

# A Convolutional Neural Network Integrating PPG Signal and Extracted Features for Dehydration Classification

José Mateus Cordova Rodrigues<sup>1</sup>, Ayrton Finicelli Lemes<sup>1</sup>,  
Daniel Mitsuki da Silva Utyama<sup>1</sup>, Pedro Daniel da Silva Gohl<sup>1</sup>,  
Eduardo James Pereira Souto<sup>1</sup>, Rafael Giusti<sup>1</sup>

<sup>1</sup>Instituto de Computação (IComp), Universidade Federal do Amazonas (UFAM),  
Manaus, Amazonas (AM), Brasil.

{jose.cordova, ayrton.lemes, daniel.utyama}@icomp.ufam.edu.br  
{pedro.gohl, esouto, rgiusti}@icomp.ufam.edu.br

**Abstract.** *Dehydration is a serious health issue that can lead to serious consequences, making its accurate detection crucial to maintaining proper bodily function. In this work, we propose a hybrid machine learning model that can classify individuals into hydrated or dehydrated states. Our approach combines a shallow convolutional neural network that extracts unsupervised local features with statistical characteristics of time series data obtained from sensors such as Photoplethysmography (PPG) and Electrodermal Activity (EDA). The results show that the proposed classification model achieves an accuracy of 73%, which is superior to most existing works in the literature that use data extracted from PPG and/or EDA signals for the classification of hydration.*

**Resumo.** *A desidratção é um sério problema de saúde que pode levar a consequências graves, tornando sua detecção precisa crucial para manter a função corporal adequada. Neste trabalho, nós propomos um modelo de aprendizado de máquina híbrido que pode classificar indivíduos em estados hidratados ou desidratados. Nossa abordagem combina uma rede neural convolucional rasa que extrai recursos locais não supervisionados com características estatísticas de dados de séries temporais obtidos de sensores como Fotopletismografia (PPG) e Atividade Eletrodérmica (EDA). Os resultados mostram que o modelo de classificação proposto alcança uma precisão de 73%, sendo superior à maioria dos trabalhos existentes na literatura que utiliza dados extraídos dos sinais PPG e/ou EDA para classificação de hidratação.*

## 1. Introdução

A água é uma das principais substâncias presentes no corpo humano, contribuindo cerca de 63% do peso corporal e presente em 90% do plasma sanguíneo. A água é fundamental para digestão, transporte de nutrientes e rejeitos e regulação da temperatura, dentre outros processos fisiológicos [Islam et al. 2025].

A falta de ingestão de água, bem como seu consumo excessivo, podem acarretar sérios riscos à saúde, tais como mau funcionamento dos rins [El-Sharkawy et al. 2015], depressão [Lee and Kim 2024] e hipertensão [Li et al. 2024]. Embora seja de conhecimento comum a importância de se manter hidratado, a desidratção é um problema ignorado por muitas pessoas. De acordo com Gomes e Sousa (2019), a ingestão de água

é frequentemente negligenciada devido ao ritmo acelerado da vida das pessoas. Além disso, a desidratação é um problema recorrente em idosos. Alguns pacientes idosos com demência esquecem de beber água e alguns optam por não beber por medo de sofrer um episódio de incontinência ou urinar com muita frequência. Já pacientes com demência podem não reconhecer os sintomas da sede ou terem dificuldade em comunicarem suas necessidades [Theodoridis et al. 2025]. Portanto, o monitoramento do nível de hidratação tem um papel vital na saúde e no bem-estar das pessoas [Liaqat et al. 2022].

Para avaliar a hidratação de seus pacientes, profissionais médicos geralmente contam com métodos clínicos e métodos invasivos, como exames de sangue e análise salivar, relacionados a marcadores sensíveis do estado de hidratação como osmolaridade plasmática (PO), características da urina, osmolaridade salivar, análise da bioimpedância (BIA), nível de água corporal total (TBW), medição da pressão arterial e a taxa de pulso [Liaqat et al. 2020]. No entanto, esses métodos são ineficazes para o monitoramento contínuo e fora do ambiente hospitalar. Neste contexto, o uso de dispositivos vestíveis para monitorar a desidratação sem a necessidade de testes invasivos ou supervisão médica pode ser altamente benéfico. Técnicas de Aprendizado de Máquina (AM) podem ser empregadas para analisar dados complexos de sensores ou de imagens em tarefas de classificação, por exemplo, para determinar se um indivíduo apresenta indícios de desidratação ou para identificar quando uma pessoa está realizando movimentos associados ao ato de beber água.

