

Teoría del Aprendizaje Computacional

CI5438 - Inteligencia Artificial 2
Clase 7

Cap 18. Russel & Norvig: Inteligencia Artificial. Un enfoque estructurado

Hipótesis

- ◆ El aprendizaje inductivo se puede reinterpretar como un buscador de buenas hipótesis en un espacio de hipótesis (H, H', H'', \dots)
- ◆ Generalmente queremos un predicado meta Q y nos gustaría encontrar una expresión equivalente o definición del candidato que clasifique correctamente a los ejemplos: **HIPOTESIS**
- ◆ El espacio de hipótesis es el conjunto de todas las hipótesis que el algoritmo de aprendizaje es capaz de abarcar. La extensión del predicado meta es el conjunto de ejemplos que satisfacen la definición del candidato.

Hipótesis

- ◆ Una hipótesis H es una expresión lógica que intenta clasificar ejemplos
- ◆ El problema del aprendizaje inductivo es la búsqueda, entre todas las hipótesis que conoce, de la que sea capaz de clasificar los ejemplos correctamente y que así vuelva verdadera la disyunción previa.
- ◆ Se puede definir como espacio de hipótesis a la enumeración de todas ellas. Pero la enumeración completa del espacio de hipótesis es imposible en la mayoría de los casos, e infinita en L1.

Hipótesis

- ◆ Dado que el espacio de hipótesis se puede modelar también como una disyunción de hipótesis (aunque el modelo lo llama espacio de versión), como veremos enseguida, es posible usar una hipótesis inconsistente junto con una regla de resolución, para eliminar con ambas las hipótesis subóptimas y reducir el espacio de versión.



Ejemplos

- ◆ Un ejemplo es un objeto con su descripción lógica y con una clasificación de un concepto booleano, que en este caso es la meta, que puede ser aplicable o no (caso de las células cancerosas, de los aspectos del día)
- ◆ Una conjunción de ejemplos es un conjunto de entrenamiento. Una hipótesis es lógicamente consistente o no, es aplicable o no, si coincide o no con los ejemplos del conjunto de entrenamiento. Si fuera inaplicable o sea inconsistente, lo podría ser de algunas de las dos maneras clásicas explicadas por la estadística:



Ejemplos: Errores

1. Con error alfa, o sea con error tipo I, falso positivo, donde el error mide la probabilidad de aceptar una hipótesis siendo así que no es verdadera. En este caso, la hipótesis ha clasificado el ejemplo con probabilidad 1,0 como positivo siendo así que en puridad de verdad es negativo (lo sabíamos de entrada), con lo cual la hipótesis ha cometido un error .



Ejemplos: Errores

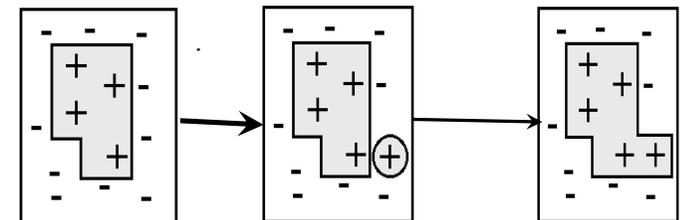
2. Con error beta, o sea con error tipo II, falso negativo, donde el error mide la probabilidad de rechazar una hipótesis siendo así que no es falsa. La hipótesis ha clasificado el ejemplo como negativo siendo así que en verdad es positivo, con lo cual la hipótesis ha cometido un error diferente del anterior y con distintas consecuencias.



Generalización

Al analizar una hipótesis concreta, le toca el turno de ingresar un ejemplo positivo que es falso negativo desde el punto de vista de la hipótesis (y que graficamos como positivo en la zona de los ejemplos negativos). Modificamos la hipótesis extendiendo (generalizando) sus predicciones positivas.

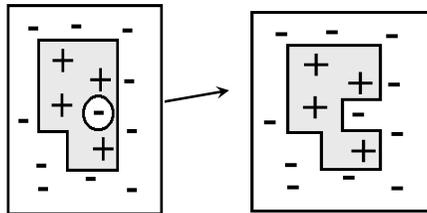
Con la generalización, la hipótesis se ha entrenado para acertar mejor los ejemplos positivos del conjunto de entrenamiento.



