



Módulo 4. Analítica del aprendizaje (L&D) engagement, impacto y modelo Kirkpatrick



1. Analítica del aprendizaje y engagement en el ciclo del colaborador



2. Medición del impacto del aprendizaje: modelo Kirkpatrick y analítica avanzada



Referencias

1. Analítica del aprendizaje y engagement en el ciclo del colaborador

Introducción

En los módulos anteriores analizamos cómo el People Analytics transforma la gestión del ciclo del colaborador a partir del uso de modelos predictivos, técnicas de machine learning y sistemas de soporte a la decisión. Estudiamos cómo la rotación, el desempeño y el engagement pueden modelizarse a través de variables observables, correlaciones y predictores que permiten anticipar riesgos y diseñar intervenciones estratégicas. Sin embargo, surge una pregunta central: ¿qué lugar ocupa el aprendizaje organizacional dentro de estos modelos analíticos? ¿Es posible medir el impacto real de la formación en la retención y el desempeño?

En contextos de alta competencia por el talento, la formación deja de concebirse como una instancia aislada para integrarse al ciclo completo del colaborador. Diversos estudios sobre analítica de recursos humanos muestran que la retención y la satisfacción se encuentran estrechamente vinculadas con oportunidades de

desarrollo y crecimiento profesional. Investigaciones basadas en análisis predictivo indican que colaboradores con bajos niveles de engagement presentan tasas de rotación significativamente superiores en comparación con aquellos con altos niveles de compromiso organizacional (Karimi & Viliyani, 2024; Mohiuddin et al., 2023). Este dato invita a reflexionar: ¿cómo se vincula la experiencia de aprendizaje con esos niveles de compromiso?

La analítica del aprendizaje —learning analytics— permite responder estas preguntas desde una perspectiva cuantitativa y estratégica. A través del análisis de datos sobre participación en programas formativos, desempeño posterior, evaluaciones y trayectorias profesionales, es posible identificar patrones que relacionan inversión en capacitación con resultados organizacionales. Este enfoque supera la medición descriptiva de horas de formación para incorporar modelos predictivos capaces de estimar impacto futuro.

Asimismo, la literatura reciente en HR Analytics señala que las organizaciones que integran capacidades analíticas en sus funciones de recursos humanos logran mayor precisión en la planificación de la fuerza laboral y en la predicción del desempeño (Shifa et al., 2026). La formación, en este marco, deja de ser un costo operativo para convertirse en una variable estratégica modelizable.

Ahora bien, medir aprendizaje implica ir más allá de la satisfacción inmediata. ¿Cómo se traduce una experiencia formativa en cambios conductuales? ¿Qué evidencia permite afirmar que una intervención de Learning & Development genera impacto organizacional? Estas preguntas conducen al análisis de modelos de evaluación, entre ellos el modelo Kirkpatrick, que abordaremos en la segunda unidad desde una perspectiva analítica.

En esta primera unidad desarrollaremos los fundamentos conceptuales y técnicos que permiten integrar el aprendizaje al ecosistema de People Analytics. Analizaremos la evolución desde enfoques tradicionales hacia modelos predictivos, estudiaremos la relación entre engagement, desempeño y retención, y examinaremos cómo los algoritmos supervisados y las técnicas de modelado permiten anticipar comportamientos en el ciclo del colaborador.

De este modo, el aprendizaje deja de evaluarse únicamente por su ejecución y comienza a analizarse por su impacto medible en variables estratégicas de negocio. Esta transformación constituye uno de los desafíos centrales de la gestión contemporánea del talento.

De la formación tradicional al Learning Analytics: fundamentos y evolución hacia modelos predictivos

La función de Learning & Development (L&D) ha atravesado una transformación estructural en las últimas dos décadas. En su configuración tradicional, la formación organizacional se orientaba principalmente a la ejecución de actividades: cursos presenciales, talleres técnicos y programas de inducción cuya evaluación se limitaba a indicadores operativos como asistencia, satisfacción o cumplimiento de horas. Este enfoque permitía describir la actividad formativa, pero ofrecía escasa evidencia sobre su impacto en variables estratégicas del ciclo del colaborador.

Con la incorporación del People Analytics, el aprendizaje comienza a analizarse como un fenómeno medible y modelizable. La formación deja de evaluarse únicamente por su implementación y pasa a estudiarse como una variable explicativa dentro de modelos predictivos vinculados con desempeño, retención y engagement. En este punto, el aprendizaje se integra al ecosistema analítico de recursos humanos.

Diversos estudios sobre predicción de rotación y desempeño evidencian que las variables asociadas al desarrollo profesional presentan correlaciones significativas con la permanencia organizacional (Karimi & Viliyani, 2024; Alhamad et al., 2024). Esto implica que la formación ya no constituye un elemento periférico, sino un posible predictor dentro de modelos supervisados de clasificación.

Desde una perspectiva técnica, la transición puede comprenderse en tres niveles evolutivos:

1

Nivel descriptivo: registro de horas de capacitación y tasas de asistencia.

2

Nivel diagnóstico: análisis de relación entre formación y desempeño posterior.