A literatura apresenta várias abordagens para detectar, inferir, e medir a desidratação de indivíduos baseado em dados de sensores não invasivos existentes em dispositivos vestíveis. Algumas abordagens usam sensores físicos com o propósito de detectar um evento de beber ou para estimar a quantidade de líquido ingerido. Sensores inerciais embarcados em dispositivos usados no pulso ou no corpo [Cergolj et al. 2025, Gomes and Sousa 2019, Ortega Anderez et al. 2021] ou em contêineres inteligentes (e.g. copos ou garrafas de água inteligentes) [Plecher et al. 2019, van Iterson et al. 2025] são exemplos disso. Outras abordagens, que visam medir o nível de hidratação do indivíduo, costumam empregar sensores fisiológicos ou biomarcadores para detectar mudanças corporais como alterações na pressão sanguínea e no batimentos cardíacos, variabilidade da condutividade da pele, temperatura, entre outros [Siyoucef et al. 2025, Armstrong 2007, Popkin et al. 2010, Kulkarni et al. 2021].

Este trabalho utiliza características extraídas de sinais de fotopletismografia (PPG) e atividade eletrodérmica (EDA) para detectar indícios de desidratação. Estudos anteriores avaliaram a desidratação produzida por atividades físicas por meio do uso de parâmetros obtidos da frequência cardíaca fornecidas pelo sinal PPG, da atividade eletrodérmica obtida pelo sinal EDA e da temperatura da pele [Liaqat et al. 2020, Sabry et al. 2022, Rizwan et al. 2020]. A vantagem do PPG e do EDA é que tratam-se de sinais de fácil coleta; em especial, existe uma grande quantidade de modelos baratos que permitem a captura do sinal PPG em ambiente livre e doméstico

Para extrair características dos sinais PPG e EDA, este trabalho adota uma arquitetura baseada em redes neurais convolucionais (CNN). As CNNs aprendem filtros que promovem extração de características da entrada, permitindo identificar e capturar padrões locais e suas variações. Esse aprendizado não supervisionado de característica acontece automaticamente nas camadas convolucionais da rede. As características pro-

duzidas são então empregadas como entrada para uma rede densa, na qual o exemplo é efetivamente classificado. Para melhorar o desempenho da rede, nós adicionamos uma nova entrada composta por um conjunto de características estatísticas básicas citadas na literatura. Uma camada de fusão é proposta para combinar as características (extraídas pela CNN e manualmente) em uma representação unificada que é usada para classificar o indivíduo como hidratado ou desidratado. O modelo proposto foi treinado e validado usando uma base de dados pública [Sabry et al. 2022]. Os resultados mostram que o modelo de classificação proposto alcança uma precisão de 73%, sendo superior à maioria dos trabalhos existentes na literatura que utiliza dados extraídos dos sinais PPG e/ou EDA para classificação de hidratação.

O restante do artigo está organizado como segue: a Seção 2 descreve os trabalhos relacionados; a Seção 3 apresenta uma descrição da metodologia utilizada; a Seção 4 descreve os experimentos e discute os resultados obtidos; por fim, na Seção 5 são apresentadas as conclusões e possibilidades de trabalhos futuros.

## 2. Trabalhos Relacionados

Manter os níveis ideais de hidratação no corpo humano é crucial para manter a saúde e prevenir várias doenças. O uso de técnicas de aprendizagem de máquina e de sensores fisiológicos tem sido visto com uma ferramenta promissora para avaliação não invasiva e precisa dos níveis de hidratação. Nesta seção, nós revisamos estudos recentes que utilizam os sensores PPG e/ou EDA e exploram o uso de técnicas de aprendizagem de máquina para detecção do nível de hidratação.

Siyoucef et al. (2025) propõem um sistema baseado em uma tela *touchscreen*, semelhante a de um *smartphone* para monitoração do grau de desidratação. Os sensores medem a capacitância da pele, que varia conforme o grau de hidratação da pessoa. Os dados foram coletados de voluntários sujeitos a desidratação em dois grupos: religiosos que se encontravam em jejum durante o período do ramadã e atletas; o grupo em jejum realizou cinco coletas ao dia em diferentes níveis de desidratação, ao passo que atletas realizaram coletas antes e depois de treinarem. Para classificar os dados, os autores empregaram modelos de AM: regressão logística, máquina de vetores de suporte (SVM), k Vizinhos mais Próximos (k-NN), florestas aleatórias e árvore de decisão. Um dos desafios encontrados no trabalho foi o efeito que o suor causa na coleta dos dados; mesmo com a limpeza dos sensores, o suor residual pode atrapalhar a leitura da capacitância da pele. Não obstante, os autores concluíram que o procedimento é adequado, especialmente para classificação binária (hidratado vs. desidratado).

