

ARTÍCULO TÉCNICO 2 DE 2

DetECCIÓN DE FATIGA SIN INTERRUPIR EL TRABAJO: EL PAPEL DE LA ACTIVIDAD PARASIMPÁTICA

Equipo de I+D de Dersalis · Dersalis Brasil Inovações em Saúde S.A. · Vitória (Brasil)

Los cuestionarios y las pruebas de atención dependen de la respuesta del trabajador e interrumpen la actividad. Dersalis desarrolló un modelo que identifica la fatiga por el predominio de la actividad parasimpática, medida a través de la variabilidad de la frecuencia cardíaca con un sensor de muñeca. **En cinco turnos de logística industrial en el pipe shop de Ocyan, en Macaé, el modelo acertó el 88% de las alertas emitidas y detectó el 72% de los periodos de baja atención, con una exactitud general del 91%.**

88%

de precisión: alertas emitidas que fueron correctas

72%

de recall: periodos de baja atención detectados

91%

de exactitud en 830 ventanas de 2 minutos

Del cuestionario al cuerpo

En el [primer artículo de esta serie](#) mostramos que, en la plataforma ODN-1, el 83% de las autoevaluaciones indicó poca o ninguna somnolencia mientras el 57% de las pruebas de atención tuvo bajo desempeño. Las pruebas psicométricas son herramientas importantes, pero la respuesta puede alejarse de la reacción biológica, porque cada persona adopta estrategias para afrontar la situación de prueba (Armario et al., 2020). Además, toda prueba exige detener la tarea.

La siguiente pregunta fue: ¿es posible identificar la fatiga de forma continua, sin depender de la respuesta del trabajador y sin interrumpir el trabajo? La literatura indica que sí. En lugar de mediciones puntuales de aptitud, el monitoreo continuo de datos vitales permite seguir cómo evoluciona la fatiga a lo largo del turno (Sparrow et al., 2019).

Lo que revela la variabilidad cardíaca

El intervalo entre un latido y el siguiente no es fijo. Esa variación, llamada variabilidad de la frecuencia cardíaca (VFC), refleja el equilibrio entre las dos ramas del sistema nervioso autónomo: la simpática, que prepara al cuerpo para la acción, y la parasimpática, que conduce al reposo y la recuperación. Por eso, la VFC se considera un marcador prometedor de somnolencia, fatiga y estrés (Burlacu et al., 2021), y estudios recientes muestran patrones distintos entre estados de fatiga y de no fatiga (Gao et al., 2022).

Las métricas que usa Dersalis están entre las recomendadas por la Task Force de la Sociedad Europea de Cardiología (1996), todas en el dominio del tiempo (Shaffer y Ginsberg, 2017):

- **RMSSD:** raíz cuadrada de la media de las diferencias al cuadrado entre intervalos consecutivos, ligada sobre todo a la actividad parasimpática;
- **SDNN:** desviación estándar de los intervalos entre latidos, que expresa la variabilidad general;
- **pNN50:** porcentaje de intervalos consecutivos que difieren en más de 50 ms.

Durante el trabajo activo, un predominio parasimpático prolongado es una señal de que el cuerpo está entrando en modo de reposo mientras la persona aún necesita estar alerta. Ese estado se asocia con más lapsos, menor atención sostenida y mayor probabilidad de error.

Cómo funciona el modelo

El sensor de muñeca utiliza fotopletismografía (PPG), una lectura óptica del flujo sanguíneo, y un acelerómetro. A partir de esas señales, el modelo calcula la frecuencia cardíaca y las métricas de VFC en ventanas cortas y aplica un árbol de decisión para identificar cuándo predomina la actividad parasimpática.

Un cuidado central fue no confundir fatiga con descanso. Los rangos de referencia parten de los valores normales de la literatura, pero se ajustaron a una población en actividad y consideran el estado de movimiento: la misma lectura tiene un significado distinto para quien está quieto y para quien está cargando material. Estos rangos no son fijos. Como el metabolismo y la resiliencia varían entre personas y entre operaciones, los umbrales pueden configurarse por operación.

Cuando el modelo identifica fatiga, el primero en ser avisado es el propio trabajador, para que adopte una contramedida (pausa, hidratación, estiramiento, cambio de tarea). Si la condición persiste, el supervisor también recibe la alerta y ambos pueden acordar una acción. No hace falta responder ningún cuestionario ni interrumpir la tarea para ser evaluado.