3

Nivel predictivo: modelización de probabilidad de retención o mejora de performance a partir de datos formativos.

Esta evolución supone una modificación en la lógica de gestión. En lugar de preguntar «¿cuántas personas asistieron al curso?», el análisis se orienta hacia interrogantes como:



¿La participación en programas de desarrollo reduce la probabilidad de rotación?

- ¿Existen patrones formativos asociados a trayectorias de alto desempeño?
- ¿Qué tipo de intervención genera mayor impacto en el compromiso organizacional?

La literatura en HR Analytics sostiene que la capacidad predictiva surge cuando las organizaciones integran datos heterogéneos en modelos analíticos consistentes (Shifa et al., 2026). En este marco, los registros de formación se transforman en insumos estratégicos.

Tabla 1. Evolución del enfoque formativo hacia Learning Analytics

Dimensión	Formación tradicional	Enfoque <i>Learning Analytics</i>
Objetivo principal	Cumplimiento de plan anual	Optimización de impacto en variables estratégicas
Indicadores utilizados	Horas, asistencia, encuestas de satisfacción	Retención, desempeño, movilidad interna

Tipo de análisis	Descriptivo	Predictivo y prescriptivo
Rol del área L&D	Operativo	Estratégico y analítico
Toma de decisiones	Basada en experiencia	Basada en modelos y evidencia

Fuente: elaboración propia con base en Karimi et al. (2024); Shifa et al. (2026); Alhamad et al. (2024).

La transición hacia Learning Analytics implica además la incorporación de técnicas de machine learning y análisis multivariable. En estudios sobre predicción de rotación, algoritmos como Random Forest, Support Vector Machine y AdaBoost han demostrado capacidad para identificar variables que incrementan o reducen la probabilidad de abandono (Karimi & Viliyani, 2024). Cuando se incorporan variables de formación —como cantidad de entrenamientos, evaluaciones de desempeño post-capacitación o progresión de habilidades—, el modelo amplía su capacidad explicativa.

Mohiuddin et al. (2023) profundizan este enfoque al integrar técnicas de Explainable AI (XAI), como el uso de valores SHAP, que permiten interpretar qué variables influyen con mayor peso en la predicción de rotación. Desde una perspectiva profesional, esto habilita decisiones más precisas: si el modelo indica que la ausencia de oportunidades de desarrollo incrementa el riesgo de salida, el área de talento puede intervenir antes de que la rotación se materialice.

La lógica predictiva se sostiene sobre tres componentes técnicos:

- 1 Identificación de variables relevantes.
- 2 Entrenamiento de modelos supervisados.
- 3 Validación y análisis de importancia de variables.

Tabla 2. Variables de aprendizaje como predictores en modelos de retención y desempeño

Variable formativa	Posible impacto	Aplicación
--------------------	-----------------	------------

	analítico	profesional
Cantidad de capacitaciones anuales	Reducción de probabilidad de rotación	Diseño de planes personalizados
Participación en programas de liderazgo	Incremento de desempeño futuro	Identificación de <i>high potentials</i>
Evaluaciones post-training	Mejora en métricas de productividad	Ajuste de contenidos formativos
Tiempo desde última capacitación	Aumento de riesgo de desvinculación	Activación de alertas tempranas

Fuente: elaboración propia con base en Mohiuddin et al. (2023); Alhamad et al. (2024).

En la práctica organizacional, esta integración transforma el rol del área de L&D. El profesional deja de centrarse exclusivamente en la ejecución y comienza a:

- Construir bases de datos integradas.
- Analizar correlaciones entre formación y resultados de negocio.

- Implementar modelos predictivos para anticipar comportamientos.
- Diseñar intervenciones basadas en evidencia.

Shifa et al. (2026) sostienen que las organizaciones que adoptan capacidades analíticas fortalecen la planificación estratégica de la fuerza laboral. En ese contexto, el aprendizaje se convierte en una variable que contribuye a la competitividad organizacional.

La evolución hacia Learning Analytics no implica simplemente incorporar tecnología, sino adoptar una racionalidad analítica. El aprendizaje se integra al ciclo del colaborador como un elemento medible, explicable y modelizable. Esta perspectiva permite comprender la formación como una inversión estratégica cuya efectividad puede evaluarse con herramientas estadísticas y modelos predictivos.

De este modo, el área de L&D se posiciona como actor central dentro del ecosistema de People Analytics, articulando desarrollo, engagement, desempeño y retención en un marco de toma de decisiones basada en datos.

**Engagement, retención y desempeño:
variables críticas en modelos de People
Analytics**

En el análisis contemporáneo del ciclo del colaborador, el engagement deja de considerarse una categoría abstracta para convertirse en una variable modelizable. Desde la perspectiva del People Analytics, el compromiso organizacional se traduce en indicadores observables que permiten anticipar comportamientos futuros, especialmente en lo que respecta a retención y desempeño. Esta transformación responde a una necesidad concreta: las organizaciones requieren comprender qué variables explican la permanencia y la productividad de sus equipos.