Rizwan et al. (2020) propuseram uma abordagem não invasiva para estimativa do nível de hidratação usando a Atividade Eletrodérmica (EDA, anteriormente conhecida como Resposta Galvânica da Pele ou GSR). Os autores usaram algoritmos de AM, incluindo regressão linear e árvores de decisão, para prever os níveis de hidratação com base nas medições de EDA. Esse estudo dividiu a base de dados em 3 grupos relacionados à postura dos voluntários durante a coleta, sentado ou em pé. Um terceiro cenário foi definido pela combinação de ambas as posturas e é rotulado como independente. A abordagem que utilizou os dados de voluntários sentados alcançou uma precisão de 81% na previsão dos níveis de hidratação. A abordagem com os dados de voluntários em pé alcançou uma precisão de 76%. A abordagem proposta com dados de postura inde-

pendente alcançou uma precisão de 71% na previsão dos níveis de hidratação, na qual demonstrou seu potencial para monitoramento do nível de hidratação em tempo real.

Reljin et al. (2018) desenvolveram um sistema automático de detecção de desidratação usando máquinas de vetores de suporte (SVMs). O sistema usa sensores não invasivos para medir a variabilidade da frequência cardíaca e prevê os níveis de desidratação com base nessas medições. Os autores demonstraram a eficácia de sua abordagem em um pequeno estudo piloto, alcançando uma precisão de 67,91% na detecção de desidratação.

Posada-Quintero et al. (2019) propuseram uma abordagem baseada em aprendizado de máquina para identificar desidratação leve usando respostas autonômicas ao estresse cognitivo. Os autores usaram modelos de aprendizado raso, tais como SVMs, k-vizinhos mais próximos (KNN) e Análise de Discriminação Quadrática (QDA), para classificar os indivíduos em grupos hidratados e desidratados com base em respostas fisiológicas, como frequência cardíaca e atividade eletrodérmica. O estudo dividiu a base de dados em quatro casos diferentes: 1) apenas medidas coletadas durante descanso; 2) apenas medidas coletadas durante o teste de estresse cognitivo; 3) a diferença entre as medidas de repouso e teste; 4) medidas de repouso e teste. Para o caso 1, utilizou-se um algoritmo de KNN que alcançou 86,7% de precisão. No caso 2 foi aplicado em um SVM que obteve uma precisão de 73,9%. Um algoritmo de KNN foi aplicado para o caso 3 e obteve 68,2% de precisão. No caso 4 foi aplicado um algoritmo de QDA que alcançou 90% de precisão.

Liaqat et. al. (2020) utilizaram uma abordagem não invasiva para detecção do nível de hidratação da pele observando cenários onde a pessoa se encontra sentada e em pé. Os autores usaram diversos algoritmos de aprendizagem de máquina, incluindo regressão logística, floresta aleatória, K-vizinhos próximos, Naive Bayes, árvores de decisão, análise do discriminante linear e AdaBoost para classificar o nível de hidratação de uma pessoa baseado nas medições obtidas pela atividade eletrodérmica (EDA). Os autores obtiveram com essa abordagem uma precisão de 93% para classificação de desidratação utilizando o algoritmo floresta aleatória.

Alaslani et al. (2024) coletaram dados de PPG utilizando a câmera de um *smartphone*. Os dados foram coletados de um grupo de 25 pessoas em jejum durante o ramadã. Experimentos foram realizados em duas modalidades: um problema de classificação múltipla (hidratado, levemente desidratado, desidratado ou severamente desidratado) e um problema de classificação binária. O sinal de PPG foi pré-processado com filtro Butterworth e frequência de corte de 10Hz, normalizado e segmentado em sub-janelas de 3 segundos. Além disso, os autores empregaram aumento de dados adicionando ruído gaussiano às janelas, promovendo diferentes experimentos nas quais os dados foram aumentados em duas, três e quatro vezes o número original de instâncias. Foram testados modelos rasos (k-NN, SVM e florestas aleatórias), modelos de sequência (LSTM e BiLSTM-FCN) e *transformers* (DistilBERT e ViT). Para todos os modelos, os autores reportaram melhoria dos resultados (em acurácia) com aumento de dados, sendo que os melhores resultados foram obtidos com dados aumentados em quatro vezes a quantidade original de instâncias. Os autores concluem que os modelos de aprendizado profundo e os *transformers* apresentam os melhores desempenhos dentre todos os analisados.

