



Módulo 1

Lección 2

Aprendizaje Automático
Supervisado

Contenido

- 
- 1 Repaso de la lección anterior
 - 2 Modelos y algoritmos en aprendizaje supervisado

- 3 Evaluación del rendimiento del modelo
 - 4 Preprocesamiento de datos
- 



Haz clic sobre los títulos para navegar en cada tema.

1. Repaso de la lección anterior

BREVE REVISIÓN DE LOS CONCEPTOS DE LA LECCIÓN ANTERIOR PARA ESTABLECER UNA CONEXIÓN.

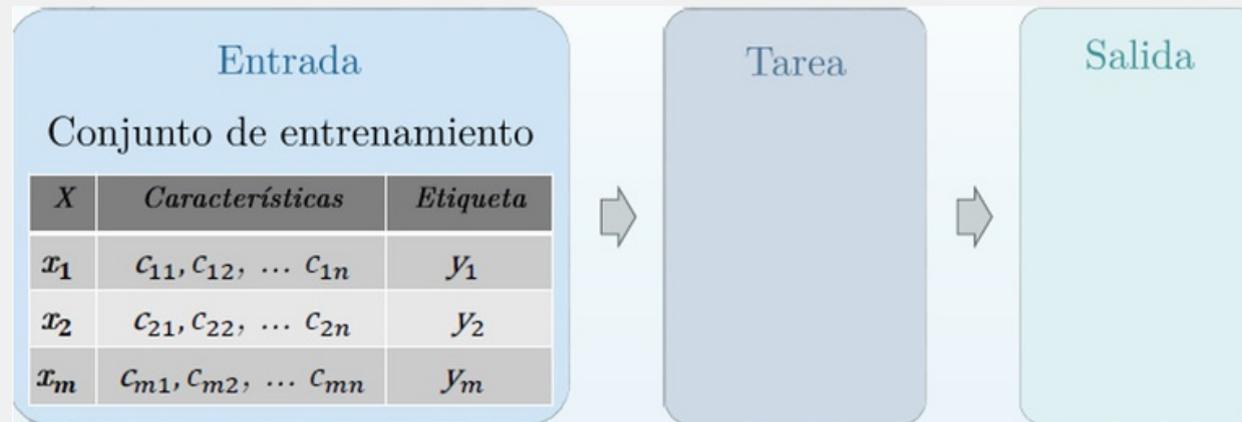
- Aclaremos dudas o preguntas surgidas durante la práctica.



[🏠 Volver a Contenido](#)

Tema 2. Modelos y algoritmos en aprendizaje supervisado

En el aprendizaje supervisado, el agente aprende de un conjunto de entrenamiento conjunto de etiquetas Y asociadas.



[Volver a Contenido](#)

- Definición y tipos

El aprendizaje supervisado es un paradigma dentro del campo del aprendizaje automático, en el cual un modelo se entrena utilizando un conjunto de datos etiquetado. En este enfoque, cada ejemplo en el conjunto de datos de entrenamiento consiste en una entrada y su correspondiente salida deseada o etiqueta. El objetivo del modelo es aprender la relación entre las entradas y las salidas, de manera que pueda hacer predicciones precisas sobre nuevas instancias no vistas.

En términos más simples, el aprendizaje supervisado implica enseñar al modelo a partir de ejemplos previamente etiquetados, permitiéndole generalizar patrones y hacer predicciones o clasificaciones en datos desconocidos.

- Elementos clave del aprendizaje supervisado

Conjunto de datos etiquetado	Modelo de aprendizaje	Proceso de entrenamiento	Predicción en datos no vistos
Contiene ejemplos de entrada junto con las salidas o etiquetas correspondientes.	Un algoritmo o arquitectura de red neuronal que se entrena para mapear las entradas a las salidas correctas.	El modelo ajusta sus parámetros utilizando el conjunto de datos de entrenamiento para minimizar la discrepancia entre las predicciones y las etiquetas reales.	Después del entrenamiento, el modelo se utiliza para hacer predicciones en datos que no formaron parte del conjunto de entrenamiento.



- Ejemplo

conceptual

Supongamos que queremos entrenar un modelo para reconocer dígitos escritos a mano. El conjunto de datos de entrenamiento contendría imágenes de dígitos junto con las etiquetas que indican qué dígito representa cada imagen.

Durante el entrenamiento, el modelo aprendería a asociar características visuales específicas con los dígitos correctos.



Después del entrenamiento, podríamos usar el modelo para predecir el dígito de nuevas imágenes no vistas con una buena probabilidad de precisión.

- Ejemplos prácticos de aplicación en diferentes contextos

Ejemplo 1. Clasificación de correos electrónicos

- Contexto: **identificar si un correo electrónico es spam o no.**
Ejemplo: un modelo de aprendizaje supervisado puede entrenarse con correos electrónicos previamente etiquetados como spam o no spam. Luego, puede predecir la categoría de nuevos correos electrónicos.



- Ejemplos prácticos de aplicación en diferentes contextos

Ejemplo 2. Diagnóstico médico

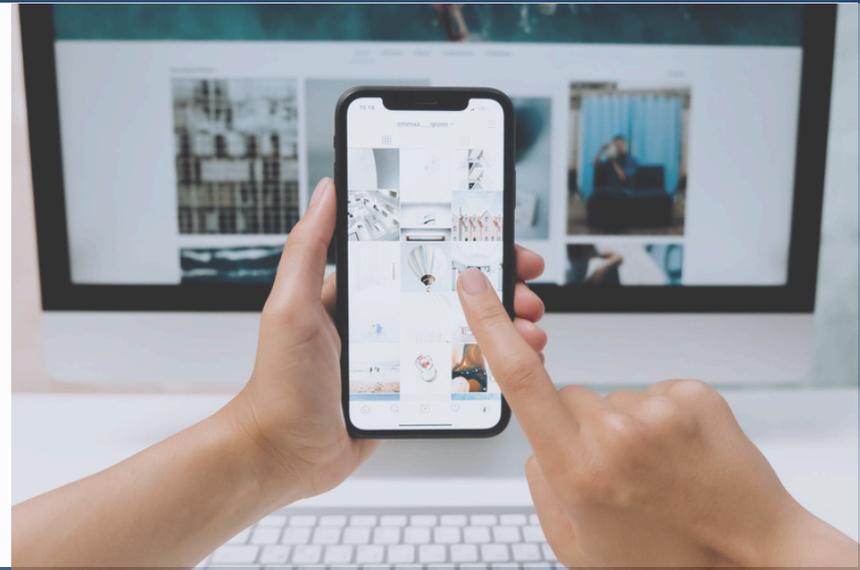
- Contexto: **predecir si un paciente tiene una enfermedad específica.**
- Ejemplo: **utilizando datos médicos previos, un modelo puede aprender a asociar ciertos síntomas y resultados de pruebas con diagnósticos específicos para ayudar en el diagnóstico de nuevos pacientes.**



- Ejemplos prácticos de aplicación en diferentes contextos

Ejemplo 3. Reconocimiento de imágenes

- Contexto: **identificar objetos en imágenes.**
- Ejemplo: un modelo puede entrenarse con un conjunto de imágenes etiquetadas con objetos específicos como perros, gatos, automóviles, etc. Luego, puede identificar estos objetos en nuevas imágenes.