Los estudios sobre predicción de rotación muestran que la desvinculación voluntaria no ocurre de manera súbita, sino que se construye a partir de patrones detectables en los datos (Karimi & Viliyani, 2024). Variables como satisfacción laboral, evaluaciones de desempeño, oportunidades de desarrollo y relación con el liderazgo presentan asociaciones significativas con la probabilidad de abandono. En este marco, el engagement funciona como variable mediadora entre experiencia organizacional y comportamiento futuro.

Desde una perspectiva técnica, el engagement puede operacionalizarse mediante:

Resultados de encuestas de clima organizacional.

Índices de participación en programas internos.

Métricas de desempeño sostenido.

Indicadores de movilidad interna.

Interacciones en plataformas digitales corporativas.

Alhamad et al. (2024) sostienen que los modelos predictivos permiten identificar señales tempranas de descompromiso antes de que se materialice la rotación. Este enfoque desplaza la gestión reactiva hacia una intervención anticipatoria. En lugar de actuar cuando el colaborador ya ha tomado la decisión de desvincularse, el análisis predictivo habilita acciones preventivas.

Por su parte, Mohiuddin et al. (2023) integran técnicas de Explainable AI (XAI) para interpretar la influencia de variables específicas en la predicción de rotación. La aplicación de valores SHAP permite visualizar el peso relativo de factores como salario, oportunidades de promoción o carga laboral. Esta explicabilidad fortalece la toma de decisiones, ya que el área de talento puede comprender qué variables impactan con mayor intensidad en cada caso individual.

En términos organizacionales, el vínculo entre engagement, desempeño y retención se estructura en una lógica sistémica:



Mayor engagement → mayor estabilidad laboral.

- Mayor estabilidad → acumulación de conocimiento organizacional.
- Acumulación de conocimiento → mejora en desempeño colectivo.

Shifa et al. (2026) demuestran que las organizaciones que adoptan prácticas analíticas robustas logran mayor precisión en la predicción de resultados de desempeño. Esta capacidad predictiva se vincula con la integración de datos provenientes de múltiples fuentes, entre ellas formación, evaluaciones de desempeño y trayectoria profesional.

Tabla 3. Variables asociadas a engagement en modelos predictivos de retención

Variable	Tipo de indicador	Impacto en modelo predictivo
Satisfacción laboral	Encuesta cuantitativa	Predictor de permanencia
Participación en capacitación	Registro administrativo	Reducción de riesgo de rotación
Evaluación de desempeño	Métrica anual o semestral	Asociación con movilidad interna

Relación con liderazgo	Índice de clima	Influencia en intención de permanencia
Balace trabajo-vida	Encuesta específica	Predictor de compromiso sostenido

Fuente: elaboración propia con base en Karimi & Viliyani (2024); Alhamad et al. (2024); Shifa et al. (2026).

Desde el punto de vista metodológico, los modelos supervisados —como Random Forest, Support Vector Machine o XGBoost— permiten clasificar colaboradores según riesgo de rotación o probabilidad de alto desempeño. Estos algoritmos procesan múltiples variables simultáneamente y estiman probabilidades individuales.

La aplicación práctica de estos modelos implica:

Integrar bases de datos de desempeño, formación y clima.

Entrenar modelos con datos históricos.

Evaluar métricas de precisión (accuracy, recall, precision).

Generar alertas tempranas para intervención estratégica.

Karimi & Viliyani (2024) señalan que el análisis multivariable mejora la capacidad explicativa respecto de enfoques unidimensionales. Esto resulta particularmente relevante cuando se analiza el engagement, dado que se trata de un constructo multifactorial.

Asimismo, Alhamad et al. (2024) destacan que la analítica avanzada permite identificar combinaciones de variables que actúan de manera conjunta. Por ejemplo:

- Bajo desempeño + ausencia de capacitación reciente + baja satisfacción → alto riesgo de rotación.
- Alto desempeño + participación en liderazgo + evaluación positiva → probabilidad de promoción.

Esta lógica combinatoria amplía la capacidad de intervención estratégica.

Tabla 4. Relación entre engagement, desempeño y resultados organizacionales

Nivel de <i>engagement</i>	Efecto en desempeño	Impacto organizacional
Alto	Productividad sostenida	Reducción de rotación

Medio	Desempeño variable	Riesgo moderado
Bajo	Disminución de rendimiento	Incremento de probabilidad de abandono

Fuente: elaboración propia con base en Mohiuddin et al. (2023); Shifa et al. (2026).

En el ejercicio profesional, esta integración analítica transforma el rol del área de talento. La gestión del engagement ya no se limita a la implementación de encuestas anuales, sino que se orienta hacia:

- Monitoreo continuo de indicadores.
- Segmentación de colaboradores según riesgo.
- Diseño de intervenciones diferenciadas.
- Evaluación de impacto de acciones correctivas.

La analítica del engagement permite comprender que la retención constituye el resultado de múltiples interacciones organizacionales. La capacidad de modelizar estas interacciones

fortalece la planificación estratégica y posiciona al área de recursos humanos como socio analítico del negocio.

