

IA na Saúde Mental: Previsão da Taxa de Burnout em Colaboradores Corporativos por meio de Aprendizado de Máquina

Lenilson D. Farache Junior¹, Jéssica M. C. Oliveira², Antonio P. Fontenele¹
Luciana R. Costa¹, Rely D. F. S. Junior¹, Viviane S. Amorim¹, Carlos A. M. Cruz²

¹Fundação Paulo Feitosa – Núcleo de Capacitação em Inteligência Artificial (NCIA)
Caixa Postal 69.075 – 351 – Manaus, AM – Brasil

²Universidade Federal do Amazonas (UFAM) – Manaus, AM – Brazil

{lenilson.220490, antonio.fontenele, rely.220544}@fpf.br

{luciana.252313, viviane.252333}@fpf.br

{mariella.oliveira, carlosamcruz}@ufam.edu.br

Abstract. *Burnout is recognized by the World Health Organization (WHO) as an occupational risk that directly impacts mental health and productivity. This study evaluated twelve machine learning models to predict burnout rates using the Burnout Among Corporate Employees dataset from Harvard Dataverse. Preprocessing techniques and exploratory analyses were applied, and six individual models and six ensemble models were trained. The performance comparison revealed relevant patterns and highlighted the potential of ensemble learning for predictive diagnosis and decision support in human resource management.*

Resumo. *O burnout é reconhecido pela Organização Mundial da Saúde (OMS) como um risco ocupacional que impacta diretamente a saúde mental e a produtividade. Este estudo avaliou doze modelos de aprendizado de máquina para prever a taxa de burnout utilizando o dataset Burnout Among Corporate Employees (Harvard Dataverse). Foram aplicadas técnicas de pré-processamento, análise exploratória e treinados seis modelos individuais e seis modelos ensembles. A comparação de desempenho revelou padrões relevantes e destacou o potencial das técnicas de ensemble learning para diagnóstico preditivo e apoio à tomada de decisão em gestão de recursos humanos.*

1. Introdução

Nas últimas décadas, o esgotamento profissional consolidou-se como um dos principais riscos psicossociais relacionados ao trabalho, sendo reconhecido pela CID-11 como um fenômeno ocupacional [Organização Mundial da Saúde 2020]. Caracterizado por exaustão emocional, despersonalização e baixa realização profissional, o burnout tem sido associado à interação entre fatores organizacionais como sobrecarga de trabalho, prazos rígidos e falta de reconhecimento e fatores pessoais, como padrões de sono e equilíbrio entre vida pessoal e profissional [Maslach and Leiter 2016, Wilton et al. 2024, Saranya et al. 2025]. Apesar da relevância do tema, muitas organizações ainda carecem

de ferramentas eficazes para identificação e prevenção precoce do burnout. Nesse cenário, o avanço das técnicas de Inteligência Artificial (IA) e Aprendizado de Máquina (ML) possibilita o desenvolvimento de modelos preditivos capazes de identificar padrões de risco a partir de dados organizacionais e pessoais [Géron 2019]. Estudos recentes destacam a eficácia de métodos baseados em *ensemble learning* na modelagem desse fenômeno [Hladiholov and Mokin 2023, Reddy and Santhi 2024]. A utilização de bases públicas, como *Burnout Among Corporate Employees* [Harvard Dataverse 2025], mostra-se promissora para a construção de modelos que auxiliem na detecção de padrões associados ao burnout e na definição de estratégias preventivas. Assim, este trabalho propõe investigar e comparar técnicas de aprendizado de máquina individuais e *ensemble* aplicadas à predição de burnout ocupacional, visando aprimorar ferramentas preditivas voltadas à saúde organizacional. Este artigo está estruturado da seguinte forma: a seção 2 apresenta os materiais e métodos empregados, a seção 3 descreve e discute os resultados obtidos e, por fim, a seção 4 aborda as considerações finais.

