

APLICACIONES DE CIENCIA DE DATOS ORIENTADAS AL ANÁLISIS DEL FACTOR HUMANO:

CASO DE ESTUDIO EN EL ÁMBITO DEL DEPORTE Y ESTUDIO DE PARALELISMOS PARA SU APLICACIÓN A EQUIPOS HUMANOS EN EL ÁMBITO INDUSTRIAL



Universidad de Oviedo

Álvaro Ponte Blanco

uo233109@unoivi.es

Máster en Automatización e Informática Industrial

Tutor: Ignacio Diaz Blanco - Universidad de Oviedo



RESUMEN

El factor humano es un apartado clave en la industria, y predecir su comportamiento puede aportar un gran valor para estimar errores humanos y mejorar el rendimiento. Debido a la ausencia de información interesante sobre el factor humano en procesos de fabricación, se ha utilizado otra tipología de datos para predecir esta conducta: información deportiva. Este TFM pretende aplicar conocimientos y algoritmos de analítica avanzada de datos con el objetivo de estudiar las características del comportamiento humano ante unas situaciones determinadas relacionadas con el deporte, desarrollando en detalle el paralelismo con el mundo industrial. Se ha especificado el caso de uso en el fútbol, debido a la gran disponibilidad de datos en la web.

Se ha creado una base de datos propia, se han realizado análisis descriptivos para comprender la información, y se han diseñado modelos predictivos para estimar probabilidades de ciertos sucesos en el deporte. El resultado final es una aplicación en un entorno HTML que permite la visualización los resultados de cada fase de una forma interactiva. Adicionalmente, el proyecto engloba otras funcionalidades con los datos como la generación automática de reportes que muestran los resultados de una temporada.

Palabras clave: **Big Data, Advanced Analytics, Data Science, IA, IoT, Human Factor, Boosting**

1. Objetivos y Estructura

El objetivo fundamental es la demostración del uso de la analítica avanzada de datos para **estimar el factor humano en la industria**. Adicionalmente, se pretende exponer otras funcionalidades del Big Data en el contexto industrial: **analítica descriptiva**, generación de reportes...

Se resuelve el problema con datos sobre un deporte concreto: el fútbol. La programación se desarrolla con **R (RStudio)** y sus librerías.



El proyecto se integra dentro de la metodología para minería de datos **CRISP-DM**:

1. Estudio del Caso de Aplicación
2. Creación de la Base de Datos
3. Diseño de Análisis Descriptivos
4. Desarrollo de Modelos Predictivos
5. Resultados e Implementación



Fig. 1.1 – Fases del Proyecto




Fig. 1.2: Metodología CRISP-DM – <http://www.sailotech.com>

2. Creación de la Base de Datos

Esta etapa consiste en la **creación de una nueva base de datos** sobre fútbol a través de procedimientos de **web scraping**. Se extrae información de cinco sitios webs distintos mediante algoritmos en R.



Fig. 2.1 – Sitios web - fuentes de información

Además de la obtención de información, esta fase contempla otras tareas:

- **Diseño** de la base de datos
- **Extracción** de información
- **Procesamiento** inicial de los datos
- **Unión** de diferentes bases de datos
- **Definición de relaciones** entre variables




Fig. 2.2 – Diseño de la base de datos generada

3. Diseño de Análisis Descriptivos

Esta fase tiene como objetivo el **desarrollo y la visualización de análisis descriptivos** utilizando la información almacenada en la base de datos generada. Esta etapa pretende ayudar al entendimiento del problema planteado, facilitar la comprensión de los datos y ofrecer una **visión gráfica e interactiva de la información**. Se distinguen cinco tipos de análisis principales:

| ANÁLISIS DEPORTIVOS | ANÁLISIS ESTADÍSTICOS | ANÁLISIS MACHINE LEARNING | ANÁLISIS ESPECÍFICOS DEL CASO | ANÁLISIS ADICIONALES |
|---|--|--|--|--|
| Análisis de índole futbolístico que son específicos para el campo de aplicación seleccionado: el deporte. | Análisis basados en patrones estadísticos como el promedio, frecuencia de sucesos o filtrados. | Análisis de mayor complejidad que utilizan técnicas más avanzadas (<i>regresión lineal, clustering...</i>) | Análisis en mayor profundidad sobre los casos de uso de los modelos predictivos (tarjetas) | Análisis sobre otros aspectos que proporcionan información útil adicional. Ej: Análisis Geoespacial. |
| | | | | |
| Fig. 3.1 – Ejemplo Análisis Deportivo | Fig. 3.2 – Ejemplo Análisis Estadístico | Fig. 3.3 – Ejemplo Análisis ML | Fig. 3.4 – Ejemplo Análisis Específico | Fig. 3.5 – Ejemplo Análisis Geoespacial |

