



Revista de Casos de Estudio en HR Analytics

Journal of HR Analytics *Case Studies*

06. Mirando la Rotación voluntaria desde HR: una visión integrada de la práctica analítica.

Looking at Voluntary Turnover from HR: An Integrated View of Analytical Practice

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 y líneas 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.

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.

Accenture.

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.

.06



.06

Mirando la Rotación voluntaria desde HR: una visión integrada de la práctica analítica.

Relationships Matter: Exploring the Network's Effect in the Performance of Teamworks.

Sonia Rodríguez
Instituto de Ingeniería del Conocimiento

Correo electrónico:
sonia.rodriguez@iic.uam.es

LinkedIn:
<https://www.linkedin.com/in/soniarodriguezsobrino/>

Beatriz Lucía
Instituto de Ingeniería del Conocimiento

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

LinkedIn:
<https://www.linkedin.com/in/beatrizlucia/>

Received: 12 september 2023
Received in revised form: 21 october 2023
Accepted: 21 november 2023
Available on-line: 29 november 2023



Palabras clave

Rotación, machine learning, variables, explicabilidad, modelos, ETL, coeficientes Sharp

Keywords

Turnover, machine learning, variables, explainability, models, ETL (Extraction, Transformation, Load), Shapley coefficients

Resumen

Este artículo tiene como objetivo explorar las estrategias fundamentadas en el análisis de datos y su contribución para comprender y mitigar la rotación laboral. Se abordarán las fases comúnmente involucradas en proyectos de esta índole, así como los elementos esenciales para enfrentar un proyecto de analítica de datos con éxito.

Abstract

This article aims to explore strategies grounded in data analysis and their contribution to understanding and mitigating employee turnover. The commonly involved phases in projects of this nature will be addressed, along with the essential elements to successfully tackle a data analytics project.

1. Rotación e impacto en las empresas

La rotación laboral se refiere al acto voluntario de una persona empleada de dejar su puesto de trabajo en una compañía, excluyendo casos como las jubilaciones o abandonos del trabajo por motivos de fuerza mayor.

Una alta tasa de rotación puede suponer un grave problema para la empresa, ya que, además del coste que supone el abandono de una persona y sustitución de la misma, puede impactar enormemente en la motivación del equipo de trabajo y en la reputación organizacional como lugar para trabajar. Desde la perspectiva del coste que supone, el abandono de un empleado implica no solo la pérdida de un recurso humano de valor para la empresa sino también la necesidad de contratar y capacitar a otra persona que ocupe este puesto y que, en un corto o medio plazo, pueda adaptarse e integrarse en la organización. En lo que respecta a la reputación, es una realidad que las compañías con alta tasa de rotación no suelen ser las más atractivas para las personas que están en búsqueda activa de empleo. Además, el efecto contagio de la rotación puede impactar negativamente en la percepción general de estabilidad en la compañía, llevando a que numerosos empleados tomen la decisión de abandonarla. En el competitivo mercado laboral actual, estas organizaciones pueden mostrar grandes dificultades significativas para atraer talento.

Los motivos por los que una persona decide abandonar la empresa son muy variados y personales, pero sí podemos encontrar que hay factores tanto internos como externos a la organización que pueden afectar a que exista una probabilidad mayor de salida voluntaria. Es evidente que el mercado va generando oportunidades diversas que pueden hacer más atractivas a otras organizaciones. En estos casos, es fundamental ser activo en un análisis continuo para comprender el mercado y revisar las prácticas de las empresas competidoras, a fin de realizar los ajustes necesarios que incentiven a los empleados a permanecer en nuestra organización.

Dentro de la empresa, el bienestar, el compromiso y la motivación de las personas representan factores cruciales para su fidelización y permanencia en ellas. Se observa como en compañías con una alta tasa de bajas voluntarias es habitual encontrar niveles más bajos de satisfacción o compromiso que pueden repercutir directamente en su productividad y, en última instancia, en el abandono de la empresa.

Conocer el riesgo que tienen las personas trabajadoras de abandonar la empresa y la identificación de los factores de riesgo que influyen en las desvinculaciones voluntarias permite a las compañías diseñar estrategias de intervención efectivas en la retención de las personas trabajadoras.

Las estrategias que se apoyan en el análisis de los datos de las personas de la compañía, así como de otro tipo de datos, por ejemplo, cifras de la competencia, representan herramientas valiosas para lograr el propósito de conocer y reducir la rotación a cifras deseadas.

