

Seminário - Construção de Modelo de Classificação binária de Estresse

Cícero C. Quarto (Pós-doutorando)
Luiz G. Penha (Mestrando)

UFMA/PPGCC-LSDi

13 de junho de 2025



Construção de Modelo de Classificação binária de Estresse

Estrutura da Apresentação

- 1 **Introdução**
Contexto, objetivos e justificativa.
- 2 **Fundamentação Teórica**
Conceitos de estresse e classificação binária.
- 3 **Metodologia**
Coleta de dados, modelos e ferramentas.
- 4 **Resultados e Discussão**
Desempenho dos modelos e limitações.
- 5 **Conclusão**
Contribuições e trabalhos futuros.

Duração: 30-40 minutos.



1. Introdução

Contexto

O estresse, quando crônico, representa um sério risco à saúde mental e física, afetando cerca de 60% dos trabalhadores[1] . As abordagens tradicionais de detecção, baseadas em auto-relatos, são subjetivas e pouco eficazes para monitoramento contínuo. Com o avanço de dispositivos móveis e vestíveis, tornou-se possível coletar dados fisiológicos de forma não intrusiva. Modelos de *machine learning* permitem a classificação automática do estresse, favorecendo intervenções precoces e a promoção da saúde.



Objetivos e motivação

- Elaborar Modelo de Aprendizagem de Máquina para a classificação binária de estresse (estresse/não estresse), utilizando dados de sensores ECG contidos no dataset WESAD.
- Validar o desempenho do modelo de Aprendizagem de Máquina desenvolvido.



1.Introdução

Justificativa

O desenvolvimento de um modelo de machine learning para classificação binária de estresse, com base em sinais ECG do dataset WESAD, contribui para atender a necessidade de métodos precisos e automatizados de detecção emocional. A utilização desse conjunto de dados padronizado garante reprodutibilidade e validade científica. Além disso, a validação do modelo permitirá avaliar sua aplicabilidade em contextos reais, favorecendo avanços no monitoramento fisiológico e na promoção da saúde mental.



2. Fundamentação Teórica

Conceitos

Estresse - Definição Clássica 1

*“Resposta inespecífica do corpo a qualquer demanda sobre ele”
(Selye, 1976) [2].*

Estresse - Definição Clássica 2

*“Uma relação particular entre a pessoa e o ambiente que é avaliada pela pessoa como relevante para seu bem-estar e na qual os recursos disponíveis para enfrentamento (coping) são excedidos”
(Lazarus, 1984) [3]*

2. Fundamentação Teórica (cont.)

Princípios do LDA

Como Funciona?

- Calcula **autovetores** (direções de separação) e **autovalores** (importância das direções).
- Maximiza a distância entre médias das classes e minimiza a variância intraclasse.

Suposições do Modelo

- Dados com distribuição **Gaussiana**.
- **Matriz de covariância igual** para todas as classes.
- Dados **linearmente separáveis**.

3. Metodologia

Metodologia

A Metodologia de construção de um modelo de Classificador binário - classe positiva "Estresse" e negativa "Não estresse- para a avaliação de eficácia na estimativa do estresse, baseou-se no artigo introdutório do dataset WESAD [4], especialmente nas características mencionadas para a elaboração do modelo de detecção de estresse, como também nas boas práticas para construção desse tipo de modelo relacionadas as etapas de pré processamento dos dados, extração de features, validação, treinamento , testes e avaliação.



3. Metodologia - Dataset WESAD

WESAD (Wearable Stress and Affect Detection) é um conjunto de dados (dataset) multimodal de acesso público, projetado para pesquisa em detecção de estresse e estados emocionais por meio de dispositivos vestíveis que foi desenvolvido pela realização de experimentos em ambiente controlado de laboratório no qual foi possível realizar registro de sinais fisiológicos e de movimento por meio de sensores posicionados no pulso e no peito dos participantes além de dados complementares colhidos pela aplicação de formulários de autorelato

- **Objetivo Principal:** Preencher a lacuna na comunidade de computação afetiva para detecção de estresse e afeto usando dispositivos vestíveis.
- **Dados Multimodais:** Inclui dados fisiológicos e de movimento.
- **Fontes de Dados:** Registrados de dispositivos vestíveis no pulso e no tórax.
- **Participantes:** Contém dados de 15 sujeitos durante um estudo em laboratório.



