

Corso di Bioinformatica

Machine Learning: apprendimento, generalizzazione e stima dell'errore di generalizzazione

Giorgio Valentini

DI – Università degli Studi di Milano

Metodi di machine learning

- I metodi di apprendimento automatico (Machine Learning - ML) consentono di effettuare inferenze e predizioni da un insieme limitato di dati disponibili
- Gli algoritmi di ML “apprendono” una funzione predittiva utilizzando una serie di esempi (dati) estratti secondo una determinata distribuzione di probabilità dall’ “Universo” dei dati.

Apprendimento induttivo

- Insieme finito di oggetti: $S = \{x_1, x_2, \dots, x_n\}, S \subset U$
- **Obiettivo:** apprendere una proprietà F di U (universo dei dati) dall'analisi di S tramite un algoritmo di apprendimento A .
- **Es. 1:** Dato un insieme S sottoinsieme di U (universo delle proteine) predire per un x di U se x ha struttura secondaria α o β , utilizzando un algoritmo $A(S)$.
- **Es. 2:** Dato un insieme S sottoinsieme di U (universo dei pazienti) predire per un x di U se è sano o malato, utilizzando un algoritmo $A(S)$.

Principali tipologie di problemi di ML

1. Problemi supervisionati:

Dato X sottoinsieme di U (insieme di oggetti) e $I(X)$ (etichette), predire $F(x)$ per ogni x appartenente a U .

L'algoritmo A utilizza X per costruire un predittore f che approssimi F (non nota a priori).

2. Problemi non supervisionati:

Dati X (insieme di oggetti) con $I(X)$ ignota, predire direttamente $F(x)$.

3. Problemi semisupervisionati:

Dato $X=X' \cup X''$ tale che $I(X')$ e' nota e $I(X'')$ e' ignota, predire $F(x)$

Principali problemi supervisionati

1. Problemi di classificazione: $F(x)$ è una funzione a valori discreti
2. Problemi di regressione: $F(x)$ è una funzione a valori continui
3. Problemi di stima della densità di probabilità $F(x)$

difficoltà



Apprendimento supervisionato

Apprendimento da dati “etichettati”: ciascun campione viene etichettato (ad es: normale o malato)

Supervisionato in quanto un “supervisore” assegna le etichette ai campioni da apprendere: cioè la learning machine è addestrata tramite un insieme di dati etichettati (\mathbf{x}, t)

La learning machine impara ad associare un determinato campione \mathbf{x} ad una classe t

L'obiettivo della learning machine consiste nell' *assegnare un' etichetta corretta a campioni la cui classe di appartenenza non è nota a priori* (ad es: deve essere in grado di predire sulla base dei dati di espressione genica se un paziente sia sano o malato)

Obiettivo dell' apprendimento supervisionato

Consiste nel predire correttamente campioni la cui classe di appartenenza non è nota priori (*generalizzazione*).

La generalizzazione dipende da:

- Accuratezza del classificatore sul training set
- Complessità della funzione computata dal classificatore
- Dimensione training set

In caso i dati siano caratterizzati da ridotta cardinalità e/o elevata dimensionalità, può sorgere il problema di *overfitting* (sovraadattamento)

Generalizzazione

L viene addestrata su un *training set* $D \subset U$.


La learning machine L è utile se può fare delle previsioni sull' Universo non noto U dei dati:

vogliamo cioè che *generalizzi* correttamente su dati che non conosce.

A questo fine L deve prevedere correttamente non tanto i dati D su cui è stata addestrata, ma i dati $(\mathbf{x},t) \in U$, $(\mathbf{x},t) \notin D$ che non conosce.

Poichè di solito non si conosce a priori U o equivalentemente la distribuzione di probabilità congiunta $P_U(\mathbf{x},t)$, le capacità di generalizzazione di L vengono valutate rispetto ad un test set T separato da D , cioè tale che $T \subset U$ e $T \cap D = \emptyset$.

Universo dei dati e campioni



Rischio atteso e rischio empirico

L' apprendimento di una funzione non nota $f: \mathcal{R}^d \rightarrow \mathcal{C}$ avviene tramite un algoritmo L che genera un insieme di funzioni g che approssimano f utilizzando solo un training set $D = \{(\mathbf{x}_i, t_i)\}_{i=1}^n$ distribuito secondo una distribuzione di probabilità non nota $P(\mathbf{x}, t)$:

$$g: \mathcal{R}^d \times \Omega \rightarrow \mathcal{C}$$

Ω rappresenta un insieme di parametri della learning machine (ad es., l'insieme dei pesi delle unità di calcolo di una rete neurale).

