

## ARTIGO TÉCNICO 2 DE 2

# Detecção de fadiga sem interromper o trabalho: o papel da atividade parassimpática

Equipe de P&amp;D Dersalis · Dersalis Brasil Inovações em Saúde S.A. · Vitória (ES)

Questionários e testes de atenção dependem da resposta do trabalhador e interrompem a atividade. A Dersalis desenvolveu um modelo que identifica a fadiga pela predominância da atividade parassimpática, medida pela variabilidade da frequência cardíaca num sensor de pulso. **Em cinco turnos de logística industrial no pipe shop da Ocyan, em Macaé, o modelo acertou 88% dos alertas emitidos e encontrou 72% dos períodos de baixa atenção, com acurácia geral de 91%.**

**88%**

de precisão: alertas emitidos que estavam certos

**72%**

de recall: períodos de baixa atenção detectados

**91%**

de acurácia em 830 janelas de 2 minutos

## Do questionário ao corpo

No [primeiro artigo desta série](#), mostramos que, na sonda ODN-1, 83% das autoavaliações indicaram pouca ou nenhuma sonolência enquanto 57% dos testes de atenção tiveram desempenho baixo. Testes psicométricos são ferramentas importantes, mas a resposta pode se afastar da reação biológica, porque cada pessoa adota estratégias para lidar com a situação de teste (Armario et al., 2020). Além disso, todo teste exige parar a tarefa.

A pergunta seguinte foi: é possível identificar a fadiga continuamente, sem depender da resposta do trabalhador e sem interromper o trabalho? A literatura aponta que sim. Em vez de medições pontuais de aptidão, o monitoramento contínuo de dados vitais permite acompanhar como a fadiga evolui ao longo do turno (Sparrow et al., 2019).

## O que a variabilidade cardíaca revela

O intervalo entre um batimento e o seguinte não é fixo. Essa variação, chamada variabilidade da frequência cardíaca (VFC), reflete o equilíbrio entre os dois ramos do sistema nervoso autônomo: o simpático, que prepara o corpo para a ação, e o parassimpático, que conduz ao repouso e à recuperação. Por isso, a VFC é considerada um marcador promissor de sonolência, fadiga e estresse (Burlacu et al., 2021), e estudos recentes mostram padrões distintos entre estados de fadiga e de não fadiga (Gao et al., 2022).

As métricas usadas pela Dersalis estão entre as recomendadas pela Task Force da Sociedade Europeia de Cardiologia (1996), todas no domínio do tempo (Shaffer e Ginsberg, 2017):

- **RMSSD**: raiz quadrada da média das diferenças entre intervalos consecutivos, ligada sobretudo à atividade parassimpática;
- **SDNN**: desvio padrão dos intervalos entre batimentos, que expressa a variabilidade geral;
- **pNN50**: porcentagem de intervalos consecutivos que diferem em mais de 50 ms.

Durante o trabalho ativo, uma predominância parassimpática prolongada é um sinal de que o corpo está entrando em modo de repouso enquanto a pessoa ainda precisa estar alerta. Esse estado está associado a mais lapsos, menor atenção sustentada e maior probabilidade de erro.

## Como o modelo funciona

O sensor de pulso usa fotopletismografia (PPG), uma leitura óptica do fluxo sanguíneo, e um acelerômetro. A partir desses sinais, o modelo calcula a frequência cardíaca e as métricas de VFC em janelas curtas e aplica uma árvore de decisão para identificar quando a atividade parassimpática predomina.

Um cuidado central foi não confundir fadiga com descanso. As faixas de referência partem dos valores normais da literatura, mas foram ajustadas para uma população em atividade e consideram o estado de movimento: a mesma leitura tem significado diferente para quem está parado e para quem está carregando material. Essas faixas não são fixas. Como metabolismo e resiliência variam entre pessoas e entre operações, os limites podem ser configurados por operação.

Quando o modelo identifica fadiga, o primeiro a ser avisado é o próprio trabalhador, para que adote uma contramedida (pausa, hidratação, alongamento, troca de tarefa). Se a condição persiste, o supervisor também recebe o alerta e os dois podem combinar uma ação. Não é preciso responder nenhum questionário nem interromper a tarefa para ser avaliado.

## A validação em campo

O modelo foi aplicado no pipe shop da Ocyan, em Macaé (RJ), com trabalhadores de logística industrial em turnos da manhã, da tarde e da noite. Foram analisados cinco turnos completos, divididos em janelas de 2 minutos: 830 janelas no total, cerca de 28 horas de trabalho.

Para saber se cada alerta estava certo, cada janela foi rotulada com base em testes e relatos de sonolência aplicados no mesmo período, indicando se o trabalhador estava ou não com a atenção sustentada reduzida. As saídas do modelo foram então comparadas a esses rótulos.

## Um turno de perto

No primeiro caso, um trabalhador de logística começou um turno de 12 horas às 19h. Pouco depois da meia-noite, os primeiros sinais fisiológicos de fadiga apareceram, e o modelo marcou três períodos de maior risco:

- **das 0h45 à 1h30**, depois de mais de cinco horas de trabalho, quando a frequência cardíaca começou a cair;

- das 3h20 às 3h50, com predominância clara da atividade parassimpática;
- das 4h às 4h30, o período mais crítico, com a frequência cardíaca no menor valor da noite.