3. Metodologia - Dataset WESAD

Modalidades de Sensores Incluídas

O dataset WESAD abrange uma variedade de modalidades de sensores, fornecendo uma visão abrangente dos estados fisiológicos e de movimento:

- **Pulso Volumétrico do Sangue (BVP)**
- **Eletrocardiograma (ECG)**
- **Atividade Eletrodérmica (EDA)**
- **Eletromiograma (EMG)**
- **Respiração**
- **Temperatura Corporal**
- **Aceleração Triaxial** (do dispositivo de pulso e do tórax)



3. Metodologia - Dataset WESAD

Como o Estudo WESAD Foi Conduzido

- **Participantes:** 15 sujeitos saudáveis (12 homens, 3 mulheres).
- **Protocolo em Laboratório:**
 - **Linha de Base (Baseline):** 20 minutos de relaxamento, lendo revistas neutras.
 - **Estresse:** 10 minutos de "Social Stress Test" (TSST) - tarefa de apresentação de discurso e aritmética mental sob pressão.
 - **Divertimento (Amusement):** 10 minutos assistindo a vídeos de comédia para induzir um estado de relaxamento e riso.
 - **Recuperação:** 10 minutos de relaxamento após as tarefas.
 - **Auto-Relatos:** Além dos dados de sensores, foram obtidos auto-relatos dos sujeitos utilizando as escalas PANAS (Positive and Negative Affect Schedule), que complementam a compreensão dos estados afetivos vivenciados.



3. Metodologia - Dataset WESAD

Como o Estudo WESAD Foi Conduzido

- **Dispositivos Vestíveis:**
 - **Empatica E4 (Pulso):** BVP, EDA, Temperatura, Acelerômetro.
 - **RespiBAN (Tórax):** ECG, EMG, Respiração, Temperatura, Acelerômetro.
- **Variável Alvo:** A classificação binária de estresse considera os estados de "Estresse" (classe positiva) vs. "Não-Estresse" (que combina "Linha de Base", "Divertimento" e "Recuperação" como classe negativa).
- **Features Extraídas:**
 - Variabilidade da Frequência Cardíaca (HRV):
 - RMSSD, pNN50 (domínio temporal)
 - Potência LF/HF (domínio frequencial)
 - Média e desvio padrão dos intervalos RR



3. Metodologia - Dataset WESAD

Desempenho do Classificador LDA (Conforme o Artigo WESAD)

- Os autores do WESAD experimentaram diversos classificadores, incluindo o LDA.
- **Estratégia de Validação:** Usaram a Validação Cruzada Leave-One-Subject-Out (LOSO), que é mais rigorosa e indica melhor generalização.
- **Resultados com LDA (LDA para Múltiplas Modalidades):**
 - O LDA apresentou desempenho competitivo, especialmente quando combinado com **features multimodais**.
 - O artigo relata que o LDA, com um conjunto de features cuidadosamente selecionado e engenharia de features, é capaz de atingir boa performance.
 - **Acurácia Média Reportada (LDA):** O artigo menciona que o LDA, em cenários multimodais e com seleção de features, pode atingir acurácias na faixa de $\approx$ **85%**.



3. Metodologia: Construção do Classificador LDA

Fluxo de Trabalho para Classificação Binária de Estresse com LDA

- ❶ **Definição do Problema:** Classificação binária (Estresse vs. Não-Estresse).
- ❷ **Coleta de Dados** **Análise exploratória:** Utilização do Dataset WESAD (multimodal, vestível).
- ❸ **Pré-processamento e Engenharia de Features:**
 - **Remoção de Artefatos:** Lidando com ruídos nos sinais fisiológicos.
 - **Filtragem:** Aplicação de filtros específicos para cada modalidade (e.g., passa-banda para ECG/BVP, passa-baixa para EDA).
 - **Segmentação:** Divisão dos dados em janelas de tempo fixas (janelas de 60 segundos com segmentos de 0,25 segundos).
 - **Extração de Features:** Cálculo de características estatísticas (média, desvio padrão, mínimo, máximo), no domínio da frequência, tempo e da entropia, para cada janela e modalidade.



