenário impõe desafios aos sistemas de saúde a fim de melhorar sua relação custo-benefício [Segun and Telukdarie 2023]. Dessa forma, cada vez mais serão necessárias soluções focadas em cuidados preventivos e não apenas em cuidados quando o paciente adoece [Kumar et al. 2023].

Em 2017, A Organização para a Cooperação e Desenvolvimento Econômico (OCDE) apontou que apenas 2,8% do montante de gastos com saúde é investido em ações preventivas e que apenas 7% desse percentual é focado na detecção antecipada de doenças [Gmeinder et al. 2017]. Os relatórios recentes da Organização Mundial da Saúde (OMS), publicados em 2023 com dados consolidados até 2021, mostraram que o percentual de 2,8% cresceu para 5% apenas [WHO 2023]. Dessa forma, para ampliar a efetividade dos sistemas de saúde é crucial o monitoramento contínuo da Qualidade de Vida (QV) das pessoas objetivando antecipar o surgimento de problemas de saúde [Oliveira et al. 2021]. As medições obtidas nesse tipo de acompanhamento possuem uma relação direta com o estado de saúde dos pacientes, além de fornecerem dados valiosos para a prática médica [Estrada-Galinanes and Wac 2018].

A Qualidade de Vida pode ser definida, então, como a percepção individual de cada ser humano sobre sua vida considerando seu contexto sociocultural, objetivos, expectativas e padrões pessoais [WHOQoL Group 1994]. Com base nessa definição, diversos mecanismos de avaliação formal têm sido propostos ao longo dos anos. Esses mecanismos buscam substituir a percepção subjetiva do médico ou profissional de saúde coletando *feedbacks* por meio de perguntas objetivas aos pacientes. Na literatura, um dos mecanismos mais citados é o questionário WHOQOL-BREF devido a sua confiabilidade e validade *cross-cultural* [Skevington et al. 2004]. O WHOQOL-BREF foi avaliado em 23 países (incluindo o Brasil) e está disponível em 19 idiomas. Sua composição engloba 26 questões relativas a quatro diferentes domínios (físico, psicológico, social e ambiental), e o resultado final é um escore objetivo que varia de 0 a 100.

No entanto, apesar dos benefícios alcançados com a utilização dessas estratégias, a aplicação contínua desse tipo de questionário é complexa, custosa, não transparente e propensa a erros [Oliveira et al. 2022].

### 1.1. Justificativa

O contexto previamente descrito destaca a necessidade de soluções voltadas à melhoria da efetividade dos sistemas de saúde, além do *gap* pesquisa relativo à mecanismos ubíquos para monitoramento contínuo da Qualidade de Vida. Nesse cenário, tem despontado o uso de tecnologias como a Internet das Coisas (IoT) ou, no caso da aplicação de IoT em saúde, a Internet das Coisas Médicas (IoHT) [Rodrigues et al. 2018]. A IoHT permite o uso de dados coletados por objetos inteligentes (*e.g.*, smartphones e wearables) para traçar um perfil de saúde dos usuários e detectar situações anômalas.

No entanto, revisões da literatura apontaram para a ausência de mecanismos que usem dados IoHT para inferir a QV dos pacientes, além de soluções capazes de sugerir

adaptações no ambiente a fim de melhorar esse indicador de saúde [Oliveira et al. 2022]. Essa ausência deve-se a diversos fatores, dentre eles os desafios inerentes à área de IoHT (heterogeneidade, alta volatilidade, mobilidade, ausência de modelos semânticos e alto custo de desenvolvimento quando as soluções envolvem Inteligência Artificial), além da dificuldade de coletar dados de forma segura. Dessa forma, considerando os benefícios relacionados às soluções voltadas ao monitoramento contínuo de QV e os desafios presentes na literatura para o desenvolvimento desse tipo de solução, justifica-se a realização deste estudo focado na aplicação de IoHT no monitoramento de Qualidade de Vida.

## 1.2. Objetivos e Contribuições

O objetivo geral desta pesquisa é desenvolver uma plataforma de Internet das Coisas Médicas capaz de inferir, de forma ubíqua, o nível de Qualidade de Vida dos usuários, usando dados de dispositivos inteligentes e algoritmos de aprendizagem de máquina.

