

Módulo 2. Gobierno y calidad de la información

☰ Introducción

☰ 1. Macrodominios y arquitectura del dato en RR. HH.

☰ 2. Employee data journey: puntos clave y procesos críticos

☰ 3. Calidad del dato: integridad, consistencia, completitud y validación

☰ 4. Modelos de datos e indicadores según especialidades (reclutamiento, DO, compensaciones, desempeño)

☰ Referencias

Introducción

El desarrollo de *people analytics* exige mucho más que la disponibilidad de datos o el uso de herramientas tecnológicas avanzadas. Para que la información del talento humano se transforme en conocimiento accionable y aporte valor real a la toma de decisiones, es indispensable contar con fundamentos sólidos de gobierno y calidad de la información. Este módulo se sitúa precisamente en ese punto crítico del proceso formativo: establecer las bases conceptuales, metodológicas y operativas que permiten gestionar los datos de RR. HH. de manera confiable, consistente y alineada con los objetivos estratégicos de la organización.

A lo largo de esta lectura se abordan los principios que rigen la organización del dato de personas, entendiendo que los datos no son neutros ni aislados, sino que forman parte de un ecosistema que atraviesa sistemas, procesos, áreas y momentos clave del ciclo de vida del colaborador. En coherencia con los propósitos de

la materia, el módulo pone el foco en cómo estructurar, integrar y gobernar la información para que pueda ser usada de forma ética, transparente y efectiva en contextos analíticos cada vez más complejos.

El primer eje de la lectura se centra en los macrodominios y la arquitectura del dato en RR. HH., lo que proporciona un marco para comprender cómo se organizan y relacionan las distintas fuentes de información del talento. A partir de allí, se profundiza en el *employee data journey*, analizando los puntos de captura, transformación y uso del dato, así como los procesos críticos que impactan directamente en su calidad. Este recorrido permite visualizar al dato como un activo dinámico, cuya trazabilidad y coherencia son fundamentales para sostener análisis confiables.

Posteriormente, la lectura aborda la calidad del dato desde una perspectiva aplicada, desarrollando dimensiones clave como la integridad, la consistencia, la completitud y la validación. Estas dimensiones se presentan no solo como criterios técnicos, sino como responsabilidades organizacionales que requieren roles, reglas y decisiones claras. Finalmente, se analizan los modelos de datos e indicadores según especialidades de RR. HH., lo cual conecta la arquitectura y la calidad de la información con las necesidades específicas de áreas como reclutamiento, desarrollo organizacional, compensaciones, desempeño y aprendizaje.

En conjunto, esta lectura busca fortalecer en ti las competencias necesarias para diseñar y sostener entornos de información robustos, que habiliten proyectos de people analytics alineados con el negocio y basados en evidencia. El dominio del gobierno y la calidad de la información no es un complemento del análisis, sino su condición de posibilidad.

CONTINUAR

1. Macrodominios y arquitectura del dato en RR. HH.

Comprender los macrodominios y la arquitectura del dato en RR. HH. es un paso imprescindible para avanzar desde una gestión operativa de la información hacia un enfoque estratégico basado en evidencia. En el contexto de *people analytics*, los datos no pueden concebirse como registros aislados ni como simples subproductos de los sistemas transaccionales. Por el contrario, constituyen un activo organizacional que debe ser estructurado, gobernado y alineado con los objetivos del negocio. Este subtema aborda precisamente cómo organizar ese activo, lo que establece una base sólida que permita análisis confiables, comparables y sostenibles en el tiempo.

Los macrodominios del dato representan grandes agrupaciones lógicas que organizan la información de personas según su naturaleza y su relación con los procesos de RR. HH. Su finalidad es reducir la complejidad inherente a la gestión del dato, lo que ofrece una visión estructurada que facilite tanto la administración

como el análisis. Hablar de macrodominios implica responder a preguntas clave como «qué datos existen», «a qué procesos del ciclo del colaborador pertenecen» y «cómo se relacionan entre sí». Desde esta perspectiva, los macrodominios no son únicamente una clasificación conceptual, sino una herramienta de gobierno que orienta decisiones técnicas, analíticas y organizacionales.

En la práctica, los macrodominios suelen organizarse en torno a grandes momentos del ciclo de vida del colaborador. Uno de los más relevantes es el dominio de datos maestros de personas, que incluye información relativamente estable como identificadores, datos demográficos, posición organizacional, dependencia jerárquica y condiciones contractuales. Este dominio funciona como columna vertebral del ecosistema de datos de RR. HH., dado que actúa como punto de referencia para el resto de los dominios. Una arquitectura deficiente en los datos maestros genera inconsistencias que se propagan a todos los análisis posteriores, afectando indicadores, comparaciones y conclusiones.