- Ejemplos prácticos de aplicación en diferentes contextos

Ejemplo 4. Análisis de sentimientos en redes sociales

- Contexto: **determinar el tono emocional de un mensaje.**
- Ejemplo: un modelo de aprendizaje supervisado puede entrenarse con mensajes previamente etiquetados como positivos, negativos o neutros en redes sociales. Después, puede clasificar automáticamente el tono de nuevos mensajes.



- Ejemplos prácticos de aplicación en diferentes contextos

Ejemplo 5. Predicción del tiempo

- Contexto: prever las condiciones meteorológicas futuras.
- Ejemplo: utilizando datos históricos de temperatura, presión atmosférica, etc. Un modelo puede aprender a predecir el clima futuro, lo que es esencial para pronósticos precisos.



- Ejemplos prácticos de aplicación en diferentes contextos

Ejemplo 6. Recomendación de productos

- Contexto: **sugerir productos a usuarios en plataformas de comercio electrónico.**
- Ejemplo: **un modelo puede entrenarse con datos de comportamiento de usuarios y sus compras pasadas para predecir productos que podrían interesarles.**



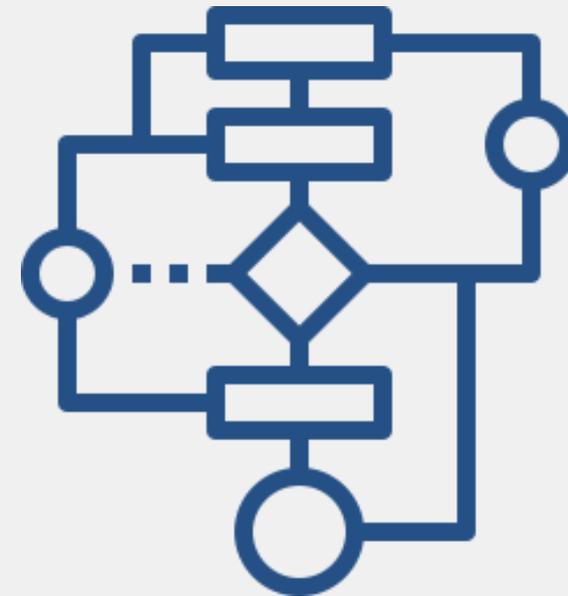
- Algoritmos de aprendizaje supervisado

Árbol de decisión de aprendizaje

