instituto
de ingeniería
del conocimiento

20
24

Nº
04



Revista de Casos de Estudio en HR Analytics

Journal of HR Analytics Case Studies

ISSN: 2792-3770 Instituto de Ingeniería del Conocimiento

La Revista de Casos de Estudio en HR Analytics
Journal of HR Analytics Case Studies

La Revista de Casos de Estudio en HR Analytics nace con la misión de facilitar el intercambio de conocimiento especializado entre profesionales y académicos en el ámbito de la **analítica de Recursos Humanos**, con el objetivo de mejorar la efectividad de las organizaciones. La entidad responsable de esta revista es la **Asociación para el Desarrollo de la Ingeniería del Conocimiento** (ADIC), siendo esta publicación on-line editada por el **Instituto de Ingeniería del Conocimiento** (IIC) con una periodicidad de un número anual.



Objetivo

La revista tiene como **objetivo** principal ser un vehículo para la reflexión y la difusión de las **buenas prácticas, últimos avances ylíneas de investigación** en el ámbito de la analítica aplicada para la toma de decisiones sobre la gestión del capital humano en las organizaciones.

La revista tiene un **carácter científico** y una **vocación divulgativa**, por ello propone artículos fundamentalmente de **carácter aplicado**. Con ellos se pretende que los profesionales de las organizaciones accedan a un conocimiento relevante acerca de cómo otras organizaciones desarrollan HRA. Y, también, acercar a los académicos el conocimiento respecto de cómo se desarrolla HRA en la práctica.



Alcance

El **enfoque de la Revista**, que pretende ser **multidisciplinar**, da cabida (entre otros) a manuscritos que: reflejen **casos prácticos** de aplicación del HRA en las organizaciones; que analicen, comparen y relacionen la utilidad de diferentes **técnicas y/o herramientas** para el abordaje de diferentes objetivos analíticos; que planteen y valoren la efectividad de diferentes **metodologías de trabajo** para el desarrollo de proyectos HRA; que ayuden a entender el **mapa de ruta** por el que transitar desde los niveles básicos del HRA hasta los niveles de excelencia; y que en general ayuden a entender cómo **mejorar la efectividad organizacional** a partir de la analítica de datos referidos a la fuerza de trabajo.

© ADIC-IIC

ISSN: 2792-3770

La revista está editada por el Instituto de Ingeniería del Conocimiento y tiene los siguientes órganos de gobernanza.

Editor

David Aguado.
Instituto de Ingeniería del Conocimiento.

Editores Asociados

Jesús de Miguel.
Centro de Investigación para la Efectividad Organizacional, Universidad Autónoma de Madrid.

Antonio Delgado.
Universidad Autónoma de Madrid.

María Jesús Belizón.
Universidad Pontificia de Comillas.

Beatriz Lucía.
Instituto de Ingeniería del Conocimiento.

Delia Majarín.
ABB.

Sergio Raja.
Zurich Seguros.

Diseño y Maquetación

Andrés Muñoz Bachiller.
Instituto de Ingeniería del Conocimiento.

Comité Editorial

Magdalena Nogueira.
Universidad Autónoma de Madrid.

Francisco Abad.
Universidad Autónoma de Madrid.

Carmen García.
Universidad Autónoma de Madrid.

José Manuel de Haro.
Universidad de Alicante.

William Ferrando Durán.
Universidad Javeriana.

Carolina Zúñiga.
Universidad Politécnica Salesiana del Ecuador.

José Carlos Andrés.
Viewnext.

Eduardo Páez.
Data4all.

Pablo Haya.
Instituto de Ingeniería del Conocimiento.

Álvaro Barbero.
Instituto de Ingeniería del Conocimiento.

Sonia Rodríguez.
Instituto de Ingeniería del Conocimiento.

Maite Sáez.
Observatorio de Recursos Humanos y Relaciones Laborales.

ÍNDICE DE CONTENIDOS

Página

01. TNLP, ONA y AI en el ámbito del HR Analytics: Introducción al Número 4 de la Revista de Casos de Estudio en HR Analytics. — 005
01.NLP, ONA, and AI in the HR Analytics field: Introduction to Issue 4 of the Journal of HR Analytics Case Studies

02. Identificación de expertos en herramientas de automatización digital mediante el análisis de redes organizacionales — 013
02. Identifying experts in digital automation tools through the analysis of organizational networks

03. ¿Puntuar Automáticamente las Entrevistas de Vídeo Asíncronas (AVIs) Mediante el Análisis de la Señal de Audio? — 029
03. Automatically Scoring Asynchronous Video Interviews via Audio Signal Analysis?

04. Entrevistas de Vídeo Asíncronas: el papel de la apariencia y las atribuciones de personalidad en la estimación de empleabilidad de candidatos en situaciones de poca información — 043
04. Asynchronous Video Interviews: The Role of Appearance and Personality Attributions in Estimating Candidate Employability in Low-Information Contexts

05. Previniendo la rotación a través del análisis del impacto que tiene la formación y capacitación de los líderes de los equipos — 066
05. Preventing turnover through analysis of the impact of team leader training and coaching

06. Procesamiento de Lenguaje Natural para el análisis de entrevistas de salida en una empresa del sector retail y manufactura. — 083
06. Natural Language Processing for Analyzing Exit Interviews of Employees in a Retail and Manufacturing Sector Company

07. Una Guía Sencilla para Analizar Automáticamente la Expresividad Facial en AVIs — 103
07. A Simple Guide for the Automatic Analysis of Facial Expressivity in AVIs

© ADIC-IIC

ISSN: 2792-3770

ARTÍCULO 01

© ADIC-IIC

ISSN: 2792-3770



.01

NLP, ONA y AI en el ámbito del HR Analytics: Introducción al Número 4 de la Revista de Casos de Estudio en HR Analytics

NLP, ONA, and AI in the HR Analytics field: Introduction to Issue 4 of the Journal of HR Analytics Case Studies

Received: 20/07/2025
Received in revised form: 31/07/2025
Accepted: 1/09/2025
Available on-line: 15/10/2025

© ADIC-IIC

ISSN: 2792-3770

Autores

.01

David Aguado
Instituto de Ingeniería del Conocimiento

Correo electrónico:
david.aguado@iic.uam.es

Link:
https://publons.com/researwcher/2594443/david-aguado

María Jesús Belizón
University Pontificia de Comillas-ICADE

Correo electrónico:
mjbelizon@comillas.edu

Link:
https://publons.com/researcher/1208454/maria-jesusbelizon-cebada

Sergio Raja
Zurich Insurance

Correo electrónico:
sergio.rajacorreas@zurich.com

Linkedin:
https://www.linkedin.com/in/sergio-raja-64608aab/

Jesús María de Miguel Calvo
Centro de Investigación para la Efectividad Organizacional de la Universidad Autónoma de Madrid

Correo electrónico:
jesus.demiguel@uam.es

Linkedin:
https://publons.com/researcher/2807103/jesus-de-miguel

Beatriz Lucía
Instituto de Ingeniería del Conocimiento

Correo electrónico:
beatriz.lucia@iic.uam.es

Linkedin:
https://www.linkedin.com/in/beatrizlucia

Delia Majarín
ABB

Correo electrónico:
deliamajarin@gmail.com

Linkedin:
https://www.linkedin.com/in/deliamajarin/

Antonio Delgado
Universidad Autónoma de Madrid

Correo electrónico:
antonio.delgado@uam.es

Linkedin:
https://www.linkedin.com/in/antoniodelgadocalvo/

© ADIC-IIC

ISSN: 2792-3770



Resumen

En este breve texto se realiza una introducción al cuarto número de la Revista de Casos de Estudio en HR Analytics. La revista, editada por el Instituto de Ingeniería del Conocimiento, pretende ser punto de encuentro entre profesionales y académicos vinculados a la práctica profesional de HR Analytics. En este número se incluyen trabajos relacionados con la Inteligencia Artificial aplicada para la puntuación de Vídeo Entrevistas de Selección Asíncronas, la utilización de técnicas analíticas como el análisis de redes organizacionales y sociales para identificar referentes técnicos, y el procesamiento del lenguaje natural para entender los motivos de abandono de los empleados; y el empleo de técnicas clásicas de regresión para analizar la relación entre el liderazgo y la formación.

Palabras clave
Práctica Profesional, Recursos Humanos, HR Analytics.

Abstract

This brief text serves as an introduction to the fourth issue of the Journal of Case Studies in HR Analytics. The journal, published by the Instituto de Ingeniería del Conocimiento (Institute of Knowledge Engineering), aims to be a meeting point for professionals and academics involved in the practical application of HR Analytics. This issue features studies related to the application of Artificial Intelligence in scoring asynchronous video inter-views, the use of analytical techniques such as organizational and social network analysis to identify technical referents, natural language processing to understand the reasons behind employee attrition, and the use of clas-sical regression techniques to examine the relationship between leadership and training.

.

Keywords
Professional Practice, Human Resource, HR Analytics.

© ADIC-IIC

ISSN: 2792-3770

1. Introducción

La transformación digital en el ámbito de la gestión de personas ha alcanzado un punto de inflexión con la irrupción de la inteligencia artificial (IA) y de técnicas avanzadas de análisis de datos. En este contexto, el desarrollo del HR Analytics se ha visto impactado con la posibilidad ya ampliamente extendida de utilizar nuevas fuentes de datos y de automatización de actividades que antes eran desarrolladas por los profesionales. Uno de los elementos que explica esta evolución es el avance en técnicas de Procesamiento del Lenguaje Natural (PLN). El PLN permite analizar grandes volúmenes de información textual, como encuestas de clima organizacional, entrevistas de selección o interacciones en plataformas corporativas, con el fin de extraer patrones de comunicación, emociones predominantes y percepciones colectivas. Gracias a estas herramientas, los responsables de Recursos Humanos pueden disponer de métricas más precisas sobre el compromiso, la satisfacción o el riesgo de rotación de los empleados. Por otro lado, mediante el Organizational Network Analysis (ONA) se introduce una nueva dimensión en el análisis del comportamiento organizativo. Esta técnica permite mapear y estudiar las relaciones formales e informales dentro de la empresa, identificando nodos de influencia, flujos de información y posibles silos de comunicación. Mediante ONA no solo se complementa el enfoque tradicional del organigrama formal, sino que se proporciona una visión dinámica y empírica de cómo circula el conocimiento y cómo se configuran las redes de colaboración dentro de la organización. Finalmente, las tecnologías que se han desarrollado bajo el paraguas de la Inteligencia Artificial (IA) se están aplicando, entre otras cosas, al análisis de la señal audiovisual que se recoge en las grabaciones del comportamiento humano.

La convergencia entre IA, PLN y ONA potencia de manera significativa el alcance del HR Analytics. Al integrar estos enfoques, las organizaciones acceden a nuevas fuentes de datos que pueden potenciar la calidad de las descripciones, explicaciones, y predicciones que realizan sobre el talento humano. El impacto de estas tecnologías trasciende el ámbito técnico y plantea nuevos desafíos éticos, metodológicos y estratégicos. La llegada de la IA y de técnicas de análisis avanzadas obliga a reconsiderar el papel del área de Recursos Humanos, no ya como función de apoyo, sino como un actor central en la creación de valor y en la sostenibilidad organizacional. El HR Analytics se configura así como una disciplina en constante expansión, impulsada por innovaciones que prometen transformar la manera en que se entiende y gestiona el talento en el siglo XXI.

Nuestra revista no ha sido ajena a esta evolución y, fruto de ello, en este nuevo número tenemos diferentes artículos en los que se describe la utilización de estas técnicas para diversos objetivos de gestión de recursos humanos. A continuación presentamos un breve resumen de lo que el lector podrá encontrar en este cuarto número de la revista.



© ADIC-IIC

ISSN: 2792-3770

2. Artículos en este número

Tal como hemos adelantado, en este número de la revista el lector encontrará un conjunto de artículos en los que se trabaja sobre dos aspectos fundamentales. Contenidos que le ayudarán a avanzar en su conocimiento acerca de cómo implementar diferentes estrategias HRA para aportar valor a su organización. El primer aspecto trabajado en los artículos presentados está relacionado con la aplicación de la Inteligencia Artificial en la puntuación de Vídeo Entrevistas Asíncronas. El segundo aspecto desarrollado es la utilización de PLN, ONA y las técnicas estadísticas basadas en el Modelo Lineal General, en la explicación de problemas habituales en la gestión de recursos humanos. Veámoslo.

2.1. IA en la puntuación de las Vídeo Entrevistas de Selección Asíncronas

Las entrevistas de selección desarrolladas mediante soportes digitales han experimentado un enorme crecimiento en los últimos años (Hickman et al., 2022). El desarrollo de diferentes plataformas comerciales (por ejemplo, VidCruiter, Spark Hire, o IA Select) ha contribuido extensamente a que las Vídeo Entrevistas Asíncronas (Asincronous Video Interviews, AVIs) se hayan convertido en una herramienta ampliamente utilizada en los procesos de reclutamiento y selección. La relación entre el coste y el alcance que permite, sin duda, es una razón de peso para esta adopción. Tres características de las AVIs tienen especial relevancia: suponen un enfoque de entrevista altamente estructurado, lo que potencialmente puede favorecer su fiabilidad y validez; son un medio con mucha menor riqueza informativa que las entrevistas presenciales, lo que puede derivar en menos información para tomar decisiones; y, por último, son por naturaleza un producto digital, y como tal, susceptible de ser "procesado" automáticamente. Dos artículos de este número se centran en cómo obtener automáticamente información de valor de las respuestas dadas por los candidatos en una AVI. Moreno (2025) se centra en cómo analizar a través de R la expresión facial del candidato durante la entrevista, recurriendo para ello a las Unidades de Acción definidas por Ekman (1982). Por otro lado, Artiñano y Aguado (2025) se centran en la señal de audio, en la prosodia, y exploran la fiabilidad de las características de la señal de audio que se extraen mediante los modelos más habituales utilizados en la ciencia de datos. Para ello emplean también R y las características del modelo eGEMAP (Eyben et al., 2016). Finalmente, en un tercer artículo, Martínez (2025) se centra en el análisis de cómo en un contexto de información limitada como son las respuestas de los candidatos en las AVIs, los entrevistadores tienden a fijarse en algunas características de los candidatos como la voz y la apariencia para realizar sus inferencias sobre la personalidad de los candidatos y tomar decisiones.

2.2. Utilización de técnicas analíticas en el análisis de diferentes retos en la gestión de recursos humanos.

Tres artículos de este número exploran mediante diversas técnicas analíticas diferentes problemas habituales en la gestión de recursos humanos como la identificación de referentes técnicos, el análisis de los motivos de abandono de la compañía y la exploración del impacto de la formación de los líderes de equipos de trabajo. En el artículo de Plazas y Haya (2025) se aborda la cuestión del análisis de los motivos de la rotación mediante la utilización de las técnicas del procesamiento del lenguaje natural. En su artículo se aborda un tema fundamental: la retención de talento. En la actualidad, las organizaciones enfrentan un entorno altamente competitivo en lo que respecta a la atracción y retención del talento, lo que obliga a fortalecer sus estrategias en la gestión de personas. Una de las herramientas tradicionalmente empleadas ha sido el análisis de las entrevistas de salida, para conocer las causas subyacentes de la desvinculación laboral. Sin embargo, el avance de la inteligencia artificial ha abierto nuevas posibilidades para procesar y analizar grandes volúmenes de información cualitativa, ofreciendo alternativas que superan las limitaciones de los métodos convencionales y que facilitan una visión más amplia de los factores que inciden en la rotación. En este sentido, en este trabajo se examinan los determinantes de la rotación en una empresa del sector manufacturero y de retail mediante técnicas de procesamiento de lenguaje natural (PLN), utilizando el software estadístico R y el modelo GPT-4o para el análisis de entrevistas de salida. Por otro lado, en el trabajo de Huffington (2025) se aborda la cuestión de la identificación de referentes técnicos mediante el análisis de redes organizacionales y sociales.

© ADIC-IIC

ISSN: 2792-3770

En el análisis desarrollado, se aplica el análisis de redes organizacionales para identificar a los expertos en herramientas de automatización digital en una organización del sector asegurador. Los resultados muestran que el análisis no solo permitió identificar a los expertos en las herramientas de interés para la organización, sino que también proporcionó una visión clara sobre cómo fluye el conocimiento relacionado con estas tecnologías dentro de la organización.

Finalmente, Cantero (2025) realiza un análisis mediante técnicas de regresión lineal para explorar los impactos de la formación de los líderes de equipos de trabajo en dos comportamientos organizacionales fundamentales: la rotación de los equipos y las oportunidades de negocio generadas por los líderes.

3. Conclusiones

Los artículos presentados en este cuarto número de la Revista de Casos de Estudio en HR Analytics suponen una continuidad respecto de número anteriores en la descripción de casos de estudio en los que se aplican las diferentes técnicas analíticas: PLN, ONA, y el Modelo Lineal General, en la exploración de problemas de gestión de recursos humanos habituales en la mayoría de las organizaciones. Además, en línea con la influencia de la inteligencia artificial, como novedad, en este número también se han presentado un conjunto de artículos encaminados a divulgar cómo implementar diferentes estrategias en R para analizar automáticamente la señal procedente de entrevistas digitalizadas.

La utilización de la IA en el ámbito de la gestión de recursos humanos hace necesaria la reflexión acerca de los condicionantes socio-éticos de su implementación. En esta línea también en este número se incluye un artículo en el que si bien no se lidia directamente con este asunto, si supone una llamada de atención acerca de los posibles sesgos que pueden cometer los entrevistadores profesionales en el análisis de las video entrevistas. Ello es también relevante desde el punto de la IA ya que son estas valoraciones realizadas por expertos las que habrán de utilizarse para el entrenamiento de los modelos automáticos.

En definitiva, un número cargado con diversos casos de estudio e ideas que sin duda contribuirán a que los profesionales de recursos humanos se acerquen a la utilización del HR Analytics para el entendimiento del comportamiento organizacional, la toma de decisiones de gestión y la automatización de procesos.



© ADIC-IIC

ISSN: 2792-3770

8. Referencias bibliográficas

- Artiñano, B., Aguado, D. (2025). ¿Puntuar Automáticamente las Entrevistas de Vídeo Asíncronas (AVIs) Mediante el Análisis de la Señal de Audio? [Automatically Scoring Asynchronous Video Interviews via Audio Signal Analysis?]. Journal of HR Analytics Case Studies, 4, x-y.
- Cantero, R. (2025). Previniendo la rotación y maximizando las oportunidades de negocio a través del análisis del impacto que tiene la formación en la capacitación de los líderes de los equipos. [Preventing turnover and maximizing business opportunities through analysis of the impact of team leader training and coaching.], Journal of HR Analytics Case Studies, 4, x-y.
- Ekman, P. (1982). Methods for measuring facial action. Handbook of methods in nonverbal behavior research, 45-90.
- Eyben, F., Scherer, K., Schuller, B., Sundberg, J., André, E., Busso, C., Devillers, L., Epps, J., Laukka, P., Narayanan, S. y 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
- Hickman, L., Bosch, N., Ng, V., Saef, R., Tay, L., & Woo, S. E. (2022). Automated video interview personality assessments: Reliability, validity, and generalizability investigations. Journal of Applied Psychology, 107(8), 1323.
- Huffington, R. (2025). Identificación de expertos en herramientas de automatización digital mediante el análisis de redes organizacionales. [Identifying experts in digital automation tools through the analysis of organizational networks.]. Journal of HR Analytics Case Studies, 4, x-y.
- Martínez, P. (2025). Entrevistas de Vídeo Asíncronas: el papel de la apariencia y las atribuciones de personalidad en la estimación de empleabilidad de candidatos en situaciones de poca información. [Asynchronous Video Interviews: The Role of Appearance and Personality Attributions in Estimating Candidate Employability in Low-Information Contexts.]. Journal of HR Analytics Case Studies, 4, x-y.
- Moreno, N. (2025). Una Guía Sencilla para Analizar Automáticamente la Expresividad Facial en AVIs. [A Simple Guide for the Automatic Analysis of Facial Expressivity in AVIs]. Journal of HR Analytics Case Studies, 4, x-y.
- Plazas, B.A., y Haya, P. (2025). Procesamiento de Lenguaje Natural para el análisis de entrevistas de salida en una empresa del sector retail y manufactura. [Natural Language Processing for Analyzing Exit Interviews of Employees in a Retail and Manufacturing Sector Company.]. Journal of HR Analytics Case Studies, 4, x-y.

© ADIC-IIC

ISSN: 2792-3770

ARTÍCULO 02

© ADIC-IIC

ISSN: 2792-3770



.02

Identificación de expertos en herramientas de automatización digital mediante el análisis de redes organizacionales

Identifying experts in digital automation tools through the analysis of organizational networks

Rick Huffington Mow
Seguros SURA Colombia

Correo electrónico:
rickhm@live.com

Linkedin:
https://linkedin.com/in/rickhm

Received: 31/10/2024
Received in revised form: 21/04/2025
Accepted: 14/05/2025
Available on-line: 15/10/2025

© ADIC-IIC

ISSN: 2792-3770



Resumen

En este caso de estudio, se aplica el análisis de redes organizacionales para identificar a los expertos en herramientas de automatización digital al interior de una organización del sector asegurador en Colombia. Las tecnologías focalizadas incluyen Power BI, Power Automate, Power Apps y UiPath StudioX. El análisis no solo permitió identificar a los expertos en cada una de estas herramientas, sino que también proporcionó una visión clara sobre cómo fluye el conocimiento relacionado con estas tecnologías dentro de la organización. Los resultados destacan las dinámicas de intercambio de información y colaboración, ofreciendo una valiosa perspectiva para mejorar la gestión del conocimiento y potenciar la eficiencia operativa. Este enfoque proporciona una herramienta práctica para fortalecer las estrategias organizacionales y desarrollar habilidades digitales de manera más efectiva.

Palabras clave

Análisis de Redes Organizacionales, Power BI, Power Apps, Power Automate, UiPath StudioX, R Studio.

Abstract

This case study applies organizational network analysis to identify experts in digital automation tools within an insurance company in Colombia. The focused technologies include Power BI, Power Automate, Power Apps, and UiPath StudioX. The analysis not only identified the experts in each of these tools but also provided a clear view of how knowledge about these technologies flows within the organization. The results highlight the dy-namics of information exchange and collaboration, offering valuable insights for improving knowledge man-agement and enhancing operational efficiency. This approach provides a practical tool to strengthen organi-zational strategies and more effectively develop digital skills.

Keywords

Organizational Network Analysis, Power BI, Power Apps, Power Automate, UiPath StudioX, R Studio.

© ADIC-IIC

ISSN: 2792-3770

1. Introducción

En la era digital actual, la automatización de procesos se ha convertido en un pilar fundamental para la eficiencia y competitividad de las organizaciones. Herramientas como Power BI, Power Apps, Power Automate y UiPath StudioX están cambiando la manera en que las empresas realizan sus operaciones, facilitando la creación de soluciones innovadoras que optimizan el flujo de trabajo y potencian la toma de decisiones basada en datos.

El éxito en la implementación y el uso efectivo de estas tecnologías depende en gran medida de la identificación y movilización de expertos dentro de la organización. Estos expertos no solo poseen el conocimiento técnico necesario, sino que también comprenden como estas herramientas pueden integrarse estratégicamente en los procesos empresariales para generar valor. La capacidad de detectar y fomentar a estas personas clave es esencial para maximizar los beneficios de la automatización digital y asegurar una transición fluida hacia un entorno de trabajo más eficiente y efectivo.

Este caso de estudio se enfoca en el análisis de redes organizacionales para identificar a dichos expertos en herramientas de automatización digital. Esta metodología de análisis pretende identificar las relaciones y flujos de conocimiento dentro de la organización, destacando a aquellas personas que actúan como nodos claves en la difusión y aplicación de estas tecnologías. La identificación de estos expertos no solo facilitará la formación de equipos de trabajo altamente competentes, sino que también promoverá una cultura organizacional orientada a la innovación y mejora continua.

2. Conceptos básicos en el análisis de redes organizacionales

El Análisis de Redes Organizacionales (ONA, por sus siglas en inglés) se basa en la teoría del análisis de redes sociales. Este enfoque considera redes sociales como cualquier grupo de personas o comunidades que comparten algún tipo de relación, y no debe confundirse con las plataformas tecnológicas llamadas redes sociales. Además, el análisis se fundamenta en gran medida en la teoría de grafos.

2.1. Definición ONA

ONA es una herramienta utilizada para identificar y comprender las interacciones y relaciones dentro de una organización. Cross, Borgatti y Parker afirman que es una poderosa herramienta de gestión porque hace visibles los patrones de intercambio de información entre empleados y equipos (Cross, Borgatti, & Parker, 2002).

2.2. Tipos de ONA

Según el método de recolección de datos, los tipos de ONA se clasifican en pasivos o activos.

- **Pasivos:** Los datos se recopilan mediante la huella digital de los empleados, como correos electrónicos, plataformas de chat de la organización u otras herramientas de interacción. La ventaja de este método es que proporciona evidencia concreta de las relaciones entre empleados, aunque no especifica la naturaleza de dichas relaciones. Sin embargo, puede generar preocupaciones respecto a la privacidad de la información.
- **Activos:** Los datos se obtienen a través de encuestas o entrevistas. Este método permite conocer el tipo de relación que existe entre los empleados, aunque depende de la disposición de los empleados a completar las encuestas. La calidad de la información puede verse afectada si se omiten relaciones o se reportan relaciones inexistentes.

Los ONAs pasivos son útiles para tener una certeza sobre la existencia de relaciones entre empleados, mientras que los ONAs activos proporcionan una comprensión más detallada sobre la naturaleza de esas relaciones, a pesar de las limitaciones mencionadas.

© ADIC-IIC

ISSN: 2792-3770

2.3. Teoría de grafos

La teoría de grafos proporciona el marco matemático fundamental para el análisis de redes sociales u organizacionales. En esta teoría, una red se representa como un grafo, compuesto por nodos (también conocidos como vértices) y enlaces.

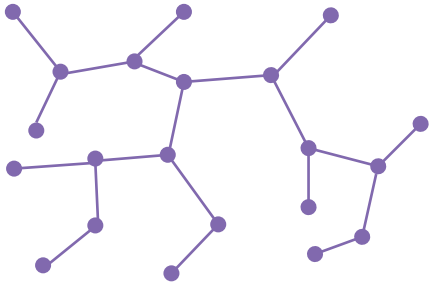


Figura 1. Representación gráfica de una red (grafo). (Bianco, 2016)

2.3.1. Nodos o vértices

Son los puntos en un grafo, que suelen representar las entidades individuales dentro de la red. En el caso del ONA, los nodos representan a las personas o equipos dentro de la organización.

2.3.2. Enlaces

Son las conexiones entre los nodos, y representan las relaciones o interacciones entre las entidades (Diestel, 2017). En el caso del ONA, estas entidades son las personas o equipos, y los enlaces muestran cómo se relacionan o interactúan entre sí.

2.3.3. Tipos de redes

Existen dos tipos principales de redes: dirigidas y no dirigidas.

- Dirigidas: En estas redes, el sentido de la relación es relevante. Por ejemplo, no es lo mismo que el empleado A envíe un correo al empleado B, que el empleado B envíe un correo al empleado A. La dirección de la interacción importa y puede influir en el análisis de la red.
- No dirigidas: En estas redes, el sentido de la relación no tiene importancia. Por ejemplo, es indiferente decir que el actor X participa en la película Y o que en la película Y participa el actor X. Lo crucial es la existencia de la relación, no su dirección.

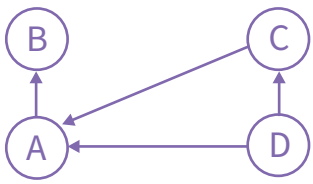


Figura 2. Grafo dirigido

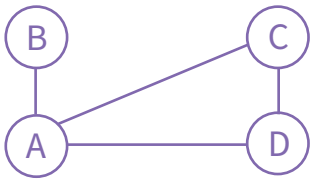


Figura 2. Grafo no dirigido

2.4. Métricas

Existen diferentes métricas según el nivel del análisis de las redes organizacionales, ya sea de manera estructural (considerando la red en su totalidad), grupal o individual.

2.4.1. Estructural

- **Densidad:** Mide la proporción entre las conexiones existentes y el número máxi-mo de conexiones posibles en la red.
- **Diámetro:** Es la longitud máxima de los caminos más cortos entre todos los pares de nodos en la red.
- **Distancia media:** Es la longitud promedio de los caminos más cortos entre todos los pares de nodos.
- **Reciprocidad:** Mide la proporción de co-nexiones que son bidireccionales, es decir, cuando un par de nodos se seleccionan mutuamente. Esta métrica solo es rele-vante en redes dirigidas.
- **Coeficiente de clustering o agrupa-miento:** Es la probabilidad de que dos ve-cinos de un nodo, seleccionados al azar, estén conectados entre sí (Easley & Klein-berg, 2010). En otras palabras, mide la tendencia de los nodos a formar grupos fuertemente conectados.
- **Componentes:** Es el total de subconjuntos conexos en la red. Un componente conexo es un subconjunto de nodos donde cada nodo tiene un camino hacia todos los demás nodos del subconjunto, y el subconjunto no es parte de un conjunto mayor (Easley & Kleinberg, 2010).

© ADIC-IIC

ISSN: 2792-3770

2.4.2. Grupal

- **Asortatividad de grado:** Mide el nivel de conexión entre nodos con grados similares. Un valor positivo indica que los nodos tienden a conectarse entre ellos, mientras que un valor negativo sugiere lo contrario.
- **Detección de comunidades:** Aunque no es una métrica en sí misma, son algoritmos robustos que identifican grupos focales al interior de la red.

2.4.3. Individual

La métrica principal a nivel individual es la centralidad, que mide la importancia o influencia de un nodo dentro de la red. Existen varios tipos de centralidad, entre ellos:

- **Grado:** Es el número de conexiones directas que tiene un nodo. En una red dirigida, se pueden medir las conexiones que entran y las que salen por separado. Esta métrica indica qué nodo es más influyente o está mejor conectado en la red.
- **Grado en n-pasos:** Por ejemplo, si n es igual a 2, se consideran las conexiones directas del nodo y las conexiones de los nodos conectados directamente a él.
- **Cercanía:** Es la suma de las distancias más cortas desde un nodo a todos los demás nodos. Esta métrica muestra qué nodo es más accesible o está más próximo a los demás en la red, indicando un alto nivel de accesibilidad social.
- **Intermediación:** Es el número de veces que un nodo aparece en los caminos más cortos entre otros nodos. Esta métrica indica qué nodo actúa como puente entre otros nodos, reflejando su rol como mediador social en la red.

3. Herramientas de automatización digital: Conceptos y aplicaciones

Las herramientas de automatización digital logran una mayor eficiencia operativa al reducir el tiempo dedicado a tareas repetitivas. Aunque existen muchas herramientas en el mercado, este estudio se enfoca en cuatro específicas, ya que son las actualmente establecidas en la organización.

- **Power BI:** Es una herramienta de visualización de datos que permite automatizar informes y mejorar la disponibilidad de la información, facilitando la toma de decisiones. Uno de los casos de uso más comunes es la automatización de tableros de control (dashboards), que consolidan las principales métricas y KPI's de la organización para facilitar su monitoreo en tiempo real.
- **Power Automate:** Es una herramienta que permite crear flujos de trabajo para automatizar tareas repetitivas, optimizando así los procesos internos. Un ejemplo común es la automatización del envío de correos electrónicos de notificación tras completar un formulario en Microsoft Forms, lo que elimina la necesidad de realizar este paso manualmente y asegura una respuesta rápida.
- **Power Apps:** Es una herramienta que facilita la creación de aplicaciones, mejorando la captura y gestión de información dentro de la organización. Por ejemplo, en el área de recursos humanos, se puede desarrollar una aplicación para registrar y hacer seguimiento de los indicadores de desempeño de los empleados, lo que permite un manejo más eficiente de la información.
- **Uipath StudioX:** Es una herramienta de RPA (Robotic Process Automation) que se utiliza para automatizar tareas repetitivas, aumentando la eficiencia y reduciendo errores humanos. Un ejemplo sería automatizar la descarga y procesamiento de información desde un sitio web de terceros, ahorrando tiempo y reduciendo la intervención manual en tareas repetitivas.

© ADIC-IIC

ISSN: 2792-3770

4. Objetivos del estudio

El objetivo principal de este caso de estudio es identificar a los expertos en cada una de las herramientas de automatización digital mencionadas anteriormente y comprender cómo fluye el conocimiento relacionado con estas herramientas dentro de la organización. A continuación, se plantean algunas preguntas para resolver dicho objetivo.

- ¿Quiénes son los expertos a los que acuden las personas cuando tienen dudas sobre cada herramienta?
- ¿Cómo se lleva a cabo la transferencia de conocimiento dentro y entre diferentes áreas de la organización?
- ¿Existen áreas dentro de la organización donde no se cuenta con ningún experto en estas herramientas?

5. Método

En este caso de estudio, se implementó un ONA activo, estructurando el enfoque en varias etapas clave que facilitaron la recopilación y análisis sistemático de los datos, así como la presentación de los principales hallazgos.

5.1. Estructuración y construcción del mecanismo de recogida de datos

Inicialmente, se definió la pregunta principal de la encuesta para capturar las relaciones entre las personas y los posibles expertos. La pregunta se formuló de la siguiente manera: "Selecciona aquellas personas a las cuales acudes cuando tienes alguna duda sobre la herramienta X para que te asesore o te brinde algún consejo", donde X representa cada una de las herramientas definidas para el estudio.

Posteriormente, se desarrolló la herramienta de captura de información utilizando Power Apps y listas de SharePoint. En la experiencia del aplicativo creado, primero se solicita al usuario que elija las herramientas que utiliza, incluyendo la opción de marcar "ninguna". Según su selección, se le formulará la pregunta principal para cada herramienta elegida.

5.2. Definición de participantes y envío de encuesta

En esta etapa, se determinaron las personas de interés para participar en el estudio, teniendo en cuenta los empleados que han desarrollado o publicado soluciones utilizando las herramientas de estudio.

Con base a esto, se invitó a un total de 945 empleados a participar, considerando que un empleado podría utilizar más de una herramienta de automatización.

La Tabla 1 muestra la distribución esperada de participantes por cada herramienta.

Herramienta	Empleados objetivo
Power BI	*592*
Power Automate	*439*
Power Apps	*252*
UiPath StudioX	*197*

Tabla 1. Participantes esperados por cada herramienta

Finalmente, se diseñó una estrategia de comunicación clara, enfatizando el propósito del estudio y asegurando que la encuesta no requeriría mucho tiempo, con el objetivo de fomentar la participación de los empleados.

© ADIC-IIC

ISSN: 2792-3770

5.3. Procesamiento y análisis de los resultados

En esta etapa, se analizó tanto la participación general como específica por cada herramienta de automatización digital, seguido del análisis de las redes generadas para obtener una visión clara del conocimiento organizacional y la red de expertos.

Un total de 405 personas completaron la encuesta, lo que representa un porcentaje general de participación del 43%. La Tabla 2 detalla la participación por cada herramienta específica.

Herramienta	Participación
Power Apps	67%
Power BI	57%
UiPath StudioX	53%
Power Automate	38%

Tabla 2. Porcentaje de participación por cada herramienta

Antes de proceder con el análisis, se realizó un preprocesamiento de los datos. Se excluyeron los empleados que indicaron no utilizar ninguna de las herramientas, asegurando que el análisis se centrara exclusivamente en los usuarios activos de las tecnologías estudiadas. Además, se integraron los datos con información relevante de los empleados, como roles y áreas de trabajo.

Para el análisis de redes, se empleó la librería igraph en RStudio, que proporcionó las funciones necesarias para explorar y calcular las métricas principales de cada red, permitiendo entender las interacciones de los participantes. La representación gráfica de las redes resultantes se realizó con la ayuda de la librería visNetwork, facilitando la visualización de estructuras complejas de red.

Es crucial destacar la complejidad inherente a la visualización de redes con un gran número de nodos y conexiones, lo cual implica desafíos significativos en términos de interpretación y análisis.

5.4. Documentación, presentación y posibles impactos de los resultados

Esta etapa final, se enfocará en la documentación y presentación de los resultados obtenidos del estudio. Los resultados serán presentados al área de aprendizaje organizacional en recursos humanos, ya que los hallazgos y datos proporcionados serán de gran valor para ellos.
La presentación de los resultados incluirá un tablero interactivo en Power BI, que permita explorar los datos de manera dinámica y detallada. Este tablero facilitará la visualización de las redes de expertos y el flujo de conocimiento, permitiendo un análisis más profundo y personalizado.

Adicionalmente, se entregará una presentación que resuma los principales resultados y conclusiones del estudio. Esta presentación destacará los expertos identificados para cada herramienta, las áreas de la organización que requieren mayor apoyo en términos de conocimiento, y cómo se transfiere el conocimiento entre las diferentes áreas.



© ADIC-IIC

ISSN: 2792-3770

Los impactos esperados de los resultados del estudio se relacionan en la siguiente tabla:

ACCIÓN	IMPACTOS
Implementar una cultura de comunidades de aprendizaje, con los referentes técnicos actuando como moderadores o líderes principales.	• Mejorar y acelerar la democratización de estas tecnologías. • Reducir costos al disminuir la necesidad de contratar aliados externos. • Promover la colaboración y el intercambio de conocimiento entre los empleados, fortaleciendo el trabajo en equipo. • Estimular la innovación al permitir tener un espacio para compartir ideas y soluciones.
Construir y publicar un directorio que permita a todos los empleados identificar y contactar a los referentes técnicos para resolver inquietudes.	• Reconocer y dar visibilidad a los referentes técnicos. • Mejorar la experiencia de los empleados al facilitarles el contacto con expertos para resolver dudas. • Aumentar la eficiencia operativa al reducir el tiempo que los empleados tardan en encontrar respuestas a sus inquietudes.
Identificar los equipos de la organización que requieren más acompañamiento o mejor comunicación sobre las formas disponibles para adquirir conocimientos en estas herramientas.	• Acelerar la transformación digital en los equipos identificados.
Dar formación especializada a los referentes técnicos para que puedan replicar el conocimiento al interior de la organización.	• Introducir nuevos conocimientos a la organización. • Fidelizar y desarrollar a los referentes técnicos. • Fortalecer la capacidad de la organización para adaptarse rápidamente a nuevos desafíos tecnológicos.

Tabla 3. Acciones e impactos

© ADIC-IIC

ISSN: 2792-3770

6. Resultados

En esta sección, se presentan los resultados del análisis de redes organizacionales realizado para cada herramienta de automatización digital definida. Cada herramienta fue analizada de forma independiente, proporcionando una visión específica de los expertos y del flujo de conocimiento dentro de la organización para cada herramienta, dado que cada una cumple con propósitos distintos y, por lo tanto, involucra conocimientos especializados que no necesariamente se superponen.

Este enfoque permite reconocer que, aunque las herramientas comparten una plataforma común, sus diferencias no solo influyen en la manera en que se implementan y utilizan dentro de la organización, sino también en los perfiles y competencias de los expertos que las gestionan. Al analizar cada red de manera separada, se ha obtenido una comprensión más precisa de las conexiones y del flujo de conocimiento específico dentro de cada área. Además, esta separación facilita la identificación clara de los desafíos y oportunidades particulares de cada herramienta, lo que optimiza la planificación estratégica y el desarrollo de competencias dentro de la organización.

La métrica principal utilizada para identificar a los expertos fue la de grado a dos pasos. Esta métrica no solo considera el número de conexiones directas que tiene una persona (grado), sino también las conexiones de sus conexiones, es decir, las personas referenciadas por otros expertos. Esto permite identificar no solo a los expertos directos, sino también a aquellos que son reconocidos por otros expertos, lo cual es crucial para capturar la verdadera extensión del conocimiento y la influencia dentro de la red.

Para definir quiénes son considerados expertos, se estableció un umbral de grado a dos pasos igual o superior a 3 para todas las herramientas. Este umbral se determinó observando la distribución long tail de los datos, donde se aprecia que la curva de distribución de grado se suaviza. Una distribución long tail es aquella en la que un pequeño número de nodos (en este caso, personas) tienen un grado muy alto, mientras que la mayoría tiene un grado bajo. Este tipo de distribución es común en redes sociales y organizacionales, y el punto donde la curva se suaviza indica una transición entre los nodos más influyentes y el resto de la red.

Al utilizar el grado a dos pasos y establecer el umbral en 3, se puede determinar que las personas identificadas como expertos son aquellas que no solo tienen un alto grado de conexiones directas, sino también una notable influencia reconocida por otros expertos en la red.

Cada nodo de una red representa a un empleado y este no necesariamente participó diligenciando la encuesta, dado que todo participante podría seleccionar a cualquier empleado de la organización, y cada enlace representa dicha selección, indicando que existe una relación entre los empleados (nodos) presentes.

6.1. Red Power BI

Para esta red participaron 339 empleados, lo cual equivale a un 57% de participación de lo esperado para esta herramienta.

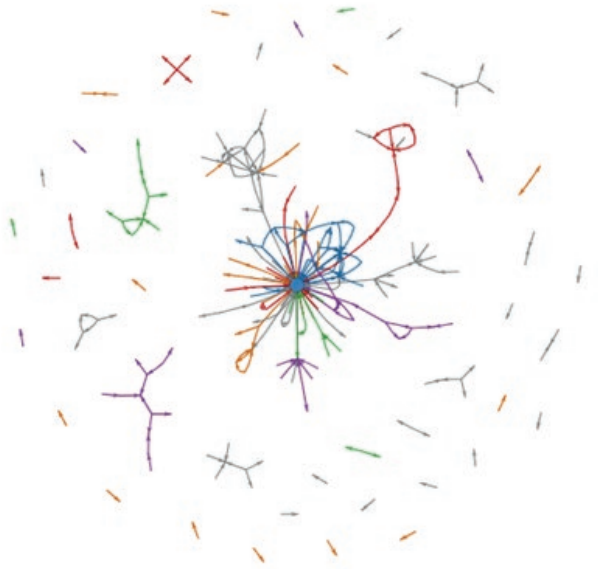


Figura 4. Red Power BI

© ADIC-IIC

ISSN: 2792-3770

En la Tabla 4 se observan las métricas principales de la red.

