

Predição de Níveis de Ansiedade Utilizando Dados de Smartwatches em Ambiente Não Controlado

Raphael M. M. Fernandes¹, Bernardo M. Rebello¹, João Vitor P. Rodrigues¹
Ana Luiza P. Alves¹, Gabriel V. S. Conceição¹, Arthur M. Fernandes¹
Débora C. Muchaluat-Saade¹, Taiane C. Ramos¹

¹ Instituto de Computação, UFF, Niterói - RJ, Brasil

raphael.m@id.uff.br, mendes.bernardo@id.uff.br,
joaovitorpereira9f@gmail.com, paivaana@id.uff.br, gabrielvsc@id.uff.br,
arthurmf@id.uff.br, debora@midia.com.uff.br, taiane-ramos@id.uff.br

Resumo. A ansiedade é um transtorno relacionado a alterações de inquietação e sono. Este estudo investiga dispositivos vestíveis para monitoramento contínuo em ambientes não controlados, utilizando aprendizado profundo. Foi avaliada uma rede LSTM para regressão dos níveis de ansiedade com dados de acelerômetro de 41 voluntários coletados por 24 horas. As pontuações foram obtidas pelo IDATE, com aumento de dados (20, 50 e 100 vezes). O melhor desempenho ocorreu com 50 (MAE: 6,04 treino; 5,30 validação). As correlações de Pearson foram 0,71 e 0,50, respectivamente. Os resultados indicam potencial para monitoramento contínuo e não invasivo da saúde mental.

Abstract. Anxiety is a prevalent disorder associated with changes in movement and sleep patterns. This study investigates wearable devices for continuous monitoring in real-life settings using deep learning. An LSTM network was evaluated to regress anxiety levels from accelerometer data collected over 24 hours from 41 volunteers. Anxiety scores were obtained using the STAI, with data augmentation via downsampling (20, 50, and 100 repetitions). The best performance was achieved with 50 repetitions (MAE: 6.04 training; 5.30 validation). Pearson correlations were 0.71 and 0.50, respectively. The results indicate potential for continuous and non-invasive mental health monitoring.

1. Introdução

A ansiedade é caracterizada por estados persistentes de apreensão, tensão e hiperativação fisiológica. Entre as manifestações comportamentais associadas à ansiedade, há estudos sobre o aumento da inquietação motora, frequentemente descrita como agitação psicomotora, dificuldade em permanecer parado e necessidade constante de movimento [Pompili et al. 2021, Luca et al. 2026]. Evidências sugerem que indivíduos com níveis elevados de ansiedade tendem a apresentar diferenças no padrão de movimento quando comparados a pessoas sem esses transtornos [Elkjær et al. 2022a, Liang et al. 2026]. Esse aumento da atividade motora pode se manifestar tanto em movimentos amplos quanto em microajustes posturais frequentes, indicando um estado contínuo de vigilância e de ativação fisiológica.

A relação entre ansiedade e movimentação diária também pode ser compreendida ao considerarmos as áreas do cérebro associadas ao transtorno. Uma maior atividade do sistema nervoso e de circuitos neurais está relacionada à resposta ao estresse,

como a amígdala e o córtex pré-frontal, que se associam a respostas comportamentais de alerta e preparação para ação [Duval et al. 2015, Vincent et al. 2025]. Como consequência, indivíduos ansiosos podem apresentar padrões motores distintos, caracterizados por maior frequência de deslocamentos, mudanças posturais e oscilações na intensidade de movimento ao longo do dia [Franklin et al. 2021a]. A disponibilidade de dispositivos vestíveis equipados com acelerômetros e giroscópios permite a quantificação objetiva desses padrões, oferecendo uma alternativa complementar às avaliações subjetivas tradicionalmente utilizadas na prática clínica.

A alteração nos padrões do sono é outro forte indício de transtorno, já que indivíduos com níveis elevados de ansiedade frequentemente apresentam aumento da latência para o início do sono, maior fragmentação do sono e redução da eficiência do repouso noturno [Alvaro et al. 2016]. A hiperativação fisiológica característica do transtorno pode persistir mesmo durante o período noturno, resultando em maior variabilidade motora e aumento de microdespertares, fenômenos que podem ser captados por dispositivos vestíveis com sensores inerciais [Straus et al. 2023]. Estudos baseados em actigrafia indicam que padrões de movimentação durante o sono apresentam correlação com níveis de ansiedade autorreferidos, sugerindo que a análise contínua do ciclo vigília-sono pode fornecer marcadores objetivos complementares para o monitoramento da saúde mental [Hamitouche et al. 2025]. Dessa forma, a integração de dados de movimento coletados ao longo de todo o dia, incluindo períodos de repouso, amplia a compreensão dos padrões comportamentais associados à ativação psicofisiológica.