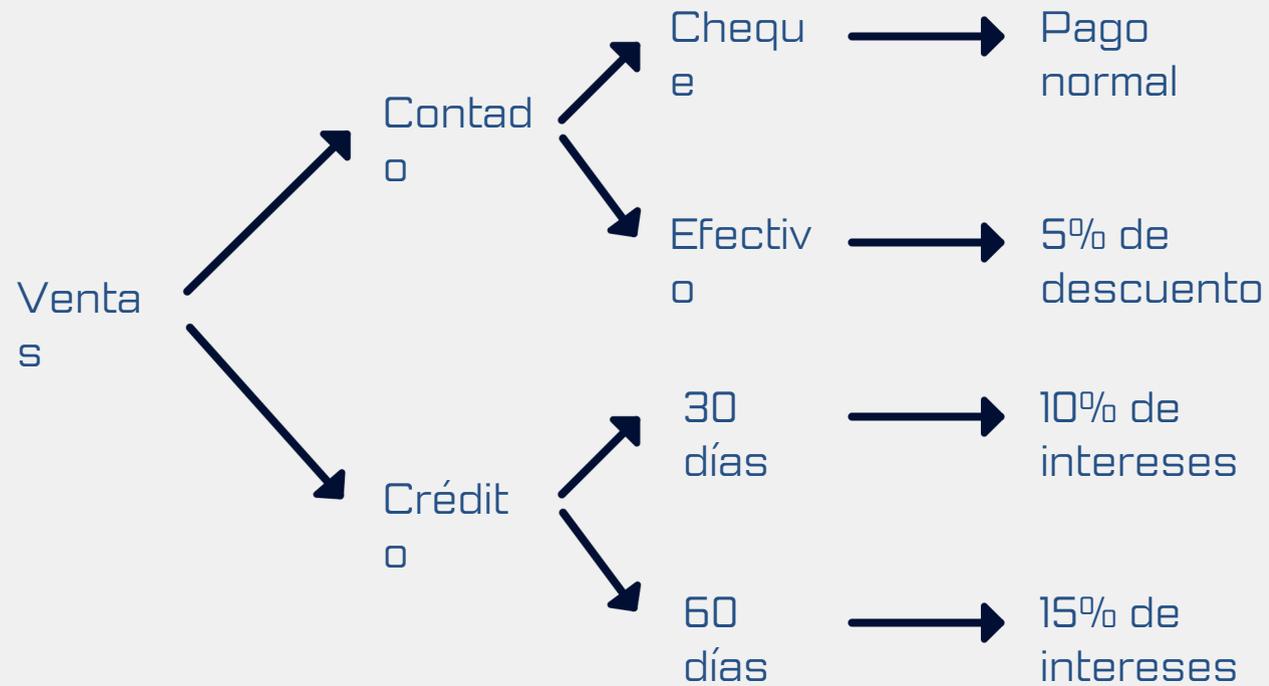
Clasificador Naive Bayes

Máquina de soporte vectorial

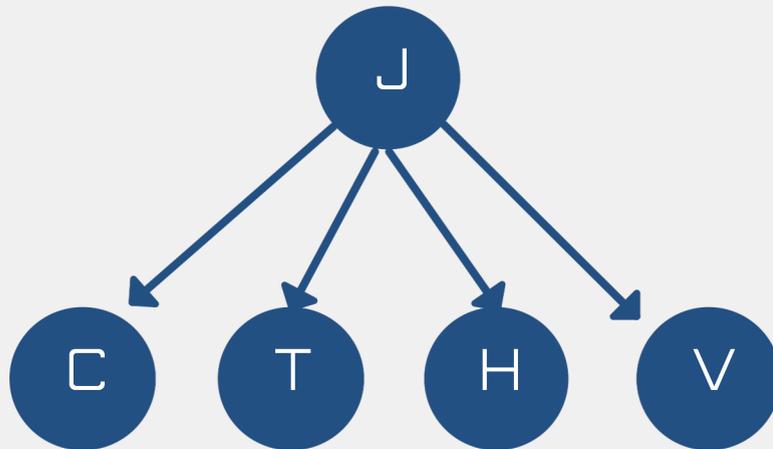
Vecinos cercanos



- Árbol de decisión de aprendizaje

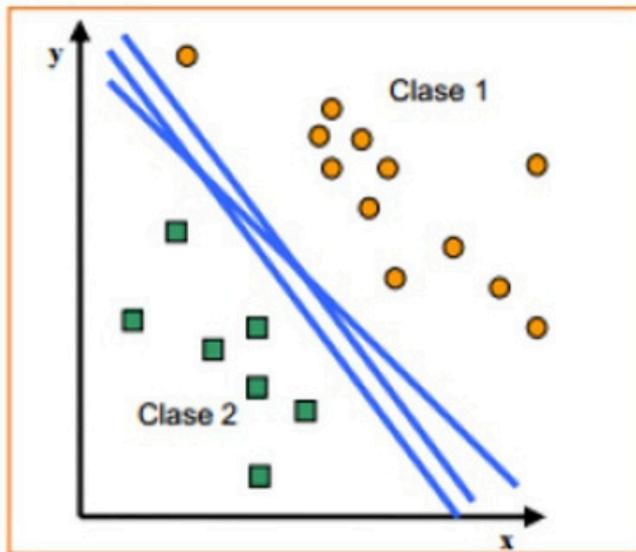


- Clasificador Naive Bayes

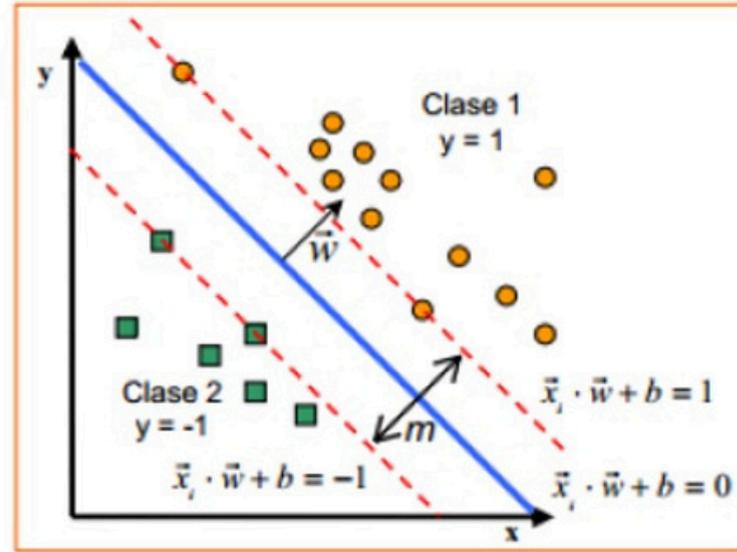


Cielo	Temperatura	Humedad	Viento	Se Jugó
Lluvia	Calor	Alta	No	No
Lluvia	Calor	Alta	Si	No
Nublado	Calor	Alta	No	Si
Soleado	Templado	Alta	No	Si
Soleado	Frio	Normal	No	Si
Soleado	Frio	Normal	Si	No
Nublado	Frio	Normal	Si	Si
Lluvia	Templado	Alta	No	No
Lluvia	Frio	Normal	No	Si
Soleado	Templado	Normal	No	Si
Lluvia	Templado	Normal	Si	Si
Nublado	Templado	Alta	Si	Si
Nublado	Calor	Normal	No	Si

- Máquina de soporte vectorial

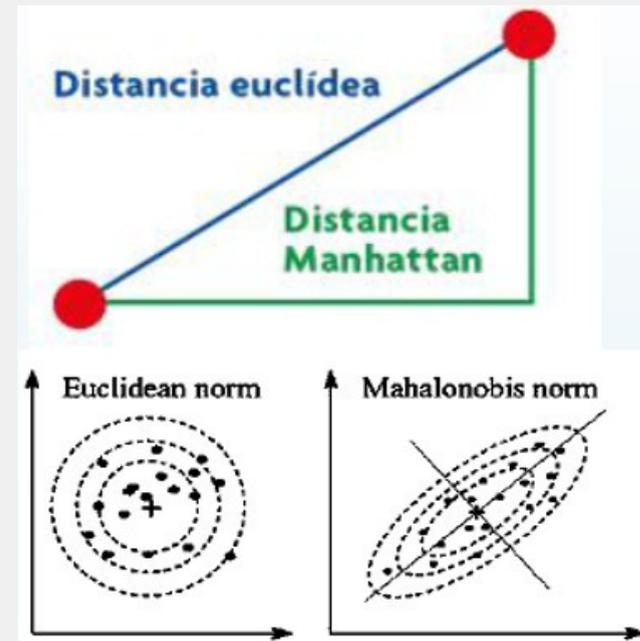
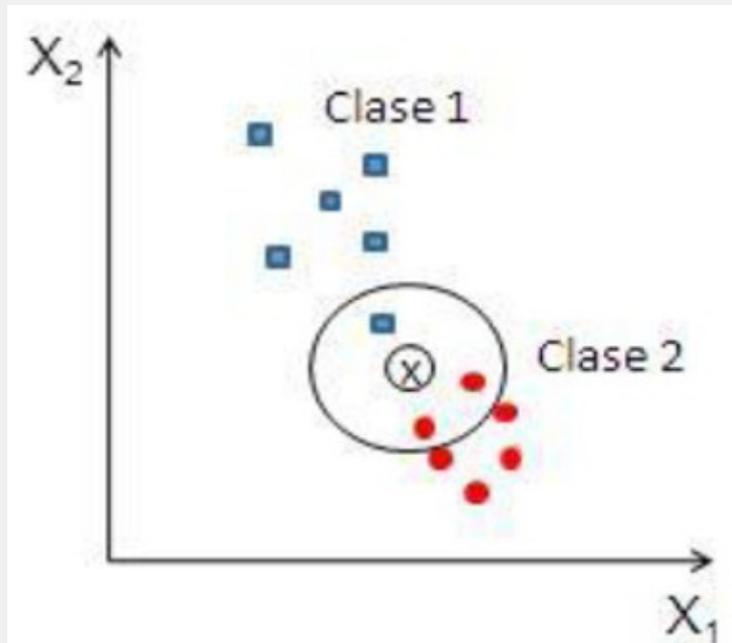


Posibles hiperplanos de separación



Hiperplano de separación óptimo

- Vecinos cercanos



Tema 3. Evaluación del rendimiento del modelo

Cuando trabajamos con modelos de aprendizaje supervisado, es crucial evaluar su rendimiento para entender cuán bien generaliza a datos no vistos. En este tema, conoceremos algunas métricas comunes de evaluación y cómo interpretarlas.

¡Sigamos avanzando!



