

# Plantilla Metodología *Peer Review*

Equipo:

Equipo de Validación:

Enabler:

Perfiles: **obligatorio** / **opcional**

Fecha:

Versión:

## Ideación

Identificación del objetivo, alcance y viabilidad del proyecto:

### Objetivo

¿Qué se pretende construir?

### Impacto

¿Se han definido KPIS?

### Salida:

¿Cuál es la funcionalidad esperada del producto?

¿Qué tipo de salida se proporcionará? Ej: predicción, ETL, tabla...

### Usuario final: (cliente, otro área, cross,..)

### Estimación de tiempo

### Otras consideraciones:

¿Necesita llevarse a otros países?

¿Se necesita un estudio de viabilidad para decidir si se continúa?

Fairness (¿potenciales riesgos?)

## Perfiles Equipo

Product Owners

ML Engineering

Data Scientists

## Perfiles Equipo Validación

Product Owners

ML Engineering

Data Scientists

### Nombres:

Nombre 1, Nombre 2...

## Datos

Datos de entrada y salida necesarios para construir la solución:

### Características de la fuente

¿Qué tipo de datos tenemos?

¿Cuál es su origen? ¿Sensible? ¿Agregado?

### Disponibilidad

¿Qué tipo de datos tenemos?

### Otras fuentes

¿Se necesita dato externo?

### Características de la salida

¿Qué tipo de datos vamos a generar?

¿Cuál es su frecuencia de actualización?

## Perfiles Equipo

Negocio

Data Hub

ML Engineering

Data Scientists

## Perfiles Equipo Validación

Data Hub

Data Scientists

### Nombres:

Nombre 1, Nombre 2...

## Modelo

Descripción de modelo/s o solución analítica elegida:

### Modelos elegidos

¿Qué modelo / ensemble se ha elegido? ¿Por qué?

¿Cuál es la complejidad? ¿Se podría reducir la misma?

¿Qué tecnología se ha utilizado?

### Entrenamiento y validación

¿Cómo de parecidos son train / val / test?

¿Se ha utilizado la validación cruzada? ¿Se ha regularizado de alguna manera?

### Implementación y despliegue

¿Es el modelo robusto? ¿Cómo escala la solución escogida?

¿Cómo se va a consumir?

¿Es interpretable?

## Perfiles Equipo

ML Engineering

Data Scientists

## Perfiles Equipo Validación

Arquitectura

ML Engineering

Data Scientists

### Nombres:

Nombre 1, Nombre 2...

## Validación

Métricas de negocio, de validación de los modelos:

### Validación de la solución

Registro coherente de logs, métricas, arquitecturas y datos históricos.

### Validación de negocio

¿Cumple la solución con lo esperado?

¿Se aplican los modelos a todos los grupos de datos?

¿Se ha realizado un test A/B?

### Validación del modelo

¿Qué función de coste se optimiza?

Métricas train / val / test

### Stress test

¿Se han probado casos extremos? ¿Entrada de datos corrupta?

## Perfiles Equipo

Negocio

Product Owners

Arquitectura

ML Engineering

Data Scientists

## Perfiles Equipo Validación

Negocio

Product Owners

Arquitectura

ML Engineering

Data Scientists

### Nombres:

Nombre 1, Nombre 2...

## Monitorización

Registro de revisiones periódicas de la solución implementada:

### Modelo

Degradación de los modelos

Frecuencia de reentrenamiento. ¿Manual o automático?

Monitorización del performance

Estabilidad de datos de entrada

### Negocio

KPIs

Importancia de features

Feedback de negocio (Cuantitativo o Cualitativo)

### Fairness

¿Se monitorizan los potenciales sesgos descritos en fases anteriores en fase de inferencia para su control?

### Otras consideraciones

¿Qué alertas necesitamos definir?

## Perfiles Equipo

Negocio

Product Owners

ML Engineering

Data Scientists

## Perfiles Equipo Validación

Product Owners

ML Engineering

Data Scientists

### Nombres:

Nombre 1, Nombre 2...