Otro macrodominio central es el de reclutamiento y selección, que concentra información sobre vacantes, candidatos, fuentes de atracción, procesos de evaluación, tiempos y resultados de contratación. Este dominio no solo es relevante para medir la eficiencia del proceso, sino también para conectar decisiones de

entrada con resultados posteriores en desempeño, rotación o desarrollo. Cuando los macrodominios se definen de forma aislada, se pierde la posibilidad de construir este tipo de análisis longitudinales. Por este motivo, uno de los principios clave del gobierno del dato es reconocer que los macrodominios son distintos, pero no independientes.

El dominio de desempeño y gestión del talento reúne evaluaciones, objetivos, *feedback*, potencial y resultados individuales o colectivos. Su correcta arquitectura exige especial atención, debido a que suele integrar información cualitativa y cuantitativa, escalas de evaluación, periodos temporales y criterios que pueden variar entre áreas o ciclos. Si estos elementos no se estandarizan dentro de una arquitectura clara, el análisis se vuelve frágil y altamente dependiente del contexto en el que se generó el dato. Aquí se hace evidente cómo la arquitectura del dato condiciona directamente la capacidad analítica de la organización.

Asimismo, los macrodominios vinculados con compensaciones y beneficios concentran datos sensibles relacionados con salarios, incentivos, estructuras retributivas y equidad interna. Desde una perspectiva de arquitectura, estos datos requieren no solo coherencia técnica, sino también fuertes criterios de gobernanza, seguridad y control de accesos. La forma en que este dominio se integra con los de desempeño, rol y antigüedad impacta

directamente en análisis críticos como brechas salariales, políticas de incentivos o simulaciones de escenarios.

El dominio de aprendizaje y desarrollo, por su parte, incorpora información sobre formación, competencias, planes de carrera y experiencias de aprendizaje. Su arquitectura suele ser especialmente fragmentada, dado que combina datos provenientes de plataformas internas, proveedores externos y registros manuales. Diseñar este macrodominio de manera integrada es fundamental para poder analizar la relación entre inversión en aprendizaje, desarrollo de capacidades y resultados organizacionales. Sin una arquitectura clara, estos vínculos quedan ocultos o se vuelven imposibles de medir.

La arquitectura del dato en RR. HH. es el marco que define cómo se estructuran, almacenan, integran y relacionan los datos de

todos estos macrodominios. No se trata únicamente de una decisión tecnológica, sino de una construcción socio-técnica que refleja prioridades organizacionales, modelos de gestión y niveles de madurez analítica. Una arquitectura bien diseñada permite que los datos fluyan desde los sistemas transaccionales hacia entornos analíticos y que conserven su significado, su trazabilidad y su calidad.

En este punto, resulta clave distinguir entre arquitectura operativa y arquitectura analítica. La primera responde a las necesidades del día a día y se centra en la eficiencia de los procesos y en el registro de eventos. La segunda, en cambio, está orientada al análisis, la integración histórica y la generación de indicadores. Muchas organizaciones intentan hacer análisis avanzados sobre arquitecturas pensadas únicamente para la operación, lo que genera fricciones, inconsistencias y sobrecarga de trabajo manual. Comprender esta diferencia es esencial para avanzar hacia People Analytics de manera sostenible.

Un principio central en el diseño de la arquitectura del dato es la estandarización. Definir estructuras comunes, catálogos de datos, definiciones compartidas y reglas de integración permite que los macrodominios dialoguen entre sí. Esta estandarización no implica rigidez absoluta, sino acuerdos mínimos que garanticen coherencia. Conceptos como «empleado», «posición», «desempeño» o «rotación» deben tener definiciones claras y

consensuadas, ya que de ellas dependen los análisis y las decisiones estratégicas.

Otro elemento de suma importancia es la identificación de relaciones entre dominios. La arquitectura del dato debe permitir conectar eventos a lo largo del tiempo y entre procesos. Por ejemplo, vincular datos de reclutamiento con desempeño posterior, o relacionar formación con movilidad interna. Estas relaciones no surgen de manera espontánea, sino que deben ser diseñadas explícitamente mediante claves, identificadores únicos y modelos de datos coherentes. Sin este diseño, el análisis se fragmenta y pierde profundidad.

Además, la arquitectura del dato en RR. HH. debe contemplar la evolución. Los macrodominios no son estáticos: los procesos cambian, se incorporan nuevas fuentes, surgen nuevas preguntas de negocio. Una arquitectura rígida dificulta la adaptación y termina convirtiéndose en un obstáculo para el análisis. Por esta razón, uno de los desafíos centrales del gobierno del dato es equilibrar estabilidad y flexibilidad, lo que permite crecer sin perder coherencia.