[🏠 Volver a Contenido](#)

- La medida de rendimiento, R

Medidas cuantitativas

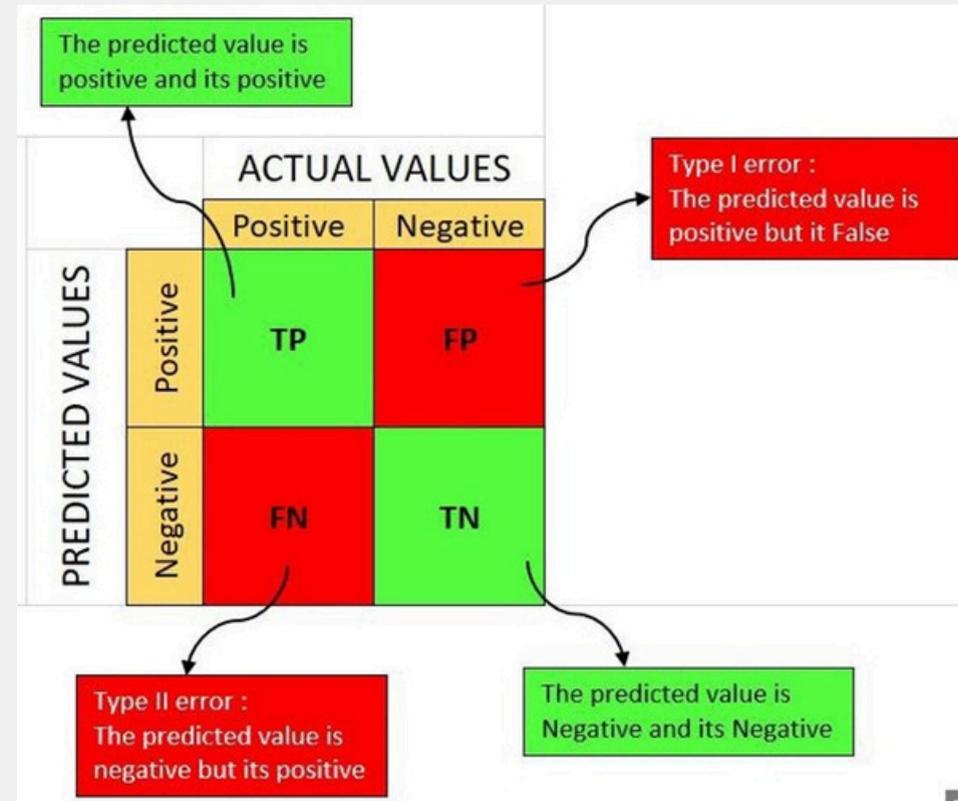
$$\text{Precisión} = \frac{\text{Resultados Correctos}}{\text{Total de ejemplos}}$$

$$\text{Tasa de error} = \frac{\text{Resultados Incorrectos}}{\text{Total de ejemplos}}$$

- Matriz de confusión

Definición: una tabla que muestra las clasificaciones correctas e incorrectas hechas por un clasificador.

Interpretación: proporciona una visión detallada de cómo el modelo clasifica las instancias.



- Precisión y recall

Precisión

Definición: la proporción de instancias clasificadas correctamente como positivas sobre el total de instancias clasificadas como positivas (verdaderos positivos + falsos positivos).

Interpretación: cuántas de las predicciones positivas son realmente correctas.

Recall (sensibilidad o tasa de verdaderos positivos)

Definición la proporción de instancias positivas correctamente identificadas sobre el total de instancias positivas (verdaderos positivos + falsos negativos).

Interpretación: qué tan bien el modelo identifica todas las instancias positivas.

- F1-Score

Definición: la media armónica de precisión y recall. Es útil cuando se desea un equilibrio entre ambas métricas.

Interpretación: proporciona un equilibrio entre la precisión y el recall.

		Predicted class	
		<i>P</i>	<i>N</i>
Actual Class	<i>P</i> Sensitivity Recall	True Positives (TP)	False Negatives (FN)
	<i>N</i> Specificity	False Positives (FP)	True Negatives (TN)

Precision

- F1-Score: ejemplo de interpretación

Supongamos que estamos evaluando un modelo de clasificación binaria (spam/no spam) con las siguientes métricas:

Precisión: **0.92** Recall: **0.85** F1-Score: **0.88**

$$\begin{aligned} \textit{precision} &= \frac{TP}{TP + FP} \\ \textit{recall} &= \frac{TP}{TP + FN} \\ F1 &= \frac{2 \times \textit{precision} \times \textit{recall}}{\textit{precision} + \textit{recall}} \\ \textit{accuracy} &= \frac{TP + TN}{TP + FN + TN + FP} \\ \textit{specificity} &= \frac{TN}{TN + FP} \end{aligned}$$

- F1-Score: ejemplo de interpretación

Esto podría interpretarse como que el modelo tiene una alta precisión, lo cual es bueno para minimizar falsos positivos. Sin embargo, el recall no es tan alto, lo que indica que hay algunas instancias positivas que el modelo no identifica, el F1-Score proporciona un equilibrio general. La interpretación específica puede variar según el contexto y las necesidades específicas del problema.

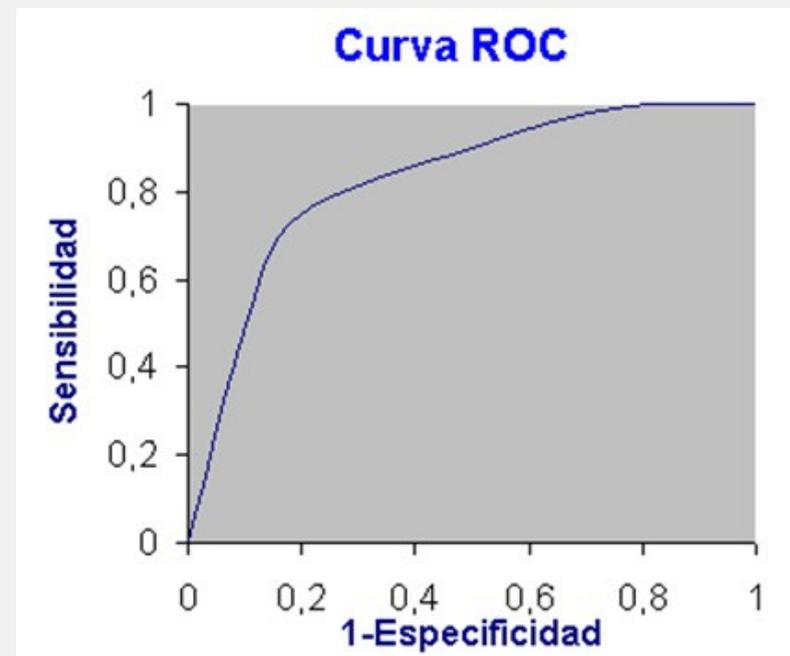
Importancia del contexto:

Las métricas deben interpretarse considerando la naturaleza del problema. Por ejemplo, en un problema médico, la recall puede ser más crítica que la precisión, ya que es fundamental identificar todas las instancias positivas, incluso si eso significa algunos falsos positivos.

