



هوش مصنوعی

فصل ۱۹

پادگیری از مثال‌ها

Learning from Examples

کاظم فولادی قلعه

دانشکده مهندسی، دانشکدگان فارابی

دانشگاه تهران

<http://courses.fouladi.ir/ai>

هوش مصنوعی

یادگیری از مثال‌ها



مقدمه

عامل‌های یادگیرنده

یادگیری

LEARNING AGENTS

یادگیری، مکانیزم‌های تصمیم‌گیری عامل را به‌گونه‌ای تغییر می‌دهد که کارایی آن بهبود یابد.

عامل‌های یادگیرنده

یادگیری

LEARNING AGENTS

یادگیری به یک عامل اجازه می‌دهد که در محیط‌های ابتدائی ناشناخته عمل کند و سپس از آنچه از آنچه دانایی اولیه‌اش به تنها‌یی ممکن بود اجازه بدهد، شایسته‌تر شود.

ساخت عامل‌های هوش مصنوعی

ایجاد مؤلفه‌ی یادگیرنده و آموزش عامل

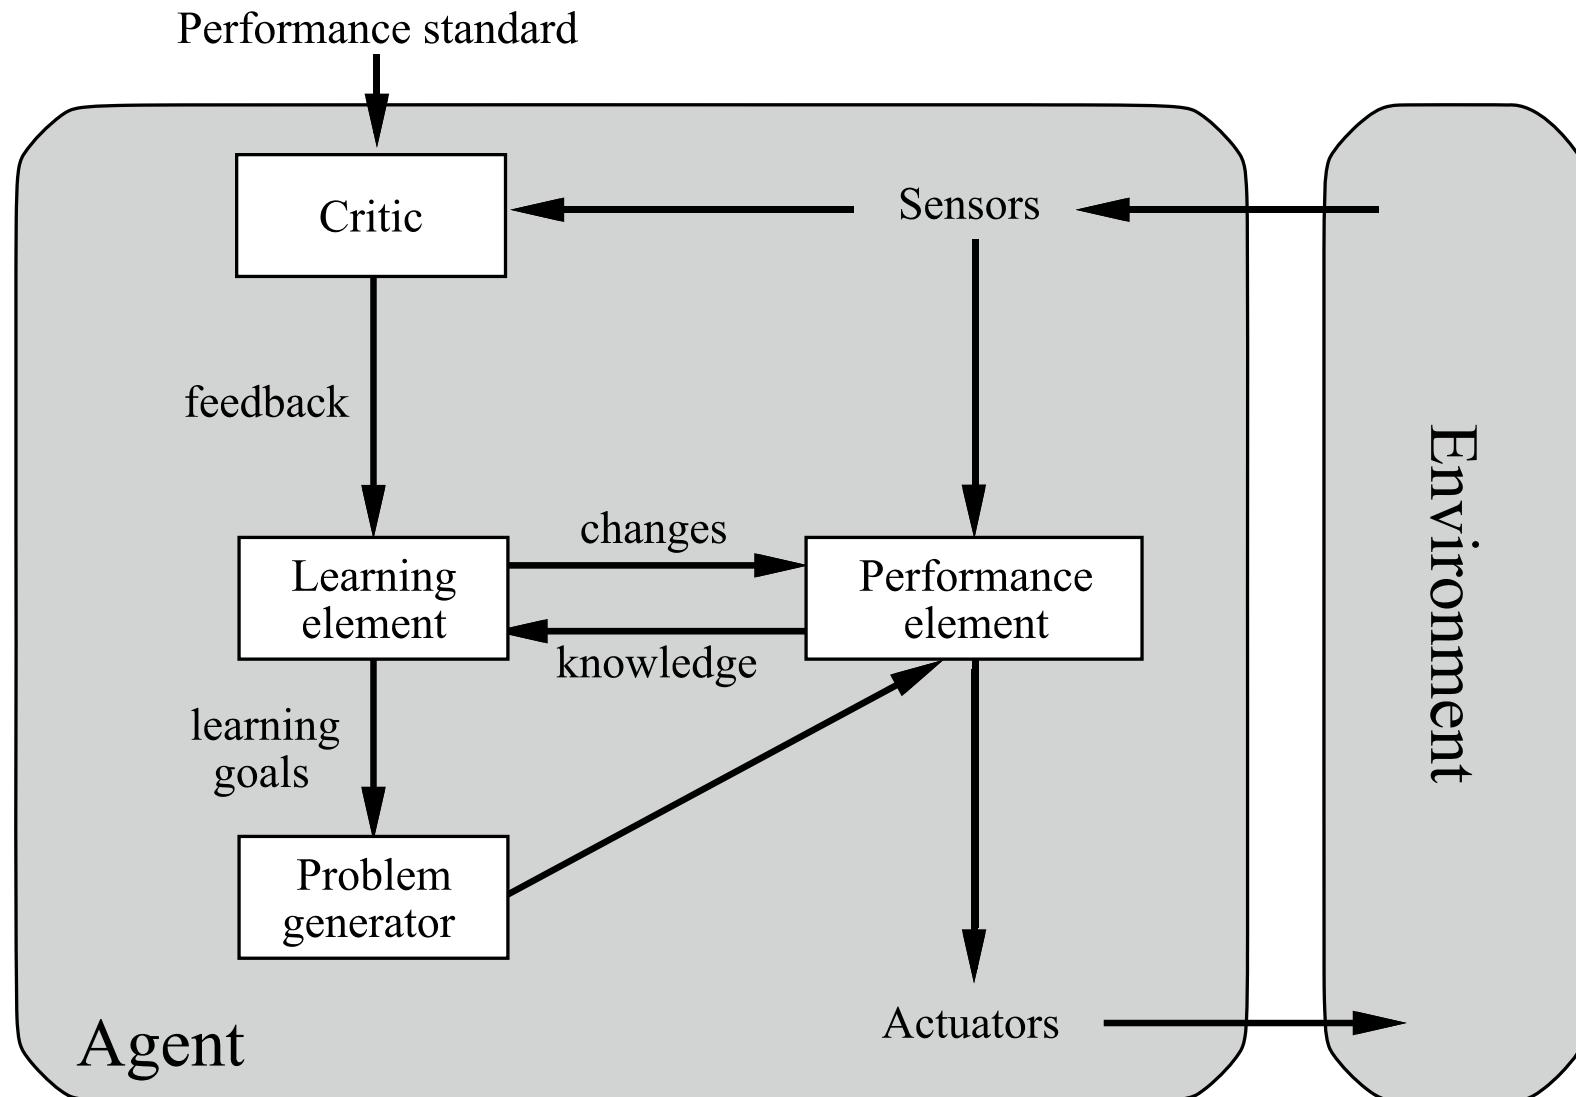
برنامه‌نویسی از صفر

پیشنهاد آلن تورینگ (۱۹۵۰)