Finalmente, comprender los macrodominios y la arquitectura del dato implica asumir que las decisiones sobre datos son decisiones estratégicas. La forma en que se estructuran los datos de RR. HH. condiciona qué se puede medir, qué se puede comparar y qué se puede anticipar. Este subtema sienta las bases para los contenidos siguientes, debido a que solo a partir de una arquitectura clara es posible analizar el recorrido del dato, garantizar su calidad y construir modelos e indicadores útiles para cada especialidad. En *people analytics*, la arquitectura no es un aspecto técnico secundario, sino el cimiento sobre el cual se construye todo el valor analítico.

CONTINUAR

2. Employee data journey: puntos clave y procesos críticos

El concepto de *employee data journey* permite comprender el dato de personas como un elemento dinámico que se crea, transforma, utiliza y, en algunos casos, se archiva o elimina a lo largo del ciclo de vida del colaborador dentro de la organización. Este enfoque resulta central para el gobierno y la calidad de la información, dado que desplaza la atención desde el dato aislado hacia el recorrido completo que este realiza entre sistemas, procesos, responsables y usos analíticos. Entender este recorrido es una condición necesaria para identificar riesgos, puntos de quiebre y oportunidades de mejora en la gestión de la información de RR. HH.

El *employee data journey* comienza incluso antes de que exista formalmente un vínculo laboral. Desde el primer contacto de una persona con la organización, dado que se generan datos que formarán parte del ecosistema de información de RR. HH. Estos datos iniciales, asociados al reclutamiento y la selección, suelen

provenir de múltiples fuentes, como plataformas de empleo, formularios, redes profesionales o procesos internos de referencia. En esta etapa temprana se definen muchos de los problemas estructurales que luego impactarán en la calidad del dato, como duplicaciones, campos incompletos o criterios poco claros de captura.

Uno de los primeros puntos clave del recorrido del dato es la captura de información. Capturar datos no es un acto neutral ni automático: implica decisiones sobre qué se solicita, cómo se solicita, quién es responsable y con qué nivel de validación. Cuando la captura se diseña sin criterios claros, el dato nace con defectos que se arrastran a lo largo de todo su ciclo de vida. Por ejemplo, campos abiertos sin estandarización, definiciones ambiguas o falta de obligatoriedad generan información difícil de integrar y analizar posteriormente. En este sentido, el gobierno del dato comienza en el momento mismo en que el dato se crea.

Tras la captura inicial, el dato suele atravesar un proceso de registro y almacenamiento en uno o varios sistemas de RR. HH. Aquí se produce una transición crítica: el dato pasa de ser información puntual a formar parte de un repositorio estructurado. En muchas organizaciones, este paso implica la migración desde herramientas de reclutamiento hacia sistemas centrales como HRIS o HRMS. Cada transferencia introduce riesgos de pérdida de información, inconsistencias o

transformaciones no documentadas. El *employee data journey* permite visualizar estas transiciones y evaluar si existen controles adecuados para preservar la integridad del dato.

Una vez registrado, el dato comienza a usarse con fines operativos. En esta fase, el *employee data journey* se vincula estrechamente con los procesos diarios de RR. HH., como la administración de legajos, la gestión de nómina, el control de ausentismo o la asignación de roles. Aquí se generan nuevos datos derivados, se actualizan atributos existentes y se producen eventos que enriquecen el historial del colaborador. Este momento del recorrido es especialmente sensible, debido a que combina alta frecuencia de uso con múltiples actores involucrados, lo que aumenta el riesgo de errores y divergencias.

Otro punto clave del recorrido del dato es la integración entre sistemas. En la práctica, la información de personas rara vez reside en un único sistema. Plataformas de desempeño, aprendizaje, compensaciones, encuestas de clima o beneficios suelen operar de manera paralela, cada una con su propia lógica de datos. El

employee data journey permite mapear cómo un mismo atributo, como el identificador del colaborador o su posición, se replica y se transforma en distintos entornos. Cuando estas integraciones no están bien diseñadas, se generan versiones múltiples de una misma realidad, lo que afecta la confiabilidad de los análisis.

A medida que el colaborador avanza en su trayectoria dentro de la organización, el recorrido del dato se vuelve más complejo. Cambios de rol, promociones, evaluaciones de desempeño, capacitaciones y ajustes salariales agregan capas de información que deben ser correctamente contextualizadas en el tiempo. Uno de los procesos críticos del *employee data journey* es la gestión de la temporalidad. Sin una correcta definición de fechas, vigencias y periodos, el análisis longitudinal se vuelve impreciso. Saber no solo qué ocurrió, sino cuándo ocurrió, es fundamental para comprender relaciones causales y tendencias.