La validación en campo

El modelo se aplicó en el pipe shop de Ocyan, en Macaé (Río de Janeiro), con trabajadores de logística industrial en turnos de mañana, tarde y noche. Se analizaron cinco turnos completos, divididos en ventanas de 2 minutos: 830 ventanas en total, cerca de 28 horas de trabajo.

Para saber si cada alerta era correcta, cada ventana se etiquetó a partir de pruebas y reportes de somnolencia aplicados en el mismo periodo, indicando si el trabajador tenía o no la atención sostenida reducida. Luego se compararon las salidas del modelo con esas etiquetas.

Un turno de cerca

En el primer caso, un trabajador de logística comenzó un turno de 12 horas a las 19 h. Poco después de la medianoche aparecieron las primeras señales fisiológicas de fatiga, y el modelo marcó tres periodos de mayor riesgo:

- **de 0:45 a 1:30**, después de más de cinco horas de trabajo, cuando la frecuencia cardíaca empezó a bajar;
- **de 3:20 a 3:50**, con un claro predominio de la actividad parasimpática;

- **de 4:00 a 4:30**, el periodo más crítico, con la frecuencia cardíaca en su valor más bajo de la noche.




Figura 1. Frecuencia cardíaca en el Caso 1, de 22 h a 7 h, tal como aparece en la plataforma. La media baja a partir de la medianoche y llega al mínimo cerca de las 4 h.

El trabajador no estaba durmiendo: el acelerómetro mostraba un movimiento compatible con esfuerzo leve. En cada periodo recibió alertas para adoptar contramedidas. Cuando estas no funcionaron o no se tomaron, también se avisó al supervisor.

Entre las 5 h y las 6 h, el movimiento disminuyó: el trabajador descansó, pero no durmió. A partir de ahí, la variabilidad entre latidos aumentó, un componente simpático compatible con privación de sueño, la conocida “resaca” de una noche en vela. A las 7 h, fin del turno, las señales de privación de sueño y fatiga extrema eran claras. En este caso, el modelo tuvo un 95% de precisión y un 78% de recall.




Figura 2. RMSSD en el Caso 1. Las franjas de color marcan los umbrales que usa el modelo.

Resultados




Figura 3. Precisión y recall del modelo en cada turno analizado y en el conjunto de las 830 ventanas.

Turno	Ventanas	Precisión	Recall	Exactitud
Caso 1 · noche	280	95%	78%	93%
Caso 2 · tarde	132	90%	82%	93%
Caso 3 · noche	132	75%	56%	92%
Caso 4 · noche	121	73%	57%	78%
Caso 5 · mañana y tarde	165	93%	76%	93%
General	830	88%	72%	91%

En términos simples: de cada 10 alertas emitidas, cerca de 9 correspondieron a periodos reales de baja atención, y de cada 10 periodos de baja atención, cerca de 7 fueron detectados. En total hubo 147 alertas correctas, 20 alertas falsas y 57 periodos de baja atención que pasaron sin alerta, en 830 ventanas.

Los casos 3 y 4 tuvieron un desempeño menor. En el caso 3 hubo pocos periodos de baja atención (16 ventanas), y cada error pesa más. En el caso 4, el trabajador se quitó el sensor entre las 2 h y las 4 h, justo en un tramo de caída de la frecuencia cardíaca.

Limitaciones y próximos pasos

Parte de los errores vino del tiempo de reacción del propio modelo. Al usar medias móviles, las alertas empezaron y terminaron, en promedio, de 2 a 4 minutos después del momento marcado en las etiquetas. Esto no tiene un impacto operativo relevante, pero cuenta como error en las métricas. La validación también se limitó a cinco turnos de una misma función.

Los próximos pasos son incorporar nuevos biomarcadores, ajustar las medias móviles y estudiar umbrales que varíen según el ciclo circadiano, el turno y el perfil de trabajo, como mantenimiento y logística.

Desde entonces, el método sigue en uso y en evolución en la plataforma de Dersalis. Hoy los gestores pueden ajustar los umbrales de alerta por operación, dirigir las notificaciones a distintos grupos y seguir el efecto de las intervenciones, respetando las diferencias de cada tipo de trabajo.

Referencias

1. Armario, A., Labad, J. y 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. y 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. y 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. y 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>
-

Versión revisada de los Technical Papers 2 y 3 (2024), elaborados por Dersalis en un proyecto de I+D con Shell Brasil y Ocyan. Los datos de los trabajadores se trataron de forma anónima, conforme a la ley brasileña de protección de datos (LGPD).