




# Budapesti Műszaki és Gazdaságtudományi Egyetem Méréstechnika és Információs rendszerek Tanszék



## VKH (Valószínűleg közelítőleg helyes) tanulás

Előadó:

Dr. Hullám Gábor

Előadás anyaga:

Dr. Dobrowiecki Tadeusz

Dr. Pataki Béla

Mennyi tanítómintára van szükség?

# Számítási tanulási elmélet

---

Hogyan tudhatja valaki, hogy a tanulási algoritmus olyan 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  $\varepsilon$  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  $\epsilon$
- ▶ 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  $\varepsilon$  és  $\delta$  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**