Para destacar a contribuição desta pesquisa, considere o seguinte cenário: John possui 35 anos, casado e com um filho. Antes da pandemia de COVID-19, ele praticava atividades físicas, comunicava-se regularmente com amigos e familiares e dormia bem. No entanto, com o agravamento da crise sanitária, John enfrentou dificuldades para manter seus hábitos saudáveis. Se um questionário QV fosse aplicado em 2019, os escores do John provavelmente seriam altos. No entanto, a reaplicação desse instrumento em 2021 traria resultados diferentes. Em 2021, os escores indicariam uma situação de alerta. Manter esses indicadores em níveis baixos pode levar a graves problemas de saúde, como depressão e ansiedade crônica. O cenário ideal seria monitorar continuamente esses indicadores de saúde para alertar John o quanto antes sobre a piora em seus indicadores. No entanto, a aplicação contínua de questionários, os quais representam um monitoramento intrusivo e não transparente, dificulta o engajamento dos participantes.

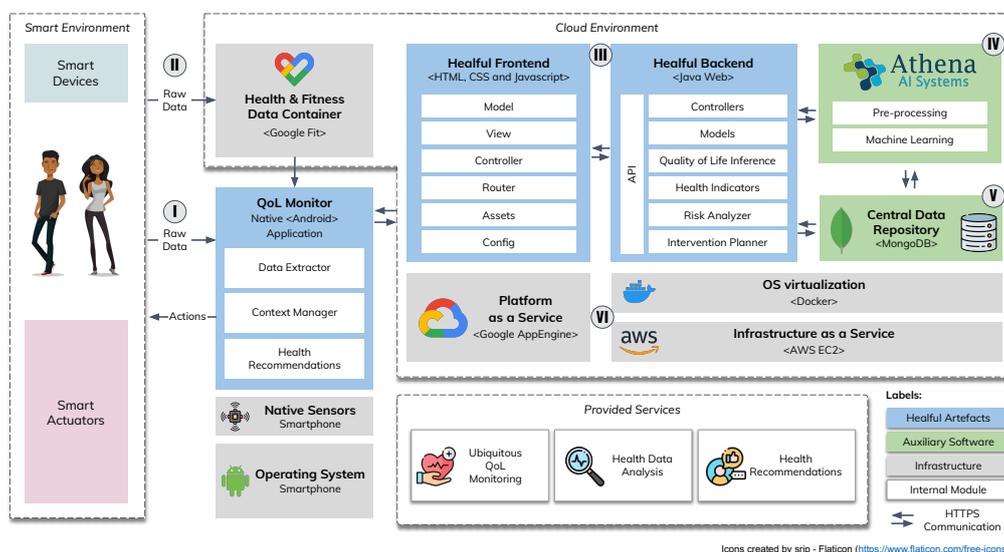
Esse cenário ilustrativo também pode ser analisado sob a ótica dos gestores públicos e privados de provedores de saúde. A crescente demanda por serviços de saúde tem forçado a busca de métodos para otimizar recursos, mantendo a qualidade dos serviços de saúde. O agravamento da saúde de John provavelmente afetará seu uso desses serviços. Assim, o monitoramento contínuo poderia desencadear alertas para antecipar intervenções, como a promoção de cuidados preventivos de forma personalizada. Esse contexto reforça a contribuição a ser alcançada com a plataforma Healful.

## 2. Plataforma Healful

Otimizar os serviços de saúde requer um acompanhamento contínuo da saúde das pessoas [Jakubczyk and Golicki 2018]. É possível então afirmar que uma sociedade moderna e dinâmica requer soluções para monitoramento de saúde sensíveis ao contexto, ubíquas e que façam uso de algoritmos inteligentes. Assim, a plataforma Healful foi desenvolvida para coordenar um conjunto de artefatos de software criados para possibilitar um monitoramento de Qualidade de Vida menos intrusivo, contínuo e ubíquo. A plataforma foi inspirada pelo loop de adaptação MAPE-K [IBM 2005], o qual foi apresentado pela IBM em 2005, mas ainda permanece amplamente utilizado, especialmente em aplicações de Internet das Coisas [Malburg et al. 2023].

A Figura 1 apresenta uma visão arquitetural dos principais módulos da plataforma. A coleta de dados é feita a partir de sensores nativos presentes no smartphone do usuário

(I) ou por meio do Google Fit (II). O Google Fit foi inserido nesse processo para superar os desafios de heterogeneidade e ausência de interfaces para extração de dados na maioria dos *wearables* comerciais. O app responsável por esse processo - QoL Monitor - está disponível para testes na Play Store e foi registrado junto ao INPI (BR 512023003335-9).