Por lo general, los proyectos de este tipo se enfocan en los siguientes objetivos:

1. Desarrollar un modelo de predicción que permita conocer el riesgo o probabilidad de salida voluntaria de una persona en su compañía. Para ello, resulta fundamental analizar el histórico de datos de la plantilla y definir la ventana de tiempo en la que se realizará la predicción (por ejemplo, a 4 o 6 meses en el futuro).
2. Identificar cuáles son las variables que afectan a esa puntuación o scoring de riesgo, con el fin de que la empresa pueda tomar medidas eficaces antes de que se produzca la renuncia voluntaria.
3. Realizar un análisis estadístico descriptivo de los datos con el objetivo de descubrir relaciones entre las variables y generar visualizaciones que faciliten la toma de decisiones.
4. Explorar la explicabilidad de los modelos de machine learning empleados durante el análisis de los datos.

En línea con lo anterior, el objetivo de este trabajo consiste en detallar los elementos esenciales que deben considerarse en el ámbito del análisis de la rotación a través del HRA. Se abordarán aspectos relativos a los datos, las técnicas analíticas a emplear y la explicabilidad de los modelos.

2. Los datos

2.1. La calidad de los datos

El primer paso siempre es determinar qué tipos de datos resultarán relevantes para abordar el proyecto y conocer la disponibilidad y localización de los mismos. En proyectos de este tipo, la fase de extracción, transformación y carga (ETL) es, sin duda, la etapa que consume más tiempo y requiere el mayor esfuerzo.

En los proyectos relacionados con la rotación de personal, es habitual contar con información sociodemográfica de los empleados, así como datos laborales que abarcan desde su historial de empleo hasta su situación laboral actual. Estos datos no siempre están centralizados en un único sistema, a menudo se requiere la colaboración activa de diversos equipos o departamentos para recopilar, localizar y, en ocasiones, interpretar su significado.

En este punto es importante la encriptación y anonimización de los datos, en línea con esto, todas las tablas de datos deben poder relacionarse entre sí a nivel persona empleada mediante un ID o código único. De esta manera las personas que analizan o tratan la información no pueden identificar a los empleados.

En la fase de análisis de datos de cualquier proyecto de estas características, es común enfrentarse a problemas relacionados con la calidad de los datos. Para minimizar su impacto y prevenir problemas posteriores, resulta importante incorporar en el proceso ETL un procedimiento que permita identificar y validar la calidad de la información. Esto asegura que las deficiencias en la calidad de los datos no influyan negativamente en el rendimiento de los modelos:

- **Valores fuera de rango o datos erróneos.**
Es común encontrarse con valores atípicos que se desvían de los rangos esperados, así como datos incorrectos, como fechas mal registradas. Durante la fase de ETL, se lleva a cabo un análisis para identificar estos casos y tomar las decisiones correspondientes.
- **Histórico de la información.**
En el momento en el que se emprende un proyecto así, es esencial definir el alcance del histórico de información con el que se va a trabajar. En general, cuanto mayor sea el histórico de datos, mayor será la precisión del modelo. Esto adquiere una importancia

destacada en proyectos donde el número de casos "positivos" en el objetivo (personas que abandonan la organización de forma voluntaria) es reducido.

No obstante, en ocasiones es necesario valorar la pertinencia de incluir todo el histórico dado que determinados eventos pueden introducir más ruido al análisis. Por ejemplo, cambios empresariales, nuevas políticas de RRHH o cambios en el procedimiento de recogida los datos, entre otros, pueden determinar que sea necesario trabajar con el histórico a partir de una determinada fecha, aunque ello implique contar con menos volumen de datos.

Por otro lado, a pesar de tener un histórico de datos inicial, puede ser que a lo largo del tiempo se hayan incorporado o eliminado algunas de las variables o campos. En estos casos, habrá que valorar la pertinencia de incluir o no estas variables en el análisis y modelado.