TIPO	MÉTRICA	RESULTADO
General	Nodos	259
	Enlaces	261
Distancia	Diámetro	5
	Distancia media	1.374
Conectividad	Densidad	0.004
	Reciprocidad	0.023
	Asortatividad de grado	-0.076
	Máximo grado de entrada	52
	Máximo grado de salida	4
Estructura	Transitividad	0.059
	Centralización de grado de entrada	0.198
	Componentes	43
	Nodos componente más larga	130 (50.19%)
	Enlaces componente más larga	172 (65.90%)

Tabla 4. Métricas red Power BI

Esta red consta de 259 empleados(nodos) y 261 interacciones o relaciones(enlaces). Se tiene un diámetro de 5 y una distancia media de 1.4, indicado que los nodos están relativamente bien conectados. La densidad es 0.004, mostrando una red muy dispersa, y la reciprocidad es 0.023, sugiriendo pocas conexiones bidireccionales. La asortatividad de grado -0.076, indicando una ligera tendencia a que nodos se conecten con otros de distinto grado. Finalmente, la red tiene 43 componentes, revelando múltiples subgrupos internos no conectados entre sí. La subred más grande de esta red contiene al 50% de los empleados, eso quiere decir, que la mitad de los empleados de la red de alguna forma están conectados.
Para esta red se tienen 21 expertos, de los cuales se tiene al menos uno en 8 áreas diferentes de la organización (57%). Y se tiene que el área predominante transfiere conocimiento a 10 áreas diferentes dentro de la organización (71%). Además, en todas las áreas existe evidencia de que al menos una persona transmite el conocimiento.

© ADIC-IIC

ISSN: 2792-3770

6.2. Red Power Automate

Para esta red participaron 168 empleados, lo cual equivale a un 38% de participación de lo esperado para esta herramienta.

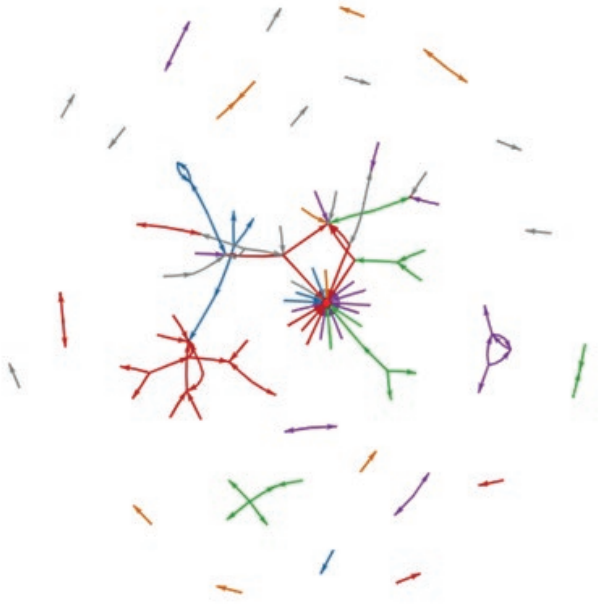


Figura 6. Red Power Automate

En la Tabla 5 se observan las métricas principales de la red.

Tipo	Métrica	Resultado
General	Nodos	132
	Enlaces	113
Distancia	Diámetro	3
	Distancia media	1.21
Conectividad	Densidad	0.007
	Reciprocidad	0.035
	Asortatividad de grado	-0.298
	Máximo grado de entrada	21
	Máximo grado de salida	4
	Transitividad	0.027
	Centralización de grado de entrada	0.154
Estructura	Componentes	26
	Nodos componente más larga	51 (38.64%)
	Enlaces componente más larga	54 (47.79%)

Tabla 5. Métricas red Power Automate

© ADIC-IIC

ISSN: 2792-3770

Esta red consta de 132 empleados(nodos) y 113 interacciones o relaciones(enlaces). Se tiene un diámetro de 3 y una distancia media de 1.21, lo que indica que los nodos están muy bien conectados. La densidad es 0.007, mostrando una red dispersa, y la reciprocidad es 0.035, sugiriendo algunas conexiones bidireccionales. La asortatividad de grado es 0.298, indicando una tendencia significativa a que nodos se conecten con otros de distinto grado. Finalmente, la red tiene 26 componentes, revelando múltiples subgrupos internos no conectados entre sí. La subred más grande de esta red contiene al 39% de los empleados de esta.

Para esta red se tienen 7 expertos, de los cuales se tiene al menos uno en 2 áreas diferentes de la organización (14%). Y se tiene que el área predominante transfiere conocimiento a 8 áreas diferentes dentro de la organización (57%). Además, se tiene que el 21% de las áreas no muestra evidencia de compartir conocimiento.

6.3. Red Power Apps

Para esta red participaron 168 empleados, lo cual equivale a un 67% de participación de lo esperado para esta herramienta.

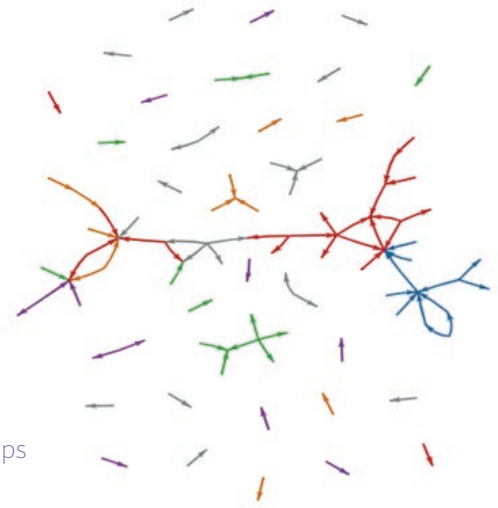


Figura 8. Red Power Apps

En la Tabla 6 se observan las métricas principales de la red.

TIPO	MÉTRICA	RESULTADO
General	Nodos	121
	Enlaces	93
Distancia	Diámetro	4
	Distancia media	1.32
Conectividad	Densidad	0.006
	Reciprocidad	0
	Asortatividad de grado	-0.068
	Máximo grado de entrada	6
	Máximo grado de salida	4
Estructura	Transitividad	0.069
	Centralización de grado de entrada	0.044
	Componentes	33
	Nodos componente más larga	44 (36.36%)
	Enlaces componente más larga	48 (51.61%)

Figura 8. Red Power Apps

© ADIC-IIC

ISSN: 2792-3770

Esta red consta de 121 empleados(nodos) y 93 interacciones o relaciones(enlaces). Se tiene un diámetro de 4 y una distancia media de 1.32, lo que indica una buena conectividad entre los nodos. La densidad es 0.006, mostrando una red dispersa, y la reciprocidad es 0, indicando que no hay conexiones bidireccionales. La asortatividad de grado es -0.068, señalando una leve tendencia a que los nodos se conecten con otros de distinto grado. Finalmente, la red tiene 33 componentes, revelando múltiples subgrupos internos no conectados entre sí. La subred más grande de esta red contiene al 36% de los empleados de esta.

Para esta red se tienen 8 expertos, de los cuales se tiene al menos uno en 5 áreas diferentes de la organización (36%). Y se tiene que el área predominante transfiere conocimiento a 8 áreas diferentes dentro de la organización (57%). Además, se tiene que el 14% de las áreas no muestra evidencia de compartir conocimiento.

6.4. Red UiPath StudioX

Para esta red participaron 104 empleados, lo cual equivale a un 53% de participación de lo esperado para esta herramienta.

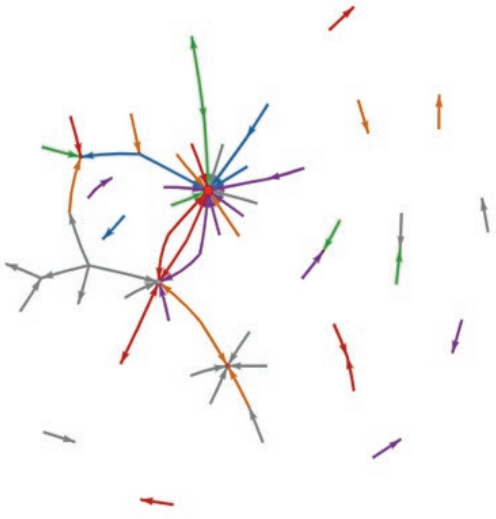


Figura 10. Red UiPath StudioX

En la Tabla 7 se observan las métricas principales de la red.

TIPO	MÉTRICA	RESULTADO
General	Nodos	74
	Enlaces	63
Distancia	Diámetro	2
	Distancia media	1.125
Conectividad	Densidad	0.012
	Reciprocidad	0
	Asortatividad de grado	-0.077
	Máximo grado de entrada	17
	Máximo grado de salida	4
Estructura	Transitividad	0
	Centralización de grado de entrada	0.221
	Componentes	14
	Nodos componente más larga	45 (60.81%)
	Enlaces componente más larga	47 (74.60%)

Tabla 7. Métricas red UiPath StudioX

© ADIC-IIC

ISSN: 2792-3770

Esta red consta de 74 empleados(nodos) y 63 interacciones o relaciones(enlaces). Se tiene un diámetro de 2 y una distancia media de 1.125, lo que indica una excelente conectividad entre los nodos. La densidad es 0.012, mostrando una red algo dispersa, y la reciprocidad es 0, indicando que no hay conexiones bidireccionales. La asortatividad de grado es -0.077, señalando una leve tendencia a que los nodos se conecten con otros de distinto grado. Finalmente, la red tiene 14 componentes, revelando varios subgrupos internos no conectados entre sí. La subred más grande de esta red contiene al 61% de los empleados de esta.

Para esta red se tienen 4 expertos, de los cuales se tiene al menos uno en 2 áreas diferentes de 14 posibles (14%). Y se tiene que el área predominante transfiere conocimiento a 10 áreas diferentes dentro de la organización (71%). Además, se tiene que el 57% de las áreas no muestra evidencia de compartir conocimiento.

7. Discusión y conclusiones

La organización ha implementado una serie de iniciativas estratégicas para fortalecer las competencias digitales, incluyendo una comunidad interna dedicada al desarrollo de habilidades en Power BI, liderada por el área de talento humano. Además, el área de automatización ha estado trabajando activamente en una iniciativa de democratización del conocimiento en Power Automate, Power Apps y UiPath StudioX, con el objetivo de extender estas habilidades a través de la organización de manera inclusiva y efectiva.

El análisis ha mostrado variaciones significativas en la transferencia de conocimiento entre las diferentes herramientas. Power BI destacó como la herramienta con evidencia más robusta de transferencia de conocimiento en todas las áreas de la organización y es la que mejor distribuye a los expertos en las diferentes áreas.

En contraste, se identificó que en UiPath StudioX, Power Apps y Power Automate existen áreas donde no se evidencia una transferencia efectiva de conocimiento. Estos hallazgos sugieren áreas de oportunidad para mejorar las estrategias de colaboración y capacitación, con el fin de optimizar la eficiencia operativa y fomentar la innovación tecnológica en toda la organización.
Al comparar la cantidad de expertos identificados para cada herramienta en relación con el total de usuarios, se observan diferencias significativas. En el caso de Power BI, los expertos representan el 3.5% de la población total de usuarios, mientras que para Power Apps, este porcentaje es del 3.2%. Por otro lado, Power Automate y UiPath StudioX tienen porcentajes de expertos del 1.6% y 2% respectivamente.

Estos resultados son satisfactorios y responden a los objetivos y preguntas planteadas. Mejorando la participación se podría profundizar en el entendimiento de cómo fluye el conocimiento en la organización y obtener certeza sobre la transferencia de conocimiento en áreas donde no se evidenció. La participación actual brinda confianza en los expertos identificados, y gracias a esto, se podrán implementar estrategias que sigan impulsando la transformación digital dentro de la organización.

© ADIC-IIC

ISSN: 2792-3770

8. Referencias bibliográficas

- Cross, R., Borgatti, S. P., & Parker, A. (2002). Making Invisible Work Visible: Using Social Network Analysis to Support Strategic Collaboration. California Management Review, 44(2), 25-46.
- Smith, J. (2014). The Implications of Passive Data Collection in Organizational Network Analysis. Journal of Organizational Computing and Electronic Commerce, 24(2-3), 196-215.
- Diestel, R. (2017). Graph Theory. Springer.
- Bianco, S. (2016). Análisis Comparativo de Algoritmos de Minería de Subgrafos Frecuentes. Revista Latinoamericana de Ingenieria de Software. 4. 111. 10.18294/relais.2016.111-142.

© ADIC-IIC

ISSN: 2792-3770

ARTÍCULO 03

© ADIC-IIC

ISSN: 2792-3770



.03

¿Puntuar Automáticamente las Entrevistas de Vídeo Asíncronas (AVIs) Mediante el Análisis de la Señal de Audio?

Automatically Scoring Asynchronous Video Interviews via Audio Signal Analysis?

Borja Artiñano
Instituto de Ingeniería del Conocimiento

Correo electrónico:
borja.artinano@iic.uam.es

Linkedin:
https://www.linkedin.com/in/borja-artinano/

David Aguado García
Universidad Autónoma de Madrid - Instituto de Ingeniería del Conocimiento

Correo electrónico:
david.aguado@iic.uam.es

Linkedin:
https://www.linkedin.com/in/davidaguado/

Received: 8/05/2025
Received in revised form: 14/05/2025
Accepted: 20/05/2025
Available on-line: 15/10/2025

© ADIC-IIC

ISSN: 2792-3770



Resumen

El uso de Video Entrevistas Asíncronas (AVIs, del inglés) ha aumentado dramáticamente en los últimos años, ofreciendo ventajas respecto de otros formatos de entrevista tradicional, como son una reducción de costes o mayor rapidez en los procesos de selección. Los avances del Aprendizaje Automático permiten puntuar automáticamente las AVIs en rasgos psicológicos mediante el análisis de, entre otras señales, la prosodia del hablante. A pesar de su extendido uso, pocos estudios han investigado aspectos psicométricos básicos como la fiabilidad o dimensionalidad de los indicadores extraídos, especialmente en entornos poco controlados, como son aquellos característicos del uso de AVIs.

El presente trabajo tiene tres objetivos: a) Estudiar la fiabilidad de un set de indicadores paraverbales extraídos de un conjunto de AVIs; b) Evaluar como la duración de la señal de audio afecta a esta fiabilidad; y c) Investigar la dimensionalidad de los indicadores que resultan fiables y no redundantes. Se dispone de una muestra de 39 estudiantes de Grado y Posgrado, que se grabaron respondiendo una pregunta típica de este contexto. Para evaluar la fiabilidad se empleó el Coeficiente de Correlación Intraclase, para detectar redundancia se empleo Unique Variable Analysis, y para estudiar la dimensionalidad se realizó un Análisis Factorial. Los resultados indican que cerca del 77% de los indicadores son adecuadamente fiables, si bien algunos muestran excesiva redundancia. La solución factorial alcanzada fue de 6 factores, que explican un 73% de la varianza total. Estos resultados son relevantes de cara al uso de AVIs en procesos de evaluación de personal, especialmente de cara al desarrollo de modelos interpretables.

Palabras clave

Video Entrevista Asíncrona (AVI), Evaluación Automática, Analítica de Voz, Procesamiento de Señales, Prosodia, HR Analytics, Psicometría.

Abstract

The use of Asynchronous Video Interviews (AVIs) in personnel selection has increased dramat-ically in recent years, offering several advantages over traditional interview formats, such as reduced costs and faster selection processes. Advances in Machine Learning have enabled the automatic scoring of AVIs on psychological traits through the analysis of various signals, including speaker prosody. Despite their growing use, few studies have investigated fundamental psy-chometric properties, such as the reliability and dimensionality of the extracted fea-tures—particularly in low-control environments typical of AVI settings.

This study has three main objectives: a) to assess the reliability of a set of paraverbal indicators extracted from a collection of AVIs; b) to evaluate how the duration of the audio signal affects this reliability; and c) to explore the dimensionality of the indicators that are both reliable and non-redundant. The sample consisted of 39 undergraduate and graduate students who recorded responses to a typical AVI question. Reliability was assessed using the Intraclass Correlation Coefficient; redundancy was examined through Unique Variable Analysis; and dimensionality was analyzed using Factor Analysis. The results show that approximately 77% of the indicators demonstrated acceptable reliability, although some exhibited high redundancy. A six-factor solu-tion was identified, explaining 73% of the total variance. These findings are relevant for the ap-plication of AVIs in personnel assessment, particularly for the development of interpretable scoring models.

Keywords

Asynchronous Video Interview (AVI), Automated assessment, Voice Analytics, Signal Processing, Prosody, HR Analytics, Psychometrics.

© ADIC-IIC

ISSN: 2792-3770

1. Introducción

1.1. Las Entrevistas de Vídeo Asíncronas (AVIs) en la Gestión de Recursos Humanos

En el ámbito de la selección de personal, las entrevistas por video asíncronas (AVIs, por sus siglas en inglés) se han convertido en una tecnología cada vez más utilizada en los procesos de reclutamiento. Este tipo de entrevistas consiste en que los candidatos graban respuestas en video a preguntas previamente definidas, utilizando una plataforma en línea u otro medio audiovisual que permite el intercambio de preguntas y respuestas grabadas entre el reclutador y el postulante. Posteriormente, estos videos son evaluados por expertos utilizando una rúbrica previamente establecida, generalmente durante la etapa de cribado del proceso de selección (Brenner et al., 2016).

Las AVIs presentan tres ventajas principales frente a las entrevistas presenciales: (1) Son más económicas y rápidas, ya que requieren menos tiempo del personal involucrado (Brenner et al., 2016); (2) Permiten una mayor estructuración de la entrevista, lo que puede traducirse en una mejora de su fiabilidad y validez (Dunlop et al., 2022); y (3) Son digitales, es decir, pueden grabarse y almacenarse (Lukacik et al., 2021). Esta última característica no solo facilita que varios evaluadores puedan revisar y calificar las mismas respuestas grabadas, aumentando así la objetividad del proceso, sino que también abre la puerta al uso de técnicas de inteligencia artificial para calificar automáticamente las entrevistas

Diferentes estudios han abordado la cuestión de la validez de las puntuaciones pronosticadas en diferentes atributos personales (i.e. personality) a partir de estas puntuaciones obtenidas automáticamente a partir de las grabaciones en vídeo proporcionadas por las AVIs (Koutsoumpis et al., 2024; Liff et al., 2024, Hickman et al., 2022). La mayoría de ellos centrándose en la validez predictiva de las puntuaciones automáticas considerando de manera conjunta las diferentes señales provenientes de las AVIs. En nuestro trabajo pretendemos aportar valor en esta línea de caracterización psicométrica de las puntuaciones automáticas sobre las Avis, analizando la fiabilidad y la dimensionalidad subyacente de las puntuaciones obtenidas a partir de una de las señales proporcionadas por las AVIs: la señal de audio. La exploración de manera aislada de cada una de las señales proporcionadas por las AVIs contribuirá a una mejor comprensión de las distintas fuentes de información que dan lugar a la asignación de una puntuación final. Esto ofrece numerosas ventajas, desde permitir el estudio de las propiedades de cada una de las señales (su fiabilidad y validez) hasta facilitar la creación de sets de variables de diseño de acuerdo con el criterio que se desea predecir, pasando por la creación de marcos teóricos que permitan interpretar más adecuadamente el algoritmo y sus resultados. Este último aspecto, además de tener un valor intrínseco en sí mismo, puede ser de interés para las organizaciones de cara a ofrecer explicaciones que justifiquen el uso de AVIs a los candidatos.

1.2. ¿Qué información (señales) hay en las AVIs para que el entrevistador tome decisiones, y cómo se extrae automáticamente?

En las AVIs (y en cualquier entrevista), el candidato ofrece tres conjuntos de señales que el entrevistador utiliza para inferir las características psicológicas de interés para el proceso de selección: (a) información verbal, referida a lo que el candidato dice, es decir el contenido que constituye la respuesta que ofrece a las cuestiones planteadas por el entrevistador; (b) información no verbal, referida a lo que hace el candidato mientras está emitiendo su respuesta (por ejemplo, su expresión facial, su postura, su expresividad corporal); y (c) información paraverbal, referida a "cómo suena" la exposición verbal que realiza el candidato al emitir sus respuestas, en lo que conocemos como la prosodia.

En una AVI, en primer lugar, es necesario extraer previamente la información deseada y representarla en un conjunto de variables. Existen varias herramientas que permiten realizar este paso, según el tipo de información que se desee extraer. Para analizar la información verbal es común utilizar el Linguistic Inquiry and Word Count o LIWC (Pennebaker et al., 2015), que realiza un conteo de las palabras emitidas por el candidato y las clasifica de acuerdo con diccionarios y subdiccionarios preconstruidos y referidos a multitud de categorías. Por ejemplo, en una AVI, se podría recoger el porcentaje de palabras del candidato que aparecen en el subdiccionario

© ADIC-IIC

ISSN: 2792-3770

denominado como Insight, que se encuentra dentro de la categoría de Procesos Cognitivos, que a su vez se encuentra dentro de la categoría de Procesos Psicológicos. También se puede extraer información de tipo lingüística, como número total de palabras, orientación temporal (pasado, presente o futuro), porcentaje de palabras que sirven una función gramatical (pronombres, artículos, etc.), etc. Otra herramienta clásica en este contexto es el Latent Semantic Analysis o LSA, que permite analizar la semántica subyacente al texto (Landauer et al., 2007). Esta herramienta representa el significado de la respuesta del candidato en base a su saturación en un espacio vectorial de dimensiones abstractas, obtenido durante el entrenamiento mediante una reducción de dimensionalidad del corpus en base a la coocurrencia de términos en una unidad lingüística (generalmente, párrafos). Esta representación se puede comparar con otras respuestas (por ejemplo, la respuesta de un candidato ideal), para obtener una medida de la distancia entre ambas. Estas herramientas clásicas se pueden ver complementadas o sustituidas por otras más modernas basadas en el uso de redes neuronales y/o IA generativa.

En el caso de la información no verbal, esta puede extraerse a través de la herramienta openFace (Amos et al., 2016), si bien debe tenerse en cuenta que este programa tan solo procesa información referida a la cabeza, y no al resto del cuerpo. En concreto, OpenFace permite procesar y extraer las conocidas como Facial Action Units (FAU), provenientes del Facial Action Coding System (FACS). El FACS es un conjunto de movimientos faciales, observables y distinguibles entre sí, que permiten codificar casi cualquier expresión facial posible (Cohn et al., 2007). OpenFace, por tanto, permite registrar la ocurrencia e intensidad de estas acciones, cada una de las cuales recoge activaciones musculares específicas. También se extrae información relativa a la orientación de la cabeza y la mirada, y otros aspectos como el pestañeo.

Finalmente, para la extracción de la información paraverbal se pueden utilizar herramientas como openSmile (Eyben et al., 2010) o Praat (Boersma, 2001). Estos software open-source permiten estandarizar la extracción de determinadas variables acústicas a través de diferentes sets de parámetros. Existen multitud de variables paraverbales disponibles, como el tono, el volumen, frecuencias centrales en los formantes, pendiente espectral, segmentos de voz por segundo, etc. A estas se les aplican diferentes funciones que indexan diferentes aspectos de la variable, como su promedio, variación o aceleración. En openSmile, las distintas variables y funciones aplicadas se recogen en sets de parámetros disponibles para el usuario, que tan solo tiene que introducir el archivo de audio como input y seleccionar el set deseado. Habitualmente pueden encontrarse publicaciones que describen el set, su proceso de construcción, y su efectividad para predecir distintos criterios.

1.3. Extracción de Características Para-Verbales mediante eGeMAPS

Dos ventajas de openSmile son la fácil extracción y estandarización de los parámetros, lo que proporciona un marco común desde el que enfocar la investigación. Sin embargo, su ámbito de amplio espectro de aplicación y la gran cantidad de parámetros que presenta hacen que la utilización de modelos más limitados sean una buena opción en estudios exploratorios iniciales como el nuestro. Entre estos sets de parámetros, el elegido en este trabajo ha sido el Extended Geneva Minimalistic Acoustic Parameter Set, o eGeMAPS (Eyben et al., 2016). Esta decisión se fundamenta en 4 pilares: 1) Las variables que extrae el modelo están seleccionadas para maximizar el potencial de reflejar procesos fisiológicos relacionados con la comunicación afectiva; 2) Su reducido número de variables facilita la interpretación; 3) Ha sido empleado previamente y de forma exitosa en tareas relacionadas con la predicción de la personalidad (Solera-Ureña et al., 2016); y 4) Su éxito en estas tareas es comparable a aquel de sets de dimensionalidad muy superior (Eyben et al, 2016).

1.4. Objetivos del Estudio

El objetivo fundamental de nuestro estudio es realizar una primera exploración sobre cómo aplicar el conocimiento psicométrico relacionado con la fiabilidad y validez a puntuación automática de las AVIs en lo que tiene que ver con su señal de audio. Ello es importante por tres motivos. El primero es que, a pesar del potencial demostrado por las técnicas de aprendizaje automático para extraer estas características, su abordaje se ha realizado de manera ajena a la teoría psicométrica, que es fundamental para poder interpretar adecuadamente los resultados obtenidos en la evaluación.

© ADIC-IIC

ISSN: 2792-3770

El segundo motivo radica en la idea de que existen diferentes decisiones respecto de las características del audio a emplear para la puntuación automática y, también, diferentes características relacionadas con la duración y condiciones en la que se obtiene la señal de audio que inciden en la fiabilidad de las estimaciones. Los estudios previos parecen señalar el impacto que sobre la fiabilidad y validez de las medidas tiene la duración de la señal de audio analizada. Sin embargo, hasta donde llega nuestro conocimiento esta cuestión no ha sido analizada en el contexto de selección de personal en el que se utilizan las AVIs. Y, finalmente, además de escasos estudios centrados en explorar la dimensionalidad de las características extraídas automáticamente de la señal de audio, estos han sido realizados bajo diseños controlados alejados de la espontaneidad y flexibilidad que permiten las AVIs. Y, sin embargo, la exploración de esta cuestión es fundamental en el análisis de la validez de las puntuaciones automáticas extraídas a partir de la señal de audio obtenida de las AVIs.

En línea con lo anterior, nuestro propósito fundamental es acercarnos al significado psicológico que tiene la extracción automática de features de audio en el contexto de las AVIs. Las dos preguntas básicas que guían el trabajo son las siguientes.

Q1: ¿Son los indicadores paraverbales extraídos, que luego se usarán como predictores en modelos cuyo fin es puntuar automáticamente las entrevistar en personalidad u otros constructos psicológicos, estables a lo largo del tiempo? En concreto, nuestro objetivo es explorar a) ¿Qué duración es necesaria en las grabaciones de audio para que estas permitan obtener medidas estables de los indicadores extraídos automáticamente? Y b) ¿Son algunos indicadores más estables que otros?

RQ2: ¿Qué dimensionalidad subyace a las diferentes features acústicas extraídas automáticamente de las AVIs mediante eGemaps? Por tanto, ¿cómo se pueden interpretar las puntuaciones automáticas obtenidas mediante este procedimiento?

2. Método

2.1. Participantes

Los análisis de basaron en las grabaciones de 39 personas, todas mujeres, con una edad media de 25 años. La participación fue voluntaria. El estudio fue autorizado por el Comité de Ética de la Investigación de la Universidad Autónoma de Madrid.

2.2. Diseño de la AVI y procedimiento

Se simula un proceso de selección de personal para una posición en la que se busca incorporar a un individuo joven y con talento a una organización. Las instrucciones que recibieron los participantes fueron: “Narra una historia corta en la que incluyas las palabras ‘accidente aéreo’, ‘fuegos artificiales’, ‘camarera, ‘ Edad Media’ y ‘supermercado’. No se utilizó ninguna plataforma tecnológica estándar. Se instruyó a los participantes a inventar una historia con duración de entre uno y dos minutos, y se permitió regrabar la respuesta tantas veces como se desease.

2.3. Medidas obtenidas

Se extrajeron 88 indicadores paraverbales a partir del set eGeMAPS v02 (ver Eyben et al., 2016 para una descripción completa del set).

2.4. Análisis de Datos

Se emplearon las librerías de Python Moviepy y Pydub para preprocesar los ficheros de vídeo que contenían las respuestas a la entrevista, y el software openSmile para extraer los indicadores paraverbales, automatizado a través de un script de Python con la librería os. Para explorar la fiabilidad, se empleó el coeficiente de correlación intraclase de dos vías de efectos mixtos, en su versión de acuerdo absoluto (Stegmann et al., 2020; McGraw y Wong, 1996). En concreto, se evaluó la fiabilidad de los valores promedio de segmentos de audio de diferente duración.

Para el análisis de la dimensionalidad se seleccionaron las características que, en los pasos anteriores, han resultado aceptablemente fiables (CCI(2, k) > 0.75 en el segmento de 30 segundos), y se obtienen sus valores para el segmento

© ADIC-IIC

ISSN: 2792-3770

completo de 60 segundos. Como paso previo, se eliminan variables que, por motivos teóricos, se considera que no resultan de interés para el análisis de AVIs, como son: (a) el rango del percentil 20 al 80, al tener ya cada uno de esos percentiles por separado; (b) aquellas variables referidas al percentil 50, ya que muestran tener una correlación superior a 0.99 con aquellas referidas a la media; y (c) todas aquellas variables calculadas sobre segmentos sin voz, excepto aquellas referidas a la duración de los mismos y a su número. Posteriormente, se aplica Unique Variable Analysis para identificar variables redundantes (Christensen et al., 2023). Estos dos pasos permiten depurar los datos antes del estudio de dimensionalidad, lo cual es especialmente importante, teniendo en cuenta las limitaciones del tamaño muestral. Finalmente, se mantienen 50 indicadores. Para explorar la dimensionalidad de estas features, se emplean primero un Análisis Paralelo utilizando como punto de corte el centil 95 de los autovalores aleatorios, y posteriormente se realiza un Análisis Factorial Exploratorio a partir de la matriz de correlaciones de Pearson. Todos los análisis estadísticos se realizan con el software R, en concreto las librerías: 'dplyr', 'MVN', 'huge', 'EGAnet', 'psych', 'UVA', 'EFAtools' y 'EFA.dimensions'.

3. Resultados

3.1. Análisis de Fiabilidad

El estudio de la fiabilidad lo abordamos mediante dos pasos. En el primero de ellos se estudia qué longitud de audio es necesario utilizar para maximizar el número de características extraídas que son estables a lo largo del tiempo. Se dividen los audios disponibles en segmentos de 5s, 10s, 15s, 20s, 25s y 30s consecutivos. Fijando k = 2, se calcula el CCI(2, k) de efectos mixtos, para segmentos de cada duración posible, teniendo en cuenta que, salvo en las condiciones de 25s y 30s, los segmentos se eligen de forma aleatoria, y siempre se asegura que no existe solapamiento. Para estos CCI se obtiene el valor muestral y se realiza un contraste poniendo a prueba la hipótesis nula $H_0: CCI \leq 0.75$ con $\alpha = 0.05$, corrigiendo la Tasa de Error tipo 1 con el procedimiento de Benjamini – Hochberg (Benjamini y Hochberg, 1995).

En la Tabla 1 se presentan los resultados obtenidos.

Duración del Segmento de Audio	Nº de indicadores con CCI < 0.75*
5 segundos	41 (64)
10 segundos	25 (48)
15 segundos	13 (32)
20 segundos	15 (24)
25 segundos	14 (21)
30 segundos	13 (20)

*Entre paréntesis, número de indicadores para los que no se rechaza la hipótesis nula al 95% de confianza.

Los resultados muestran que, en general, el número de features que resultan estables aumenta al incrementarse la duración del segmento seleccionado, si bien entre los 15 y los 30 segundos la magnitud de las diferencias va comienza a descender. En estas duraciones, el número de features que ha resultado estable en la muestra es similar. Estos resultados contrastan con los de Almaghrabi et al. (2022) que, trabajando con el CCI muestral, encuentran grandes diferencias al pasar de segmentos de 30 segundos a segmentos de 60 segundos, incluso a pesar de trabajar de forma similar (empleando un único audio por sujeto, dividiéndolo en segmentos y calculando el CCI entre estos segmentos). Es posible que, aunque las diferencias de 5 segundos con las que trabajamos nosotros sean lo bastante pequeñas para no producir un efecto en el CCI muestral, doblar la longitud del audio sí que produzca resultados visibles. En cualquier caso, si atendemos a los resultados de los contrastes de hipótesis, sí que vemos que, al aumentar la duración, se incrementa el número de features cuyos valores son incompatibles con la hipótesis nula (al 95% de confianza).

En el segundo paso, y centrados ya en los segmentos de audio de únicamente 30 segundos, exploramos el grado en el que las características de audio extraídas automáticamente a partir de diferentes selecciones de 30 segundos dentro del mismo participante son estables. Para ello, se obtiene de nuevo el CCI de dos vías y efectos mixtos, por cada indicador.

© ADIC-IIC

ISSN: 2792-3770

Los resultados muestran que de las 88 características extraídas en por el modelo, 68 superan un CCI poblacional de 0.75, al 95% de confianza (75 superan ese mismo punto de corte con el CCI muestral), representando un 77% del total de features. Este resultado contrasta con los de Stegmann et al. (2020), que encontraron que tan solo el 11% de las más de 6000 features que analizaron superaban este punto de corte; y Feng et al. (2024), que encontraron que aproximadamente la mitad de las features evaluadas alcanzaban un valor de 0.5. Por supuesto, al utilizar diferentes sets de parámetros, diferente población, y diferentes tareas, los resultados son difícilmente comparables. En la Tabla 2 pueden apreciarse el número de características que se mantienen estables en función de diferentes puntos de corte.

Tabla 2. Número de features cuyo CCI (2,k) no supera

Punto de corte	Nº de features
$r = 0.5$	9 (13)
$r = 0.75$	13 (20)
$r = 0.9$	21 (39)

Nota: Entre paréntesis se incluyen los resultados del contraste de hipótesis al 95% de confianza.



En la Tabla 3 se muestran las características que no son estables y que, por tanto, entenderíamos que no ofrecen información fiable para el cálculo de puntuaciones automáticas. Como se ob-serva, las características menos estables (CCI < 0.75) son:

Tabla 3. Características No Estables

Característica Extraída	Descripción
F0semitoneFrom27.5Hz_sma3nz_meanRisingSlope *F0semitoneFrom27.5Hz_sma3nz_meanFallingSlope* *F0semitoneFrom27.5Hz_sma3nz_stddevRisingSlope* *F0semitoneFrom27.5Hz_sma3nz_stddevFallingSlope*	Reflect the speed (and its variability) and consistency with which the pitch of the voice rises or falls.
mfcc2_sma3_stddevNorm *mfcc3_sma3_stddevNorm* *mfcc4_sma3_stddevNorm* *mfcc2V_sma3nz_stddevNorm* *mfcc3V_sma3nz_stddevNorm* *mfcc4V_sma3nz_stddevNorm*	Reflect the variability (normalized standard deviation) of the MFCC coefficients (2, 3, and 4).
jitterLocal_sma3nz_stddevNorm	Normalized standard deviation of the local pitch instability (jitter).
slopeV0-500_sma3nz_stddevNorm	Normalized standard deviation of the spectral slope in the range of 0-500 Hz (distribution of energy in low frequencies).
logRelF0-H1-H2_sma3nz_stddevNorm	Normalized standard deviation of the logarithmic ratio between the first and second harmonics of the fundamental frequency (information about the harmonic structure of the voice

© ADIC-IIC

ISSN: 2792-3770

3.2. Análisis de Dimensionalidad

El Análisis Paralelo recomienda extraer 6 factores, que se concretan en una solución que explica el 73% de la varianza. El método de extracción escogido es el de Mínimos Cuadrados no Ponderados, y se emplea rotación Oblimin. Los factores presentan correlaciones de entre -0.19 y 0.27. De Winter et al. (2009) sugieren que correlaciones inter-factor de esta magnitud afectarán a la recuperación de parámetros del Análisis Factorial con un tamaño muestral pequeño, si bien no de forma exagerada.

En la Tabla 4 (en la siguiente página) se presenta la matriz patrón resultante. Se puede observar que presenta saturaciones en algunos casos muy elevadas particularmente en el primer factor, en el que 8 variables muestran una saturación superior a 0.9, y en el segundo, que presenta 5 variables con saturaciones superiores a 0.8 y otras 2 saturaciones superiores a 0.7. Si estas fueran las saturaciones poblacionales, la solución recuperada, incluso en la situación adversa en la que se encuentran nuestros datos, podría ser razonablemente estable (De Winter et al., 2009). Respecto a los factores restantes, tenemos pocas garantías de su estabilidad, en particular de los dos últimos.



© ADIC-IIC

ISSN: 2792-3770

Tabla 4. Matriz de Patrón de la solución de 6 factores

	F1	F2	F3	F4	F5	F6
F0semitoneFrom27.5Hz_sma3nz_amean	0.05	0.12	-0.05	***0.83***	-0.17	0.04
F0semitoneFrom27.5Hz_sma3nz_stddevNorm	0.18	0.22	0.04	***-0.81***	0.11	-0.12
loudness_sma3_amean	***0.95***	-0.16	-0.05	0.06	0.09	-0.01
loudness_sma3_stddevNorm	***0.31***	***0.4***	0.24	-0.09	***-0.66***	-0.02
loudness_sma3_percentile20.0	***0.63***	***-0.34***	-0.25	0.01	***0.32***	-0.07
loudness_sma3_percentile80.0	***0.97***	-0.12	-0.02	0.06	0.03	0
loudness_sma3_meanRisingSlope	***0.99***	0.03	0	0.01	-0.07	0.04
loudness_sma3_stddevRisingSlope	***0.99***	0.09	-0.02	-0.02	-0.07	0
loudness_sma3_meanFallingSlope	***0.98***	0.06	-0.06	-0.05	-0.06	0.01
loudness_sma3_stddevFallingSlope	***0.96***	0.11	-0.04	-0.1	-0.07	0
jitterLocal_sma3nz_amean	0.01	0.12	0.22	***-0.78***	0.05	-0.18
shimmerLocaldB_sma3nz_amean	0.02	0.1	0.27	***-0.76***	***-0.36***	0.11
shimmerLocaldB_sma3nz_stddevNorm	***0.32***	***0.58***	0.06	0.1	0.11	-0.07
HNRdBACF_sma3nz_amean	-0.01	0.19	0.07	***0.9***	0.05	-0.02
HNRdBACF_sma3nz_stddevNorm	-0.04	-0.2	-0.08	***-0.75***	0.02	-0.21
logRelF0-H1-H2_sma3nz_amean	-0.15	0.17	-0.17	0.04	0.08	-0.12
logRelF0-H1-A3_sma3nz_amean	-0.28	0.1	***0.64***	0.07	-0.15	0.18
logRelF0-H1-A3_sma3nz_stddevNorm	0.26	0.01	***-0.36***	***-0.38***	0.07	***-0.32***
F1frequency_sma3nz_amean	0	0.15	**0.3**	***0.38***	***-0.37***	-0.03
F1frequency_sma3nz_stddevNorm	-0.1	0.02	***-0.81***	-0.02	0.21	0.05
F1bandwidth_sma3nz_amean	-0.02	0.1	0.25	0.23	0.03	***0.67***
F1amplitudeLogRelF0_sma3nz_amean	0.12	***-0.84***	0.01	-0.16	0.12	-0.04
F1amplitudeLogRelF0_sma3nz_stddevNorm	0	***0.89***	-0.05	0.26	0.02	0.02
F2frequency_sma3nz_amean	-0.01	0.19	***0.38***	***0.51***	-0.18	-0.28
F2bandwidth_sma3nz_amean	0.04	0.06	-0.04	0.02	-0.07	***0.83***
F2amplitudeLogRelF0_sma3nz_amean	0.14	***-0.84***	-0.16	-0.1	0.08	0
F2amplitudeLogRelF0_sma3nz_stddevNorm	-0.06	***0.74***	0.28	0.15	0.29	-0.1
F3frequency_sma3nz_amean	-0.15	0.23	***0.35***	***0.38***	***-0.3***	***-0.34***
F3frequency_sma3nz_stddevNorm	0.1	0.02	-0.08	0.13	0	***0.71***
F3bandwidth_sma3nz_amean	-0.06	-0.06	-0.25	0.08	0.29	***0.62***
F3bandwidth_sma3nz_stddevNorm	0.01	0.22	-0.29	***0.5***	0.08	-0.22
F3amplitudeLogRelF0_sma3nz_amean	0.16	***-0.82***	-0.2	-0.09	0.11	-0.07
F3amplitudeLogRelF0_sma3nz_stddevNorm	-0.11	***0.69***	***0.37***	0.14	0.24	0.06
alphaRatioV_sma3nz_amean	0.04	***-0.3***	***-0.8***	-0.03	***-0.3***	0.11
alphaRatioV_sma3nz_stddevNorm	-0.06	0	***0.71***	-0.23	***0.5***	-0.08
hammarbergIndexV_sma3nz_amean	-0.16	0.26	***0.72***	0.03	0.07	0.07
hammarbergIndexV_sma3nz_stddevNorm	0.2	0.17	***-0.57***	***0.38***	***-0.37***	-0.18
slopeV0-500_sma3nz_amean	-0.22	-0.18	0.05	***0.41***	***-0.6***	-0.12
slopeV500-1500_sma3nz_amean	-0.16	0.07	***-0.82***	-0.05	0.27	0.13
slopeV500-1500_sma3nz_stddevNorm	0.11	-0.1	***0.73***	-0.05	0.08	-0.18
spectralFluxV_sma3nz_amean	***0.99***	0.02	0.16	0.04	0.04	0.01
mfcc1V_sma3nz_amean	0.01	0.08	***0.63***	-0.22	***-0.33***	0.26
mfcc1V_sma3nz_stddevNorm	0.1	0.02	***-0.57***	***0.38***	-0.03	***-0.3***
mfcc2V_sma3nz_amean	-0.07	0.27	***0.32***	0.08	***0.72***	-0.16
mfcc3V_sma3nz_amean	0.06	0.12	-0.14	-0.2	0.27	-0.23
mfcc4V_sma3nz_amean	0.12	0.12	-0.05	-0.15	***0.66***	0.25
VoicedSegmentsPerSec	0.04	***0.79***	-0.26	***-0.33***	0.1	0.03
MeanVoicedSegmentLengthSec	0.02	***-0.92***	0.29	***0.32***	0.02	0.06

© ADIC-IIC

ISSN: 2792-3770

4. Conclusiones

En conjunto, los resultados presentados en este estudio permiten realizar un acercamiento inicial a la exploración de la fiabilidad y validez de las puntuaciones automáticas obtenidas para la señal de audio en las AVIs. Respecto de la fiabilidad, se muestra que no todas las características que extraen los modelos automáticos son estables a lo largo del tiempo y que, por tanto, el empleo de estas características debiera de someterse a análisis a la hora de emplearlas en la estimación de puntuaciones automáticas. La señal de voz está sujeta a diferentes condicionantes externos que, evidentemente, condicionan su producción. Y en esa línea es razonable encontrar características que son menos estables y más dependientes de estos contextos que otras. Por otro lado, nuestro trabajo también arroja luz acerca de un parámetro operativo como es la longitud que debe tener un segmento de audio para que la extracción de puntuaciones a partir de él sea estable. Es una cuestión relevante ya que la carga computacional para desarrollar este tipo de procedimientos es grande y en búsqueda de la eficiencia una buena elección de la longitud de audio a analizar es relevante. Nuestro estudio muestra que con el aumento del número de segundos utilizados aumenta también el número de características que se mantienen estables. Con nuestros datos parece que utilizar segmentos de unos treinta – sesenta segundos puede ser una buena opción operativa. Finalmente, es relevante también en términos de fiabilidad, la identificación que realizamos de aquellas características del audio que parecen no ser estables en segmentos de 30 segundos.