**Figura 1. Visão arquitetural dos principais módulos da plataforma Healful.**

Na nuvem, a Healful possui dois subsistemas (III): o frontend, desenvolvido em Javascript para permitir ao pesquisador ou profissional de saúde configurar que dados devem ser coletados, qual algoritmo de análise será aplicado aos dados, quais contextos serão monitorados e quais ações devem ser disparadas em cada contexto; e o backend, desenvolvido usando Java para dar suporte às funcionalidades da plataforma. O backend também lida com a comunicação com a ferramenta Athena (IV), a qual é responsável pela análise dos dados [Oliveira et al. 2018], e com MongoDB, o qual é responsável por armazenar de forma segura os dados dos usuários.

Vale destacar ainda que a plataforma engloba diversos outros artefatos de software, tais como o método utilizado para inferência de Qualidade e o método para o cálculo de cinco indicadores de saúde (nível de mobilidade diária, nível de atividade física, nível de mobilidade social, nível de solidão e qualidade do sono), os quais atuam de forma complementar ao escore de Qualidade de Vida. Maiores detalhes na tese completa.

### 3. Resultados e Discussão

Para avaliar o impacto do trabalho proposto, três avaliações empíricas foram conduzidas: um estudo de caso para validar os modelos de aprendizagem de máquina, um survey com usuários finais da plataforma para obter feedbacks sobre o uso da ferramenta e outro survey com profissionais de saúde para validar os indicadores de saúde.

Quanto ao estudo de caso, o propósito foi investigar o processo de inferência do nível de Qualidade de Vida nos domínios físico e psicológico, usando dados coletados de smartphones e *wearables*, para avaliar esse processo, com respeito aos erros obtidos pelos regressores (erro médio absoluto - MAE e erro médio quadrático - RMSE) tendo como

valor de referência o resultado obtido pelo questionário WHOQOL-BREF, considerando o ponto de vista dos pesquisadores, no contexto de adultos independentes.

Quarenta e quatro (44) adultos participaram como voluntários em um processo de coleta de dados que durou seis meses. Os dados eram coletados diariamente e enviados para a nuvem de forma criptografada. Semanalmente, o usuário recebia uma notificação para responder o questionário WHOQOL-BREF. Assim, após um exaustivo processo de limpeza e processamento de dados, foi possível criar um dataset com 1.373 instâncias.

A partir dos dados coletados, cinco algoritmos de aprendizagem de máquina foram selecionados para avaliação: Linear Regression, Decision Tree Regressor, Random Forest Regressor, GBoost Regressor e Extra Trees Regressors. Os modelos foram codificados usando Jupyter notebooks hospedados na plataforma Kaggle e cada algoritmo foi executado 30 vezes usando o método *cross-validation*. A Tabela 1 traz os resultados iniciais do estudo de caso.

**Tabela 1. Resultados do estudo de caso considerando as métricas MAE, RMSE e tempo de treinamento para os datasets dos domínios físico e psicológico.**

Algoritmo	Dataset físico			Dataset psicológico		
	MAE	RMSE	Tempo	MAE	RMSE	Tempo
Linear Regression	9,5658	14,4308	0,7544	10,6868	17,6120	0,8286
Decision Tree	6,9889	10,4243	1,4479	6,8111	10,5715	1,5317
Random Forest	5,6870	8,0745	92,0384	5,4534	7,7493	98,3695
GBoost	6,0078	8,1860	528,8100	5,7768	8,0693	438,2732
Extra Trees	5,3672	7,4918	16,8884	5,1965	7,3320	16,7467

Após a realização dos testes de hipótese usando os métodos Kruskal-Wallis e Dunn's test, observou-se que o Random Forest apresentou resultados estatisticamente superiores aos demais algoritmos em ambos os datasets. Posteriormente, realizou-se algumas melhorias no modelo final a partir da engenharia de features e de ajustes de parâmetros. Dessa forma, os resultados apontaram que é possível inferir o nível QV dos usuários a partir de dados coletados em smartphones e *wearables* considerando um erro médio de 10% do valor de referência adotado pela OMS. Esse resultado implica que a Healful pode atuar como ferramenta complementar à prática médica, possibilitando um monitoramento diário da Qualidade de Vida das pessoas. Maiores detalhes podem ser obtidos na tese completa: [repositorio.ufc.br/handle/riufc/75777](https://repositorio.ufc.br/handle/riufc/75777).