El *employee data journey* también incluye el uso analítico del dato. En esta etapa, la información deja de servir exclusivamente a la

operación y se convierte en insumo para indicadores, reportes, *dashboards* y modelos analíticos. Este cambio de propósito exige un nivel de calidad superior, debido a que el dato se expone a comparaciones, agregaciones e interpretaciones estratégicas. Muchos problemas de *people analytics* surgen cuando se intenta analizar datos que fueron diseñados solo para cumplir una función administrativa. El recorrido del dato permite identificar estas tensiones y anticipar ajustes necesarios en su diseño.

Un aspecto crítico en esta fase es la transformación del dato. Para que la información sea analizable, suele requerir procesos de limpieza, normalización, agregación o enriquecimiento. Cada transformación introduce el riesgo de alterar el significado original del dato si no se documenta adecuadamente. El gobierno del *employee data journey* implica definir reglas claras sobre cómo se transforman los datos, quién autoriza esos cambios y cómo se garantiza la trazabilidad entre el dato original y el dato analítico. Sin esta trazabilidad, la confianza en los resultados se ve seriamente comprometida.

La validación del dato constituye otro proceso clave a lo largo del recorrido. Validar no es solo corregir errores, sino asegurar que el dato tenga sentido en relación con el contexto organizacional. Por ejemplo, detectar combinaciones improbables, valores fuera de rango o inconsistencias entre dominios. La validación puede realizarse en distintos momentos del *employee data journey*, pero

resulta especialmente efectiva cuando se incorpora de manera preventiva, en lugar de reactiva. Integrar controles de validación tempranos reduce costos y mejora la calidad global de la información.

El *employee data journey* no termina con el análisis. También incluye la comunicación y el uso del dato para la toma de decisiones. Los resultados analíticos influyen en políticas, acciones y estrategias que, a su vez, generan nuevos datos. Este carácter circular del recorrido refuerza la idea de que el dato no es un elemento estático, sino parte de un sistema en constante retroalimentación. Comprender este ciclo completo permite diseñar mejores procesos y alinear la gestión del dato con los objetivos estratégicos de la organización.

Un proceso frecuentemente subestimado dentro del recorrido del dato es la gestión de accesos y la seguridad de la información. A lo largo del *employee data journey*, distintos actores acceden al dato con finalidades diversas. Definir quién puede ver, modificar o analizar determinada información es una decisión crítica que impacta tanto en la calidad como en la ética del uso del dato. Un acceso inadecuado puede derivar en manipulaciones indebidas, interpretaciones erróneas o vulneraciones de la privacidad. Por este motivo, el gobierno del recorrido del dato debe integrar criterios de seguridad desde el inicio.

Asimismo, el *employee data journey* contempla el cierre del ciclo de vida del dato. Cuando un colaborador deja la organización, sus datos no desaparecen automáticamente. Algunos deben conservarse por razones legales, otros pueden anonimizarse y otros eliminarse. Este proceso final suele ser uno de los menos estructurados, pero tiene un impacto directo en la calidad de los análisis históricos y en el cumplimiento normativo. Definir reglas claras para esta etapa es parte integral de una gestión madura del recorrido del dato.

Desde una perspectiva de *people analytics*, mapear el *employee data journey* permite identificar procesos críticos en los que se concentra el mayor riesgo para la calidad de la información. Estos puntos suelen coincidir con momentos de alta intervención humana, múltiples sistemas o decisiones poco formalizadas. Al mismo tiempo, el análisis del recorrido del dato revela

oportunidades para automatizar, estandarizar y mejorar procesos, lo que fortalece la confiabilidad de los datos desde su origen.

En términos de competencias, comprender el *employee data journey* implica desarrollar una mirada sistémica sobre la información de RR. HH. No se trata solo de saber analizar datos, sino de entender cómo esos datos se producen y circulan dentro de la organización. Esta comprensión habilita un diálogo más efectivo entre áreas técnicas, analíticas y de negocio, alineando expectativas y responsabilidades. Además, permite anticipar las limitaciones del dato y comunicar resultados con mayor rigor y transparencia.

En resumen, el *employee data journey* ofrece un marco integral para gestionar la información de personas de manera estratégica. Identificar sus puntos clave y procesos críticos es un paso esencial para garantizar la calidad, la coherencia y la utilidad del dato a lo largo de todo su ciclo de vida. Este enfoque no solo mejora los análisis actuales, sino que sienta las bases para una práctica de *people analytics* sostenible, ética y alineada con los objetivos organizacionales.