- Área bajo la curva ROC (AUC-ROC)

Definición: mide la capacidad del modelo para distinguir entre clases.

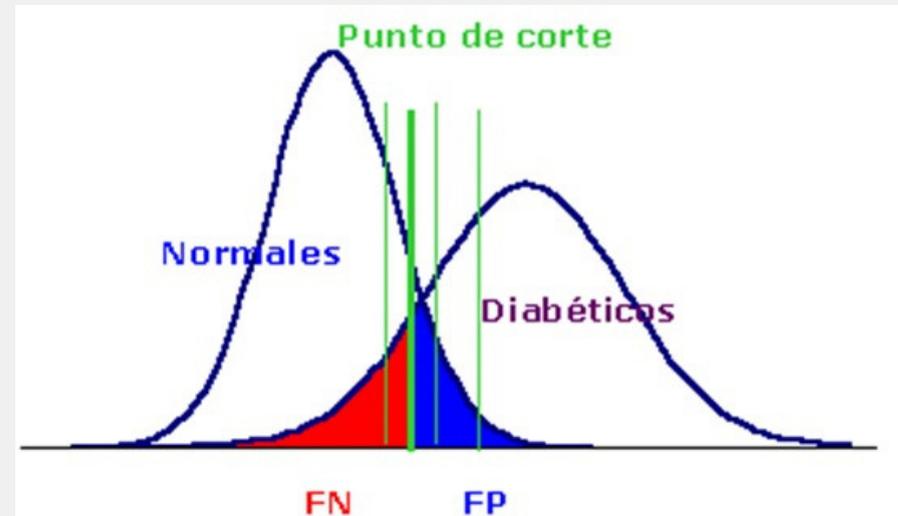
Interpretación: cuánto se desplaza el modelo entre verdaderos positivos y falsos positivos a través de diferentes umbrales.



3.1. Curvas ROC

En la clase anterior, se consideró que el resultado de las pruebas diagnósticas eran categóricos. Sin embargo, muchas pruebas producen resultados continuos, p.e. nivel de glucosa en sangre para diagnosticar la diabetes.

El comportamiento de dichas pruebas depende de donde se ponga el punto de corte y lo habitual es que exista un grado variable de solapamiento en la fdp de la variable resultado. En el caso de la glucosa la situación se esquematiza en la gráfica.

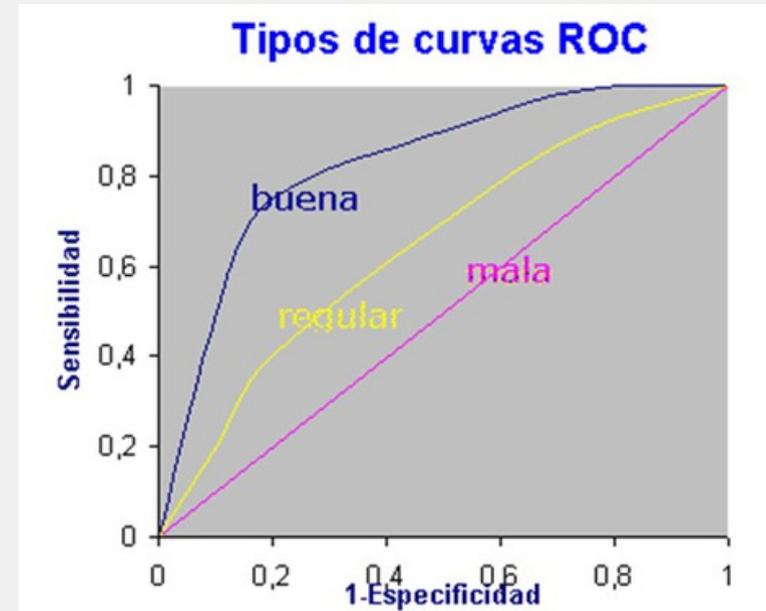


- Curvas ROC

Si se desplaza el punto de corte a la derecha (valores mayores de glucosa), disminuyen los falsos positivos (región azul) pero aumentan los falsos negativos (región roja) o, en otros términos, disminuye la sensibilidad y aumenta la especificidad e inversamente si se desplaza a la izquierda; de modo que, un problema en estas pruebas es la selección del punto de corte óptimo.

Para caracterizar su comportamiento, se usan las llamadas curvas ROC (Receiver Operating Characteristic), desarrolladas por los operadores de radar e introducidas en la investigación clínica por los radiólogos (Hanley y McNeil): son curvas en las que se presenta la sensibilidad en función de los falsos positivos (complementario de la especificidad) para distintos puntos de corte.

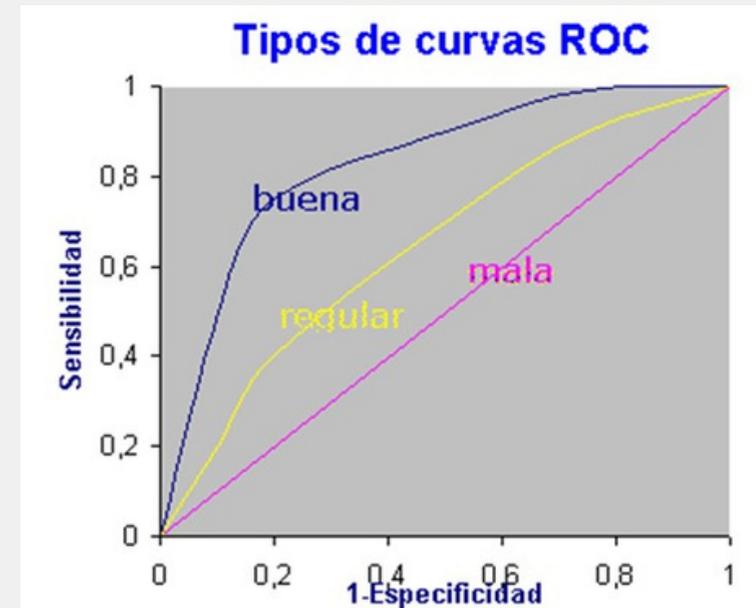
- Información contenida en la curva
 - Si la prueba fuera perfecta, es decir, sin solapamiento, hay una región en la que cualquier punto de corte tiene sensibilidad y especificidad iguales a 1: la curva solo tiene el punto (0,1).
 - Si la prueba fuera inútil, ambas fdp's coinciden y la sensibilidad (verdaderos positivos) es igual a la proporción de falsos positivos, la curva sería la diagonal de (0,0) a (1,1).
 - Las pruebas habituales tienen curvas intermedias.