Sendo possível mensurar diferentes tipos de padrão na movimentação diária de um indivíduo e correlacioná-los a níveis de ansiedade, as técnicas de aprendizado de máquina podem apresentar resultados satisfatórios na identificação automática desses padrões. Em particular, as redes neurais profundas têm demonstrado desempenho elevado na análise de séries temporais complexas [LeCun et al. 2015]. O uso de sensores inerciais, como acelerômetros e giroscópios, produzem sinais multivariados ao longo do tempo, cuja dinâmica pode conter informações relevantes sobre estados emocionais e fisiológicos. Assim, elas capturam as dependências de curto e longo prazo presentes nos dados de movimento para detectar padrões sutis associados à ansiedade.

As redes neurais recorrentes (RNNs), especialmente a LSTM, têm sido amplamente empregadas na modelagem de sequências temporais devido à sua capacidade de preservar informações relevantes ao longo do tempo e de mitigar o problema do desaparecimento do gradiente [Graves 2012]. Essa característica é particularmente importante na análise de sinais provenientes de sensores corporais, em que padrões comportamentais podem emergir de combinações temporais complexas no eixo de aceleração [Wang et al. 2019]. Ao integrar múltiplas dimensões de dados inerciais, os modelos LSTM extraem representações latentes que distinguem diferentes níveis de ativação psicofisiológica, ampliando as possibilidades de aplicação da inteligência artificial no monitoramento da saúde mental.

Neste contexto, o presente trabalho investiga o uso de um modelo LSTM para detectar níveis de ansiedade a partir de dados de movimento corporal. Para isso, empregamos uma base de dados composta por sinais de acelerômetro coletados durante a rotina diária de 41 participantes, juntamente com escalas psicométricas aplicadas no momento da coleta para quantificar os níveis de ansiedade. A contribuição principal deste traba-

lho é demonstrar que o modelo LSTM proposto, que adota uma abordagem de regressão, aprende padrões temporais associados às diferentes pontuações nas escalas de ansiedade, o que contribui para o desenvolvimento de abordagens automatizadas de monitoramento emocional baseadas em sensores vestíveis.

O restante deste artigo está organizado da seguinte forma: Na Seção 2, apresentamos os trabalhos relacionados, destacando abordagens recentes na utilização de redes neurais profundas para análise de neuroimagem. A Seção 3 detalha toda metodologia presente no estudo, incluindo pré-processamento, aumento de dados e a rede neural. Na Seção 4, detalhamos os resultados obtidos referentes a tarefa de regressão nos dados de acelerômetro. A Seção 5 apresenta a discussão dos achados, contextualizando-os à luz da literatura existente e das limitações do estudo. Por fim, a Seção 6 traz as conclusões do trabalho e direções para pesquisas futuras.

2. Trabalhos Relacionados

A análise de ansiedade e de sono utilizando métodos de aprendizado de máquina (AM) ainda é pouco explorada na literatura. Embora existam evidências consistentes de que transtornos de ansiedade estão associados a alterações nos padrões de sono e na atividade circadiana, poucos trabalhos buscam integrar essas variáveis por meio de modelos preditivos, limitando-se a análises correlacionais ou a comparações entre grupos, que não adotam abordagens computacionais capazes de estimar sintomas de ansiedade a partir de dados objetivos coletados por dispositivos vestíveis.

Entre os estudos que se aproximam dessa proposta, destaca-se o trabalho de Fang et al. (2025), que investigaram a identificação de ansiedade clinicamente significativa em indivíduos com insônia de curto prazo utilizando dados de acelerômetro obtidos por dispositivos vestíveis. A ansiedade nesses indivíduos foi detectada por meio de uma escala psicométrica, conhecida como *Generalized Anxiety Disorder*, voltada à ansiedade generalizada. Os autores aplicaram diferentes algoritmos de AM, incluindo *XGBoost*, *Random Forest*, SVM e MLP, e avaliaram conjuntos de características relacionadas à atividade física, ao sono e ao ritmo circadiano. O melhor desempenho foi obtido pelo modelo *XGBoost*, com dados coletados por no mínimo 5 dias, alcançando uma área sob a curva (AUC) de 0,77. Apesar da contribuição, o estudo limita-se à classificação binária. Além disso, utilizaram a técnica SMOTE para geração de dados sintéticos, o que pode introduzir vieses e comprometer a capacidade de generalização dos modelos em amostras independentes.

