



UNIVERSITÀ
di VERONA

Dipartimento
di SCIENZE UMANE



TALIA Pilot

Verso algoritmi AI di classificazione del burnout tramite vocal biomarkers

Chiara Bassi · Francesca Marinaro · Michele Scandola · Riccardo Sartori · Anna Maria Meneghini · Andrea Ceschi

Dipartimento di Scienze Umane · Università di Verona

INTRODUZIONE Analisi della letteratura- Burnout

- 1 Sindrome da stress cronico con impatto sulla salute (insonnia, disturbi cardiovascolari e metabolici) e sul rendimento sia in ambito lavorativo che accademico (Khamissa et al., 2022; Madigan & Curran, 2021; Corbeanu et al., 2023).
- 2 Inclusa nell'ICD-11 ma non classificata come condizione medica: i criteri diagnostici oggettivi restano una sfida aperta.
- 3 La valutazione si basa su self-report retrospettivi: soggettivi, episodici, poco ecologici.
- 4 Al momento, la ricerca si è focalizzata su alcuni biomarcatori fisiologici: asse HPA, ANS, stress ossidativo (Danhof-Pont et al., 2011; Grossi et al., 2015).



INTRODUZIONE/GAP Analisi della letteratura- Analisi vocale

- Tra i biomarcatori, la voce è promettente: misurabile oggettivamente dal segnale audio, riflette stati emotivi e fisiologici, adatta a un monitoraggio non invasivo (Fagherazzi et al., 2021).
- Gli stati affettivi e lo stress cronico alterano la fonazione via attivazione simpatica, respirazione e tensione muscolare, modificando i parametri acustici (Cummins et al., 2015).
- L'analisi vocale automatica (ML/AI) ha reso la voce un biomcatore trattabile su larga scala, applicato a depressione, ansia e PTSD (Low et al., 2020) e a stressori lavorativi quotidiani in contesti ecologici e longitudinali (Langer et al., 2022).



Il gap: applicata a stress, depressione e ansia, la voce non è ancora stata usata per il burnout come sindrome specifica, né in un disegno ecologico e longitudinale. TALIA è il primo passo verso algoritmi AI di classificazione del rischio di burnout da biomarcatori vocali, con etichette derivate empiricamente



OBIETTIVO

Lo studio pilota mira a identificare profili psicologici stabili di burnout e a verificare se associati a pattern vocali discriminabili, da utilizzare come etichette per algoritmi AI di classificazione del rischio.

Preregistrato (OSF: <https://doi.org/10.17605/OSF.IO/HMK4F>) per disegno, raccolta dati e misure · analisi esplorative in quanto studio pilota



METODO · 1 / 5 Disegno e procedura

31 giorni di raccolta

7 time point (ogni 5 giorni)

135 Studenti universitari afferenti ai 3 cicli, dottorandi e junior researcher

	T0 Day 1	T1 Day 6	T2 Day 11	T3 Day 16	T4 Day 21	T5 Day 26	T6 Day 31
Setting	LAB Univr	HOME remoto	HOME remoto	HOME remoto	HOME remoto	HOME remoto	LAB Univr
Task 1 Sociodem.	●	○	○	○	○	○	○
Task 2 Scale psico.	●	●	●	●	●	●	●
Task 3 Disc. libero	●	●	●	●	●	●	●
Task 4 Frase std.	●	●	●	●	●	●	●
Booth	●	○	○	○	○	○	●

LAB (Univr)

HOME (remoto)

Task eseguito

Non eseguito

LAB · T0 e T6

- Vicoustic VicBooth Ultra (≈ 30 dB)
- Neumann TLM 103 · cardioid · 7 dBA · 20 Hz–20 kHz
- Audient iD14 MKII · 24-bit · 96 kHz

HOME · T1–T5

- Device personali
- Nessun vincolo su microfono o ambiente
- Stessa stanza · ~10 cm dalla bocca

Reminder ogni 5 giorni dalle 17:00 (email · Outlook · SMS), sessione a fine giornata, trade-off controllo ↔ ecologia





Frase standardizzate

contenuto controllato · 1 file audio

- 14 frasi brevi · tutti i fonemi italiani
- Bilanciate sorde/sonore · lunghezza variabile
- Semanticamente neutre (alcune nonsense)