دو پرسش برای طراحی عامل یادگیرنده:

- (۱) عنصر انجام‌دهنده چه باشد؟ (یکی از ساختارهای چهارگانه برنامه عامل)
- (۲) چگونه یادگیری انجام شود؟ (روش‌های گوناگون و مؤلفه‌های مختلف ساختار عامل)

عامل‌های یادگیرنده

LEARNING AGENTS

عامل‌های یادگیرنده

اجزای داخلی

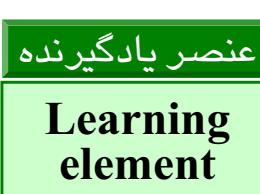
معیار کارآیی استاندارد: Performance standard



به عنصر یادگیرنده
فیدبک می‌دهد:

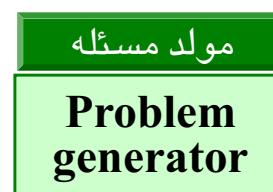
با توجه به یک معیار
استاندارد کارآیی ثابت به
عنصر یادگیرنده می‌گوید
که عامل چه قدر خوب
عمل کرده است.

ثابت است.
باید به طور کامل خارج از عامل باشد
(عامل نباید بتواند آن را تغییر دهد).



مسئول بهبود
بخشیدن به کارآیی:

تغییرات عنصر
انجام‌دهنده را برای بهتر
عمل کردن در آینده
مشخص می‌کند.