2. Materiais e Métodos

A Figura 1 apresenta o pipeline proposto neste estudo, que abrangem desde a preparação dos dados até a avaliação final do modelo. Essa arquitetura reflete boas práticas consolidadas na literatura, permitindo organizar as etapas de forma modular e reproduzível.




Figura 1. Pipeline do sistema proposto para previsão de burnout

Fonte: Elaboração própria.

Utilizou-se o banco de dados *Burnout Among Corporate Employees*, composta por 22.750 instâncias e 17 atributos relacionados a fatores organizacionais e pessoais conforme pode ser visto na Tabela 1 as cinco primeiras instâncias (linhas) do dataset e os quatro primeiros atributos (colunas).

Tabela 1. Instâncias e Atributos do dataset de Harvard

Employee ID	Gender	Company Type	Burn Rate
ffe32003000360033003200	Female	Service	0.16
ffe3700360033003500	Male	Service	0.36
ffe31003300320037003900	Female	Product	0.49
ffe32003400380032003900	Male	Service	0.20
ffe31003900340031003600	Female	Service	0.52

Para o pré-processamento aplicou transformações numéricas e categóricas com *ColumnTransformer*, usando codificação *one-hot* e padronização. Foram treinados seis

modelos individuais (*Linear, Ridge, Lasso, SVR, Decision Tree e Random Forest individual*) e seis modelos *ensemble* (*Voting, Bagging, Random Forest, AdaBoost, Gradient Boosting e Stacking*). A validação ocorreu via *GridSearch* e o desempenho foi avaliado no conjunto de teste por meio das métricas R^2 , RMSE e MAE.

2.1. Setup

A Tabela 2 apresenta a configuração geral do ambiente de desenvolvimento. Os experimentos foram conduzidos em ambiente local, utilizando a linguagem Python (versão 3.13.5) e um conjunto de bibliotecas amplamente empregadas em ciência de dados e aprendizado de máquina.

Tabela 2. Configuração do ambiente de desenvolvimento

Componente	Especificação
Versão do Python	3.13.5
Bibliotecas principais	NumPy, Pandas, Matplotlib, Seaborn, Scikit-learn
Método de Validação	GridSearch + CV
IDE utilizada	VS Code
Recursos de hardware	Processador Intel Core i7, 16 GB RAM

3. Resultados e Discussão

A análise dos resultados na Tabela 3 mostra que o *Gradient Boosting Regressor* apresentou o melhor desempenho, com $R^2 = 0.93$, quanto mais próximo de 1 o coeficiente de determinação (R^2) melhor a variância do modelo explicada no teste. Para as métricas RMSE e MAE, valores menores indicam menores erros de predição do modelo.

Tabela 3. Desempenho dos modelos — Métricas de Teste

Modelo	RMSE	MAE	R^2	Tempo(s)
GradientBoostingRegressor	0.052336	0.040427	0.930144	6.791502
StackingRegressor	0.053431	0.041119	0.927191	34.035932
BaggingRegressor	0.053603	0.041194	0.926720	13.492470
RF_ind	0.053613	0.041205	0.926694	4.047849
VotingRegressor	0.055859	0.043237	0.920422	8.128691
RandomForest	0.061180	0.047529	0.904540	1.644852
SVR	0.063157	0.050494	0.898271	5.814708
Ridge	0.065758	0.049062	0.889718	0.033419
Linear	0.065759	0.049062	0.889717	0.042692
Lasso	0.065813	0.048989	0.889536	0.259148
Decision Tree	0.074311	0.054785	0.859167	0.126442
AdaBoostRegressor	0.117620	0.097360	0.647170	0.425900

Conforme a Figura 2, os resultados do gráfico de colunas mostram uma comparação entre os modelos individuais versus os modelos *ensemble* por meio da métrica R^2 . O gráfico de pizza mostra a participação relativa de cada modelo *ensemble* no conjunto de teste, refletindo que o *Gradient Boosting* teve o melhor desempenho na métrica $R^2 = 0.93$ com participação relativa de 17,7%. Pesquisas recentes destacam a robustez de métodos baseados em combinação de modelos para problemas preditivos para identificar padrões associados ao esgotamento ocupacional.