Por otro lado, en este estudio también os acercamos a la exploración del significado psicológico de las características extraídas automáticamente. Mediante el Análisis Factorial Exploratorio realizado encontramos que, subyaciendo a las 50 características de audio exploradas, parecen existir 6 factores relevantes. Los factores, sin embargo, son de dudosa interpretación. En gran medida esto se debe a la dificultad de realizar interpretaciones sin tener en primer lugar garantías sobre la estabilidad de los factores obtenidos. Por tanto, para mejorar esta situación, sería conveniente repetir los análisis con un volumen de datos mayor, así como con una muestra más heterogénea.

FACTOR	DESCRIPCIÓN
Energía vocal	Incluye aspectos como el volumen y energía promedio empleados, su variación a lo largo del discurso, y la velocidad a la que aumentan o disminuyen. Es decir, perceptivamente, las personas con mayores puntuaciones hablan en promedio con un volumen más elevado, con más rango, y que varía más rápidamente.
Formantes y segmentos de voz	Relacionado con el empleo de segmentos de habla continuada más cortos y numerosos, en el discurso. Además, se asocia a una menor amplitud de los formantes estudiados, y una mayor variación. La amplitud de los formantes se relaciona con como de salientes son percibidos ciertos sonidos, como las vocales.
Calidad de la voz	Incluye los indicadores Alpha Ratio y Hammarberg Index, que son utilizados para evaluar la claridad de la voz. También incluye otros indicadores como el MFCC1, o el flujo espectral.
Agradabilidad/ Estabilidad	Muestra saturaciones elevadas en el Harmonics to Noise Ratio, que refleja una señal de audio estable y periódica. También se asocia a valores inferiores para el jitter y el shimmer, que indican que el volumen y el tono son más estables, y a un tono más elevado.
MFCC	Factor en el que destacan los componentes MFCC. Estos indicadores, por sí solos, no tienen una correspondencia perceptiva directa, pero han mostrado ser útiles en un amplio espectro de tareas relacionadas con el procesamiento de la voz. También aparecen representados otros indicadores con saturaciones cruzadas en otros factores.
Ancho de banda de los formantes	Factor representado principalmente por el ancho de banda de los formantes, que es mayor. Hay varios posibles correlatos, tanto perceptivos como fisiológicos, a estos indicadores, como puede ser una voz más cansada.

© ADIC-IIC

ISSN: 2792-3770

Como se ha comentado previamente, el reciente trabajo de Feng et al. (2024) identificó una solución de 9 componentes que explicaba alrededor de un 80% de la varianza, y la de Van Rijn y Larrouy-Maestri (2023) un 57% con 7 factores. Nuestra solución, con tan solo 6 factores, ha logrado explicar un 73% de la varianza del set total, encontrándose los factores mejor definidos, con un mínimo de 4 variables relevantes por factor.

Más allá de estos aspectos, quedan muchos interrogantes sin responder de cara a la aplicación práctica de la evaluación de características de la voz en AVIs. Por ejemplo, sería interesante comprobar si los resultados aquí expuestos se pueden extender a cualquier tipo de ítem empleado para elicitar la voz del entrevistado, o si será necesario considerar un set de features distinto por ítem. También sería relevante estudiar con mayor detalle como distintos aspectos como el lugar, el equipo utilizado, o la distancia al micrófono empleado, afectan a los resultados aquí obtenidos.

Más allá de las cuestiones técnicas, subrayamos la necesidad de continuar la investigación entre estas variables y la personalidad de los sujetos, y desarrollar modelos teóricos que detallen mecanismos explicativos de las mismas, de cara a aportar garantías de validez al empleo de AVIs en la evaluación. Si algo se puede desprender de este artículo es la importancia de asegurar que las AVIs, con su enorme potencial para alterar el mundo de la selección de personal, cumplan las mismas garantías psicométricas que los instrumentos a los que pueden llegar a sustituir.



© ADIC-IIC

ISSN: 2792-3770

5. Referencias bibliográficas

- Almaghrabi, S. A., Thewlis, D., Thwaites, S., Rogasch, N. C., Lau, S., Clark, S. R. y Baumert, M. (2022). The reproducibility of bio-acoustic features is associated with sample duration, speech task, and gender. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 30, 167-175.
- Amos, B., Ludwiczuk, B., y Satyanarayanan, M. (2016). OpenFace: A general-purpose face recognition library with mobile applications (CMU-CS-16-118). CMU School of Computer Science.
- Benjamini, Y. 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.
- Boersma, P. (2001). Praat, a system for doing phonetics by computer. Glot International, 5(9/10), 341–345.
- Brenner, F. S., Ortner, T. M., y Fay, D. (2016). Asynchronous video interviewing as a new technology in personnel selection: The applicant's point of view. Frontiers in psychology, 7, 863.
- Christensen, A. P., Garrido, L. E., y Golino, H. (2023). Unique Variable Analysis: A Network Psychometrics Method to Detect Local Dependence. Multivariate Behavioral Research, 58(6), 1165-1182. https://doi.org/10.1080/00273171.2023.2194606.
- Cohn, Jeffrey., Ambadar, Zara., y Ekman, Paul. (2007). Observer-Based Measurement of Facial Expression with the Facial Action Coding System. The Handbook of Emotion Elicitation and Assessment.
- De Winter, J. C. F., Dodou, D., y Wieringa, P. A. (2009). Exploratory factor analysis with small sample sizes. Multivariate Behavioral Research, 44(2), 147–181. https://doi.org/10.1080/00273170902794206
- Dunlop, P. D., Holtrop, D., y Wee, S. (2022). How asynchronous video interviews are used in practice: A study of an Australian-based AVI vendor. International Journal of Selection and Assessment, 30, 448–455. https://doi.org/10.1111/ijsa.12372
- Eyben, F., Wöllmer, M., y Schuller, B. (2010). Opensmile: The Munich versatile and fast open-source audio feature extractor. En Proceedings of the 18th ACM international conference on Multimedia, 1459-1462. https://doi.org/10.1145/1873951.1874246
- Eyben, F., Scherer, K., Schuller, B., Sundberg, J., André, E., Busso, C., Devillers, L., Epps, J., Laukka, P., Narayanan, S. y 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
- Feng, F., Zhang, Z., Tang, L., Qian, H., Yang, L.-Z. y Jiang, H., Li, H. (2024). Test-retest reliability of acoustic and linguistic measures of speech tasks. Computer Speech y Language, 83, 101547. https://doi.org/10.1016/j.csl.2023.101547.
- Hickman, L., Bosch, N., Ng, V., Saef, R., Tay, L., y Woo, S. E. (2022). Automated video interview personality assessments: Reliability, validity, and generalizability investigations. Journal of Applied Psychology, 107(8), 1323–1351. https://doi.org/10.1037/apl0000695
- Koutsoumpis, A., Ghassemi, S., Oostrom, J. K., Holtrop, D., van Breda, W., Zhang, T., y de Vries, R. E. (2024). Beyond traditional interviews: Psychometric analysis of asynchronous video interviews for personality and interview performance evaluation using machine learning. Computers in Human Behavior, 154, 108128. https://doi.org/10.1016/j.chb.2023.108128
- Landauer, T.K., McNamara, D.S., Dennis, S., y Kintsch, W. (Eds.). (2007). Handbook of Latent Semantic Analysis (1st ed.). Psychology Press. https://doi.org/10.4324/9780203936399
- Liff, J., Mondragon, N., Gardner, C., Hartwell, C. J., y Bradshaw, A. (2024). Psychometric properties of automated video interview competency assessments. Journal of Applied Psychology, 109(6), 921–948. https://doi.org/10.1037/apl0001173
- Lukacik, E.-R., Bourdage, J. S., y Roulin, N. (2022). Into the void: A conceptual model and research agenda for the design and use of asynchronous video interviews. Human Resource Management Review, 32(1), Article 100789. https://doi.org/10.1016/j.hrmr.2020.100789

© ADIC-IIC

ISSN: 2792-3770

- Pennebaker, James y Boyd, Ryan y Jordan, Kayla y Blackburn, Kate. (2015). The Development and Psychometric Properties of LIWC2015. University of Texas.
- Solera-Ureña, R., et al. (2016). Acoustic-Prosodic Automatic Personality Trait Assessment for Adults and Children. In A. Abad, et al. (Eds.), Lecture Notes in Computer Science. Springer. https://doi.org/10.1007/978-3-319-49169-1_19
- Stegmann, G. M., Hahn, S., Liss, J., Shefner, J., Rutkove, S. B., Kawabata, K., Bhandari, S., Shelton, K., Duncan, C. J. y Berisha, V. (2020). Repeatability of commonly used speech and language features for clinical applications. Digital biomarkers, 4(3), 109-122.
- Van Rijn, P., y Larrouy-Maestri, P. (2023). Modelling individual and cross-cultural variation in the mapping of emotions to speech prosody. Nature Human Behaviour, 7(3), 386-396. https://doi.org/10.1038/s41562-022-01505-5

© ADIC-IIC

ISSN: 2792-3770

ARTÍCULO 04

© ADIC-IIC

ISSN: 2792-3770



.04

Entrevistas de Vídeo Asíncronas: el papel de la apariencia y las atribuciones de personalidad en la estimación de empleabilidad de candidatos en situaciones de poca información

Asynchronous Video Interviews: The Role of Appearance and Personality Attributions in Estimating Candidate Employability in Low-Information Contexts

Pilar Martínez González
Especialista de Recursos Humanos

Correo electrónico:
pilimago95@gmail.com

Linkedin:
https://www.linkedin.com/in/pilar-m-b650a5170/

Received: 2/02/2025
Received in revised form: 25/03/2025
Accepted: 12/06/2025
Available on-line: 15/10/2025

© ADIC-IIC

ISSN: 2792-3770



Resumen

La decisión de contratación de un candidato para un puesto de trabajo puede verse influida por diversos factores. La formación de primeras impresiones y la atribución de personalidad de los solicitantes juegan un papel indispensable en el proceso de selección de personal. Además del lenguaje verbal, el lenguaje no verbal (lenguaje corporal, facial y paralenguaje) desempeñan un papel primordial en la formación de primeras impresiones, así como la apariencia física. En el presente estudio se analiza, por un lado, la atribución de personalidad y la estimación de empleabilidad realizadas por expertos en el área de selección de personal. Y por otro, se estudia la relación que existe entre los distintos rasgos de personalidad atribuidos a través del lenguaje corporal, facial y del paralenguaje. Los resultados muestran que las atribuciones de personalidad se ven influenciadas en gran medida por la apariencia física y por la expresividad facial de los candidatos. Al igual que indican, que la estimación de empleabilidad depende en gran medida de la apariencia física.

Palabras clave
personalidad, selección de personal, lenguaje no verbal, empleabilidad.

Abstract

The decision to hire a candidate for a job can be influenced by several factors. The formation of first impres-sions and the attribution of personality of applicants can play an essential role in the personnel recruitment process. In addition to verbal language, non-verbal language (body language, facial language and paralan-guage) can have a crucial influence on the formation of first impressions, as can physical appearance. This study analyses, on the one hand, the personality attribution and the employability assessment carried out by experts in the area of personnel recruitment. On the other hand, it studies the connection that exists between the different personality traits attributed through body language, facial language and paralanguage. The results show that personality attributions are largely influenced by the physical appearance and facial expres-siveness of candidates. They also indicate that the estimation of employability depends strongly on physical appearance.

Keywords
personality, personnel recruitment, non-verbal language.

© ADIC-IIC

ISSN: 2792-3770

1. Introducción

El capital humano es uno de los pilares fundamentales que sustentan las organizaciones. Es por ello, que la selección de personal adquiere un papel fundamental a la hora de incorporar nuevo talento humano a todas las organizaciones. La buena praxis en la selección de personal dotará a las organizaciones de una plantilla de trabajadores competentes para cada puesto y de la selección de personal dependerá el talento con el que cuenta una organización. El hecho de contar con un potente capital humano proporciona a las empresas una fuerte ventaja competitiva ante otras, además de influir en el prestigio y valor que posee dicha organización.

En el proceso de selección de personal, es fundamental que los equipos de selección y detección del talento lo formen profesionales en el área que sean capaces de identificar aquellas cualidades que hacen a un candidato idóneo para cubrir un puesto de trabajo frente a otros. En dicho proceso, existen diversas variables que influyen en la decisión de contratación sobre un candidato. En una entrevista de trabajo, es muy importante la información acerca de las "habilidades duras" del candidato, es decir, formación que posee y experiencia en otros puestos de trabajo. Dicha información es primordial a la hora de tomar una decisión de contratación. Pero además de esta información de habilidades duras, conocimientos y aptitudes técnicas para realizar el trabajo, aparece otra información adicional que influye en la toma de decisión del personal de selección. Dentro de esa información adicional juega un papel importante la primera impresión que el seleccionador se lleva sobre el candidato, que es de vital importancia para la decisión de contratación. Esta primera impresión puede suponer un desempate entre dos candidatos en igualdad de condiciones "teóricas". La primera impresión se forma a partir de una gran cantidad de señales que percibe el entrevistador (vestimenta, atractivo, presencia, movimientos corporales, movimientos faciales, la voz, la forma de hablar, la forma de expresarse, etc). Este tipo de señales no verbales, influyen de manera importante en la formación de la primera impresión sobre una persona, además de que, a través de esta primera impresión, los seleccionadores son capaces de inferir una gran cantidad de información acerca de la forma de actuar y pensar del candidato.

En este proceso de evaluación de las características de los candidatos la herramienta más usada mundialmente es la entrevista personal, ya sea estructurada, no estructurada o por competencias (McDaniel et al, 1994; Salgado et al., 2001). Las entrevistas de selección son usadas debido al respaldo científico que poseen de que se puede tomar una mejor decisión sobre la contratación de un candidato tras haber conocido al candidato en persona, antes que evaluaciones biográficas o mediante diferentes tests (Gatewood et al., 2011). Además, la investigación muestra que los expertos de las organizaciones tienden a confiar más en la primera impresión que se forman sobre un candidato frente a los resultados de los diferentes tests (Dipboye, 1994).

Las señales no verbales que un candidato emite durante una entrevista de trabajo (sonrisa, gestos, contacto visual, postura corporal, velocidad del habla, tono, etc) juegan un importante papel en una entrevista de trabajo. A través de ellas los expertos intentan inferir características relevantes sobre el candidato como la personalidad, habilidades, competencias, liderazgo, motivación para el puesto o ganas de trabajar en la organización (Gatewood et al., 2011). Gran parte de esta información puede ser inferida a través del comportamiento y lenguaje verbal del candidato, aun así, el lenguaje no verbal cumple también un papel fundamental, ya que a través de él se expresa una gran cantidad de información (Arvey y Campion, 1982; Schlenker, 1980). Hay evidencia suficiente que muestra que la primera impresión que un entrevistador se realiza sobre un candidato no está basada únicamente en la información verbal que los candidatos emiten, si no en la manera en la cual los candidatos responden las preguntas realizadas por los entrevistadores (Imada y Hakel, 1977).

Este fenómeno es especialmente relevante en el contexto actual de entrevistas de vídeo asíncronas (AVIs) en las que el entrevistador no tiene forma de indagar sobre las características del candidato y modificar así su primera impresión, sino que únicamente cuenta con la información grabada emitida por el candidato. La importancia de estas señales no verbales es aún más crucial en un contexto donde el entrevistador no puede interactuar en tiempo real con el candidato, por lo que cada detalle tiene mucha importancia ya que se extrae de la información grabada.

En línea con lo anterior, es importante que los entrevistadores en procesos de selección tomen consciencia de aquellas señales no verbales que pueden desencadenar atribuciones inconscientes (incluso en entrevistas estructuradas), ya que estas señales pueden añadir información muy valiosa que evite tomar

© ADIC-IIC

ISSN: 2792-3770

decisiones errónea o sesgos en los juicios. El objetivo sería analizar qué señales verbales en las entrevistas de vídeo asíncronas (AVIs) se consideran por los evaluadores para tomar decisiones sobre la empleabilidad y la personalidad de los candidatos.

1.1 ¿Cómo se forman los entrevistadores una primera impresión del candidato?

La formación de impresiones sobre la personalidad se ve influida por factores verbales y no verbales (la forma de andar, la forma de gesticular, la forma de hablar, la postura, el discurso, las expresiones faciales, etc). Es decir, el comportamiento expresivo de una persona hace que los demás se puedan formar impresiones sobre ella (Ambady y Rosenthal, 1992). Desde hace tiempo, algunos expertos como Gordon Allport (1937), sugirieron que un indicador importante de la personalidad de un individuo podía ser su comportamiento expresivo. A raíz de la exposición a ese comportamiento expresivo de los demás, cada persona se forma una impresión sobre los otros, que se ve reforzada en posteriores acercamientos. Según Allport (1961), Goffman (1959, 1971) y otros autores, el comportamiento expresivo es el primordial en la percepción de las personas. Según Allport y Vernon (1933) el estilo expresivo de las personas resulta ser bastante estable en una gran variedad de contextos.

Estudios llevados a cabo por Wilson y Schooler (1991) afirman que los observadores pueden llegar a ser muy precisos en los juicios que realizan a partir de muy poca información y el más mínimo procesamiento cognitivo. Además, se ha demostrado que las personas comunican las expectativas y preferencias que poseen a través del lenguaje expresivo, mediante señales no verbales de manera muy disimulada (Chaikin, Sigler y Derlega, 1974; Christensen y Rosenthal, 1982; Harris y Rosenthal, 1985; Rosenthal, 1966; Rosenthal y Rubin, 1978; Snyder, Tanke y Berscheid, 1977; Word, Zanna y Cooper, 1974).

Los juicios que se realizan sobre otras personas pueden ser muy precisos, sobre todo cuando se basan en observaciones breves de su comportamiento expresivo (Albright et al., 1988; Funder y Colvin, 1988; Watson, 1989). El término “thin slices” (pequeños fragmentos) se ha usado en la literatura para poder describir breves fragmentos del comportamiento social de las personas y de la personalidad. A partir de estos breves fragmentos los observadores son capaces de inferir estados, rasgos y otras características de la personalidad de las personas (Carney, Colvin y Hall, 2007). Además, es un enfoque bastante adecuado a partir de cual poder estudiar la precisión con la que las personas se forman primeras impresiones de otros (Ambady y Rosenthal, 1992; Ambady, Bernieri y Richeson, 2000). Estudios llevados a cabo por Rosenthal, Hall, DiMatteo, Rogers y Archer (1979) señalan que en sólo 375 milisegundos se puede identificar de manera precisa las emociones de otros. Según los resultados del metaanálisis llevado a cabo por Ambady y Rosenthal (1992), las personas son capaces de emitir juicios muy precisos a partir de segmentos muy pequeños de comportamiento sobre ciertas dimensiones afectivas o de la personalidad.

En las AVIs, comparadas con las entrevistas fase to face o con las vídeo entrevistas, el entrevistador (o el analizador de la información) dispone de menos fragmentos para formarse ese juicio de primera impresión. Y aunque la evidencia disponible es contradictoria la precisión de estas estimaciones puede verse afectada por el tiempo disponible para la observación del candidato. El modelo de precisión realista (RAM) (Funder, 2001) y el modelo promedio ponderado (WAM) (Kenny, 1994) proponen que la precisión de un juicio sobre otra persona debería de aumentar a medida que la cantidad de información que se tiene sobre esa persona aumenta. Es decir, sugieren que la precisión sería mayor a medida que los fragmentos observables sean mayores. Otros autores, observan que la precisión aumenta con el número y la variedad de contextos conductuales que el observador ve sobre otra persona (Borkenau, Mauer, Riemann, Spinath y Angleitner, 2004). En definitiva las AVIs tienen un contexto más limitado que otros formatos de entrevistas para que los evaluadores se formen un juicio preciso sobre el candidato.

Por otro lado, sabemos también que hay variaciones en función del canal de comportamiento que los observadores ven. Los canales más usados son: los canales no verbales y los canales vocales (cara, cuerpo o ambas, paralenguaje), los canales verbales (discurso y transcripción) y los canales audiovisuales (combinación de los dos anteriores). Hay una gran cantidad de estudios que concluyen en que no hay gran diferencia en los juicios emitidos dependiendo del canal (Burns y Beier, 1973; English y Jelenevsky, 1971; Strahan y Zytowski, 1976; Strong, Taylor, Bratton y Loper, 1971). Las personas, por otro lado, pueden emitir tres tipos de señales no verbales: las dinámicas, las estáticas y las paralingüísticas. Las señales dinámicas son aquellas que cambian fácilmente, como por ejemplo puede ser el contacto visual, los

© ADIC-IIC

ISSN: 2792-3770

movimientos de las manos, la orientación del cuerpo, la sonrisa, las gesticulaciones faciales o el movimiento de la cabeza, entre otras. Las señales estáticas son aquellas relativas a las variables demográficas de una persona o la atractividad física, entre otras. Por último, las señales paralingüísticas son aquellas referidas a las características vocales de una persona (tono de voz, velocidad del habla, etc) (DeGroot y Gooty, 2009).

Desde el punto de vista selectivo, es relevante tener en cuenta que los candidatos realizan habitualmente un proceso de gestión de la propia imagen, para proporcionar al entrevistador la imagen que creen que será mejor valorada por este. Las personas son capaces de controlar el lenguaje expresivo que muestran para crear una determinada impresión más favorable a los demás (Goffman, 1959, 1971), pero, aun así, no pueden controlar la totalidad de los canales (Ekman y Friesen, 1969). Es decir, en alguna ocasión, las personas pueden controlar sus palabras, pero es más difícil controlar la expresión facial, la voz o las expresiones corporales. Toda esa falta de control sobre los comportamientos expresivos que se emiten se atribuye a una falta de consciencia sobre ese comportamiento expresivo, ya que se realiza de manera natural o innata. El canal expresivo más fácilmente modulable es el canal verbal, seguido de las expresiones faciales y el cuerpo, siendo la voz el canal menos controlable (Brown, 1986; Rosenthal y DePaulo, 1979).

1.2 ¿Cómo infieren los entrevistadores las características psicológicas de los candidatos a partir de estas señales y las primeras impresiones?

Diversos trabajos en la formación de impresiones afirman que las autoevaluaciones de la propia personalidad coinciden en gran medida con las evaluaciones de personalidad que los desconocidos hacen sobre esa misma persona (Passini y Norman, 1966; Albright, Kenny y Malloy, 1988; Funder y Colvin, 1988; Watson, 1989). En cualquier caso, hay ciertos factores sobre la personalidad que son más fácilmente observables en el comportamiento, como señales de extraversión, dominancia, impulsividad, exhibición y feminidad o masculinidad, frente a otras señales que son más difícilmente observables en el comportamiento, como ocurre con la autonomía, la persistencia o la comprensividad (Buck, 1975, 1977; Cunningham, 1977; Friedman, Di-Matteo y Taranta, 1980; Friedman, Riggio y Segall, 1980; Lippa, 1976, 1978a, 1978b). Estos factores más fácilmente observables aparecen consistentemente en el lenguaje expresivo de las personas y suelen ser fácilmente observables por los observadores. En todo este lenguaje expresivo de una persona, hay diferencias en cuanto al sexo de la persona, es decir, el lenguaje expresivo de mujeres y hombres no es el mismo en la forma de mirar, tocar o moverse, entre otras (Hall, 1978, 1979). Además, el grado de atractivo físico de una persona adquiere una importancia enorme en la formación de impresiones, sobre todo en las situaciones de zero-aquiance (situaciones de primer acercamiento entre personas, es decir, personas que no se conocen previamente) (Riggio y Friedman, 1986).

También, se pueden encontrar diferencias en las percepciones que los jueces realizan sobre otros. Parece ser que, los varones que hablan de manera fluida gesticulan más y tienen un movimiento corporal más acentuado, obtienen una primera impresión mucho más favorable de ellos. Por otro lado, aquellas mujeres que son más facialmente expresivas, espontáneas y extrovertidas suelen obtener unos juicios más favorables (Riggio y Friedman, 1986).



© ADIC-IIC

ISSN: 2792-3770

La entrevista de personal se centra fundamentalmente en obtener una información teórica y no comportamental de la persona, basada en conocer la experiencia profesional de una persona, digamos que más centrada en conocer respuestas correctas e incorrectas referidas principalmente a cuestiones relativas al trabajo. En realidad, las entrevistas estructuradas están diseñadas especialmente para evaluar facetas relacionadas con el trabajo (Huffcutt et al., 2001), dejando a un lado la medición de los constructos de personalidad. Sin embargo, cuando un entrevistador toma una decisión acerca de un candidato, no sólo lo hace en base a aquellas facetas relacionadas con el trabajo, sino que también lo hace teniendo en cuenta otros factores de personalidad del candidato, es decir, información sobre el candidato que está fuera de la información recopilada en la entrevista. Por otro lado, la información del comportamiento no verbal que se obtiene es mucho menos estructurada y abierta a la situación. Es en la obtención de esa información menos estructurada relativa al comportamiento cuando los entrevistadores se forman las primeras impresiones sobre los candidatos y a partir de la cual toman las decisiones más fiables en muy poco tiempo (Ambady et al, 1999). Las señales visuales no verbales que se dan en una entrevista han demostrado tener un gran efecto en la evaluación del entrevistador. Según la investigación en el ámbito (Gifford, Ng y Wilkinson, 1985; Imada y Hakel, 1977; McGovern y Tinsley, 1978; Raza y Carpenter, 1987; Young y Beier, 1977), los juicios que los entrevistadores hacen sobre los candidatos resultan afectados por el lenguaje expresivo no verbal que emiten los candidatos en una entrevista. Estas señales, pueden presentarse como predictores consistentes del desempeño en el trabajo (Burnett, 1993; Motowidlo y Burnett, 1995). Un estudio realizado por Blackman (2002) muestra que las señales visuales no verbales son imprescindibles en la precisión de los juicios de personalidad que realizan los entrevistadores. Según este estudio, la fiabilidad en la predicción de la personalidad sobre un candidato es mejor en una entrevista cara a cara, frente a una entrevista telefónica (en la cual no existe un comportamiento visible del candidato). Además, el mismo autor defiende que es en las entrevistas no estructuradas donde se puede realizar un juicio acerca de la personalidad del candidato con mayor precisión, ya que el candidato en este tipo de entrevistas es más libre a la hora de hablar y expresarse.

Dichas señales, como puede ser el contacto visual, la orientación del cuerpo del entrevistado, la sonrisa, la atractividad física de la persona o los gestos que realiza con las manos, pueden influir de manera positiva los juicios que emiten los entrevistadores (Cash y Kilcullen, 1985; Hollandsworth, Kazelskis, Stevens y Dressel, 1979; Imada y Hakel, 1977; Kinicki y Lockwood, 1985; McGovern y Tinsley, 1978; Parsons y Liden, 1984; Raza y Carpenter, 1987; Wexley, Fugita y Malone, 1975; Young y Beier, 1977). La atractividad física (Dipboye et al., 1977; Raza y Carpenter, 1987), la vestimenta (Forsythe et al. 1985), los gestos de las manos, la sonrisa o la orientación del cuerpo hacia el entrevistador parecen ser aquellas señales que más positivamente son valoradas por el entrevistador (Gifford et al. 1985; Rasmussen 1984; Forbes y Jackson 1980; Hollandsworth et al. 1979; Imada y Hakel 1977). Diversos estudios han mostrado que la cantidad de contacto visual y expresividad facial que muestra un candidato en una entrevista de trabajo influye en la impresión que el entrevistador se hace sobre esa persona (Frauendorfer y Mast, 2015). Un mayor contacto visual y expresividad favorece una percepción más positiva del candidato, destacando adjetivos como interesante, relajado, fuerte, exitoso, activo, maduro, sensible, agradable, entre otros. Por otro lado, aquellos candidatos que tienen un mayor movimiento y cambio de la postura se perciben como entusiastas y aquellos que mueven más la cabeza se perciben como más sensibles (Anderson y Shackleton, 1990). De dicho estudio, se puede inferir que las habilidades sociales que los candidatos muestran en las entrevistas de trabajo se correlacionan de manera positiva con los gestos que realizan y el tiempo que están hablando (Gifford et al., 1985).

Otro estudio, llevado a cabo por Borkenau y Liebler (1992), muestra que una voz potente, una expresión facial amable, la sonrisa y mayores movimientos de la cabeza expresan extraversión. Por otro lado, una voz alta, la expresión facial amigable y menos movimientos de las manos o de la cabeza expresan amabilidad. Por último, neuroticismo puede expresarse también mediante una voz potente. DeGroot y Motowidlo (1999), plantean la posibilidad de que aquellos entrevistados que son físicamente más atractivos, miran de manera más fija al entrevistador, tienen una mayor movilidad de las manos, sonríen más y tienden a orientar el cuerpo hacia el entrevistador, forman una mejor y más favorable impresión en los entrevistadores. Se basan en que aquellas señales no verbales (visuales) que emiten las personas pueden ser

© ADIC-IIC

ISSN: 2792-3770

aspectos de la personalidad estables que dichas personas muestran de manera consistente en diferentes situaciones. Por ello, se acepta que los candidatos llevan a cabo señales no verbales similares en una entrevista de trabajo a las que llevarían a cabo en una situación cotidiana. Dicho estudio pone de manifiesto que la mezcla del lenguaje expresivo y el vocal podría explicar la varianza existente entre los juicios que los entrevistadores han emitido sobre el grado de ajuste al puesto de trabajo.

Según investigaciones llevadas a cabo por Imada y Hakel (1977), aquellos candidatos que tienen un comportamiento más cercano al entrevistador son percibidos con un mayor grado de ajuste al puesto de trabajo, además de percibir que están más motivados y serán más exitosos en su desempeño. Además, según McGovern y Tinsley (1978), aquellos candidatos que sostienen un mayor contacto visual, tienen un nivel de energía alto, se muestran como más afectivos, hablan de manera fluida y poseen una mayor modulación del tono de voz, suelen ser elegidos para una posterior fase en el proceso de selección. Sin embargo, aquellos candidatos que tienen un menor contacto visual con el entrevistador se perciben como menos motivados y se evalúan más bajo (Tessler y Sushelsky, 1978). Sonreír y mantener un contacto visual con el entrevistador son comportamientos positivos que están muy relacionados con los candidatos que son agradables (Kristof-Brown et al., 2002). Si diferenciamos estos comportamientos no verbales por el sexo, las mujeres suelen sonreír, asentir más, hablar más rápido, tener un tono más alto y variar más el tono de voz que los candidatos hombres (Van Vianen y Van Schie, 1995; Frauendorfer et al., 2014b).
Aquella impresión favorable creada a través del lenguaje no verbal incluye señales positivas, por ejemplo, la sonrisa del candidato, el contacto visual, asentimiento ante las afirmaciones y gesticulación facial. Los candidatos que proyectan más proactivamente estas señales positivas suelen ser evaluados de una manera más favorable por el entrevistador (Stevens y Kristof, 1995). Estas señales no verbales positivas son importantes ya que tienen un gran impacto en la decisión sobre el candidato a la hora de la elección para un puesto de trabajo, sobre todo en aquellas entrevistas menos estructuradas, en las cuales hay mayor libertad de comportamiento por parte del candidato (Tsai et al., 2005).

Según Forbes y Jackson (1980) dicho comportamiento no verbal es una fuente de ayuda para que el entrevistador pueda juzgar al candidato, ya que una preselección de candidatos no aporta una gran cantidad de información sobre los candidatos. Sin embargo, en un cara a cara se puede evaluar más al detalle términos fundamentales como las competencias, la educación o la experiencia que difieren a unos candidatos de otros. Es más, según afirman Edinger y Patterson (1983), ante una situación homogénea de candidatos, la atención se centra en el comportamiento no verbal, ya que ayuda a diferenciarlos.

Hay otras teorías que afirman lo anterior, en la línea del refuerzo, los entrevistadores toman una decisión acerca del candidato en los primeros momentos de la entrevista y dicha decisión se ve reforzada durante la entrevista en base al comportamiento que muestra el candidato (Webster, 1964). Así, el comportamiento no verbal que muestra el candidato ayuda a reforzar la impresión que el entrevistador se llevó en el primer momento, tanto si es una impresión favorable o desfavorable hacia el candidato. Es por ello, que se puede afirmar que cuanta mayor cercanía muestra un candidato en una entrevista de trabajo, más favorable será la impresión que se lleve el entrevistador y más positiva será su evaluación (Frauendorfer y Mast, 2015).

Blackman (2002), realizó un estudio en el que se concluye que aquellos participantes en el rol de seleccionadores de personal fueron bastante precisos a la hora de evaluar a los candidatos en cuanto a su personalidad, incluso en una entrevista simulada. De igual manera, los expertos fueron muy precisos en las evaluaciones realizadas basadas en 30 minutos (Barrick et al., 2000). Por otro lado, Gifford et al. (1985) muestran al campo de la investigación que los expertos podían evaluar de una manera bastante precisa las habilidades sociales de los candidatos a través de una grabación de la entrevista de los candidatos. Sin embargo, hay otros resultados e investigaciones fuera del ámbito de la selección de personal que muestran que no se encuentran diferencias significativas en los juicios emitidos o evaluaciones acerca de otras personas si la duración de la exposición al comportamiento es de 30 segundos o cinco minutos (Ambady y Rosenthal, 1992, 1993; Murphy, 2005), lo cual contradice otros resultados en el campo de las impresiones.

© ADIC-IIC

ISSN: 2792-3770

2. Justificación y Objetivos

Los entrevistadores han de ser conscientes, que por muy estructurada que esté una entrevista, hay factores y señales no verbales de los candidatos que llevan a que los entrevistadores hagan atribuciones inconscientemente sobre ellos. Es por ello, que puede ser muy importante prestar también atención a estas señales no verbales que brindan una gran cantidad de información sobre el candidato, ya que, de no prestar la suficiente atención a estas señales, el entrevistador puede tomar malas decisiones acerca de un candidato o emitir juicios sesgados La evaluación del ajuste al perfil del candidato ante un puesto de trabajo se ve claramente influenciado por aquellas valoraciones subjetivas que realiza el entrevistados (Van Dam, 2003). El modelo de lente de Brunswik (1956) también expone el impacto que las atribuciones de personalidad pueden tener en la predicción del rendimiento en el trabajo y la evaluación del candidato en la entrevista cuando ambos canales (entorno y percepción) son usados.

En línea con ello, el objetivo de este trabajo es analizar qué señales no verbales proporcionadas por los candidatos en las AVIs son tenidas en cuenta por los evaluadores para tomar decisiones sobre la empleabilidad de los candidatos y sobre su personalidad.

De forma específica en nuestro estudio pretendemos dar respuestas a estas tres preguntas de investigación.

- ¿Con qué elementos de la expresividad corporal y verbal se relacionan las atribuciones de personalidad que realizan los entrevistadores?
- ¿Con qué elementos de la expresividad corporal y verbal se relacionan la estimación de empleabilidad que realizan los expertos?
- ¿Qué influye más en la estimación de la empleabilidad, la atribución de personalidad o la expresividad corporal y verbal?

Poder responder a las preguntas previamente planteadas nos abre un abanico enorme de mejora en relación al área de selección de personal como evaluar competencias clave de los candidatos, poder hacer análisis con mayor exhaustividad de la expresión corporal en candidatos, inferir rasgos de personalidad basándonos en esas señales no verbales observadas en las grabaciones, desarrollar herramientas que permitan analizar de una manera más objetivas esas señales no verbales, además de poder facilitar orientación a los entrevistadores y candidatos de cara a que la información no verbal que comparten facilite el proceso de toma de decisiones.



© ADIC-IIC

ISSN: 2792-3770

3. Metodología

3.1. Participantes

En el estudio participaron 50 candidatos y 8 expertos evaluadores. Cada evaluador realizó la evaluación de 10/11 participantes. La media de edad de los candidatos es de 24 años y su distribución por género es de 90% mujeres y 10% hombres. Los participantes fueron captados mediante una estrategia de bola de nieve a través de los contactos de la autora. Los expertos corresponden al equipo de la Dirección de Selección y Talento de una compañía nacional referente en el transporte de viajeros y mercancías por ferrocarril, que cuenta con 16.000 empleados. La Dirección de Selección y Talento está formada por 11 personas con formaciones específicas en el área de recursos humanos, de los cuales los 8 expertos evaluadores son psicólogos con formación adicional en recursos humanos.

3.2. Medidas

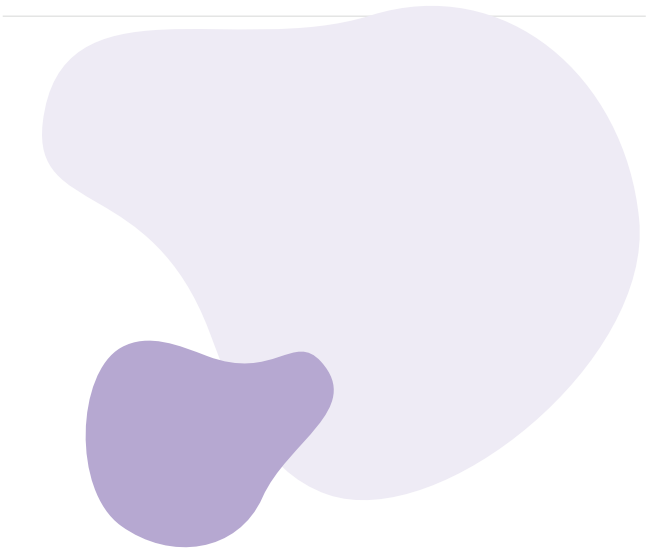
Auto valoración de la Personalidad de los candidatos. Se midieron Ajuste Emocional, Extraversión, Cordialidad, Apertura a la Experiencia y Responsabilidad. Se utilizó una adaptación del Inventario NEO reducido de cinco factores (NEO-FFI)

Valoración de la Personalidad de los Candidatos mediante la apreciación de los Evaluadores. Se evaluaron las mismas características que en la autovaloración de los candidatos y mediante el mismo instrumento (adaptándolo a la respuesta en tercera persona).
Valoración de la Empleabilidad de los Candidatos por parte de los evaluadores. Se utilizó un único ítem en el que se pide al evaluador que señale el porcentaje de empleabilidad que estima para el candidato (0-100).
Valoración de la Apariencia de los Candidatos por parte de los evaluadores. Se utilizó una rúbrica sobre el comportamiento-movimiento del participante en la que se explora su apariencia física a través de: (a) su lenguaje corporal, considerando estos tres elementos: LC1, que se refiere a lenguaje corporal 1 (expresividad en el movimiento), LC2, que se refiere a lenguaje corporal 2 (viveza del movimiento) y LC3, se refiere a lenguaje corporal 3 (tensión-ansiedad del movimiento); (b) su expresión facial; y (c) su paralenguaje.

Para la valoración de la personalidad, la empleabilidad y la apariencia de los candidatos, los evaluadores utilizaron las AVIs que los candidatos habían grabado, Estas fueran 50 vídeos a color. Los vídeos están compuestos por un candidato respondiendo a la instrucción siguiente: “Relata una historia que contenga las palabras: accidente aéreo, fuegos artificiales, camarera, supermercado y edad media. Puedes utilizar papel y lápiz para anotar durante tres minutos tus ideas y luego grábate contando la historia (unos cuatro minutos)”. Para grabar el vídeo se les pide que se graben de cuerpo entero. Los vídeos se proyectan a los evaluadores con sonido a través de un ordenador portátil.

