

## EL PAPEL FUTURO DEL *BIG DATA* Y EL APRENDIZAJE AUTOMÁTICO EN LA EFICIENCIA DE LAS INSPECCIONES EN MATERIA DE SEGURIDAD Y SALUD

### Introducción

Las inspecciones son probablemente el instrumento más importante que utilizan los organismos gubernamentales de inspección de trabajo para garantizar que las empresas adoptan las medidas necesarias para cumplir con las normativas en materia de seguridad y salud en el trabajo. No obstante, el efecto de dichas inspecciones depende de diversos factores. Un factor fundamental es el proceso de selección de los objetos de inspección, es decir, las empresas o los lugares que se van a inspeccionar. En principio, existen al menos tres enfoques distintos en cuanto a la selección. El primer enfoque es realizar inspecciones en todas las empresas con independencia de los posibles riesgos, del tamaño de la empresa, del tipo de sector o de cualquier otro criterio. El segundo enfoque supone seleccionar las empresas basándose en un muestreo aleatorio según el cual todas las empresas, independientemente de cualquier característica, tienen las mismas probabilidades de ser seleccionadas. Ambos métodos suelen considerarse poco efectivos en lo que a las condiciones preventivas y económicas se refiere (Blanc, 2013). Por tanto, la mayoría de los organismos de inspección de trabajo seleccionan empresas en función del tercer enfoque, a saber, el enfoque basado en el riesgo..

Aunque este enfoque es un principio esencial para la mayoría de las inspecciones de trabajo actuales, su aplicación práctica plantea retos sustanciales. El principal motivo es que faltan métodos de análisis de riesgos lo suficientemente detallados (Mischke et al., 2013). Sin métodos apropiados que permitan una priorización en función del riesgo, el enfoque basado en el riesgo corre el peligro de convertirse en una declaración gubernamental de principios sin consecuencias prácticas reales. Por tanto, es necesario desarrollar métodos que permitan la selección de empresas de alto riesgo (Weil, 2008).

La mayor parte de los organismos de inspección de trabajo recopilan y almacenan enormes cantidades de datos relacionados con sus objetos de inspección y sus actividades de inspección. Por consiguiente, los organismos de inspección pueden llegar a disponer de grandes volúmenes de datos que aumentan con gran rapidez, a los que hoy se hace referencia con el término «*big data*». El *big data*, combinado con las tecnologías de aprendizaje automático, se utiliza cada vez más para distintos fines predictivos, aprendiendo de las tendencias ocultas en los datos. Por ejemplo, el valor predictivo del *big data* y las técnicas de aprendizaje automático se está poniendo a prueba en ámbitos tan diversos como el pronóstico del cáncer y los resultados en los pacientes, la predicción de quiebras, la predicción del precio del petróleo, la detección del fraude fiscal, la predicción de delitos y la previsión de los mercados de valores. No obstante, la cuestión fundamental que se aborda en el presente documento es si el uso del *big data* y las técnicas de aprendizaje automático para seleccionar objetos de inspección de alto riesgo es un recurso prometedor para las inspecciones de trabajo.

### Selección en función del riesgo

Según los principios de mejores prácticas para las políticas regulatorias, señalados por la Organización para la Cooperación y el Desarrollo Económicos (OCDE, 2014), los análisis de los riesgos y las evaluaciones de riesgos deberían ser la base para seleccionar los objetos de inspección de las inspecciones de trabajo. Esto significa que deberían seleccionarse las empresas para inspección en función de las valoraciones de la probabilidad y las consecuencias de los

riesgos como pueden ser los accidentes, las exposiciones peligrosas y las condiciones de trabajo ilícitas. El fundamento de la selección basada en el riesgo es el reconocimiento de que, debido a los escasos recursos de inspección, no es posible controlar todas las esferas de riesgo ni todos los objetos de riesgo. En lo referente a las inspecciones de seguridad y salud de las autoridades de inspección de trabajo, esto significa que se debe dar prioridad a algunos ámbitos problemáticos frente a otros. Asimismo, se debe dar prioridad a la inspección de unas empresas frente a otras.