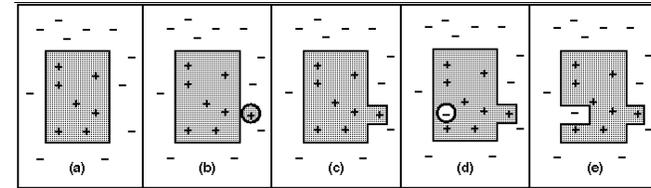
Especialización

Al analizar una hipótesis concreta, le toca el turno de ingresar un ejemplo negativo, que es falso positivo desde el punto de vista de la hipótesis (y que graficamos como negativo en la zona de los ejemplos positivos). Modificamos la hipótesis achicando (especializando) la zona para sus predicciones positivas.

Con la especialización, la hipótesis se ha entrenado para acertar mejor los ejemplos negativos del conjunto de entrenamiento.



Búsqueda de la mejor hipótesis del momento



- ◆ Si la hipótesis encuentra un ejemplo falso positivo hay que extender la misma y generalizarla para incluir al ejemplo de marras.
- ◆ En el otro caso hay que achicar la zona de clase positiva especializando la hipótesis para incluir el ejemplo falso positivo.
- ◆ Después de cada generalización/especialización hay que verificar la consistencia de la especialización del momento.

Por qué funciona el aprendizaje

- ◆ Uno de los problemas del aprendizaje es saber si los algoritmos de aprendizaje nos proporcionan una teoría que prediga el futuro

Teoría del Aprendizaje Computacional

- ◆ Trata de responder a esta pregunta
- ◆ "Cualquier hipótesis que esté completamente errada será seguramente descartada con una alta probabilidad después de un pequeño número de ejemplos, debido a que hará una predicción incorrecta"
- ◆ Esta es la idea del aprendizaje probable y aproximadamente correcto (Probably Approximately Correct or PAC-Learning)

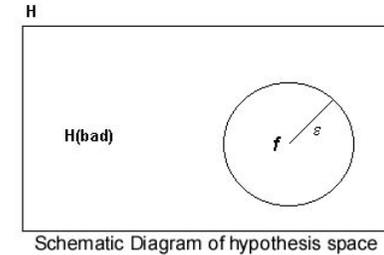


Número de ejemplos necesarios

- ◆ En el libro hay formulas "feas" para determinar el número de ejemplos de entrenamiento necesarios
- ◆ La probabilidad de que una hipótesis de una respuesta correcta es calculada
- ◆ Sólo las hipótesis que mantienen una probabilidad por debajo de un nivel aceptable son "buenas"



ϵ -Ball



- ◆ El tamaño del error probabilístico que es aceptable para una hipótesis
- ◆ En este caso f es la hipótesis correcta



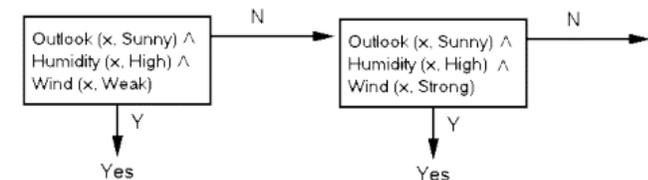
Hypothesis Space Problem

- ◆ Once again the sheer size of the hypothesis space thwarts us.
- ◆ For Boolean functions, sample complexity grows at a rate of 2 to the power of 2 to the power of n (doubly exponential growth)
- ◆ The only solution is to somehow reduce this



Learning Decision Lists

- ◆ Reduce the size of the hypothesis space to a size that may actually be learnable
- ◆ It greatly reduces the number of tests
- ◆ Each test increases in complexity





Decision List Learning

```

function DECISION-LIST-LEARNING(examples) returns a decision list, No or failure
if examples is empty then return the value No
t ← a test that matches a nonempty subset examplest of examples
      such that the members of examplest are all positive or all negative
if there is no such t then return failure
if the examples in examplest are positive then o ← Yes
else o ← No
return a decision list with initial test t and outcome o
      and remaining elements given by DECISION-LIST-LEARNING(examples − examplest.)
  
```



k -DL

- ◆ Limiting the size of decision list tests to at most k literals allows the use of a learning algorithm, which is called k -DL.
- ◆ It can be shown that k -DL is PAC-Learnable. (while k -DT isn't)