En síntesis, la articulación entre engagement, desempeño y retención configura un núcleo central dentro del People Analytics. Comprender estas relaciones desde modelos predictivos habilita intervenciones basadas en evidencia y reduce la incertidumbre en la toma de decisiones.

Modelos predictivos en RR. HH.: machine learning, turnover y toma de decisiones basada en datos

La consolidación del People Analytics como enfoque estratégico se materializa en la aplicación de modelos predictivos orientados a anticipar comportamientos en el ciclo del colaborador. Entre estos comportamientos, el turnover constituye uno de los fenómenos más estudiados, dado su impacto financiero, operativo y cultural en las organizaciones.

Los modelos predictivos permiten estimar la probabilidad de que un colaborador abandone la organización a partir de un conjunto

de variables históricas. Karimi & Viliyani (2024) aplican algoritmos supervisados como Random Forest, Support Vector Machine y AdaBoost para clasificar empleados según riesgo de rotación. Estos modelos procesan múltiples variables simultáneamente y detectan patrones no lineales que exceden el análisis descriptivo tradicional.

Desde el punto de vista técnico, el **proceso de modelización incluye:**

- Selección de variables relevantes.
- Limpieza y normalización de datos.
- División en conjuntos de entrenamiento y prueba.
- Evaluación de métricas como *accuracy*, *precision* y *recall*.
- Validación cruzada para evitar *overfitting*.

Este enfoque permite transformar datos históricos en estimaciones probabilísticas futuras. Por ejemplo, si un modelo identifica que bajo desempeño, escasa capacitación y baja satisfacción salarial se asocian consistentemente con

rotación, puede clasificar nuevos casos en función de esa estructura predictiva.

Mohiuddin et al. (2023) amplían este enfoque mediante la incorporación de técnicas de Explainable AI (XAI), particularmente valores SHAP. Esta metodología permite interpretar el peso específico de cada variable en la predicción individual. En términos profesionales, esto significa que la decisión de intervenir no se basa únicamente en una probabilidad numérica, sino en la comprensión de los factores que la explican.

El uso de modelos predictivos en recursos humanos cumple tres funciones estratégicas:

Identificación temprana de riesgo.

Segmentación de población laboral.

Priorización de intervenciones.

Shifa et al. (2026) sostienen que la integración analítica fortalece la planificación estratégica de la fuerza laboral al reducir la incertidumbre en decisiones críticas. En esta línea, el aprendizaje organizacional —analizado en subtemas anteriores— puede incorporarse como variable explicativa dentro de los modelos.

Alhamad et al. (2024) enfatizan que la predicción del turnover adquiere sentido cuando se vincula con estrategias de engagement. El modelo no se orienta únicamente a identificar riesgo, sino a habilitar acciones correctivas que modifiquen la trayectoria del colaborador.

Tabla 5. Algoritmos utilizados en predicción de turnover y sus aplicaciones

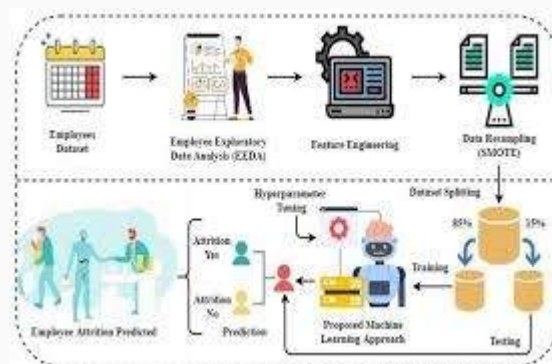
Algoritmo	Característica principal	Aplicación en RR. HH.
<i>Random Forest</i>	Modelo de árboles múltiples que reduce varianza	Identificación de variables críticas en rotación
<i>Support Vector Machine</i>	Clasificación mediante hiperplanos óptimos	Segmentación de empleados por riesgo
<i>AdaBoost</i>	Método de ensamblado que mejora clasificadores débiles	Mejora de precisión en predicción
<i>XGBoost</i>	Optimización por gradiente eficiente	Modelos de alta precisión para grandes volúmenes de datos

Fuente: elaboración propia con base en Karimi & Viliyani (2024); Mohiuddin et al. (2023).

La implementación organizacional de estos modelos requiere infraestructura tecnológica, calidad de datos y competencias analíticas. Sin embargo, el impacto estratégico radica en la transición desde una gestión reactiva hacia una gestión anticipatoria.

Desde una lógica profesional, el flujo operativo de un modelo predictivo puede representarse de la siguiente manera:

Figura 1. Flujo de modelización predictiva en People Analytics



Fuente: elaboración propia a partir de Karimi & Viliyani (2024); Mohiuddin et al. (2023).

Este flujo representa una secuencia lógica:

1. Recolección de datos (desempeño, formación, clima, compensación).
2. Preprocesamiento y selección de variables.
3. Entrenamiento del modelo.
4. Generación de probabilidades individuales.
5. Interpretación mediante XAI.