El principio de selección basada en el riesgo no es un concepto novedoso. Hace casi cincuenta años, en la evaluación del sistema de supervisión de la seguridad y la salud en el trabajo en el Reino Unido llevada a cabo por la Comisión Robens, se introdujo el enfoque basado en el riesgo (combinado con la autorregulación) como un ideal en el proceso de modernización de la inspección reglamentaria (Robens, 1972). Con el fin de garantizar el uso de los recursos de inspección de forma eficiente, el Informe Robens recomendaba que las autoridades competentes concentraran sus recursos de manera selectiva en los ámbitos problemáticos más importantes y que dieran prioridad a empresas y problemas que habían sido detectados mediante el análisis sistemático de todos los datos disponibles relacionados con la seguridad y la salud, p.ej., las estadísticas de accidentes, la información técnica y los conocimientos locales de la inspección de trabajo.

Las recomendaciones del Informe Robens han sido adoptadas de forma generalizada por los organismos de inspección de trabajo tanto internacionalmente como en los Estados miembros de la UE. La generalización del enfoque basado en el riesgo supone que la mayoría de los organismos de inspección de trabajo actuales han adoptado la idea de retirar recursos de objetos de inspección de bajo riesgo y concentrar más recursos para aplicarlos en objetos de mayor riesgo. Para que esto sea posible, es preciso que se lleve a cabo algún tipo de análisis de datos. Los métodos analíticos para identificar los sectores de alto riesgo y los grupos de trabajadores expuestos a riesgos están bien desarrollados. Estos análisis basados en el riesgo normalmente se fundamentan en estadísticas nacionales relacionadas, por ejemplo, con las enfermedades profesionales, los accidentes de trabajo, y las exposiciones laborales. El análisis constituye el fundamento de las campañas de inspección, los planes estratégicos y los ámbitos prioritarios nacionales e incluso internacionales.

Bastante menos comunes que los análisis generales basados en el riesgo son los métodos que permiten fijar prioridades entre empresas de un mismo sector. Entre los organismos de inspección de trabajo, un enfoque habitual para la selección de empresas expuestas a riesgos es confiar en los conocimientos locales de los inspectores. Algunos organismos de inspección de trabajo, como los de Dinamarca y Suecia, han estudiado la utilidad de sistemas de clasificación de los riesgos basados en escalas aditivas. Utilizando escalas agregadas se da a cada empresa una puntuación de riesgo basada en diversas características de la empresa (p.ej., tipo de sector y número de accidentes registrados) que se suman hasta obtener una puntuación acumulada, y se da prioridad para la inspección a las empresas con la mayor puntuación acumulada. No obstante, el problema del uso de las escalas agregadas es que muestran niveles relativamente bajos de validez predictiva, es decir, la puntuación no es especialmente adecuada para separar las empresas de alto riesgo de las de bajo riesgo.

## Big data y aprendizaje automático

El proceso de dar prioridad a unas empresas frente a otras es comparable a buscar una aguja en un pajar. En este caso, el pajar podría consistir en los cientos de miles de posibles objetos de inspección, pero solo algunos de dichos objetos son agujas, es decir, tienen un nivel de riesgo inadmisibles. Precisamente, de buscar agujas en un pajar es de lo que en gran medida tratan el *big data* y el aprendizaje automático.

El principal objetivo de los algoritmos de aprendizaje automático es proporcionar un modelo estadístico que pueda utilizarse para hacer predicciones, clasificaciones, estimaciones o tareas

similares. En el ámbito, por ejemplo, de la predicción del cáncer, los investigadores utilizan desde hace más de tres décadas algoritmos de aprendizaje automático para predecir la predisposición, la recurrencia y la supervivencia al cáncer. Desde el punto de vista temático, la predicción del cáncer está muy lejos de la selección de objetos de inspección basada en el riesgo, pero ambos son ejemplos de retos predictivos o problemas del tipo «una aguja en un pajar».