Figura 1. *Employee data journey*



* Modelo de 6 Fases y 24 Touchpoints desarrollado por enEvolución y Buljan & Partners

Fuente: [imagen sin título sobre employee data journey], s. f., <https://bit.ly/4qDxZ0M>.

CONTINUAR

3. Calidad del dato: integridad, consistencia, completitud y validación

La calidad del dato constituye uno de los ejes centrales del gobierno de la información en RR. HH. y una condición indispensable para el desarrollo efectivo de *people analytics*. Sin datos de calidad, cualquier análisis, por sofisticado que sea el modelo o la herramienta utilizada, corre el riesgo de producir conclusiones erróneas o poco confiables. En este caso, se aborda la calidad del dato no como un concepto abstracto o exclusivamente técnico, sino como una responsabilidad organizacional que atraviesa procesos, roles y decisiones a lo largo de todo el ciclo de vida del colaborador.

Hablar de calidad del dato implica preguntarse si la información disponible es adecuada para el propósito que se le asigna. En el contexto de RR. HH., ese propósito suele estar vinculado tanto a la gestión operativa como a la toma de decisiones estratégicas. Un mismo dato puede ser suficiente para cumplir una función administrativa básica, pero resultar insuficiente o inadecuado

para un análisis comparativo, predictivo o longitudinal. Por este motivo, la calidad no es un atributo absoluto, sino relativo al uso que se hará de la información. Este enfoque es clave para comprender por qué la calidad del dato debe gestionarse de manera deliberada y no asumirse como una consecuencia automática de los sistemas.

Entre las dimensiones más relevantes de la calidad del dato se encuentran la integridad, la consistencia, la completitud y la validación. Cada una de estas dimensiones aborda un aspecto específico del problema y, en conjunto, permiten evaluar de forma integral el estado de la información de RR. HH. Comprenderlas en profundidad es fundamental para identificar fallas, diseñar controles y establecer prioridades de mejora.

La integridad del dato se refiere a la corrección estructural y relacional de la información. Un dato íntegro es aquel que respeta las reglas definidas dentro de la arquitectura del sistema y mantiene relaciones válidas con otros datos. En RR. HH., la integridad se manifiesta, por ejemplo, cuando cada colaborador tiene un identificador único, cuando los registros de desempeño están correctamente asociados a una persona y a un periodo, o cuando las posiciones organizacionales existen antes de asignarse a un empleado. La falta de integridad suele evidenciarse en duplicaciones, registros huérfanos o vínculos incorrectos entre dominios de datos.

Los problemas de integridad no suelen ser visibles a simple vista, pero tienen un impacto profundo en los análisis. Un error en la relación entre tablas o sistemas puede alterar conteos, promedios o tasas, lo que genera indicadores que no reflejan la realidad. Por esta razón, la integridad del dato es una dimensión crítica desde el punto de vista del gobierno de la información. Garantizarla requiere definir reglas claras de modelado, claves primarias y foráneas, así como controles que eviten la creación de registros inválidos desde el origen.

La consistencia del dato hace referencia a la coherencia interna de la información cuando se compara un mismo dato o atributo en distintos contextos, momentos o sistemas. Un dato consistente es aquel que mantiene el mismo significado y valor cuando debería hacerlo. En RR. HH., los problemas de consistencia son especialmente frecuentes debido a la multiplicidad de sistemas y procesos involucrados. Por ejemplo, un colaborador puede figurar con distintas áreas, niveles o fechas de ingreso según la fuente consultada, lo que genera confusión y desconfianza en los reportes.

La inconsistencia no siempre implica que uno de los datos sea «incorrecto» en términos absolutos, sino que refleja una falta de alineación en las definiciones o en los procesos de actualización. En muchos casos, distintos sistemas responden a lógicas temporales diferentes, lo que produce desfasajes que no están

documentados. Gestionar la consistencia del dato implica acordar definiciones comunes, establecer fuentes de verdad y clarificar qué sistema prevalece para cada tipo de información. Sin este trabajo previo, el análisis se convierte en un ejercicio de conciliación permanente.

La completitud del dato se refiere al grado en que la información necesaria está efectivamente disponible. Un dato completo no es aquel que contiene «todo», sino aquel que incluye los campos requeridos para el análisis o la gestión que se desea llevar a cabo. En RR. HH., los problemas de completitud son muy habituales y suelen originarse en procesos de captura mal diseñados, falta de obligatoriedad en ciertos campos o resistencia de los usuarios a proporcionar información. Campos vacíos, valores genéricos o información desactualizada limitan significativamente el potencial analítico del dato.