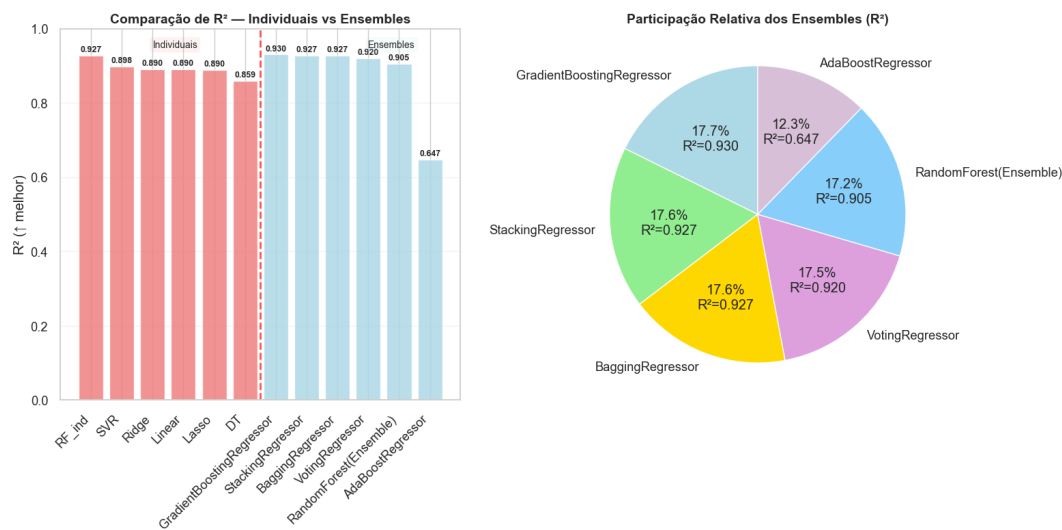


Figura 2. Comparação de R² — Modelos Individuais vs Ensembles

Fonte: Elaboração própria.

4. Considerações Finais

Como trabalhos futuros, pretende-se explorar arquiteturas mais avançadas, como redes neurais profundas e modelos híbridos, além de integrar dados longitudinais e de sensores *wearables*, ampliando a capacidade preditiva e favorecendo aplicações práticas em programas de monitoramento de saúde ocupacional.

Referências

- Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. O'Reilly Media, Sebastopol, CA, 2 edition.
- Havard Dataverse (2025). Burnout among corporate employees. <https://doi.org/10.7910/DVN/VG6KQD>. Publicado em: 14 abr. 2025. Acesso em: 10 set. 2025.
- Hladiholov, S. S. and Mokin, O. B. (2023). Comparative analysis of machine learning models for predicting employee burnout. *Visnyk VNTU*, (5):25–31.
- Maslach, C. and Leiter, M. P. (2016). Understanding the burnout experience: recent research and its implications for psychiatry. *World Psychiatry*, 15(2):103–111.
- Organização Mundial da Saúde (2020). Classificação estatística internacional de doenças e problemas relacionados à saúde – cid-11. <https://icd.who.int/>. Acesso em: 10 set. 2025.
- Reddy, R. E. and Santhi, K. (2024). Exploring mental fatigue and burnout in the workplace: A survival analysis approach. *EAI Endorsed Transactions on Pervasive Health and Technology*, 10(1):e5.
- Saranya, T. S., Kumar, A., and Rao, V. (2025). Deep learning frameworks for early detection of occupational burnout. *SSRN Electronic Journal*.
- Wilton, R., Turner, M., and Hall, D. (2024). The brownie study: Wearable-based monitoring for early detection of burnout. *BMC Nursing*, 23:1711.