

Fundamentos del Machine Learning

Que es la inteligencia artificial

- IA General: Trata de desarrollar un sistema que presenta la flexibilidad y versatilidad de la inteligencia humana para resolver un amplio rango de problemas cognitivos complejos.
- IA Especializada: Trata de desarrollar sistemas que pueden ser usados solo para las tareas para los que fueron diseñados.

Que es el machine learning

Es una rama de la IA que trata de desarrollar algoritmos que permitan a las máquinas aprender. Se busca desarrollar modelos computacionales que sean capaces de resolver problemas complejos usando como base ejemplos.

Cuando es apropiado usar machine learning

- Si no se tiene suficiente conocimiento explícito para obtener un algoritmo para resolver el problema, pero se tienen ejemplos de como se resuelve.
- Si el problema a resolver varía con el tiempo.
- Si los datos llegan continuamente y contienen nueva información que permite mejorar el sistema con el tiempo.

Generalización

Término usado para describir la capacidad de un modelo para clasificar o predecir nuevos datos correctamente. Hay 2 conceptos importantes relacionados con la generalización:

- Underfitting: El modelo no trabaja bien con los datos.
- Overfitting: El modelo trabaja demasiado bien con los datos, los memoriza, pero hace predicciones poco fiables con datos nuevos.

Hay que encontrar un balance entre estos 2 conceptos.

Preparación y limpieza de datos

Antes de usar datos para entrenar un modelo, suele ser necesario realizar ciertas preparaciones de los datos como:

- Normalizar los datos (Scaling)
- REcodificar las variables no-numéricas
- Eliminación de ruido y datos sin sentido

- Imputación de datos

Modelos lineales de aprendizaje supervisado

Primero debemos conocer las notaciones y definiciones:

- Vectores: Vienen como matrices en columna
 - Producto de vectores:

$$\begin{matrix} \mathbf{x} \\ \mathbf{y} \end{matrix} = \begin{bmatrix} x_1 & x_2 & \dots & x_m \\ y_1 & y_2 & \dots & y_m \end{bmatrix}$$
$$\mathbf{x} \cdot \mathbf{y} = x_1 y_1 + x_2 y_2 + \dots + x_m y_m$$

- Norma de un vector

$$\|x\| = \sqrt{X^T X} = \sqrt{X_1^2 + x_2^2 + X^2_m}$$

Métodos de regresión lineal

Tienen como objetivo predecir una o más variables continuas dado el valor de un set explicativo de variables representado por un vector X con dimensión m

$$X = \begin{bmatrix} x_1 & x_2 & \dots & x_m \end{bmatrix}$$

Para predecir los valores de las variables tenemos los siguientes elementos clave:

- **Variables explicativas:** variables de entrada del modelo
- **Ejemplos de entrenamiento:** Un grupo de n datos $x_1 \dots x_n$ de las variables explicativas para el cual el valor de la variable a ser predecido es conocido t_1, \dots, t_n
- **Un Modelo:** Es una función parametrizable W que representa la relación entre x y t
- **Función objetivo** (o error o coste) que indica como de bien tiene que aproximar el modelo los datos de entrenamiento
- **Un método de optimización** para encontrar el modelo óptimo minimizando la función objetivo.



- **Proceso de entrenamiento:** El objetivo es construir el modelo para obtener los parámetros W óptimos para predecir el valor de t para un nuevo valor de x . Esto requiere un dataset de entrenamiento compuesto por n observaciones $x_1 \dots x_n$ y un set de valores predecidos t_1, \dots, t_n (Aprendizaje supervisado)

Métodos de clasificación lineal

Clasificación supervisada

Es similar a la regresión excepto en que el valor predecido toma valores dentro de un pequeño set discreto de datos. En el caso específico de clasificación binarias solo hay 2 posibles valores para cada ítem, por ejemplo:

- $t_i=0$ para datos de clase negativa
- $t_i=1$ para datos de clase positiva

Es una clasificación supervisada por que las etiquetas están disponibles para los datos entrenados.