- **Unidad o medida del dato.**
En proyectos de rotación, los datos que informan sobre la evolución del empleado en la empresa suelen registrarse a nivel mensual. Esto implica que sea necesario trabajar con una fila de datos para cada empleado y cada mes (p.e: turnos, nº horas extras, días de vacaciones, permisos, bajas, tipo de baja, etc.). Sin embargo, hay otro tipo de datos que se presentan en otra escala temporal de medida, por ejemplo, de manera anual, semestral, como puede ser el salario, subidas, promociones, evaluaciones del desempeño, etc.
Es fundamental realizar un tratamiento riguroso y exhaustivo para evitar inconsistencias en la tabla de datos.
- **Elevado número de valores perdidos.**
Es habitual encontrar variables con un elevado número de valores perdidos, por un lado, y también valores perdidos con difícil imputación.
El análisis de omisiones, que debe realizarse en los primeros momentos, permite localizar aquellos datos que faltan o están incompletos para determinar si se deben imputar y cómo, o bien si deben ser tratados como valores perdidos.

Incluir variables con elevada tasa de omisiones puede tener impacto en la precisión del modelo, en algunos casos. Sin embargo, es importante mencionar que existen modelos de analítica avanzada que pueden manejar eficazmente variables con datos faltantes.

- **Variables redundantes.**

Dentro de los sistemas de la compañía, es posible encontrar datos o variables que proporcionan la misma información, por ejemplo, la fecha de nacimiento y la edad, o la antigüedad en la empresa, el departamento y el puesto. En esa línea, es esencial localizarlos para eliminar variables redundantes que puedan impactar en el análisis.

- **Segmentación de los datos.**

Es necesario decidir, una vez finalizado el análisis inicial de los datos, cuáles van a servir para entrenar el modelo, y cuáles para testarlo. Lo más habitual es dejar el último año para testar la eficacia del algoritmo de predicción, pero dependerá del volumen y el tipo de datos.

2.2. Las variables

La tabla analítica resultante de la ETL contendrá la información de todos los empleados, registrada de manera mensual, para el colectivo objeto de análisis y el histórico previamente definido.

Cuando se trabaja con modelos de aprendizaje supervisado, es esencial tener claramente localizada la variable target u objetivo. En general, en proyectos enfocados en la rotación, esta es la variable o el campo donde se informa de la situación del empleado en su relación contractual con la empresa. Y donde se identificará a los que causan baja voluntaria y a los que no. Será, por tanto, la variable que servirá para clasificar a los empleados y entrenar el modelo; en términos estadísticos, es la variable criterio o dependiente.

En proyectos de análisis de la rotación, es común contar con diversos tipos de variables que pueden agruparse de la siguiente manera:

- **Variables relacionadas con el personal contratado (o que fue contratado en algún momento).** Estas variables contienen información proporcionada por la organización y suelen abordar aspectos como:

- Datos sociodemográficos: incluyen edad, país de origen, estado civil, número de hijos, dirección, entre otros.
- Área de trabajo: abarca información de la posición del empleado en la empresa, como el departamento, el puesto, la categoría profesional del empleado, así como su tipo de contrato, turnos y horarios.
- Grupos de interés: asignación a colectivos específicos (proyectos, áreas, perfiles, etc.).
- Situación del empleado en la organización: engloba aspectos como antigüedad, salario, bonificaciones, evaluaciones de desempeño, viajes de trabajo, movilidad laboral, estancias internacionales, promociones, vacaciones y ausencias, entre otros.
- Formación reglada o no reglada.
- Datos procedentes de las encuestas de clima laboral o estudios de valores organizacionales (habitualmente se dispone de esta información de forma agregada, lo que complica su utilización para el modelo).
- Entrevistas de salida. Esta información, si existe, se analiza de forma descriptiva pero no para el entrenamiento del modelo de predicción ya que es una información que solo se obtiene una vez decidida la salida.

- **Variables calculadas.** Se trata de información adicional que se incorpora también al modelo a partir del cálculo basado en datos de variables existentes y que permite analizar con más detalle la evolución de aspectos interesantes. Algunos ejemplos son:

- Ventanas temporales: Son variables que originalmente se registran en una métrica concreta, por ejemplo 'horas de formación mensual' y posteriormente se calculan de manera agregada en diferentes escalas de tiempo: por ejemplo 'horas de formación en los últimos 6 meses', 'horas de formación en los últimos 12 meses' y 'horas de formación en los últimos 24 meses'.
- Datos calculados relativos a una segmentación específica (responsable, departamento, equipo, etc.): antigüedad, número de empleados, número de empleados que han sido baja voluntaria, etc.