4. Desarrollo de Modelos Predictivos

Las estimaciones se hacen a través de **modelos predictivos**. Se utiliza un algoritmo de **gradient boosting** implementado en R a través de la librería **XGBoost**. Se desarrolla un modelo de cada tipo (binario, multiclase, y de regresión) relacionado con el **comportamiento humano en el deporte**.

Etapas en el desarrollo de modelos predictivos:

1. Definición de la **variable objetivo**
2. Selección de **Información** para el modelo
3. Creación de **MasterTable**
4. Optimización de **Parámetros** y Ejecución
5. **Evaluación** del modelo y **Métricas** de resultado

ANALOGÍAS EN LA INDUSTRIA

Modelos de Estimación de Tarjetas

- Las tarjetas son el resultado de una **acción no reglamentaria** en el fútbol. La analogía de este caso es la predicción de errores humanos en un proceso de producción industrial
- **Modelo de Tarjetas Rojas**: Estimación de probabilidad de un error con consecuencias graves
- **Numero de Tarjetas Amarillas**: cantidad de errores leves (retrasos, poca calidad) en el procedimiento.



Modelo de Estimación de la Asistencia

- Este modelo es análogo a un modelo de **predicción de la demanda** en la industria. Pretende estimar el comportamiento de espectadores, que cumplen el rol de potenciales clientes de un producto.



MODELO DE CLASIFICACIÓN BINARIO: ESTIMACIÓN DE LA PROBABILIDAD DE EXPULSIÓN

La variable objetivo es 1 si hay expulsiones y 0 en caso contrario.

La métrica de error es compleja debido a las clases desbalanceadas. Métricas basadas en la **captura del nº de expulsiones** en función del valor estimado en la predicción



Fig. 4.1 – Importancia de las variables más significativas del modelo binario

MODELO DE CLASIFICACIÓN MULTICLASE: CÁLCULO DE Nº TARJETAS AMARILLAS EN UN PARTIDO

La variable objetivo es el **número total de tarjetas amarillas** en un encuentro. Las clases son el número posible de tarjetas (0, 1, 2, 3, 4..)

El resultado para cada muestra es un **vector con la probabilidad de pertenencia a cada una de las clases**




Fig. 4.2 – Representación de las proporciones asignadas a cada clase para una muestra aleatoria del test

MODELO DE REGRESIÓN: ESTIMACIÓN DE LA ASISTENCIA DE PÚBLICO AL ESTADIO

La variable objetivo es el **porcentaje de ocupación de un estadio** para un encuentro determinado (rango de 0 a 1)

El resultado también es un valor continuo en el mismo rango. Para la métrica de error se ha utilizado el parámetro **RMSE**



Fig. 4.3 – Comparación de la predicción y el valor real de la variable para cien muestras aleatorias

5. Generación Automática de Reportes

Se trata de una funcionalidad con los datos que permite **generar archivos** en formato de **xlsx de forma automática**.

Está basado en un **algoritmo en R** que recibe como entrada un **csv** con datos de los resultados de una temporada y genera un fichero de Excel con tres hojas:

Fig. 5.1 y 5.2 : Muestra de los reportes generados

- **Hoja 1:** Resumen de los resultados de una temporada por jornadas
- **Hoja 2:** Clasificación de una competición liguera
- **Hoja 3:** Tabla Cruzada de Resultados

6. Aplicación Web

Se trata de una **aplicación en un entorno web** que muestra los resultados de las fases de este proyecto de **forma visual e interactiva**.

Está diseñada con el paquete **Shiny**, una librería de R que permite el desarrollo de aplicaciones en **lenguaje HTML** a través de la programación en **RStudio**. También se puede combinar con funciones de otros lenguajes.

Dentro de la aplicación, el usuario tiene la posibilidad de **visualizar resultados, interactuar con los análisis descriptivos o extraer información** de las tablas.

Figuras 6.1, 6.2, 6.3 y 6.4 : Aplicación en Entorno Web