3.3. Procedimiento

En primer lugar los candidatos cumplimentaron el cuestionario y grabaron la AVI. En segundo lugar los vídeos con las AVIs fueron visualizados por los evaluadores y, a continuación, cumplimentaron el cuestionario con las medidas sobre los candidatos.



© ADIC-IIC

ISSN: 2792-3770

4. Resultados

En la tabla 1 se muestran las correlaciones de las 12 variables del estudio. Además, también se muestra la media, la desviación típica y la fiabilidad de la escala de medida (alfa de Cronbach) de cada una de las variables. Los datos sugieren diversas correlaciones muy interesantes. Este primer análisis nos ayuda a situarnos de cara a dar respuesta a los objetivos de nuestro estudio. A partir de estas correlaciones, trabajaremos con aquellas variables que muestran una correlación significativa, desechando así aquellas que no. Encontramos que la estimación de empleabilidad realizada por los expertos posee correlación con los cinco rasgos de personalidad inferido por los expertos, además de con la apariencia física, la expresión facial y el paralenguaje. Por otro lado, la apariencia física correlaciona significativamente con las estimaciones de personalidad de los expertos en los cincos rasgos de personalidad. La estimación de extraversión correlaciona además con LC1, LC2, expresión facial y paralenguaje. La estimación de amabilidad correlaciona además con LC3, expresión facial y paralenguaje. La estimación de responsabilidad correlaciona además con LC2 y expresión facial. La estimación de ajuste emocional correlaciona además con expresión facial y paralenguaje. La estimación de apertura a la experiencia correlaciona además con LC2, expresión facial y paralenguaje.

Tabla 1. Correlaciones variables estudio y estadísticos descriptivos (media, desviación típica, alfa de Cronbach).

	1	2	3	4	5	6	7	8	9	10	11	12
1. Empleabilidad												
2. Extraversión experto	,427**											
3. Amabilidad experto	,401**	,327*										
4. Responsabilidad experto	,369**	,343**	0,205									
5. Ajuste emocional experto	,372**	,454**	,368**	0,136								
6. Apertura experiencia experto	,499**	,297*	,641**	0,158	,458**							
7. Apariencia Física	,617**	,410**	,283*	,472**	,309**	,275*						
8. LC1	0,197	,314**	0,044	0,057	0,190	0,194	-0,055					
9. LC2	,319**	,456**	0,149	,251*	0,154	,228*	0,160	,682**				
10. LC3	-0,175	-0,200	-,271*	0,032	-0,218	-0,093	-,275*	,323**	0,219			
11. Expresión facial	,534**	,440**	,508**	,267*	,446**	,495**	,526**	0,191	,334**	-,438**		
12. Paralenguaje	,512**	,352**	,319**	0,205	,327**	,370**	,593**	-0,015	0,170	-,431**	,609**	
Media	68,64	11,76	13,64	12,23	11,06	12,53	30,88	12,05	11,89	14,37	14,31	29,42
Desviación típica	15,494	3,34	2,51	3,46	2,36	3,28	6,27	3,95	3,32	3,67	2,93	5,28
Alfa de Cronbach	(1)	0,898	0,922	0,927	0,725	0,887	0,734	0,858	0,877	0,603	0,745	0,740

Correlaciones entre las doce variables obtenidas de la recogida de datos del presente estudio (* p < .05, ** p < .01). LC1 se refiere a lenguaje corporal 1 (expresividad en el movimiento), LC2 se refiere a lenguaje corporal 2 (viveza del movimiento) y LC3 se refiere a lenguaje corporal 3 (tensión-ansiedad del movimiento).

(1) No posee medida de fiabilidad ya que posee un solo ítem.

© ADIC-IIC

ISSN: 2792-3770

Tabla 2.
Variables independientes introducidas en los modelos de regresión realizados.

Extraversión experto	Apariencia física LC1 LC2 Expresión facial Paralenguaje
Amabilidad experto	Apariencia física LC3 Expresión facial Paralenguaje
Responsabilidad experto	Apariencia física LC2 Expresión facial
Ajuste emocional experto	Apariencia física Expresión facial Paralenguaje
Apertura a la experiencia experto	Apariencia física LC2 Expresión facial Paralenguaje
Empleabilidad	Apariencia física LC2 Expresión facial Paralenguaje
Empleabilidad	Apariencia física LC2 Expresión facial Paralenguaje Extraversión experto Amabilidad experto Responsabilidad experto Ajuste emocional experto Apertura a la experiencia experto

En la tabla 3 se muestra el modelo de regresión entre la estimación de extraversión que realizan los expertos y las variables apariencia física, LC1, LC2, expresión facial y paralenguaje. Aquí se encuentra una correlación significativa entre extraversión, apariencia física, LC2 y expresión facial. El porcentaje de varianza explicado de estas variables es un 35.4% (con una significación de 0.028). El peso que cada una de las variables posee es 24.7% la apariencia física, un 35.1% LC2 y un 22.6% la expresión facial.

En la tabla 4 se observa el modelo de regresión entre la estimación de la amabilidad que realizan los expertos y las variables apariencia física, expresión facial, paralenguaje y LC3. Encontramos aquí una correlación significativa entre la amabilidad y la expresión facial. El porcentaje de varianza explicado de la relación es un 25.5% (con una significación de 0.028). El peso de la expresión facial en la relación es de un 51.5%.

En la tabla 5 se encuentra el modelo de regresión entre la estimación de responsabilidad que realizan los expertos y las variables apariencia física, expresión facial y LC2. Encontramos aquí una correlación significativa entre responsabilidad y apariencia física. El porcentaje de varianza explicado de la relación es un 21.6% (con una significación de 0.00). El peso de la expresión facial en la relación es de un 47.6%.

En la tabla 6 se muestra el modelo de regresión entre la estimación de ajuste emocional que realizan los expertos y las variables apariencia física, expresión facial y paralenguaje. Encontramos aquí una correlación significativa entre ajuste emocional y expresión facial. El porcentaje de varianza explicado de la relación es un 19.8% (con una significación de 0.00). El peso de la expresión facial en la relación es de un 45.6%.

En la tabla 7 se encuentra el modelo de regresión entre la estimación de apertura a la experiencia que realizan los expertos y las variables apariencia física, expresión facial, paralenguaje y LC2. Encontramos aquí una correlación significativa entre apertura a la experiencia y la expresión facial. El porcentaje de varianza explicado de la relación es un 24.1% (con una significación de 0.00). El peso de la expresión facial en la relación es de un 50.1%.

© ADIC-IIC

ISSN: 2792-3770

Tabla 3. Modelo de Regresión en la Explicación de la Extraversión apreciada por los Expertos.

	Coeficiente	R cuadrado ajustado	Sig. Cambio en f	Coeficiente estandarizado beta	Sig. Coeficiente beta
1. Apariencia física	***0,424***	*0,354*	*0,028*	*0,247*	*0,028*
2. LC1	*0,330*				
3. LC2	***0,475***			*0,351*	*0,001*
4. Expresión facial	***0,483***			*0,226*	*0,057*
5. Paralenguaje	*0,384*				

Correlaciones entre la estimación de extraversión de los expertos y aquellas variables que correlacionan significativamente con extraversión: apariencia física, LC1, LC2, expresión facial y paralenguaje. LC1 se refiere a lenguaje corporal 1 (expresividad en el movimiento), LC2 se refiere a lenguaje corporal 2 (viveza del movimiento).

*Variable dependiente: extraversión experto

Tabla 4. Modelo de Regresión en la Explicación de la Amabilidad apreciada por los Expertos.

	Coeficiente	R cuadrado ajustado	Sig. Cambio en f	Coeficiente estandarizado beta	Sig. Coeficiente beta
1. Apariencia física	*0,286*	*0,255*	*0,000*		
2. Expresión facial	***0,515***			*0,515*	*0,000*
3. Paralenguaje	*0,336*				
4. LC3	*-0,286*				

Correlaciones entre la estimación de amabilidad de los expertos y aquellas variables que correlacionan significativamente con amabilidad: apariencia física, expresión facial y paralenguaje y LC3. LC3 se refiere a lenguaje corporal 3 (tensión-ansiedad del movimiento).

*Variable dependiente: amabilidad experto

Tabla 5. Modelo de Regresión en la Explicación de la Responsabilidad apreciada por los Expertos.

	Coeficiente	R cuadrado ajustado	Sig. Cambio en f	Coeficiente estandarizado beta	Sig. Coeficiente beta
1. Apariencia física	***0,476***	*0,216*	*0,000*	*0,476*	*0,000*
2. Expresión facial	*0,288*				
3. LC2	*0,265*				

Correlaciones entre la estimación de responsabilidad de los expertos y aquellas variables que correlacionan significativamente con responsabilidad: apariencia física, expresión facial y LC2. LC2 se refiere a lenguaje corporal 2 (viveza del movimiento).

*Variable dependiente: responsabilidad experto

© ADIC-IIC

ISSN: 2792-3770

Tabla 6. Modelo de Regresión en la Explicación del Ajuste Emocional apreciada por los Expertos.

	Coeficientes	R cuadrado ajustado	Sig. Cambio en f	Coeficiente estandarizado beta	Sig. Coeficiente beta
1. Apariencia física	*0,308*	*0,198*	*0,000*		
2. Expresión facial	***0,456***			*0,456*	*0,000*
3. Paralenguaje	*0,339*				

Correlaciones entre la estimación de ajuste emocional de los expertos y aquellas variables que correlacionan significativamente con ajuste emocional: apariencia física, expresión facial y paralenguaje. *Variable dependiente: ajuste emocional experto

Tabla 7. Modelo de Regresión en la Explicación de la Apertura a la Experiencia apreciada por los Expertos.

	Coeficiente	R cuadrado ajustado	Sig. Cambio en f	Coeficiente estandarizado beta	Sig. Coeficiente beta
1. Apariencia física	*0,275*	*0,241*	*0,000*		
2. Expresión facial	***0,501***			*0,501*	*0,000*
3. Paralenguaje	*0,381*				
4. LC2	*0,232*				

Correlaciones entre la estimación de apertura a la experiencia de los expertos y aquellas variables que correlacionan significativamente con apertura a la experiencia: apariencia física, expresión facial, paralenguaje y LC2. LC2 se refiere a lenguaje corporal 2 (viveza del movimiento). *Variable dependiente: apertura experiencia experto

Referido a la segunda pregunta de investigación, podemos encontrar el modelo de regresión llevado a cabo en la tabla 8, llevado a cabo entre la estimación de empleabilidad que realizan los expertos y las variables apariencia física, expresión facial, paralenguaje y LC2. Encontramos aquí una correlación significativa entre empleabilidad, apariencia física y expresión facial. El porcentaje de varianza explicado de la relación es un 43.7% (con una significación de 0.008). El peso de la apariencia física en la relación es de un 48.1% y el de la expresión facial un 28%.

Tabla 8. Modelo de Regresión en la Explicación de la Empleabilidad apreciada por los Expertos

	Coeficiente	Rcuadrado ajustado	Sig. Cambio en f	Coeficiente estandarizado beta	Sig. Coeficiente beta
1. Apariencia física	***0,629***	*0,437*	*0,008*	*0,481*	*0,000*
2. Expresión facial	***0,534***			*0,280*	*0,008*
3. Paralenguaje	*0,516*				
4. LC2	*0,291*				

Correlaciones entre la estimación de empleabilidad de los expertos y aquellas variables que correlacionan significativamente con empleabilidad: apariencia física, expresión facial, paralenguaje y LC2. LC2 se refiere a lenguaje corporal 2 (viveza del movimiento).

*Variable dependiente: empleabilidad

© ADIC-IIC

ISSN: 2792-3770

Por último, en cuanto a la pregunta de investigación tercera, en la tabla 9 se muestra el modelo de regresión llevado a cabo entre la empleabilidad, la apariencia física, la expresión facial, el paralenguaje, LC2 y la estimación de los cinco rasgos de personalidad (extraversión, amabilidad, responsabilidad, ajuste emocional y apertura a la experiencia). Aparece aquí una correlación significativa entre empleabilidad, apariencia física y apertura a la experiencia. El porcentaje de varianza explicado de la relación es un 50.4% (con una significación de 0.00). El peso de la apariencia física en la

Tabla 9. Modelo de Regresión en la Explicación de la Empleabilidad apreciada por los Expertos

	Coeficiente	Rcuadrado ajustado	Sig. Cambio en f	Coeficiente estandarizado beta	Sig. Coeficiente beta
1. Apariencia física	***0,629***			*0,530*	*0,000*
2. Expresión facial	*0,534*				
3. Paralenguaje	*0,516*				
4. LC2	*0,291*				
5. Extraversión experto	*0,456*				
6. Amabilidad experto	*0,396*	*0,504*	*0,000*		
7. Responsabilidad experto	*0,377*				
8. Ajuste emocional experto	*0,382*				
9. Apertura experiencia experto	***0,507***			*0,363*	*0,000*

Correlaciones entre la estimación de empleabilidad de los expertos y aquellas variables que correlacionan significativamente con empleabilidad: apariencia física, expresión facial, paralenguaje, LC2, extraversión, amabilidad, responsabilidad, ajuste emocional y apertura a la experiencia. LC2 se refiere a lenguaje corporal 2 (viveza del movimiento).

* Variable dependiente: empleabilidad



© ADIC-IIC

ISSN: 2792-3770

5. Conclusiones y discusión

Los resultados obtenidos en los análisis son prometedores en el campo. En primer lugar, sorprende la cantidad de variables que pueden influir en la empleabilidad de un candidato. Estas variables, dejando a un lado las variables relativas a experiencia o formación del empleado, son relativas al lenguaje corporal y verbal del candidato y a la personalidad. La decisión sobre el grado de empleabilidad que posee un candidato parece verse influenciada por la personalidad del candidato, la apariencia física, el lenguaje corporal, la expresión facial y el paralenguaje que los seleccionadores infieren sobre dicho candidato. Por otro lado, tanto la apariencia física como la expresión facial se relacionan positivamente con la inferencia de los rasgos de personalidad que realizan los expertos.

En segundo lugar, se estudia de qué manera dependen las atribuciones de personalidad que realizan los expertos de la expresividad corporal. La atribución que los entrevistadores hacen de la extraversión se puede predecir de la apariencia física (24.7%), de la viveza del movimiento (35.1%) y de la expresión facial (22.6%). La atribución de amabilidad depende en un 51.5% de la expresión facial. La atribución de la responsabilidad depende en un 47.6% de la apariencia física. La atribución del ajuste emocional del candidato se debe en un 45.6% de la expresión facial y la apertura a la experiencia en un 50.1% de la expresión facial.

En tercer lugar, se estudia qué elementos de la expresividad corporal y verbal que muestran los candidatos tienen relación con la estimación de la empleabilidad que realizan los expertos. Nuevamente, las protagonistas son la apariencia física y la expresividad facial de los candidatos, teniendo una importancia de un 48.1% y un 28% respectivamente.

Por último, en la estimación de empleabilidad que realizan los expertos, se pretende conocer si influye más la atribución de la personalidad realizada o la expresividad corporal y verbal que muestran los candidatos. Así, tanto la personalidad como el lenguaje expresivo del candidato parecen tener una gran influencia en la estimación de la empleabilidad, siendo significativo la relación que posee con la apariencia física (53%) y con el rasgo de personalidad de apertura a la experiencia (36.3%).

Así, es muy importante el papel que poseen tanto la apariencia física como la expresión facial en una primera impresión, y más en una entrevista a una candidatura de trabajo. Aquellos candidatos que muestran una expresión facial más agradable y una apariencia física más cuidada tienen a obtener puntuaciones más altas en los rasgos de personalidad. Se observa que el movimiento no parece estar muy relacionado con la inferencia de la personalidad (salvo para la extraversión), y tampoco el paralenguaje que muestran los candidatos. Por otro lado, aquellos candidatos que muestran una apariencia física más cuidada y una expresividad facial más agradable obtienen también mayores puntuaciones en empleabilidad. En última instancia, tanto la personalidad como el lenguaje expresivo del candidato tienen un papel fundamental en la empleabilidad que se estima, siendo más importante en la estimación la apariencia física del candidato.

Estos resultados comprueban nuevamente los estudios realizados por Gifford, Ng y Wilkinson, 1985; Imada y Hakel, 1977; McGovern y Tinsley, 1978; Raza y Carpenter, 1987; Young y Beier, 1977, dentro de los cuales la decisión de empleabilidad se ve influida por el lenguaje expresivo que muestra el candidato. De los resultados del presente estudio se puede observar la importancia del lenguaje no verbal en las AVIs, y la necesidad de prestar atención al lenguaje expresivo del candidato en una entrevista, ya que nos puede aportar una gran cantidad de información sobre cómo va a actuar el candidato, rendimiento y capacidades (Ambady et al, 1999; Gifford et al. 1985; Imada y Hakel 1977; Raza y Carpenter 1987).

Es importante señalar algunas variables extrañas que han afectado al presente estudio:

1) La variedad de la muestra es muy limitada, siendo en gran medida mujeres universitarias.

2) Presencia de diversas variables extrañas, como el entorno en el cual se grababa el vídeo (utensilios que se podían ver de la habitación dónde se encontraban los candidatos), la vestimenta que utilizaban los participantes, etc. Así, tampoco se ha podido controlar a qué elementos han de prestar atención los expertos.

© ADIC-IIC

ISSN: 2792-3770

De estos resultados se pueden considerar varios puntos interesantes. Por un lado, podría ser una importante línea de investigación el indagar qué aspectos de la apariencia física y que aspectos de la expresión facial son más importantes a la hora de hacer predicciones de personalidad y estimaciones sobre empleabilidad. Por otro lado, estudiar por qué la apertura a la experiencia tiene tanta relación con la estimación de la empleabilidad, frente a rasgos como la extroversión, la amabilidad o la responsabilidad (que son los grandes protagonistas en los estudios relativos a atribuciones de personalidad en el ámbito laboral y predictores del rendimiento laboral).

Para futuras líneas de investigación, se proponen el estudio de diversas variables. Primero el estudio de la fiabilidad con la que los expertos han inferido tanto los rasgos de personalidad como la estimación de empleabilidad de los candidatos. En segundo lugar, estudiar si existe diferencia entre las estimaciones excluyendo el paralenguaje de los candidatos (comprobar si existen diferencias entre la visualización de los vídeos con sonido o sin sonido). En tercer lugar, hacer un análisis de la diferencia entre el lenguaje expresivo y verbal entre hombres y mujeres, contando para ello con una muestra masculina de mayor número. En cuarto lugar, sería interesante medir la diferencia en la precisión en las estimaciones de personalidad en contextos distintos en cuanto a tiempo (exposiciones mayores o exposiciones pequeñas). Por último, medir las diferencias en cuanto a la precisión de las estimaciones y predicciones entre expertos masculinos y femeninos.

Es indudable que la tecnología cada día más está siendo de vital importancia para mejorar muchos procesos. Por ello, el diseño de una metodología inteligente que sea capaz de realizar atribuciones de personalidad a través del lenguaje expresivo y verbal que muestra un candidato podría suponer una gran fuente de ayuda a los procesos de selección en las organizaciones. Se espera que los resultados del presente estudio ayuden a contribuir en el campo de investigación.

© ADIC-IIC

ISSN: 2792-3770

6. Referencias bibliográficas

- Albright, L., Kenny, D. A. y Malloy, T. E. (1988). Consensus in personality judgments at zero acquaintance. Journal of Personality and Social Psychology, 55, 387-395.
- Allport, G. W (1937). Personality: A psychological interpretation. New York: Holt.
- Allport, G. W. (1961). Patterns and growth in personality. New York: Holt, Rinehart & Winston.
- Allport, G. W y Vernon, P. E. (1933). Studies in expressive movement. New York: Haffher.
- Ambady, N., Bernieri, F. J. y Richeson, J. A. (2000). Toward a histology of social behavior: judgmental accuracy from thin slices of the behavioral stream. In M. P. Zanna (Ed.), Advances in experimental social psychology (Vol. 32, pp. 201–271). San Diego, CA: Academic Press.
- Ambady, N., Hallahan, M. y Conner, B. (1999). Accuracy of judgments of sexual orientation from thin slices of behavior. Psychological Bulletin, 77, 538–547.
- Ambady, N. y Rosenthal, R. (1992). Thin slices of expressive behavior as predictors of interpersonal consequences: a meta-analysis. Psychological Bulletin, 111, 256–274.
- Ambady, N. y Rosenthal, R. (1993). Half a minute: Predicting teacher evaluations from thin slices of nonverbal behavior and physical attractiveness. Journal of Personality and Social Psychology, 3, 431–441.
- Anderson, N. R. y Shackleton, V. J. (1990). Decision making in the graduate selection interview: A field study. Journal of Occupational Psychology, 63, 63–76. doi: 10.1111/j.2044-8325.1990.tb00510.x.
- Aronovitch, C. D. (1976). The voice of personality: Stereotyped judgments and their relation to voice quality and sex of speaker. The Journal of Social Psychology, 99, 207–220.
- Arvey, R. D. y Campion, J. E. (1982). The employment interview: A summary and review of recent research. Personnel Psychology, 35, 281–322. doi: 10.1111/j.1744-6570.1982.tb02197.x.
- Barrick, M.R. y Mount, M.K. (1991). The big five personality dimensions and job performance: A meta-analysis. Personnel Psychology, 44, 1-26. doi: 10.1111/j.1744-6570.1991.tb00688.x.
- Barrick, M. R., Patton, G. K. y Haugland, S. N. (2000). Accuracy of interview judgments of job applicant personality traits. Personnel Psychology, 53(4), 925–951. doi: 10.1111/j.1744-6570.2000.tb02424.x.
- Bing, M.N. y Lounsbury, J.W. (2000). Openness and job performance in U.S.-based Japanese manufacturing companies. Journal of Business and Psychology, 14, 515-522.
- Blackman, M. C. (2002). The employment interview via the telephone: Are we sacrificing accurate personality judgments for cost efficiency? Journal of Research in Personality, 36, 208– 223. doi:10.1006/jrpe.2001.2347.
- Blackman, M. C. (2002). Personality judgment and the utility of the unstructured employment interview. Basic & Applied Social Psychology, 24, 241–250.
- Brown, R. (1986). Social psychology: The second edition. New York: Free Press.
- Borkenau, P. y Liebler, A. (1992). Trait inferences: Sources of validity at zero acquaintance. Journal of Personality and Social Psychology, 62, 645–657. doi:10.1037/0022-3514.62.4.645.
- Borkenau, P. y Liebler, A. (1993). Convergence of stranger ratings of personality and intelligence with selfratings, partner ratings, and measured intelligence. Journal of Personality and Social Psychology, 65, 546–553.
- Borkenau, P., Mauer, N., Riemann, R., Spinath, F. M. y Angleitner, A. (2004). Thin slices of behavior as cues of personality and intelligence. Journal of Personality and Social Psychology, 86, 599–614.
- Buck, R. (1975). Nonverbal communication of affect in children. Journal of Personality and Social Psychology, 31, 644-653.
- Buck, R. (1977). Nonverbal communication of affect in preschool children: Relationships with personality and skin conductance. Journal of Personality and Social Psychology, 35, 225-236.
- Burnett, J. R. (1993). Utilization and validity of nonverbal cues in the structured interview. Unpublished doctoral dissertation, University of Florida, Gainesville.

© ADIC-IIC

ISSN: 2792-3770

- Burns, K. L. y Beier, E. G. (1973). Significance of vocal and visual channels in the decoding of emotional meaning. Journal of Communication, 23, 118-130.
- Carney, D. R., Colvin, C. R. y Hall, J. A. (2007). A thin slice perspective on the accuracy of first impressions. Journal of Research in Personality, 41(5), 1054-1072.
- Cash, T. F. y Kilcullen, R. N. (1985). The aye of the beholder: Susceptibility to sexism and beautyism in the evaluation of managerial applicants. Journal of Applied Social Psychology, 15, 591-605.
- Chaikin, A. L., Sigler, E. y Derlega, V J. (1974). Nonverbal mediation of teacher expectancy effects. Journal of Personality and Social Psychology, 30,144-149.
- Christensen, D. y Rosenthal, R. (1982). Gender and nonverbal decoding skills as determinants of interpersonal expectancy effects. Journal of Personality and Social Psychology, 42, 75-87.
- Clark, L.A. y Watson, D. (1991). General affective dispositions in physical and psychological health. In C.R. Snyder & D.R. Forsyth (Eds.) Handbook of social and clinical psychology: The health perspective. New York: Pergamon.
- Cunningham, M. R. (1977). Personality and the structure of the nonverbal communication of emotion. Journal of Personality, 45, 564-584.
- De Fruyt, F. y Mervielde, I. (1999). RIASEC types and Big Five traits as predictors of employment status and nature of employment. Personnel Psychology,52, 701-727.
- DeGroot, T. y Gooty, J. (2009). Can nonverbal cues be used to make meaningful personality attributions in employment interviews?. Journal of Business and Psychology, 24(2), 179-192.
- DeGroot, T. y Motowidlo, S. J. (1999). Why visual and vocal interview cues can affect interviewers' judgments and predict job performance. Journal of Applied Psychology, 84(6), 986.
- DePaulo, B. M. (1992). Nonverbal behavior and self-presentation. Psychological Bulletin, 111, 203–243. doi: 10.1037/0033 2909.111.2.203.
- Dipboye, R. L. (1994). Structured and unstructured interviews: Beyond the job-fit model. In G. R. Ferris (Ed.), Research in personnel and human resources management (Vol. 12). Greenwich, CT: JAI Press.
- Dipboye, R. L., Arvey, R. D. y Terpstra, D. E. (1977). Sex and physical attractiveness of raters and applicants as determinants of resume evaluations. The Journal of Applied Psychology, 62, 288–294. doi:10.1037/0021-9010.62.3.288.
- Dunn, W.S., Mount, M.K., Barrick, M.R. y Ones, D.S. (1995). Relative importance of personality and general mental ability in managers' judgements of applicant qualifications. Journal of Applied Psychology, 80, 500-509. doi: 10.1037/0021-9010.80.4.500.
- Edinger, J. A. y Patterson, M. L. (1983). Nonverbal involvement and social control. Psychological Bulletin, 93, 30–56.
- Ekman, P. (1973). Darwin and facial expression: A century of research in review. New York: Academic Press Inc.
- Ekman, P. y Friesen, W. V (1969). Nonverbal leakage and cues to deception. Psychiatry, 32, 88-106.
- Ekman, P. y Friesen, W. V. (1975). Unmasking the face: A guide to recognizing emotions from facial expressions. Englewood Cliffs, NJ: Prentice Hall Inc.
- English, R.W. y Jelenevsky, S. (1971). Counselor behavior as judged under audio, visual, and audiovisual communication conditions. Journal of Consulting Psychology, 18, 509-513.
- Epitropaki, O. y Martin, R. (2005). From ideal to real: A longitudinal study of the role of implicit leadership theories on leader–member exchanges and employee outcomes. The Journal of Applied Psychology, 90, 659–676. doi:10.1037/0021-9010.90.4.659.
- Forbes, R. J. y Jackson, P. R. (1980). Nonverbal behavior and the outcome of selection interviews. Journal of Occupational Psychology, 53, 65–72.
- Forsythe, S., Drake, M. F. y Cox, C. E. (1985). Influence of applicant's dress on interviewer's selection decisions. The Journal of Applied Psychology, 70, 374–378. doi:10.1037/0021-9010.70.2.374.
- Frauendorfer, D. y Mast, M. S. (2015). The impact of nonverbal behavior in the job interview. In The social psychology of nonverbal communication (pp. 220-247). Palgrave Macmillan, London.

© ADIC-IIC

ISSN: 2792-3770

- Friedman, H. S., DiMatteo, M. R. y Taranta, A. (1980). A study of the relationship between individual differences in nonverbal expressiveness and factors of personality and social interaction. Journal of Research in Personality, 14, 351-364.
- Friedman, H. S., Riggio, R. E. y Segall, D. O. (1980). Personality and the enactment of emotion. Journal of Nonverbal Behavior, 5, 35-48.
- Funder, D. C. (1987). Errors and mistakes: Evaluating the accuracy of social judgment. Psychological Bulletin, 101, 75-91.
- Funder, D. C. (2001). Accuracy in personality judgment: research and theory concerning an obvious question. In B. W. Roberts & R. Hogan (Eds.), Personality Psychology in the Workplace. Decade of Behavior (pp. 121–140). Washington: American Psychological Association.
- Funder, D. C. y Colvin, C. R. (1988). Friends and strangers: Acquaintanceship, agreement, and the accuracy of personality judgment. Journal of Personality and Social Psychology, 55,149-158.
- Funder, D. C. y Dobroth, K. M. (1987). Differences between traits: properties associated with interjudge agreement. Journal of Personality and Social Psychology, 52, 409–418.
- Funder, D. C. y Sneed, C. D. (1993). Behavioral manifestations of personality: an ecological approach to judgmental accuracy. Journal of Personality and Social Psychology, 64, 479–490. doi: 10.1037/0022-3514.64.3.479.
- Gatewood, R. D., Feild, H. S. y Barrick, M. R. (2011). Human resource selection. Mason, OH: South-Western Cengage Learning.
- Gifford, R. (1991). Mapping nonverbal behavior on the interpersonal circle. Journal of Personality and Social Psychology, 61, 279–288.
- Gifford, R., Ng, C. y Wilkinson, M. (1985). Nonverbal cues in the employment interview: Links between applicant qualities and interviewer judgments. The Journal of Applied Psychology, 70, 729–736. doi:10.1037/0021-9010.70.4.729.
- Goffman, E. (1959). The presentation of self in everyday life. Garden City, NY: Doubleday, Anchor Books.
- Goffman, E. (1971). Relations in public. New York: Basic Books.
- Goldberg, L.R. (1993). The structure of phenotypic personality traits: Authors' reactions to the six comments. American Psychologist, 48,1303-1304.
- Guerrero, L. K. (2005). Observer ratings of nonverbal involvement and immediacy. In V. Manusov (Ed.), The sourcebook of nonverbal measures. Mahwah, NJ: Lawrence Erlbaum Associates, Inc. Publishers.
- Guion, R. M. y Highhouse, S. (2006). Essentials of personnel assessment and selection. Mahwah, NJ: Lawrence Erlbaum Associates.
- Hall, J. A. (1978). Gender effects in decoding nonverbal cues. Psychological Bulletin, 85, 845-857.
- Hall, J. A. (1979). Gender, gender roles, and nonverbal communication skills. In R. Rosenthal (Ed.), Skill in nonverbal communication (pp. 32-67). Cambridge, MA: Oelgeschlager, Gunn, & Hain.
- Hall, J. A. (1984). Nonverbal sex differences: Communication accuracy and expressive style. Baltimore, MD: Johns Hopkins University Press.
- Harris, M. J., & Rosenthal, R. (1985). Mediation of interpersonal expectancy effects: 31 meta-analyses. Psychological Bulletin, 97, 363- 386.
- Hollandsworth, J. G., Jr, Kazelskis, R., Stevens, J. y Dressel, M. E. (1979). Relative contributions of verbal, articulative, and nonverbal communication to employment decisions in the job interview setting. Personnel Psychology, 32, 359–367. doi: 10.1111/j.1744-6570.1979.tb02140.x.
- Hough, L.M., Eaton, N.K., Dunnette, M.D., Kamp, J.D. y McCloy, R.A. (1990). Criterion-related validities of personality constructs and the effect of response distortion on those validities. Journal of Applied Psychology, 75, 581-595.
- Huffcutt, A. I., Conway, J. M., Roth, P. L. y Stone, N. J. (2001). Identification and meta-analytic assessment of psychological constructs measured in employment interviews. The Journal of Applied Psychology, 86, 897–913. doi:10.1037/0021-9010.86.5.897.

© ADIC-IIC

ISSN: 2792-3770

- Imada, A. S. y Hakel, M. D. (1977). Influence of nonverbal communication and rater proximity on impression and decisions in simulated employment interviews. The Journal of Applied Psychology, 62, 295–300. doi:10.1037/0021-9010.62.3.295.
- Judge. T.A., Higgins, C.A., Thoresen, C.J. y Barrick, M.R. (1999). The big five personality traits, general mental ability, and career success across the life span. Personnel Psychology, 52, 621-652.
- Kenny, D. A. (1994). Interpersonal perception: A social relations analysis. New York: Guilford.
- Kinicki, A. J. y Lockwood, C. A. (1985). The interview process: An examination of factors recruiters use in evaluating job applicants. Journal of Vocational Behavior, 26, 117-125.
- Kristof-Brown, A. L., Barrick, M. R. y Franke, M. (2002). Applicant impression management: Dispositional influences and consequences for recruiter perceptions of fit and similarity. Journal of Management, 28, 27–46.
- Kruglanski, A. W (1989). The psychology of being "right": The problema of accuracy in social perception and cognition. Psychological Bulletin, 106, 395-409.
- Lippa, R. (1976). Expressive control and the leakage of dispositional extraversion during role-played teaching. Journal of Personality, 44, 541-559.
- Lippa, R. (1978a). Expressive control, expressive consistency, and the correspondence between expressive behavior and personality. Journal of Personality, 46, 438-461.
- Lippa, R. (1978b). The naive perception of masculinity-femininity on the basis of expressive cues. Journal of Research in Personality, 12, 1-14.
- Lippa, R. y Dietz, J. K. (2000). The relation of gender, personality, and intelligence to judges' accuracy in judging strangers' personality from brief video segments. Journal of Nonverbal Behavior, 24, 25–43.
- Lord, R. G. (1985). An information processing approach to social perceptions, leadership perceptions and behavioral measurement in organizational settings. In B. M. Staw & L. L. Cummings (Eds.), Research in organizational behavior (Vol. 7, pp. 85–128). Greenwich, CT: JAI Press.
- Lowery, C.M. y Krilowicz, T.J. (1994). Relationship between nontask behaviours, rated performance and objective performance measures. Psychological Reports, 74, 571-578.
- McCrae, R.R. y Costa, P.T. (1997). Personality trait structure as human universal. American Psychologist, 52, 509-516.
- McDaniel, M. A., Whetzel, D. L., Schmidt, F. L. y Maurer, S. D. (1994). The validity of employment interviews: A comprehensive review and meta-analysis. Journal of Applied Psychology, 79, 599–616. doi: 10.1037/0021-9010.79.4.599.
- McGovern, T. V. y Tinsley, H. E. A. (1978). Interviewer evaluations of interviewee nonverbal behavior. Journal of Vocational Behavior, 13, 163-171. doi: 10.1016/0001-8791(78)90041-6.
- Motowidlo, S. J. y Burnett, I. R. (1995). Aural and visual sources of validity in structured employment interviews. Organizational Behavior and Human Decision Processes, 61, 239-249.
- Murphy, N. A. (2005). Using thin slices for behavioral coding. Journal of Nonverbal Behavior, 29(4), 235–246.
- Ng, E. S. W. y Sears, G. J. (2010). The effect of adverse impact in selection practices on organizational diversity: A field study. The International Journal of Human Resource Management, 21, 1454–1471.
- Nicholls, M. A. M. y Visser, D. (2010). Validation of a test battery for the selection of call centre operators in a communications company. South African Journal of Psychology, 39, 19–31.
- Norman, W. T. y Goldberg, L. R. (1966). Raters, ratees, and randomness in personality structure. Journal of Personality and Social Psychology, 4, 681–691.
- Parsons, C. K. y Liden, R. C. (1984). Interviewer perceptions of applicant qualifications: A multivariate field study of demographic characteristics and nonverbal cues. Journal of Applied Psychology, 69, 557-568.
- Passini, F. T y Norman, W T. (1966). A universal conception of personality structure? Journal of Personality and Social Psychology, 4, 44-49.

© ADIC-IIC

ISSN: 2792-3770

- Rasmussen, K. G. (1984). Nonverbal behavior, verbal behavior, resume credentials, and selection interview outcomes. The Journal of Applied Psychology, 69, 551–556. doi:10.1037/0021-9010.69.4.551.
- Raza, S. M. y Carpenter, B. N. (1987). A model of living decisions in real employment interviews. The Journal of Applied Psychology, 72, 596–603. doi:10.1037/0021-9010.72.4.596.
- Riggio, R. E. y Friedman, H. S. (1986). Impression formation: The role of expressive behavior. Journal of Personality and Social Psychology, 50(2), 421.
- Rosenthal, R. (1966). Experimenter effects in behavioral research. Englewood Cliffs, NJ: Prentice-Hall.
- Rosenthal, R. y Rubin, D. B. (1978). Interpersonal expectancy effects: The first 345 studies. Behavioral and Brain Sciences, 3, 377-415.
- Rosenthal, R. y DePaulo, B. M. (1979). Sex differences accomodation in nonverbal communication. In R. Rosenthal (Ed.), Skill in nonverbal communication: Individual differences. Cambridge, MA: Oelgeschlager, Gunn, & Hain.
- Rosenthal, R., Hall, J. A., DiMatteo, M. R., Rogers, P. L. y Archer, D. (1979). Sensitivity to nonverbal communication: The PONS Test. Baltimore: Johns Hopkins University Press.
- Rothmann, S. y Coetzer, E. P. (2003). The big five personality dimensions and job performance. SA Journal of Industrial Psychology, 29(1), 68-74.
- Roulin, N., Bangerter, A. y Levashina, J. (2014). Interviewers' perceptions of impression management in employment interviews. Journal of Managerial Psychology, 29(2), 141–163.
- Salgado, J.F. (1997). The five-factor model of personality and job performance in the European Community. Journal of Applied Psychology, 82, 30-43.
- Salgado, J. F., Viswesvaran, C. y Ones, D. S. (2001). Predictors used for personnel selection: An overview of constructs, methods, and techniques. In N. Anderson, D. S. Ones, H. K. Sinangil y C. Viswesvaran (Eds.), Handbook of industrial, work, and organizational psychology (Vol. 1). Thousands Oaks, CA: Sage.
- Schlenker, B. R. (1980). Impression management: The self-concept, social identity, and interpersonal relations. Monterey, CA: Brooks/Cole.
- Schmid Mast, M., Bangerter, A., Bulliard, C. y Aerni, G. (2011). How accurate are recruiters' first impressions of applicants in employment interviews? International Journal of Selection and Assessment, 19, 198–208.
- Schmidt, F. L. y Hunter, J. E. (1998). The validity and utility of selection methods in personnel psychology: Practical and theoretical implications of 85 years of research findings. Psychological Bulletin, 124, 262–274. doi: 10.1037/0033-2909.124.2.262.
- Schneider, M.H. (1999). The relationship of personality and job settings to job satisfaction. Dissertation Abstracts International: Section B: Science and Engineering, 59, 6103.
- Snyder, M., Tanke, E. y Berscheid, E. (1977). Social perception and interpersonal behavior: On the self-fulfilling nature of social stereotypes. Journal of Personality and Social Psychology, 35, 656-666.
- Stevens, C. K. y Kristof, A. L. (1995). Making the right impression: A field study of applicant impression management during job interviews. Journal of Applied Psychology, 80, 587–606. doi: 10.1037/0021-9010.80.5.587.
- Strahan, C. y Zytowski, D. G. (1976). Impact of visual, vocal, and lexical cues on judgments of counselor qualities. Journal of Counseling Psychology, 23, 387-393.
- Strong, S. R., Taylor, R. G, Bratton, J. C. y Loper, R. G. (1971). Nonverbal behavior and perceived counselor characteristics. Journal of Counseling Psychology, 18, 554-561.
- Tessler, R. y Sushelsky, L. (1978). Effects of eye contact and social status on perception of a job applicant in an employment interviewing situation. Journal of Vocational Behavior, 13, 338–347.
- Tett, R.P., Jackson, D.N. y Rothstein, M. (1991). Personality measures as predictors of job performance: A meta-analytic review. Personnel Psychology, 44, 703-742.
- Tokar, D.M. y Subich, L.M. (1997). Relative contributions of congruence and personality dimensions to job satisfaction. Journal of Vocational Behaviour, 50, 482-491.

© ADIC-IIC

ISSN: 2792-3770

- Tsai, W.-C., Chen, C.-C. y Chiu, S.-F. (2005). Exploring boundaries of the effects of applicant impression management tactics in job interviews. Journal of Management, 31, 108–125.
- Tews, M. J., Stafford, K. y Tracey, J. B. (2011). What matters most? The perceived importance of ability and personality for hiring decisions. Human Resources Management, 52, 94–101.
- Van Dam, K. (2003). Trait perception in the employment interview: A five-factor model perspective. International Journal of Selection and Assessment, 11, 43–55. doi:10.1111/1468-2389.00225.
- Van Vianen, A. E. M. y Van Schie, E. C. M. (1995). Assessment of male and female behavior in the employment interview. Journal of Community and Applied Social Psychology, 5, 243–257.
- Vincent, J. P., Friedman, L. C, Nugent, J. y Messerly, L. (1979). Demand characteristics in observations of marital interactions. Journal of Consulting and Clinical Psychology, 47, 557-566.
- Vinchur, A.J., Schippmann, J.S., Switzer, F.S. y Roth, P.L. (1998). A meta-analytic review of predictors of job performance for salespeople. Journal of Applied Psychology, 83, 586-597.
- Watson, D. (1989). Strangers' ratings of the five robust personality factors: Evidence of a surprising convergence with self-report. Journal of Personality and Social Psychology, 57,120-128.
- Webster, E. C. (1964). Decision making in the employment interview. Montreal: Eagle.
- Wexley, K. N., Fugita, S. S. y Malone, M. P. (1975). An applicant's nonverbal behavior and student-evaluators' judgments in a structured interview setting. Psychological Reports, 36, 391- 394.
- Wilson, D. T y Schooler, J. W (1991). Thinking too much: Introspection can reduce the quality of preferences and decisions. Journal of Personality and Social Psychology, 60,181-192.
- Word, C. Q, Zanna, M. P. y Cooper, J. (1974). The nonverbal mediation of self-fulfilling prophecies in interracial interaction. Journal of Experimental Social Psychology, 10,109-120.
- Young, D. M. y Beier, E. G. (1977). The role of applicant nonverbal communication in the employment interview. Journal of Employment Counseling, 14, 154-165.