Diferentemente das abordagens discutidas acima, este trabalho propõe uma arqui-

tutura que combina uma CNN rasa para extração de características locais não supervisionadas, juntamente com características estatísticas que codificam informações globais das séries temporais utilizadas (dados dos sinais PPG e EDA). Além disso, durante o processo de validação uma abordagem hold-out por indivíduo foi adotada para evitar vazamento de dados.

### **3. Materias e Método**

Este trabalho tem como objetivo propor um método para detecção de desidratação utilizando dados de sensores fisiológicos e uma arquitetura híbrida de aprendizado profundo, com a finalidade de contribuir para o monitoramento de desidratação. Detalhes sobre o conjunto de dados, pré-processamento dos dados e arquitetura de rede são apresentados a seguir.

#### **3.1. Conjunto de dados**

Este estudo utilizou a base de dados pública proposta por Sabry et al. (2022), que inclui sinais inerciais e fisiológicos coletados de 11 indivíduos durante um período de jejum. Nesta pesquisa foram selecionados apenas os sinais fisiológicos de Atividade Eletrodérmica (EDA) e Fotopletismografia (PPG). Os dados foram coletados a partir da unidade *Shimmer Galvanic Skin Response* (GSR), com seus eletrodos de resposta galvânica nos dedos indicador e médio da mão esquerda e o clipe de fotopletismografia atrelado ao lóbulo da orelha esquerda. Foram considerados dois cenários de jejum: o primeiro durante o período de jejum do Ramadã e o segundo durante um período de jejum intermitente sem ingestão de sólidos ou líquidos, registrando o último evento de ingestão de água ou comida. Os indivíduos não foram restritos em relação a movimentos ou horários de uso do dispositivo vestível, a fim de representar um cenário real de uso durante atividades do dia-a-dia, embora a maioria dos dados tenha sido coletada enquanto os usuários estavam sentados.

#### **3.2. Tratamento dos dados**

Nesta etapa, os dados foram preparados para serem utilizados em um modelo de predição. Para isso, os dados foram segmentados em janelas deslizantes de 4 minutos [Sabry et al. 2022], com sobreposição de 50% entre janelas adjacentes. Essa técnica de sobreposição é comumente adotada em análise de séries temporais, pois permite capturar informações de continuidade e mudanças graduais nos dados [Posada-Quintero et al. 2019].

Os dados brutos do PPG foram preparados para análise, passando por diferentes etapas de processamento. Primeiro, os valores dos dados brutos foram normalizados. Em seguida, os dados normalizados foram submetidos a um filtro de passa-baixa Butterworth para remover as frequências acima de 8 Hz e abaixo de 0,5 Hz, mantendo apenas as frequências relevantes para a análise, conforme sugerido em [Akar et al. 2013].

Em seguida, foi realizada extração de características. Foram extraídas das janelas informações importantes como a taxa de batimentos por minuto, a taxa de respiração e a raiz quadrada média de diferenças sucessivas entre batimentos cardíacos normais. A taxa de batimentos por minuto, por exemplo, é um indicador importante do estado cardiovascular de um indivíduo, enquanto a taxa de respiração pode fornecer informações

sobre a função respiratória. A raiz quadrada média de diferenças sucessivas entre batimentos cardíacos normais é um indicador da variabilidade da frequência cardíaca, que é um importante biomarcador do sistema nervoso autônomo e pode ser útil para avaliar o estresse e outras condições de saúde. Essas características foram extraídas dos sinais do PPG filtrado usando o Heartpy [Van Gent et al. 2019], que é uma biblioteca especializada em análise de sinais de PPG.

Além dessas características também foram extraídas características estatísticas (mínimo, média, variância, entropia, desvio padrão, percentil, mediana, moda e curtose) dos sinais GSR e PPG. Essas características estatísticas podem ser usadas para descrever as propriedades dos sinais. Por exemplo, uma alta variância ou entropia pode indicar que o sinal está mais irregular e imprevisível, enquanto uma curtose elevada pode indicar que os dados têm uma distribuição mais concentrada em torno da média. Essas informações podem ser úteis na detecção de alterações fisiológicas ou emocionais presentes nos sinais GSR e PPG [Liaqat et al. 2020].