Pastre et al. (2022) propõem uma revisão de estudos que utilizaram actigrafia para investigar padrões de sono e atividade em indivíduos com transtornos de ansiedade. Através da revisão, os autores identificaram evidências de maior fragmentação do sono, aumento da variabilidade intradiária e redução da continuidade do sono em pacientes ansiosos. Em especial, subgrupos como o transtorno de ansiedade generalizada apresentaram menor tempo total de sono e maior instabilidade do ritmo circadiano. Esse estudo pode indicar que padrões objetivos de movimento e atividade diferem entre participantes do controle e participantes com ansiedade, e essas diferenças podem ser captadas por dispositivos de coleta de dados de movimento.

Em Bursa et al. (2023) foi demonstrado que dados de acelerômetro e giroscópio provenientes de *smartphones* e *smartwatches* atingem elevada acurácia na identificação

de padrões comportamentais. Trabalhos recentes aplicando arquiteturas de AP a dados inerciais reportam acurácias superiores a 90% em tarefas de classificação de atividades, evidenciando a robustez desses sensores. Isso sugere que os sinais captados por *smartwatches* são informativos para a modelagem de padrões complexos de movimento, o que amplia sua aplicabilidade em contextos clínicos.

Apesar das contribuições existentes, não foram identificados, na literatura, estudos que proponham a análise de regressão dos níveis de ansiedade a partir de dados objetivos de movimento e sono. Ainda assim, evidências prévias demonstram a alta precisão de sensores vestíveis na captura de padrões de atividade, bem como a associação entre maiores índices de movimento e ansiedade em comparação a indivíduos controle.

Diante desse cenário, este trabalho propõe investigar o uso de um modelo de aprendizado de máquina para prever níveis de ansiedade com base em dados obtidos por *smartwatch*. Além disso, considerando as limitações do aumento de dados artificiais, propõe-se uma estratégia de aumento de dados estruturado, sem geração de dados sintéticos.

3. Metodologia

A metodologia é composta pelo recrutamento e coleta dos dados de acelerômetro dos participantes, seguida de um pré-processamento e um aumento de dados, realizado para melhorar a generalização devido a alta necessidade de grandes conjuntos de dados das redes neurais. A Figura 1 ilustra todo o pipeline conduzido na proposta.

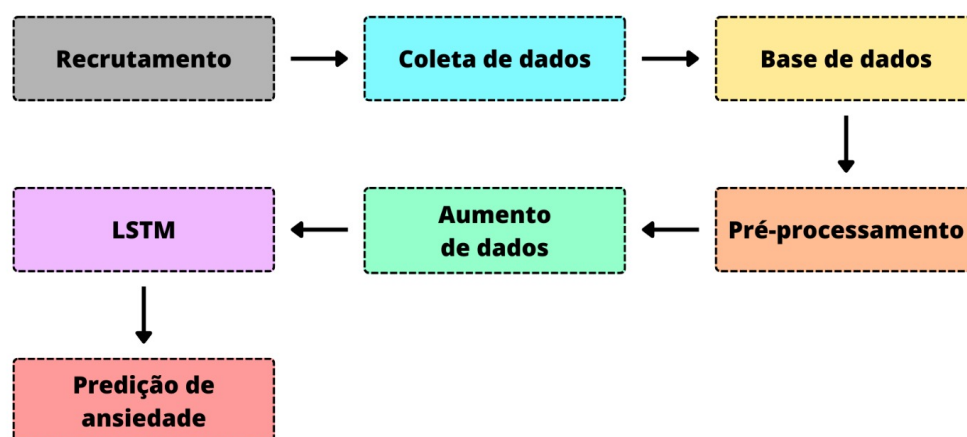


Figura 1. Workflow da metodologia do estudo, incluindo recrutamento dos voluntários, coleta e organização dos dados, pré-processamento com normalização, aplicação de técnicas de aumento de dados, construção do modelo LSTM e predição dos níveis de ansiedade.

