

---

# Documentación de Caso de Uso 2:

## Calidad Vinícola

### 1. Contexto y Objetivo del Modelo

En la industria enológica, determinar la calidad de un vino suele requerir el tiempo y la experiencia de sumilleres y catadores profesionales.

Este caso de uso demuestra cómo la Inteligencia Artificial puede actuar como un "catador digital", prediciendo la puntuación de calidad de un vino blanco basándose puramente en sus propiedades químicas detectables en laboratorio.

- **Objetivo de la predicción (Target):** quality (Puntuación de la calidad del vino, en una escala del 1 al 10).
- **Dataset utilizado:** winequality-white.csv

### 2. Estructura de los Datos

El modelo ha sido entrenado utilizando un conjunto de datos que detalla los análisis químicos de distintas muestras de vino blanco. Las variables que evalúa la IA incluyen:

- **Niveles de Acidez y pH:** Acidez fija, acidez volátil, ácido cítrico y nivel de pH.
- **Composición de Azúcar y Sal:** Azúcar residual y cloruros.
- **Conservantes y Alcohol:** Dióxido de azufre libre y total, sulfatos y el porcentaje de alcohol.
- **Características Físicas:** Densidad del líquido.

### 3. Configuración del Algoritmo

Tras una prueba inicial con un modelo lineal, se procedió a **optimizar la configuración** para intentar captar la compleja química del vino, donde los ingredientes tienen un equilibrio delicado y su impacto no es simplemente una línea recta (ej. ni mucho ni poco azúcar).

Se utilizó un algoritmo **Support Vector Machine (SVM)** con los siguientes hiperparámetros avanzados:

- **Kernel:** RBF (Radial Basis Function). Permite a la IA trazar fronteras de decisión curvas y no lineales, buscando agrupaciones de vinos con química similar.
- **C y Gamma:** Ajustados para que el modelo preste mayor atención a los pequeños matices químicos.

## 4. Análisis de Resultados y Rendimiento

El modelo optimizado fue evaluado mediante validación cruzada (5 Folds). Los resultados nos muestran un interesante escenario de "equilibrio técnico" donde se prioriza la utilidad práctica frente a la estadística pura:

- **R2 Score (~0.200 - 20%):** A nivel estadístico puro, explicar el gusto humano subjetivo mediante química sigue siendo un reto matemático complejo, manteniendo un índice de varianza explicada moderado.
- **MAE - Error Absoluto Medio (~0.540):** ¡El gran éxito de esta optimización! En la práctica diaria, la predicción de la IA ha mejorado su precisión neta, equivocándose por apenas **medio punto (0.54)** respecto a la nota que le daría un catador humano profesional en una escala de 1 a 10.
- **RMSE - Raíz del Error Cuadrático Medio (~0.791):** Esta métrica, ligeramente superior, indica que cuando el modelo falla, suele hacerlo penalizado por vinos "atípicos" (vinos que químicamente parecen mediocres pero que a los humanos les encantan, o viceversa).

### Conclusión:

El modelo "Calidad Vinícola" optimizado con Kernel RBF demuestra ser una herramienta altamente práctica. Su margen de error promedio de solo 0.54 puntos lo convierte en un excelente filtro previo de laboratorio. Una bodega podría utilizar este modelo de forma inmediata para categorizar rápidamente sus lotes basándose en el análisis químico, reservando a los catadores humanos solo para los vinos con puntuaciones dudosas o sobresalientes.

---