- Variables calculadas en función del tiempo: Se trata de variables que reflejan el tiempo transcurrido desde un último evento, por ejemplo, tiempo desde la última promoción, o desde la última subida de sueldo, etc.
- Variables calculadas referidas a 'distancias': Incluyen datos como la distancia al puesto de trabajo o el tiempo en traslado del domicilio al puesto de trabajo. En proyectos relacionados la rotación o el absentismo este tipo de variables pueden tener importancia.
- Variables con datos acumulados: Estas variables representan la acumulación de datos a lo largo del

tiempo, como por ejemplo el número de promociones, viajes realizados o cursos completados, etc.

- Existen otro tipo de **variables externas** que pueden ser de utilidad para incorporar a los modelos, como, por ejemplo:
 - Indicadores de rotación en compañías del mismo sector.
 - Estudios laborales relacionados con las preferencias de ciertos perfiles según formación, generación, etc.

3. Entrenamiento del modelo y técnicas analíticas

3.1. Entrenamiento de modelos

Una vez configurada la tabla analítica con datos completos, limpios y coherentes, y una vez decididas inicialmente las variables a utilizar, se procede a la fase de entrenamiento del modelo de predicción.

Antes de entrar en detalles, resulta importante definir la variable objetivo o target, es decir, lo que se busca predecir. En proyectos de este tipo, la atención se centra en anticipar la posibilidad de renuncias voluntarias por parte de los empleados en los próximos meses. Se sugiere un periodo de anticipación de entre 3 y 6 meses, ya que estos modelos son más precisos al prever un periodo de tiempo más corto. Este plazo ofrece a la empresa oportunidad de intervenir y, en la medida de lo posible, evitar la salida de un empleado de la compañía.

Esta etapa se puede abordar desde dos enfoques: mediante la utilización de modelos de machine learning (de aprendizaje supervisado) y mediante técnicas de estadística tradicional basada en modelos lineales. En ocasiones los modelos lineales tradicionales funcionan suficientemente bien, pero trabajan con un número reducido de variables que no permiten entender el problema en toda su complejidad. A cambio, trabajar con técnicas de machine learning es más complejo y requiere más datos, pero permiten ser más eficaces en la predicción ya que incorporan un gran número de variables y son capaces de entender relaciones complejas y no necesariamente lineales entre ellas.

- Técnicas de estadística multivariante: permiten analizar la relación lineal entre las variables analizadas y la variable target (rotación). Dependiendo de la técnica utilizada, permiten explorar las relaciones entre variables y descubrir diferencias entre los grupos analizados. Algunas técnicas empleadas incluyen análisis de varianza y diferencias de medias, correlaciones o regresiones lineales. Si el objetivo es la predicción, la técnica más utilizada es la regresión (lineal o logística) que permite comprender de forma muy sencilla el impacto que tienen las variables predictoras en el criterio.
- Modelos de machine learning: estos modelos permiten capturar las relaciones no lineales entre el objeto de estudio, en este caso la salida voluntaria de la empresa, y las variables conocidas para cada persona. Permiten estimar, en función de las variables, el riesgo de que se produzca una baja voluntaria para una persona y mes. La elección del modelo a utilizar depende de varios factores, como la tipología de datos, si están desbalanceados (muy pocos casos positivos, por ejemplo), la calidad de los mismos, los valores perdidos, el histórico contemplado, etc. Se suelen emplear técnicas de aprendizaje supervisado (comunmente utilizadas en estos proyectos), de aprendizaje no supervisado y de aprendizaje por refuerzo.