El paso final resulta determinante. El modelo predictivo adquiere valor cuando orienta decisiones concretas, tales como:

- Activar planes de desarrollo personalizados.
- Ajustar esquemas de compensación.
- Rediseñar carga laboral.
- Fortalecer liderazgo en áreas críticas.

La toma de decisiones basada en datos no reemplaza el criterio profesional, sino que lo complementa con evidencia cuantitativa. El análisis predictivo reduce la ambigüedad y permite asignar recursos de manera más eficiente.

En síntesis, los modelos de machine learning aplicados al turnover consolidan la dimensión estratégica del People Analytics. Su integración con variables de aprendizaje y engagement fortalece la comprensión integral del ciclo del

colaborador y habilita intervenciones anticipatorias que impactan en la estabilidad organizacional.

CONTINUAR

2. Medición del impacto del aprendizaje: modelo Kirkpatrick y analítica avanzada

Introducción

En la unidad anterior analizamos cómo el aprendizaje puede integrarse a los modelos predictivos de People Analytics, especialmente en relación con engagement, desempeño y turnover. Observamos que los datos formativos constituyen insumos estratégicos cuando se incorporan a algoritmos de machine learning y sistemas de soporte a la decisión. Sin embargo, surge un interrogante central para la práctica profesional: ¿cómo se mide el impacto real del aprendizaje en los resultados organizacionales?

La evaluación de la formación ha ocupado históricamente un lugar operativo dentro de las organizaciones. No obstante, en entornos competitivos y orientados a resultados, la medición del impacto adquiere una dimensión estratégica. La literatura en HR Analytics demuestra que las organizaciones que integran capacidades analíticas en sus procesos de talento logran mayor precisión en la predicción de desempeño y retención (Shifa et al.,

2026). En este marco, la evaluación del aprendizaje deja de limitarse a la satisfacción inmediata y se orienta hacia resultados medibles.

Estudios sobre predicción de rotación evidencian que variables asociadas al desarrollo profesional presentan correlaciones significativas con la permanencia organizacional (Karimi & Viliyani, 2024; Alhamad et al., 2024). Este hallazgo invita a profundizar: ¿cómo se conecta una intervención formativa con cambios conductuales sostenidos? ¿Qué evidencia permite afirmar que una acción de Learning & Development genera impacto en el negocio?

El modelo Kirkpatrick ofrece un marco estructurado para abordar estas preguntas, al proponer niveles progresivos de evaluación que vinculan reacción, aprendizaje, comportamiento y resultados. No obstante, su aplicación contemporánea requiere integración con herramientas analíticas avanzadas y enfoques de predictive analytics que permitan cuantificar relaciones causales y anticipar efectos futuros.

En esta unidad abordaremos la evaluación del aprendizaje desde una perspectiva analítica, integrando el modelo Kirkpatrick con metodologías de modelización y sistemas de decisión basados en datos. El objetivo consiste en comprender cómo la medición del impacto formativo puede articularse con estrategias de

engagement, retención y desempeño dentro del ciclo del colaborador.

El modelo Kirkpatrick en clave analítica: de la reacción al impacto organizacional

La evaluación del aprendizaje ha evolucionado desde mediciones centradas en la satisfacción inmediata hacia modelos orientados a resultados organizacionales. El modelo Kirkpatrick constituye uno de los marcos más utilizados para estructurar este proceso, al proponer cuatro niveles progresivos de evaluación: reacción, aprendizaje, comportamiento y resultados. En su formulación original, el modelo ofrecía una secuencia lógica para analizar el efecto de una intervención formativa. En la actualidad, su integración con herramientas de People Analytics amplía su capacidad explicativa.

En contextos organizacionales orientados a la evidencia, la pregunta profesional ya no se limita a «¿gustó la capacitación?», sino que se reformula en términos analíticos: ¿qué efecto medible produjo la intervención en variables estratégicas del negocio? Esta transición implica incorporar métricas objetivas, análisis longitudinales y modelos predictivos.

Los estudios sobre predicción de turnover y desempeño demuestran que las variables vinculadas al desarrollo profesional presentan asociaciones significativas con permanencia organizacional y productividad (Karimi & Viliyani, 2024; Alhamad et al., 2024). En este marco, el modelo Kirkpatrick puede reinterpretarse como una estructura escalonada de generación de datos.

Desde una perspectiva técnica, cada **nivel del modelo** produce información diferente:

Nivel 1: —

indicadores de percepción inmediata.

Nivel 2: —

evidencia de adquisición de conocimientos o habilidades.

Nivel 3: —

cambios conductuales observables en el puesto de trabajo.

Nivel 4: —

impacto en resultados organizacionales medibles.

La integración analítica permite conectar estos niveles con variables cuantificables dentro de sistemas de HR Analytics.

Tabla 6. Niveles del modelo Kirkpatrick y su traducción analítica

Nivel	Enfoque tradicional	Enfoque en <i>People Analytics</i>
Reacción	Encuesta de satisfacción	Índice de experiencia formativa correlacionado con <i>engagement</i>
Aprendizaje	Prueba de conocimientos	Medición comparativa pre y post capacitación

Comportamiento	Observación cualitativa	Indicadores de desempeño longitudinal
Resultados	Impacto general	Relación estadística con retención, productividad y movilidad

Fuente: elaboración propia con base en Karimi & Viliyani (2024); Shifa et al. (2026).

