


Machine Learning y Seguridad y Salud

Proyecto Auditor Virtual de Vodafone Spain



Jornada Foment del Treball
INTELIGENCIA ARTIFICIAL APLICADA A LA PRL
17/10/2023





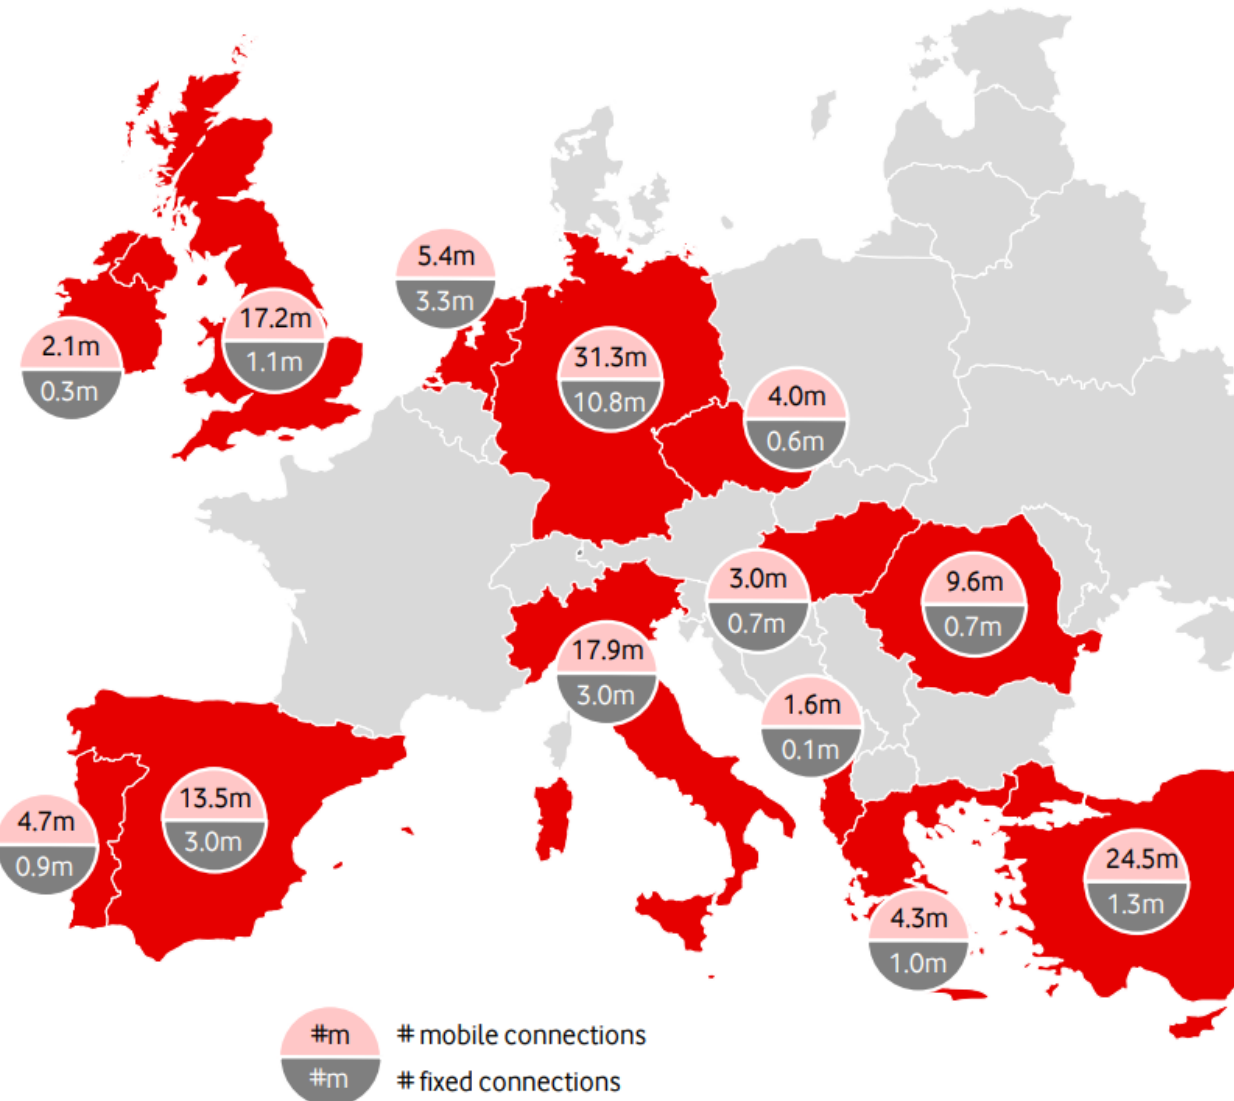
1

El contexto

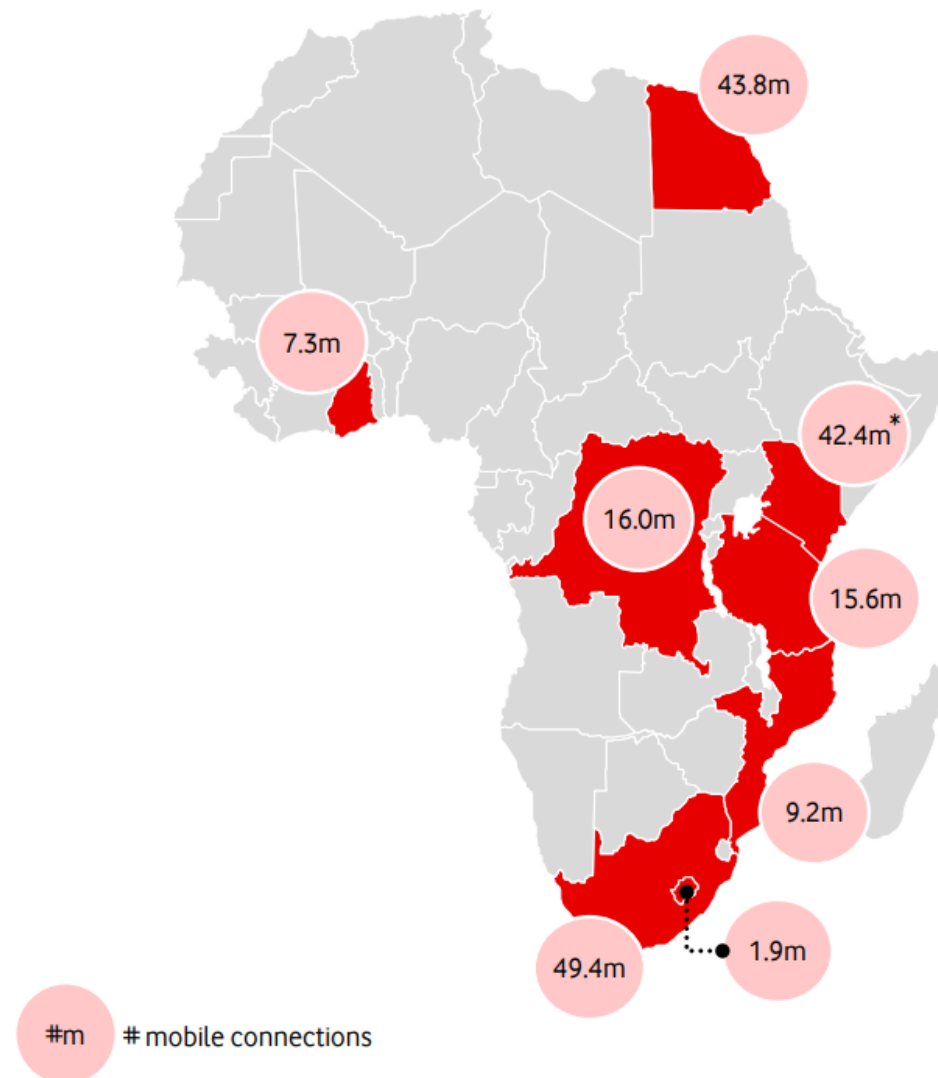


Grupo Vodafone en el mundo

Europe : converged connectivity leader



Africa : leading data & payments provider



Vodafone Spain

