

Lärbarhetsteori

- 1 Teoretiska frågeställningar
 - Vad kan gå fel?
- 2 PAC-Learning
 - Consistent learners
 - Antal träningsexempel
 - Inläring av konjunktioner
 - Inläring utan Bias
- 3 VC-dimensionen
 - Exempel
 - Komplexitetsmått
- 4 Fel under inläringen
 - Find-S
 - Candidate Elimination
 - Teoretiska gränser

1 Teoretiska frågeställningar

- Vad kan gå fel?

2 PAC-Learning

- Consistent learners
- Antal träningsexempel
- Inläring av konjunktioner
- Inläring utan Bias

3 VC-dimensionen

- Exempel
- Komplexitetsmått

4 Fel under inläringen

- Find-S
- Candidate Elimination
- Teoretiska gränser

Frågor för teoretisk analys av inlärning

Frågor för teoretisk analys av inläring

- Hur svårt är ett givet inlärningsproblem?

Frågor för teoretisk analys av inläring

- Hur svårt är ett givet inlärningsproblem?
- Hur många träningsexempel krävs?

Frågor för teoretisk analys av inläring

- Hur svårt är ett givet inlärningsproblem?
- Hur många träningsexempel krävs?
- Hur många felklassningar kan vi förvänta oss under och efter inläringen?

Frågor för teoretisk analys av inläring

- Hur svårt är ett givet inlärningsproblem?
- Hur många träningsexempel krävs?
- Hur många felklassningar kan vi förvänta oss under och efter inläringen?
- Hur stor är risken att inläringen misslyckas?

Förutsättningar:

- Begreppsinlärning
- Träning och test från samma fördelning \mathcal{D}

Förutsättningar:

- Begreppsindelning
- Träning och test från samma fördelning \mathcal{D}

Vilken sorts fel kan uppstå?

Förutsättningar:

- Begreppsinläring
- Träning och test från samma fördelning \mathcal{D}

Vilken sorts fel kan uppstå?

- Resultatet av inläringen kan vara dåligt
Hypotesen ger fel klassning ibland

Förutsättningar:

- Begreppsinläring
- Träning och test från samma fördelning \mathcal{D}

Vilken sorts fel kan uppstå?

- Resultatet av inläringen kan vara dåligt
Hypotesen ger fel klassning ibland
- Inläringen själv kan gå dåligt
Hittar ibland ingen vettig hypotes

Begränsning av hur dåliga hypoteser får bli

Begränsning av hur dåliga hypoteser får bli

True Error — sannolikheten att en viss hypotes gör fel

Begränsning av hur dåliga hypoteser får bli

True Error — sannolikheten att en viss hypotes gör fel

$$\text{error}_{\mathcal{D}}(h) \equiv P_{x \in \mathcal{D}} [h(x) \neq c(x)]$$

Begränsning av hur dåliga hypoteser får bli

True Error — sannolikheten att en viss hypotes gör fel

$$\text{error}_{\mathcal{D}}(h) \equiv P_{x \in \mathcal{D}} [h(x) \neq c(x)]$$

En hypotes h sägs vara **ganska rätt** (*approximately correct*) när

$$\text{error}_{\mathcal{D}}(h) < \epsilon$$

Begränsning av hur ofta inlärningen får misslyckas

Begränsning av hur ofta inlärningen får misslyckas

Risken att inlärningen inte hittar en tillräckligt bra hypotes

Begränsning av hur ofta inlärningen får misslyckas

Risken att inlärningen inte hittar en tillräckligt bra hypotes

$$P_L [\text{error}_{\mathcal{D}}(h) \geq \epsilon]$$

Begränsning av hur ofta inlärningen får misslyckas

Risken att inlärningen inte hittar en tillräckligt bra hypotes

$$P_L [\text{error}_{\mathcal{D}}(h) \geq \epsilon]$$

Algoritmen L sägs **troligen** (*probably*) hitta en lösning när

$$P_L [\text{error}_{\mathcal{D}}(h) \geq \epsilon] < \delta$$

- 1 Teoretiska frågeställningar
 - Vad kan gå fel?
- 2 PAC-Learning
 - Consistent learners
 - Antal träningsexempel
 - Inläring av konjunktioner
 - Inläring utan Bias
- 3 VC-dimensionen
 - Exempel
 - Komplexitetsmått
- 4 Fel under inläringen
 - Find-S
 - Candidate Elimination
 - Teoretiska gränser