3. Metodologia: Construção do Classificador LDA

Fluxo de Trabalho para Classificação Binária de Estresse com LDA

4 Seleção/Redução de Features:

- Exclusão de segmentos inválidos do conjuntos de dados
- seleção de segmentos baseado na frequência das tags.
- cria dados sintéticos para favorecer o treinamento do modelo

5 Divisão dos Dados: Estratégia de validação cruzada para treino e teste.

- **Validação Leave-One-Subject-Out (LOSO):** Crucial para generalização. Um sujeito é usado para teste, e os restantes para treino. Repetido para todos os sujeitos.

6 Treinamento do Classificador LDA:

- O LDA busca projetar os dados em um espaço de menor dimensão, maximizando a separação entre as classes e minimizando a variância intra-classe.
- Ideal para problemas de classificação binária quando as classes são linearmente separáveis ou quase isso.



3. Metodologia: Construção do Classificador LDA

Fluxo de Trabalho para Classificação Binária de Estresse com LDA

- 8 **Avaliação do Modelo:** Uso de métricas para classificação binária (F!-Score, Accuracy)



3. Metodologia - Ferramentas Utilizadas

Ferramentas

- 1 **Linguagem:** Python — linguagem de programação versátil, fácil de aprender e amplamente usada em ciência de dados.
- 2 **Scikit-learn:** biblioteca para criar modelos de machine learning, como classificação, regressão e agrupamento.
- 3 **Numpy:** biblioteca para cálculos numéricos eficientes com vetores, matrizes e álgebra linear.
- 4 **Pandas:** biblioteca para manipular e analisar dados tabulares, como planilhas e tabelas.
- 5 **Matplotlib:** biblioteca para criar gráficos e visualizações, como linhas, barras e histogramas.



3. Metodologia I. Leitura e Pré-processamento Inicial

Características

- ❶ **Entrada:** Dados brutos do ECG (arquivos .pkl) por sujeito
- ❷ **Processamento:**
 - Conversão para mV: $\left(\frac{raw}{2^{16}} - 0.5\right) \times 3$
 - Indexação temporal (fs=700Hz)
- ❸ **Saída:** Série temporal do ECG + rótulos originais (0-7)



3. Metodologia II. Pré-processamento do Sinal ECG

Etapas

- 1 **Filtro Passa-Alta** (0.5Hz): Remove baseline wander
- 2 **Filtro Notch** (50Hz): Elimina ruído de linha
- 3 **Filtro Passa-Banda** (0.5-40Hz): Mantém frequências cardíacas
- 4 **Normalização**: Z-score ($\frac{ECG - \mu}{\sigma}$)



3. Metodologia III. Segmentação e Rotulagem

Parâmetros

- Janela: 60s com passo de 0.25s ($f_s=700\text{Hz}$)
- **Rótulos:**
 - 0 (baseline) e 2 (amusement) $\rightarrow$ 0 (não-estresse)
 - 1 (stress) $\rightarrow$ 1 (estresse)
 - Outros (3-7) descartados
- **Label Purity:** Proporção da label dominante na janela



3. Metodologia IV. Extração de Features (HRV)

Características Calculadas

Domínio do Tempo:

- HR_Mean, HR_Std
- SDNN, RMSSD
- NN50

Domínio da Frequência:

- LF (0.04-0.15Hz)
- HF (0.15-0.4Hz)
- LF/HF Ratio



3. Metodologia V. Balanceamento de Dados

Abordagens Comparadas

- **SMOTE:**
 - $k_neighbors=3$
 - Aplicado apenas no treino
- **Alternativas:**
 - Undersampling (perda de dados)
 - Class Weight (ajuste de priors)



3. Metodologia VI. Modelagem e Validação

Pipeline

- ① **Modelo:** Linear Discriminant Analysis (LDA)
- ② **Validação:** Leave-One-Subject-Out (LOSO)
- ③ **Métricas:**
 - Acurácia
 - F1-Score (classe 1)
 - Matriz de Confusão