El salto cualitativo ocurre en la conexión entre el Nivel 3 y el Nivel 4. Mohiuddin et al. (2023) demuestran que los modelos explicables mediante técnicas de Explainable AI permiten identificar qué variables de aprendizaje inciden en predicciones de permanencia o desempeño. Esto significa que el Nivel 4 puede cuantificarse a través de análisis multivariable.

En la práctica profesional, la operacionalización del modelo implica integrar datos de múltiples fuentes:

- Plataforma de gestión de aprendizaje (LMS).
- Evaluaciones de desempeño periódicas.
- Indicadores de productividad.
- Registros de promoción o movilidad interna.



Este enfoque transforma la evaluación en un proceso continuo y basado en evidencia.

Tabla 7. Indicadores asociados a cada nivel del modelo en entornos analíticos

Nivel Kirkpatrick	Indicadores cuantificables	Aplicación estratégica
Reacción	Índice de satisfacción promedio	Ajuste de diseño instruccional
Aprendizaje	Diferencia de puntaje pre-post	Validación de efectividad técnica
Comportamiento	Variación en métricas de desempeño	Seguimiento de transferencia
Resultados	Reducción de rotación, aumento de productividad	Justificación de inversión en L&D

Fuente: elaboración propia con base en Alhamad et al. (2024); Shifa et al. (2026).

La integración analítica del modelo Kirkpatrick fortalece la toma de decisiones basada en datos. El área de Learning & Development puede:

- Establecer métricas claras antes de implementar la intervención.
- Definir variables dependientes e independientes.
- Aplicar análisis correlacional y modelos predictivos.
- Evaluar impacto longitudinal.

Desde una lógica estratégica, la evaluación del aprendizaje se vincula con resultados de negocio cuando se incorporan herramientas de modelización. Shifa et al. (2026) sostienen que las organizaciones que adoptan capacidades analíticas avanzadas logran mayor alineación entre gestión del talento y objetivos estratégicos.

Asimismo, el modelo Kirkpatrick adquiere mayor robustez cuando se complementa con análisis estadísticos que permitan estimar la magnitud del impacto. En este sentido, la evaluación deja de ser descriptiva para convertirse en analítica y predictiva.

En síntesis, reinterpretar el modelo Kirkpatrick desde el People Analytics implica transformar una estructura conceptual clásica en un sistema de medición cuantificable, integrado y orientado a resultados organizacionales. Esta perspectiva habilita decisiones fundamentadas y posiciona la evaluación del aprendizaje como componente estratégico dentro del ciclo del colaborador.

Integración de HR Analytics y Learning & Development: dashboards, XAI y sistemas de soporte a decisiones

La medición del impacto del aprendizaje adquiere verdadera dimensión estratégica cuando se integra en sistemas analíticos capaces de transformar datos en decisiones. En este sentido, la articulación entre HR Analytics y Learning & Development (L&D) permite que la evaluación deje de ser un ejercicio aislado para convertirse en un componente del ecosistema de gestión del talento.

En entornos organizacionales complejos, la información relacionada con capacitación, desempeño, retención y movilidad interna se encuentra distribuida en múltiples sistemas. La integración analítica requiere consolidar estas fuentes en plataformas unificadas que permitan visualizar patrones y generar alertas tempranas. Aquí adquieren relevancia los dashboards analíticos y los sistemas de soporte a decisiones.

Mohiuddin et al. (2023) describen la construcción de un Decision Support System basado en modelos predictivos y técnicas de Explainable AI (XAI). Este tipo de sistema permite no solo estimar probabilidades de turnover, sino también interpretar los factores que inciden en cada predicción individual. Desde la práctica

profesional, esta capacidad de explicabilidad resulta determinante para diseñar intervenciones formativas específicas.

La integración operativa se estructura en tres dimensiones:

1

Consolidación de datos formativos, de desempeño y clima organizacional.

2

Aplicación de modelos de machine learning entrenados con datos históricos.

3

Visualización de resultados en entornos interactivos para toma de decisiones.

Karimi & Viliyani (2024) evidencian que los modelos supervisados mejoran su capacidad predictiva cuando incorporan variables vinculadas con desarrollo profesional. Esto implica que los registros de capacitación no deben analizarse de forma independiente, sino integrarse dentro del modelo general del ciclo del colaborador.

Desde una perspectiva estratégica, los dashboards permiten monitorear:



Participación en programas de formación.

Evolución del desempeño post-capacitación.

- Relación entre inversión formativa y retención.
- Segmentación de colaboradores según riesgo o potencial.

Shifa et al. (2026) sostienen que la adopción de capacidades analíticas fortalece la alineación entre talento y objetivos organizacionales. En esta línea, el área de L&D se posiciona como generadora de datos estratégicos, no únicamente como ejecutora de programas.

