




Budapesti Műszaki és Gazdaságtudományi Egyetem Méréstechnika és Információs rendszerek Tanszék



VKH (Valószínűleg közelítőleg helyes) tanulás

Előadó:

Hullám Gábor

Előadás anyaga:

Dobrowiecki Tadeusz
Pataki Béla

Mennyi tanítómintára van szükség?

Számítási tanulási elmélet

Hogyan tudhatja valaki, hogy a tanulási algoritmus a tudást eredményezett, amely helyesen fogja megjósolni a jövőt?

Az induktív tanulásnál:

honnan tudjuk, hogy a h hipotézis jól közelíti az f célfüggvényt, ha nem ismerjük f -et?

Az alapelv

- ▶ bármely, súlyosan hibás hipotézis már kis számú példa vizsgálata után is szinte biztosan „megbukik”, mivel nagy valószínűséggel legalább egy helytelen eredményt fog jósolni.
- ▶ valószínűtlen, hogy súlyosan hibás lehet olyan hipotézis, amely egy kellően nagy tanuló példahalmazzal konzisztens.



VKH

Valószínűleg Közelítőleg Helyes (Probably Approximately Correct).

VKH-tanulás (PAC-learning)

▶ **De hány példára van szükség a biztonsághoz?**

X az összes lehetséges példák halmaza, D a példák eloszlása.

H az összes lehetséges hipotézisek halmaza.

m a tanuló halmaz példáinak száma.



VKH

Legyen a keresett, valódi f függvény eleme \mathbf{H} -nak. Ekkor h hipotézis f függvényhez képesti **hibája** a D eloszlású példahalmazon:


$$e(h) = P(h(x) \neq f(x) \mid x \in D)$$

h hipotézist **közelítőleg helyes**, ha $e(h) \leq \varepsilon$, ahol ε kicsi.

m példa vizsgálata után nagy valószínűséggel az összes konzisztens hipotézis közelítőleg helyes lesz.

$$P(h_{VKH}(x) \neq f(x) \mid x \in D) = e(h) < \varepsilon$$
$$P(h_{VKH}(x) = f(x) \mid x \in D) = e(h) \geq (1 - \varepsilon)$$

$$P(h_{ROSSZ}(x) \neq f(x) \mid x \in D) = e(h) > \varepsilon$$
$$P(h_{ROSSZ}(x) = f(x) \mid x \in D) = e(h) \leq (1 - \varepsilon)$$



VKH

P(egy „alapvetően rossz” h_r hipotézis az első m példával konzisztens)?

$e(h_r) > \varepsilon$ miatt annak valószínűsége, hogy bármelyik adott példára jó eredményt ad $P(h_{\text{rossz}}(x) = f(x) | x \in D) = e(h) \leq (1 - \varepsilon)$

m példára:

$$P(h_r \text{ jó eredményt ad } m \text{ példára}) \leq (1 - \varepsilon)^m$$

▶ Annak valószínűsége, hogy az összesen $|\mathbf{H}_{\text{rossz}}|$ nem VKH hipotézis közül *valamelyik* konzisztens lesz mind az m mintánkkal:

$$P(\text{konzisztens } h \in \mathbf{H}_{\text{rossz}}) \leq |\mathbf{H}_{\text{rossz}}| (1 - \varepsilon)^m \leq |\mathbf{H}| (1 - \varepsilon)^m$$

$$|\mathbf{H}| \cdot (1 - \varepsilon)^m \leq \delta$$



VKH

Valószínűleg közelítőleg helyes (VKH).