© ADIC-IIC

ISSN: 2792-3770

ARTÍCULO 05

© ADIC-IIC

ISSN: 2792-3770



.05

Previniendo la rotación a través del análisis del impacto que tiene la formación y capacitación de los líderes de los equipos

Preventing turnover through analysis of the impact of team leader training and coaching

Rocío Cantero Palma

Correo electrónico:
canteropalma@gmail.com

Linkedin:
https://www.linkedin.com/in/roc%C3%ADo-cantero-palma-06187ba3/

Received: 13/02/2025
Received in revised form: 1/06/2025
Accepted: 31/07/2025
Available on-line: 15/10/2025

© ADIC-IIC

ISSN: 2792-3770



Resumen

Este proyecto de investigación tiene como objetivo analizar el impacto de la formación en los líderes dentro de una organización, basándose en la evidencia de que la formación es una estrategia fundamental para mejorar la efectividad organizacional y la transmisión de su marco cultural. El estudio se centrará en descubrir la posible relación de las personas no formadas con la rotación en sus equipos y si supone una falta de capacidades para las futuras oportunidades en nuevos retos de negocio. Será relevante el conocimiento accionable que arroja el análisis poder dar respuesta a las estrategias, por ejemplo, a la gestión del tamaño de los equipos, las oficinas a las que pertenecen o las escuelas de conocimiento a impulsar. Usaremos técnicas estadísticas para explicar el impacto de la formación a través de diferentes factores relevantes.

Palabras clave

Líderes empresariales, Impacto de la formación, Pérdida de oportunidades de negocio, Coste de rotación de personal.

Abstract

This research project aims to analyze the impact of training on leaders within an organization, based on the belief that training is a fundamental strategy for improving organizational effectiveness and transmitting its cultural framework. The study will focus on uncovering the potential relationship between untrained individuals and turnover within their teams and whether it represents a lack of capabilities for future opportunities in new business challenges. The actionable insights generated by the analysis will be relevant to informing strategies, for example, regarding the management of team size, the offices to which they belong, or the knowledge schools to promote. We will use statistical techniques to explain the impact of training through various relevant factors.

Keywords

Business leaders, Impact of training, Loss of business opportunities, Cost of staff turnover.

© ADIC-IIC

ISSN: 2792-3770

1. Introducción

El proyecto analítico tiene de referencia a una empresa especializada en servicios de consultoría tecnológica donde los valores que guían sus servicios se establecen en base al cliente como prioridad, la anticipación a los retos y las personas como potencial para conseguir los resultados en equipo.

La formación, es una de las palancas estratégicas para conseguir los objetivos de negocio y estar alineados con la cultura y transmisión de valores. Para ello dispone de una Universidad Corporativa propia con una arquitectura de formación que pretende ser un catalizador para la evolución del conocimiento de la compañía, trasmisor de valores y la cultura, promover el desarrollo integral de los profesionales, siendo una marca fuerte y reconocible referente dentro de las Universidades Corporativas.

Dentro de las líneas de actuación formativas para los diferentes colectivos, la figura de liderazgo es clave por su influencia en un gran número de personas. En España, los líderes suponen el 26% de la compañía (5.138 profesionales), que, si lo observamos desde la óptica de las personas en las que influye su estilo de liderazgo, supone el 65% restante de la compañía (12.945 profesionales) en los que repercuten sus decisiones, los valores que transmiten o las actitudes que promueven. Dejamos a un lado en este estudio el 9% de perfiles ejecutivos.

La compañía quiere velar por construir un ecosistema de trabajo excepcional que tenga un impacto positivo en las personas: a nuestros profesionales, clientes, asociaciones externas, sociedad. Para ellos los principios de liderazgo son transmitidos a través de la formación. Analizar su impacto, nos guiará a tomar decisiones estratégicas basadas en la estadística predictiva aplicada a recursos humanos.

2. Introducción

La arquitectura formativa de la Universidad Corporativa está orientada a una propuesta de valor del aprendizaje a todos los profesionales, distribuida en las siguientes escuelas de conocimiento donde los líderes tienen acceso a la formación de:

- Escuela de negocio: Formación personalizada la compañía y en el negocio de nuestro cliente.
- Escuela de transformación digital: Conocimientos tecnológicos que se anticipen a las necesidades de clientes, generando productos y activos.
- Escuela de gestión de proyectos: Proporcionar un «cómo» en metodología y gestión de proyectos, así como la formación técnica necesaria para ejecutarlos.
- Escuela de talento: Formación en las habilidades que requieren los profesionales.

A nivel organizacional es una preocupación que las personas con categoría de líder no estén adquiriendo y desarrollando las habilidades y aptitudes necesarias para transmitir la visión de negocio, cultura y valores, así como oficio. Es por ello que analizaremos el impacto de la formación como prevención a la rotación en sus equipos y en la generación de capacidades para futuras oportunidades de negocio. En la Tabla 1 se presentan las diferentes circunstancias que rodean el problema obtenidas a partir de información proporcionada en el entorno del estudio. Dadas las consecuencias estimadas, se hace muy relevante el abordaje del estudio por el tremendo impacto económico que repercute en la empresa (rotación y/o no acceso a futuras oportunidades), así como en los comportamientos de los líderes que influyen en más de la mitad del colectivo que compone la compañía.

© ADIC-IIC

ISSN: 2792-3770

"Impacto de la formación en los líderes como prevención a la rotación en sus equipos y en la generación de capacidades para futuras oportunidades de negocio"	
CAUSAS	CONSECUENCIAS
Desconocimiento de la oferta formativa por llevar poco tiempo en la compañía	Rotación no deseada de sus equipos
Desconfianza de la efectividad de la formación	Perdida de acceso a oportunidades de negocio
Formación insuficiente/no especializada/inadecuada	Falta de capacidad para cumplir con los estándares de calidad de oficio
Personas de diferentes generaciones con creencias la necesidad de formarse distinta	No transmisión de cultura y valores organizacionales
Baja participación en la formación	Desempeño inadecuado del rol de liderazgo
Falta de modelos de referencia a seguir	Disminución de la productividad y eficiencia

Tabla 1 "Relación de causas – consecuencias"

3. Objetivos del estudio

El proyecto tiene como objetivo principal analizar el impacto de la formación en los líderes, partiendo de la creencia para la compañía de que la formación es la base estratégica para favorecer la efectividad de la organización en la transmisión de su modelo organizacional. Para ello, analizaremos el comportamiento formativo de los líderes, pretendiendo:

- Identificar el patrón de éxito del líder formado.
- Evaluar el estado de realización de la formación por parte de los profesionales.
- Analizar la relación de la formación con la rotación de sus equipos.
- Investigar los silos de formación existentes.
- Anticipar la falta de capacitación de los lideres para las futuras oportunidades de negocio.
- Gestionar de forma inteligente la formación para dar respuesta a las necesidades de la organización.

Específicamente, a través del estudio se pretende dar respuesta a las preguntas de investigación planteadas en la Tabla 2. Además, en la tabla, se explicita el valor añadido que tendrá para la organización dar respuesta a dichas preguntas y posibles acciones.



© ADIC-IIC

ISSN: 2792-3770

Pregunta de investigación	Conocimiento accionable	Acciones
¿En qué se están formando actualmente los líderes? ¿Qué horas de formación están destinando a cada tipo de formación (en adelante escuelas de conocimiento)? ¿Existe un patrón claro de líderes no formados? ¿y formados?	Identificar patrones de comportamiento formados y no formados de los líderes.	• Tener un perfil claro del tipo de profesional y poder diseñar de forma personalizada tanto áreas a potenciar como de mejora en nuestros planes de formación ligándolo con el patrón identificado. • Establecer un patrón de consumo de cursos en función de los tipos de liderazgo, poder potenciar o detectar silos formativos al respecto. • Clusterizar a nuestro colectivo de líder que permita avanzar en la personalización de la formación.
¿Qué relación existe entre la rotación de los equipos y la formación de los líderes?	Saber si la relación de la formación con la rotación influye.	Proyectos de incremento de formación en las categorías donde actualmente disponemos de más tasa de rotación no deseada.
¿Influye la escuelas de conocimiento que realizan en la rotación? ¿Qué tipo de escuelas de conocimiento es más relevante para influir sobre la rotación de forma positiva?	Conocer si influye el tipo de formación que realizan en la rotación. Es decir, que el % de rotación sea muy bajo significativamente si realizan determinado tipo de formación.	Refuerzo de las formaciones que más influyen en el sentido de "baja rotación" para poder difundir más su realización.
¿Influye el número de horas destinadas a formarse en la rotación?	Conocer si hay una relación entre las horas formándose y la rotación.	Intentar identificar el número de horas óptimo que marca el equilibrio en la rotación y establecerlo con las distintas unidades como la unidad mínima de horas de aprendizaje por profesional recomendado como prevención de la rotación.
¿Influye la antigüedad en la empresa en estar formado? ¿Yen el tipo de escuelas de conocimiento que realizan?	Conocer si la antigüedad influye en la decisión de formarse.	Establecer eventos periódicos para informar sobre la formación disponible.
¿Influye el tipo de liderazgo en la empresa en estar formado? ¿Yen el tipo de escuelas de	Conocer si influye el tipo de liderazgo en realizar formación.	Identificar si hay tipos de liderazgo que no están realizando formación de forma significativa, para analizar si la oferta actual cubre sus necesidades. Además, también identificar qué tipo de liderazgo

Tabla 2: "Mapa de consecuencias"

© ADIC-IIC

ISSN: 2792-3770

4. Método

4.1. Origen de datos

Esa base de datos ha sido tratada con fines académicos y reflejan características del colectivo de la compañía de forma anonimizada.

4.2. Variables

Según nuestro contexto, el objetivo que perseguimos, la viabilidad del dato disponible, así como el impacto del resultado del estudio, identificamos 27 variables que serán utilizadas en el estudio. A continuación, detallamos cada variable asociada a la explicación de esta, el tipo de dato que recogeremos, y el rango de medida.

Variables Predictoras

1.Zona de Salario (Geo_Zone): Esta variable dicotómica refleja si el participante está en una zona geográfica con salarios porcentualmente superiores al resto de oficinas (Spain Zone 1: Madrid, Barcelona y Bilbao) o si pertenece al resto de oficinas (Spain Zone 2: Resto de oficinas).

2. Sede de la Oficina (Office): Esta variable categórica identifica la sede a la que pertenece el candidato (A Coruña, Alicante, Barcelona, Bilbao, Castellón, Ciudad Real, Granada, Jaén, Las Palmas Gran Canaria, Madrid, Málaga, Mallorca, Mérida, Murcia, Oviedo, Pamplona, Salamanca, Santander, Santiago de Compostela, Sevilla, Tenerife, Valencia, Valladolid, Zaragoza].

3. Unidad de negocio (Business_unit): Esta variable categórica identifica la unidad de negocio a la que pertenece el profesional [AS, BANK, BPO, BSA, BUS, CIB, ECS, GDEAL, GDNE, IND, IS, PPSS, PROD, SEG, SES, SUSI, TEC, TEL, UTI].

4. Segmento de talento (Talent_segment): Esta variable categórica identifica los diferentes tipo de líder que hay en la compañía en base a su aportación de valor. [Lead, Expert Lead, Top Lead, Top Expert Lead].

5. Fecha incorporación (Entry_date): Esta variable recoge la fecha de incorporación en la compañía. Fecha DD/MM/YYYY.

6. Antigüedad (Ternure): Esta variable numérica recoge la antigüedad en la empresa del profesional en años. [0-999999].

7. Rango de antigüedad (Tenure_range): Esta variable categórica identifica el rango de antigüedad en la empresa del profesional de año en año. [0 - 1 Years, 1- 2 Years, 2 - 3 Years …].

8. Género del profesional (Gender): Esta variable categórica identifica el género del profesional. [Female, Male].

9. Edad (Age): Esta variable numérica identifica la edad del profesional [0-99].

10. Rango edad (Age_range): Esta variable categórica identifica el rango de edad del profesional. [18 - 25 Years, 26 - 30 Years,31 - 35 Years,36 - 40 Years,41 - 45 Years,46 - 50 Years,51 - 55 Years,56 -60 Years,61 - 65 Years, >65 Years].

11. Horas totales de formación (Total_traning_hours): Esta variable numérica identifica las horas totales dedicadas por el profesional a formarse. Sin contemplar formación de obligado cumplimiento legal [0-999999].

12. Está formado (Is_training_hours): Esta variable dicotómica identifica si está formado o no el líder [0 No formado /1 Sí Formado].

13. Horas de formación en negocio (Total_training_hours Business School): Esta variable numérica identifica las horas totales dedicadas por el profesional a formarse en conocimiento de Cliente y de Compañía. [0-999999].

14. Está formado en conocimiento de negocio (is_training_ Business_School): Esta variable dicotómica identifica si está formado o no en conocimiento de Cliente y de Compañía [0 No formado 1 Sí Formado].

15. Horas de formación en transformación (Total_training_hours_digital_transformation_school): Esta variable numérica identifica las horas totales dedicadas por el profesional a formarse en conocimiento disruptivo y de innovación para nuevas oportunidades de negocio [0-999999].

16. Está formado en conocimiento de transformación (is_training_ digital_transformation_school): Esta variable dicotómica identifica si está formado o no en conocimiento disruptivo y de innovación [0 No formado 1 Sí Formado].

17. Horas de formación en metodología (Total_training_hours_delivery_school): Esta variable numérica identifica las horas totales dedicadas por el profesional a formarse en metodología, gestión de proyectos y técnica [0-999999].

18. Está formado en conocimiento metodología (is_training__delivery_school): Esta variable dicotómica identifica si está formado o no metodología, gestión de proyectos y técnica [0 No formado 1 Sí Formado].

© ADIC-IIC

ISSN: 2792-3770

19. Horas de formación en habilidades (Total_training_hours_evolving_talent_School): Esta variable numérica identifica las horas totales dedicadas por el profesional a formarse en competencias [0-999999].

20. Está formado en conocimiento en habilidades (is_training__evolving_talent_School): Esta variable dicotómica identifica si está formado o no en competencias [0 No formado 1 Sí Formado].

21. Total profesionales en los equipos (HC_unit_teams): Esta variable numérica identifica el total de profesionales de los equipos (jerárquicamente inferior a la categoría Leader) de la unidad a la que pertenece el profesional [0-999999].

22. Edad media de los equipos (Average_age_unit_teams): Esta variable numérica identifica la media de la edad de los equipos (jerárquicamente inferior a la categoría Leader) de la unidad a la que pertenece el profesional [0-999999].

23. Diferencia edad (different_age_team): Esta variable numérica identifica la diferencia entre la edad del líder y la edad media de los equipos (jerárquicamente inferior a la categoría Leader) de la unidad a la que pertenece el profesional [0-999999].

24. Antigüedad media de los equipos: (Ternure_unit_teams): Esta variable numérica identifica la media de la antigüedad de los equipos (jerárquicamente inferior a la categoría Leader) de la unidad a la que pertenece profesional [0-999999].

25. Media integrantes equipo (Average_team_by_lead): Esta variable numérica identifica la media de personas en el equipo por leader [0-999999].

26. Media oportunidades (Average_opportunity_leader): Esta variable numérica identifica la media de oportunidades por leader [0-999999].

Variables Criterio

27. Rotación media de los equipos (Average_unit_teams_ turnover): Esta variable numérica identifica la media de la rotación no deseada de los equipos (jerárquicamente inferior a la categoría Leader) de la unidad a la que pertenece el profesional [0-999999].

28. Oportunidades de negocio (Unit_opportunities): Esta variable numérica identifica el número de oportunidades de proyectos a futuro de la unidad. Entendiendo oportunidad como proyectos en negociación con el cliente a la espera de la aprobación por su parte [0-999999].

Variables Criterio

27. Rotación media de los equipos (Average_unit_teams_ turnover): Esta variable numérica identifica la media de la rotación no deseada de los equipos (jerárquicamente inferior a la categoría Leader) de la unidad a la que pertenece el profesional [0-999999].

28. Oportunidades de negocio (Unit_opportunities): Esta variable numérica identifica el número de oportunidades de proyectos a futuro de la unidad. Entendiendo oportunidad como proyectos en negociación con el cliente a la espera de la aprobación por su parte [0-999999].

5. Resultados

A continuación presentamos los resultados obtenidos en el estudio. En primer lugar se presenta el análisis descriptivo y en segundo lugar el análisis predictivo.

5.1. Análisis Descriptivo

En la Tabla 3 se presentan los estadísticos descriptivos e intercorrelaciones de las variables del estudio. En la Tabla no se incluyen las correlaciones con las variables: (1) Zona de Salario, (2) Sede de la Oficina, (3) Unidad de negocio, (4) Segmento de talento o (5) Fecha incorporación, (7) Tenure_range, (8) Gender, (10) Age_range, (12) Is_training_hours, (14) is_training_ Business_School, (16) is_training_ digital_transformation_school, (18) is_training__delivery_school, (20) is_training__evolving_talent_School por no ser variables cuantitativas.

© ADIC-IIC

ISSN: 2792-3770

Nº	Descripción	Media	Desviación típica	6	9	11	13	15	17	19	21	22	23	24	25	26	27	28
6	*Ternure*	*6.5*	*5.1*	*1.0*	*0.19*	*-0.04*	*-0.10*	*0.02*	*0.02*	*-0.06*	*0.19*	*0.24*	*0.10*	*0.31*	*0.15*	*-0.18*	*-0.10*	*-0.12*
9	*Age*	*39.3*	*7.6*	*0.19*	*1.0*	*0.00*	*-0.02*	*0.00*	*0.01*	*0.0*	*0.28*	*0.33*	*0.92*	*0.26*	*0.30*	*-0.17*	*-0.12*	*-0.22*
11	***Total_traning_hours***	***22.3***	***37.8***	***-0.04***	***0.00***	***1.0***	***0.50***	***0.22***	***0.84***	***0.58***	***-0.07***	***-0.10***	***0.04***	***-0.09***	***-0.09***	***0.05***	***-0.03***	***0.14***
13	***Total_training_hours Business School***	***4.8***	***12.8***	***-0.10***	***-0.02***	***0.50***	***1.0***	***0.02***	***0.14***	***0.17***	***-0.04***	***-0.10***	***0.01***	***-0.09***	***-0.07***	***0.03***	***0.00***	***0.16***
15	***Total_training_hours_digital_transformation_school***	***0.9***	***12.7***	***0.02***	***0.00***	***0.22***	***0.02***	***1.0***	***0.18***	***-0.00***	***-0.02***	***-0.00***	***0.00***	***0.01***	***-0.04***	***0.01***	***-0.00***	***0.04***
17	***Total_training_hours_delivery_school***	***11.6***	***24.1***	***0.02***	***0.01***	***0.84***	***0.14***	***0.18***	***1.0***	***0.20***	***-0.03***	***-0.05***	***0.03***	***-0.01***	***-0.05***	***0.03***	***-0.06***	***0.10***
19	*Total_training_hours_evolving_talent_School*	*5*	*11.3*	*-0.06*	*0.00*	*0.58*	*0.17*	*-0.00*	*0.20*	*1.0*	*-0.08*	*-0.06*	*0.03*	*-0.05*	*-0.08*	*0.03*	*0.02*	*0.04*
21	***HC_unit_teams***	***885***	***1003.5***	***0.19***	***0.28***	***-0.07***	***-0.04***	***-0.02***	***-0.03***	***-0.08***	***1.0***	***0.43***	***0.11***	***0.26***	***0.93***	***-0.57***	***-0.23***	***-0.40***
22	***Average_age_unit_teams***	***31.1***	***2.8***	***0.24***	***0.33***	***-0.10***	***-0.10***	***-0.00***	***-0.05***	***-0.06***	***0.43***	***1.0***	***-0.06***	***0.83***	***0.57***	***-0.26***	***-0.30***	***-0.48***
23	*different_age_team*	*3.7*	*3*	*0.10*	*0.92*	*0.04*	*0.01*	*0.00*	*0.03*	*0.03*	*0.11*	*-0.06*	*1.0*	*-0.06*	*0.08*	*-0.07*	*-0.00*	*-0.04*
24	***Ternure_unit_teams***	***2.9***	***1***	***0.31***	***0.26***	***-0.05***	***-0.09***	***0.01***	***-0.01***	***-0.05***	***0.26***	***0.83***	***-0.06***	***1.0***	***0.25***	***-0.34***	***-0.27***	***-0.36***
25	***Average_team_by_lead***	***2.54***	***3.32***	***0.15***	***0.30***	***-0.09***	***-0.07***	***-0.04***	***-0.05***	***-0.08***	***0.93***	***0.57***	***0.08***	***0.25***	***1.0***	***-0.43***	***-0.19***	***-0.53***
26	*Average_opportunity_leader*	*3.21*	*1.98*	*-0.18*	*-0.17*	*0.05*	*0.03*	*0.01*	*0.03*	*0.03*	*-0.57*	*-0.26*	*-0.07*	*-0.34*	*-0.43*	*1.0*	*0.37*	*0.28*
27	*Average_unit_teams_ turnover*	*0.1*	*0.1*	*-0.10*	*-0.12*	*-0.03*	*0.00*	*-0.00*	*-0.06*	*0.02*	*-0.23*	*-0.30*	*-0.00*	*-0.27*	*-0.19*	*0.37*	*1.0*	*-0.24*
28	***Unit_opportunities***	***1233***	***812.9***	***-0.12***	***-0.22***	***0.14***	***0.16***	***0.04***	***0.10***	***0.04***	***-0.40***	***-0.48***	***-0.054***	***-0.36***	***-0.53***	***0.28***	***-0.24***	***1.0***

Tabla 3. Estadísticos Descriptivos e Inter-correlaciones entre las variables del estudio.

© ADIC-IIC

ISSN: 2792-3770

Características colectivo líder

La población de líderes es de 5.137, siendo por tipo de liderazgo el más grande el grupo Lead es (2.035), seguido de Top Leader (1.227), Expert Lead (1.167) y Top Expert Leader (708). Están concentrados en una de las oficinas (Madrid) y con un tramo de edad más común entre los 31 y 45 años. Más presencia en este colectivo de hombres (67%) frente a mujeres (33%), alineado con la distribución de género en el resto de los colectivos de la compañía. Más personas formadas (68%) que no formadas (32%), aproximadamente misma distribución que en el resto de los colectivos de la compañía. En total 114.366 horas de formación de los líderes formados. Por escuelas de conocimiento, los líderes formados en la escuela de conocimiento de negocio invierten 24.650h, en la escuela de transformación tecnológica 4.670h, en la escuela de gestión de proyectos 59.347h y en la escuela de habilidades 2.569h. El líder tiene una media de 4 oportunidades de negocio a futuro. Gran concentración en años de antigüedad entre 6 y 10 años en la compañía. Es por ello por lo que posteriormente se ha decido transformar el dato y dividirlo por años, obteniendo así una visión más detallada de los años de antigüedad con más presencia en los líderes siendo entre 1 y 3 años y entre 6 y 7 años específicamente.

Características equipos

Analizando la foto de los equipos de los líderes, la media de edad es de 31 años, tienen una media de 2,78 años de antigüedad en la compañía, están compuestos por una media de 2,52 personas y la rotación está entorno al 14%.

Horas de formación, género y tipo de líder

En el Gráfico 1 se muestran las horas de formación realizadas por los líderes en función del género. Los datos muestran que la media para los hombres (22.63 horas de formación) es ligeramente superior a la de las mujeres (21.54 horas de formación). Ambos grupos tienen la misma mediana (8), indicando que el punto central de los datos es el mismo para ambos géneros. Estos datos suponen un descubrimiento relevante ya que arrojan resultados muy distintos a los esperados, al describir un colectivo de mujeres líderes con más uniformidad en las horas de formación, frente a un colectivo de hombres líderes muy dispar, y con picos y bajos muy pronunciados en el número de horas que se forman.

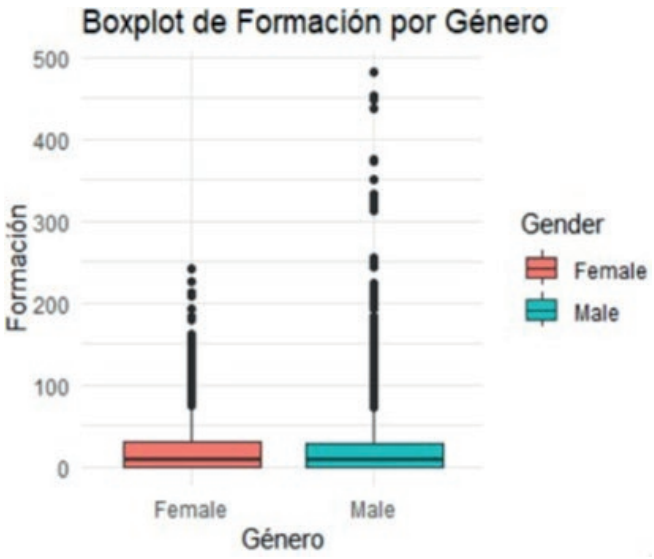


Gráfico 1

Como continuación de la exploración entre formación y el género, en el Gráfico 2 se incluye el tipo de liderazgo del profesional. Como se puede observar, Top Leader es el grupo con más formación tanto en promedio como en la mediana, sugiriendo que la mayoría de sus miembros reciben muchas horas de formación. Expert Lead es el grupo con menos formación en promedio, y aunque algunos miembros reciben muchas horas de formación, la mayoría recibe muy pocas. Respecto de la dispersión, Expert Lead (40.99) muestra la mayor variabilidad, lo que significa que hay grandes diferencias entre las personas en cuanto a las horas de formación recibidas. Finalmente, teniendo en cuenta la forma de la distribución, se observa que en todos los tipos de liderazgo hay asimetría positiva, pero es más pronunciada en Expert Lead (5.45), lo que sugiere que, en este grupo, hay muchas personas con muy pocas horas de formación y algunas con muchas horas. Expert Lead (42.37) tiene una curtosis muy alta, lo que sugiere que hay más valores extremos en este grupo, es decir, hay algunas personas con muchísimas horas de formación.

© ADIC-IIC

ISSN: 2792-3770

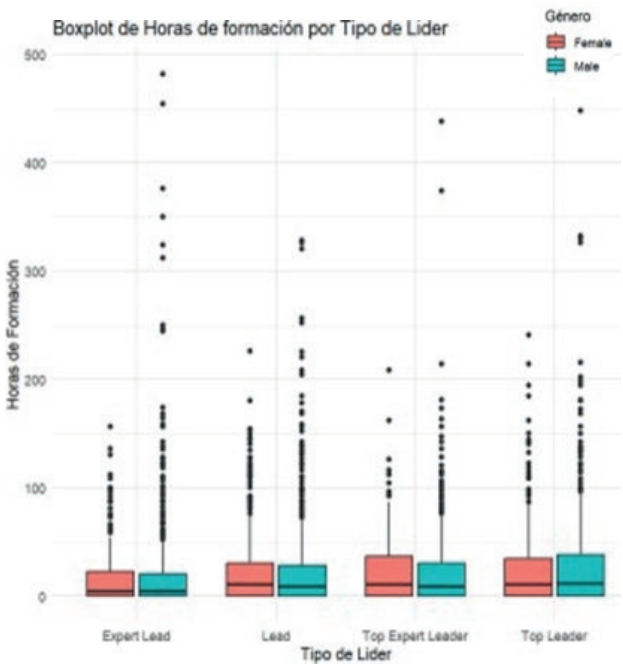


Gráfico 2

El análisis descriptivo nos evidencia que los Expert Lead no se forman lo suficiente. Teníamos la intuición de que podría llegar ser por una oferta formativa poco apetecible para este tipo de colectivo o con unas creencias muy arraigadas sobre en qué deben formarse (altamente técnicas y poco en habilidades).

Adicionalmente, en el Gráfico 3 se presenta el mismo tipo de análisis pero centrado en las horas de formación en la escuela de conocimiento de habilidades (softskills). Los resultados obtenidos han sido impactantes. Aun partiendo de la creencia de que algunos tipos de liderazgo no consumían de forma habitual formación en habilidades, el resultado ha sido más negativo que el esperado: en los cuatro tipos de liderazgo la mayoría no se está formando en habilidades. Siendo todas las medias bastante bajas, es solamente el Top Leader el que más tiempo dedicaría a formarse. Algo que puede tener sentido al posicionarse más cerca de estar gerenciable y ver inminente esa necesidad de formarse para su nuevo reto. Como puede apreciarse al observar la mediana se ve que en los 4 tipos de liderazgo la mayoría no recibe formación. Si bien es el Top Leader el que más formación recibe en promedio, no siendo aun así muy alta. Además los datos muestran una alta variabilidad en las horas realizadas en todos los grupos, menos en el de los Lead, indicando una menor variabilidad extrema. Todos los grupos tienen una distribución de horas de formación sesgada a la derecha, lo que indica que la mayoría de los miembros reciben pocas horas de formación en habilidades. Finalmente, al compararlo por género se observa que los Lead es el colectivo más equilibrado. Sin embargo, para el resto de las categorías, algunas mujeres reciben muchas horas de formación, mientras que otras reciben muy pocas. Los hombres tienen una distribución más uniforme, lo que significa que la mayoría de ellos reciben un número de horas de formación más similar entre sí.

El análisis descriptivo nos evidencia que los Expert Lead no se forman lo suficiente. Teníamos la intuición de que podría llegar ser por una oferta formativa poco apetecible para este tipo de colectivo o con unas creencias muy arraigadas sobre en qué deben formarse (altamente técnicas y poco en habilidades).

Adicionalmente, en el Gráfico 3 se presenta el mismo tipo de análisis pero centrado en las horas de formación en la escuela de conocimiento de habilidades (softskills). Los resultados obtenidos han sido impactantes. Aun partiendo de la creencia de que algunos tipos de liderazgo no consumían de forma habitual formación en habilidades, el resultado ha sido más negativo que el esperado: en los cuatro tipos de liderazgo la mayoría no se está formando en habilidades. Siendo todas las medias bastante bajas, es solamente el Top Leader el que más tiempo dedicaría a formarse. Algo que puede tener sentido al posicionarse más cerca de estar gerenciable y ver inminente esa necesidad de formarse para su nuevo reto. Como puede apreciarse al observar la mediana se ve que en los 4 tipos de liderazgo la mayoría no recibe formación. Si bien es el Top Leader el que más formación recibe en promedio, no siendo aun así muy alta. Además los datos muestran una alta variabilidad en las horas realizadas en todos los grupos, menos en el de los Lead, indicando una menor variabilidad extrema. Todos los grupos tienen una distribución de horas de formación sesgada a la derecha, lo que indica que la mayoría de los miembros reciben pocas horas de formación en habilidades. Finalmente, al compararlo por género se observa que los Lead es el colectivo más equilibrado. Sin embargo, para el resto de las categorías, algunas mujeres reciben muchas horas de formación, mientras que otras reciben muy pocas. Los hombres tienen una distribución más uniforme, lo que significa que la mayoría de ellos reciben un número de horas de formación más similar entre sí.

© ADIC-IIC

ISSN: 2792-3770

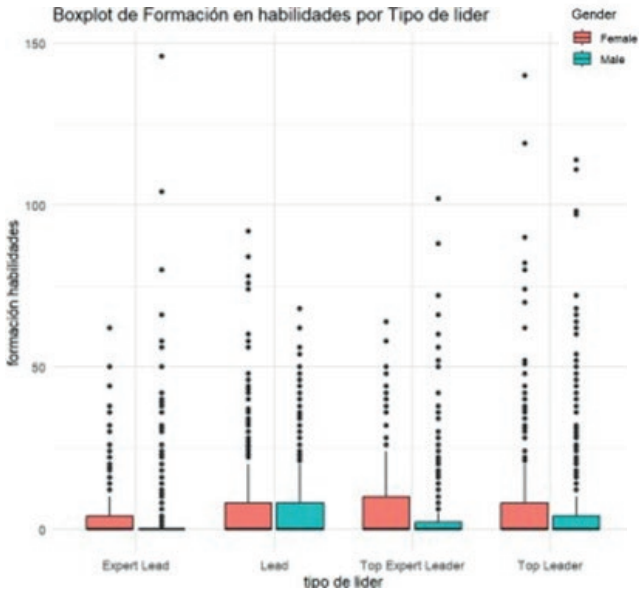


Gráfico 3

Siguiendo el análisis descriptivo más visual que arroja el gráfico, nos encontramos con posibles problemas de equidad: la mayor variabilidad en la formación podría significar que no todas las mujeres tienen las mismas oportunidades de formación. Algunas están siendo muy bien capacitadas, mientras que otras están siendo dejadas de lado. Para los hombres, las oportunidades de formación parecen ser más consistentes y similares entre ellos.

Fruto del análisis descriptivo realizado encontramos algunos problemas relacionados con la muestra y con el criterio de horas de formación. Respecto de la muestra nos encontrábamos ante perfiles referentes técnicos y que lideran ese conocimiento, pero por su propio rol, realizar formación forma parte de sus tareas para luego realizar una transmisión de conocimiento. Consideramos que desvirtuaría el objetivo del estudio. Por lo tanto, Expert Lead y Top Expert Lead no se incluirán en el análisis predictivo. En cuanto a las horas de formación se identifican algunos outliers que afectan a la dispersión. Además, las horas más altas de formación corresponden al colectivo de expertos que como indicaba entra dentro de su propio rol formarse para transmitir conocimiento, así que quedarán apartados del estudio. También, nos encontramos con ciertos perfiles en situación sin proyecto, que utilizan ese tiempo para imputar horas a formación, por lo que no nos merece interés incluirlos al no ser decisión propia. Todo lo superior a 150 horas de formación, ha sido excluido del estudio. En el Anexo 1 se presenta un análisis descriptivo adicional teniendo en cuenta las anteriores modificaciones.

5.2. Análisis Predictivos

Modelo Predictivo de la Rotación

Con el objetivo de incluir en el modelo únicamente aquellas variables que muestran evidencia independiente de relación con el criterio de rotación, se analizaron para las variables numéricas la correlación con el criterio y su colinealidad. Para las variables categóricas, se examinó el grado en el que existían diferencias significativas en la rotación. En la construcción del modelo se utilizó la regresión lineal. D las variables predictoras disponibles se eliminaron “Business unit” ya que causaba overfitting (evidenciado por un rendimiento desproporcionadamente bueno en los datos de entrenamiento R-Squared =1). También se eliminaron las variables “is_training” y “is_training_delivery_school” ya que vienen explicadas por “Total_traning_hours” y “Total_training_hours_delivery_school” respectivamente. Además se eliminaron también variables cuyos coeficientes de correlación no son significativos al nivel $p < 0.05$). En la Tabla 4 pueden apreciarse las variables incluidas en el modelo. Para validar la calidad de los pronósticos ofrecidos por el modelo de predicción se utilizó la validación cruzada. Los datos muestran que el modelo tiene un error estándar residual relativamente bajo, lo que indica que las predicciones del modelo están cerca de los valores reales en promedio. El R-cuadrado ajustado sugiere que alrededor del 50% de la variabilidad en la variable dependiente puede ser explicada por el modelo, lo que indica un ajuste moderado. El estadístico F es significativamente alto, lo que apunta a que disponemos de predictores en el modelo que son significativamente diferentes de cero.

Modelo Predictivo de las Oportunidades de negocio

En la elaboración del modelo de predicción de las oportunidades de negocio, se ha seguido la misma orientación que con el modelo elaborado para la predicción de la rotación. Con el objetivo de incluir en el modelo únicamente aquellas variables que muestran evidencia independiente de relación con la variable dependiente, se analizaron para las variables numéricas la correlación con el criterio y su colinealidad. Para las variables categóricas, se examinó el grado en el que existían diferencias significativas respecto de la variable dependiente.

© ADIC-IIC

ISSN: 2792-3770

Después de realizar la validación cruzada, observamos que el modelo tiene un error estándar residual relativamente bajo 1.365, lo que indica que las predicciones del modelo están cerca de los valores reales en promedio. El R-cuadrado múltiple sugiere que alrededor del 49% de la variabilidad en la variable dependiente puede ser explicada por el modelo, lo que indica un ajuste moderado. El estadístico F es significativamente alto, lo que sugiere que disponemos de predictores en el modelo que son significativamente diferente de cero.

	R cuadrado ajustado	Sig. Cambio en f
Variables Incluidas en el Modelo de Regresión en la Explicación de Rotación en los Equipos		
Office; Talent_segment; Total_traning_hours; is_training_business_school; is_training_digital_transformation_school; Total_training_hours_delivery_school; is_training_evolving_talent_school; HC_unit_teams; Average_age_unit_teams; Average_team_by_lead; Unit_opportunities	*.50*	*.001*
Variables Incluidas en el Modelo de Regresión en la Explicación de las Oportunidades de Negocio		
Office; Gender; is_training_digital_transformation_school; Total_training_hours_delivery_school; HC_unit_teams; Average_team_by_lead; Average_age_unit_teams; Ternure_unit_teams; Unit_opportunities	*.49*	*.001*

Tabla 5. Variables Incluidas en el Modelo de Regresión en la Explicación de Rotación en los Equipos.

© ADIC-IIC

ISSN: 2792-3770

6. Discusión

En la Tabla 6 se representa cómo el impacto de la formación está presente en la explicación de rotación y oportunidades de negocio como variables dependientes. Si bien es cierto que su influencia estadísticamente es baja, en ambos estudios se ha concluido que tiene significación estadística.

VARIABLES	ROTACIÓN	OPORTUNIDADES
GEO_ZONE	✗	✗
*OFFICE	✓	✓
BUSINESS_UNIT	✗	✗
TALENT_SEGMENT	✓	✗
ENTRY_DATE	✗	✗
TERNURE	✗	✗
TENURE_RANGE	✗	✗
GENDER	✗	✓
AGE	✗	✗
AGE_RANGE	✗	✗
TOTAL_TRANING_HOURS	✓	✗
IS_TRAINING_HOURS	✗	✗
TOTAL_TRAINING_HOURS BUSINESS SCHOOL	✗	✗
IS_TRAINING_ BUSINESS_SCHOOL	✓	✗
TOTAL_TRAINING_HOURS_DIGITAL_TRANSFORMATION_SC	✗	✗
*IS_TRAINING_ DIGITAL_TRANSFORMATION_SCHOOL	✓	✓
*TOTAL_TRAINING_HOURS_DELIVERY_SCHOOL	✓	✓
IS_TRAINING_ _DELIVERY_SCHOOL	✗	✗
TOTAL_TRAINING_HOURS_EVOLVING_TALENT_SCHOOL	✗	✗
IS_TRAINING_ _EVOLVING_TALENT_SCHOOL	✓	✗
AVERAGE_UNIT_TEAMS_ TURNOVER	✗	✗
*HC_UNIT_TEAMS	✓	✓
*AVERAGE_AGE_UNIT_TEAMS	✓	✓
DIFFERENT_AGE_TEAM	✗	✗
TERNURE_UNIT_TEAMS	✗	✓
DIFFERENT_TERNURE_TEAMS	✗	✗
*UNIT_OPPORTUNITIES	✓	✓
*AVERAGE_TEAM_BY_LEAD	✓	✓
AVERAGE_OPPORTUNITY_LEADER	✓	✗

*Destacamos en este color las variables que impactan en Rotación y Oportunidades

Tabla 6. Resumen Resultados de Predicción

© ADIC-IIC

ISSN: 2792-3770

Adicionalmente al anterior resumen, a continuación se describe cómo se comportan las variables en la explicación de las variables dependientes recopilando los principales titulares de los resultados y con el contexto del colectivo.

Impactos de la formación de los líderes

Líderes formados, tienen menos rotación en sus equipos. Sobre todo, si están formados en Delivery School donde adquieren las habilidades en metodología y gestión de proyectos o en Evolving Talent School donde adquieren habilidad relacionadas con el liderazgo y las relaciones profesionales. Podríamos relacionar a que tienen la capacitación para gestionar alcance, plazo o riesgos del proyecto de forma más eficiente, donde el equilibrio de tareas en el equipo está más eficiente, alineada con la cultura y valores en las habilidades de liderazgo y conlleva a menos rotación por sobrecarga o mala gestión del líder.
Líderes formados, tienen más oportunidades de negocio. Aquí es reseñable cuando específicamente están formados en Digital Transformation School, que capacita en conocimientos tecnológicos que se anticipen a las necesidades de nuestros clientes y generen productos y activos.

Impactos de las características de los equipos

Tener menos equipo, aumenta la posibilidad de disponer más oportunidades de negocio*. A nivel explicativo, disponemos de dos medidas (HC Unidad, influye negativamente y Personas en el equipo del líder, influye positivamente) para esta relación donde podemos relacionar:

- HC: Unidad Necesidad mayor de estar en la parte comercial con perfiles muy diversos que dificultan el alineamiento del contacto con cliente, venta de proyectos, generación de oportunidades.
- Personas en el equipo del líder: Mayor tiempo para dedicar a la apertura de negocio al tener un equipo amplio.

Equipos más maduros hacen que el líder acceda a más oportunidades. Relacionado con el clima de equipo, el engagement, la consolidación de sus flujos de trabajo más consolidados; hace que el líder le posibilite una delegación de tareas y estar en las conversaciones de negocio en oportunidades.

Mayor edad del equipo del líder, menos rotación. Equipos compuestos por perfiles más maduros, podemos inferir en momentos vitales que requieren mayor estabilidad (familiar) o seguridad profesional hace que la gestión del líder se vea respaldada con menos rotación. Tiene relación con, más año en la compañía.