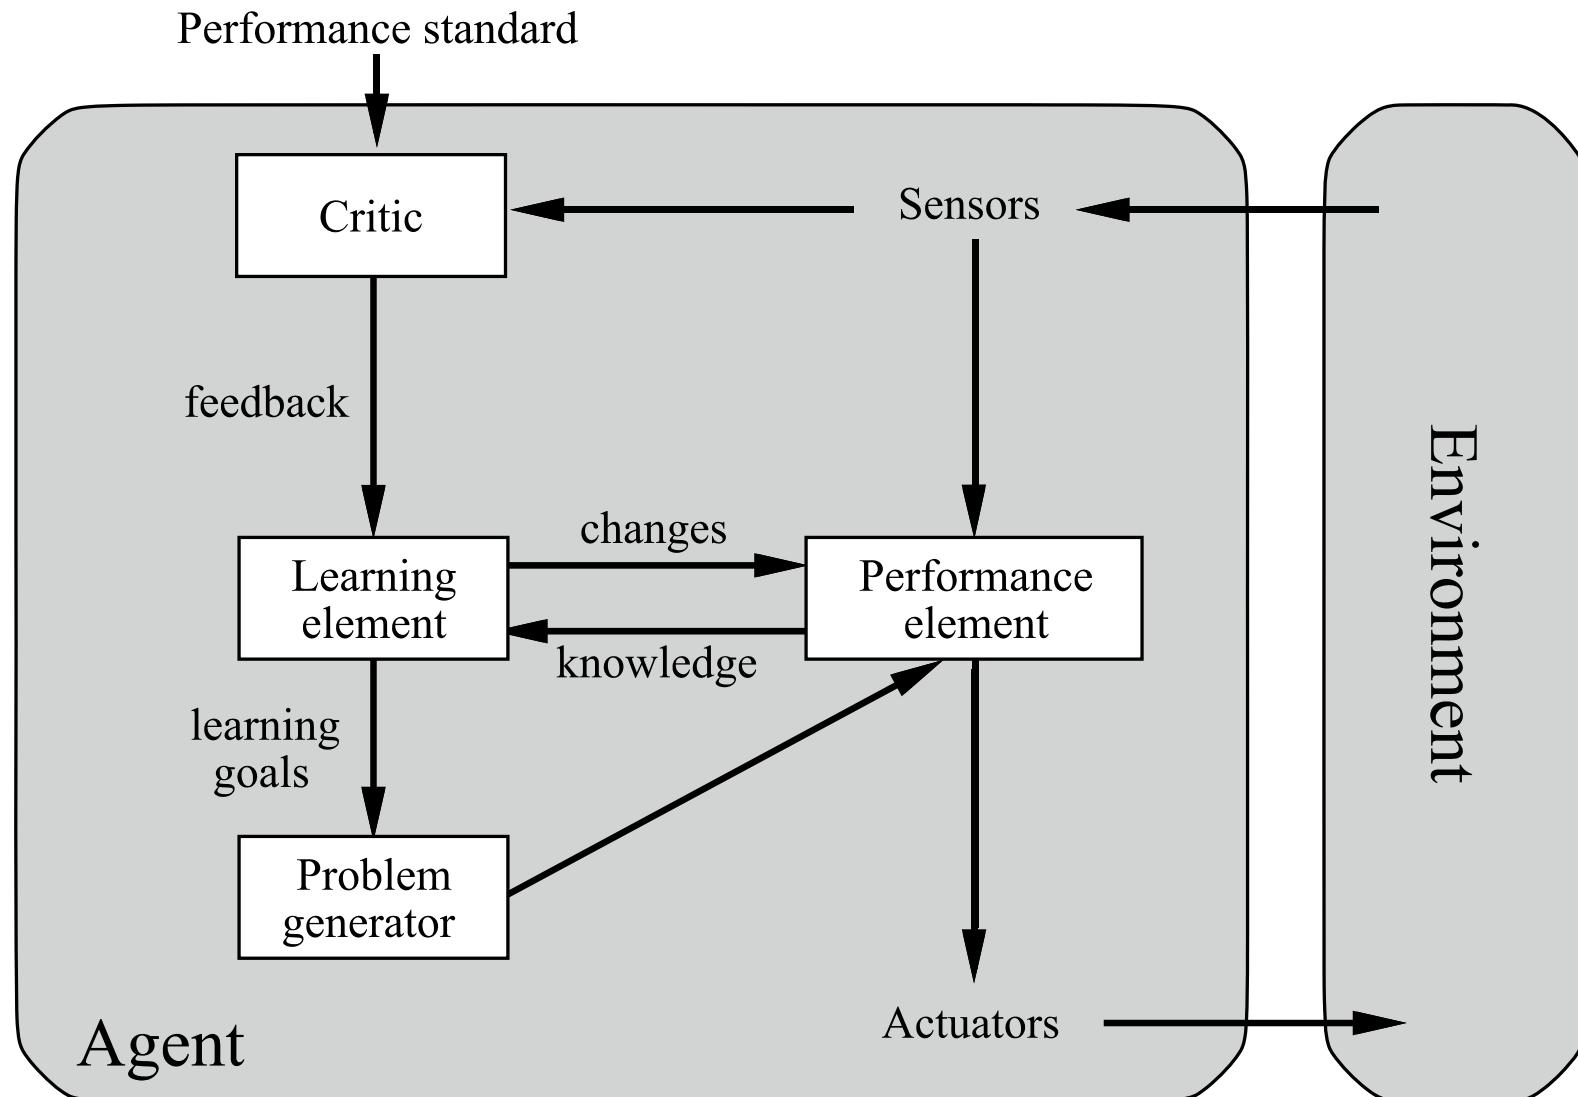


مسئول انتخاب کنش بیرونی:

می‌تواند هر یک از ساختارهای
چهارگانه‌ی برنامه‌ی عامل را داشته باشد.

یادگیری در عامل هوشمند: فرآیند تغییر هر جزء عامل به این منظور که
آن جزء تطابق بیشتری با اطلاعات فیدبک داشته باشد و از این طریق کارآیی کل عامل بهبود یابد.

عامل‌های یادگیرنده

LEARNING AGENTS

هوش مصنوعی

یادگیری از مثال‌ها

۱

صورت‌های یادگیری

عنصر یادگیری

LEARNING ELEMENT

هر مؤلفه‌ی یک عامل می‌تواند به وسیله‌ی یادگیری از داده‌ها بهبود پیدا کند.

مؤلفه‌های مؤثر در طراحی عنصر یادگیری			
فیدبک <i>Feedback</i>	بازنمایی <i>Representation</i>	مؤلفه‌ی کارکردی <i>Functional Component</i>	عنصر انجام‌دهنده <i>Performance Element</i>
چه نوع فیدبکی در دست است؟	مؤلفه‌ی کارکردی چگونه بازنمایی می‌شود؟	کدام مؤلفه‌ی کارکردی باید یادگرفته شود؟	چه نوع عنصر انجام‌دهنده‌ای استفاده می‌شود؟
فیدبک موجود برای یادگیری	بازنمایی داده‌ها و مؤلفه	مؤلفه‌ای که باید بهبود یابد	نوع معماری برنامه‌ی عامل