- Bondad de la curva

Un parámetro para evaluar la bondad de la prueba es el área bajo la curva que tomará valores entre 1 (prueba perfecta) y 0,5 (prueba inútil).

Puede demostrarse, (Hanley y McNeil) que esta área puede interpretarse como la probabilidad de que ante un par de individuos, uno enfermo y el otro sano, la prueba los clasifique correctamente.

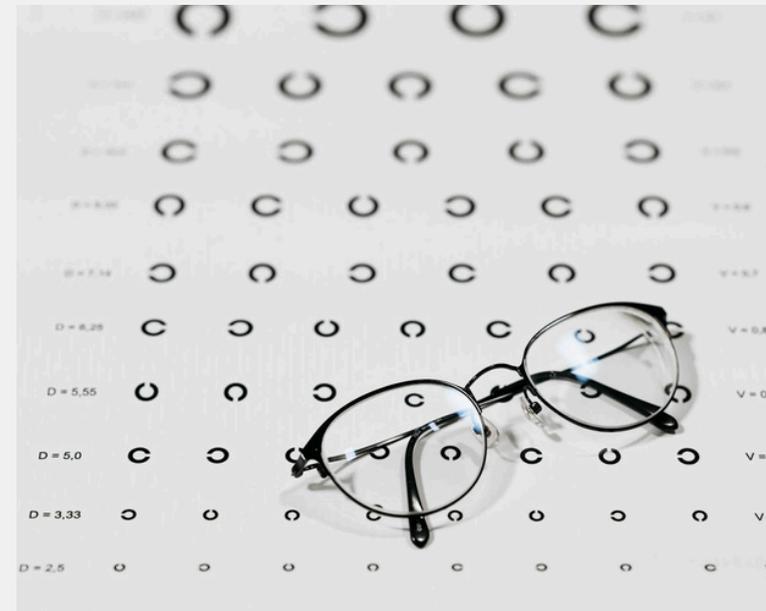


- Utilidades y limitaciones de las curvas ROC

Utilidades:

- Comparar dos pruebas o dos puntos de corte. Comparación de dos curvas o de dos puntos sobre una curva.
- Elegir el punto de corte apropiado para un determinado paciente.

Limitaciones de su uso: solo contemplan dos estados clínicos posibles (sano y enfermo) y no sirven para situaciones en que se trata de discernir entre más de dos enfermedades.



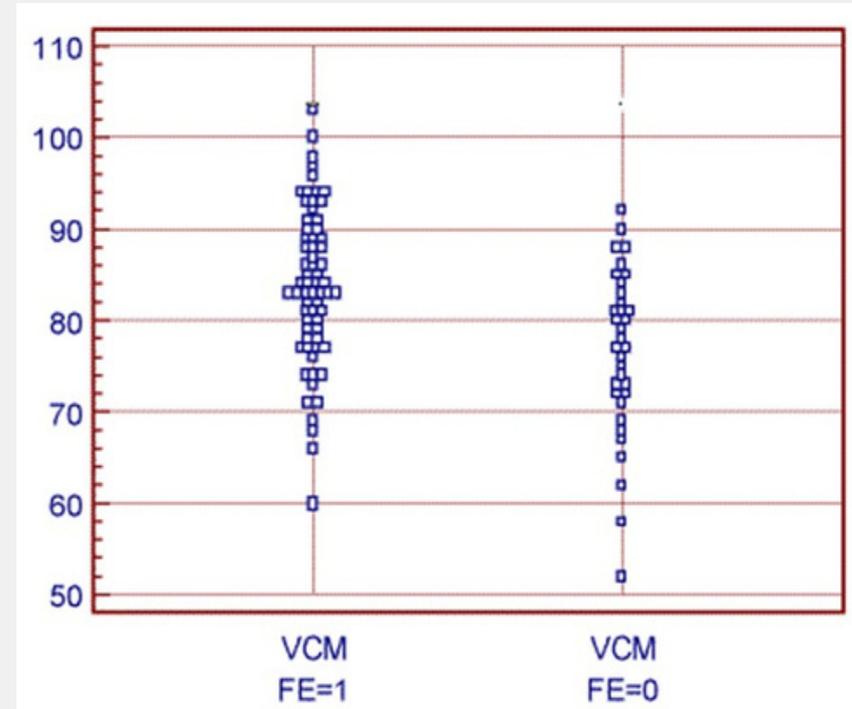
- Ejemplo

Evaluación del volúmen corpuscular medio (VCM) en el diagnóstico de anemia ferropénica. Se usa como "patrón de oro" la existencia de depósitos de hierro en la médula ósea.

Tabla de datos (hipotética): VCM

Sin Fe (n=34): 52, 58, 62, 65, 67, 68, 69, 71, 72, 72, 73, 73, 74, 75, 76, 77, 77, 78, 79, 80, 80, 81, 81, 81, 82, 83, 84, 85, 85, 86, 88, 88, 90, 92.

Con Fe (n=66): 60, 66, 68, 69, 71, 71, 73, 74, 74, 74, 76, 77, 77, 77, 77, 78, 78, 79, 79, 80, 80, 81, 81, 81, 82, 82, 83, 83, 83, 83, 83, 83, 84, 84, 84, 84, 85, 85, 86, 86, 86, 87, 88, 88, 88, 89, 89, 89, 90, 90, 91, 91, 92, 93, 93, 93, 94, 94, 94, 94, 96, 97, 98, 100, 103.

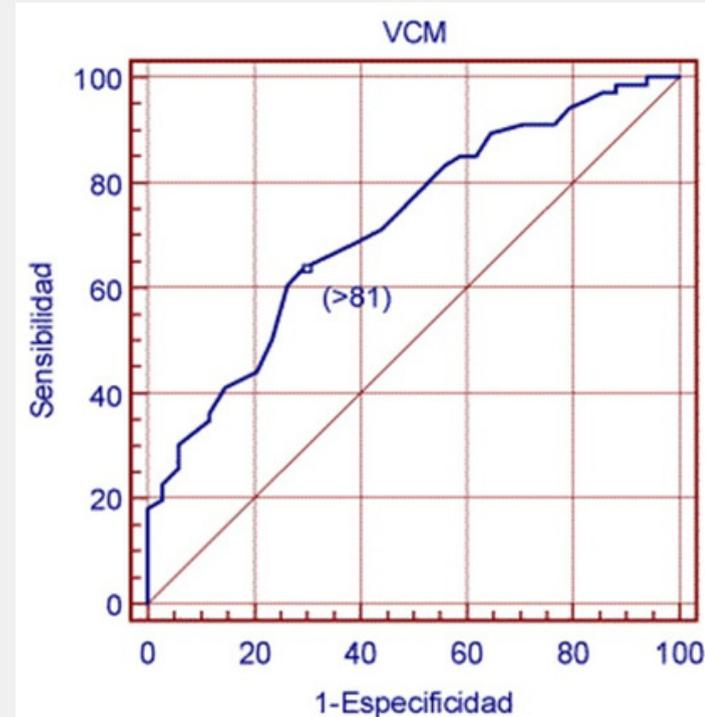


Donde se observa solapamiento. Para diversos puntos de corte (es decir, decidiendo que hay anemia cuando el VCM es menor que el punto de corte), las sensibilidad y proporciones de falsos positivos figuran en la siguiente tabla:

Punto Corte	Sensibilidad	1-Especificidad
65	$3/34=0,088$	$1/66=0,015$
70	$7/34=0,206$	$4/66=0,061$
75	$13/34=0,382$	$10/66=0,152$
80	$19/34=0,559$	$19/66=0,288$
85	$27/34=0,794$	$37/66=0,561$
90	$32/34=0,941$	$49/66=0,742$
92	$33/34=0,971$	$53/66=0,803$

La anterior tabla de información produce la siguiente curva ROC, cuya área es 0,717 con un EE de 0,05, es decir no es una prueba demasiado buena. Si se quisiera comparar esta prueba con otra, p.e. niveles séricos de ferritina, se construiría para ella otra curva y se calcularía su área.

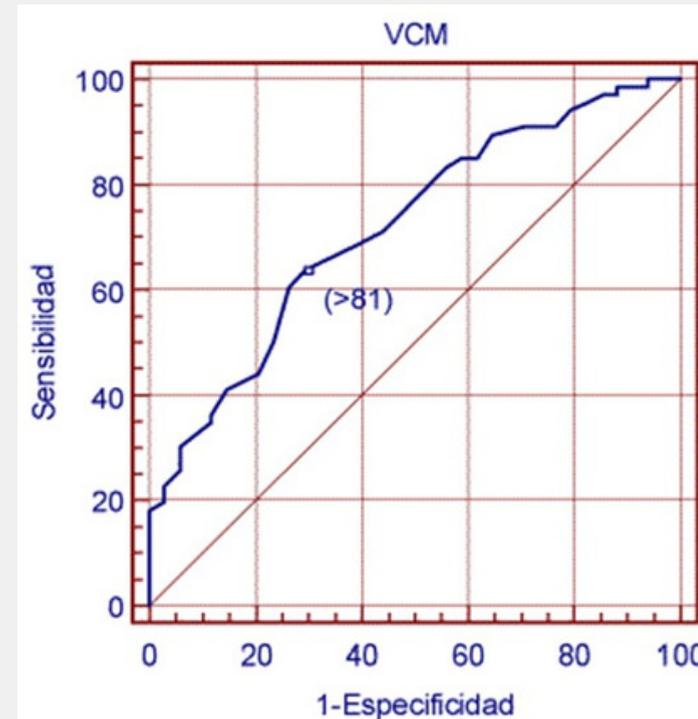
Veamos, a continuación, cómo hacerlo.



Supongamos $A=0,868$ y $EE(A)=0,04$. El estadístico para compararlas es (si ambas curvas han sido estimadas independientemente, es decir, con distintos sujetos, en caso contrario, véase Hanley J.A., McNeil B.J. (1983)):

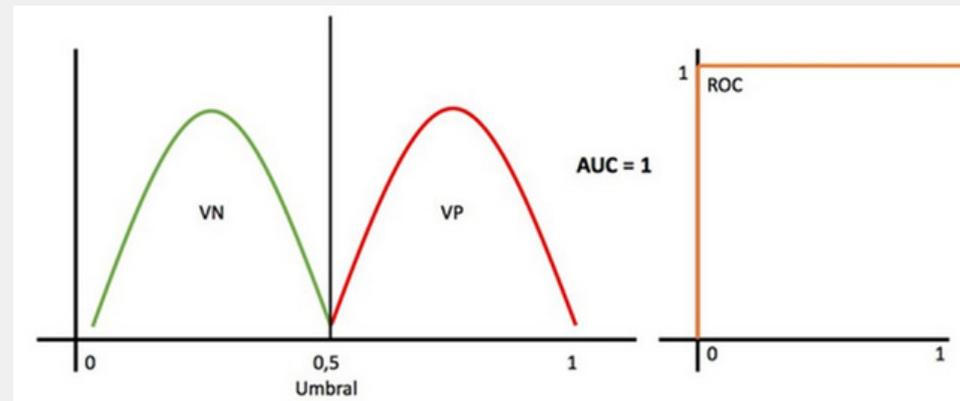
$$z = \frac{A_1 - A_2}{\sqrt{EE(A_1)^2 + EE(A_2)^2}} \propto N(0,1)$$

Que en este ejemplo vale 2,34 que como es mayor que 1,96 ambas pruebas tienen un rendimiento significativamente distinto.



3.2. Área bajo la curva (AUC)

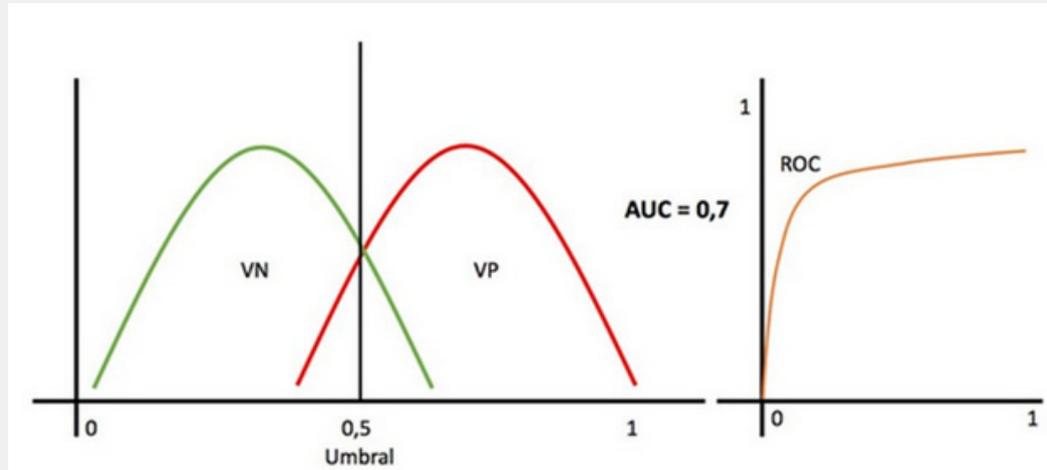
El AUC es el área bajo la curva ROC. Este puntaje nos da una buena idea de qué tan bien funciona el modelo. Veamos algunos ejemplos de esto:



Esta es una situación ideal. Cuando dos curvas no se superponen en absoluto, el modelo tiene una medida ideal de separación, y es perfectamente capaz de distinguir entre clase positiva y clase negativa.