Los dos tipos más comunes de algoritmos de aprendizaje automático son el aprendizaje supervisado y aprendizaje no supervisado. En el aprendizaje supervisado, el algoritmo consiste en una variable dependiente (p.ej., el nivel de riesgo) que debe predecirse a partir de un conjunto de variables independientes. Por supuesto, las predicciones exactas requieren elevados niveles de correlación entre las variables independientes y la variable dependiente. En el aprendizaje no supervisado, no hay una variable dependiente que predecir, sino que el objetivo del algoritmo es agrupar los datos (p.ej. distintos grupos de riesgos) por semejanza. A diferencia de las escalas agregadas, como las estudiadas por las inspecciones de trabajo de Dinamarca y Suecia, los algoritmos utilizados en el aprendizaje automático mejoran progresivamente sus predicciones, fundamentalmente mediante ensayo y error. Esto quiere decir que la máquina aprende de éxitos (predicciones correctas) y errores (predicciones incorrectas) anteriores e intenta recoger este conocimiento para que las predicciones sean más precisas basándose en la retroalimentación recibida.

## Uso del *big data* y el aprendizaje automático en la selección de objetos de inspección

Los algoritmos de aprendizaje supervisado y no supervisado requieren un volumen suficiente de datos, tanto con respecto al número de observaciones como al número de variables, normalmente conocidos como «rasgos». Como ya se ha señalado, la mayoría de los organismos de inspección de trabajo recopilan y almacenan una enorme cantidad de datos relacionados con sus objetos de inspección y sus actividades de inspección. Los datos disponibles normalmente tienen que ver con rasgos específicos de la empresa como el número de empleados, la antigüedad de la empresa, la agrupación industrial, el número de inspecciones previas, el resultado de dichas inspecciones previas y las notificaciones de accidentes. Asimismo, el número de datos aumenta progresivamente al añadirse nuevas inspecciones. En principio pues, abordar el reto de seleccionar empresas de alto riesgo mediante el uso del *big data* debería, al menos a primera vista, resultar adecuado para los algoritmos de aprendizaje automático. A pesar de ello, ha habido pocos intentos en este sentido. Existen, no obstante, notables excepciones, y todas ellas ilustran que el *big data* y el aprendizaje automático podrían ser muy pertinentes para que los organismos de inspección de trabajo solucionen el problema de seleccionar objetos de inspección de alto riesgo.

El primer ejemplo es un trabajo de investigación que estudia la idoneidad de las metodologías de aprendizaje automático para la predicción de accidentes laborales o, más concretamente, de caídas en el mismo nivel (Matías et al., 2008). A pesar de sus predicciones relativamente precisas, el inconveniente de este estudio es que los rasgos incluidos en los algoritmos no son el tipo de datos de los que normalmente disponen las inspecciones de trabajo (p.ej., uso de equipo de protección individual y prácticas de limpieza). Asimismo, las caídas al mismo nivel representan solo un porcentaje ínfimo de los riesgos laborales de los que se ocupan las inspecciones de trabajo.

El segundo ejemplo es también un trabajo de investigación (Hajakbari y Minaei-Bidgoli, 2014). Este trabajo desarrolló un sistema de puntuación para predecir el riesgo de accidentes de trabajo. Además, concluyó que es posible predecir el riesgo de distintos tipos de accidentes laborales de forma relativamente precisa en función de algunas características generales de la empresa (la actividad principal de la empresa, la distribución por sexos, el número de empleados, etc.). Asimismo, el estudio concluyó que el algoritmo podía utilizarse para identificar lugares de trabajo

que requerían inspecciones periódicas de seguridad y salud. Los datos utilizados en este estudio se extrajeron de la base de datos de un organismo de inspección de trabajo. No obstante, una vez más, el inconveniente del estudio es que los accidentes de trabajo representan únicamente uno de los muchos riesgos laborales de los que se ocupan las inspecciones de trabajo. Asimismo, uno de los problemas concretos de depender de las estadísticas de daños a la salud es que se sabe que dichos datos son extremadamente susceptibles a la infranotificación.