La falta de completitud no afecta a todos los análisis por igual. Algunos indicadores pueden tolerar ciertos niveles de datos faltantes, mientras que otros se vuelven inviables. Por ejemplo, analizar brechas salariales requiere información completa y

precisa sobre compensaciones, rol y nivel, mientras que un análisis exploratorio de *headcount* puede realizarse con un conjunto más reducido de atributos. Comprender esta diferencia es clave para priorizar esfuerzos de mejora y evitar exigir niveles de completitud innecesarios en todos los casos.

La validación del dato atraviesa y complementa las dimensiones anteriores. Validar implica comprobar que el dato no solo cumple con reglas técnicas, sino que tiene sentido desde el punto de vista del negocio y del contexto organizacional. La validación puede incluir controles de formato, rangos permitidos, coherencia entre variables o detección de valores atípicos. En RR. HH., la validación adquiere una relevancia particular, dado que muchos datos dependen de interpretaciones humanas y de criterios que pueden variar entre áreas o momentos.

Un aspecto clave de la validación es definir en qué momento del ciclo de vida del dato se realiza. Validar solo al final del proceso, cuando el dato ya se utiliza para análisis, suele ser costoso e ineficiente. En cambio, incorporar validaciones tempranas en los puntos de captura permite prevenir errores y mejorar la calidad desde el origen. Esta lógica preventiva es uno de los principios fundamentales del gobierno del dato y requiere una estrecha colaboración entre áreas de RR. HH., tecnología y analítica.

Las cuatro dimensiones de la calidad del dato no operan de manera aislada. Un problema de integridad puede derivar en inconsistencias, la falta de completitud puede complicar la validación y una validación deficiente puede ocultar errores estructurales. Por esta razón, gestionar la calidad del dato exige una mirada integral que considere el ecosistema completo de información. En este sentido, la calidad no es solo un atributo del dato, sino un resultado de procesos bien diseñados y gobernados.

Desde una perspectiva organizacional, uno de los errores más comunes es delegar la calidad del dato exclusivamente en el área técnica o en los equipos de analítica. Si bien estos actores cumplen un rol clave, la calidad se construye principalmente en los procesos de negocio. Son las decisiones sobre qué se captura, cómo se define un concepto o cuándo se actualiza un registro las que determinan, en gran medida, el nivel de calidad alcanzado. Por este motivo, el gobierno de la calidad del dato requiere roles claros, responsabilidades compartidas y acuerdos interáreas.

La calidad del dato también tiene una dimensión cultural. Promover una cultura de datos implica que las personas comprendan el impacto de sus acciones sobre la información que generan y utilizan. Cuando los usuarios perciben el dato como un

requisito administrativo sin consecuencias, la calidad tiende a deteriorarse. En cambio, cuando existe conciencia sobre el uso analítico de la información y su impacto en decisiones reales, se fortalece el compromiso con la precisión y la completitud. Este cambio cultural es progresivo y debe ser acompañado por políticas, formación y retroalimentación.

En el contexto de *people analytics*, la calidad del dato adquiere una relevancia estratégica. Modelos predictivos, análisis comparativos y visualizaciones ejecutivas amplifican tanto los aciertos como los errores del dato subyacente. Un pequeño problema de calidad puede escalar rápidamente y afectar decisiones de alto impacto, como políticas de compensación, planes de desarrollo o estrategias de retención. Por este motivo, invertir en calidad del dato no es un lujo ni una etapa preliminar prescindible, sino una condición necesaria para la madurez analítica.

Además, la calidad del dato está estrechamente vinculada con la ética y la transparencia. Decisiones basadas en datos incompletos, inconsistentes o mal validados pueden generar sesgos, inequidades o interpretaciones erróneas que afecten a las personas. Gestionar la calidad del dato es también una forma de proteger a la organización y a sus colaboradores, asegurando

que las decisiones se basen en información confiable y contextualizada.

En síntesis, la integridad, la consistencia, la completitud y la validación conforman un marco fundamental para evaluar y gestionar la calidad del dato en RR. HH. Estas dimensiones permiten identificar debilidades, priorizar mejoras y diseñar procesos más robustos. Más allá de las herramientas o tecnologías disponibles, la calidad del dato es el resultado de decisiones conscientes y sostenidas en el tiempo. Dominar estos conceptos te permitirá no solo analizar mejor la información, sino también contribuir activamente a construir entornos de datos más confiables, éticos y alineados con los objetivos estratégicos de la organización.