3.1. Recrutamento de Voluntários

O recrutamento de voluntários para a coleta de dados desta pesquisa foi autorizado pelo Conselho de Ética em Pesquisa da Universidade Federal Fluminense (UFF) e aprovado sob o CAE 75923323.1.0000.5243. Os participantes foram majoritariamente da população universitária da UFF, incluindo estudantes de graduação e pós-graduação, bem como membros da comunidade acadêmica. A escolha desse público se deve à acessibilidade logística e à viabilidade de acompanhamento presencial durante as etapas de orientação e de devolução do *smartwatch*, o que contribui para um maior controle das variáveis durante a coleta em condições de vida livre. O estudo foi divulgado por meio de eventos presenciais em espaços acadêmicos e de publicações nas redes sociais. Os interessados entraram em contato com a equipe de pesquisa para agendamento da entrevista inicial, apresentando os objetivos do estudo e cumprindo os procedimentos éticos necessários.

Foram estabelecidos critérios de exclusão para garantir a integridade metodológica da coleta e a qualidade dos dados adquiridos. Foram excluídos indivíduos que não possuíam capacidade de se movimentar livremente devido a deficiência física ou a limitação motora significativa, visto que a análise proposta depende diretamente da variabilidade natural dos padrões de movimento. Também foram excluídos participantes em uso de medicamentos que pudessem alterar substancialmente a rotina diária ou os padrões de sono, como fármacos sedativos ou estimulantes, devido ao potencial impacto sobre as variáveis analisadas. Por fim, foram considerados inelegíveis os indivíduos que não pudessem utilizar o *smartwatch* por, no mínimo, 24 horas consecutivas, período necessário para a obtenção de um registro representativo da rotina diária, incluindo vigília e sono. Esses critérios asseguraram que os dados coletados refletissem padrões naturais de atividade e repouso, reduzindo possíveis fatores de confusão e aumentando a consistência das análises subsequentes.

3.2. Coleta de Dados

Para a coleta de dados fisiológicos, utilizou-se um dispositivo de *smartwatch* (*Samsung Galaxy Watch 7*) equipado com sensores inerciais de movimento. O principal sensor utilizado foi o acelerômetro para detecção de aceleração linear e vibração. No entanto, o dispositivo não possui um sistema de coleta contínua dos parâmetros de interesse do estudo. Assim, desenvolvemos um aplicativo próprio, responsável por acessar os sensores, realizar as coletas periódicas e armazenar os dados.

Os voluntários da pesquisa preencheram o Termo de Consentimento Livre e Esclarecido (TCLE) e um questionário com informações básicas para avaliação dos critérios de inclusão e exclusão. De acordo com os critérios de inclusão, o voluntário preencheu a escala psicométrica denominada Inventário de Ansiedade Traço-Estado (IDATE), o foco deste estudo. O IDATE é um instrumento de autorrelato, desenvolvido por [Spielberger and Gorsuch 1983], utilizado na avaliação psicológica para medir aspectos da ansiedade. A escala contém 20 questões que devem ser respondidas com uma escala de 4 pontos: (1) Quase nunca; (2) Às vezes; (3) Frequentemente; e (4) Quase sempre. A pontuação total da escala varia de 20 a 80 pontos, indicando diferentes níveis de ansiedade com base na média dos resultados dos participantes: baixo nível de ansiedade (abaixo da média), moderado (próximo da média) e alto (acima da média, próximo de 80

pontos). Para preservar a privacidade dos voluntários, os formulários são identificados por um identificador numérico do participante (ID), em conformidade com a Lei Geral de Proteção de Dados Pessoais (LGPD), Lei nº 13.709/2018.

Após o preenchimento das escalas, os voluntários tiveram o relógio colocado no pulso dominante, seguido de instruções sobre o uso correto do relógio. Foi solicitado que o voluntário utilizasse o relógio por um período mínimo de 24 horas, sem removê-lo para tomar banho ou dormir. Foi orientado que o voluntário seguisse sua rotina habitual, incluindo atividades físicas, tarefas domésticas e sono. Ao encerrar o prazo de coleta estipulado, os participantes retornaram à universidade para devolver o *smartwatch*. Os dados foram armazenados em arquivos de texto no dispositivo durante a coleta e transferidos de forma *offline* para um computador na devolução. Em breve, os dados serão compilados em um banco de dados a ser disponibilizado à comunidade científica, com acesso controlado.

3.3. Caracterização da Amostra

A amostra foi composta por 41 voluntários, com idades entre 17 e 60 anos (média de 26 anos), incluindo 18 mulheres e 23 homens. Os níveis de ansiedade, avaliados por escala psicométrica no momento da coleta, apresentaram média de 53 pontos (Desvio Padrão = 5,11), indicando distribuição relativamente homogênea com variabilidade suficiente para análise por regressão. Nenhum participante foi classificado na faixa de ausência de ansiedade, sugerindo predominância de níveis ao menos leves do transtorno na amostra.