Un tercer ejemplo es la herramienta desarrollada por la Autoridad Noruega de Inspección Laboral (NLIA) para ayudar a los inspectores a seleccionar las empresas con respecto al riesgo (Dahl et al., 2018). La herramienta, denominada «herramienta de predicción de grupos de riesgo» (RGTP por sus siglas en inglés), clasifica las empresas en cuatro grupos basándose en los riesgos previstos: empresas de riesgo muy bajo, empresas de riesgo bajo, empresas de riesgo alto y empresas de riesgo muy alto. Cuanto más elevado sea el grupo de riesgo de una empresa, más alta es la probabilidad de que una futura inspección de dicha empresa detecte desviaciones graves con respecto al cumplimiento de la normativa sobre seguridad y salud. Los inspectores pueden ver el grupo que se le ha asignado a una empresa en la interfaz de la web interna de la autoridad noruega de inspección laboral. Por tanto, cuando seleccionan las empresas para la inspección, los inspectores conocen los grupos de riesgo de las empresas y, de este modo, son capaces de hacer una selección teniendo en cuenta el riesgo.

La herramienta de predicción de grupos de riesgo (RGTP) se construyó sobre la base de modelos predictivos mediante un algoritmo de aprendizaje automático utilizando el denominado análisis de regresión logística binaria. Sobre la base del modelo de regresión, todas las empresas de Noruega (aproximadamente 230.000) se asignan a uno de los cuatro grupos de riesgo. Esto se lleva a cabo en dos fases. En la primera, el modelo de regresión predice la probabilidad de que una futura inspección detecte desviaciones graves con respecto al cumplimiento de la normativa sobre seguridad y salud. En la segunda fase, el modelo utiliza el valor de probabilidad pronosticado para asignar la empresa a un grupo de riesgo.

Inicialmente, la herramienta se desarrolló sobre la base de los registros de alrededor de 35.000 inspecciones de seguridad y salud realizadas por la autoridad noruega de inspección laboral (NLIA). No obstante, las predicciones realizadas por la herramienta se convierten de forma gradual y automática en predicciones más precisas a medida que aumenta el número de inspecciones. Esto significa que el algoritmo se ajusta basándose en la retroalimentación (predicciones correctas o incorrectas) que recibe cuando se realizan nuevas inspecciones y se registran en la base de datos de NLIA .

La herramienta de predicción de grupos de riesgo pertenece al tipo de algoritmos de aprendizaje supervisado, según los cuales las inspecciones de seguridad y salud que reflejan desviaciones graves (variable dependiente) deben predecirse a partir de una serie de características de la empresa (rasgos). Los rasgos que utiliza la herramienta son características generales de la empresa como su tamaño, el grupo industrial, el número de inspecciones anteriores, los resultados de dichas inspecciones, la antigüedad de la empresa, su situación geográfica y las notificaciones de accidentes. La validez predictiva de la herramienta se comprueba todos los meses, y la experiencia hasta ahora (tras unos dieciocho meses de prueba) es que el algoritmo consigue seleccionar empresas de alto riesgo de forma extremadamente precisa. Esto significa que hay pocos falsos positivos y pocos falsos negativos, es decir, pocas inspecciones dentro del grupo de riesgo muy bajo dan lugar a la detección de desviaciones graves, mientras que la mayor parte de las inspecciones dentro del grupo de riesgo muy alto dan lugar a la detección de desviaciones graves. Los grupos de riesgo bajo y alto tienen resultados intermedios.

Las conclusiones que se extraen del uso de la herramienta desarrollada por la autoridad noruega de inspección laboral demuestran que es posible seleccionar objetos de inspección mediante la utilización del *big data* y el aprendizaje automático. Enfoques de aprendizaje automático similares se han probado también en al menos otros dos organismos de inspección laboral europeos con resultados prometedores: la Autoridad Sueca del Entorno Laboral (Ridemar, 2018) y el organismo

neerlandés de inspección laboral SZW (Jacobusse y Veenman, 2016). No obstante, la herramienta noruega no es necesariamente transferible a otros organismos de inspección laboral, ya que su uso depende de cómo se almacenen los datos, de la calidad de estos, de su acceso y de la estructura de la base de datos. Asimismo, la selección de empresas mediante el uso de la herramienta implica la aceptación del modo en el que se define y operacionaliza el riesgo en el algoritmo. Tal y como se ha descrito, la herramienta se basa en una definición del riesgo que implica que, cuanto más elevado es el grupo de riesgo de una empresa, más alta es la probabilidad de que una futura inspección de dicha empresa detecte desviaciones graves con respecto al cumplimiento de la normativa sobre seguridad y salud. Esto significa que la herramienta se ocupa principalmente de los denominados riesgos de gestión y control y no de los riesgos inherentes. Mientras que los riesgos de gestión y control surgen de la capacidad y disposición de una empresa para gestionar los riesgos (p.ej., mediante el cumplimiento de los correspondientes reglamentos), los riesgos inherentes son aquellos que se derivan de la naturaleza de las actividades de una empresa (p.ej., caídas verticales, exposición a sustancias químicas, trastornos musculoesqueléticos).