4,180 M €

Ingresos

13,9 M

Clientes móviles

3,4 M

Clientes de banda ancha

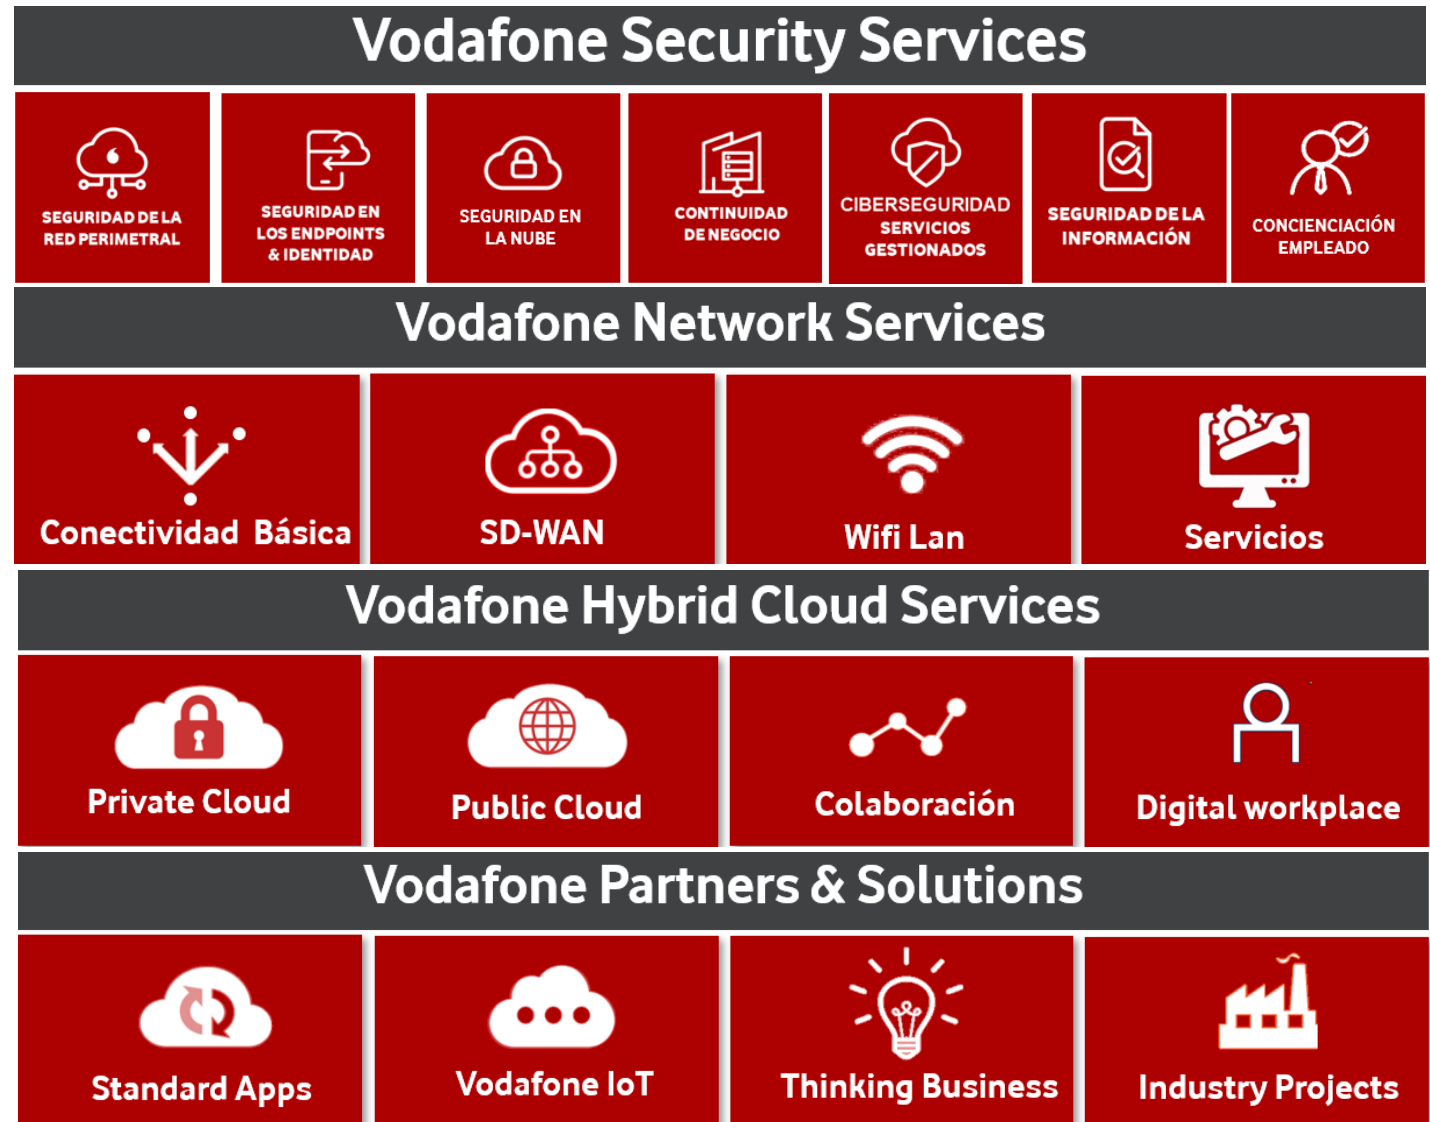
1,5 M

Clientes de TV



Vodafone

Enterprise Solutions



Vodafone España en cifras



4.100 Empleados propios

+15 Centros de trabajo



+25.000 trabajadores acreditados

15.000 emplazamientos



+ 1.300.000

Actuaciones anuales sobre la red

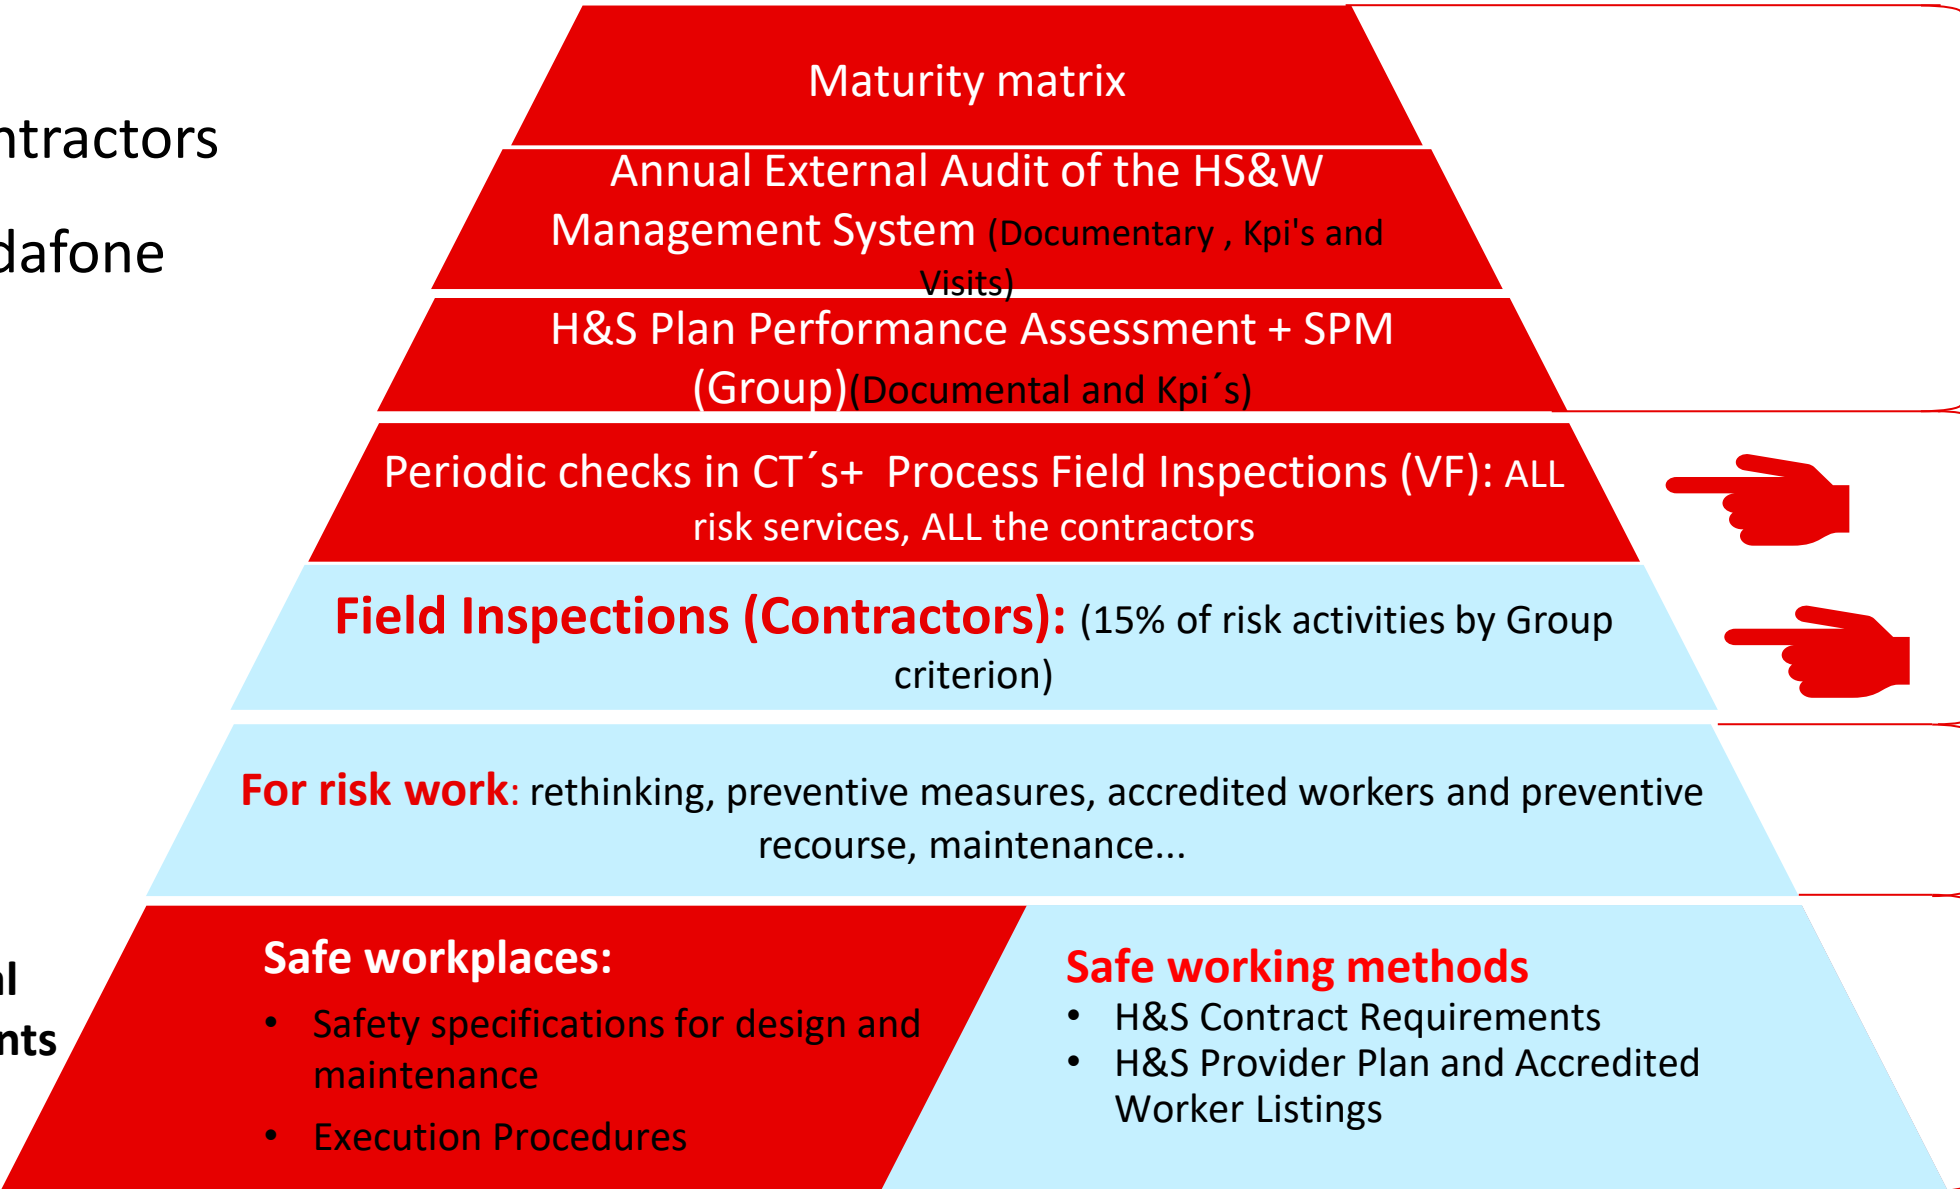
+ 83.000

Trabajos de riesgo alto



Pirámide de Control Vodafone Spain

- Contractors
- Vodafone




Evaluación y control de indicadores

Control de los trabajos en campo

Preparación de los trabajos

Previa a la contratación



Contractual requirements

- Safe workplaces:**
- Safety specifications for design and maintenance
 - Execution Procedures

- Safe working methods**
- H&S Contract Requirements
 - H&S Provider Plan and Accredited Worker Listings




Control de trabajos de alto riesgo en obra

Las inspecciones de campo que realiza Vodafone, se hacen de forma homogénea a todos los contratos, supplier y zonas, de forma que nos de una visión global de como se están ejecutando los trabajos. Inspecciones se realizan a entre el 5 y el 10% de todos los trabajos de riesgo.