3.4. Pré-processamento

Os sinais do acelerômetro do *smartwatch* foram organizados em séries temporais compostas por timestamp e três componentes de aceleração (eixos X, Y e Z), conforme ilustrado no gráfico A da Figura 2. O pré-processamento incluiu leitura e organização dos arquivos, filtragem dos sinais e separação dos participantes em conjuntos de treino e validação.

Para dados provenientes de versões anteriores do dispositivo, foi aplicada filtragem adicional em cada eixo utilizando filtro de mediana seguido de média móvel, com o objetivo de reduzir ruídos e suavizar o sinal (gráfico B da Figura 2). Em seguida, os valores foram limitados ao intervalo $[-14, 14]$ e normalizados para padronizar a escala das variáveis.

A separação entre conjuntos foi realizada em nível de participante, de modo que 32 indivíduos foram usados exclusivamente para treino e 9, exclusivamente para validação, evitando que janelas de um mesmo sujeito aparecessem em mais de um conjunto. Essa estratégia garante que a avaliação do modelo ocorra sempre com participantes não vistos durante o treinamento, o que aproxima o cenário de uma aplicação real.

3.5. Aumento de Dados

Devido à pequena quantidade de amostras no conjunto de dados, foi adotada uma estratégia de aumento de dados baseada em *downsampling* estruturado, com o objetivo de ampliar a capacidade de generalização do modelo sem gerar dados sintéticos. Diferentemente de técnicas que aplicam transformações artificiais ao sinal, essa abordagem utiliza apenas reamostragens do próprio sinal original, preservando suas características estatísticas e temporais.

Gráfico A




Gráfico B




Figura 2. Dados brutos do acelerômetro nos eixos X, Y e Z. O eixo horizontal representa o tempo e o vertical a aceleração (em g). O gráfico A se refere aos dados brutos, sem nenhum tipo de pré-processamento. O gráfico B se refere ao mesmo recorte temporal após aplicar os filtros de mediana, média móvel e limitação de amplitude.




Figura 3. Imagem ilustrativa do aumento de dados utilizados de um mesmo participante. O dado original se refere aos dados de acelerômetro antes do processo de downsampling estruturado. O downsampling 1 e 2, por sua vez, referem-se às diferentes subamostragens extraídas do mesmo sinal original por meio de uma seleção de pontos ao longo da série temporal, que serão utilizadas como entrada no modelo

O processo consistiu na extração de múltiplas subamostras a partir da mesma série temporal de acelerômetro. Para cada série, foram selecionados pontos equidistantes ao longo do tempo, formando diferentes versões reamostradas do sinal por meio de *downsampling*. Cada uma dessas subamostras corresponde a um segmento temporal independente, derivado da série contínua de dados coletados.

Dessa forma, cada subamostra foi considerada uma instância individual no conjunto de treinamento. Consequentemente, as entradas do modelo deixaram de representar apenas um participante completo, passando a incluir múltiplos recortes temporais de sua rotina diária. Esse procedimento aumentou o número efetivo de amostras disponíveis para o treinamento do modelo. A Figura 3 ilustra o processo de aumento de dados adotado.

Para avaliar o impacto da estratégia de reamostragem na estabilidade e no desempenho preditivo do modelo, o processo de *downsampling* foi repetido múltiplas vezes de forma independente. Especificamente, foram geradas três configurações distintas, nas quais o procedimento foi executado 3 vezes distintas de forma que cada participante tivesse seus dados aumentados 20, 50 e 100 vezes. Dessa forma, a taxa de amostragem que originalmente era de 0,1 Hz passa a ser 0,005 Hz, 0,002 Hz e 0,001 Hz, respectivamente.

Ao realizar o aumento de dados, houve cuidado para que todas as amostras geradas a partir do mesmo dado de um mesmo participante permanecessem em apenas um conjunto (treino ou validação), para evitar o vazamento de dados. A análise comparativa entre as diferentes quantidades de reamostragem permitirá investigar o efeito do aumento progressivo do número de amostras sobre as métricas de desempenho, a estabilidade do erro de regressão e a capacidade de generalização do modelo LSTM. Os impactos específicos de cada configuração serão discutidos na seção de resultados, com foco na relação entre o número de reamostragens e a variabilidade preditiva.