Mayor tamaño de los equipos del líder aumenta el riesgo de rotación. Ocasionado quizá por esa diversidad de personas a la que gestionar, dificulta su labor de engagement con el equipo. Además, **determinadas oficinas determinan la rotación de los equipos del líder.**

Líderes, oportunidades y rotación

Líderes con más oportunidades, son los que más rotación tienen en sus equipos. A nivel explicativo, hace pensar varios posibles motivos:

- Mayor presión a los equipos por las oportunidades disponibles.
- Mayor carga de trabajo del líder que hace perder de vista la salud relacional de su equipo.
- Desarrolla a un equipo más atractivo para el mercado.
- Mayores oportunidades para el líder en su negocio, puede significar un mercado emergente, innovador o disruptivo, que hace que la capacitación de sus equipos en ello, adquiera un valor en el mercado externo más elevado que el ritmo de crecimiento que tendrían a nivel interno.

Menor rotación por el sentimiento de pertenencia generado por la antigüedad del equipo y del líder, genera un vínculo emocional que reduce el riesgo de rotación. En la parte de la antigüedad del líder, por el contexto de compañía, puede llegar a asociarse con proyectos poco atractivos que están menos relacionados con oportunidades, lo que hace una zona de confort, sin ser un talento de tecnologías emergentes que puedan ser tentadas por la competencia. Líderes con menos antigüedad, puede ser incorporados de otras compañías donde una cultura diferente a la nuestra genere rotación en los equipos.

Oficinas, hay ecosistemas que aumentan las oportunidades del líder. Hay una influencia positiva de determinadas oficinas y con el contexto de negocio, son las que se encuentran en más sinergias con proyectos entre las diferentes unidades.

© ADIC-IIC

ISSN: 2792-3770

Unidades de negocio que generan altas oportunidades, hacen aumentar la capacidad del líder de estar presente en estos mercados emergentes.

La perspectiva de género

La perspectiva de género para tener en cuenta en oportunidades. Hay una diferencia entre hombre y mujer, teniendo mayores oportunidades los hombres.

7. Conclusión

El análisis realizado refuerza la creencia en el impacto positivo que la formación genera en las personas. Estar formado impacta económicamente tanto en la rotación como en las oportunidades de negocio que tiene el líder, haciendo disminuir pérdidas y aumentar ganancias en la compañía. Se hace indispensable continuar el estudio y plantearse nuevas preguntas. Conocer el nivel de retorno que revierte a la empresa el coste de inversión en formación. Con respecto a la rotación que previene y las oportunidades que capacita, si bien es cierto que el porcentaje de influencia es muy bajo, monetizarlo nos ayudará a convertir el dato en acción y posicionar a la universidad corporativa como eje estratégico para los retos de negocio de la compañía.

Será relevante el conocimiento accionable descrito anteriormente para poder dar respuesta a las estrategias a seguir para reducir la rotación, por un lado, y aumentar las oportunidades de negocio por otro lado, en los ámbitos donde hay influencia. Por ejemplo, sería interesante comenzar a trabajar sobre las variables que tienen en común ambos modelos predictivos:

- **Oficina:** Realizar acciones ad hoc con la dirección de oficinas que fomente la formación con el empoderamiento de cómo impulsa el acceso a más oportunidades para el líder y menos rotación en sus equipos. Podríamos comenzar de forma faseada por aquellas donde los índices están más bajos (oportunidades) y altos (rotación).
- **Escuelas de conocimiento:** En las escuelas de conocimiento de transformación digital y de gestión de proyectos traccionar a mediante acciones muy personalizadas con los no formados refuerzos de estas formaciones para poder promocionar su realización como predictores de su influencia oportunidades y rotación.
- **Tamaño equipos:** Establecer acciones desde el Staffing de los proyectos para ver cómo podríamos estructurar equipos de proyecto equilibrados. Aquí, a futuro sería interesante incluir una nueva variable que nos permitiese conocer la composición de esos equipos, así como el formato de trabajo que tienen (distribuidos, full remote, presencial), permitirá personalizar más las acciones a llevar a cabo.
- **Edad de los equipos:** Descubrir si hay silos en habilidades que necesitan los líderes para poder liderar a los equipos en función de la edad. Además de profundizar en futuros estudios centrados en sus equipos. Tener un perfil claro del tipo de profesional y poder diseñar de forma personalizada tanto áreas a potenciar como de mejora en nuestros planes de formación ligándolo con el patrón identificado.
- **Oportunidades de negocio:** Realizar sensibilización de la importancia de la formación como inversión ante lo que podría ser un coste oportunidad futura de proyectos disruptivos en los que no estamos preparados y podríamos perder cuota de mercado. Clusterizar a nuestro colectivo de líder que permita avanzar en la personalización de la formación que aplique en base a los tipos de proyecto.

Un aspecto adicional de interés de los resultados presentados es qué predice que los profesionales tomen la decisión de formarse. Los datos obtenidos, para el líder no formado, indican que para la decisión de formarse influirán los siguientes elementos:

- Sus equipos son más maduros en edad.
- Sus equipos tienen más antigüedad.
- Dispone de más oportunidades.
- Pertenece a determinadas unidades, destaca una unidad entre el resto como influyente en la formación.
- Tener entre 1 y 2 años de experiencia.
- Aumenta la probabilidad que se forme si es mujer.
- Aumenta la probabilidad que se forme si es top leader.
- Aumenta la probabilidad que se forme si aumenta su edad.

© ADIC-IIC

ISSN: 2792-3770

En definitiva, la formación es un elemento clave dentro del campo de recursos humanos que nos ayuda no solo a afrontar nuestros retos dentro del ámbito de las personas, si no que va más allá traspasando al entorno estratégico en la cuenta de resultados del negocio.

7.1. ANEXO 1. Análisis Descriptivo Adicional

1. Relación Formación - Rotación

- **Mayor rotación en no formados (15% vs 14% en formados).** Aunque la diferencia es pequeña, el análisis estadístico confirma que es significativa. Esto indica que la formación contribuye, aunque de manera moderada, a la retención.
- **Impacto en perfiles de liderazgo.** En Top Leaders la formación reduce de forma clara la rotación, mientras que en Lead el efecto es menos visible.
- **Efecto por género.** Tanto hombres como mujeres reducen su rotación cuando están formados, lo que demuestra un beneficio transversal.
- **Tipo de formación: Delivery School.** Es la escuela que más incide en reducir la rotación, al aportar herramientas prácticas de gestión y metodología de proyectos que refuerzan la permanencia de los equipos.

2. Relación Formación - Oportunidades de Negocio

- **Mujeres formadas con mayor acceso.** Cuando las mujeres están formadas, acceden a más oportunidades. La brecha de género desaparece si ambos grupos reciben formación.
- **Top Leaders con ventaja significativa.** La formación multiplica sus opciones de acceder a nuevas oportunidades, confirmando la relevancia de capacitar a quienes ocupan posiciones estratégicas.
- **Efecto de la edad.** Los profesionales jóvenes acceden más a oportunidades, independientemente de la formación, aunque ésta sigue reforzando el acceso en todos los tramos de edad.
- **Horas de formación con efecto limitado.** Existe una relación positiva y significativa, pero el efecto real es débil: más horas ayudan, aunque no explican gran parte de la variabilidad.
- **Tipo de formación: Digital Transformation y Evolving Talent.** Son las más influyentes en el acceso a oportunidades. La primera aporta conocimientos tecnológicos y la segunda habilidades blandas, ambas muy valoradas en el mercado.



© ADIC-IIC

ISSN: 2792-3770

ARTÍCULO 06

© ADIC-IIC

ISSN: 2792-3770



.06

Procesamiento de Lenguaje Natural para el análisis de entrevistas de salida en una empresa del sector retail y manufactura

Natural Language Processing for Analyzing Exit Interviews of Employees in a Retail and Manufacturing Sector Company

Brajhan Alexis Plazas Chávez
Correo electrónico:
Brajhan_plazas@hotmail.com

Linkedin:
https://www.linkedin.com/in/bplazas/

Pablo A. Haya Coll
Instituto de Ingeniería del Conocimiento

Correo electrónico:
pablo.haya@iic.uam.es

Linkedin:
https://www.linkedin.com/in/pablohaya/

Received: 16/01/2025
Received in revised form: 11/06/2025
Accepted: 12/07/2025
Available on-line: 15/10/2025

© ADIC-IIC

ISSN: 2792-3770



Resumen

En un contexto en donde la competencia por el talento es cada vez más desafiante para las organizaciones, se hace imperativo potenciar las prácticas en recursos humanos a fin de atraer y retener el mejor talento. Tradicionalmente, las entrevistas de retiro han sido una práctica muy común en esta área porque son esenciales para entender los motivos que subyacen al abandono de los empleados. Con el auge de la inteligencia artificial se han desarrollado nuevas técnicas para analizar grandes volúmenes de datos cualitativos. Lo cual pudiera ser una alternativa para superar las limitaciones de los métodos tradicionales y proporcionar una comprensión más profunda de las razones detrás de la rotación de empleados. En este contexto, este estudio investigó los factores que influyen en la rotación de empleados en una compañía de sector manufactura y retail, aplicando técnicas de procesamiento de lenguaje natural (PLN) utilizando el programa estadístico R y GPT4o para analizar datos de entrevistas de retiro. La muestra comprendió 400 entrevistas realizadas en Colombia y México, segmentadas por área de trabajo. A través del análisis de sentimientos y el análisis de frecuencia de palabras, se identificaron las principales razones de salida de los colaboradores y se hicieron hallazgos no solo previsibles mediante el análisis cuantitativo de la entrevista. Por ejemplo, que la variable agilidad y simplicidad fue el elemento más mencionado y que la calificación de sentimiento de todas las entrevistas sugiere una mayoría de opiniones neutras. Se concluye que, integrar análisis cuantitativos y cualitativos resulta enriquecedor y que las técnicas basadas en PLN agregan valor para encontrar patrones que no solo podrían obtenerse con el análisis numérico.

Palabras clave

Procesamiento de Lenguaje Natural (PLN), Entrevistas de Salida, Análisis de Rotación de Empleados, Software Estadístico R, Estrategias de Retención de Empleados, Datos de Empleados en Colombia y México, Inteligencia Artificial en Recursos Humanos.

Abstract

In a context where the competition for talent is increasingly challenging for organizations, it is imperative to enhance human resources practices to attract and retain the best talent. Traditionally, exit interviews have been a very common practice in this area because they are essential for understanding the reasons behind employees' departure. With the rise of artificial intelligence, new techniques have been developed to analyze large volumes of qualitative data, which could be an alternative to overcome the limitations of traditional methods and provide a deeper understanding of the reasons behind employee turnover. In this context, this study investigates the factors influencing employee turnover in a manufacturing and retail company by ap-plying natural language processing (NLP) techniques using the statistical program R to analyze exit interview data. The sample comprises 400 interviews conducted in Colombia and Mexico, segmented by work area. Through sentiment analysis and word frequency analysis, the main reasons for employees leaving were identi-fied, and findings were made that were not only predictable through the quantitative analysis of the interview. For example, the variable agility and simplicity was the most mentioned element, and the sentiment rating of all interviews suggests most of neutral opinions. It is concluded that integrating quantitative and qualitative analyses is enriching and that NLP-based techniques add value in finding patterns that could not be obtained solely with numerical analysis.

Keywords

Natural Language Processing (NLP), Exit Interviews, Employee Turnover Analysis, Statistical Software R, Employee Retention Strategies, Employee Data in Colombia and Mexico, Artificial Intelligence in Human Resources.

© ADIC-IIC

ISSN: 2792-3770

1. Introducción

Han existido tradicionalmente prácticas de recursos humanos que se han consolidado de manera masiva en las organizaciones, sin embargo, el uso de algunas de ellas como por ejemplo las entrevistas de retiro, ha planteado de entrada dificultades en su interpretación y análisis por la naturaleza cualitativa de la información; en especial para organizaciones que recolectan un gran volumen de estas. El uso de este tipo de información es fundamental en recursos humanos y en las organizaciones de forma más general, puesto que suponen un insumo importante para poder entender en profundidad los motivos por los cuales los colaboradores se marchan. También, esto permite identificar no solo las oportunidades de mejora sino también los elementos más destacados de una cultura organizacional. Esto es particularmente muy útil para construir una marca empleadora diferencial, asegurando, por ejemplo, que antiguos trabajadores puedan convertirse en embajadores de una compañía y que puedan recomendarla como un buen lugar para trabajar, lo que impacta directamente en la capacidad de retener talento (Spain & Groysberg, 2016).

Por otra parte, una de las prioridades de las áreas de recursos humanos ha sido poder hacer objetiva su gestión basando sus acciones en la riqueza de los datos. Esta demanda en su gestión y que viene de otras áreas de la organización justifica que las prácticas deban aumentar su confiabilidad y profundidad en la interpretación de la información que administra esta área.

En tiempos más recientes y con el auge de la inteligencia artificial, el desarrollo de nuevas tecnologías hace disponible nuevos métodos para la interpretación y análisis de información extensa y cualitativa. Dentro de este grupo de técnicas se encuentra el procesamiento de lenguaje natural o por sus siglas PLN; en inglés NLP, el cual se define como la capacidad de las máquinas mediante un grupo de técnicas computacionales para realizar tareas asociadas al lenguaje humano tal como comprenderlo, identificar patrones y tomar decisiones. De la misma manera el análisis de texto mediante PLN ha mostrado tener un amplio número de aplicaciones como son la construcción de redes neuronales, traducción automática, análisis de sentimientos, construcción de chatbots, entre otros. Estas aplicaciones se han extendido en diversos sectores como lo son finanzas, salud, educación, entre otros (Cofino, C. L., Escorial, R. B., & Enquilino, D. L. B., 2024).

Uno de los métodos más utilizados derivados del PLN es el análisis de sentimiento o minería de opinión, el cual tiene como finalidad determinar la actitud o el estado emocional con la que un autor emite un comentario o una opinión. Este proceso determina una puntuación cuantitativa de una cadena de texto haciendo una valoración de una o varias palabras asignando una puntuación negativa o positiva. Esta puntuación puede realizarse mediante el comparativo con bases de datos ya preestablecidas y construidas por diversos autores o mediante técnicas más elaboradas como un análisis semántico utilizando otros recursos de inteligencia artificial. Esta técnica se ha utilizado principalmente en sectores como servicio al cliente para poder analizar grandes volúmenes de información e identificar cuáles son las mayores áreas de oportunidad para ajustar procesos como diseño de producto o marketing (Lakhchini, W., & Aknin, A.,2023). También, se ha utilizado en la creación de herramientas como Sloan Review - Culture 500 desarrollada por MIT la cual realiza un análisis de más de 1 millón de comentarios que asignan empleados activos o retirados de las 500 compañías con mayores ingresos según la revista Fortune en la plataforma Glassdoor®. La cual a su vez es un sitio en línea donde se califican anónimamente elementos asociados a cultura y ambiente laboral dentro de las organizaciones. Posterior a este análisis, todos los comentarios se clasifican utilizando PLN y ordenan a las compañías en las siguientes variables de cultura: agilidad, diversidad, integridad, colaboración, ejecución, desempeño, atención a clientes innovación y respeto. Esto permite a futuros colaboradores identificar cuáles son las fortalezas y mayores áreas de oportunidad de las organizaciones, lo cual tiene un impacto directo sobre la percepción de marca empleadora de estas organizaciones.

Esta es solo una de las aplicaciones en los cuales la inteligencia artificial tiene una ampliación en prácticas en recursos humanos. En los últimos años se ha utilizado el análisis de texto y el procesamiento de lenguaje natural en los siguientes campos específicos de recursos humanos: reclutamiento, análisis de sentimiento y retroalimentación, gestión del desempeño, cumplimiento y análisis legal, planificación de sucesión y entrenamiento (AIHR, 2022).

© ADIC-IIC

ISSN: 2792-3770

2. Justificación del problema

La rotación de personal es un desafío crítico en sectores como manufactura y retail, donde la competencia por el talento es intensa en especial para niveles de cargo más operativos. En México la alta rotación y la competencia de talento son particularmente pronunciadas por una alta demanda laboral y poca disponibilidad de talento. De hecho, los estudios laborales de organizaciones como las cámaras de comercio estatales en México han encontrado que existe un déficit en la fuerza laboral de varios estados en comparación con la necesidad de trabajadores. Estas diferencias aumentan en particular en compañías de sector manufacturero y de acuerdo con el portal Factorial las tasas de rotación promedio en este país son del 16 % lo cual la constituye en la más elevada en toda Latinoamérica (Factorial, 2024).

En Colombia, y de acuerdo con los análisis de rotación presentados por la firma consultora Page Group, la rotación promedio se encuentra entre el 10 y 15 %. Y en esta geografía, los sectores que cuentan con mayores niveles de rotación a cierre de 2023 fueron retail, ventas y consumo masivo; en particular sobre retail el 75 % los colaboradores abandonan su trabajo en menos de un año, lo cual marca una diferencia importante versus otros sectores como tecnología o finanzas en donde los porcentajes son 38 % y 45 % respectivamente. En contraste y de acuerdo con el mismo estudio, en las posiciones de mayor nivel en la estructura organizacional los niveles de rotación tienden a ser menores lo que genera que el panorama general en Colombia sea algo más alentador, considerando que estas últimas posiciones tienen un mayor impacto en la estrategia de los negocios.

De forma general no cubrir las posiciones en la cobertura y los tiempos necesarios se convierte en uno de los retos principales para las organizaciones que operan en estos sectores y en particular en algunas regiones sobre otras, puesto que este fenómeno no solo incrementa los costos operativos y pone en riesgo la continuidad de los negocios, sino que también afecta la motivación y productividad de los empleados activos al tener que sobrecargarse con actividades de las posiciones no cubiertas.

Siendo así, poder determinar los motivos que subyacen el retiro de los colaboradores se convierte en un insumo valioso para comprender el problema y posteriormente tomar decisiones que permitan contrarrestar el impacto negativo de la alta rotación. Es así como, las entrevistas de retiro son uno de los recursos principales para tal propósito. Sin embargo, a menudo no se profundiza en los datos cualitativos que se recolectan, lo que impide a las organizaciones entender completamente los motivos detrás de la rotación.

Con la aparición de nuevas tecnologías se puede analizar de forma ordenada un gran volumen de datos, no solo mediante de naturaleza cuantitativa, sino que el uso de la inteligencia artificial y en concreto del PLN permite un análisis más profundo y eficiente de datos de origen cualitativo como lo son los comentarios, proporcionando perspectivas valiosas que pueden ser utilizados para mejorar las estrategias de retención, marca empleadora y la gestión en recursos humanos.

En línea con lo anterior, el objetivo de este proyecto asociado a analítica de Recursos Humanos consistió en aplicar técnicas avanzadas de análisis de datos e inteligencia artificial en un conjunto de entrevistas de retiro para identificar factores clave que influyen en la rotación, así como detectar tendencias, fortalezas y áreas de oportunidad, y proponer estrategias que contribuyan a mejorar la retención de los colaboradores de la organización.



© ADIC-IIC

ISSN: 2792-3770

3. Método

El presente estudio aplica herramientas de PLN para analizar la información recolectada mediante entrevistas de retiro en una empresa multisector de manufactura y retail, con operaciones en Colombia y México. La información analizada proviene de 400 entrevistas realizadas a colaboradores que abandonaron por jubilación y voluntariamente la organización durante los años 2023 y 2024, Estas entrevistas se realizaron de forma centralizada por un profesional en psicología y recolectadas mediante un formato de entrevista semiestructuradas. Los informes se consolidaron de forma virtual para su facilidad en la recolección de datos. La distribución de las entrevistas por sector y país se puede identificar en la tabla 1. Para los fines de este estudio, se ha optado por incluir entrevistas a personas que han alcanzado la etapa de jubilación. Aunque esta práctica no es común en las áreas de recursos humanos, dichas entrevistas pueden ofrecer información valiosa sobre los factores protectores que favorecen la retención del talento dentro de las organizaciones.

Tabla 1. Porcentaje entrevistas por área y región

Área	Colombia	México	Total
Retail	*28,8 %*	*0 %*	*28,8 %*
Manufactura	*28 %*	*28,8 %*	*58,8 %*
Otros	*10,6 %*	*1,8 %*	*12.4 %*
Total	*67,1 %*	*32,9 %*	*100 %*

El formato de entrevista se diseñó buscando ser representativo de varios elementos de la organización tales como clima, cultura, remuneración, beneficios, liderazgo, entre otras que se describen a continuación.

Variables a consideración.

Mediante entrevistas de Retiro:

- **Motivos de Retiro:** Se identifican hasta 3 razones específicas por las cuales los empleados decidieron dejar la empresa. Entendiendo que muchas veces el retiro no solo se da por una causa. Las opciones se limitaron y estandarizaron según experiencias previas de entrevistas de retiro en la organización.
- **Valoración Likert de Factores Principales de la Organización:** Los empleados valoran distintos factores de la organización utilizando una escala Likert de 5 niveles.
- **eNPS (Employee Net Promoter Score):** Mide la disposición de los empleados a recomendar la empresa como un lugar para trabajar. Toma valores entre 0 y 10.
- **Respuestas Cualitativas sobre Aspectos Positivos y Negativos del Líder y de la Organización:** Se recogen opiniones detalladas sobre los líderes y la organización en general. Para los análisis de este trabajo se tuvieron en consideración las siguientes preguntas:
  - ¿Qué habría influido para que la decisión fuera quedarse en la compañía? Esta pregunta se denominará “Factor_Quedarse” para los análisis cualitativos posteriores.
  - ¿Hay algún comentario/situación que quieras ampliar o que no se haya preguntado en este formulario?, esta pregunta se denominará “Ampliación” para los análisis cualitativos posteriores.

Adicionalmente y para propósitos de análisis se incluyeron las siguientes variables:

- **Mediante HRIS (Sistema de Información de Recursos Humanos):**
  - **Antigüedad:** Número de años que el empleado ha trabajado en la empresa.
  - **Género:** Identificación de género del empleado.
  - **Ciudad:** Ubicación geográfica del empleado.
  - **Área:** Departamento o área en la que trabaja el empleado.
  - **Cargo:** Posición laboral en la organización.

© ADIC-IIC

ISSN: 2792-3770

Para analizar la información cuantitativa se utilizó Microsoft Excel y RawGraphics 2.0; para la información cualitativa se utilizó el software estadístico R para el cual se utilizaron varios paquetes de los cuales se resaltan los que se describen a continuación:

1. **dplyr:** Proporciona herramientas generales para la manipulación y transformación de datos.
2. **tidytext:** Permite el procesamiento, tokenización y análisis de datos textuales de manera ordenada.
3. **ggplot2:** Facilita la creación de gráficos y visualizaciones de datos.
4. **Wordcloud:** para la realización de nubes de palabras, herramienta útil en análisis cualitativo.

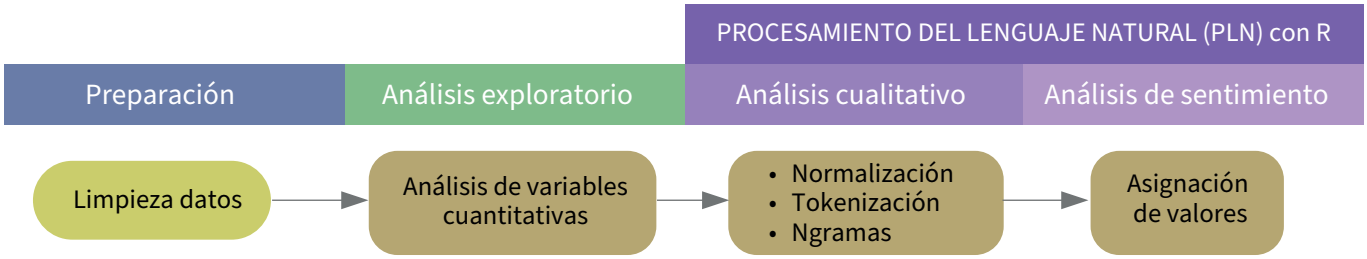


Gráfico 1. Flujo proceso análisis de datos con inteligencia artificial

4. Resultados

Para iniciar el proceso de análisis se practicó una limpieza de los datos, eliminando registros que pudieran no estar completos o que correspondieran a regiones fuera del propósito de este estudio.

4.1. Motivo primario de retiro

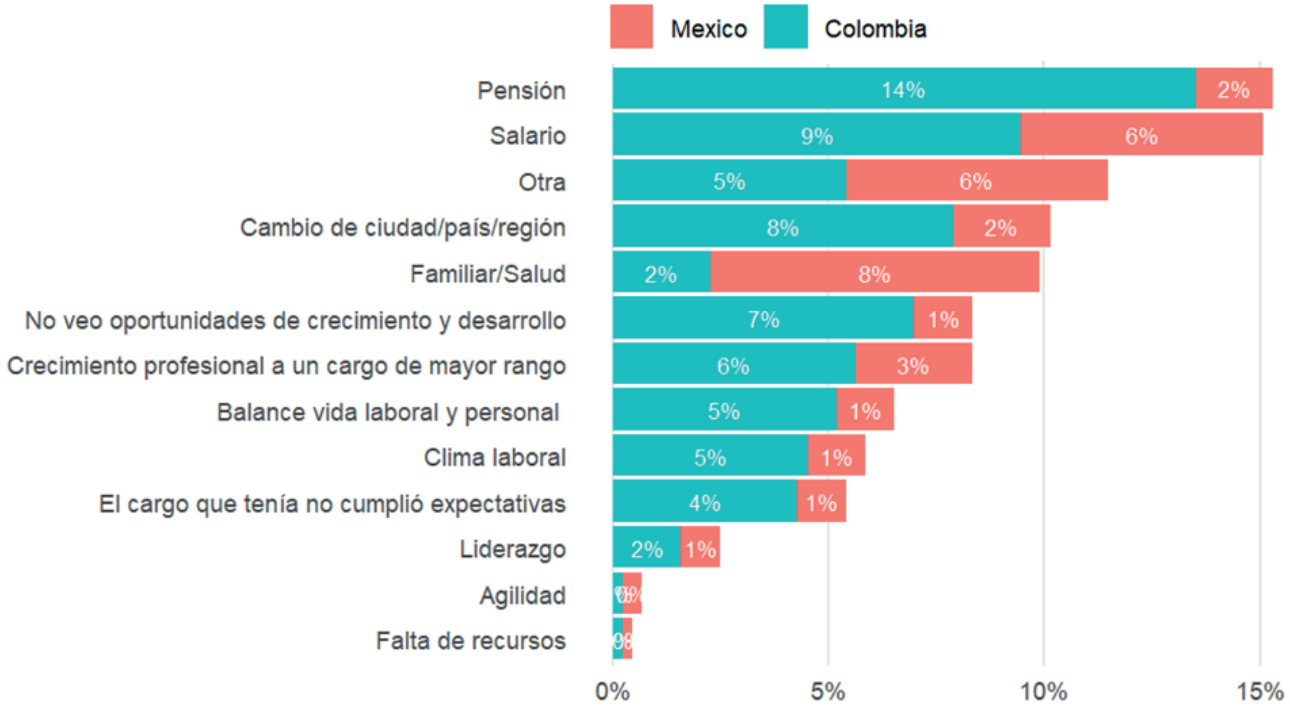
Al explorar las variables cuantitativas, se realizó un análisis de las preguntas de la encuesta para identificar los principales motivos de abandono de los puestos por país. Estos motivos fueron obtenidos mediante la pregunta cerrada “Motivo Primario de Retiro”.

Al observar los resultados segmentados por región podemos identificar que en Colombia el principal motivo de retiro es Jubilación o Pensión, representando un 13 % del total de casos, seguido por Salario con un aproximadamente 9 %. Estos hallazgos son coherentes porque esta compañía lleva mucho más tiempo de presencia en Colombia que en México, lo cual se traduce directamente a ciclos de vida más largos. En comparación, en México, los principales motivos de retiro se asocian a temas familiares o de salud tanto propios como de algún familiar, con un porcentaje cercano al 8 %, seguidos por Otros motivos con un 6 %, en tercer lugar, temas relativos a Salario con un 6 %. Un aspecto para destacar en la recolección de información es que la entrevistadora ha percibido una mayor facilidad para contactar a las personas en Colombia, en contraste con México, donde este proceso parece ser más desafiante y requiere mayores esfuerzos de persuasión para obtener información detallada sobre los motivos de retiro. Esto podría sugerir algunas diferencias culturales, aunque sería necesario realizar más investigaciones para fundamentar estas observaciones con mayor certeza.

© ADIC-IIC

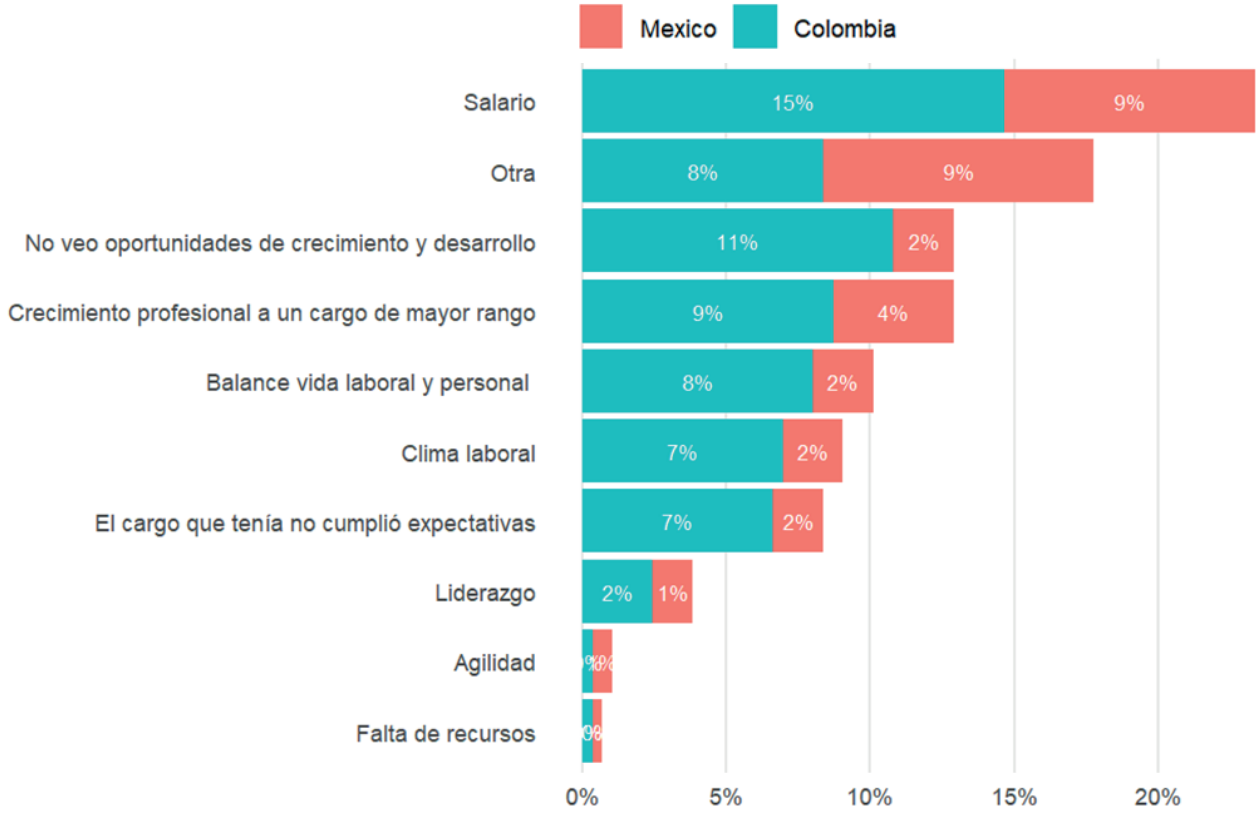
ISSN: 2792-3770

Gráfico 2. Principales motivos de retiro por país



Dentro de estas causas identificamos tres causas que son ajenas a las palancas que puede ejercer la compañía: Pensión, Familiar/Salud y Cambio de ciudad/país/región. Filtrando estas causas queda patente que la causa más importante de retiro es el Salario que se recoge en un 24 % de las encuestas incluyendo las dos regiones. También es importante mencionar que Colombia tiene una representación importante dos causas de retiro relacionadas con el crecimiento personal en la empresa: No veo oportunidades de crecimiento y desarrollo con un 11 %, y Crecimiento profesional a un cargo de mayor rango con un 9 %. Ambas suman un 18 % de las encuestas.

Gráfico 3. Motivos de retiro más relevantes por país, considerando solo factores gestionables por la organización



© ADIC-IIC

ISSN: 2792-3770

Con relación al liderazgo, el cual es uno de los elementos que de acuerdo a la firma consultora Great Place to Work (GPTW, 2024) el liderazgo es la principal piedra angular para la retención en la organización. Se puede observar en la gráfica 3 que este no supone uno de los motivos de preocupación. En la encuesta se incluye hasta cuatro preguntas relacionadas con el liderazgo del jefe inmediato que corroboran estos datos. Más del 74 % de los encuestados puntúan 4 o 5 en una escala del 1 al 5 a su jefe inmediato siendo los puntos más positivos dentro del liderazgo: el acompañamiento, clima, y comunicación adecuada. Estos datos parecen ser coherentes con las evaluaciones de clima laboral internas de la organización en donde se percibe de forma general un buen nivel en estilo de liderazgo, particularmente en Colombia.

Es reseñable que cuando se pregunta por aspectos de mejora más del 45 % responde que ninguno. Sólo un 30 % incluyen algún comentario. En la tabla 2 se resumen los aspectos de mejora segmentados por región y área dentro de la empresa. No se analiza el área de Otras porque se disponen de pocos comentarios (12 en Colombia y uno en México respectivamente).

Tabla 2. Aspectos de mejora del liderazgo

	COLOMBIA	MÉXICO
MANUFACTURA	**Disponibilidad**, gestión y trato humano. **Comunicación:** falta de flexibilidad y reconocimiento de logros, con comunicación deficiente que genera desconfianza y temor a expresar inquietudes. Respuestas impulsivas. **Mayor capacitación** y claridad en los objetivos.	**Disponibilidad** y apoyo del jefe en el área para enseñar o guiar limitan el aprendizaje y el crecimiento de los colaboradores **Comunicación** deficiente y distante que genera desconexión y desinformación entre los turnos. La ausencia de retroalimentación. **Favoritismo** y asignación desigual de tareas.
RETAIL	**Falta de acompañamiento** y apoyo constante. **Actitudes autoritarias** y favoritismo, con discriminación hacia otros, especialmente en términos de género. **Comunicación** es percibido como hiriente o irrespetuoso. **Sobrecarga laboral** para algunos empleados **Falta de claridad** en los objetivos	

© ADIC-IIC

ISSN: 2792-3770

Al analizar la Tabla 2, se identifican diferencias notables en relación con las áreas, destacando un mayor número de elementos en el sector retail. Este hallazgo es consistente con los resultados obtenidos en las encuestas internas de clima laboral de la organización, donde se percibe un liderazgo menos maduro y con una mayor tendencia a ser autoritario.

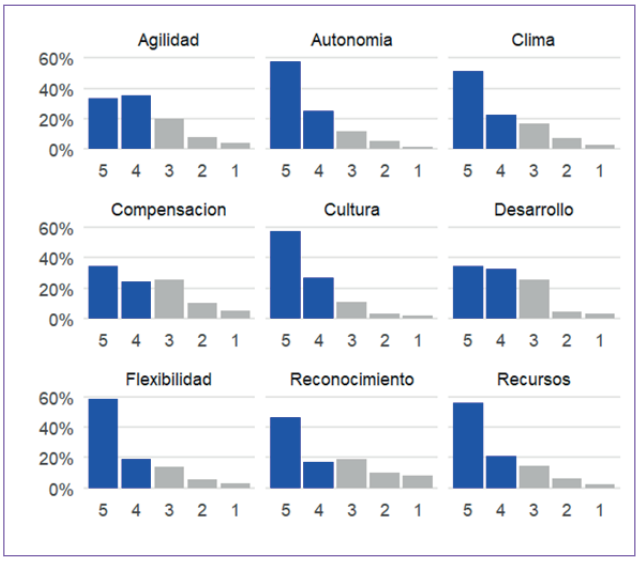
4.2. Dimensiones y Mejora

La encuesta incluye una pregunta donde se califica a la compañía en las siguientes dimensiones:

- Clima, la cual se refiere a los aspectos de equidad, liderazgo y compañerismo.
- Cultura, se refiere a las características como valores y comportamientos vividos en la organización.
- Desarrollo, se refiere a todas las oportunidades de crecimiento o aprendizaje facilitadas por la organización en cuanto a recursos o posibilidad de crecimiento en la estructura organizacional.
- Compensación, se refiere a todo el paquete salarial incluyendo beneficios excepcionales que puedan ser atractivos
- Recursos, se refiere a todos los elementos suministrados por la organización para el desarrollo de las actividades en el cargo, tanto en elementos físico como digitales.
- Agilidad, se refiere a la la forma en que se tomadas las decisiones en la organización.
- Autonomía, se refiere a la capacidad de las personas de tomar decisiones de forma independiente sin requerir la autorización de otros.
- Reconocimiento, se refiere a todos los reconocimientos no salariales mediante rituales o prácticas culturales tales como retroalimentaciones verbales o escritas.
- Flexibilidad, se refiere a todas las opciones que promuevan balance vida trabajo, como teletrabajo o días extra de descanso.

Cada dimensión se puntúa desde 1 a 5 siendo 1 el valor más bajo y 5 excelente. En la gráfica 4 se muestran los resultados de las puntuaciones para cada dimensión. Se observa que las dimensiones de Agilidad, Compensación, Desarrollo y Reconocimiento presentan puntuaciones más bajas que el resto. En estas cuatro dimensiones el porcentaje de puntuaciones altas (5 ó 4) está por debajo del 70 % (68 %, 58 %, 66 % y 63 % respectivamente).

Gráfico 4. Calificación Likert por dimensión



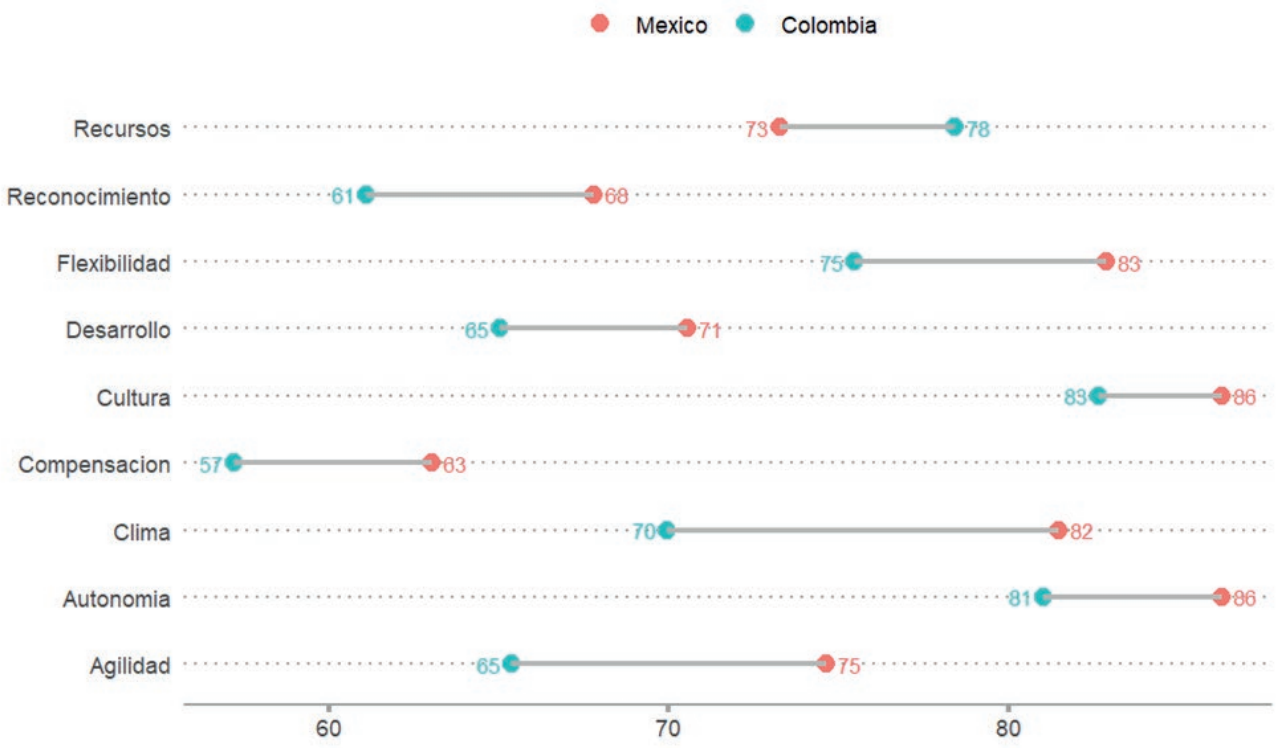
© ADIC-IIC

ISSN: 2792-3770

Si desglosamos el porcentaje de puntuaciones más altas (5 ó 4) por región podemos observar que en la región de México las puntaciones son sensiblemente más altas que en Colombia excepto en la dimensión Recursos. En el gráfico 5 representan los porcentajes de respuestas más altas para cada dimensión segmentados por región.

Al analizar las variables con mejores resultados generales, se observa que la cultura y la autonomía destacan por sus altas puntuaciones. Estos elementos se alinean con los atributos identitarios de la marca empleadora proyectados por la organización estudiada en este estudio. En contraste, la dimensión de compensación continúa siendo la peor valorada. Este resultado es consistente con la dinámica de los mercados de talento evaluados, caracterizados por una alta competitividad salarial en particular en el sector manufacturero.