دانایی پیشین
Prior Knowledge

دانایی پیشین
که عامل در اختیار دارد

عنصر یادگیری

مثال

LEARNING ELEMENT

مؤلفه‌های مؤثر در طراحی عنصر یادگیری			
فیدبک <i>Feedback</i>	بازنمایی <i>Representation</i>	مؤلفه‌ی کارکردی <i>Functional Component</i>	عنصر انجام‌دهنده <i>Performance Element</i>
برد/باخت <i>Win/Loss</i>	تابع خطی وزن‌دار <i>Weighted Linear Function</i>	تابع ارزیابی <i>Evaluation Function</i>	عامل جستجوی تخاصمی <i>Adversarial Search Agent</i>
برآمد <i>Outcome</i>	اصول موضوع حالت مابعد <i>Successor-State Axioms</i>	مدل گذر <i>Transition Model</i>	عامل منطقی <i>Logical Agent</i>
برآمد <i>Outcome</i>	شبکه‌ی بیزی پویا <i>Dynamic Bayes Network</i>	مدل گذر <i>Transition Model</i>	عامل مبتنی بر سودمندی <i>Utility-Based Agent</i>
کنش درست <i>Correct Action</i>	شبکه‌ی عصبی <i>Neural Network</i>	تابع ادراک - کنش <i>Percept-Action Function</i>	عامل واکنشی ساده <i>Simple Reflex Agent</i>