CONTINUAR

4. Modelos de datos e indicadores según especialidades (reclutamiento, DO, compensaciones, desempeño)

El diseño de modelos de datos e indicadores en RR. HH. constituye el punto de encuentro entre la arquitectura de la información, la calidad del dato y las necesidades específicas del negocio. No existe un único modelo de datos válido para todos los contextos ni un conjunto universal de indicadores aplicable a cualquier organización. Por el contrario, los modelos y métricas deben construirse a partir de las particularidades de cada especialidad de RR. HH., respetando sus procesos, objetivos y decisiones clave. Este subtema aborda cómo adaptar los modelos de datos a distintas áreas funcionales, lo que garantiza coherencia, trazabilidad y valor analítico.

Un modelo de datos puede entenderse como la representación estructurada de la información necesaria para describir un fenómeno y analizarlo. En RR. HH., estos modelos organizan entidades como personas, posiciones, eventos y resultados, así

como las relaciones entre ellas. La calidad de un modelo no se mide solo por su sofisticación técnica, sino por su capacidad para responder preguntas relevantes. Un modelo bien diseñado permite construir indicadores claros, comparables y accionables; uno deficiente limita el análisis y genera interpretaciones ambiguas.

En el ámbito del reclutamiento y la selección, los modelos de datos suelen centrarse en entidades como vacantes, candidatos, procesos, fuentes de atracción y decisiones de contratación. Un aspecto clave de este modelo es la correcta identificación de eventos a lo largo del proceso, desde la apertura de una vacante hasta la incorporación efectiva. Cada evento debe contar con marcas temporales precisas, lo que permite calcular indicadores como tiempos de cobertura, tasas de conversión o eficiencia por fuente. Sin una estructura temporal clara, estos indicadores pierden sentido y se vuelven difíciles de comparar.

Los indicadores de reclutamiento adquieren valor cuando se vinculan con resultados posteriores. Para ello, el modelo de datos debe permitir relacionar al candidato contratado con su trayectoria dentro de la organización. Esta conexión habilita análisis más avanzados, como la calidad de la contratación, entendida como la relación entre decisiones de entrada y desempeño, permanencia o desarrollo futuro. Diseñar el modelo

sin esta perspectiva limita el análisis a métricas operativas y desaprovecha el potencial estratégico del dato.

En desarrollo organizacional (DO), los modelos de datos suelen ser más complejos y menos estandarizados. Esta especialidad trabaja con información relacionada con estructura organizacional, roles, competencias, clima, cultura y cambios organizativos. Muchas de estas variables son de naturaleza cualitativa o se recogen a través de instrumentos como encuestas y evaluaciones. El desafío del modelo de datos en DO consiste en integrar esta información de manera estructurada, lo cual preserva su significado y permite elaborar análisis comparativos en el tiempo.

Los indicadores en DO suelen centrarse en dimensiones como *engagement*, clima laboral, alineación cultural o efectividad organizacional. Para que estos indicadores sean útiles, el modelo de datos debe considerar niveles de agregación claros, como equipos, áreas o unidades de negocio. Además, es fundamental vincular estos resultados con variables estructurales, como

liderazgo, carga de trabajo o rotación. Sin un modelo que contemple estas relaciones, los indicadores de DO quedan aislados y pierden capacidad explicativa.

En el área de compensaciones y beneficios, los modelos de datos requieren un alto nivel de precisión y control. Aquí se trabaja con información sensible, estructurada en torno a conceptos como salario base, incentivos, beneficios, bandas salariales y elegibilidad. El modelo debe permitir analizar la compensación desde múltiples perspectivas, incluyendo equidad interna, competitividad externa y evolución en el tiempo. Para ello, es indispensable contar con definiciones claras de roles, niveles y familias de puestos, así como con históricos bien conservados.

Los indicadores de compensaciones, como brechas salariales, dispersión o posicionamiento respecto al mercado, dependen directamente de la calidad del modelo de datos subyacente. Un error en la definición de roles o en la asignación de niveles puede distorsionar por completo el análisis. Además, el modelo debe facilitar la segmentación por variables relevantes, como género, antigüedad o desempeño, siempre respetando criterios éticos y

de confidencialidad. Diseñar estos modelos exige un equilibrio entre detalle analítico y protección de la información.

En gestión del desempeño, los modelos de datos se centran en evaluaciones, objetivos, *feedback* y resultados. Uno de los principales desafíos en esta especialidad es la heterogeneidad de los instrumentos usados. Escalas, criterios y periodicidades pueden variar entre áreas o ciclos, lo que complica la comparación. El modelo de datos debe contemplar estas variaciones y ofrecer mecanismos para normalizar o contextualizar la información sin perder su significado original.