Gráfico 5. Calificación Likert por dimensión



© ADIC-IIC

ISSN: 2792-3770

4.3. Employee Net Promoter Score

El Employee Net Promoter Score (ENPS) se mide mediante una pregunta estándar en la que se pide que indique la probabilidad de recomendar a la empresa a terceros en una escala del 1 al 10. Las respuestas indican que el 88 % de los empleados puntúan por encima de 7. En la Gráfica 6 se muestra la distribución de estas puntuaciones donde se observa que más del 50 % valora con un 10 a la empresa.

El eNPS se calcula como:

% de (#Promotores – #Destractores) / Total

es decir que su forma de interpretarlo es un valor que puede ir desde -100 a 100, en general Un eNPS positivo, aunque no llegue a 100, generalmente se considera un indicador de satisfacción de los trabajadores, mientras que un eNPS negativo sugiere que hay áreas de mejora en la satisfacción de los empleados.

Aunque no es común encontrar benchmarks específicos por región o país de manera abierta, el portal Perceptyx señala que un valor de referencia promedio en Estados Unidos para múltiples sectores es 12. Por otro lado, fuentes como Peoplelytics destacan que, con datos de 2021, los sectores relacionados con tecnología presentan los puntajes más altos, con promedios entre 30 y 40, mientras que otros como el de educación tienen los valores más bajos, con promedios entre 0 y 10.

Dentro de esta valoración positiva, si comparamos el ENPS de las causas que son ajenas a las palancas que puede ejercer la compañía (Pensión, Familiar/Salud y Cambio de ciudad/país/región) con el ENPS del resto de causas se observa que hay más de un punto de diferencia en promedio (9.32 frente 8.18). La Gráfica 7 explica gráficamente esta diferencia. Los valores medios de ENPS Pensión y Familiar/Salud son los más elevado, posicionándose Cambio de ciudad/país/región en cuarto lugar.

Gráfico 6. Calificación Likert por dimensión

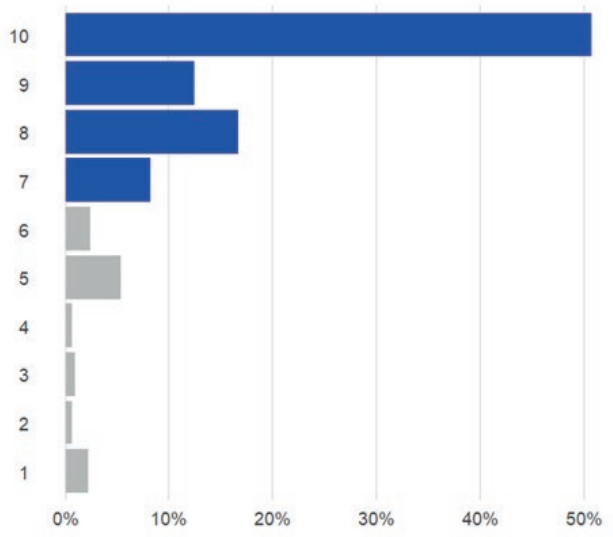
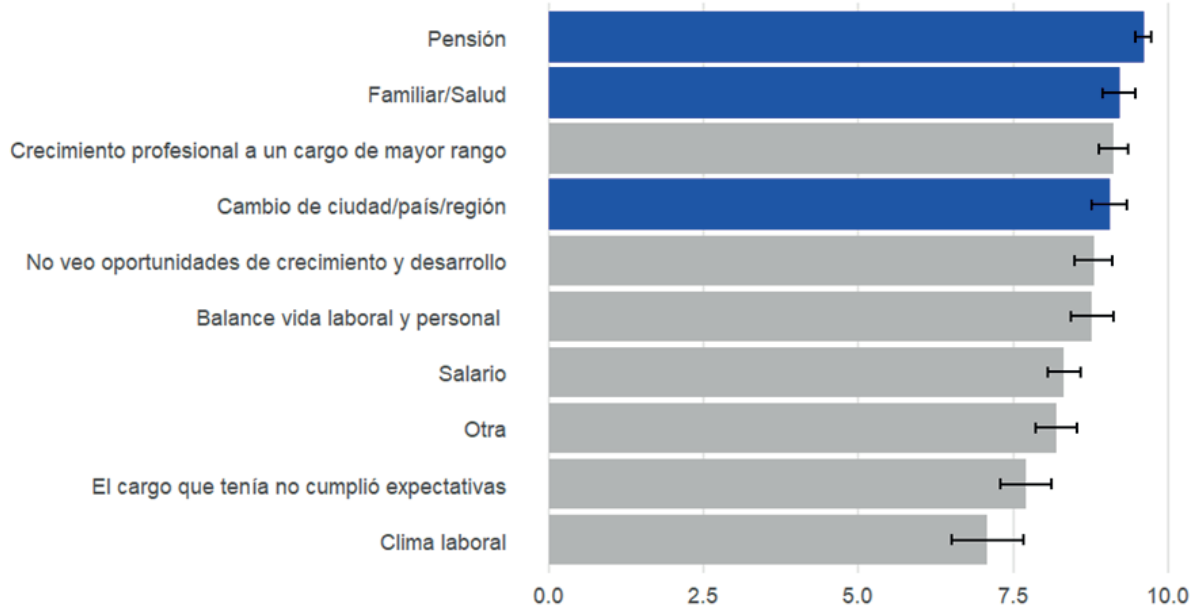


Gráfico 7. Calificación Likert por dimensión



© ADIC-IIC

ISSN: 2792-3770

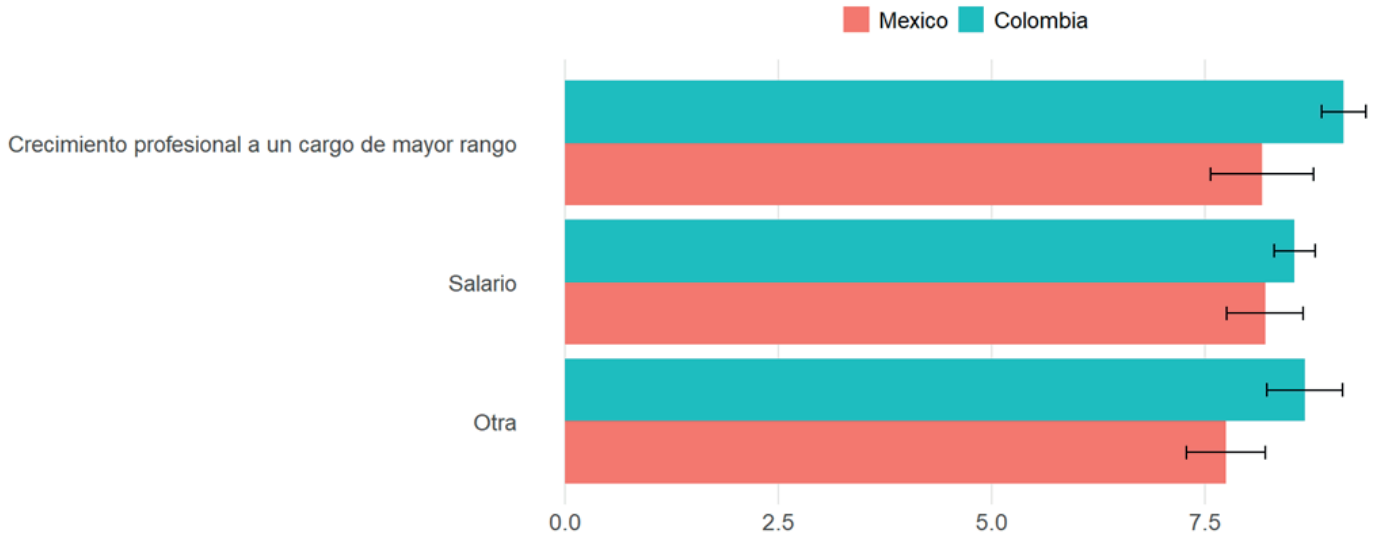
En la Tabla 1 se observa que hay un porcentaje muy similar de entrevistas en el área de Manufactura tanto en Colombia como México, lo cual permite realizar una comparación entre las dos regiones. Como era previsible, el ENPS de aquellos empleados que se retiran por causas ajenas a la compañía es similar, mientras que se observa una diferencia de más de medio punto en las causas donde la compañía tiene capacidad de acción (véase Tabla 3).

	ENPS (Manufactura)	
Área	Ajenas	Propias
Colombia	9.30	8.4
México	9.38	7.74

Tabla 3. ENPS por Región y Área

Una comparativa en aquellas causas donde se han recopilado más de diez entrevistas arroja diferencias significativas en las causas de Crecimiento profesional a un cargo de mayor rango y Otra (véase el Gráfico 8).

Gráfico 8. Motivos de retiro con Diferencias Significativas



4.4. Factor quedarse

Al analizar la pregunta "Factor Quedarse", la gráfica 9 muestra que el 76 % de los términos se relaciona con las causas de retiro previamente identificadas sobre las cuales la compañía no tiene influencia directa. Estos motivos se agruparon bajo el concepto homologado de "No_directo", facilitando así la interpretación de los resultados. Por ejemplo, este concepto incluye temas como problemas de salud o movilidad hacia otras ciudades o países, en los cuales la compañía no puede intervenir directamente para retener al colaborador. En el cual se identifican que salario y crecimiento son los elementos más frecuentes mencionados por los colaboradores para quedarse en la organización.

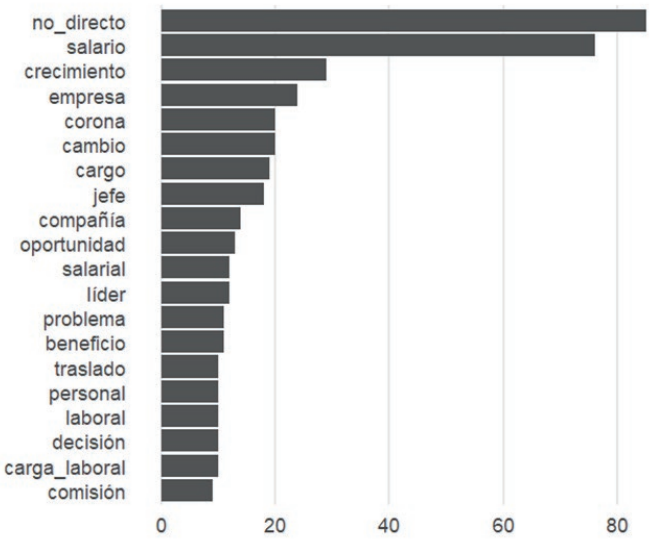


Gráfico 9. Palabras más frecuentes en Factor_Quedarse

© ADIC-IIC

ISSN: 2792-3770

Al realizar un análisis cualitativo y complementario utilizando inteligencia artificial con ChatGPT 4o como se identifica en la tabla 4 sobre los comentarios que mencionan las palabras Salario y Crecimiento, se puede identificar que el detalle de la información recolectada en dicha pregunta no es muy amplio. Por ejemplo, el 39 % de los comentarios solo responden a dicha pregunta mencionando las palabras, salario, incremento salario o mejor salario sin algún contexto adicional, lo cual no permite un análisis más profundo sobre qué otro elemento relacionado a la compensación pudiera mejorarse. Solo en retail logra identificarse que las personas que abandonan la organización quisieran tener mayor claridad de los procesos de asignación sobre el mismo.

Análisis cualitativo de comentarios asociados a “salario” y "crecimiento" en pre-gunta “Factor_quedarse”

	MANUFACTURA	RETAIL	OTRAS
COLOMBIA	Oportunidad de crecimiento profesional y plan de carrera son destacados como motivos de permanencia deseada.	Crecimiento profesional y claridad en el proceso de ascenso son factores men-cionados para quedarse.	Crecimiento salarial y profesional, con énfasis en un plan de carrera y re-conocimiento.
MÉXICO	Crecimiento en salario, así como oportunidades de aprendizaje y crecimiento laboral.	N/A	N/A

Tabla 4. Análisis cualitativo en pregunta “Factor_Quedarse”

4.5. Ampliación

Con base en los resultados reflejados en la gráfica 10, que analiza las respuestas a la pregunta “Ampliación”, se observa que "jefe" y "compensación" son los términos más mencionados, apareciendo en el 25% de las entrevistas en total. Esto los posiciona como factores clave para los colaboradores, ya que están directamente relacionados con la percepción del liderazgo y los beneficios económicos ofrecidos por la organización.

Cabe destacar que "líder" y "jefe" podrían estar haciendo referencia a un mismo concepto, lo que sugiere que el impacto del liderazgo en la percepción general podría ser mayor de lo que reflejan los datos individuales. Este hallazgo es consistente con las definiciones propuestas en las teorías organizacionales, donde el liderazgo se reconoce como un factor clave en la experiencia de los empleados.

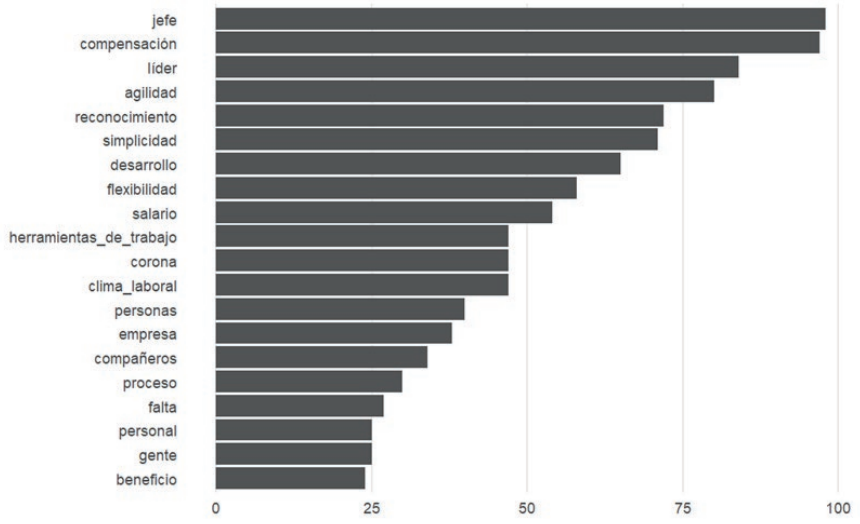


Gráfico 10. Palabras más frecuentes Ampliación

© ADIC-IIC

ISSN: 2792-3770

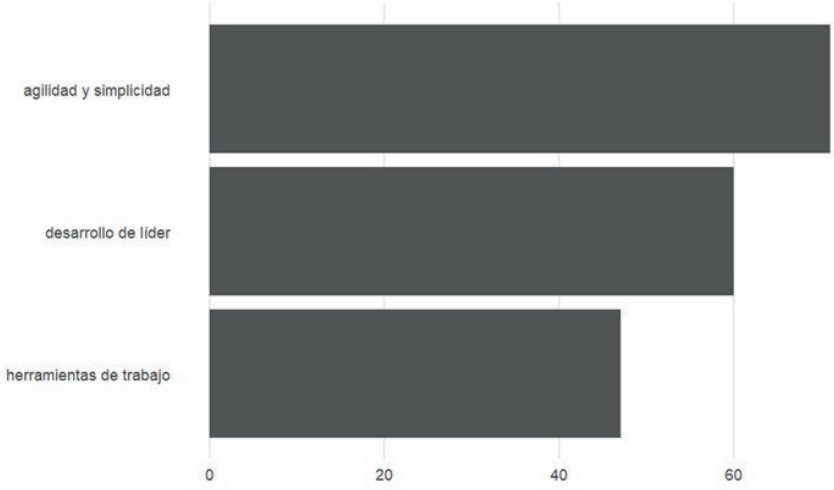


Gráfico 11. Palabras más frecuentes en la variable "Ampliación"

Teniendo en cuenta que "Agilidad y simplicidad" fue el conjunto de palabras más mencionada dentro de todas las entrevistas de la pregunta "Ampliación" se hizo un análisis cualitativo de los 78 comentarios que hacen por lo menos alguna mención a "agilidad y simplicidad". Esta información fue potenciada y complementada con un análisis en GPT4o. Los resultados se dividieron por país y área y se presentan en la tabla 4.

Análisis cualitativo de comentarios asociados a "agilidad y simplicidad"

	MANUFACTURA	RETAIL	OTRAS
COLOMBIA	**Agilidad:** Necesidad de mejorar la agilidad en la toma de decisiones y en la implementación de cambios que involucran varias áreas, y evitando exceso de aprobadores. **Simplicidad:** Necesidad de simplificar los procedimientos administrativos y operativos complejos mediante la digitalización de procesos repetitivos.	**Agilidad:** Énfasis en la capacidad de respuesta rápida a demandas del cliente y adaptación a cambios del mercado. **Simplicidad:** Simplificación de los sistemas de punto de venta y procesos de atención al cliente, buscando interfaces más fáciles de usar y procedimientos menos engorrosos para áreas de venta y soporte.	**Agilidad:** Necesidad de reducir la carga administrativa para mejorar la agilidad en las tareas diarias. **Simplicidad:** Se requiere mejores herramientas de trabajo para ser más eficientes.
MÉXICO	**Agilidad:** Necesidad de agilizar los procesos de producción para reducir tiempos y mejorar la coordinación entre departamentos, evitando cuellos de botella que retrasen las operaciones **Simplicidad:** Simplificar la cadena de suministro y la gestión de inventarios mediante sistemas más intuitivos y menos pasos burocráticos para la gestión de stock, lo que permitiría una respuesta más rápida a las demandas del mercado.	N/A	**Agilidad:** Énfasis en la rapidez de los sistemas de información y necesidad de herramientas tecnológicas más eficientes. **Simplicidad:** Simplificación de la interfaz de usuario y reducción de pasos en procesos de aprobación.

Tabla 5. Análisis cualitativo "Agilidad y Simplicidad"

© ADIC-IIC

ISSN: 2792-3770

Finalmente, se realizó un análisis de sentimientos de todas las entrevistas mediante la comparación con una base de léxico de sentimientos denominada AFINN. En dicha base se asigna una puntuación entre -5 a 5 a diferentes palabras en función del sentimiento que puedan estar describiendo en total la oración. Es importante aclarar que, aunque estas puntuaciones son por palabra, el gráfico presenta la suma total de los puntajes por entrevista completa. Es decir, cada punto del eje horizontal representa el resultado acumulado del análisis de sentimiento de una entrevista, en este caso los valores totales oscilan entre -30 y +10.

En el gráfico 12 se observa que las entrevistas realizadas en Colombia tienden a acumular valores más positivos en comparación con las de México. Esta diferencia sugiere una mayor presencia de lenguaje positivo en las entrevistas colombianas, lo cual está alineado con otros resultados de esta investigación.

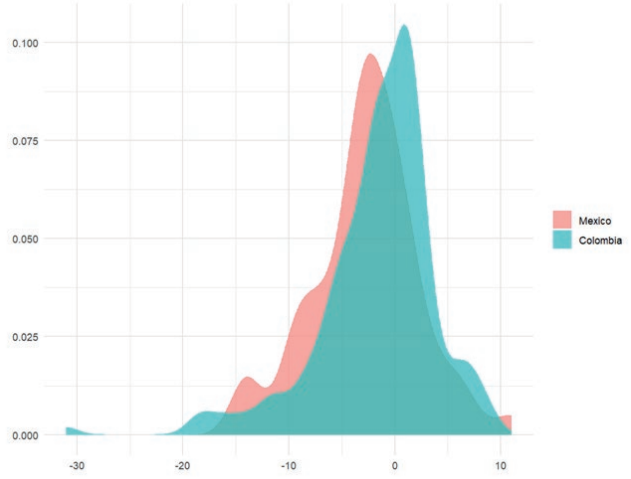


Gráfico 12. Análisis de Sentimiento por País

En relación a las diferencias entre áreas podemos encontrar que los resultados del área de retail se ubican algo más a la derecha versus los de manufactura, una explicación a esto puede estar en que en el área de retail solo existe en Colombia, geografía donde se han obtenidos mejores resultados de forma más general.

No se realizó este tipo de gráfico para la variable "Factor_quedarse", correspondiente a la pregunta "¿Qué habría influido para que la decisión fuera quedarse en la compañía?" debido a que esta pregunta busca identificar elementos positivos que motivarían a los colaboradores para mantenerse en la organización. Por lo tanto, es

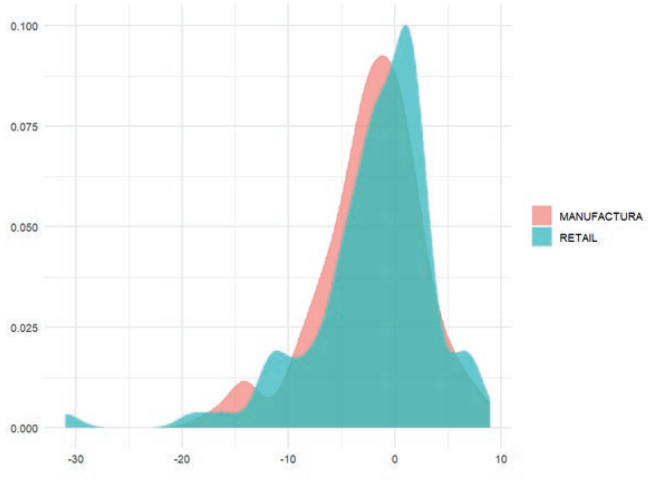


Gráfico 13. Análisis de Sentimiento por área



© ADIC-IIC

ISSN: 2792-3770

5. Discusión

Haciendo un análisis general sobre los resultados cuantitativos podemos identificar que sí existen diferencias entre los motivos de retiro para los países analizados. Por una parte, Colombia presenta retiros asociados a jubilaciones/pensión y luego salario mientras que en México obedecen a temas familiares, una explicación directa de estas diferencias podría estar en que la antigüedad promedio de los empleados activos en Colombia son superiores a los de México. Es probable que la relación de confianza sobre el empleador de parte de los trabajadores de Colombia hace que su abandono sea hasta culminar su ciclo de carrera profesional. Por otra parte, en general, el mercado de talento en México resulta ser más desafiante y competido que el Colombiano, lo cual podría asociarse en una mayor disponibilidad de ofertas de empleo y por ende de mayor probabilidad de que las personas encuentren otras opciones de trabajo lo que aumenta naturalmente la rotación. También, esta organización lleva mayor tiempo operando en Colombia que en México y tiene más consolidada su propuesta de valor al empleado en el primer territorio.

Al identificar patrones por área se identifica que el área de retail tiene calificaciones cuantitativas menos favorables que las de manufactura. Y aunque la compensación es la variable peor calificada en ambas áreas, el resultado es menor para las áreas de retail. Por lo tanto, el foco para mejorar la posible retención de talento de la muestra debería enfocarse en revisar la estrategia de compensación en las áreas de retail, esto se complementa con los hallazgos cualitativos en donde se identifica que existe una falta de claridad sobre el proceso de asignación de salarios en dicha área.

Al contrastar los hallazgos generales de los principales motivos de retiro y los presentados por el informe en Colombia de PageGroup en 2023 se encuentra que los tres motivos principales por los cuales los colaboradores abandonan las organizaciones son: 76 % por salarios más competitivos, seguido de 37 % por desarrollo de carrera y 38 % por proyectos personales. Estos resultados son consistentes con los hallazgos de la muestra analizada.
Al comparar la información obtenida tanto cualitativa como cuantitativamente, se observa que, a pesar de las calificaciones positivas en las encuestas Likert, hay un nivel de información que podría no estar completamente capturado con los resultados cuantitativos. En particular, el análisis cualitativo revela que la variable "agilidad" es frecuentemente mencionada en los comentarios de los empleados sobre la “ampliación”, a pesar de no ser la que obtiene las calificaciones más bajas. Esto sugiere que el análisis cualitativo aporta un valor agregado al proporcionar una comprensión más profunda de las percepciones y preocupaciones de los empleados, que no siempre son evidentes en los datos cuantitativos. En la misma vía, este análisis permite identificar los elementos asociados a Agilidad y simplicidad que deben mejorarse lo cual hubiera sido imposible de determinar basándose únicamente en las calificaciones cuantitativas.

Al comparar ambas preguntas cualitativas se encuentra que la pregunta “Amplicación” es mucho más susceptible de variedad de análisis en comparación a “Factor_Quedarse” y que por consiguiente la primera fue más enriquecedora para la identificación de aspectos de mejora. Lo que sugiere que dejar una pregunta abierta para las entrevistas de retiro puede ser más valioso que preguntar por qué se quisieran quedar las personas.
Para terminar, este trabajo muestra que la incorporación de técnicas basadas en inteligencia artificial es viable y agrega valor a la gestión en recursos humanos, permitiendo no solo un mejor diagnóstico sino también permite otorgar profundidad sobre el diseño de planes de acción. A través del análisis combinado de información cuantitativa y cualitativa, se ha podido no solo diagnosticar mejor las causas del retiro de los empleados, sino también obtener una comprensión más profunda de sus percepciones. Esto ofrece una visión más completa que puede guiar la toma de decisiones estratégicas lo que, a su vez, puede contribuir significativamente a mejorar la retención de los empleados y gestión de marca empleadora.

© ADIC-IIC

ISSN: 2792-3770

6. Conclusiones

Este trabajo se centró en el análisis de patrones y tendencias a partir de las entrevistas de salida realizadas a 400 colaboradores de una empresa del sector industrial que opera en varios sectores principalmente de manufactura y retail en Colombia y México. La investigación combinó metodologías cuantitativas y cualitativas, integrando herramientas de inteligencia artificial, particularmente el PLN, para abordar tanto la complejidad como el volumen de los datos recopilados. Estas entrevistas, diseñadas para capturar las razones y percepciones de los empleados al dejar la organización, representaron una fuente clave para entender las dinámicas de rotación y de esta manera ayudar a la toma de decisiones más estratégicas en recursos humanos.

A través de este enfoque, se analizaron factores fundamentales detrás del abandono laboral, incluyendo los principales motivos de retiro, las percepciones sobre el liderazgo y la valoración de diversas dimensiones organizacionales como compensación, desarrollo, cultura, clima, ENPS y agilidad. Los resultados proporcionaron una mejor comprensión de los elementos que influyen en la decisión de los empleados de abandonar o permanecer en la organización. Este enfoque permitió identificar áreas de mejora y formular hallazgos accionables para optimizar las estrategias de retención de talento, adaptándose a las necesidades y expectativas particulares de los colaboradores según su área, país y contexto.

Como elementos destacados dentro de los hallazgos, se identificaron diferencias en los motivos de retiro por país. El salario se presenta como el principal motivo en ambas regiones; sin embargo, en Colombia predominan factores relacionados con la jubilación/pensión, mientras que en México destacan temas familiares y de salud. Además, se observó que la población mexicana tiende a ser menos directa sobre sus motivos reales al momento del retiro, requiriendo de mayor persuasión en las entrevistas para profundizar en las razones subyacentes. Esto podría afectar significativamente la interpretación de los resultados en esta sección.

Como segundo elemento, se identificaron diferencias entre las áreas, destacando que el área de retail presentó calificaciones más bajas en términos de compensación y liderazgo en comparación con manufactura. Esto es consistente con otras evaluaciones realizadas en la empresa, como las relacionadas con el clima organizacional. Finalmente, el análisis cuantitativo de las dimensiones organizacionales revela que compensación, desarrollo, y reconocimiento fueron las menos valoradas.
En el análisis cualitativo de los comentarios, emergió "agilidad y simplicidad" como un tema recurrente. Aunque no recibió bajas puntuaciones en los análisis cuantitativos, fue señalado como un área de mejora clave.
Este trabajo confirma la importancia de integrar análisis cuantitativos y cualitativos para comprender de manera holística la rotación de empleados. Asimismo, el uso de técnicas de PLN y análisis de sentimientos en recursos humanos aporta un enfoque innovador y eficaz para identificar patrones y percepciones que los métodos tradicionales podrían no captar. Esto se alinea con la literatura previa, que resalta el papel de la inteligencia artificial en la toma de decisiones estratégicas de talento.
En cuanto a las implicaciones prácticas, los resultados ofrecen insumos accionables para mejorar las estrategias de retención, como ajustar políticas salariales y simplificar procesos en las áreas operativas. También destacan la relevancia de fomentar una comunicación más clara y un liderazgo más sólido, especialmente en el sector retail. A nivel teórico, este estudio demuestra la viabilidad de utilizar PLN para abordar desafíos organizacionales y sugiere que los análisis combinados (cuantitativos y cualitativos) enriquecen significativamente la interpretación de datos organizacionales.

A partir de los hallazgos, se sugiere que futuras investigaciones amplíen e integren otras fuentes de información interna de la organización, tales como evaluaciones de desempeño o cumplimiento de objetivos, para asociar cómo los análisis de entrevistas de salida influyen en los resultados del negocio, permitiendo incluso cuantificarlos. También se propone explorar otras técnicas más avanzadas de PLN, como Deep Learning, que podrían permitir un análisis más profundo y matizado de los resultados, e incluso identificar relaciones más complejas entre las palabras, no solo su cuantificación.

Adicionalmente, se recomienda realizar estudios longitudinales o multilingües para observar cómo evolucionan los motivos de salida, las percepciones organizacionales y los sentimientos a lo largo del tiempo. Esto resulta particularmente útil en empresas con operaciones en múltiples regiones o sectores. Los estudios multilingües podrían identificar diferencias en los resultados en función de los idiomas hablados, lo cual es especialmente relevante para organizaciones globales.

© ADIC-IIC

ISSN: 2792-3770

Automatizar este tipo de análisis, involucrando otras áreas internas como la ciencia de datos, podría potenciar los resultados. Como cierre, este trabajo destaca la importancia de incorporar técnicas de inteligencia artificial, como el Procesamiento de Lenguaje Natural, en la gestión de recursos humanos para abordar desafíos complejos como la rotación de personal. Al combinar análisis cualitativos y cuantitativos, se logra una comprensión más profunda de las percepciones de los empleados, proporcionando un marco valioso para el diseño de estrategias efectivas de retención y marca empleadora. Estos hallazgos no solo contribuyen a la empresa estudiada, sino que también sientan las bases para futuras investigaciones y aplicaciones en otros contextos organizacionales, ya que estas metodologías pueden adaptarse a cualquier organización que recolecte entrevistas de retiro.

© ADIC-IIC

ISSN: 2792-3770

7. Referencias bibliográficas

- AIHR. (2022, March 4). How natural language processing can revolutionize human resources. AIHR. https://www.aihr.com/blog/natural-language-processing-revolutionize-human-resources/
- Spain, E., & Groysberg, B. (2016). Making exit interviews count. Harvard Business Review. Recuperado de https://hbr.org/2016/04/making-exit-interviews-count
- Great Place To Work. (2024). Research: 3 employee experiences most likely to drive retention [Comunicado de prensa]. Recuperado de https://www.greatplacetowork.com/press-releases/employee-experiences-drive-retention
- Cofino, C. L., Escorial, R. B., & Enquilino, D. L. B. (2024). A literature review on natural language processing (NLP) in aiding industry to progress. International Journal of Engineering Trends and Technology, 72(2), 41-46. https://doi.org/10.14445/22315381/IJETT-V72I2P105
- PageGroup. (2023). Estudio de Remuneración PageGroup Colombia 2023. Michael Page.
- Peoplelytics. (s. f.). ¿Qué es una buena puntuación de eNPS? Peoplelytics. Recuperado el 8 de diciembre de 2024, de https://www.peoplelytics.co/blog/what-is-good-enps-score/
- Foley, K. (2024, 18 de junio). Employee Net Promoter Score (eNPS): What You Need to Know. Perceptyx. Recuperado de https://blog.perceptyx.com/employee-net-promoter-score
- Factorial. (2024). Tasa de rotación de personal en México: Cálculo, estadísticas y causas. Factorial. Recuperado el 26 de mayo de 2024, de https://factorial.mx/blog/tasa-rotacion-personal-mexico/
- Lakhchini, W., & Aknin, A. (2023). Sentiment analysis to support business decision-making: A bibliometric study. ResearchGate.
- Grensing-Pophal, L. (2024, April 8). Using Natural Language Processing for Sentiment Analysis. SHRM.

© ADIC-IIC

ISSN: 2792-3770

ARTÍCULO 07

© ADIC-IIC

ISSN: 2792-3770



.07

Una Guía Sencilla para Analizar Automáticamente la Expresividad Facial en AVIs

A Simple Guide for the Automatic Analysis of Facial Expressivity in AVIs

Rubén Moreno Cifuentes
Científico de datos

Correo electrónico:
rubenmorenocifuentes@gmail.com

Linkedin:
www.linkedin.com/in/rubén-moreno-cifuentes-054b102b1

Received: 28/02/2025
Received in revised form: 8/07/2025
Accepted: 17/07/2025
Available on-line: 15/10/2025

© ADIC-IIC

ISSN: 2792-3770



Resumen

La creciente competencia entre empresas para optimizar los procesos de selección de personal y contratar a los mejores candidatos ha impulsado el desarrollo de técnicas que integran el uso de nuevas tecnologías. En este contexto, las Entrevistas en Video Asíncronas (AVIs) han ganado popularidad, ya que permiten prescindir de la simultaneidad entre entrevistado y entrevistador además de posibilitar la automatización de su análisis. Este artículo presenta una sencilla guía para el análisis automático de la expresividad facial en AVIs, utilizando el programa Py-Feat, una herramienta que analiza el rostro y devuelve valores relacionados con movimientos musculares simples a lo largo del vídeo. El objetivo de la guía es facilitar la implementación de técnicas automáticas como el análisis de la expresividad en los procesos de selección, incluso por parte de profesionales sin formación técnica especializada.

Palabras clave

AVIs, Expresividad facial, análisis automático, procesos de selección.

Abstract

The increasing competition among companies to optimize recruitment processes and attract the best candidates has driven the development of techniques that incorporate new technologies. In this context, Asynchronous Video Interviews (AVIs) have gained popularity, as they eliminate the need for interviewer-interviewee simultaneity and allow for automated analysis. This article presents a simple guide for the automatic analysis of facial expressivity in AVIs, using Py-Feat, a tool that analyzes faces and returns values related to simple muscle movements throughout the video. The aim of the guide is to facilitate the implementation of automatic techniques such as facial expressivity analysis within recruitment processes, even by professionals without technical expertise.

Keywords

AVIs, Facial Expressivity, automatic analysis, recruitment processes.

© ADIC-IIC

ISSN: 2792-3770

1. Introducción

El desarrollo de las nuevas tecnologías ha promovido el aumento en el uso de una novedosa modalidad de entrevistas entre los profesionales de los recursos humanos, las entrevistas en vídeo asíncronas o AVIs por sus siglas en inglés (Asynchronous video interviews).

Esta modalidad elimina la necesidad de simultaneidad entre entrevistado y entrevistador, lo que las convierte en una alternativa más económica y rápida que las entrevistas tradicionales presenciales o que las vídeo entrevistas síncronas, permitiendo entrevistar a un mayor número de candidatos en menor tiempo. El diseño y detalles de las AVIs son diferentes en función de cada proceso de selección, aunque todas siguen el mismo patrón: para llevarlas a cabo, el entrevistado debe conectarse a una plataforma online, donde se le presentan una serie de preguntas de entrevista, que deberá grabar respondiendo (Lukacik et al., 2022).

Estos vídeos son analizados posteriormente por entrevistadores experimentados, que deciden si el candidato avanzará a las siguientes fases del proceso de selección. Sin embargo, cada vez es más común el uso de inteligencia artificial para realizar el análisis de las AVIs de manera automática. Esto reduce el coste y el tiempo, a la vez que la necesidad de personal para analizar los vídeos. Estos programas observan el comportamiento de los candidatos y predicen sus niveles en diferentes habilidades cognitivas como la inteligencia (Hickman, Tay et al., 2024), las habilidades de comunicación (Rasipuram & Jayagopi, 2016; Suen, Hung et al., 2020) o el rendimiento en entrevistas y la contratabilidad (Koutsoumpis, Ghassemi et al., 2024).

La investigación en la puntuación automatizada de las AVIs se ha centrado especialmente en la medición de personalidad (Hickman, Bosch et al., 2022; Koutsoumpis, Ghassemi et al., 2024; Suen, Hung et al., 2019). La personalidad es uno de los indicadores más útiles a la hora de predecir el comportamiento en el trabajo y como se desenvolverá el futuro trabajador con sus tareas (Martínez, Lado et al., 2025; Tett, Jackson et al., 1991; Sackett, Zhang et al., 2022), por lo que hallar modos de optimizar la medición de la personalidad en las entrevistas es vital para mejorar el proceso de selección.

Estas técnicas se basan en la extracción automática de las señales conductuales (verbales, paraverbales y/o no verbales) mediante programas, para estudiar los rasgos de personalidad (Mehta, Majumder et al., 2020). Las señales verbales hacen referencia a aquello que las personas dicen, su discurso, mientras que las paraverbales consisten en la expresión al hablar, como el tono o la velocidad. Las señales no verbales por su parte, en las que se centra la presente guía, aluden a gestos y expresiones del entrevistado.

Ahora bien, ¿hasta qué punto se puede juzgar la personalidad de las personas a través de su conducta observable? El modelo de lente desarrollado por Brunswik en 1955 plantea como las personas utilizan las señales observables que reciben de los demás que creen que son relevantes, como sus expresiones o su forma de hablar, a la hora de hacer inferencias sobre su personalidad o habilidades. Por ende, las personas exteriorizan la personalidad a través de su conducta, que es captada por los demás para llevar a cabo juicios sobre el carácter. De igual manera, esto puede ser detectado por algoritmos, los cuales podrán llevar a cabo un análisis automático para predecir la personalidad basándose en las señales conductuales de los entrevistados durante los vídeos.

Entre las posibles señales captadas por estos algoritmos, las investigaciones sugieren que las señales no verbales podrían consistir en buenos indicadores de personalidad, ya que, a diferencia de las señales verbales, comprenden conductas automáticas que no conllevan un procesamiento cognitivo, por lo que estarían más relacionadas con los estados internos de la persona (DeGroot & Gooty, 2009).

Numerosos estudios se han centrado en investigar la relación entre la conducta y los rasgos de personalidad y como las personas usan las señales no verbales para juzgar el carácter de los demás (Breil, Osterholz, et al., 2021; Zebrowitz & Montepare, 2008).

Ishii et al. (2020) encontraron relación entre diferentes conductas observables y los factores del Big Five. Descubrieron que las personas con altos niveles de apertura miraban más a la cabeza del interlocutor y que las personas con alta responsabilidad asentían con la cabeza más a menudo. Además, encontraron que existía relación entre apertura, amabilidad y responsabilidad y los movimientos de las manos; y entre apertura, amabilidad y neuroticismo y la inclinación del cuerpo al hablar. Asimismo, Grünberg et al. (2018) desarrollaron el “Münster Behavior Coding-System" (M-BeCoSy), un sistema que categoriza 284 conductas observables en relación con 7 rasgos de personalidad: expresividad,

© ADIC-IIC

ISSN: 2792-3770

dominancia, arrogancia, amabilidad, agresividad y comportamientos relacionados con emociones negativas o competencias intelectuales.

El estudio de las señales no verbales en AVIs, se centra principalmente en los movimientos de la cabeza, la mirada y las expresiones faciales. Para su análisis, se extrae información sobre determinados puntos de referencia en el rostro que, de manera combinada constituyen lo que denominamos Unidades de Acción o AUs.

Las AUs consisten en los movimientos individuales de músculos que forman las expresiones faciales. Están recogidas en el 'Facial Action Coding System' (FACS) desarrollado por Ekman y Wallace en 1978 (posteriormente revisado en 2002), el cual descompone los movimientos faciales en la musculatura que las provocan. Este sistema de codificación facial recoge 46 movimientos (AUs) entre los que incluye movimientos de cabeza y ojos, y movimientos de los músculos faciales.

Las AUs pueden presentarse de forma individual o de manera combinada, formando expresiones faciales complejas. Estas combinaciones pueden tener un valor aditivo, cuando solo potencia la expresión al añadir un nuevo movimiento, o no aditivo, cuando cambia la expresión al darse juntos los AUs (Tian, Kanade, et al., 2001). Aunque el número de AUs es limitado, se han encontrado hasta 7000 posibles combinaciones (Ekman, 1982). AU06, que describe la elevación de las mejillas, AU12, que se activa cuando ascienden las comisuras de los labios, y AU25, que informa de la apertura de los labios, es un ejemplo de combinación de AUs que se suelen activar juntos para formar la sonrisa.

Para obtener las AUs, programas como OpenFace (Baltrušaitis, Mahmoud et al. 2015; Baltrušaitis, Robinson et al. 2016) o Py-Feat (Cheong, Jolly et al. 2023), utilizan Histogramas de Gradientes Orientados (HOG) para la extracción de características a partir de las coordenadas de los puntos de referencia faciales. Después, utilizan Maquinas de Vector Soporte (SVM) para la detección de la aparición de las AUs y Regresión de Vector Soporte (SVR) para calcular la intensidad de estas. Ambos procesos se llevan a cabo utilizando kernels lineales. Esta información se utiliza para entrenar modelos de redes neuronales que llevarán a cabo una predicción de la personalidad de los entrevistados. En la validación de estos modelos se utilizan como criterio "ground truth" cuestionarios auto-informados u observadores expertos. Habitualmente se calcula la precisión con la que el programa es capaz de predecir la personalidad de los entrevistados, junto con indicadores de fiabilidad y validez del proceso.

El análisis automático en AVIs, es un tema novedoso y, hasta ahora, poco estudiado, por lo que es vital obtener más evidencia sobre el alcance de estos programas a la hora de predecir la personalidad o habilidades en las entrevistas. Es necesario un seguimiento de dichos estudios, donde se lleve a cabo un proceso exhaustivo de replicación que valide los resultados obtenidos y asegure el correcto uso de esta metodología.