- ▶ Ha egy tanuló algoritmus olyan hipotézist ad, amely m megfelelően kiválasztott (véletlen mintavétel) példa esetén is konzisztens, akkor ennek a hipotézisnek legalább $(1 - \delta)$ valószínűséggel a hibája legfeljebb ϵ
- ▶ A kívánt példaszám $(\delta, \epsilon$ és a hipotézistér mintakomplexitásának függvénye):

$$|\mathbf{H}| \cdot (1 - \epsilon)^m \leq \delta$$

$$|\mathbf{H}| \cdot e^{-\epsilon \cdot m} \leq \delta$$

$$\ln|\mathbf{H}| + \ln(e^{-\epsilon \cdot m}) \leq \ln(\delta)$$

$$\ln|\mathbf{H}| - \epsilon \cdot m \leq \ln(\delta)$$

$$\ln|\mathbf{H}| - \ln(\delta) \leq \epsilon \cdot m$$

$$\frac{1}{\epsilon} (\ln|\mathbf{H}| - \ln(\delta)) \leq m$$



Minta komplexitás és tanulhatóság

Egy **függvény megtanulható** példákból adott ε és δ szinten, ha a szükséges példaszám probléma paramétereinek $(\varepsilon, \delta, \mathbf{H})$ polinomiális függvénye, azaz, ha a hipotézis tér **minta komplexitása exponenciálisnál kisebb.**

A dilemma:

- ha nem korlátozzuk a tanuló algoritmus hipotéziseinek terét, akkor az algoritmus nem lesz képes tanulni,
- ha viszont korlátozzuk, akkor lehet, hogy a valódi, keresett függvényt zárjuk ki.



Minta komplexitás és tanulhatóság

A dilemma:

- ha nem korlátozzuk a tanuló algoritmus hipotéziseinek terét, akkor az algoritmus nem lesz képes tanulni,
- ha viszont korlátozzuk, akkor lehet, hogy a valódi, keresett függvényt zárjuk ki.

Két kiút a csapdából:

- ha az algoritmus lehetőleg a **legegyszerűbb** hipotézist adja meg, de legtöbb esetben a legegyszerűbb hipotézis számítása **kezelhetetlen**.
- **legtöbb esetben** nincs szükségünk a Boole függvények teljes kifejező erejére, ennél **kötöttebb** nyelvekkel is megoldhatók feladataink.



VKH példa -1.

Ha $|\mathbf{H}|=10^7$ és 99% biztonsággal ($1-\delta=0,99$, azaz $\delta =0,01$) szeretnénk állítani, hogy a megtanított eszköz hibája nem lesz 5%-nál nagyobb, akkor

$$\frac{1}{\epsilon} (\ln|\mathbf{H}| - \ln(\delta)) \leq m$$
$$\frac{1}{0.05} (7\ln(10) - \ln(0.01)) = 414,46 < m$$

- ▶ Tehát, ha $m=415$ véletlen minta mindegyikével konzisztens a tanított eszközünk, akkor ilyen biztonsággal garantálhatjuk a hibaszintet



VKH példa -2.

- ▶ Tanítsunk meg példák alapján egy 10-bemenetű Boole függvényt! Hány minta kell, ha max. 1%-os hibát 99,9% biztonsággal akarunk garantálni?

$$\frac{1}{\epsilon} (\ln |\mathbf{H}| - \ln(\delta)) \leq m$$



VKH példa -2.

- ▶ Tanítsunk meg példák alapján egy 10-bemenetű Boole függvényt! Hány minta kell, ha max. 1%-os hibát 99,9% biztonsággal akarunk garantálni?

$$\frac{1}{\epsilon} (\ln |\mathbf{H}| - \ln(\delta)) \leq m$$

- ▶ A.) 716,69
- ▶ B.) 7166,9
- ▶ C.) 71669
- ▶ D.) 716699



VKH példa -2.

- ▶ Tanítsunk meg példák alapján egy 10-bemenetű Boole függvényt! Hány minta kell, ha max. 1%-os hibát 99,9% biztonsággal akarunk garantálni?

- ▶ $|\mathbf{H}|=2^{2^n} \rightarrow |\mathbf{H}|=2^{2^{10}}$

$$\frac{1}{\epsilon} (\ln|\mathbf{H}| - \ln(\delta)) \leq m$$

$$\frac{1}{0.01} (1024 \cdot \ln(2) - \ln(0.001)) = 71669 < m$$

- ▶ Mi ezzel a gond?
Hány különböző példát lehet generálni egy 10 bemenetű Boole-függvénnel? **1024**
-