3.2. Validación de los modelos: Resultados

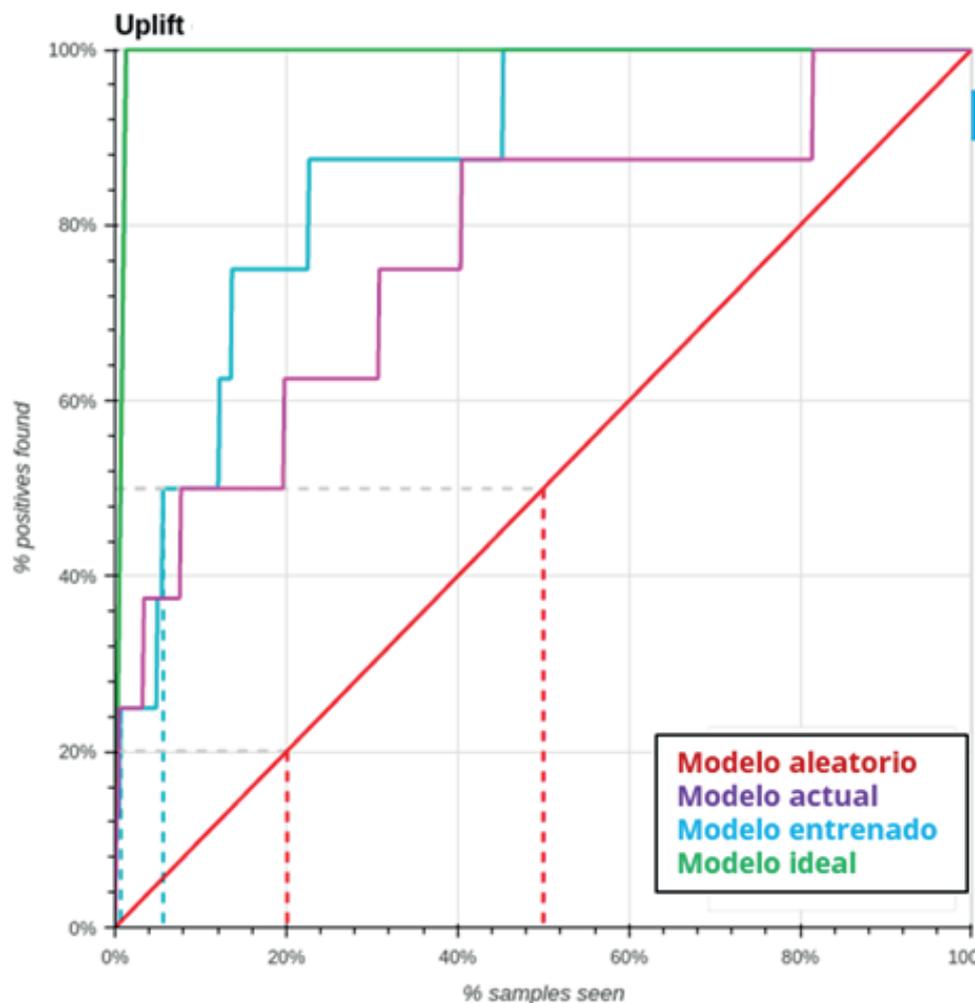
Para evaluar la precisión de los modelos, una de las técnicas comunes es el uso de gráficos de curva uplift. Estos gráficos proporcionan una representación visual e intuitiva del rendimiento del modelo.

Como se observa en la figura 1, en el eje X se encuentran los datos de todo el conjunto (cada persona y mes) ordenados de mayor a menor en función del score que el modelo asigna. En el eje Y se muestran los casos reales de bajas voluntarias en esa lista ordenada. La curva uplift del

modelo se representa como una línea azul (Modelo entrenado en la leyenda de la figura). Si el modelo fuese perfecto, la curva resultante coincidiría con la línea verde.

Por otro lado, si las personas fueran asignadas a una probabilidad de riesgo de manera aleatoria, se obtendría una curva como la que se representa en color rojo. Esta comparativa también puede llevarse a cabo si la organización utiliza un modelo de predicción propio para comparar la eficacia de los dos.

Figura 1.



Este gráfico permite responder dos tipos de preguntas:

- Si atendemos a un determinado porcentaje de la muestra (X), ¿cuántos positivos (o alto riesgo) (Y) encontramos?
- O bien, si queremos encontrar Y positivos, ¿qué % de la muestra (X) tenemos que ver?

De esta forma, se obtiene una aproximación a la eficacia del modelo entrenado.

4. Utilidad de la explicabilidad

Además, con el objetivo de trabajar bajo el marco de la transparencia requerida en este tipo de proyectos, y para facilitar la interpretación de los resultados, una vez obtenido el mejor modelo posible, es decir el que muestra un mejor rendimiento o eficacia, se debe poner el foco en el análisis de la explicabilidad del modelo.

Una de las grandes dificultades de utilizar técnicas de machine learning es la complejidad para conocer el peso que tienen las diferentes variables en el modelo, es decir, qué dimensiones o variables son relevantes en el fenómeno que se está analizando y, más aún, conocer qué dimensiones tienen más peso para cada caso concreto, para cada persona analizada.

En el ámbito de los RRHH este tema cobra especial relevancia ya que las decisiones que se puedan tomar serán sensiblemente diferentes si la variable con un mayor peso tiene que ver con la retribución, con las vacaciones o con la distancia al puesto de trabajo. En este caso concreto, hace que resulte imprescindible conocer cuánto acierta el modelo en su predicción y también identificar en qué se basa para tomar la decisión. Su uso permite hacer una comunicación más transparente y comprensible de las variables que están detrás del modelo.