En la práctica, los riesgos de gestión y control y los riesgos inherentes están relacionados, pero eso no implica que los dos tipos de riesgos estén necesariamente muy correlacionados empíricamente. Por tanto, confiar ciegamente en herramientas que seleccionan empresas basándose solo en uno de estos tipos de riesgo puede tener como consecuencia que se pasen por alto otros tipos de riesgos. En el marco del régimen normativo noruego, este problema se aborda haciendo hincapié en los riesgos inherentes al tipo de actividad de la empresa a la hora de identificar áreas prioritarias, grupos de trabajadores expuestos a riesgos y sectores de alto riesgo, mientras que los riesgos de gestión y control se priorizan cuando se seleccionan empresas de forma concreta.

## Desafíos

El hecho de que los riesgos de gestión y control, por una parte, y los riesgos inherentes, por otra, no estén necesariamente correlacionados empíricamente nos lleva a otro desafío, probablemente mayor, en la aplicación del *big data* y los algoritmos de aprendizaje automático a la selección basada en el riesgo. Los tres ejemplos de herramientas de aprendizaje automático anteriormente mencionados son ejemplos de selección unidimensional, es decir, selección basada en una definición concreta del riesgo. Sin embargo, en el mundo laboral, los riesgos no son solo de un tipo concreto. Por lo tanto, las autoridades encargadas de la aplicación se ocupan de múltiples tipos de riesgos, por ejemplo, accidentes, exposición a sustancias químicas, exposición a agentes biológicos, riesgos psicosociales, trastornos musculoesqueléticos y *dumping* social. Dentro de estos tipos de riesgos, hay incluso más subtipos. Desarrollar modelos de riesgo que consigan reflejar esta variedad es muy complicado ya que los distintos tipos de riesgos no están necesariamente correlacionados. Así pues, captar dicha variedad es algo muy diferente a predecir la probabilidad de un tipo concreto de riesgo (Dahl et al., 2018).

Un segundo desafío, aunque relacionado, hace que la labor de selección en función del riesgo sea todavía más compleja. Se trata de la denominada «trampa política» (Black, 2010). Aunque los algoritmos de aprendizaje automático son dinámicos, en el sentido de que pueden aprender de los éxitos y errores y adaptarse a ellos, no tienen en cuenta los distintos puntos de vista políticos. En primer lugar, el contexto político es inconstante y, por ello, los tipos de riesgo a los que se les da prioridad hoy pueden no ser una prioridad mañana. En segundo lugar, el contexto político es pluridimensional. Por lo tanto, las diferentes partes interesadas, p.ej., políticos, empresarios, trabajadores, los medios de comunicación y el público, tienen puntos de vista diferentes sobre qué tipos de riesgos deben considerarse prioritarios. Esto ilustra que el riesgo en el mundo laboral no es necesariamente un elemento objetivo, sino que implica una dimensión social.

Un tercer desafío, digno de ser considerado, está relacionado con el hecho de que, aunque los organismos de inspección de trabajo disponen de enormes cantidades de datos relacionados con sus objetos de inspección, estos datos normalmente hacen referencia al nivel de empresa y los datos de empresa no son necesariamente los más adecuados a tener en cuenta (véase, por ejemplo, Gunningham y Sinclair, 2007). En una base de datos una empresa concreta se identifica normalmente con un identificador único como, por ejemplo, un número de identificación fiscal o un código de cuenta de cotización. La capacidad de un algoritmo de aprendizaje automático de asignar un valor de riesgo pronosticado concreto a una empresa depende de identificadores únicos. No obstante, todos los posibles objetos de inspección no son automáticamente identificables mediante un identificador único. Por ejemplo, en el contexto del sector de la construcción no se selecciona necesariamente una empresa de hormigón para su inspección, sino una obra en construcción en un momento dado. Hay al menos dos problemas relacionados con dicha temporalidad. En primer lugar, las obras de construcción y otros lugares temporales de trabajo pueden no ser identificables mediante identificadores únicos. En segundo lugar, aunque fueran identificables, la temporalidad implica que un algoritmo de aprendizaje automático podría no tener oportunidad de aprender de sus éxitos y errores predictivos antes de que concluyera la obra y las empresas que estaban en dicho lugar de trabajo se hubieran trasladado a una obra nueva.