Mientras, los proveedores realizan autocontroles al 15 % de sus trabajos de riesgo, según su propio criterio y medios.

¿Se puede utilizar la información del 10% de trabajos supervisados por Vodafone para mejorar la elección de trabajos a inspeccionar por los Proveedores?

High Risk works - Inspecciones de campo



- Inspeccionados por Vodafone
- Inspeccionados por Tier 1
- No inspeccionados

Inspecciones de campo de Vodafone

Objetivo
5-10 %

Cada **1.000 inspecciones de campos**, encontramos **32 incumplimientos**
3,2%

Inspecciones de campo por parte de proveedores

Objetivo
15 %

Cada **1.000 inspecciones de campos**, encontraron **6 incumplimientos**
0,6 %



Machine Learning aplicado a la detección de intoxicaciones alimentarias

[nature](#) > [npj digital medicine](#) > [articles](#) > [article](#)

Article | [Open Access](#) | [Published: 06 November 2018](#)

Machine-learned epidemiology: real-time detection of foodborne illness at scale

[Adam Sadilek](#), [Stephanie Caty](#), [Lauren DiPrete](#), [Raed Mansour](#), [Tom Schenk Jr](#), [Mark Bergtholdt](#), [Ashish Jha](#)
✉ [Prem Ramaswami](#) & [Evgeniy Gabrilovich](#)

[npj Digital Medicine](#) **1**, Article number: 36 (2018) | [Cite this article](#)

26k Accesses | **29** Citations | **581** Altmetric | [Metrics](#)

Abstract

Machine learning has become an increasingly powerful tool for solving complex problems, and its application in public health has been underutilized. The objective of this study is to test the efficacy of a machine-learned model of foodborne illness detection in a real-world setting. To this end, we built FINDER, a machine-learned model for real-time detection of foodborne illness using anonymous and aggregated web search and location data. We computed the fraction of people who visited a particular restaurant and later searched for terms indicative of food poisoning to identify potentially unsafe restaurants. We used this information to focus restaurant inspections in two cities and demonstrated that FINDER improves the accuracy of health inspections; restaurants identified by FINDER are 3.1 times as likely to be deemed unsafe during the inspection as restaurants identified by existing methods. Additionally, FINDER enables us to ascertain previously intractable epidemiological information, for example, in 38% of cases the restaurant potentially causing food poisoning was not the last one visited, which may explain the lower precision of complaint-based inspections. We found that FINDER is able to reliably identify restaurants that have an active lapse in food safety, allowing for implementation of corrective actions that would prevent the potential spread of foodborne illness.



2

Proyecto Minority Report




Proyecto Minority Report

Objetivo

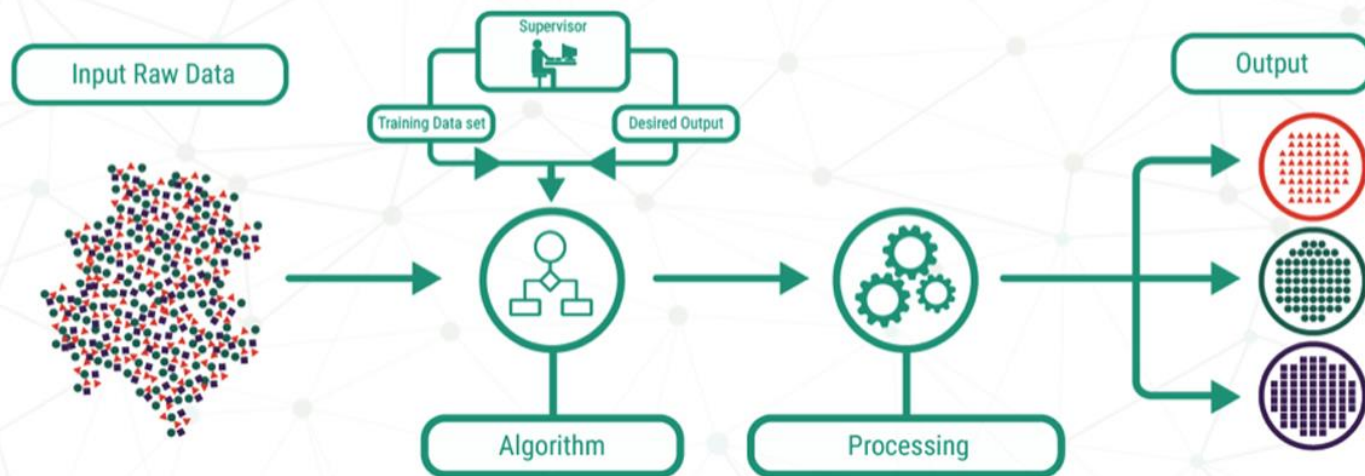
Prever con anticipación en que trabajos críticos de alto riesgo puede producirse un incumplimiento de seguridad.

Visión final

Detectar situaciones de riesgo, antes de que comiencen los trabajos, permitiendo su control y reduciendo la probabilidad de que ocurra un accidente.



Supervised Learning



Datos usados

Datos que definen la inspección

¿Cuándo?