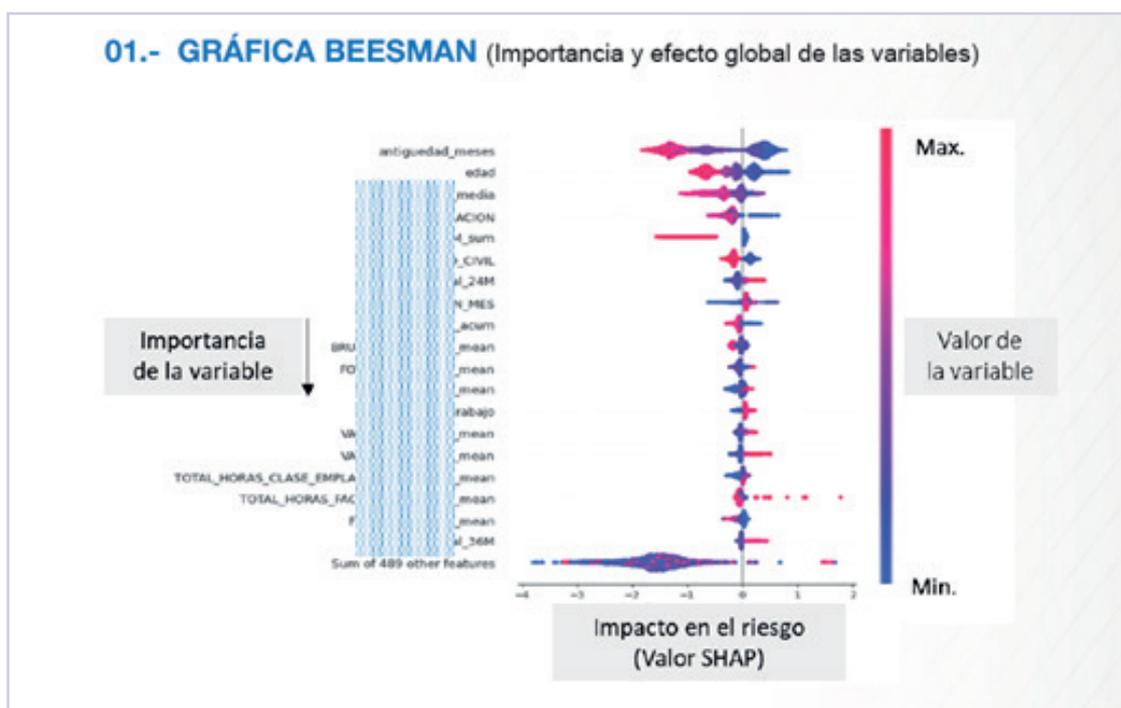
En esa línea, en los últimos años se ha avanzado con la

utilización de técnicas de explicabilidad y una de las técnicas para abordar este tema son los coeficientes de Shapley. Estas técnicas permiten estimar la influencia de cada variable en el riesgo de baja voluntaria en un mes determinado.

Los coeficientes se calculan teniendo en cuenta las interacciones entre todas variables, utilizando cálculos relativamente complejos. Una vez calculados los coeficientes para cada variable se interpretan del siguiente modo: los valores de Shapley más altos indican una mayor importancia o contribución de una característica a las predicciones del modelo, mientras que los coeficientes más bajos indican una contribución menor.