3.6. Modelo LSTM

Os dados pré-processados foram utilizados como entrada do modelo *Long Short-Term Memory* (LSTM) proposto para a regressão do escore de ansiedade. O modelo utiliza duas camadas LSTM com ativação *tanh*, seguidas de uma camada de *dropout* e de *batch normalization*, e de uma camada densa final com ativação linear para produzir a predição contínua do escore de ansiedade. O modelo foi treinado com o otimizador *Adam*, utilizando o Erro Quadrático Médio (MSE) como função de perda e o Erro Absoluto Médio (MAE) como métrica de avaliação. Especificamente, a primeira camada LSTM possui 64 unidades e a segunda 32 unidades, com a taxa de *dropout* fixada em 0,4. O processo de treinamento foi configurado para executar por um máximo de 100 épocas, utilizando lotes (*batches*) de tamanho 16. Para avaliação dos resultados, foram utilizados o MAE, o MSE e o coeficiente de correlação de *Pearson* entre as previsões do modelo e os valores de referência.

4. Resultados

A Tabela 1 apresenta um comparativo entre os treinamentos dos modelos quando usados diferentes valores de aumento de dados. A análise comparativa das diferentes quantidades de aumento de dados revela comportamentos distintos. Na configuração com 50 repetições, observamos o melhor equilíbrio entre desempenho no treinamento e capacidade de generalização, com os menores valores de MAE e os coeficientes de correlação

mais consistentes no conjunto de validação. O gráfico de dispersão, quando utilizado com um aumento de 50 vezes nos dados, é apresentado na Figura 4. Embora a configuração com 100 repetições tenha se destacado no conjunto de treinamento, apresentando melhora no MAE e na correlação, tal desempenho não se manteve na validação, o que sugere limitação na capacidade de generalização. A configuração com 20 repetições apresentou resultados satisfatórios tanto no treino quanto na validação, porém, manteve desempenho inferior ao observado com 50 repetições, indicando que esse volume intermediário de amostragem foi mais adequado ao equilíbrio entre aprendizado e robustez do modelo.

Tabela 1. Impacto da quantidade de aumento de dados no desempenho do modelo nos conjuntos de treinamento e validação.

Quantidade	Treino		Validação	
	MAE	r	MAE	r
20	6.7883	0.747	5.7255	0.433
50	6.0435	0.711	5.3098	0.547
100	4.7204	0.881	6.4736	-1.410

Esse comportamento pode ser atribuído ao método de aumento de dados por *down-sampling*, visto que quanto maior o número de amostragens, menores serão as séries temporais derivadas da original, reduzindo a quantidade de informação temporal analisada pelo modelo LSTM. Considerando que arquiteturas recorrentes dependem da preservação de dependências temporais de curto e longo prazo, a diminuição excessiva do tamanho das sequências compromete a capacidade do modelo de capturar padrões dinâmicos relevantes, o que impacta negativamente sua generalização. Assim, embora o aumento de dados tenha potencial para aumentar a robustez do treinamento, sua aplicação em níveis muito elevados pode levar à perda de informações temporais essenciais.

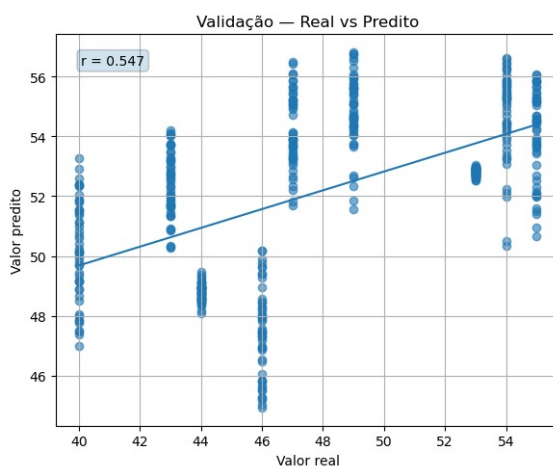


Figura 4. Gráfico de correlação entre o predito e o verdadeiro dos dados de validação quando a técnica de aumento de dados é aplicada 50 vezes. É possível notar que há vários valores reais iguais devido à técnica de aumento de dados estruturados.

Em geral, os resultados indicam que a configuração com 50 repetições de *down-sampling* apresentou o melhor equilíbrio entre a variabilidade amostral e a preservação da

estrutura temporal dos dados, refletindo um desempenho mais estável e consistente entre treino e validação. Isso evidencia a importância de calibrar cuidadosamente estratégias de aumento de dados em problemas envolvendo séries temporais, especialmente quando modelos recorrentes são empregados.