## Referências

- [Estrada-Galinanes and Wac 2018] Estrada-Galinanes, V. and Wac, K. (2018). Visions and Challenges in Managing and Preserving Data to Measure Quality of Life. In *2018 IEEE 3rd International Workshops on Foundations and Applications of Self\* Systems (FAS\*W)*, pages 92–99, Trento. IEEE.
- [Gmeinder et al. 2017] Gmeinder, M., Morgan, D., and Mueller, M. (2017). How much do oecd countries spend on prevention? *OECD Health Working Papers*, (101). <https://www.oecd-ilibrary.org/content/paper/f19e803c-en>. Acessado em 16-03-2024.
- [IBM 2005] IBM (2005). An architectural blueprint for autonomic computing. Technical report, IBM, United States. <https://api.semanticscholar.org/CorpusID:16909837>. Accessed on April 13, 2016.

- [Jakubczyk and Golicki 2018] Jakubczyk, M. and Golicki, D. (2018). Estimating the Fuzzy Trade-Offs Between Health Dimensions with Standard Time Trade-Off Data. In *Advances in Fuzzy Logic and Technology 2017*. Springer International Publishing, Cham.
- [Kumar et al. 2023] Kumar, M., Kumar, A., Verma, S., Bhattacharya, P., Ghimire, D., Kim, S.-h., and Hosen, A. S. M. S. (2023). Healthcare Internet of Things (H-IoT): Current Trends, Future Prospects, Applications, Challenges, and Security Issues. *Electronics*, 12(9):2050.
- [Malburg et al. 2023] Malburg, L., Hoffmann, M., and Bergmann, R. (2023). Applying MAPE-K control loops for adaptive workflow management in smart factories. *Journal of Intelligent Information Systems*, 61(1):83–111.
- [Nations 2018] Nations, U. (2018). World urbanization prospects 2018. *United Nations, Department of Economic and Social Affairs, Population Division*.
- [Nations 2019] Nations, U. (2019). World population prospects: the 2019 revision. *United Nations, Department of Economic and Social Affairs, Population Division*.
- [Oliveira et al. 2018] Oliveira, P., Neto, P. S., Britto, R., Rabelo, R., Braga, R., and Souza, M. (2018). Ciaas-computational intelligence as a service with athena. *Computer Languages, Systems & Structures*, 54:95–118.
- [Oliveira et al. 2022] Oliveira, P. A. M., Andrade, R. M. C., Neto, P. S. N., and Oliveira, B. S. (2022). Internet of health things for quality of life: Open challenges based on a systematic literature mapping. In *Proceedings of the 15th International Joint Conference on Biomedical Engineering Systems and Technologies*, Online Streaming. INSTICC, SCITEPRESS - Science and Technology Publications.
- [Oliveira et al. 2021] Oliveira, P. A. M., Andrade, R. M. C., and Santos Neto, P. A. (2021). IoT-Health Platform to Monitor and Improve Quality of Life in Smart Environments. In *2021 IEEE 45th Annual Computers, Software, and Applications Conference (COMPSAC)*, pages 1909–1912, Madrid, Spain. IEEE.
- [Rodrigues et al. 2018] Rodrigues, J. J., Segundo, D. B. D. R., Junqueira, H. A., Sabino, M. H., Prince, R. M., Al-Muhtadi, J., and De Albuquerque, V. H. C. (2018). Enabling technologies for the internet of health things. *IEEE Access*, 6:13129–13141.
- [Segun and Telukdarie 2023] Segun, A. and Telukdarie, A. (2023). Revolutionizing Healthcare Delivery Through Wireless Wearable Antenna Frameworks: Current Trends and Future Prospects. *IEEE Access*, 11:80327–80347.
- [Skevington et al. 2004] Skevington, S. M., Lotfy, M., and O’Connell, K. A. (2004). The world health organization’s whoqol-bref quality of life assessment psychometric properties and results of the international field trial. *QoL Research*, 13(2):299–310.
- [WHO 2023] WHO, W. H. O. (2023). Global health expenditure report: Coping with the pandemic (2023). <https://apps.who.int/nha/database/DocumentationCentre/Index/en>. Acessado em 16-03-2024.
- [WHOQoL Group 1994] WHOQoL Group (1994). The Development of the World Health Organization Quality of Life Assessment Instrument (the WHOQOL). In *Quality of Life Assessment International Perspectives*, pages 41–57. Springer Berlin Heidelberg, Berlin, Heidelberg.