PAC-learning

PAC-learning

Probably Approximately Correct

PAC-learning

Probably Approximately Correct

Givet

C Begreppet som ska läras

ϵ krav på felet

δ krav på risken

n exemplens storlek

PAC-learning

Probably Approximately Correct

Givet

C Begreppet som ska läras

ϵ krav på felet

δ krav på risken

n exemplens storlek

PAC-learnable: Tiden att hitta en lösning växer polynomiellt i $\text{size}(C)$, n , $\frac{1}{\epsilon}$ och $\frac{1}{\delta}$

Analys av en Consistent learner

Analys av en Consistent learner

- Förutsättning: inga fel i träningsexemplen

Analys av en Consistent learner

- Förutsättning: inga fel i träningsexemplen
- Exemplen dras från fördelningen \mathcal{D}

Analys av en Consistent learner

- Förutsättning: inga fel i träningsexemplen
- Exemplen dras från fördelningen \mathcal{D}
- Svaret är alltid konsistent med träningsexemplen

Analys av en Consistent learner

- Förutsättning: inga fel i träningsexemplen
- Exemplen dras från fördelningen \mathcal{D}
- Svaret är alltid konsistent med träningsexemplen
- ”Farliga hypoteser”:

$$\text{error}_{\mathcal{D}}(h) \geq \epsilon$$

Analys av en Consistent learner

- Förutsättning: inga fel i träningsexemplen
- Exemplen dras från fördelningen \mathcal{D}
- Svaret är alltid konsistent med träningsexemplen
- ”Farliga hypoteser”:

$$\text{error}_{\mathcal{D}}(h) \geq \epsilon$$

Vi vill inte att inläringen
ger en farlig hypotes som svar!

Analys av en Consistent learner

- Förutsättning: inga fel i träningsexemplen
- Exemplen dras från fördelningen \mathcal{D}
- Svaret är alltid konsistent med träningsexemplen
- ”Farliga hypoteser”:

$$\text{error}_{\mathcal{D}}(h) \geq \epsilon$$

Vi vill inte att inläringen
ger en farlig hypotes som svar!

Hur stor är risken att en farlig hypotes är konsistent med alla
träningsexempel?

- Sannolikheten att en hypotes h **motsägs** av ett exempel

$$\text{error}_{\mathcal{D}}(h)$$

- Sannolikheten att en hypotes h **motsägs** av ett exempel

$$\text{error}_{\mathcal{D}}(h)$$

- Sannolikheten att h **inte motsägs**

$$1 - \text{error}_{\mathcal{D}}(h)$$

- Sannolikheten att en hypotes h **motsägs** av ett exempel

$$\text{error}_{\mathcal{D}}(h)$$

- Sannolikheten att h **inte motsägs**

$$1 - \text{error}_{\mathcal{D}}(h)$$

- Risken att en *farlig hypotes* ($\text{error}_{\mathcal{D}}(h) \geq \epsilon$) **inte motsägs** av ett slumpmässigt valt träningsexempel

$$\leq (1 - \epsilon)$$

- Risken att en *farlig hypotes* inte motsägs av **ett** slumpmässigt valt träningsexempel

$$\leq (1 - \epsilon)$$

- Risken att en *farlig hypotes* inte motsägs av **ett** slumpmässigt valt träningssexempel

$$\leq (1 - \epsilon)$$

- Risken att en *farlig hypotes* inte motsägs av **m** slumpmässigt dragna träningssexempel

- Risken att en *farlig hypotes* inte motsägs av **ett** slumpmässigt valt träningsexempel

$$\leq (1 - \epsilon)$$

- Risken att en *farlig hypotes* inte motsägs av **m** slumpmässigt dragna träningsexempel

$$\leq (1 - \epsilon)^m$$

- Risken att en *farlig hypotes* inte motsägs av **ett** slumpmässigt valt träningsexempel

$$\leq (1 - \epsilon)$$

- Risken att en *farlig hypotes* inte motsägs av **m** slumpmässigt dragna träningsexempel

$$\leq (1 - \epsilon)^m$$

- Hur stor är risken att **någon farlig hypotes** i H råkar stämma med alla exempel:

- Risken att en *farlig hypotes* inte motsägs av **ett** slumpmässigt valt träningsexempel

$$\leq (1 - \epsilon)$$

- Risken att en *farlig hypotes* inte motsägs av **m** slumpmässigt dragna träningsexempel

$$\leq (1 - \epsilon)^m$$

- Hur stor är risken att **någon farlig hypotes** i H råkar stämma med alla exempel:

$$\leq |H| \cdot (1 - \epsilon)^m$$

- Risken att en *farlig hypotes* inte motsägs av **ett** slumpmässigt valt träningssexempel

$$\leq (1 - \epsilon)$$

- Risken att en *farlig hypotes* inte motsägs av **m** slumpmässigt dragna träningssexempel

$$\leq (1 - \epsilon)^m$$

- Hur stor är risken att **någon farlig hypotes** i H råkar stämma med alla exempel:

$$\leq |H| \cdot (1 - \epsilon)^m$$

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

Hur många träningsexempel behövs?