Costantini et al., 2014



Discorso libero

condizioni ecologiche · 3 file audio

- *Attività quotidiane* cosa hai fatto oggi
 - *Gestione routine* come hai affrontato imprevisti
 - *Esperienza emotiva* come ti sei sentito/a
- domande emotivamente neutre · parlato spontaneo



openSMILE · eGeMAPS v02 → 88 parametri Eyben et al., 2010
· 2016

16 features selezione: seguendo la review Low et al., 2020 · estratte separatamente per task

Prosodiche

- **F0_mean**: altezza media (semitoni, log re 27.5 Hz)
- **F0_sd**: variabilità intra-utterance
- **F0_range**: estensione della modulazione

Energia

- **Loudness**: intensità percettiva (sone)
- **Loudness_sd**: variabilità di intensità

Qualità vocale

- **Jitter**: irregolarità ciclo-ciclo in F0
- **Shimmer**: perturbazioni di ampiezza
- **HNR**: energia periodica / aperiodica (dB)

Spettrali

- **AlphaRatio**: 50–1000 Hz vs 1–5 kHz (dB)
- **Hammarberg**: 0–2 kHz vs 2–5 kHz (dB)
- **SpectralFlux**: variazione spettrale frame-to-frame
- **MFCC1–2**: forma/inclinazione involucro spettrale

Temporal

- **VoicedLen**: durata media fonazione continua (s)
- **PauseLen**: durata media pause (s)
- **VoicedSeg**: n. segmenti sonori (fluenza)



METODO · 3 / 5 Misure psicometriche

Scala	Dimensione	N	ω	Fonte
OLBI-S	Esaurimento	8 item	$\omega = .840$	<i>Loscalzo et al., 2024</i>
	Disimpegno	8 item	$\omega = .782$	
JAWS	HPHA · alto piacere / alta attivaz.	3 item	$\omega = .877$	<i>Schaufeli & van Rhenen, 2006 Balducci</i>
	HPLA · alto piacere / bassa attivaz.	3 item	$\omega = .763$	
	LPHA · basso piacere / alta attivaz.	3 item	$\omega = .798$	
	LPLA · basso piacere / bassa attivaz.	3 item	$\omega = .724$	
JD	Complessità del compito	4 item	$\omega = .881$	<i>Maynard & Hakel, 1997</i>
JR	Supporto sociale	3 item	$\omega = .898$	<i>Bakker & Demerouti, 2014</i>

Versione daily wording adattato al frame temporale giornaliero (es. Oggi, prima di iniziare a studiare, mi sono sentito stanco/a)



Sociodemografiche · T0 only

Anagrafica età, genere, stato civile

Studio livello, ore settimanali

Salute BMI, consumo di fumo, alcol, caffeina

Farmaci che possono influenzare la qualità vocale o l'espressione emotiva: antidepressivi, antipsicotici, ansiolitici.

Condizioni che alterano la voce: disturbi gastrointestinali associati ad alterazioni laringee (Cesari et al., 2018)



METODO · 4 / 5 Data preprocessing del dato vocale

1 |Task labeling · Whisper*

- Classificazione automatica tipo di task (frasi std. vs. parlato libero)

2 |Standardizzazione · Ffmpeg

- Conversione WAV,16-bit mono,
- Ricampionamento a 16 kHz

3 |Sanity check · YAMNet

- Verifica segnale fisico: ≥ 20 KB, ≥ 1 s, RMS > 0.0002

4 |Loudness + VAD · Silero VAD

- Normalizzazione -23 LUFS per file (K-weighted)
- Trimming silenzio iniziale/finale → 3.814 file

5 |Estrazione feature · openSMILE

- eGeMAPS v02: 88 parametri
- 16 feature selezionate
- Estrazione separata per task

6 |Controllo qualità · 2 stadi

- Stadio 1 — outlier $|z| > 3$: 1 part. (dBp=-60), 32 sessioni (29 part.), 2 file
- Stadio 2 — filtro ≤ 4 s: -73 file
Completeness ≥ 5 wave: -2 part.

*(Radford et al., 2023)

188

auto-selezionati

141

dopo completezza e qualità audio

135

campione analitico finale


3.646

file audio analizzati



METODO · 5 / 5 Strategia analitica

Poiché il burnout non dispone di etichette diagnostiche oggettive, il clustering viene utilizzato per derivarle empiricamente dai profili psicometrici.

1

Aggregazione a livello di persona

Media per partecipante di ciascuna variabile, calcolata su tutte le sessioni e tutti i task.

→ il livello medio stabile di ogni individuo

Tutte le scale orientate nella stessa direzione: punteggi alti = più burnout

2

Cluster analysis

$k = 2$, scelto empiricamente: screeplot e silhouette convergono sullo stesso valore.