Figura 1. Frequência cardíaca no Caso 1, das 22h às 7h, como aparece na plataforma. A média cai a partir da meia-noite e chega ao mínimo perto das 4h.

O trabalhador não estava dormindo: o acelerômetro mostrava movimento compatível com esforço leve. Em cada período, ele recebeu alertas para adotar contramedidas. Quando elas não funcionaram ou não foram tomadas, o supervisor também foi avisado.

Entre 5h e 6h, o movimento caiu: o trabalhador descansou, mas não dormiu. A partir daí, a variabilidade entre batimentos aumentou, um componente simpático compatível com privação de sono, a conhecida "ressaca" de uma noite em claro. Às 7h, fim do turno, os sinais de privação de sono e fadiga extrema eram claros. Neste caso, o modelo teve 95% de precisão e 78% de recall.




Figura 2. RMSSD no Caso 1. As faixas coloridas marcam os limites usados pelo modelo.

# Resultados




Figura 3. Precisão e recall do modelo em cada turno analisado e no conjunto das 830 janelas.

| Turno                  | Janelas | Precisão | Recall | Acurácia |
|------------------------|---------|----------|--------|----------|
| Caso 1 · noite         | 280     | 95%      | 78%    | 93%      |
| Caso 2 · tarde         | 132     | 90%      | 82%    | 93%      |
| Caso 3 · noite         | 132     | 75%      | 56%    | 92%      |
| Caso 4 · noite         | 121     | 73%      | 57%    | 78%      |
| Caso 5 · manhã e tarde | 165     | 93%      | 76%    | 93%      |
| Geral                  | 830     | 88%      | 72%    | 91%      |

Em linguagem direta: de cada 10 alertas emitidos, cerca de 9 corresponderam a períodos reais de baixa atenção, e de cada 10 períodos de baixa atenção, cerca de 7 foram detectados. No conjunto, foram 147 alertas corretos, 20 alertas falsos e 57 períodos de baixa atenção que passaram sem alerta, em 830 janelas.

Os casos 3 e 4 tiveram desempenho menor. No caso 3, houve poucos períodos de baixa atenção (16 janelas), e cada erro pesa mais. No caso 4, o trabalhador tirou o sensor entre 2h e 4h, justamente num trecho de queda da frequência cardíaca.

## Limitações e próximos passos

Parte dos erros veio do tempo de reação do próprio modelo. Por usar médias móveis, os alertas começaram e terminaram, em média, de 2 a 4 minutos depois do momento marcado nos rótulos. Isso não tem impacto operacional relevante, mas conta como erro nas métricas. A validação também se limitou a cinco turnos de uma mesma função.

Os próximos passos são incorporar novos biomarcadores, ajustar as médias móveis e estudar limites que variem conforme o ciclo circadiano, o turno e o perfil de trabalho, como manutenção e logística.

Desde então, o método segue em uso e evolução na plataforma da Dersalis. Hoje os gestores podem ajustar os limites de alerta por operação, direcionar as notificações para grupos diferentes e acompanhar o efeito das intervenções, respeitando as diferenças de cada tipo de trabalho.

---

## Referências

1. Armario, A., Labad, J. e Nadal, R. (2020). Focusing attention on biological markers of acute stressor intensity: empirical evidence and limitations. *Neuroscience & Biobehavioral Reviews*, 111, 95–103. <https://doi.org/10.1016/j.neubiorev.2020.01.013>
  2. Burlacu, A., Brinza, C., Brezulianu, A. e Covic, A. (2021). Accurate and early detection of sleepiness, fatigue and stress levels in drivers through heart rate variability parameters: a systematic review. *Reviews in Cardiovascular Medicine*, 22(3), 845–852. <https://doi.org/10.31083/j.rcm2203090>
  3. Gao, R., Yan, H., Duan, J. et al. (2022). Study on the nonfatigue and fatigue states of orchard workers based on electrocardiogram signal analysis. *Scientific Reports*, 12(1), 1–17. <https://doi.org/10.1038/s41598-022-08705-z>
  4. Shaffer, F. e Ginsberg, J. P. (2017). An overview of heart rate variability metrics and norms. *Frontiers in Public Health*, 5, 258. <https://doi.org/10.3389/fpubh.2017.00258>
  5. Sparrow, A. R., LaJambe, C. M. e Van Dongen, H. P. A. (2019). Drowsiness measures for commercial motor vehicle operations. *Accident Analysis & Prevention*, 126, 146–159. <https://doi.org/10.1016/j.aap.2018.04.020>
  6. Task Force of the European Society of Cardiology and the North American Society of Pacing and Electrophysiology (1996). Heart rate variability: standards of measurement, physiological interpretation and clinical use. *Circulation*, 93(5), 1043–1065. <https://doi.org/10.1161/01.CIR.93.5.1043>
- 

Versão revisada, em português, dos Technical Papers 2 e 3 (2024), elaborados pela Dersalis em projeto de P&D com a Shell Brasil e a Ocyan. Dados de trabalhadores tratados de forma anônima, em conformidade com a LGPD.