Fecha



Resultado

0 = Todo OK
1 = Incorrecto

¿Qué trabajo?
¿Por quien?
¿Dónde?

Departamento
Servicio
Tier 1
Empresa...
Provincia

Uso de machine learning

Supervised learning

Machine Learning consiste básicamente en automatizar, a través de diferentes algoritmos, la identificación de patrones o tendencias que están "ocultos" en los datos.

El objetivo del aprendizaje automático es crear un modelo que nos permita resolver una tarea determinada. A continuación, el modelo se entrena utilizando grandes cantidades de datos.

El modelo aprende de estos datos y luego es capaz de hacer predicciones.

In supervised learning, los algoritmos funcionan con datos "etiquetados" (data labels), tratando de encontrar una función que, dadas las variables de entrada (input data), les asigna la etiqueta de salida adecuada. El algoritmo se entrena con un "historial" de datos y por lo tanto "aprende" a asignar la etiqueta de salida adecuada a un nuevo valor, es decir, predice el valor de salida.



3

Desarrollo de la solución

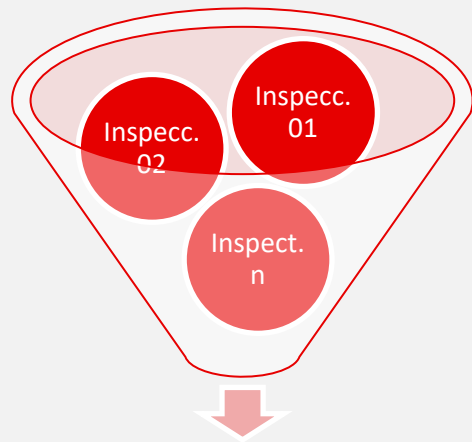


Desarrollo del proyecto | Fases


Fase 1 Recopilación de Datos



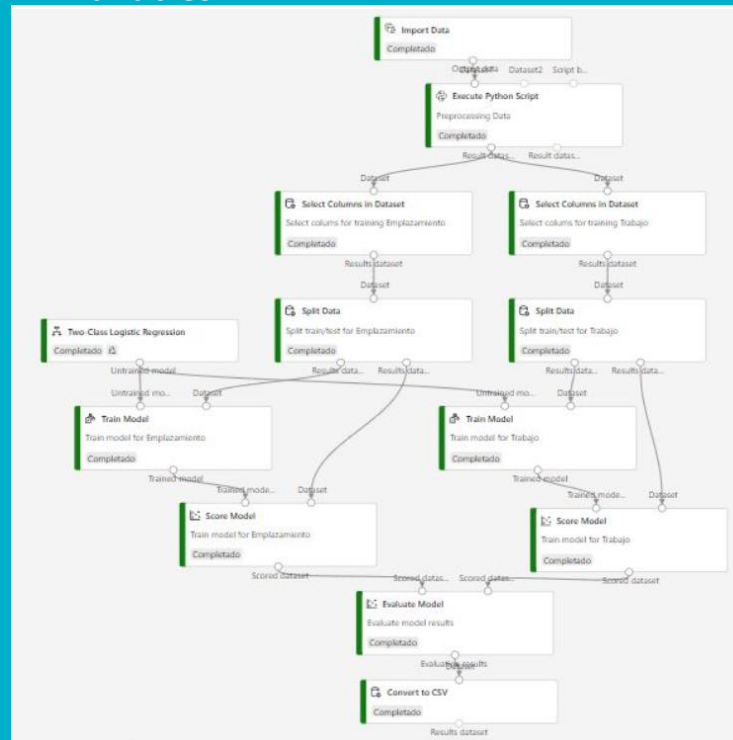
Más de 14.000 inspecciones de campo parametrizadas e incluidas en la base de datos



Fase 2 Selección de algoritmo y entrenamiento con los datos



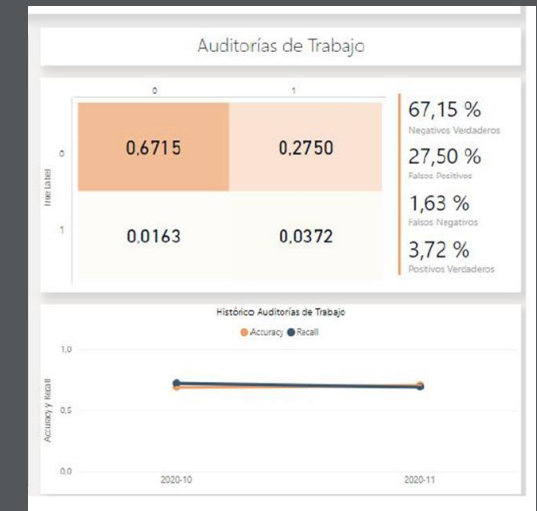
Se estudian más de 492 MILLONES de combinaciones posibles con todas las variables.



Fase 3 Análisis de resultados



Predice correctamente el 69,53% de trabajos incorrectos.



¿Qué significa esto?