صورت‌های یادگیری

FORMS OF LEARNING

صورت‌های یادگیری					
یادگیری استنباطی <i>Deductive Learning</i>	یادگیری استقرائی <i>Inductive Learning</i>				
یادگیری کل به جزء	یادگیری جزء به کل				
یادگیری تحلیلی <i>Analytical Learning</i>	یادگیری یک تابع یا قاعده‌ی عمومی (درست/نادرست) از روی جفت‌های خاص ورودی - خروجی				
<p>حرکت از یک قاعده‌ی عمومی شناخته شده به قاعده‌ی جدیدی که منطقاً استلزم می‌شود.</p> <p>(مفید است، زیرا امکان پردازش کارآمدتر را فراهم می‌کند.)</p>	<p>یادگیری نیمه‌نظرارتی <i>Semisupervised</i></p> <p>یادگیری با وجود تعداد کمی مثال برچسب‌دار و مجموعه‌ی بزرگی از داده‌های بی‌برچسب</p>	<p>یادگیری تقویتی <i>Reinforcement</i></p> <p>یادگیری از روی یک سری تقویت‌ها (پاداش‌ها و جریمه‌ها)</p>	<p>یادگیری بی‌نظرارت <i>Unsupervised</i></p> <p>یادگیری الگوهای درون ورودی بدون وجود فیدبک صریح (clustering) (مثل</p>	<p>یادگیری بانظرارت <i>Supervised</i></p> <p>یادگیری نگاشت ورودی به خروجی با دیدن مثال‌های برچسب‌دار</p>	<p>تقسیم‌بندی بر اساس نوع فیدبک موجود برای یادگیری</p> <p>سه نوع اصلی یادگیری</p>

یادگیری استقرائی

آنچه ساینس (science) نامیده می‌شود

INDUCTIVE LEARNING (A.K.A. SCIENCE)

یادگیری استقرائی

Inductive Learning

یادگیری جزء به کل

یادگیری یک تابع یا قاعده‌ی عمومی (درست/نادرست)
از روی جفت‌های خاص ورودی - خروجی

یادگیری نیمه‌نظرارتی

Semisupervised

یادگیری تقویتی

Reinforcement

یادگیری بی‌نظرارت

Unsupervised

یادگیری بانظرارت

Supervised

* در مورد ساینس، عامل کل نژاد بشری در کل زمان‌هاست.

هوش مصنوعی

یادگیری از مثال‌ها

۳

یادگیری
با نظارت

یادگیری بانظارت

SUPERVISED LEARNING

یادگیری بانظارت

Supervised Learning

یک مجموعه‌ی آموزشی از N جفت ورودی-خروجی نمونه داده شده است:

$$(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)$$

که در آن هر y_j به وسیله‌ی یک تابع مجھول f تولید شده است:

$$y = f(x)$$

یک تابع h را کشف کنید که تابع واقعی f را تقریب بزند.

یادگیری بانظارت

مفاهیم کلیدی

SUPERVISED LEARNING

یادگیری بانظارت

Supervised Learning

مجموعه‌ی جفت‌های ورودی-خروجی معلوم برای آموزش یادگیرنده

مجموعه‌ی آموزشی
Training Set

مجموعه‌ی جفت‌های ورودی-خروجی معلوم برای آزمایش یادگیرنده

مجموعه‌ی آزمایشی
Test Set

تابع f که باید یاد گرفته شود

هدف
Target

تابع مجهول h که باید تقریب مناسبی برای f باشد

فرضیه
Hypothesis

مجموعه‌ی همه‌ی توابع منتخب h برای تقریب f

فضای فرضیه
Hypothesis Space

\mathcal{H}

یادگیری بانظارت

مثال: یادگیری ارزش حالتها در بازی دوز

SUPERVISED LEARNING

f is the target function

An example is a pair $x, f(x)$, e.g.,

O	O	X
	X	
X		

, +1

Problem: find a(n) hypothesis h

such that $h \approx f$

given a training set of examples

یادگیری بانظارت

طبقه‌بندی و رگرسیون

SUPERVISED LEARNING

وقتی خروجی y از یک مجموعه‌ی متناهی مشخص انتخاب شود.