## Conclusiones finales

Los desafíos descritos anteriormente muestran que existen dificultades significativas relacionadas con la selección de objetos de inspección de alto riesgo mediante la utilización del *big data* y de técnicas de aprendizaje automático. No obstante, estos desafíos no eliminan en ningún caso la utilidad de dichas técnicas en el marco de un enfoque basado en el riesgo. Al contrario, los desafíos ilustran que la selección en función del riesgo probablemente no deba confiar únicamente en los algoritmos de aprendizaje automático. El ejemplo noruego anteriormente mencionado así lo demuestra. En lugar de permitir que el algoritmo elija objetos directamente, los inspectores pueden tomar decisiones basadas en los riesgos teniendo en cuenta las predicciones que realiza el algoritmo teniendo en cuenta el riesgo sobre la base de las predicciones que realiza el algoritmo. Esto implica la combinación de inteligencia artificial y humana, de modo que la una complementa los puntos fuertes de la otra. Cuando se trata de predecir acontecimientos sociales complejos en general, la combinación de ambos tipos de inteligencia es probablemente una necesidad.

## Referencias

- Black, J., 2010: *Risk-based regulation: Choices, practices and lessons being learnt*. «Risk and regulatory policy: Improving the governance of risk». Publicaciones de la OCDE, 2010, OCDE, París.
- Blanc, F., 2013: *Inspection reforms: why, how, and with what results*. OCDE, París.
- Dahl, Ø., Kilskar, S. S., Skarholt, K., Rosness, R., 2018: *Risikobasert tilsyn i de nordiske arbeidstilsynene*. (Inspecciones laborales en función del riesgo en los países nórdicos). Consejo de Ministros Nórdico, Copenhague.
- Gunningham, N., Sinclair, D., 2007: «Factors impinging on the effectiveness of the Mines Inspectorate». The Australian National University, Camberra.
- Hajakbari, M. S., Minaei-Bidgoli, B., 2014: «A new scoring system for assessing the risk of occupational accidents: A case study using data mining techniques with Iran's Ministry of Labor data.» *Journal of Loss Prevention in the Process Industries* 32, pp. 443-453.
- Jacobusse, G., Veenman, C., 2016: «On selection bias with imbalanced classes». *International Conference on Discovery Science*, Bari, pp. 325-340.
- Matías, J. M., Rivas, T., Martín, J. E., Taboada, J., 2008: «A machine learning methodology for the analysis of workplace accidents». *International Journal of Computer Mathematics* 85, pp. 559-578.
- Mischke, C., Verbeek, J. H., Job, J., Morata, T. C., Alvesalo-Kuusi, A., Neuvonen, K., Clarke, S., Pedlow, R. I., 2013: «Occupational safety and health enforcement tools for preventing occupational diseases and injuries». *Cochrane Database of Systematic Reviews* 2013, Issue 8, Art. No CD010183.
- OCDE, 2014. «OECD Best practice principles for regulatory policy: Regulatory enforcement and inspections». Organización para la Cooperación y el Desarrollo Económico, París.
- Ridemar, A., 2018: *Decision support for SWEA inspections*. KTH Royal Institute of Technology, Stockholm.
- Robens, L., 1972: *Safety and Health at Work: Report of the Committee 1970-1972*. Her Majesty's Stationery Office, Londres.
- Weil, D., 2008: «A strategic approach to labour inspection». *International Labour Review* 147, pp. 349-375.

*Autores: Øyvind Dahl investigador experimentado, SINTEF Digital — Seguridad y Fiabilidad, Trondheim, Noruega*

*Annick Starren, Agencia Europea para la Seguridad y la Salud en el Trabajo (EU-OSHA).*