Cada 1.000 inspecciones de campo



Encontrado 32 deficiencias (3,2 %)

Antes



Machine learning

Después

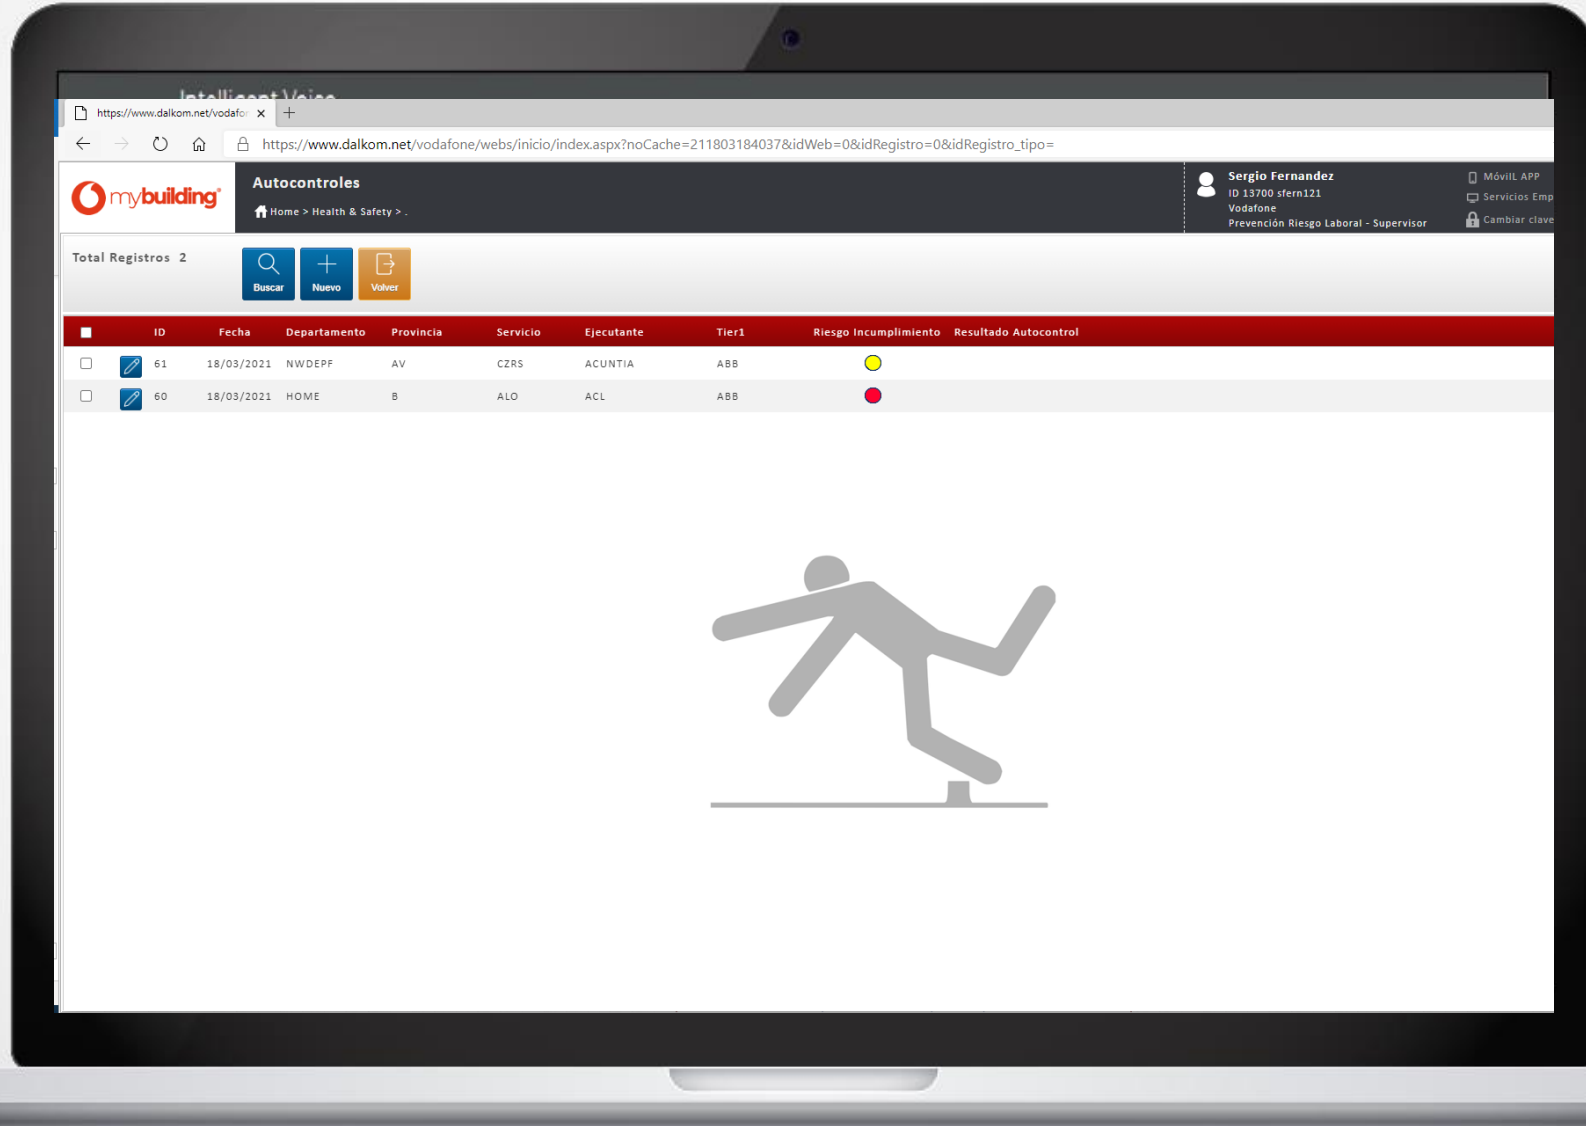
Selecciona 100 obras específicas



Donde encontraremos 19 deficiencias (19 %)



Auditor Virtual | Acceso a la herramienta



Para facilitar el acceso a los proveedores, se crea un desarrollo en MyBuilding (el sitio web que utilizan para enviar la información de sus empleados a Vodafone), que está conectado a Azure Machine Learning.