O conjunto de dados utilizado possui um desbalanceamento muito grande entre os indivíduos, resultando em uma distribuição desbalanceada entre as classes, como mostrado na Tabela 1. Entretanto, antes de realizar alterações no conjunto, os dados foram particionados em um subconjunto de treinamento e outro de teste utilizando a abordagem *hold-out*. Especificamente, os indivíduos 3 e 4 foram selecionados para compor o conjunto de teste devido ao fato de possuírem coletas aproximadamente balanceadas. Os demais indivíduos foram utilizados para treinamento.

Para lidar com o desbalanceamento dos indivíduos no conjunto de treinamento, realizamos uma sub-amostragem aleatória da amostra do indivíduo 1 para 2.808.000 observações. Esse número foi definido por ser próximo da quantidade de observações do segundo indivíduo com maior tempo de coleta e por ser compatível com o tamanho de janela definido para os experimentos. Na fase de treinamento foram geradas observações da classe minoritária sinteticamente aplicando a técnica SMOTE (Synthetic Minority Over-sampling Technique) [Blagus and Lusa 2013] com o propósito de manter equilibrado o número de observações de cada classe (hidratado e não hidratado). No total, foram utilizadas 15.536.352 observações para treino e 4.181.424 para teste.

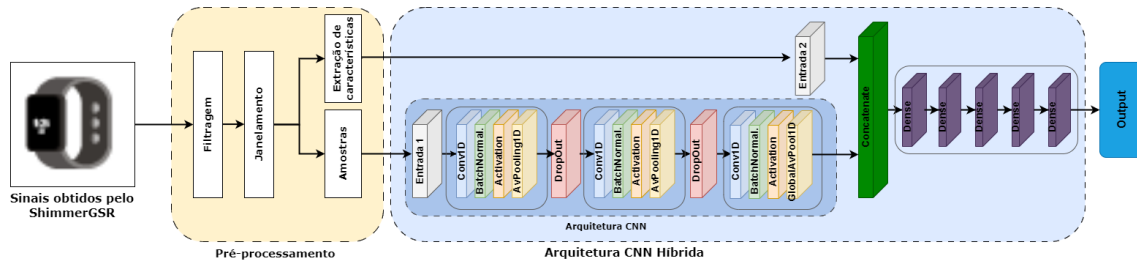
**Tabela 1. Tamnho da amostra por indivíduo (*subject*).**

	<b>Observações de Hidratados</b>	<b>Observações de Desidratados</b>	<b>Total</b>
S1	6.054.672	3.475.680	9.530.352
S2	840.528	84.240	924.768
S3	546.624	475.488	1.022.112
S4	1.630.512	1.528.800	3.159.312
S5	318.864	115.440	434.304
S6	0	125.424	125.424
S7	33.072	0	33.072
S8	111.696	0	111.696
S9	115.440	0	115.440
S10	124.176	0	124.176
S11	169.728	0	169.728

### 3.3. Arquitetura da rede

A arquitetura CNN híbrida (CNN-H) proposta tem duas entradas, conforme a Figura 1. Na primeira entrada, os sinais GSR (dois componentes do sinal: resistência e condutância) e PPG são submetidos a rede composta por três blocos para realizar a extração de características, cada um consistindo de uma camada de convolução 1D com filtros de tamanho variado, seguida de uma camada de *batch normalization*, uma camada de ativação ReLU (Rectified Linear Unit) e uma camada de *pooling* para reduzir o número de parâmetros a serem aprendidos e a quantidade de computação realizada na rede. Por fim, os 2 primeiros blocos possuem uma camada de *dropout* com 30% e 20%, empregados para reduzir o risco de *overfitting*. Dessa forma, após percorrer os blocos citados, os dados de entrada são transformados em um vetor de características.

Em seguida, as características extraídas pelas camadas de convolução são concatenadas com as características estatísticas (Entrada 2) e são passadas para as camadas densas com função de ativação ReLU, sendo a última camada com função de ativação *Softmax*. A saída do modelo híbrido é uma avaliação se os dados representam um cenário de hidratação ou desidratação. A saída da rede neural é uma avaliação da possibilidade de uma amostra ser de um episódio de hidratação ou desidratação. A Tabela 2 especifica a arquitetura, mostrando as camadas, formato das saídas e o tamanho do kernel.



**Figura 1. Arquitetura CNN híbrida proposta para reconhecimento de desidratação.**

### 3.4. Métricas de Avaliação

Para avaliar o método proposto foram utilizadas as métricas: precisão, revocação e F1-score. A matriz de confusão que relata o número de verdadeiros positivos (VP), verdadeiro negativo (VN), falsos positivos (FP) e falsos negativos (FN) foi utilizada para calcular essas métricas.