Hur många träningsexempel behövs?

Hur många exempel m krävs för att risken att få en farlig hypotes säkert ska vara mindre än δ

Hur många träningsexempel behövs?

Hur många exempel m krävs för att risken att få en farlig hypotes säkert ska vara mindre än δ

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

Hur många träningsexempel behövs?

Hur många exempel m krävs för att risken att få en farlig hypotes säkert ska vara mindre än δ

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

$$e^{\epsilon m} \geq \frac{|H|}{\delta}$$

Hur många träningsexempel behövs?

Hur många exempel m krävs för att risken att få en farlig hypotes säkert ska vara mindre än δ

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

$$e^{\epsilon m} \geq \frac{|H|}{\delta}$$

$$m \geq \frac{1}{\epsilon} \left[\ln |H| + \ln \frac{1}{\delta} \right]$$

Viktigt samband:

$$m \geq \frac{1}{\epsilon} \left[\ln |H| + \ln \frac{1}{\delta} \right]$$

Viktigt samband:

$$m \geq \frac{1}{\epsilon} \left[\ln |H| + \ln \frac{1}{\delta} \right]$$

Är detta PAC-learnable?

Viktigt samband:

$$m \geq \frac{1}{\epsilon} \left[\ln |H| + \ln \frac{1}{\delta} \right]$$

Är detta PAC-learnable?

Potentiellt problem: $|H|$ kan vara för stor

Inläring av konjunktioner

Inläring av konjunktioner

Exempel: $\text{Soligt} \wedge \neg \text{Blåsig} \wedge \text{Blött}$

Inläring av konjunktioner

Exempel: Soligt \wedge \neg Blåsig \wedge Blött

n attribut $\Rightarrow 3^n$ möjliga begrepp $\Rightarrow |H| = 3^n$

Inläring av konjunktioner

Exempel: Soligt \wedge \neg Blåsig \wedge Blött

n attribut $\Rightarrow 3^n$ möjliga begrepp $\Rightarrow |H| = 3^n$

$$m \geq \frac{1}{\epsilon} \left[n \ln 3 + \ln \frac{1}{\delta} \right]$$

Inläring av konjunktioner

Exempel: Soligt \wedge \neg Blåsig \wedge Blött

n attribut $\Rightarrow 3^n$ möjliga begrepp $\Rightarrow |H| = 3^n$

$$m \geq \frac{1}{\epsilon} \left[n \ln 3 + \ln \frac{1}{\delta} \right]$$

- Linjärt i $\frac{1}{\epsilon}$

Inläring av konjunktioner

Exempel: Soligt \wedge \neg Blåsig \wedge Blött

n attribut $\Rightarrow 3^n$ möjliga begrepp $\Rightarrow |H| = 3^n$

$$m \geq \frac{1}{\epsilon} \left[n \ln 3 + \ln \frac{1}{\delta} \right]$$

- Linjärt i $\frac{1}{\epsilon}$
- Linjärt i n

Inläring av konjunktioner

Exempel: Soligt \wedge \neg Blåsig \wedge Blött

n attribut $\Rightarrow 3^n$ möjliga begrepp $\Rightarrow |H| = 3^n$

$$m \geq \frac{1}{\epsilon} \left[n \ln 3 + \ln \frac{1}{\delta} \right]$$

- Linjärt i $\frac{1}{\epsilon}$
- Linjärt i n
- Logaritmiskt i $\frac{1}{\delta}$

Inläring av konjunktioner

Exempel: Soligt \wedge \neg Blåsig \wedge Blött

n attribut $\Rightarrow 3^n$ möjliga begrepp $\Rightarrow |H| = 3^n$

$$m \geq \frac{1}{\epsilon} \left[n \ln 3 + \ln \frac{1}{\delta} \right]$$

- Linjärt i $\frac{1}{\epsilon}$
- Linjärt i n
- Logaritmiskt i $\frac{1}{\delta}$

Verkar vara **PAC-learnable!**

Dessutom krävs att *tiden för varje exempel* är polynomisk.