- Obiettivo dell' apprendimento non è minimizzare il rischio empirico $R_{emp}(\omega)$:

$$R_{emp}(\omega) = \frac{1}{n} \sum_{i=1}^n Loss(g(\mathbf{x}_i, \omega), t_i)$$

bensì il rischio atteso $R(\omega)$:

$$R(\omega) = \iint Loss(g(\mathbf{x}, \omega), t) p(\mathbf{x}, t) d\mathbf{x} dt$$

A parte le difficoltà matematiche della minimizzazione del funzionale $R(\omega)$, quasi sempre la funzione di densità di probabilità congiunta non è nota ...

Stima del rischio atteso

Il rischio empirico non sempre converge al rischio atteso.

La *Teoria Statistica dell' Apprendimento di Vapnik* ha mostrato che un limite superiore al rischio atteso può essere scomposto in due componenti:

$$R(\omega) \leq R_{emp}(\omega) + \Phi(h/m)$$

dove il primo termine dipende dal rischio empirico, mentre l' intervallo di confidenza Φ dipende principalmente dal rapporto fra la complessità h della learning machine e la cardinalità m del training set disponibile.



- Per valutare le capacità di generalizzazione delle learning machine è necessario stimare il rischio atteso e non semplicemente il rischio empirico.
- Il problema è: come stimare il rischio atteso ?

Due approcci principali alla stima del rischio atteso

1. Stima teorica dei limiti superiori al rischio atteso (basati sull' errore empirico e sulla stima della complessità della learning machine)
2. Stima sperimentale (basata sul campionamento dei dati disponibili)

Metodi di stima sperimentale dell' errore di generalizzazione

Holdout

Suddivisione dei dati in *training* e *test* set (tipicamente 2/3 ed 1/3)

Holdout multiplo

Holdout ripetuto n volte

Cross validation

Partizione dei dati in k sottoinsiemi disgiunti (fold)

k-fold: training con k-1 fold, test sul rimanente; il processo è ripetuto k volte utilizzando ognimvolta come test set un fold differente.

Leave-one-out: k = numero dei campioni disponibili

Bootstrap

Campionamento con rimpiazzo


Metodi out-of-bag

Training sui campioni estratti tramite bootstrap e testing sui rimanenti campioni non selezionati. Il processo è ripetuto n volte.


Metodo di hold-out (1)

■ Split dataset into two groups

- Training set: used to train the classifier
- Test set: used to estimate the error rate of the trained classifier



■ A typical application the holdout method is determining a stopping point for the back propagation error



Metodo di hold-out (2)

- **The holdout method has two basic drawbacks**

- In problems where we have a sparse dataset we may not be able to afford the “luxury” of setting aside a portion of the dataset for testing
- Since it is a single train-and-test experiment, the holdout estimate of error rate will be misleading if we happen to get an “unfortunate” split


- **The limitations of the holdout can be overcome with a family of resampling methods at the expense of higher computational cost**

- Cross Validation
 - Random Subsampling
 - K-Fold Cross-Validation
 - Leave-one-out Cross-Validation
- Bootstrap

Holdout ripetuto

■ Random Subsampling performs K data splits of the entire dataset

- Each data split randomly selects a (fixed) number of examples without replacement
- For each data split we retrain the classifier from scratch with the training examples and then estimate E_i with the test examples



■ The true error estimate is obtained as the average of the separate estimates E_i


- This estimate is significantly better than the holdout estimate

$$E = \frac{1}{K} \sum_{i=1}^K E_i$$

K-fold cross validation

■ Create a K-fold partition of the the dataset

- For each of K experiments, use K-1 folds for training and a different fold for testing
- This procedure is illustrated in the following diagram for K=4



■ K-Fold Cross validation is similar to Random Subsampling

- The advantage of K-Fold Cross validation is that all the examples in the dataset are eventually used for both training and testing


■ As before, the true error is estimated as the average error rate on test examples

$$E = \frac{1}{K} \sum_{i=1}^K E_i$$

Leave-one-out

- **Leave-one-out is the degenerate case of K-Fold Cross Validation, where K is chosen as the total number of examples**

- For a dataset with N examples, perform N experiments
- For each experiment use N-1 examples for training and the remaining example for testing



- **As usual, the true error is estimated as the average error rate on test examples**

$$E = \frac{1}{N} \sum_{i=1}^N E_i$$

Sintesi della lezione

- Tipologie di metodi di apprendimento automatico (Machine Learning - ML)
- Apprendimento e generalizzazione
- Rischio empirico e rischio atteso
- Stima sperimentale del rischio atteso (errore di generalizzazione)