Regiones de decisión

- Métodos de aprendizaje lineal: Las superficies de decisión generadas son funciones lineales de datos (hyperplanos)
- Métodos de aprendizaje no lineal: Las superficies de decisión que generan son funciones no lineales de los datos.

Conclusión sobre los clasificadores lineales

- Least Squares: No es una buena elección en general para clasificaciones ya que es muy sensible a los desbalances
- Regresión logística: El método más robusto ya que no es sensible a desbalances.

Métricas para la evaluación del error

Primero es necesario diferenciar entre error de función y métrica de evaluación:

- La función de pérdida es la función usada para optimizar el modelo. Minimizada durante el entrenamiento y, en general, es diferenciable en los parámetros del modelo
- Las Métricas de evaluación son utilizadas para juzgar el rendimiento del modelo. No interviene durante la optimización del proceso del modelo y no necesita ser diferenciable.

Métricas de error de evaluación para regresión

- **Mean Squared Error (MSE):** Es la siguiente función donde y_i es la salida del modelo y t_i es la salida actual para el dato i . Pesa los errores grandes de forma más pesada debido al uso del error cuadrado.

$$MSE = \frac{1}{n} \sum_{i=1}^n (t_i - y_i)^2$$

- **Root Mean Squared Errors (RMSE):** Ventaja sobre MSE, facilita la interpretación ya que el error obtenido es relativo a las unidades de los datos.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (t_i - y_i)^2}$$

- **Mean Absolute Error (MAE):** Trata todos los errores de la misma forma, mientras que MSE y RMSE le dan una mayor penalización a los errores altos. Poco adecuada si se quiere prestar atención a errores de predicción potencialmente grandes.

$$MAE = \frac{1}{n} \sum_{i=1}^n |t_i - y_i|$$

- **Mean Absolute Percentage Error (MAPE):** Tiene como ventajas que, al ser un porcentaje, es independiente de la escala de los datos, es fácil de interpretar, aunque su valor puede ser mayor del 100% y que es resistente a los errores de outlier. También tiene varios puntos negativos, por ejemplo, hay problemas con la división si hay valores a ser predichos equivalentes 0, si los valores son pequeños puede tener valores demasiado grandes y no es fiable frente a predicciones sistemáticamente más pequeñas que los valores actuales.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{t_i - y_i}{t_i} \right|$$

• **Symmetric Mean Absolute Percentage Error (SMAPE):**

- Ventajas:
 - Interpretación clara al ser porcentajes
 - No afectado por outliers
 - Genera valores entre 0% y 100% solucionando el problema de MAPE
 - Es simétrico con respecto a predicciones bajas o altas.
- Desventajas:
 - Tiene problemas con la división si la predicción y el valor actual son equivalentes a 0
 - No es simétrico ya que las sobrepredicciones e infrapredicciones no se tratan de forma equivalente.

$$SMAPE = \frac{100}{n} \sum_{i=1}^n \frac{|t_i - y_i|}{|t_i| + |y_i|}$$

Métricas de evaluación del error para la clasificación supervisada

Tenemos una matriz de confusión para dos clases de problemas:

- **Error de tipo I:** Falsos positivos (FP)
- **Error de tipo II:** Falsos Negativos (FN)

Predicción de clasificador/Clase Real	Positivo	Negativo
Positivo	Verdaderos Positivos (TP)	Falsos positivos (FP)
Negativo	Falsos negativos(FN)	Verdaderos negativos (TN)

- **Precisión:** Tasa global de aciertos del sistema. Es problemática cuando se trabaja con datasets desbalanceados.

$$Precisión = \frac{\text{Aciertos Globales}}{\text{Casos Totales}} = \frac{TP+TN}{TP+TN+FP+FN}$$

- **Sensibilidad:** de todos los ejemplos positivos cuantos fueron predecidos como positivos.

$$Sensibilidad = \frac{\text{Aciertos de casos positivos}}{\text{Casos positivos}} = \frac{TP}{TP+FN}$$

From:

<https://www.knoppia.net/> - **Knoppia**

Permanent link:

https://www.knoppia.net/doku.php?id=pan:machine_learning_v2&rev=1767815455



Last update: **2026/01/07 19:50**