Find-S: Ok

Inläring utan Bias

Inlärning utan Bias

Alla tänkbara delmängder av X är hypoteser

Inlärning utan Bias

Alla tänkbara delmängder av X är hypoteser

$$|X| = 2^n$$

Inläring utan Bias

Alla tänkbara delmängder av X är hypoteser

$$|X| = 2^n$$

$$|H| = 2^{2^n}$$

Inläring utan Bias

Alla tänkbara delmängder av X är hypoteser

$$|X| = 2^n$$

$$|H| = 2^{2^n}$$

$$m \geq \frac{1}{\epsilon} \left[2^n \ln 2 + \ln \frac{1}{\delta} \right]$$

Inlärning utan Bias

Alla tänkbara delmängder av X är hypoteser

$$|X| = 2^n$$

$$|H| = 2^{2^n}$$

$$m \geq \frac{1}{\epsilon} \left[2^n \ln 2 + \ln \frac{1}{\delta} \right]$$

Ej PAC-learnable!

Inlärning utan Bias

Alla tänkbara delmängder av X är hypoteser

$$|X| = 2^n$$

$$|H| = 2^{2^n}$$

$$m \geq \frac{1}{\epsilon} \left[2^n \ln 2 + \ln \frac{1}{\delta} \right]$$

Ej PAC-learnable!

Skattningen är dock en övre gräns (överskattning)

Vi har inte visat att m verkligen växer exponentiellt med n

Inläring utan Bias

Alla tänkbara delmängder av X är hypoteser

$$|X| = 2^n$$

$$|H| = 2^{2^n}$$

$$m \geq \frac{1}{\epsilon} \left[2^n \ln 2 + \ln \frac{1}{\delta} \right]$$

Ej PAC-learnable!

Skattningen är dock en övre gräns (överskattning)

Vi har inte visat att m verkligen växer exponentiellt med n

I detta fall *är* det sant

- 1 Teoretiska frågeställningar
 - Vad kan gå fel?
- 2 PAC-Learning
 - Consistent learners
 - Antal träningsexempel
 - Inläring av konjunktioner
 - Inläring utan Bias
- 3 VC-dimensionen
 - Exempel
 - Komplexitetsmått
- 4 Fel under inläringen
 - Find-S
 - Candidate Elimination
 - Teoretiska gränser

Problem med $|H|$

Problem med $|H|$

- Alltför pessimistiska skattningar

Problem med $|H|$

- Alltför pessimistiska skattningar
- Oanvändbar när $|H| = \infty$

Problem med $|H|$

- Alltför pessimistiska skattningar
- Oanvändbar när $|H| = \infty$

Vapnik — Chervonenkis observation:

Det intressanta är *inte antalet* hypoteser,
utan hur de kan **forma olika delmängder** i X

Splittring

En ändlig mängd S **splittras** av hypoteserna H om varje delmängd ur S beskrivs av något $h \in H$

Splittring

En ändlig mängd S **splittras** av hypoteserna H om varje delmängd ur S beskrivs av något $h \in H$

Storleken på S ger ett mått på hur uttrycksfull H är

Splittring

En ändlig mängd S **splittras** av hypoteserna H om varje delmängd ur S beskrivs av något $h \in H$

Storleken på S ger ett mått på hur uttrycksfull H är

VC-dimension

$$VC(H)$$

Storleken på den största delmängden
av X som splittras av H

Exempel:

H Intervall på reela talaxeln

X Reella tal

Exempel:

H Intervall på reela talaxeln

X Reella tal

- Kan 2 punkter splittras?

Exempel:

H Intervall på reela talaxeln

X Reella tal

- Kan 2 punkter splittras?
- Kan 3 punkter splittras?

Exempel:

H Intervall på reela talaxeln

X Reella tal

- Kan 2 punkter splittras?
- Kan 3 punkter splittras?

Slutsats: $VC(H) = 2$

Exempel:

H Separerande hyperplan

X Punkter i \mathbb{R}^r

Exempel:

H Separerande hyperplan

X Punkter i \mathbb{R}^r

- När $r = 1$

Exempel:

H Separerande hyperplan

X Punkter i \mathbb{R}^r

- När $r = 1$

$$\text{VC}(H) = 2$$

Exempel:

H Separerande hyperplan

X Punkter i \mathbb{R}^r

- När $r = 1$

$$VC(H) = 2$$

- När $r = 2$

Exempel:

H Separerande hyperplan

X Punkter i \mathbb{R}^r

- När $r = 1$

$$\text{VC}(H) = 2$$

- När $r = 2$

$$\text{VC}(H) = 3$$

Exempel:

H Separerande hyperplan

X Punkter i \mathbb{R}^r

- När $r = 1$

$$\text{VC}(H) = 2$$

- När $r = 2$

$$\text{VC}(H) = 3$$

- Generellt

Exempel:

H Separerande hyperplan

X Punkter i \mathbb{R}^r

- När $r = 1$

$$\text{VC}(H) = 2$$

- När $r = 2$

$$\text{VC}(H) = 3$$

- Generellt

$$\text{VC}(H) = r + 1$$

Antal träningsexempel

Antal träningsexempel

Tidigare skattning

$$m \geq \frac{1}{\epsilon} \left[\ln |H| + \ln \frac{1}{\delta} \right]$$

Antal träningsexempel

Tidigare skattning

$$m \geq \frac{1}{\epsilon} \left[\ln |H| + \ln \frac{1}{\delta} \right]$$

Ny skattning

$$m \geq \frac{1}{\epsilon} \left[4 \log_2 \frac{2}{\delta} + 8 \text{VC}(H) \cdot \log_2 \frac{13}{\epsilon} \right]$$

Antal träningsexempel

Tidigare skattning

$$m \geq \frac{1}{\epsilon} \left[\ln |H| + \ln \frac{1}{\delta} \right]$$

Ny skattning

$$m \geq \frac{1}{\epsilon} \left[4 \log_2 \frac{2}{\delta} + 8 \text{VC}(H) \cdot \log_2 \frac{13}{\epsilon} \right]$$

Mycket bättre (mindre)

- 1 Teoretiska frågeställningar
 - Vad kan gå fel?
- 2 PAC-Learning
 - Consistent learners
 - Antal träningsexempel
 - Inläring av konjunktioner
 - Inläring utan Bias
- 3 VC-dimensionen
 - Exempel
 - Komplexitetsmått
- 4 Fel under inläringen
 - Find-S
 - Candidate Elimination
 - Teoretiska gränser

Alternativt prestandamått för inlärningsalgoritmer:

Hur många fel görs under inläringen

Find-S

Find-S

- Lär sig bara vid felklassning

Find-S

- Lär sig bara vid felklassning
- Generaliserar i värsta fall bara ett attribut varje gång

Find-S

- Lär sig bara vid felklassning
- Generaliserar i värsta fall bara ett attribut varje gång
- Första gången väljs en speciellt hypotes

Find-S

- Lär sig bara vid felklassning
- Generaliserar i värsta fall bara ett attribut varje gång
- Första gången väljs en speciellt hypotes
- Maximalt $n + 1$ ändringar

Find-S

- Lär sig bara vid felklassning
- Generaliserar i värsta fall bara ett attribut varje gång
- Första gången väljs en speciellt hypotes
- Maximalt $n + 1$ ändringar

Man gör maximalt $n + 1$ fel

Candidate Elimination

Candidate Elimination

- Vi måste tvinga ur algoritmen ett förslag

Candidate Elimination

- Vi måste tvinga ur algoritmen ett förslag
- Antag att vi använder majoritetsröstning bland hypoteserna som är kvar i *Version Space*

Candidate Elimination

- Vi måste tvinga ur algoritmen ett förslag
- Antag att vi använder majoritetsröstning bland hypoteserna som är kvar i *Version Space*
- Fel bara när **minst hälften** av VS har fel

Candidate Elimination

- Vi måste tvinga ur algoritmen ett förslag
- Antag att vi använder majoritetsröstning bland hypoteserna som är kvar i *Version Space*
- Fel bara när **minst hälften** av VS har fel
- Varje gång vi gör fel försvinner minst hälften av VS

Candidate Elimination

- Vi måste tvinga ur algoritmen ett förslag
- Antag att vi använder majoritetsröstning bland hypoteserna som är kvar i *Version Space*
- Fel bara när **minst hälften** av VS har fel
- Varje gång vi gör fel försvinner minst hälften av VS

Maximalt $\log_2 |H|$ fel

Optimal inlärning

- Bästa algoritmen
- Värsta fallet
Svåraste begreppet, värsta sekvensen av exemplen

Optimal inlärning

- Bästa algoritmen
- Värsta fallet
Svåraste begreppet, värsta sekvensen av exemplen

Antal fel för att lära begreppet C :

$$\text{Opt}(C)$$

Optimal inlärning

- Bästa algoritmen
- Värsta fallet
Svåraste begreppet, värsta sekvensen av exemplen

Antal fel för att lära begreppet C :

$$\text{Opt}(C)$$

Teoretiska gränser

$$\text{VC}(C) \leq \text{Opt}(C) \leq \log_2 |C|$$