La utilización de técnicas de XAI aporta una ventaja adicional. Cuando el sistema identifica que la ausencia de oportunidades de desarrollo incrementa el riesgo de desvinculación, el área puede intervenir con acciones específicas, tales como planes de carrera, mentorías o capacitación técnica. Esta lógica transforma la evaluación en intervención basada en evidencia.

Alhamad et al. (2024) destacan que la analítica avanzada permite identificar señales tempranas de descompromiso. La combinación entre indicadores formativos y métricas de desempeño fortalece la capacidad de anticipación organizacional.

Tabla 8. Componentes de integración entre HR Analytics y L&D

Componente	Función analítica	Impacto en la toma de decisiones
Base de datos integrada	Consolidación de información del ciclo del colaborador	Visión sistémica del talento
Modelos de <i>machine learning</i>	Predicción de desempeño y <i>turnover</i>	Identificación de riesgos y oportunidades
<i>Dashboards</i> interactivos	Visualización de métricas clave	Monitoreo continuo y segmentación
Técnicas de <i>XAI</i>	Interpretación de variables influyentes	Intervenciones personalizadas
Sistema de soporte a decisiones	Integración de análisis y acción	Planificación estratégica basada en datos

Fuente: elaboración propia con base en Mohiuddin et al. (2023); Karimi & Viliyani (2024); Shifa et al. (2026).

En el ejercicio profesional, la integración entre HR Analytics y L&D redefine el rol del área de talento. El proceso formativo se vincula con indicadores de negocio y se evalúa a través de métricas

cuantificables. Esta articulación fortalece la legitimidad estratégica de la función y permite justificar inversiones en capacitación mediante evidencia empírica.

La gestión basada en datos no reemplaza el criterio organizacional, sino que lo complementa con análisis estructurado. La incorporación de dashboards, modelos predictivos y técnicas de explicabilidad posiciona la evaluación del aprendizaje como componente central del People Analytics aplicado al ciclo del colaborador.

De la predicción a la intervención: estrategias basadas en datos para mejorar engagement y performance

La consolidación de la analítica del aprendizaje no culmina en la medición ni en la predicción. El verdadero valor estratégico del People Analytics se materializa cuando los resultados de los modelos se traducen en intervenciones concretas sobre el ciclo del colaborador. En este punto, la organización transita desde la estimación probabilística hacia la acción deliberada.

Los modelos predictivos de turnover y desempeño permiten identificar colaboradores en riesgo o con alto potencial. Sin embargo, la gestión profesional exige diseñar respuestas específicas en función de los factores detectados. Mohiuddin et

al. (2023) demuestran que la incorporación de técnicas de Explainable AI (XAI) facilita esta transición, ya que permite comprender qué variables inciden en cada predicción individual. La interpretación de valores SHAP, por ejemplo, orienta decisiones diferenciadas.

Desde una lógica operativa, el proceso de intervención basada en datos se estructura en cuatro momentos:

- 1 Identificación de patrones mediante modelos de machine learning.
- 2 Interpretación de variables explicativas.
- 3 Diseño de acciones específicas.
- 4 Evaluación longitudinal de impacto.

Karimi & Viliyani (2024) sostienen que los modelos supervisados mejoran su utilidad organizacional cuando se integran en procesos de retroalimentación continua. Esto implica que la intervención también genera nuevos datos que alimentan el sistema analítico.

La relación entre aprendizaje, engagement y desempeño se fortalece cuando la intervención responde a evidencia cuantitativa. Shifa et al. (2026) subrayan que las organizaciones

con capacidades analíticas avanzadas logran mayor alineación entre gestión del talento y objetivos estratégicos. En este sentido, la analítica deja de ser una herramienta diagnóstica para convertirse en un instrumento de planificación estratégica.

Las intervenciones pueden estructurarse en distintos niveles:

Individual: —

planes de desarrollo personalizados, mentorías, reconfiguración de objetivos.

Grupal: —

rediseño de dinámicas de liderazgo, fortalecimiento de equipos críticos.

Organizacional: —

ajustes en políticas de carrera, compensación y cultura.

Alhamad et al. (2024) destacan que la identificación temprana de señales de descompromiso permite activar estrategias de retención antes de que la desvinculación se materialice. Esta

capacidad anticipatoria constituye uno de los principales aportes del People Analytics aplicado a L&D.