4.Resultado e Discussão

- **Discussão:** LDA é um modelo linear e computacionalmente eficiente. Sua performance é forte quando a separabilidade das classes é linear, obtendo um resultado satisfatório



6. Modelagem e Validação

Pipeline

- ① **Modelo:** Linear Discriminant Analysis (LDA)
- ② **Validação:** Leave-One-Subject-Out (LOSO)
- ③ **Métricas:**
 - Acurácia
 - F1-Score (classe 1)
 - Matriz de Confusão



Desempenho do Modelo

- **Acurácia média:** 0.8355 ± 0.0327
- **F1-score médio:** 0.8440 ± 0.0310
- **Precisão média:** 0.6217 ± 0.0382
- **Recall médio:** 0.9779 ± 0.0536

Observação

Os resultados apresentam média e desvio padrão calculados sobre todas as folds da validação LOSO.



Interpretação das Métricas

- Recall (0.9779) indica capacidade de detectar a classe positiva
- Precisão (0.6217)
- F1-score (0.8440) relação entre precisão e recall
- Acurácia geral de 83.55% desempenho global



4.Resultado e Discussão




Figura: Matriz de Confusão agregada do modelo de classificação



5. Conclusão - Limitações e Oportunidades Futuras

Limitações Atuais

- Dependência excessiva de dados fisiológicos (ECG, EDA, EMG)
- Visão unidimensional do estresse (apenas dimensões fisiológicas)
- Falta de integração com fatores ambientais e contextuais
- Dificuldade em capturar relações complexas entre múltiplas dimensões



5. Conclusão - Limitações e Oportunidades Futuras

Novas Dimensões a Explorar

- **Ambiente:**

- Qualidade do ar
- Nível de ruído
- Iluminação
- Temperatura

- **Contexto:**

- Carga de trabalho
- Relações sociais
- Calendário/produtividade

- **Comportamento:**

- Padrões de digitação
- Movimentos oculares
- Postura corporal

- **Psicológico:**

- Diários digitais
- Interações em redes sociais
- Respostas a questionários



5. Conclusão - Limitações e Oportunidades Futuras

Questões em Aberto

- ① Como ponderar automaticamente a importância relativa de cada modalidade?
- ② Quais técnicas de fusão de dados são mais adequadas para integrar:
 - Dados contínuos (sensores)
 - Dados discretos (questionários)
 - Dados contextuais (ambiente)
- ③ Qual o impacto diferentes dimensões na classificação do estresse?
- ④ Como validar modelos em cenários complexos e dinâmicos?



5. Conclusão - Limitações e Oportunidades Futuras

1. Digital Twins

- Classificação em tempo real do Estresse com dados novos presentes no DT
- Estimar a probabilidade de estresse para configurações diferentes de interação indivíduo versus ambiente em meio virtual.
- Identificar quais dimensões mais contribuem para o estresse. (incluindo novas dimensões)

2. Modelos de Inteligência Computacional

- Avaliar Modelos diferentes para o Reconhecimento de Estresse
- Considerar a combinação de modelos computacionais para o Reconhecimento de Estresse.

Referências



GLOBAL RESEARCH INSTITUTE. **Work Wellbeing Report Global**. [S. l.]: [s. n.], 2024. Disponível em: <https://d341ezm4iqaae0.cloudfront.net/assets/2024/09/13002905/Work-Wellbeing-Report-Global-1.pdf>. Acesso em: 15 abr. 2025.



SELYE, Hans. Stress in Health and Disease. Boston: Butterworths, 1976.



LAZARUS, Richard S.; FOLKMAN, Susan. Stress, Appraisal, and Coping. New York: Springer Publishing Company, 1984.



SCHMIDT, Phillip; REISS, Attila; DURSUN, Zehra; VAN LAERHOVEN, Kristof. Introducing WESAD, a multimodal dataset for wearable stress and affect detection. In: *Proceedings of the 20th ACM International Conference on Multimodal Interaction*. New York: ACM, 2018. p. 400–408.



Cícero Costa Quarto - **Lattes**

- E-mail: **cicero@engcomp.uema.br**

Luiz Gonzaga de Souza Penha - **Lattes**

- E-mail: **luiz.penha@lsdi.ufma.br**