A precisão é uma métrica que indica a proporção de exemplos classificados como positivos pelo modelo que realmente pertencem a essa classe. A precisão reflete o quão “confiável” é no caso de uma classificação positiva; em nosso caso, qual a probabilidade de uma pessoa estar realmente desidratada quando o modelo dá uma saída positiva. A precisão foi calculada a partir da seguinte fórmula:

$$Pre = \frac{VP}{VP + FP}$$

A revocação é uma métrica que indica a proporção de exemplos classificados como positivos em relação ao número total de exemplos verdadeiramente positivos. A

**Tabela 2. Parâmetros utilizados na arquitetura proposta.**

	<b>Tipo</b>	<b>Formato da Saída</b>	<b>Número de Filtros</b>	<b>Tamanho do Kernel</b>	<b>Função de Ativação</b>
0	Camada de Entrada 1	624x3	-	-	-
1	Camada de Convolução 1D	624x16	16	64	ReLu
2	Camada de Normalização	624x16	-	-	-
3	Camada de Ativação	624x16	-	-	ReLu
4	Agrupamento Médio	312x16	-	-	-
5	Dropout	312x16	-	-	-
6	Camada de Convolução 1D	312x64	64	32	ReLu
7	Camada de Normalização	312x64	-	-	-
8	Camada de Ativação	312x64	-	-	ReLu
9	Agrupamento Médio	156x64	-	-	-
10	Dropout	156x64	-	-	-
11	Camada de Convolução 1D	156x64	64	16	ReLu
12	Camada de Normalização	156x64	-	-	-
13	Camada de Ativação	156x64	-	-	ReLu
14	Agrupamento Médio	64	-	-	-
15	Camada de Entrada 2	30	-	-	-
16	Concatenação	94	-	-	-
17	Densa 1	64	-	-	-
18	Densa 2	32	-	-	-
19	Densa 3	16	-	-	-
20	Densa 4	8	-	-	-
21	Camada de Saída	2	-	-	-

revocação mede a capacidade do modelo de detectar todos os exemplos positivos em um conjunto de dados; em nosso caso, qual a probabilidade de o modelo identificar que uma pessoa está desidratada. A revocação pode ser calculada a partir da seguinte fórmula:

$$Rev = \frac{VP}{VP + FN}$$

O F1-score é uma métrica que combina a precisão e a revocação do modelo, fornecendo uma medida única do desempenho geral do modelo. O F1-score é calculado como a média harmônica entre a precisão e a revocação do modelo, utilizando a seguinte fórmula:

$$F_1 = \frac{2 \cdot Rev \cdot Pre}{Rev + Pre}$$

#### 4. Resultados e Discussão

Neste trabalho, o problema foi tratado como um problema de classificação binária, com duas classes distintas: hidratado e desidratado. O principal desafio encontrado foi lidar com desequilíbrio dos dados, com a maioria dos dados concentrada nos primeiros indivíduos, como evidenciado na Tabela 1. Para abordar esse problema, nós utilizamos estratégias de sub-amostragem (aleatória) e super-amostragem (SMOTE) nas classes majoritária e minoritária, respectivamente.



A Tabela 3 mostra a precisão, revocação e F1-Score obtidos a partir do conjunto de dados usados nos experimentos. Os resultados mostram que nosso modelo pode reconhecer um indivíduo desidratado com 73% de precisão e apresenta uma taxa de revocação bem próxima, 72,5% das amostras positivas existentes foram classificadas corretamente.

**Tabela 3. Desempenho da arquitetura proposta.**

	Número de Observações	Precisão	Revocação	F1-score
Hidratados	1.451.424	0,70	0,77	0,74
Desidratados	1.506.336	0,76	0,68	0,72
Média	1.478.880	0,73	0,725	0,73

Para fins de comparação, a Tabela 4 apresenta dados de trabalhos da literatura que propõem modelos de detecção de desidratação e as métricas usadas para avaliar o modelo proposto. Reljin et al. (2018) sugeriram usar dados extraídos da fotopletiografia (PPG) para detectar desidratação usando máquina de vetores de suporte, resultando em uma precisão de 67,91%. Posada-Quintero et al. (2019) propuseram o uso de estresse cognitivo para melhorar a detecção de desidratação, usando um KNN validando por meio da técnica *Leave-One-Subject-Out* (LOSO), que é uma espécie de validação cruzada na qual cada *fold* contém os dados de um indivíduo. Utilizando apenas dados de voluntários em descanso por 4 minutos, a precisão alcançada é de 86,7%. Esse cenário está alinhado com nossa abordagem, que não considerou dados de indivíduos com estresse cognitivo.