Aunque la literatura se ha focalizado en la predicción de la personalidad en AVIs, esta suele estar acompañada de otras habilidades cognitivas a predecir como la inteligencia o las habilidades de comunicación. Asimismo, frecuentemente no se selecciona un amplio espectro de factores de personalidad, en cambio se opta por aquellos considerados mejores predictores de la conducta laboral, como la Responsabilidad o la Extroversión. Sin embargo, esto puede no ser cierto para todos los empleos, lo que lleva a una visión reduccionista del proceso de selección. Por ende, es necesario más estudios que profundicen y se centren en la obtención de la personalidad de manera automática en AVIs, contando con un mayor abanico de factores que podrían ser útiles de implementar en el proceso de selección de diferentes trabajos.

En la misma línea, comúnmente la literatura se ha centrado en la detección de las emociones para predecir la personalidad y no tanto en los movimientos individuales de músculos faciales. Sin embargo, la detección automática de emociones es un tema que plantea numerosas cuestiones éticas y legales a tener en cuenta recientemente explicitadas en el reglamento de Inteligencia Artificial de la UE. Mientras que las emociones pueden variar en su expresión en diferentes culturas, los movimientos faciales no profundizan en un significado social, lo que nos ayudaría a eliminar este posible sesgo. Además, es conveniente llevar a cabo estudios sobre la automatización de las AVIs en diferentes culturas y contextos para obtener una visión más global del alcance de esta metodología y solucionar los posibles sesgos que pudieran tener los modelos.

En la literatura centrada en la automatización de las AVIs es frecuente encontrar que los investigadores usan programas como OpenFace o Emotient, los cuales son menos accesibles para investigadores independientes o usuarios poco experimentados en la programación. PyFeat supone una alternativa sencilla de usar y gratuita, que proporciona todas las herramientas necesarias para un análisis facial completo. No obstante, al ser una solución novedosa es necesario realizar estudios para conocer su funcionalidad.

© ADIC-IIC

ISSN: 2792-3770

2. Objetivos

En línea con lo anterior, el presente trabajo tiene como objetivo familiarizar al profesional de recursos humanos con el uso de estas metodologías automáticas, y proporcionar una herramienta que contribuya a optimizar los procesos de selección.

Estas herramientas demandan cierto nivel de habilidad técnica para su adecuada ejecución, un perfil que a menudo no se encuentra en estos departamentos. Esto conlleva la necesidad de dar visibilidad a alternativas accesibles que puedan ser empleadas sin requerir un nivel avanzado de competencias técnicas. Por este motivo, Py-Feat representa una herramienta de gran utilidad. Al estar desarrollado en Python, uno de los lenguajes más comunes y fáciles de manejar, convierten Py-Feat en una versión accesible para todos los públicos. Además, se trata de una solución basada en software de código abierto, por lo que puede ser implementado por empresas pequeñas o con pocos recursos de manera gratuita.

A pesar de la accesibilidad inherente del programa, es esencial la disponibilidad de una guía estructurada en español que proporcione los recursos necesarios para implementarlos de forma fácil y práctica a tareas reales del ámbito de la selección.

3. Utilizando Py Feat para analizar las AVIs

Py Feat

Para la extracción de señales no verbales de las AVIs vamos a utilizar el programa Py-Feat ("Python Facial Expression Analysis Toolbox"). Dicho programa aporta una serie de herramientas y modelos para llevar a cabo un análisis total de la información facial. Con él se pueden analizar imágenes y vídeos para obtener datos sobre detección de caras, puntos de expresividad, posición de la cabeza, AUs, y emociones.

Py-Feat devuelve el análisis en 20 de las 46 AUs recogidas en el FACS de Ekman (para una descripción más detallada de las 20 AUs analizadas ver Anexo 1). El programa es capaz de extraer diversos datos faciales, sin embargo, no se tendrán en cuenta todos debido a que algunos de ellos constituyen un paso intermedio para obtener los valores de las AUs (como las coordenadas, el ancho y largo del rectángulo que envuelve a la cara en el vídeo, indicando su posición y tamaño durante este o las coordenadas en "X" e "Y" de 68 puntos faciales). Tampoco se tendrán en cuenta los datos de estimación de las emociones por las razones planteadas anteriormente.

El sistema de detección está basado en un conjunto de árboles de decisión que estiman la probabilidad de activación de cada AU, expresada en una escala de 0 a 1. No obstante, algunas AUs especificas (7, 11 y 20) solo proporcionan datos binarios, indicando únicamente la presencia o ausencia de la expresión. Aunque el programa aporta valores de probabilidad y no directamente de intensidad de los movimientos musculares, esta puede interpretarse como un grado estimado de evidencia de activación de una AU. En la práctica, valores más altos pueden asociarse con expresiones más claras y amplias y por consiguiente más intensas. Además, el programa proporciona un valor que indica la precisión con la que se ha reconocido una cara en el frame analizado.

El código abierto de Py-Feat puede encontrase en la página web oficial (Py-Feat, 2024). No obstante, se presenta a continuación una guía paso a paso de cómo entender y adecuar el código en función de la tarea de una manera más accesible.



© ADIC-IIC

ISSN: 2792-3770

El Código para Extraer la Información y prepararla para el análisis

Antes de comenzar a trabajar con el código, se debe importar las librerías necesarias para que funcionen todos los comandos. La librería feat es fundamental, pues contiene el programa de detección de caras. Especificamos la importación de la función detector, pues constituye el comando principal para crear el detector. Os nos permite interactuar con el sistema operativo, crear carpetas o navegar por directorios. Pandas es la librería de referencia para tratar con tablas de datos (dataframes) y archivos como Excel. Seaborn y matplotlib.pyplot nos permite trabajar con gráficas y visualización estadística.

```
from feat import detector
import os
import pandas as pd
import seaborn as sns
import matplotlib.pyplot as plt
```

Una vez importadas las librerías necesarias, se puede comenzar a desarrollar el código de nuestro detector.

El primer paso consiste en crear el detector. Es necesario especificar al comando el clasificador que se debe emplear de modo que el detector pueda centrarse en la información facial relevante. El programa lleva integrado diversos clasificadores preentrenados, cada uno basados en distintos conjuntos de datos y modelos de aprendizaje.

Para la detección de caras y postura de la cabeza:

```
detector_img2pose = detector(face_model='img2pose')
```

Para la detección de landmarks:

```
detector_mfn = detector(landmark_model='mobilefacenet')
detector_mobilenet = detector(landmark_model='mobilenet')
detector_pfld = detector(landmark_model='pfld')
```

Para la detección de emociones:

```
detector_resmasknet = detector(emotion_model='resmasknet')
detector_svm_emotion = detector(emotion_model='svm')
```

Para la detección de identidad:

```
detector_facenet = detector(identity_model='facenet')
```

Para la detección de AUs, en las cuales se va a centrar el desarrollo del código, se puede optar por dos clasificadores. No obstante vamos a continuar empleando XGBoost ('xgb'):

```
detector_xgb = detector(au_model='xgb')
detector_svm_au = detector(au_model='svm')
```

El código se ha optimizado para que sea capaz de analizar un conjunto de vídeos secuencialmente, otorgándole únicamente la ruta al directorio que los contenga. Sin embargo, para facilitar la comprensión se va a desarrollar el código para el análisis de un único vídeo. Para ello, empezamos indicando la ruta al vídeo que queramos analizar y lo guardamos en un objeto que podamos utilizar más adelante.

```
video = "/path al video"
```

El código proporciona datos en varias etapas, por lo que se crea una carpeta específica del vídeo para poder guardar todos los resultados y que sean accesibles. Le indicamos el directorio donde queremos que se cree la carpeta. Se le asigna el mismo nombre que el vídeo para facilitar su reconocimiento.

```
directorio = "/path al directorio"
carpeta = os.path.join(directorio, video.replace('.mp4', ''))
os.makedirs(carpeta, exist_ok=True)
```

Una vez completado esto, se puede ejecutar el análisis con el detector. Este analiza las AUs en fotogramas específicos del vídeo, por ello, es necesario especificar el número de fotogramas que se deben omitir entre cada análisis mediante el comando skip_frames. 25 fotogramas es una medida muy común de fotogramas por segundo, con lo que conseguiríamos obtener información facial del vídeo en cada segundo. Además, se añade el umbral de confianza de 0.95 con el parámetro fase_detection_threshold. Este valor representa la probabilidad mínima requerida para que una detección facial se considere válida.

```
prediccion = detector_xgb.detect_video(
    video_path, data_type="video", skip_frames=25, face_detection_threshold=0.95
)
```

Esto devuelve una tabla de datos con tantas filas como momentos haya analizado y 687 columnas. Como se ha comentado previamente, el detector aporta información innecesaria que únicamente ensucia los resultados finales y no aportan valor. Así pues es necesario eliminarla, para obtener unos resultados relevantes y manejables. Mantenemos únicamente los valores de las AUs, los movimientos de cabeza (Pitch, Roll y Yaw) y el índice de precisión de detección de la cara (FaceScore).

```
prediccion=prediccion.loc[:, ['frame','approx_time','FaceScore','Pitch','Roll','Yaw',
                              'AU01','AU02','AU04','AU05','AU06','AU07','AU09','AU10',
                              'AU11','AU12','AU14','AU15','AU17','AU20','AU23','AU24',
                              'AU25','AU26','AU28','AU43']]
```

© ADIC-IIC

ISSN: 2792-3770

De esta manera obtenemos una tabla mucho más limpia y únicamente con la información sobre las AUs y los movimientos de cabeza.

frame	frame	approx_time	FaceScore	Pitch	Roll	Yaw	AU01	\
0	0	00:00	0.999476	4.592134	-4.579653	5.047100	0.484288	
50	50	00:02	0.998372	-22.693747	-6.381645	3.176411	0.297578	
100	100	00:04	0.997500	-39.725880	-5.557603	0.561935	0.319564	
150	150	00:06	0.998746	-34.834575	-6.449733	1.596458	0.290974	
200	200	00:08	0.998081	-54.838343	-6.030469	-0.407811	0.374275	
250	250	00:10	0.996481	-60.440392	-6.827624	0.150614	0.425677	
300	300	00:12	0.998316	-34.556506	-5.965477	-0.769800	0.308966	
350	350	00:14	0.997001	-45.085884	-6.078697	3.897102	0.279891	
400	400	00:16	0.998330	-37.150925	-4.809018	-0.888964	0.400314	
450	450	00:18	0.997168	-42.250013	-5.725909	-2.119978	0.246572	
500	500	00:20	0.999723	-10.344955	-9.054590	2.568155	0.180290	

frame	AU02	AU04	AU05	...	AU14	AU15	AU17	AU20	\
				...					
0	0.461819	0.102779	0.383849	...	0.131895	0.090627	0.357878	0.0	
50	0.099975	0.925645	0.266178	...	0.700364	0.323078	0.135155	1.0	
100	0.190687	0.836512	0.270448	...	0.853305	0.183536	0.193792	1.0	
150	0.068373	0.881136	0.255071	...	0.753640	0.240845	0.151348	1.0	
200	0.608592	0.613731	0.245633	...	0.705286	0.334161	0.230719	1.0	
250	0.624286	0.711573	0.265426	...	0.733984	0.470170	0.232188	1.0	
300	0.153007	0.935485	0.259395	...	0.776926	0.205322	0.158784	1.0	
350	0.194211	0.916907	0.270058	...	0.748131	0.134369	0.155107	1.0	
400	0.114695	0.896338	0.244216	...	0.752051	0.298672	0.152166	1.0	

Una vez obtenidos estos datos los guardamos en un archivo Excel en la carpeta creada para el vídeo.

```
prediccion_path = os.path.join(carpeta, f'prediccion_{video.replace(".mp4", ".csv")}')
prediccion.to_csv(prediccion_path, index=False)
```

No obstante, el objetivo es emplear los datos de la expresión facial como predictores. Por esta razón, es necesario una manera de unificar los datos de varios vídeos en un mismo archivo y que por tanto, cada vídeo ocupe una única fila. En este punto del código, cada vídeo ocupa tantas filas como momentos del vídeo han sido analizados, así que es vital resumir estos datos. Para ello, se obtienen estadísticos de cada variable analizada. Concretamente se calcula la media, la desviación típica y los cuartiles. Se añade a esta tabla de datos una columna con los nombres de cada estadístico y otra con el identificador del vídeo.

```
resumen = prediccion.describe()

resumen.insert(0, 'Var', ['N', 'Media', 'Sd', 'Min', '25%', 'Mediana', '75%', 'Max'])
resumen.insert(0, 'ID', [{video.rsplit('.', 1)[0]}]*8)
```

Esto se lleva a cabo, ya que como vemos, el programa va a mostrar los estadísticos en diferentes filas, y para convertirlo en una única fila, es necesario trasformar la tabla de formato largo a ancho y necesita estos datos para hacer el pivotado como veremos más adelante.

	ID	Var	frame	FaceScore	Pitch
{Video prueba 3}		N	4.000000	4.000000	4.000000
{Video prueba 3}		Media	150.000000	0.998794	0.144412
{Video prueba 3}		Sd	129.099445	0.001124	6.507795
{Video prueba 3}		Min	0.000000	0.997164	-4.901992
{Video prueba 3}		25%	75.000000	0.998516	-4.671661
{Video prueba 3}		Mediana	150.000000	0.999172	-1.755142
{Video prueba 3}		75%	225.000000	0.999450	3.060931
{Video prueba 3}		Max	300.000000	0.999667	8.989925

© ADIC-IIC

ISSN: 2792-3770

De nuevo, se guardan estos datos en la carpeta del vídeo, para llevar un registro.

```
resumen_path = os.path.join(carpeta, f'resumen_{video.replace(".mp4", ".csv")}')
resumen.to_csv(resumen_path, index=False)
```

Al pivotar la tabla, todas las variables van a contar con un recuento de observaciones (N), el cual es el mismo para todas. Así pues, guardamos ese valor y eliminamos la fila de la tabla.

```
frame_count = resumen.loc['count', 'frame']
resumen = resumen.drop('count', axis=0)
```

Por otro lado, la variable frame, está calculada de los fotogramas en el momento del análisis y sus estadísticos no aportan ninguna información por lo que los eliminamos también.

```
resumen = resumen.drop('frame', axis=1)
```

Una vez que solamente se mantienen las variables relevantes, se realiza el pivotado de la tabla de formato largo a ancho, para resumir el vídeo en una única fila. Cada variable nueva se nombra combinando el nombre de la variable original con el estadístico correspondiente. Se añade al terminar el número de observaciones del vídeo, para llevar constancia de la longitud del vídeo.

```
trasposicion = {'ID': resumen['ID'].iloc[0]}

for col in resumen.columns[2:]:
    for var in resumen['Var']:
        nueva_columna = f"{col}_{var}"
        trasposicion[nueva_columna] = resumen.loc[resumen['Var'] == var, col].values[0]

fila = pd.DataFrame([trasposicion])

fila.insert(1, 'N', frame_count)
```

Obtenemos ahora una tabla con una única fila y 170 columnas. Este formato ya nos permite agruparlo a los resultados de otros vídeos y emplearlos como predictores.

```
              ID    N  FaceScore_Media  FaceScore_Sd  FaceScore_Min  \
{Video prueba 3}  4.0         0.998794      0.001124       0.997164

FaceScore_25%  FaceScore_Mediana  FaceScore_75%  FaceScore_Max  \
     0.998516           0.999172        0.99945       0.999667

Pitch_Media  ...  AU28_Mediana  AU28_75%  AU28_Max  AU43_Media   AU43_Sd  \
   0.144412  ...      0.189101  0.410544  0.979337     0.05169  0.017614

AU43_Min  AU43_25%  AU43_Mediana  AU43_75%  AU43_Max
0.038484   0.04065      0.045582  0.056622  0.077112
```

Por último, para facilitar la visualización de la distribución de los resultados de las AUs, se obtienen dos gráficos de barras resumen donde se muestran las medias y medianas de cada AU. Para ello, primero se ha de crear la figura donde plasmaremos los dos gráficos, indicándole el tamaño (figsize) y el título (suptitle) deseado.

```
plt.figure(figsize=(12, 6))
plt.suptitle(f'Análisis de AUs: {video}', fontsize=16)
```

© ADIC-IIC

ISSN: 2792-3770

En ambos se establece un umbral de 0.5 para colorear las distintas AUs diferente en función de si superan o no este valor, para facilitar la visualización y el reconocimiento de las AUs prevalentes en el vídeo. Creamos ahora el gráfico de la distribución de medias.

```
plt.subplot(1, 2, 1)
medias = resumen.iloc[[0], 6:26].values.flatten()
colores_mean = ['mediumseagreen' if value > 0.5 else 'coral' for value in medias]

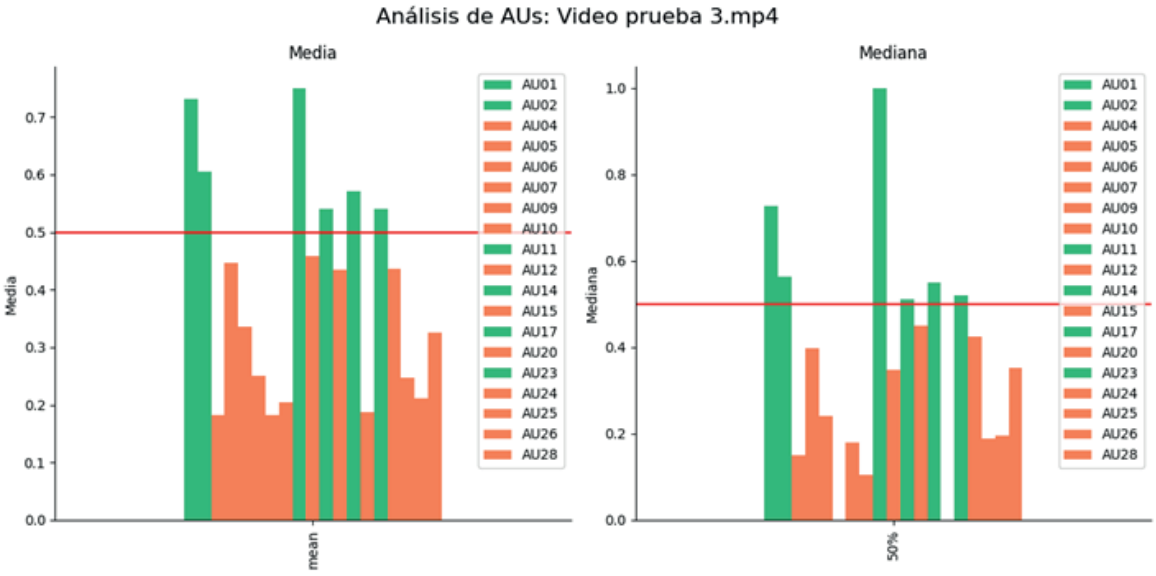
ax1 = resumen.iloc[[0], 6:26].plot(kind='bar', title='Media', ax=plt.gca(), color=colores_mean)
ax1.set_ylabel('Media')
plt.axhline(y=umbral, color='red')
sns.despine()
```

De la misma manera creamos la gráfica de la distribución de las medianas.

```
plt.subplot(1, 2, 2)
medianas = resumen.iloc[[4], 6:26].values.flatten()
colores_medi = ['mediumseagreen' if value > 0.5 else 'coral' for value in medianas]

ax2 = resumen.iloc[[4], 6:26].plot(kind='bar', title='Mediana', ax=plt.gca(), color=colores_medi)
ax2.set_ylabel('Mediana')
plt.axhline(y=umbral, color='red')
sns.despine()
```

Estos gráficos se pueden obtener para cualquiera de los estadísticos de resumen, cambiando la línea: resumen.iloc[[0], 6:26]. El cero indica la primera fila de la tabla, que corresponde a las medias, y se puede sustituir por la fila deseada, mientras que el 6:26 indica al programa que solo plasme la información de las AUs y descarte el índice de precisión y los movimientos de cabeza. A continuación, se muestran los gráficos resultantes.



Guardamos los gráficos en la carpeta del vídeo para poder visualizarlos en cualquier momento.

```
grafico_path = os.path.join(carpeta, f'grafico_{video.replace(".mp4", ".png")}')
plt.savefig(grafico_path)
```

© ADIC-IIC

ISSN: 2792-3770

Una vez comprendido el proceso de análisis de un único vídeo, la automatización secuencial de un conjunto es una tarea muy sencilla.

En lugar de indicar al programa la ruta al vídeo, solo es necesario la ruta al directorio donde se encuentren todos los vídeos.

```
directorio = "/path al directorio"
```

Con esta información, le pedimos al programa que cree una lista con todos los archivos dentro del directorio con una extensión concreta, en nuestro caso mp4, pero se puede sustituir o combinar con cualquier formato de vídeo.

```
videos = [f for f in os.listdir(directorio) if f.endswith('.mp4')]
```

El último paso que añadir antes de comenzar el análisis es crear un data frame vacío donde se puedan guardar conjuntamente los datos finales de cada vídeo para su posterior visionado y uso como predictores.

```
resultados = pd.DataFrame()
```

Para realizar el análisis construimos un bucle que recorra todos los vídeos que contiene la lista creada (videos), en el que introduciremos los comandos desarrollados anteriormente.

```
for video in videos: ···
```

Es necesario guardar automáticamente la ruta del vídeo al inicio del bucle para poder indicárselo al detector más adelante.

```
video_path = os.path.join(directorio, video)
```

Concatenar los datos del vídeo en su formato unificado en una fila al data frame de todos los vídeos conjuntos, tras hacer el pivotado.

```
resultados = pd.concat([resultados, fila], ignore_index=True)
```

Y para terminar, fuera del bucle, guardar los resultados conjuntos cuando ya ha terminado de analizar todos los vídeos.

```
resultados_path = os.path.join(directorio, 'resultados_conjuntos.csv')
resultados.to_csv(resultados_path, index=False)
```

El código completo de la automatización secuencial se encuentra disponible en el Anexo 2 para su consulta y utilización.



© ADIC-IIC

ISSN: 2792-3770

4. Discusión

En años recientes, la creciente concentración de las empresas en las grandes ciudades ha generado una mayor competencia entre quienes postulan a los puestos de trabajo. Esto, unido al aumento en el nivel de preparación de los candidatos dificulta la labor de los profesionales de los recursos humanos que deben realizar numerosas entrevistas para encontrar a la persona más adecuada para cada puesto de trabajo.

Esta tendencia ha desencadenado el desarrollo de técnicas que facilitan el proceso de selección, mediante fases automáticas que realicen una criba inicial y reduzcan el número de candidatos que es necesario evaluar manualmente. Es vital entonces optimizar este proceso para que evolucione paralelo a la complejidad de la tarea. Técnicas como el análisis automático de la personalidad o diversas habilidades cognitivas protagonizan este avance, pues constituyen excelentes criterios para un primera fase de selección.

Si bien estas metodologías ayudan a facilitar la tarea de selección, no pueden convertirse en un sustituto de la labor humana. La criba mediante análisis automático debe servir como apoyo a la decisión final llevada a cabo por profesionales humanos.

Estas metodologías, pese a que conllevan muchos beneficios, también han hecho visible una nueva problemática. El análisis automático constituye un tema legal y social complejo. Muchos candidatos rechazan ofertas de trabajo cuando descubren que están implicados procesos automáticos, pues tienen la creencia de que no van a recibir una evaluación igual de justa que la realizada por un humano. Esto puede provocar que profesionales totalmente capacitados para el puesto de trabajo no entren en el proceso, perdiendo las empresas grandes oportunidades.

Esta creencia puede estar provocada por la falta de conocimiento sobre estas metodologías. En este aspecto, la presente guía puede ser un acercamiento para que candidatos con dudas sobre los procesos automáticos puedan comprender como funcionan y que, de hecho, están programados para ofrecer un trato justo y objetivo.

En este sentido, se debe asegurar que estos programas son configurados de manera que no implementen ningún tipo de sesgo. Un modelo es tan eficiente como lo son los datos con los que se le ha entrenado. Muchos detractores de esta metodología opinan que no proporciona las misma oportunidades en función de la edad, etnia, género o la pertenencia a distintas culturas. Diferentes grupos pueden tener diferentes expresividades y externalizaciones de la personalidad y un modelo unitario puede no recogerlas todas. De tal manera que es necesario que sean modelados con representación suficiente de los grupos participantes.

En otro orden de cosas, es fundamental tener en consideración la información facial que se dispone a analizar. En la presente guía, se muestra como analizar las Unidades de Acción, que representan movimientos musculares simples y no acarrean ningún problema. No obstante, como se comentaba, el programa es capaz de identificar diversa información facial, como las emociones o descriptores biométricos, y estos constituyen un asunto legal complejo.

El Reglamento de Inteligencia Artificial (RIA) de la Unión Europea prohíbe el uso de tecnologías que empleen datos biométricos para el reconocimiento de emociones en el lugar de trabajo. Esta prohibición no se extiende a la detección de expresiones, gestos o movimientos que si son permitidas por la RIA (Parlamento Europeo, 2024). Sin embargo, aunque no impliquen impedimentos legales, es necesario el consentimiento explicito y claro por parte de los candidatos para su uso. Asimismo, se debe incluir una explicación sobre el propósito concreto del uso de estos datos, para que los candidatos estén debidamente informados de que técnicas se van a emplear en el proceso de selección y que tipo de información se recopilará antes de comenzar.

Esto resalta la importancia de contar con una guía como esta. Si bien existe una amplia literatura centrada en el estudio del alcance de estos métodos automáticos, para que el usuario común confíe en su uso, es fundamental acercarle el proceso, hacerlo comprensible y así reducir los prejuicios que aún persisten en torno a estas técnicas.

Lejos de ser magia, estos métodos se basan en procedimientos técnicos bien fundamentados, que se vuelven comprensibles para cualquier usuario al ser explicados de manera adecuada por una guía clara y accesible.

© ADIC-IIC

ISSN: 2792-3770

6. ANEXOS

Anexo 1. Lista de AUs analizadas.

A continuación, se presentan las 20 AUs analizadas por el programa junto con sus descripciones y los músculos que intervienen en el movimiento. Para ver la totalidad de los 100 movimientos recogidos en el 'FACS', dirigirse a la página oficial de "Py-Feat" o al manual de 'FACS' de Ekman.

AU	Descripción	Músculos
1	Elevador de la ceja interna	Frontalis (Medial)
2	Elevador de la ceja externa	Frontalis (Lateral)
4	Depresor de la ceja	Procerus, Depressor Supercilii, Corrugator Supercilii
5	Elevador del párpado superior	Levator Palpebrae Superioris, Músculo tarsal superior
6	Elevador de las mejillas	Orbicularis Oculi (orbital)
7	Tensor del parpado	Orbicularis Oculi (palpebral)
9	Arrugamiento de la nariz	Levator Labii Superioris Alaeque Nasi
10	Elevador del labio superior	Levator Labii Superioris
11	Profundizador del naso labial	Zygomaticus Minor
12	Tirador de las comisuras de los labios	Zygomaticus Major
14	Dimpler (comisuras de los labios hacia abajo)	Buccinator
15	Depresor de la comisura de los labios	Depressor Anguli Oris
17	Elevador del mentón	Mentalis
20	Estirador de labios	Risorius, Platysma
23	Tensor de labios	Orbicularis Oris
24	Presor de labios	Orbicularis Oris
25	Apertura de labios	Depressor Labii Inferioris
26	Caída de la mandíbula	Masseter, Temporalis, Medial Pterygoid
28	Succión de labios	Orbicularis Oris
43	Ojos cerrados	Levator Palebrae Superioris (relajación)

© ADIC-IIC

ISSN: 2792-3770

Anexo 2. Código completo.

```
for video in videos:
    print('Analizando video: ', video, '...', sep="") # Añadimos un mensaje informando el video que esta analizando

    # Ruta del video
    video_path = os.path.join(directorio, video)

    # Creamos la carpeta para el video
    carpeta = os.path.join(directorio, video.replace('.mp4', ''))
    os.makedirs(carpeta, exist_ok=True)

    # Ejecutamos el análisis
    prediccion = detector.detect_video(
        video_path, data_type="video", skip_frames=25, face_detection_threshold=0.95
    )

    prediccion=prediccion.loc[:, ['frame','approx_time','FaceScore','Pitch','Roll','Yaw',
                                  'AU01','AU02','AU04','AU05','AU06','AU07','AU09','AU10',
                                  'AU11','AU12','AU14','AU15','AU17','AU20','AU23','AU24',
                                  'AU25','AU26','AU28','AU43']]

    # Guardamos el analisis por fotograma
    prediccion_path = os.path.join(carpeta, f'prediccion_{video.replace(".mp4", ".csv")}')
    prediccion.to_csv(prediccion_path, index=False)

    # Sacamos el resumen
    resumen = prediccion.describe()

    # Añadimos variables de identificacion y nombres de los estadisticos
    resumen.insert(0, 'Var', ['N', 'Media', 'Sd', 'Min', '25%', 'Mediana', '75%', 'Max'])
    resumen.insert(0, 'ID', [{video.rsplit('.', 1)[0]}]*8)

    # Guardamos el resumen
    resumen_path = os.path.join(carpeta, f'resumen_{video.replace(".mp4", ".csv")}')
    resumen.to_csv(resumen_path, index=False)

    # Guardamos el número de mediciones
    frame_count = resumen.loc['count', 'frame']

    # Eliminamos la variable de frame y el recuento de mediciones de cada variable
    resumen = resumen.drop('frame', axis=1)
    resumen = resumen.drop('count' ,axis=0)

    # Creamos un diccionario para almacenar los datos
    trasposicion = {'ID': resumen['ID'].iloc[0]}

    # Bucle para combinar los nombres de las columnas en una sola línea
    for col in resumen.columns[2:]:  # Sin 'ID' y 'Var'
        for var in resumen['Var']:
            nueva_columna = f"{col}_{var}"
            trasposicion[nueva_columna] = resumen.loc[resumen['Var'] == var, col].values[0]

    # Creamos un nuevo DataFrame a partir del diccionario
    fila = pd.DataFrame([trasposicion])

    # Añadimos el número de mediciones
    fila.insert(1, 'N', frame_count)

    # Agregamos la fila a los resultados finales
    resultados = pd.concat([resultados, fila], ignore_index=True)


    # Creamos dos gráficos: de las medias y medianas de las AUs:

    # Creamos la figura
    plt.figure(figsize=(12, 6))
    plt.suptitle(f'Análisis de AUs: {video}', fontsize=16)
```

© ADIC-IIC

ISSN: 2792-3770

```
    # Gráfico Medias
    plt.subplot(1, 2, 1)
    medias = resumen.iloc[[0], 6:26].values.flatten()
    colores_mean = ['mediumseagreen' if value > 0.5 else 'coral' for value in medias]

    ax1 = resumen.iloc[[0], 6:26].plot(kind='bar', title='Media', ax=plt.gca(), color=colores_mean)
    ax1.set_ylabel('Media')
    plt.axhline(y=umbral, color='red')
    sns.despine()

    # Gráfico Medianas
    plt.subplot(1, 2, 2)
    medianas = resumen.iloc[[4], 6:26].values.flatten()
    colores_medi = ['mediumseagreen' if value > 0.5 else 'coral' for value in medianas]

    ax2 = resumen.iloc[[4], 6:26].plot(kind='bar', title='Mediana', ax=plt.gca(), color=colores_medi)
    ax2.set_ylabel('Mediana')
    plt.axhline(y=umbral, color='red')
    sns.despine()

    # Ajustamos el layout
    plt.tight_layout()

    # Guardamos el gráfico
    grafico_path = os.path.join(carpeta, f'grafico_{video.replace(".mp4", ".png")}')
    plt.savefig(grafico_path)

# Guardamos todos los resultados juntos
resultados_path = os.path.join(directorio, 'resultados_conjuntos.csv')
resultados.to_csv(resultados_path, index=False)
```

© ADIC-IIC

ISSN: 2792-3770

5. Referencias bibliográficas

- Baltrusaitis, T., Mahmoud, M., & Robinson, P. (2015). Cross-dataset learning and person-specific normalisation for automatic Action Unit detection. 2015 11th IEEE International Conference and Workshops on Automatic Face and Gesture Recognition (FG), 6, 1–6. https://doi.org/10.1109/FG.2015.7284869
- Baltrusaitis, T., Robinson, P., & Morency, L.-P. (2016). OpenFace: An open source facial behavior analysis toolkit. 2016 IEEE Winter Conference on Applications of Computer Vision (WACV), 1–10. https://doi.org/10.1109/WACV.2016.7477553
- Breil, S. M., Osterholz, S., Nestler, S., & Back, M. D. (2021). 13 contributions of nonverbal cues to the accurate judgment of personality traits. The Oxford handbook of accurate personality judgment, 195-218.
- Brunswik, E. (1955). Representative design and probabilistic theory in a functional psychology. Psychological Review, 62(3), 193–217. https://doi.org/10.1037/h0047470
- Cheong, J. H., Jolly, E., Xie, T., Byrne, S., Kenney, M., & Chang, L. J. (2023). Py-feat: Python facial expression analysis toolbox. Affective Science, 4(4), 781-796.
- DeGroot, T., & Gooty, J. (2009). Can Nonverbal Cues be Used to Make Meaningful Personality Attributions in Employment Interviews? Journal of Business and Psychology, 24(2), 179–192. https://doi.org/10.1007/s10869-009-9098-0
- Ekman, P. (1982). Methods for measuring facial action. Handbook of methods in nonverbal behavior research, 45-90.
- Ekman, P., & Friesen, W. V. (1978). Facial action coding system. Environmental Psychology & Nonverbal Behavior.
- Ekman, P., Friesen, W. V., & Hager, J. C. (2002). Facial Action Coding System. Manual and Investigator's Guide, Salt Lake City, UT: Research Nexus.
- Grünberg, M., Mattern, J., Geukes, K., Küfner, A. C., & Back, M. D. (2018). Assessing group interactions in personality psychology: The Münster behavior coding-system (M-BeCoSy). The Cambridge handbook of group interaction analysis, 1, 602-611.
- Hickman, L., Bosch, N., Ng, V., Saef, R., Tay, L., & Woo, S. E. (2022). Automated Video Interview Personality Assessments: Reliability, Validity, and Generalizability Investigations. Journal of Applied Psychology, 107(8), 1323–1351. https://doi.org/10.1037/apl0000695
- Hickman, L., Tay, L., & Woo, S. E. (2024). Are automated video interviews smart enough? Behavioral modes, reliability, validity, and bias of machine learning cognitive ability assessments. Journal of Applied Psychology. https://doi.org/10.1037/apl0001236
- Ishii, R., Ahuja, C., Nakano, Y. I., & Morency, L.-P. (2020). Impact of Personality on Nonverbal Behavior Generation. Proceedings of the 20th ACM International Conference on Intelligent Virtual Agents, 1–8. https://doi.org/10.1145/3383652.3423908
- Koutsoumpis, A., Ghassemi, S., Oostrom, J. K., Holtrop, D., van Breda, W., Zhang, T., & de Vries, R. E. (2024). Beyond traditional interviews: Psychometric analysis of asynchronous video interviews for personality and interview performance evaluation using machine learning. Computers in Human Behavior, 154, 108128. https://doi.org/10.1016/j.chb.2023.108128
- Lukacik, E. R., Bourdage, J. S., & Roulin, N. (2022). Into the void: A conceptual model and research agenda for the design and use of asynchronous video interviews. Human Resource Management Review, 32(1), 100789.
- Martínez, A., Lado, M., Cuadrado, D., & Salgado, J. F. (2025). A Meta-analysis of the Relationship between Cognitive Intelligence and the Big Five Assessed by Quasi-Ipsative Forced-choice Personality Inventories: Implications for Predicting Job Performance. Journal of Work and Organizational Psychology, 41(1), 19-26.
- Mehta, Y., Majumder, N., Gelbukh, A., & Cambria, E. (2020). Recent trends in deep learning based personality detection. The Artificial Intelligence Review, 53(4), 2313–2339. https://doi.org/10.1007/s10462-019-09770-z

© ADIC-IIC

ISSN: 2792-3770

- Parlamento Europeo y Consejo de la Unión Europea. (2024). Reglamento (UE) 2024/1689 del Parlamento Europeo y del Consejo, de 13 de junio de 2024, por el que se establecen normas armonizadas en materia de inteligencia artificial y por el que se modifican los Reglamentos (CE) n.° 300/2008, (UE) n.° 167/2013, (UE) n.° 168/2013, (UE) 2018/858, (UE) 2018/1139 y (UE) 2019/2144 y las Directivas 2014/90/UE, (UE) 2016/797 y (UE) 2020/1828 (Reglamento de Inteligencia Artificial). Diario Oficial de la Unión Europea. ELI: http://data.europa.eu/eli/reg/2024/1689/oj
- Rasipuram, S., Rao S. B, P. & Jayagopi, D. B. (2016). Asynchronous video interviews vs. face-to-face interviews for communication skill measurement: a systematic study. Proceedings of the 18th ACM international conference on multimodal interaction, 370-377. https://doi.org/10.1145/2993148.2993183
- Sackett, P. R., Zhang, C., Berry, C. M., Lievens, F., & Eby, L. T. (2022). Revisiting Meta-Analytic Estimates of Validity in Personnel Selection: Addressing Systematic Overcorrection for Restriction of Range. Journal of Applied Psychology, 107(11), 2040–2068. https://doi.org/10.1037/apl0000994
- Suen, H. Y., Hung, K. E., & Lin, C. L. (2020). Intelligent video interview agent used to predict communication skill and perceived personality traits. Human-centric Computing and Information Sciences, 10(1), 3.
- Suen, H.-Y., Hung, K.-E., & Lin, C.-L. (2019). TensorFlow-Based Automatic Personality Recognition Used in Asynchronous Video Interviews. IEEE Access, 7, 61018–61023. https://doi.org/10.1109/ACCESS.2019.2902863
- Tett, R. P., Jackson, D. N., & Rothstein, M. (1991). Personality measures as predictors of job performance: A meta-analytic review. Personnel Psychology, 44(4), 703–742. https://doi.org/10.1111/j.1744-6570.1991.tb00696.x
- Tian, Y.-I., Kanade, T., & Cohn, J. F. (2001). Recognizing action units for facial expression analysis. IEEE Transactions on Pattern Analysis and Machine Intelligence, 23(2), 97–115. https://doi.org/10.1109/34.908962
- Zebrowitz, L. A., & Montepare, J. M. (2008). First impressions from facial appearance cues. First impressions, 171-204.

© ADIC-IIC

ISSN: 2792-3770

ARTÍCULO 07

© ADIC-IIC

ISSN: 2792-3770

instituto de ingeniería del conocimiento

TECNOLOGÍA Y ANÁLISIS DE DATOS AL SERVICIO DE RR. HH.

HR ANALYTICS

El análisis de los datos de RR. HH. permite obtener información de valor para una mejor gestión del talento. El IIC aplica analítica descriptiva y predictiva para optimizar procesos de selección, predecir el absentismo o la rotación e identificar a los profesionales con más potencial, entre otros proyectos.

EVALUACIÓN DE COMPETENCIAS

Dentro de la plataforma online eValue, desarrollamos pruebas objetivas y fiables para evaluar las competencias transversales, el nivel de inglés o las motivaciones de candidatos y empleados. Además de tomar mejores decisiones, se obtienen datos de calidad para analizar, por ejemplo, sus necesidades de formación.

ANÁLISIS DE REDES ORGANIZACIONALES

Los proyectos AROS permiten analizar las relaciones de trabajo y las interacciones entre los profesionales. Representadas visualmente en un grafo, se pueden identificar redes informales, referentes ocultos o cuellos de botella en la organización, para emprender acciones de mejora.

www.iic.uam.es

INSTITUTO DE INGENIERÍA DEL CONOCIMIENTO (IIC)

EXPERTOS EN INTELIGENCIA ARTIFICIAL DESDE 1989

El Instituto de Ingeniería del Conocimiento (IIC) es un centro I+D+i experto desde hace más de 35 años en el tratamiento y análisis de todo tipo de datos, el motor de la inteligencia artificial. Trabajamos para ofrecer **una visión real de la IA**, a través del desarrollo de herramientas propias y de la consultoría en proyectos más personalizados.

Partimos de la **investigación aplicada** para que los avances lleguen de forma práctica a sectores como el de la salud, la energía, los RR. HH. o los seguros. Apostamos por **soluciones de calidad y por una IA responsable**, pero la clave es que detrás de la tecnología sigan estando las personas. Es el equipo multidisciplinar del IIC el que marca la diferencia.

Las soluciones tecnológicas del IIC para RR. HH. van dirigidas a **mejorar la toma de decisiones en la gestión del talento**. Ofrecemos herramientas para recoger datos de calidad sobre las personas, como las pruebas de **evaluación de eValue**, y desarrollamos **proyectos People Analytics** a medida para extraer conclusiones. Todos estos servicios cuentan con el soporte y trabajo conjunto de psicólogos, psicómetras y expertos en tecnología del IIC.

ENTORNO BANCARIO | ENTORNO RR.HH. | ENTORNO SEGUROS | ENTORNO ENERGÍA | ENTORNO SALUD | ENTORNO INTELIGENCIA DE CLIENTE



NUESTROS ASOCIADOS:

Santander | MAPFRE | IBM | UAM Universidad Autónoma de Madrid

INSTITUTO DE INGENIERÍA DEL CONOCIMIENTO

C/ Francisco Tomás y Valiente, 11 EPS,
Edificio B, 5ª planta UAM Cantoblanco.
28049 Madrid
http://www.iic.uam.es/
contacto.iic@iic.uam.es
(+34) 91 497 2323



instituto
de ingeniería
del conocimiento

www.iic.uam.es

Instituto de Ingeniería del Conocimiento

C/ Francisco Tomás y Valiente, nº 11
Escuela Politécnica Superior (EPS),

Edificio B, 5ª planta
Universidad Autónoma de Madrid (UAM).

28049 Cantoblanco, Madrid

T. (+34) 91 497 23 23