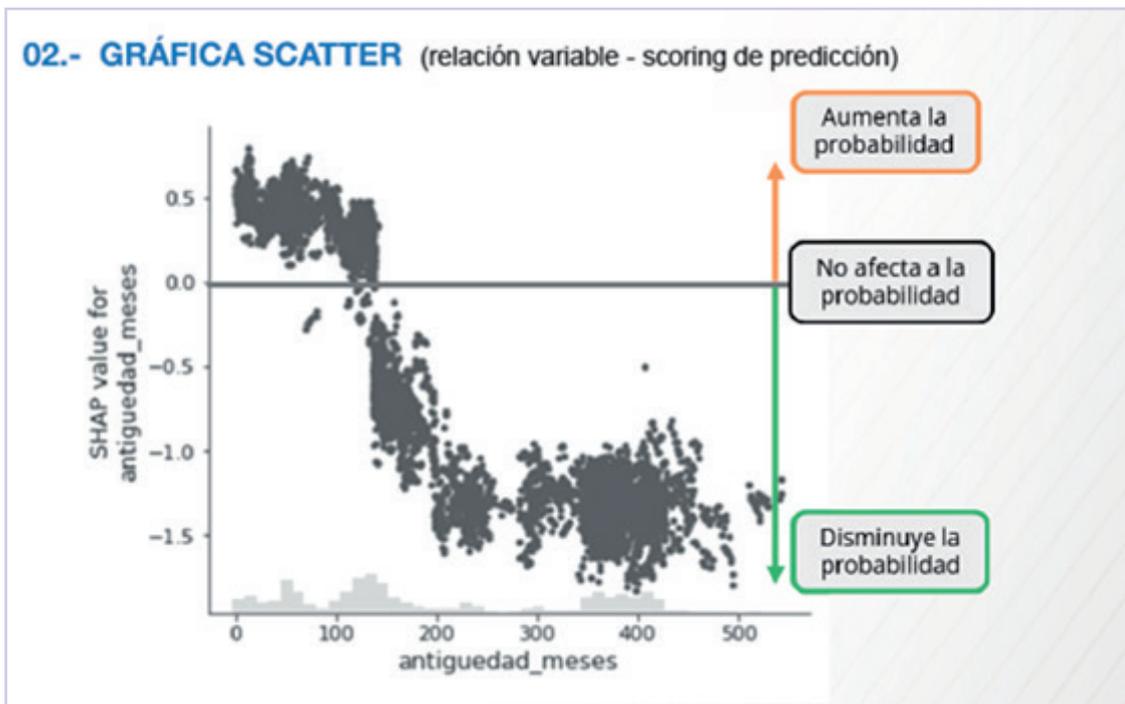
Estos valores nos ofrecen muchas formas de visualización, a través de representaciones gráficas y permiten obtener información del modelo en tres niveles: Foco en el Modelo completo, Foco en una Variable y Foco en una persona para la que se ha estimado un riesgo.

¿Cuáles son las variables más relevantes del modelo que afectan al valor de predicción? Para visualizar la importancia y el impacto global de las variables en el modelo, se puede utilizar la gráfica Beesman.



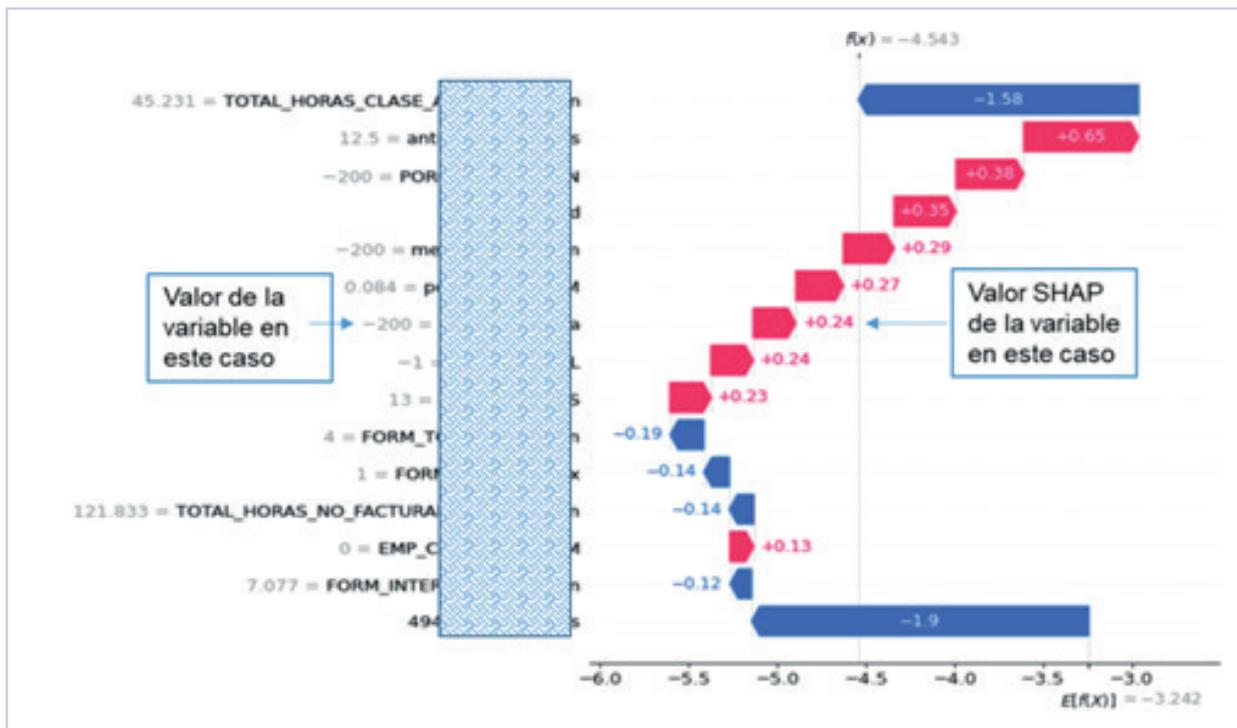
Para interpretar este gráfico, hay que tener en cuenta que cada punto representa el valor que toma cada variable en cada caso predicho (mes/persona). Estas variables están ordenadas de mayor a menor impacto en el riesgo de baja voluntaria. El color indica el valor que toma la variable en el rango de valores posible. Por otro lado, el eje X representa los valores de Shap. Para ver el impacto de cada una de las variables en la salida del modelo hay que observar los valores que adquieren. Si un punto se encuentra a la izquierda del 0 (valor negativo) significa que el valor que toma la variable hace que el riesgo de baja voluntaria disminuya, mientras que si está en a la derecha del 0 (positivo) lo aumenta.