Rizwan et al. (2020) sugeriram o uso do algoritmo k-vizinhos mais próximos (KNN), separando os dados em “sentado”, “em pé” ou “independente”, sendo este último definido pela combinação das posturas físicas sentado e em pé. Os resultados de precisão obtidos foram 81%, 76% e 71%, respectivamente, sendo a abordagem de indivíduos com postura “independente” compatível com a apresentada nesse trabalho. Nosso estudo simula um ambiente livre e menos restritivo, usando um modelo gerado a partir de uma arquitetura de CNN híbrida, resultando em uma precisão de 73%. É importante ressaltar que os resultados obtidos em nosso estudo foram claramente afetados pelos diferentes estados de hidratação dos indivíduos existentes na base de dados utilizada.

**Tabela 4. Comparação com outros trabalhos encontrados na literatura.**

	Sensores	Arquitetura	Precisão	Validação
[Reljin et al. 2018]	PPG	SVM	67,91%	Cross-validation
[Posada-Quintero et al. 2019]	PPG/EDA	KNN	86,7%	LOSO
[Rizwan et al. 2020]	EDA	KNN	71%	Cross-validation
Proposto neste Artigo	PPG/EDA	Modelo híbrido	73%	Subject hold-out

## 5. Conclusão

Neste trabalho, propomos uma abordagem não invasiva para a detecção de episódios de desidratação a partir de sinais fisiológicos obtidos por sensores de fotopletiografia (PPG) e atividade eletrodérmica (EDA). Desenvolvemos uma arquitetura CNN híbrida que integra uma rede convolucional rasa para extração de padrões locais com um conjunto de características estatísticas que descrevem propriedades globais dos sinais.

Conforme representado na Tabela 3, o método proposto alcançou 73% de precisão, 72,5% de revocação e 73% de F1-score em um conjunto de dados coletados em ambiente livre de indivíduos com níveis de desidratação diferentes. Esses resultados sugerem que é possível relacionar a diferença de um indivíduo hidratado ou desidratado com os dados obtidos pelos sensores fisiológicos, o que pode ser usado em monitoramento contínuo através de dispositivos vestíveis. Os testes foram realizados em modelo não-agnóstico ao indivíduo, no qual os dados de treino e de teste foram coletados de indivíduos distintos, sugerindo a capacidade de generalização do modelo.

As limitações do trabalho incluem o baixo número de indivíduos e o desbalanceamento das classes.

Como trabalhos futuros, propomos a inclusão de novos sinais fisiológicos (como temperatura da pele ou aceleração corporal), exploração de técnicas de janelamento dinâmico, adaptativas ao sinal e o foco em modelos mais leves e interpretáveis para implementação embarcada em dispositivos de baixo custo.

## Agradecimentos

O presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (AUXPE-CAPES-PROEX) - Código de Financiamento 001 e do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq). Adicionalmente, este trabalho foi parcialmente financiado pela Fundação de Amparo à Pesquisa do Estado do Amazonas - FAPEAM - por meio do projeto PDPG-CAPES.

## Referências

- Akar, S. A., Kara, S., Latifoğlu, F., and Bilgic, V. (2013). Spectral analysis of photoplethysmographic signals: The importance of preprocessing. *Biomedical Signal Processing and Control*, 8(1):16–22.
- Alaslani, R., Perzhilla, L., Rahman, M. M. U., Laleg-Kirati, T.-M., and Al-Naffouri, T. Y. (2024). You can monitor your hydration level using your smartphone camera. *arXiv preprint arXiv:2402.07467*.
- Armstrong, L. E. (2007). Assessing hydration status: the elusive gold standard. *Journal of the American College of Nutrition*, 26(sup5):575S–584S.
- Blagus, R. and Lusa, L. (2013). Smote for high-dimensional class-imbalanced data. *BMC bioinformatics*, 14:1–16.
- Cergolj, V., Stankoski, S., Pirc, M., and Luštrek, M. (2025). Drinking event detection on a sensing wristband using machine learning. *Journal of Ambient Intelligence and Smart Environments*, 17(2):164–181.
- El-Sharkawy, A. M., Sahota, O., and Lobo, D. N. (2015). Acute and chronic effects of hydration status on health. *Nutrition reviews*, 73(suppl\_2):97–109.
- Gomes, D. and Sousa, I. (2019). Real-time drink trigger detection in free-living conditions using inertial sensors. *Sensors*, 19(9):2145.
- Islam, T., Rigan, M. M. H., Bhuiyan, M. O. H., Hashem, T., and Rahman, M. M. (2025). H2opulse: Smartphone-assisted vein evaluation for early recognition of dehydration.

*Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 9(2):1–24.

- Kulkarni, N., Compton, C., Luna, J., and Alam, M. A. U. (2021). A non-invasive context-aware dehydration alert system. In *Proceedings of the 22nd International Workshop on Mobile Computing Systems and Applications*, pages 157–159.
- Lee, J. W. and Kim, Y. (2024). Association of plain water intake with self-reported depression and suicidality among korean adolescents. *Epidemiology and health*, 46:e2024019.
- Li, S., Xiao, X., and Zhang, X. (2024). Association between plain water intake and risk of hypertension: longitudinal analyses from the china health and nutrition survey. *Frontiers in Public Health*, 11:1280653.
- Liaqat, S., Dashtipour, K., Arshad, K., and Ramzan, N. (2020). Non invasive skin hydration level detection using machine learning. *Electronics*, 9(7):1086.
- Liaqat, S., Dashtipour, K., Rizwan, A., Usman, M., Shah, S. A., Arshad, K., Assaleh, K., and Ramzan, N. (2022). Personalized wearable electrodermal sensing-based human skin hydration level detection for sports, health and wellbeing. *Scientific Reports*, 12(1):3715.
- Ortega Anderez, D., Lotfi, A., and Pourabdollah, A. (2021). A deep learning based wearable system for food and drink intake recognition. *Journal of Ambient Intelligence and Humanized Computing*, 12:9435–9447.
- Plecher, D. A., Eichhorn, C., Lurz, M., Leipold, N., Böhm, M., Krcmar, H., Ott, A., Volkert, D., and Klinker, G. (2019). Interactive drinking gadget for the elderly and alzheimer patients. In *Human Aspects of IT for the Aged Population. Social Media, Games and Assistive Environments: 5th International Conference, ITAP 2019, Held as Part of the 21st HCI International Conference, HCII 2019, Orlando, FL, USA, July 26-31, 2019, Proceedings, Part II 21*, pages 444–463. Springer.
- Popkin, B. M., D’Anci, K. E., and Rosenberg, I. H. (2010). Water, hydration, and health. *Nutrition reviews*, 68(8):439–458.
- Posada-Quintero, H. F., Reljin, N., Moutran, A., Georgopalis, D., Lee, E. C.-H., Giersch, G. E., Casa, D. J., and Chon, K. H. (2019). Mild dehydration identification using machine learning to assess autonomic responses to cognitive stress. *Nutrients*, 12(1):42.
- Reljin, N., Malyuta, Y., Zimmer, G., Mendelson, Y., Blehar, D. J., Darling, C. E., and Chon, K. H. (2018). Automatic detection of dehydration using support vector machines. In *2018 14th Symposium on Neural Networks and Applications (NEUREL)*, pages 1–6. IEEE.
- Rizwan, A., Ali, N. A., Zoha, A., Ozturk, M., Alomainy, A., Imran, M. A., and Abbasi, Q. H. (2020). Non-invasive hydration level estimation in human body using galvanic skin response. *IEEE Sensors Journal*, 20(9):4891–4900.
- Sabry, F., Eltaras, T., Labda, W., Hamza, F., Alzoubi, K., and Malluhi, Q. (2022). Towards on-device dehydration monitoring using machine learning from wearable device’s data. *Sensors*, 22(5):1887.

- Siyoucef, S., Adnane, M., Rahman, M. M. U., Laleg-Kirati, T.-M., and Al-Naffouri, T. Y. (2025). Non-invasive monitoring of dehydration of fasting and sportspeople subjects via skin capacitance. *IEEE Sensors journal*.
- Theodoridis, X., Poulia, K. A., and Chourdakis, M. (2025). What's new about hydration in dementia? *Current Opinion in Clinical Nutrition & Metabolic Care*, 28(1):20–24.
- Van Gent, P., Farah, H., Van Nes, N., and Van Arem, B. (2019). Heartpy: A novel heart rate algorithm for the analysis of noisy signals. *Transportation research part F: traffic psychology and behaviour*, 66:368–378.
- van Iterson, H. C., Liang, R.-H., and Markopoulos, P. (2025). Redesigning fluid tracking probes for elderly lifestyle retrofit. In *Proceedings of the Nineteenth International Conference on Tangible, Embedded, and Embodied Interaction*, pages 1–6.