→ K-means (seed 9 · nstart 25)
· silhouette = 0.27

Struttura debole ma presente (> 0.25)

3

Discriminazione vocale

Wilcoxon rank-sum tra i due profili, non parametrico: nessuna assunzione di normalità.

→ stratificato per task × time point · correzione FDR

Benjamini & Hochberg, 1995

Schema dei confronti

T0

28 variabili
vocali + sociodemografiche +
psicometriche
*verifica: nessuna differenza
demografica*

T1–T6

24 variabili
16 vocali + 8 psicometriche
*sociodem. escluse: stabili e
senza differenze*

**2 task × 7 time point
analisi separate**

frasi standardizzate ·
discorso libero
*le feature dipendono dal
task*



RISULTATI · 1 / 2 Due profili psicologici distinti

Centroidi dei cluster · punteggi standardizzati (z)



DISTRESS

n = 60 44.4%

alto burnout · alto affetto negativo

BENESSERE

n = 75 55.6%

basso burnout · alto affetto positivo

k = 2 screeplot e silhouette convergono
silhouette = 0.27 struttura debole ma presente

Burnout e affetto negativo separano i profili; richieste (JD) e risorse (JR) molto meno.



Nessuna differenza demografica

genere · età · BMI · ore di studio — tutti p.adj > .05

