

Regressione lineare come strumento per il Machine Learning (Apprendimento Automatico)

AI artificiale intelligence

Disciplina che si occupa della progettazione di software / hardware che possano prendere decisioni in maniera autonoma.

Machine Learning (ML) è una branca dell'AI,
(TOM MITCHELL)

ML si preoccupa di progettare algoritmi che si perfezionano in maniera automatica con l'esperienza.

L'idea è quella di fare acquisire alla macchina o al software la capacità di eseguire un

Compito prefissato (Decidere se un' e-mail è spam o meno; predire il costo di un appartamento...)

Un primo modo per raggiungere il nostro obiettivo è quello di

1. Scrivere delle regole ben precise da seguire.
2. Fornire dei dati al software e lasciare che il software impari in maniera autonoma dai dati a disposizione.

ML ^{affronta} due problemi principali

a) CLASSIFICAZIONE

Es. Spam / Non Spam

Melanoma / Non melanoma

Frode / Non Frode

b) REGRESSIONE
(Predire il valore di un dato)

Es Costo di un appartamento

REGRESSIONE LINEARE

(Altezza padre)
Dati: $x_1 \text{ --- } x_2 \text{ --- } \dots (x_1 \text{ --- } x_N)$

In generale N è molto grande

(Altezza studente)
 $y_1 \text{ --- } y_2 \text{ --- } \dots (y_1 \text{ --- } y_N)$

Cerchiamo l'equazione di una retta

$$Y = mX + q$$

che approssimi l'andamento dei dati.

Dalla Google Sheet infatti ci è sembrato di riconoscere

una dipendenza di tipo
lineare delle y dalle x
(Scatter plot)

In realtà $\forall i=1, \dots, 20$

$$(*) \quad y_i = mx_i + q + \underline{e_i}$$

e_i : errore per l' i -esimo dato

Obiettivo : cercare m e q

IDEA : li cerco in modo tale
da minimizzare gli errori
commessi.

Def Sia

$$E = \frac{1}{20} \sum_{i=1}^{20} (y_i - (mx_i + q))^2 =$$

$$\frac{1}{20} \sum_{i=1}^{20} e_i^2 \quad \left(\begin{array}{l} \text{Uso l'eq.ne} \\ (*) \end{array} \right)$$

È si dice errore quadratico medio.

OSSERVAZIONE

Non consideriamo gli e_i con il loro segno per evitare che errori con segno opposto si annullino. Prendiamo il quadrato (invece che ad esempio $|e_i|$) per pesare di più gli errori più grandi.

REGRESSIONE LINEARE AI MINIMI QUADRATI: Scegliamo m e q in modo tale da minimizzare E (errore quadratico medio)

Procedura: si considera E come funzione di m e q
 $E = E(m, q)$ e se ne calcolano le derivate parziali rispetto ad m e q .

^{invece}
Non utilizziamo delle definizioni di statistica.

Def $x_1 - x_{20}$

Si dice media di $x_1 - x_{20}$

$$\bar{x} = \frac{1}{20} \sum_{i=1}^{20} x_i$$

(La media di $y_1 - y_{20}$: $\bar{y} = \frac{1}{20} \sum_{i=1}^{20} y_i$)

Def Si dice varianza di $x_1 - x_{20}$

$$S_x^2 = \frac{1}{20} \sum_{i=1}^{20} (x_i - \bar{x})(x_i - \bar{x})$$

S_x^2 è una misura di quanto gli x_i si discostano dalla media \bar{x} .

Def Si dice covarianza di

$x_1 - x_{20}, y_1 - y_{20}$

$$S_{xy} = \frac{1}{20} \sum_{i=1}^{20} (x_i - \bar{x})(y_i - \bar{y})$$

Se $Y_i = mX_i + q \quad i=1, \dots, 20$

(se gli e_i fossero tutti nulli,
se (x_i, y_i) sono tutti sulla retta
di equazione $y = mx + q$)

$$\begin{aligned}
 1. \quad \bar{Y} &= \frac{1}{20} \sum_{i=1}^{20} Y_i = \frac{1}{20} \sum_{i=1}^{20} (mX_i + q) = \\
 &= \frac{1}{20} \sum_{i=1}^{20} mX_i + \frac{1}{20} \sum_{i=1}^{20} q = \\
 &= m \cdot \frac{1}{20} \sum_{i=1}^{20} X_i + q = m\bar{X} + q
 \end{aligned}$$

$$\begin{aligned}
 2. \quad S_{XY} &= \frac{1}{20} \sum_{i=1}^{20} (X_i - \bar{X})(Y_i - \bar{Y}) = \\
 &\quad \begin{matrix} Y_i = mX_i + q \\ \bar{Y} = m\bar{X} + q \end{matrix} \quad \frac{1}{20} \sum_{i=1}^{20} (X_i - \bar{X})(mX_i + q - m\bar{X} - q) = \\
 &= \frac{1}{20} \sum_{i=1}^{20} (X_i - \bar{X}) m (X_i - \bar{X}) = \\
 &= m \frac{1}{20} \sum_{i=1}^{20} (X_i - \bar{X})(X_i - \bar{X}) = \\
 &= m S_X^2
 \end{aligned}$$

Dalla 2. $S_{xy} = m S_x^2$

$$\Rightarrow \boxed{m = \frac{S_{xy}}{S_x^2}}$$

Dalla 1. $\bar{y} = m \bar{x} + q$

\Rightarrow Posso ricavare q da \bar{y}, m, \bar{x}

$$\boxed{q = \bar{y} - m \bar{x}}$$

Se $y_i = m x_i + q$ possiamo ricavare
 m e q da $\bar{x}, \bar{y}, S_x^2, S_{xy}$

TEOREMA $(x_i, y_i), i=1, \dots, 20$

La retta di regressione lineare
 (quella che minimizza l'errore
 medio quadratico) è

$$y = mx + q$$

com $\boxed{m = \frac{S_{xy}}{S_x^2}} \mid , \boxed{q = \bar{y} - m\bar{x}}$

dove $\bar{x}, \bar{y}, S_{xy}, S_x^2$ sono state definite precedentemente.

Con i nostri dati $\bar{x} \approx 179.85$

$$S_x^2 \approx 42.63$$

$$S_{xy} \approx 37.63$$

$$\bar{y} \approx 145.2$$

$$m = \frac{S_{xy}}{S_x^2} \approx 0.8828$$

$$q = \bar{y} - m\bar{x} \approx 145.2 - 0.8828(179.85) \\ \approx -13.56$$

$$Y = m_1 x_1 + m_2 x_2 + q$$

Si risolve un opportuno sistema

lineare per trovare m_1, m_2 e q

(MINIMI QUADRATI
REGRESSIONE MULTILINEARE)

cinzia.elia@uniba.it