¿Cómo afecta una variable en concreto al valor de predicción? Para visualizar cada variable de manera independiente y analizar los valores que está tomando y el resultado ofrece en cada caso, se puede utilizar una gráfica del tipo scatter o dispersión. En el ejemplo se observa cómo, en el caso de la antigüedad medida en meses, aparecen valores de shap positivos (aumenta el riesgo) para personas con antigüedad por debajo de 100 meses (aprox.), ya parecen valores negativos (el riesgo disminuye) para antigüedades superiores a 100-120 meses. En este caso parece que el riesgo es mayor en los primeros años de contratación, para la muestra en general.



¿Cuáles son las variables más relevantes para un caso en concreto? Por último, los gráficos de cascadas permitirán observar el peso de cada variable sobre el score de una persona en concreto.

La gráfica representa como contribuye cada variable a subir o bajar el riesgo de una persona y mes en concreto. Partiendo del valor esperado, es decir el valor que obtendría la predicción sin tener en cuenta ninguna variable, se representa el peso de cada variable (eje Y) en el scoring (eje X).



.06



instituto de ingeniería
del conocimiento

INSTITUTO DE INGENIERÍA DEL CONOCIMIENTO (IIC)

PIONEROS EN INTELIGENCIA ARTIFICIAL DESDE 1989

El Instituto de Ingeniería del Conocimiento (IIC) es un centro privado de I+D+i fundado en 1989 y pionero en Inteligencia Artificial. Llevamos más de 30 años trabajando en análisis Big Data y diferentes técnicas de **Machine Learning** y **Procesamiento del Lenguaje Natural (PLN)**, entre otras.

Nuestra apuesta de valor es el desarrollo de algoritmos y soluciones tecnológicas adaptadas a diferentes sectores y basadas siempre en la investigación aplicada. Como centro sin ánimo de lucro, comercializamos los productos y servicios fruto de nuestro trabajo para reinvertir los beneficios en más investigación e innovación.

En el IIC estamos especializados en tecnologías de analítica avanzada y en el desarrollo de **modelos de Inteligencia Artificial** para las áreas de Banca, RR. HH., Energía, Salud, Seguros e Inteligencia de Cliente.

Además, destacamos por ser expertos en la preparación y tratamiento de todo tipo de datos para su análisis y por la metodología que utilizamos para acompañar a nuestros clientes durante todo el proceso.

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.



ENTORNO
BANCARIO



ENTORNO
RR.HH.



ENTORNO
SEGUROS



ENTORNO
ENERGÍA



ENTORNO
SALUD



ENTORNO
INTELIGENCIA
DE CLIENTE



NUESTROS ASOCIADOS:



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/empleo-iic/>

contacto.iic@iic.uam.es

(+34) 91 497 2323



www.linkedin.com/company/instituto-de-ingenier-a-del-conocimiento---iic



www.twitter.com/IIConocimiento



www.youtube.com/IIConocimiento



INNOVADATA



iic
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