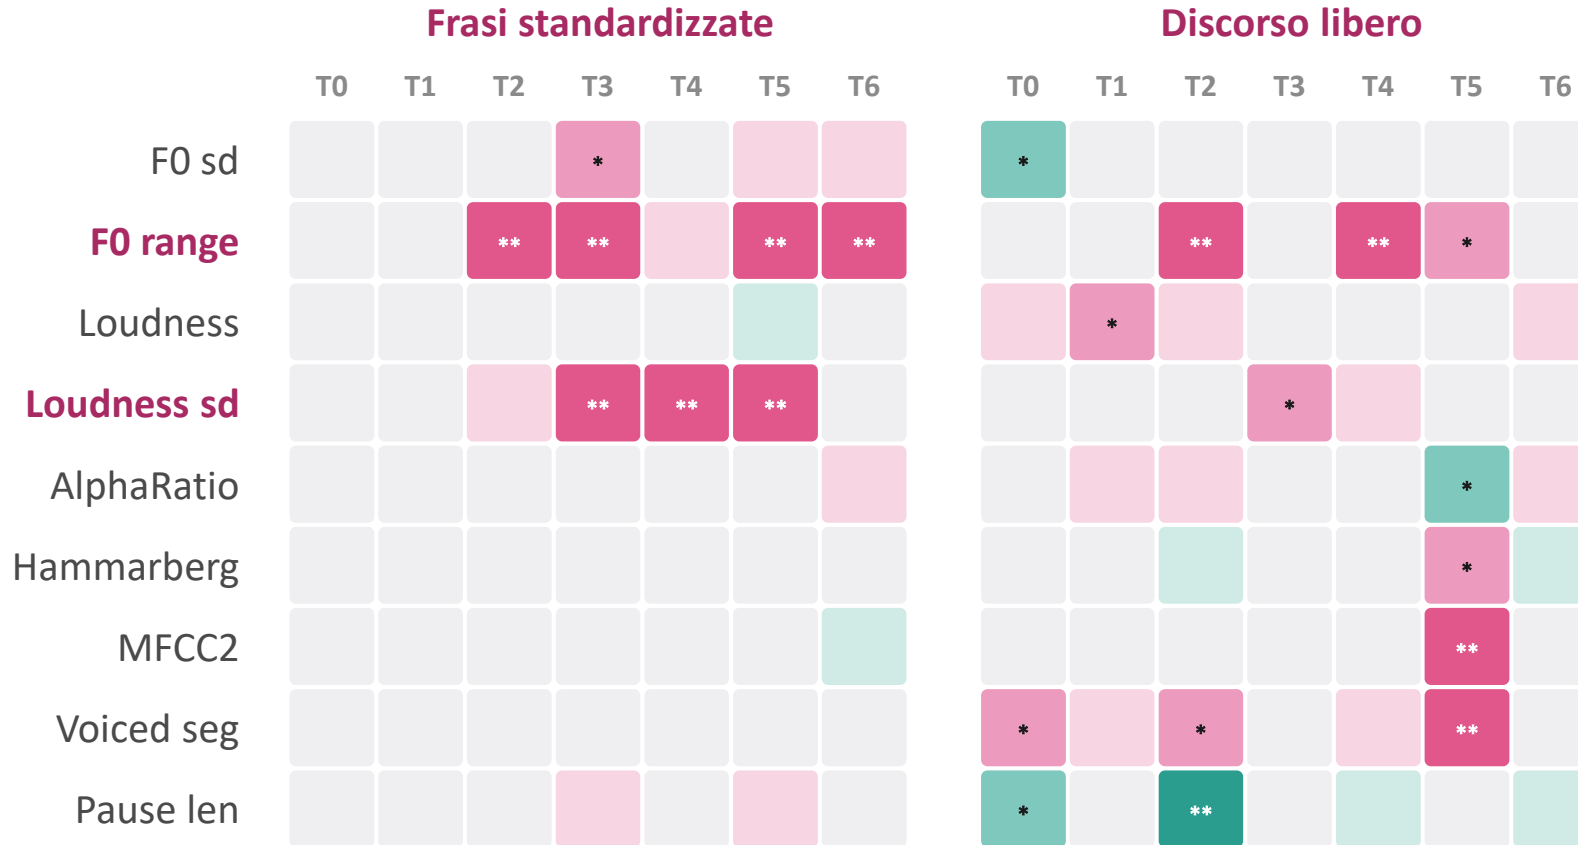


Separazione stabile a tutti i 7 time point

OLBI e JAWS LPLA/LPHA — p.adj < .001



RISULTATI · 2 / 2 Pattern vocali dei profili psicologici



■ distress più basso ■ distress più alto

* $p_{adj} < .05$ ** $p_{adj} < .01$ tinta chiara = tendenza ($p_{adj} < .10$); mostrate solo le feature con ≥ 1 effetto significativo ($p_{adj} < .10$)

Il pattern

Nelle frasi standardizzate il distress mostra **F0 range e variabilità di loudness più bassi, sistematici da T2 a T6.**

Nel discorso libero gli effetti sono sparsi e di direzione mista.

→ *ridotta modulazione prosodica ed energetica nel distress: coerente con appiattimento affettivo e ridotto arousal.*



I limiti

- Natura pilota del disegno.
- Struttura dei cluster debole–moderata (silhouette = 0.27).
- Numerosità campionaria contenuta.
- Discorso libero meno robusto del parlato controllato.

OGGI

Proof of concept

I profili di burnout hanno un correlato vocale discriminabile.



DOMANI

Etichette per l'AI

I profili diventano target per addestrare algoritmi di classificazione automatica del rischio.