یادگیری بانظارت
Supervised Learning

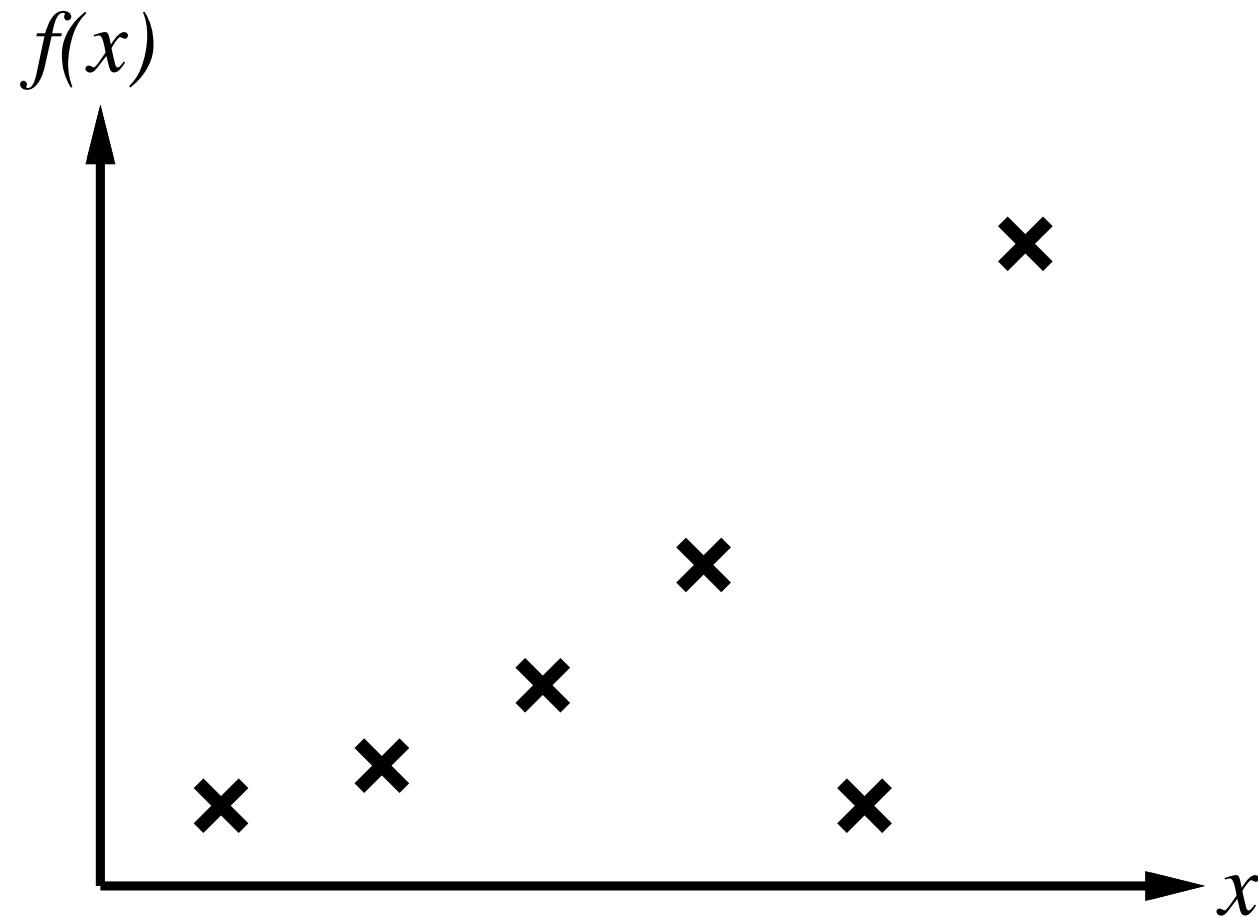
طبقه‌بندی
Classification

رگرسیون
Regression

وقتی خروجی y یک عدد باشد (یافتن امید شرطی یا متوسط y)