Los indicadores de desempeño, como distribución de evaluaciones, cumplimiento de objetivos o identificación de alto potencial, solo son confiables si el modelo de datos incorpora correctamente la dimensión temporal y el contexto de evaluación. Comparar resultados de distintos periodos sin considerar cambios en los criterios puede llevar a conclusiones erróneas. Por este motivo, un modelo robusto incluye metadatos que describen las condiciones bajo las cuales se generó cada dato, lo que refuerza la transparencia y la interpretabilidad del análisis.

En aprendizaje y desarrollo (L&D), los modelos de datos suelen integrar información proveniente de múltiples plataformas y proveedores. Cursos, programas, certificaciones, competencias y

experiencias de aprendizaje forman parte de un ecosistema fragmentado. El desafío consiste en unificar esta información en un modelo que permita analizar tanto la participación como el impacto del aprendizaje. Para ello, es necesario definir entidades claras, como actividades formativas, participantes y resultados esperados, así como relaciones entre ellas.

Los indicadores de L&D evolucionan desde métricas básicas de asistencia o finalización hacia análisis más sofisticados sobre transferencia al puesto, desarrollo de competencias o impacto en el desempeño. Este avance solo es posible si el modelo de datos permite conectar la información de aprendizaje con otros dominios, como desempeño o movilidad interna. Sin estas conexiones, el análisis se limita a describir actividades, pero no a evaluar su efectividad real.

Más allá de las particularidades de cada especialidad, existe un conjunto de principios comunes para el diseño de modelos de datos en RR. HH. Uno de ellos es la coherencia transversal. Aunque cada área tenga sus propias métricas, los modelos deben compartir entidades y definiciones básicas, como persona, rol o periodo. Esta coherencia permite integrar indicadores y construir una visión holística del talento. Cuando cada especialidad desarrolla sus modelos de manera aislada, se generan silos analíticos difíciles de reconciliar.

Otro principio fundamental es la orientación a la decisión. Los indicadores no deben definirse por la disponibilidad del dato, sino por las preguntas que se busca responder. Un modelo de datos bien diseñado parte de decisiones concretas y retrocede hasta identificar la información necesaria para sustentarlas. Este enfoque evita la proliferación de indicadores irrelevantes y centra el esfuerzo analítico en aquello que realmente aporta valor al negocio.

La gobernanza juega un rol central en este proceso. Definir quién es responsable de cada modelo, cómo se validan los indicadores y cómo se comunican los resultados es tan importante como el diseño técnico. Sin acuerdos claros, los modelos tienden a evolucionar de manera desordenada, perdiendo consistencia y credibilidad. La gobernanza asegura que los modelos de datos y los indicadores se mantengan alineados con los objetivos estratégicos y con las prácticas éticas de la organización.

Asimismo, los modelos de datos deben diseñarse con una visión evolutiva. Las necesidades analíticas cambian, surgen nuevas preguntas y se incorporan nuevas fuentes de información. Un modelo excesivamente rígido se vuelve rápidamente obsoleto, mientras que uno flexible permite adaptaciones sin comprometer la coherencia. Esta flexibilidad no implica falta de control, sino la capacidad de incorporar cambios de manera ordenada y documentada.

En el contexto de *people analytics*, los modelos de datos e indicadores actúan como traductores entre la complejidad del talento humano y la toma de decisiones basada en evidencia. Cada especialidad de RR. HH. aporta una perspectiva particular, pero todas dependen de modelos sólidos para transformar datos en conocimiento. Comprender estas diferencias y similitudes te permitirá diseñar análisis más pertinentes, dialogar con mayor claridad con las áreas involucradas y construir indicadores que realmente apoyen la gestión estratégica del talento.

Resumiendo, cabe destacar que los modelos de datos y los indicadores no son un fin en sí mismos, sino medios para comprender y mejorar la realidad organizacional. Adaptarlos a las

especialidades de RR. HH., manteniendo coherencia, calidad y orientación estratégica, es uno de los desafíos centrales del gobierno de la información. Dominar este enfoque te posiciona no solo como analista, sino como un actor clave en la construcción de decisiones más informadas, responsables y alineadas con los objetivos de la organización.

CONTINUAR

Referencias

[Imagen sin título sobre *employee data journey*]. (s. f.).

<https://www.unniun.com/wp->

[content/uploads/2019/11/Employee-Journey-Map-1.png](https://www.unniun.com/wp-content/uploads/2019/11/Employee-Journey-Map-1.png).

CONTINUAR