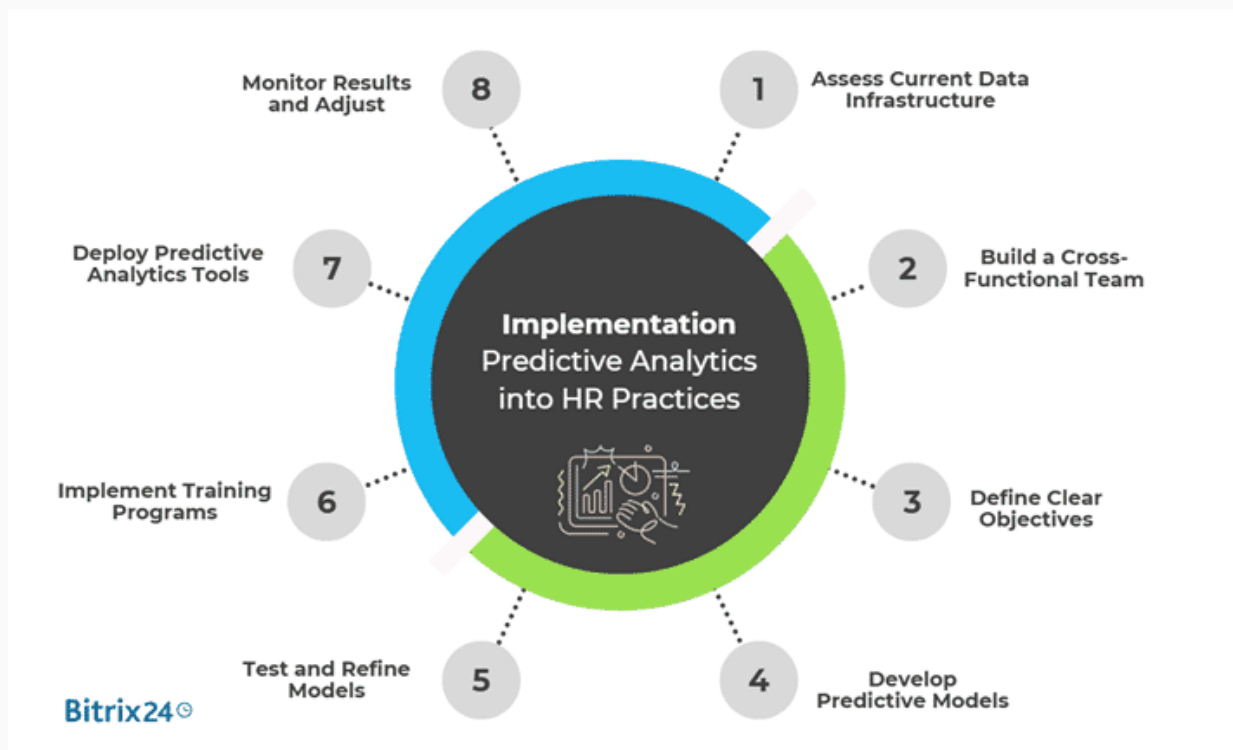
Tabla 9. Intervenciones basadas en datos según factores predictivos detectados

Factor identificado por el modelo	Tipo de intervención	Objetivo estratégico
Baja participación en formación	Plan de capacitación personalizado	Incrementar <i>engagement</i>
Estancamiento en desempeño	Programa de mentoría	Mejorar <i>performance</i>
Escasas oportunidades de promoción	Plan de carrera estructurado	Reducir riesgo de <i>turnover</i>
Sobrecarga laboral detectada	Redistribución de tareas	Sostener productividad
Alta potencialidad identificada	Programa de liderazgo	Desarrollo de talento clave

Fuente: elaboración propia con base en Mohiuddin et al. (2023); Alhamad et al. (2024)

La lógica de intervención basada en datos puede representarse de la siguiente manera:

Figura 2. Ciclo de intervención estratégica basada en People Analytics



Fuente: elaboración propia a partir de Karimi & Viliyani (2024); Shifa et al. (2026).

Este ciclo evidencia una dinámica de mejora continua:

Los datos alimentan el modelo.


- El modelo genera predicciones.
- Las predicciones orientan intervenciones.
- Las intervenciones producen nuevos datos.

La integración entre analítica y acción fortalece la gestión estratégica del talento. El área de L&D asume un rol activo en la transformación organizacional al diseñar respuestas basadas en evidencia cuantitativa.

En síntesis, la transición desde la predicción hacia la intervención consolida el enfoque del People Analytics aplicado al aprendizaje. La organización que adopta esta lógica reduce la incertidumbre, optimiza recursos y fortalece la sostenibilidad de su capital humano. La evaluación del impacto deja de ser una instancia posterior para convertirse en parte constitutiva de la estrategia organizacional.

CONTINUAR

Referencias



Alhamad, A. M., Hilan, I. M., Alghowl, I. S. M., Eljaiebi, M. I., & Buraqan, K. K. M. (2024). *Predicting employee turnover through advanced HR analytics: Implications for engagement strategies*. *Educational Administration: Theory and Practice*, 30(5), 964–972. <https://doi.org/10.53555/kuey.v30i5.2995>

Karimi, M., & Seyedkazem Viliyani, K. (2024). *Employee turnover analysis using machine learning algorithms*.

Mohiuddin, K., Alam, M. A., Alam, M. M., Welke, P., Martin, M., Lehmann, J., & Vahdati, S. (2023). *Retention is all you need*. In *Proceedings of the 32nd ACM International Conference on Information and Knowledge Management (CIKM '23)*. <https://doi.org/10.1145/3583780.3615497>

Shifa, S., Abbas, S. J., & Muhammad, K. K. (2026). *HR analytic as a strategic tool: Predicting talent retention and performance*. *The Critical Review of Social Sciences Studies*, 4(1), 387–395.

CONTINUAR