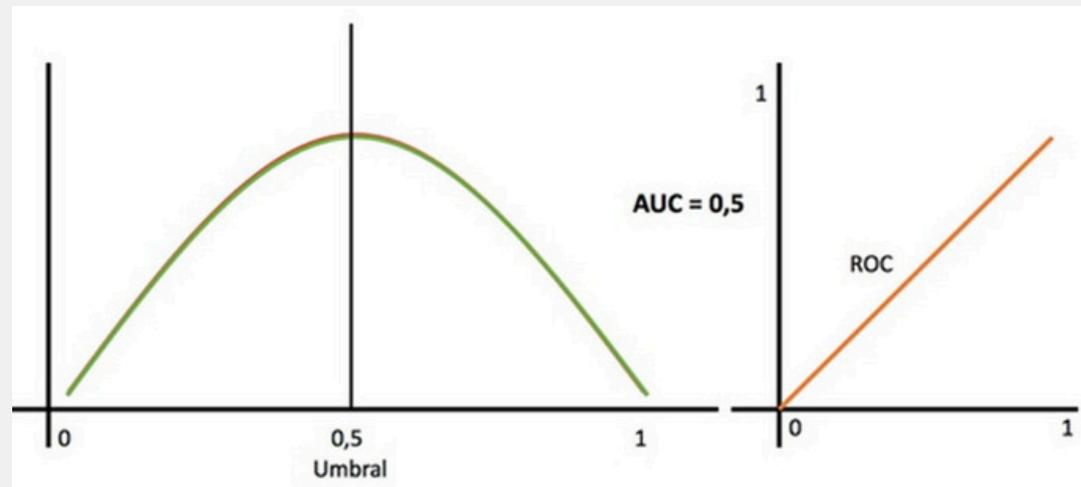
Este es un segundo ejemplo de área bajo la curva:



Cuando dos distribuciones se superponen, introducimos errores; dependiendo del umbral, podemos minimizarlos o maximizarlos. Cuando AUC es 0.7, significa que hay 70% de probabilidad de que el modelo pueda distinguir entre clase positiva y clase negativa.

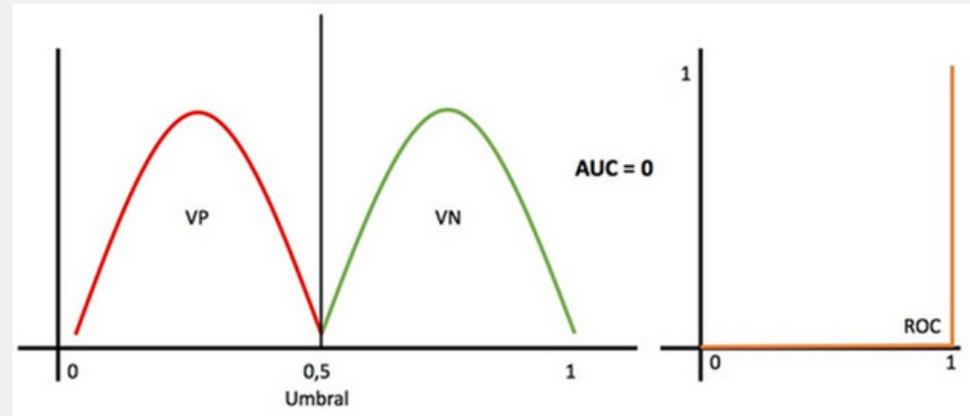


Veamos un tercer caso:



Esta es la peor situación. Cuando el AUC es aproximadamente 0.5, el modelo no tiene capacidad de discriminación para distinguir entre clase positiva y clase negativa.

Un cuarto ejemplo se presenta cuando AUC es aproximadamente 0, el modelo en realidad está correspondiendo a las clases; significa que el modelo predice la clase negativa como una clase positiva y viceversa.



Cuando AUC es aproximadamente 0, el modelo en realidad está correspondiendo a las clases; significa que el modelo predice la clase negativa como una clase positiva y viceversa.

- Este método es conveniente por las siguientes razones:

- Es invariable con respecto a la escala. Mide qué tan bien se clasifican las predicciones, en lugar de sus valores absolutos.
- Es invariable con respecto al umbral de clasificación. Mide la calidad de las predicciones del modelo sin tener en cuenta qué umbral de clasificación se elige.



Tema 4. Preprocesamiento de datos

El preprocesamiento de datos desempeña un papel fundamental en el éxito de los modelos de aprendizaje supervisado.

Los conjuntos de datos reales a menudo contienen valores faltantes. El preprocesamiento puede abordar este problema mediante técnicas como la imputación de datos o la eliminación de instancias incompletas.



[🏠 Volver a Contenido](#)

- Conozcamos los aspectos más importantes del preprocesamiento de datos

Normalización y escalado	Codificación de variables categóricas	Gestión de datos desbalanceados
<p>Diferentes características pueden tener escalas diferentes. La normalización y el escalado aseguran que todas las características contribuyan de manera equitativa al modelo, evitando la dominación de características con magnitudes mayores.</p>	<p>Los algoritmos de aprendizaje supervisado generalmente requieren que las variables categóricas se conviertan en formatos numéricos. El preprocesamiento incluye técnicas como la codificación one-hot para manejar estas variables.</p>	<p>En problemas con clases desbalanceadas, donde una clase tiene muchos más ejemplos que la otra, el preprocesamiento puede incluir técnicas como el submuestreo, sobre muestreo o generación de datos sintéticos para abordar este problema.</p>

- Ejemplos de mejora de rendimiento
 - Eliminación de *outliers*: un conjunto de datos puede contener valores atípicos que afectan negativamente el rendimiento del modelo. El preprocesamiento mediante la eliminación de outliers mejora la capacidad del modelo para generalizar.
 - Normalización de texto: En problemas de procesamiento de lenguaje natural (NLP), normalizar el texto mediante la eliminación de puntuación, la conversión a minúsculas y la lematización puede mejorar la calidad de las características y la eficacia del modelo.



- Ejemplos de mejora de rendimiento

- Imputación de datos faltantes: **en conjuntos de datos con valores faltantes, el preprocesamiento mediante técnicas de imputación (media, mediana, etc), garantiza que el modelo no se vea afectado negativamente por la falta de información.**
- Selección de características: **algunas características pueden ser irrelevantes o redundantes. El preprocesamiento mediante técnicas de selección de características optimizan el conjunto de características, mejorando la eficiencia del modelo y reduciendo la posibilidad de sobreajuste.**



El preprocesamiento de datos es esencial para garantizar que los conjuntos de datos sean adecuados y efectivos para la construcción de modelos de aprendizaje supervisado.

Este mejora la calidad de los datos, aborda problemas específicos y contribuye significativamente al rendimiento y la generalización del modelo. Considerar cuidadosamente las necesidades específicas del conjunto de datos y del modelo es clave para un preprocesamiento efectivo.