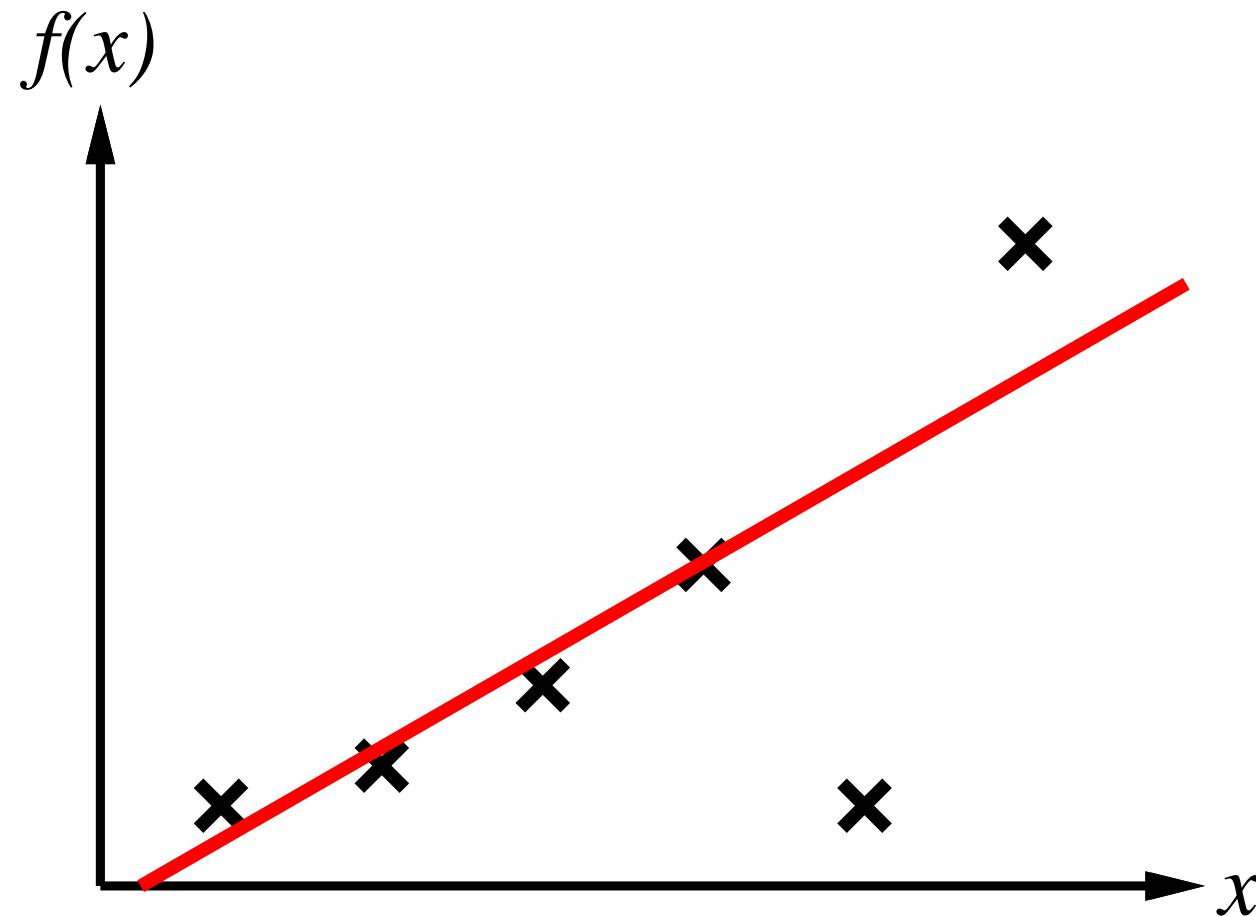
روش یادگیری بانظارت

مثال: برازش منحنی (۱ از ۵)