Os resultados obtidos indicam um cenário promissor quanto à capacidade de modelos preditivos baseados em aprendizado profundo para estimar níveis de ansiedade. Considerando particularmente a configuração com 50 aumentos, os achados evidenciam que a abordagem adotada foi capaz de aprender representações relevantes a partir de dados coletados em contexto de vida livre, ao longo de um dia completo, preservando a complexidade e a variabilidade inerentes a esse tipo de aquisição. As métricas de desempenho alcançadas demonstram que a rede neural foi capaz de capturar características significativas dos sinais analisados. Mesmo diante do elevado grau de complexidade do problema proposto, o modelo apresentou desempenho consistente, sugerindo boa capacidade de generalização no escopo do conjunto avaliado, reforçando o potencial da utilização de arquiteturas profundas para a modelagem de estados emocionais a partir de dados fisiológicos e comportamentais coletados em condições reais de uso.

5. Discussão

No presente trabalho, o modelo baseado em arquitetura LSTM foi avaliado com base em um conjunto de dados coletado nesta pesquisa, com o objetivo de analisar sua capacidade de prever níveis de ansiedade em contexto de vida livre. A utilização de dados adquiridos ao longo de um dia completo, fora de ambientes controlados, permitiu investigar o desempenho do modelo em um cenário mais próximo das condições reais de aplicação, caracterizado por elevada variabilidade e ruído.

O trabalho também demonstrou que variáveis relacionadas ao movimento apresentaram relação significativa com os níveis de ansiedade por meio de análise de regressão, indicando que padrões motores podem atuar como indicadores comportamentais relevantes para estados emocionais. Esses resultados vão de acordo com evidências da literatura, que apontam que indivíduos com transtornos de ansiedade apresentam alterações mensuráveis no sistema motor [Elkjær et al. 2022b]. Além disso, estudos que utilizaram sensores de movimento para mensurar inquietação em indivíduos com ansiedade demonstraram que níveis mais elevados de inquietação corporal estão associados a estados persistentes de ativação e vigilância característicos da ansiedade [Franklin et al. 2021b]. Em conjunto, esses achados sustentam a hipótese de que sinais de movimento capturados por sensores corporais ou dispositivos vestíveis podem contribuir para a identificação e monitoramento de sintomas associados à ansiedade.

Com isso, validamos como contribuição o potencial de modelos baseados em RNNs para a modelagem de estados emocionais a partir de dados de vida livre. A capacidade de aprender padrões estruturais ao longo do tempo, característica intrínseca às LSTMs, mostrou-se adequada para lidar com sequências temporais extensas e com variações diárias nos sinais analisados, indicando consistência no processo de aprendizado no escopo investigado.

Entretanto, algumas limitações devem ser consideradas na interpretação dos resultados. O estudo apresenta um número amostral reduzido, o que pode comprometer a robustez das métricas e limitar a generalização. Além disso, houve uma baixa distribuição

entre os níveis de ansiedade, não existindo nenhum indivíduo considerado sem ansiedade. Esse fator que pode influenciar o processo de treinamento e favorecer determinados padrões em detrimento de outros. Por fim, a amostra se concentra no ambiente universitário, o que restringe a diversidade do perfil dos participantes e pode limitar a generalização dos resultados para outras populações. Como trabalhos futuros, planejamos ampliar coleta de dados e conduzir experimentos de explicabilidade que busquem relacionar melhor o tipo de movimentação do indivíduo com os níveis de ansiedade, bem como investigar outras arquiteturas para modelagem de séries temporais, incluindo modelos baseados em *Transformers*, a fim de comparar desempenho e robustez em cenários de vida livre.

6. Conclusão

Neste estudo, investigamos a aplicação de redes neurais recorrentes do tipo LSTM para a predição de níveis de ansiedade a partir de dados de acelerômetro coletados por dispositivos vestíveis em contexto de vida livre. Nosso principal objetivo foi avaliar a capacidade do modelo em aprender padrões temporais de movimento associados às pontuações de ansiedade obtidas por meio de escala psicométrica. Os resultados reforçam o potencial da utilização de técnicas de aprendizado profundo aplicadas a dados provenientes de dispositivos vestíveis para o desenvolvimento de ferramentas de monitoramento contínuo e não invasivo da saúde mental.

7. Agradecimentos

Este trabalho foi financiado pela Fundação Carlos Chagas Filho de Amparo à Pesquisa do Estado do Rio de Janeiro (FAPERJ) E-26/210.759/2024 (295437).