1 Screening non invasivo
monitoraggio ecologico e ripetibile



2 Follow-up longitudinale
tracciare il rischio nel tempo



3 Strumenti AI clinici
supporto a prevenzione e cura



RIFERIMENTI BIBLIOGRAFICI

- Bakker, A. B., & Demerouti, E. (2014). Job Demands–Resources Theory. 1–28. <https://doi.org/10.1002/9781118539415.wbwell019>
- Balducci, C., Schaufeli, W. B., & Fraccaroli, F. (2011). The job demands–resources model and counterproductive work behaviour: The role of job-related affect. *European Journal of Work and Organizational Psychology*, 20(4), 467–496. <https://doi.org/10.1080/13594321003669061>
- Benjamini, Y., & Hochberg, Y. (1995). Controlling the False Discovery Rate: A Practical and Powerful Approach to Multiple Testing. *Journal of the Royal Statistical Society. Series B (Methodological)*, 57(1), 289–300. <https://doi.org/10.1111/j.2517-6161.1995.tb02031.x>
- Cesari, U., De Pietro, G., Marciano, E., Niri, C., Sannino, G., & Verde, L. (2018). A new database of healthy and pathological voices. *Computers & Electrical Engineering*, 68, 310–321. <https://doi.org/10.1016/j.compeleceng.2018.04.008>
- Corbeanu, A., Iliescu, D., Ion, A., & Spînu, R. (2023). The link between burnout and job performance: A meta-analysis. *European Journal of Work and Organizational Psychology*, 32, 1–18. <https://doi.org/10.1080/1359432X.2023.2209320>
- Costantini, G., Iaderola, I., Paoloni, A., & Todisco, M. (2014). Emovo Corpus: An Italian Emotional Speech Database. *European Language Resources Association (ELRA)*. <https://art.torvergata.it/handle/2108/97109>
- Cummins, N., Scherer, S., Krajewski, J., Schnieder, S., Epps, J., & Quatieri, T. F. (2015). A review of depression and suicide risk assessment using speech analysis. *Speech Communication*, 71, 10–49. <https://doi.org/10.1016/j.specom.2015.03.004>
- Danhof-Pont, M. B., Van Veen, T., & Zitman, F. G. (2011). Biomarkers in burnout: A systematic review. *Journal of Psychosomatic Research*, 70(6), 505–524. <https://doi.org/10.1016/j.jpsychores.2010.10.012>
- Eyben, F., Scherer, K. R., Schuller, B. W., Sundberg, J., André, E., Busso, C., Devillers, L. Y., Epps, J., Laukka, P., Narayanan, S. S., & Truong, K. P. (2016). The Geneva Minimalistic Acoustic Parameter Set (GeMAPS) for Voice Research and Affective Computing. *IEEE Transactions on Affective Computing*, 7(2), 190–202. <https://doi.org/10.1109/TAFFC.2015.2457417>
- Eyben, F., Wöllmer, M., & Schuller, B. (2010). Opensmile: The munich versatile and fast open-source audio feature extractor. *Proceedings of the 18th ACM international conference on Multimedia, MM '10*, 1459–1462. <https://doi.org/10.1145/1873951.1874246>
- Fagherazzi, G., Fischer, A., Ismael, M., & Despotovic, V. (2021). Voice for Health: The Use of Vocal Biomarkers from Research to Clinical Practice. *Digital Biomarkers*, 5(1), 78–88. <https://doi.org/10.1159/000515346>
- Grossi, G., Perski, A., Osika, W., & Savic, I. (2015). Stress-related exhaustion disorder – clinical manifestation of burnout? A review of assessment methods, sleep impairments, cognitive disturbances, and neuro-biological and physiological changes in clinical burnout. *Scandinavian Journal of Psychology*, 56(6), 626–636. <https://doi.org/10.1111/sjop.12251>
- Khammissa, R. A. G., Nemutandani, S., Feller, G., Lemmer, J., & Feller, L. (2022). Burnout phenomenon: Neurophysiological factors, clinical features, and aspects of management. *Journal of International Medical Research*, 50(9), 03000605221106428. <https://doi.org/10.1177/03000605221106428>
- Langer, M., König, C. J., Siegel, R., Fredenhagen, T., Schunck, A. G., Hähne, V., & Baur, T. (2022). Vocal-Stress Diary: A Longitudinal Investigation of the Association of Everyday Work Stressors and Human Voice Features. *Psychological Science*, 33(7), 1027–1039. <https://doi.org/10.1177/09567976211068110>
- Loscalzo, Y., Rice, K. G., & Giannini, M. (2024). Psychometric properties of the Italian oldenburg burnout inventory (student version) and measurement invariance with the USA. *Current Psychology*, 43(9), 8241–8251. <https://doi.org/10.1007/s12144-023-05020-2>
- Low, D. M., Bentley, K. H., & Ghosh, S. S. (2020). Automated assessment of psychiatric disorders using speech: A systematic review. *Laryngoscope Investigative Otolaryngology*, 5(1), 96–116. <https://doi.org/10.1002/lio2.354>
- Madigan, D. J., & Curran, T. (2021). Does Burnout Affect Academic Achievement? A Meta-Analysis of over 100,000 Students. *Educational Psychology Review*, 33(2), 387–405. <https://doi.org/10.1007/s10648-020-09533-1>
- Maynard, D. C., & Hakel, M. D. (1997). Effects of Objective and Subjective Task Complexity on Performance. *Human Performance*, 10(4), 303–330. https://doi.org/10.1207/s15327043hup1004_1
- Radford, A., Kim, J. W., Xu, T., Brockman, G., McLeavey, C., & Sutskever, I. (2023). Robust Speech Recognition via Large-Scale Weak Supervision. *Proceedings of the 40th International Conference on Machine Learning*, 28492–28518. <https://proceedings.mlr.press/v202/radford23a.html>
- Schaufeli, W., & Van Rhenen, W. (2006). Over de rol van positieve en negatieve emoties bij het welbevinden van managers: Een studie met de Job-Well-being Scale (JAWS). *Gedrag & Organisatie*, 19(4). <https://doi.org/10.5117/2006.019.004.002>
- Preregistrazione e materiali · OSF:** <https://doi.org/10.17605/OSF.IO/HMK4F>





Grazie!

Chiara Bassi

Dipartimento di Scienze Umane

Università di Verona

chiara.bassi@univr.it