Con esto, pueden seleccionar las variables que definen una obra y la máquina devuelve el valor de probabilidad en forma de semáforo.

Como plus, después de esto pueden grabar si finalmente han llevado a cabo el autocontrol y el resultado de la misma.



4

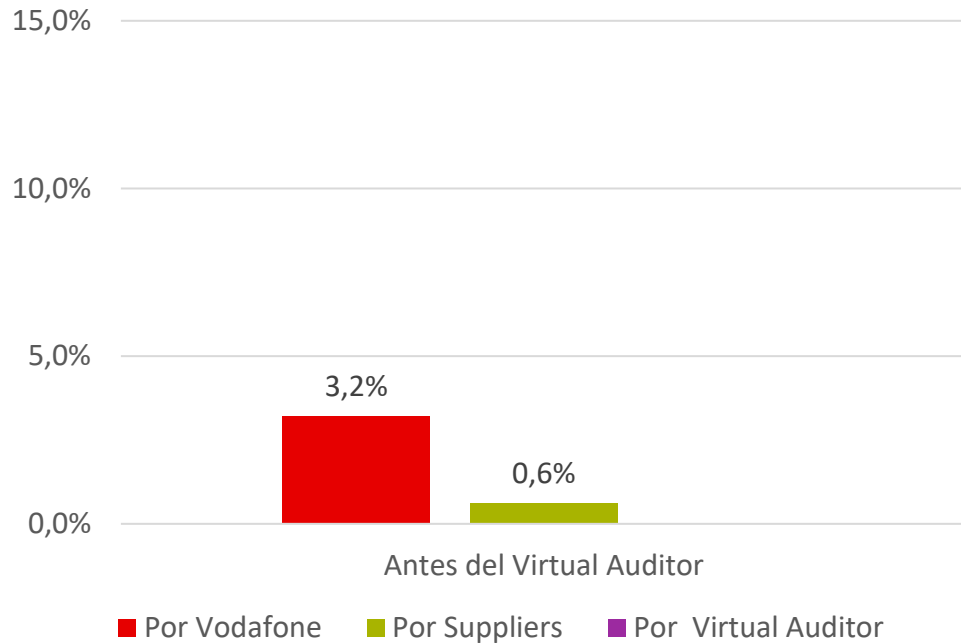
Resultados



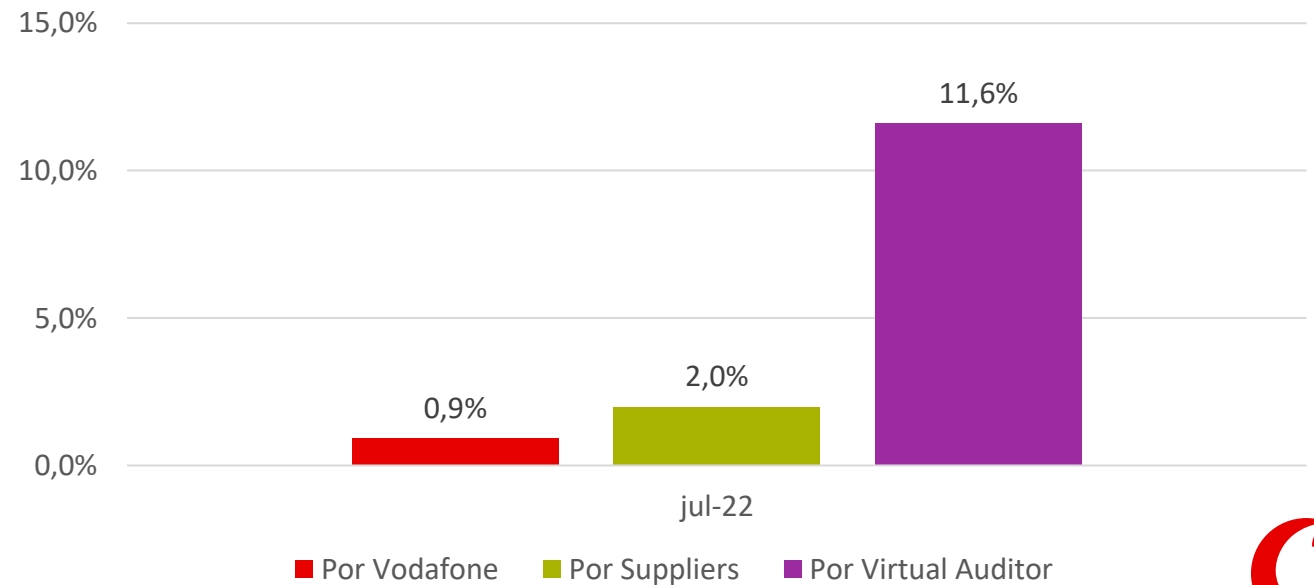
Virtual Auditor | Despliegue de la solución y resultados



% Trabajos con incumplimientos antes del despliegue del Auditor Virtual



% Trabajos con incumplimientos despues del despliegue del Auditor Virtual





"Lo que todos nosotros debemos hacer es garantizar que estemos empleando la IA de manera que beneficie a la humanidad, no que la perjudique."

Tim Cook





Together we can