Referências

- Alvaro, P. K., Roberts, R. M., and Harris, J. K. (2016). The bidirectional relationship between sleep and anxiety: Implications for treatment. *Sleep Medicine Reviews*, 28:1–12.
- Bursa, S. Ö., Durmaz İncel, Ö., and Işıklar Alptekin, G. (2023). Building lightweight deep learning models with tensorflow lite for human activity recognition on mobile devices. *Annals of Telecommunications*, 78(11):687–702.
- Duval, E. R., Javanbakht, A., and Liberzon, I. (2015). Neural circuits in anxiety and stress disorders: a focused review. *Therapeutics and clinical risk management*, pages 115–126.
- Elkjær, E., Mikkelsen, M. B., Michalak, J., Mennin, D. S., and O’Toole, M. S. (2022a). Motor alterations in depression and anxiety disorders: A systematic review and meta-analysis. *Journal of affective disorders*, 317:373–387.
- Elkjær, E., Mikkelsen, M. B., Michalak, J., Mennin, D. S., and O’Toole, M. S. (2022b). Motor alterations in depression and anxiety disorders: A systematic review and meta-analysis. *Journal of affective disorders*, 317:373–387.
- Fang, L., Zeng, W., Zheng, S., Du, S., Yang, H., Luo, X., Zeng, S., Huang, Z., Chen, W., and Zhang, B. (2025). a. *Depression and anxiety*, 2025(1):3082856.

- Franklin, A. R., Mathersul, D. C., Raine, A., and Ruscio, A. M. (2021a). Restlessness in generalized anxiety disorder: using actigraphy to measure physiological reactions to threat. *Behavior therapy*, 52(3):734–744.
- Franklin, A. R., Mathersul, D. C., Raine, A., and Ruscio, A. M. (2021b). Restlessness in generalized anxiety disorder: using actigraphy to measure physiological reactions to threat. *Behavior therapy*, 52(3):734–744.
- Graves, A. (2012). Long short-term memory. *Supervised sequence labelling with recurrent neural networks*, pages 37–45.
- Hamitouche, D., Zamorano, T., Barkat, Y., Parekh, D., Palaniyappan, L., Jalali, S., and Benrimoh, D. (2025). Sleep and activity patterns as transdiagnostic behavioral biomarkers in psychiatry: Longitudinal observational study from the deep-dd study. *JMIR Form Res*, 9.
- LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *Nature*, 521(7553):436–444.
- Liang, Q., Xu, Z., Chen, S., and Qiu, Y. (2026). Differential neural dynamics in psychomotor retardation and agitation of depression. *Human Brain Mapping*, 47(2):e70453.
- Luca, M., Luca, A., Barlati, S., Buson, L., Menesello, V., Magistrali, A., Silva, R., Perusi, G., Nibbio, G., Bignotti, S., Tura, G., Ferri, R., Gennarelli, M., Vita, A., Souery, D., Kasper, S., Zohar, J., Montgomery, S., Ferentinos, P., and Spina, E. (2026). Agitation and anxiety features define a more severe phenotype in unipolar depression. *Psychiatry Research*, 357:116928.
- Pastre, M. and Lopez-Castroman, J. (2022). Actigraphy monitoring in anxiety disorders: A mini-review of the literature. *Frontiers in psychiatry*, 13:984878.
- Pompili, M., Ducci, G., Galluzzo, A., Rosso, G., Palumbo, C., and De Berardis, D. (2021). The management of psychomotor agitation associated with schizophrenia or bipolar disorder: a brief review. *International journal of environmental research and public health*, 18(8):4368.
- Spielberger, C. and Gorsuch, R. (1983). *Manual for the State-trait Anxiety Inventory (form Y) ("self-evaluation Questionnaire")*. Consulting Psychologists Press.
- Straus, L. D., An, X., Ji, Y., McLean, S. A., Neylan, T. C., Group, A. S., Cakmak, A. S., Richards, A., Clifford, G. D., Liu, M., et al. (2023). Utility of wrist-wearable data for assessing pain, sleep, and anxiety outcomes after traumatic stress exposure. *JAMA psychiatry*, 80(3):220–229.
- Vincent, C. J., Aguilar-Alvarez, R., Vanderhoof, S. O., Mott, D. D., and Jasnow, A. M. (2025). An amygdala-cortical circuit for encoding generalized fear memories. *Molecular Psychiatry*, pages 1–14.
- Wang, J., Chen, Y., Hao, S., Peng, X., and Hu, L. (2019). Deep learning for sensor-based human activity recognition: A survey. *Sensors*, 17:416.