SUPERVISED LEARNING METHOD

روش یادگیری بانظارت

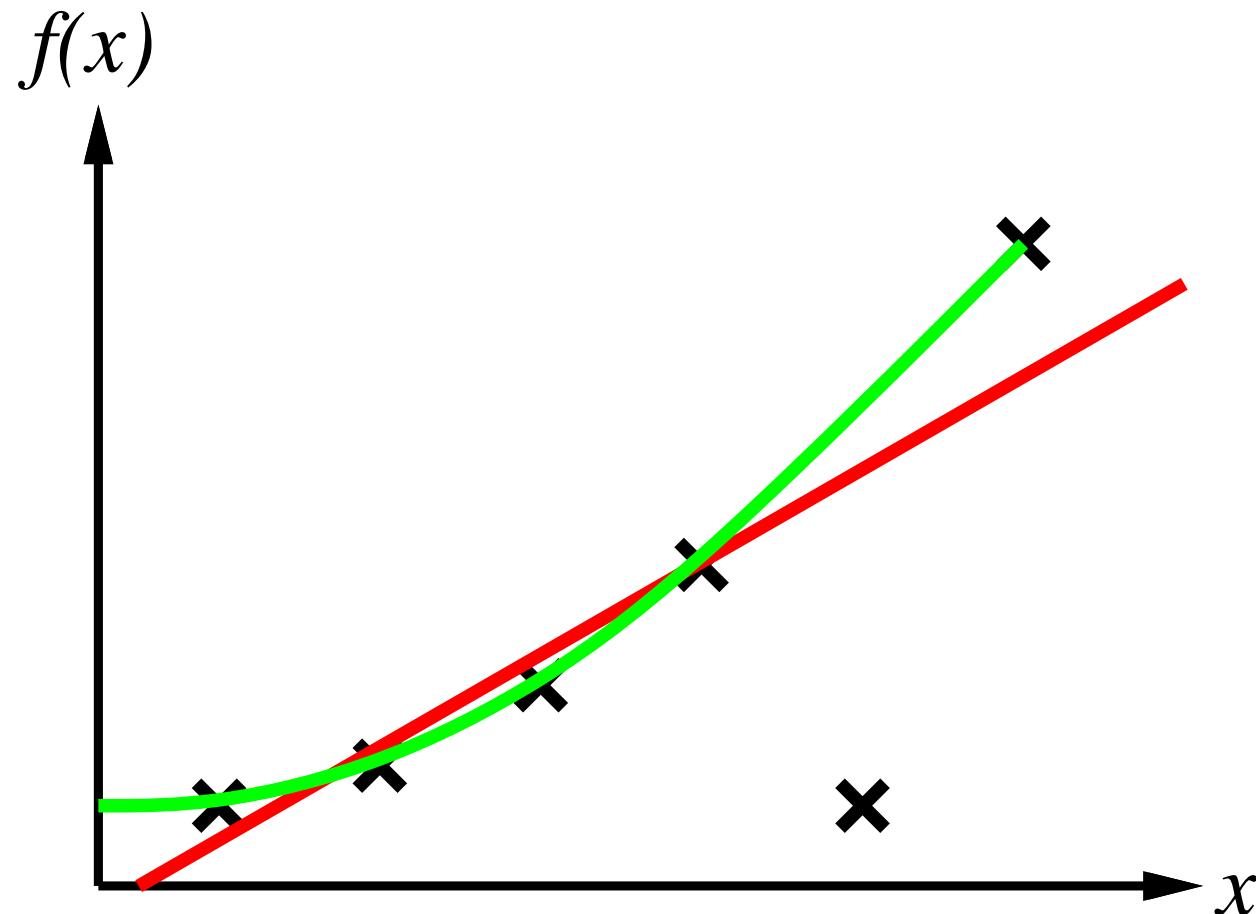
مثال: برازش منحنی (۲ از ۵)

SUPERVISED LEARNING METHOD

فرضیه بسیار ساده (چندجمله‌ای خطی)، ناسازگار، تعمیم‌پذیری خوب

روش یادگیری استقرائی

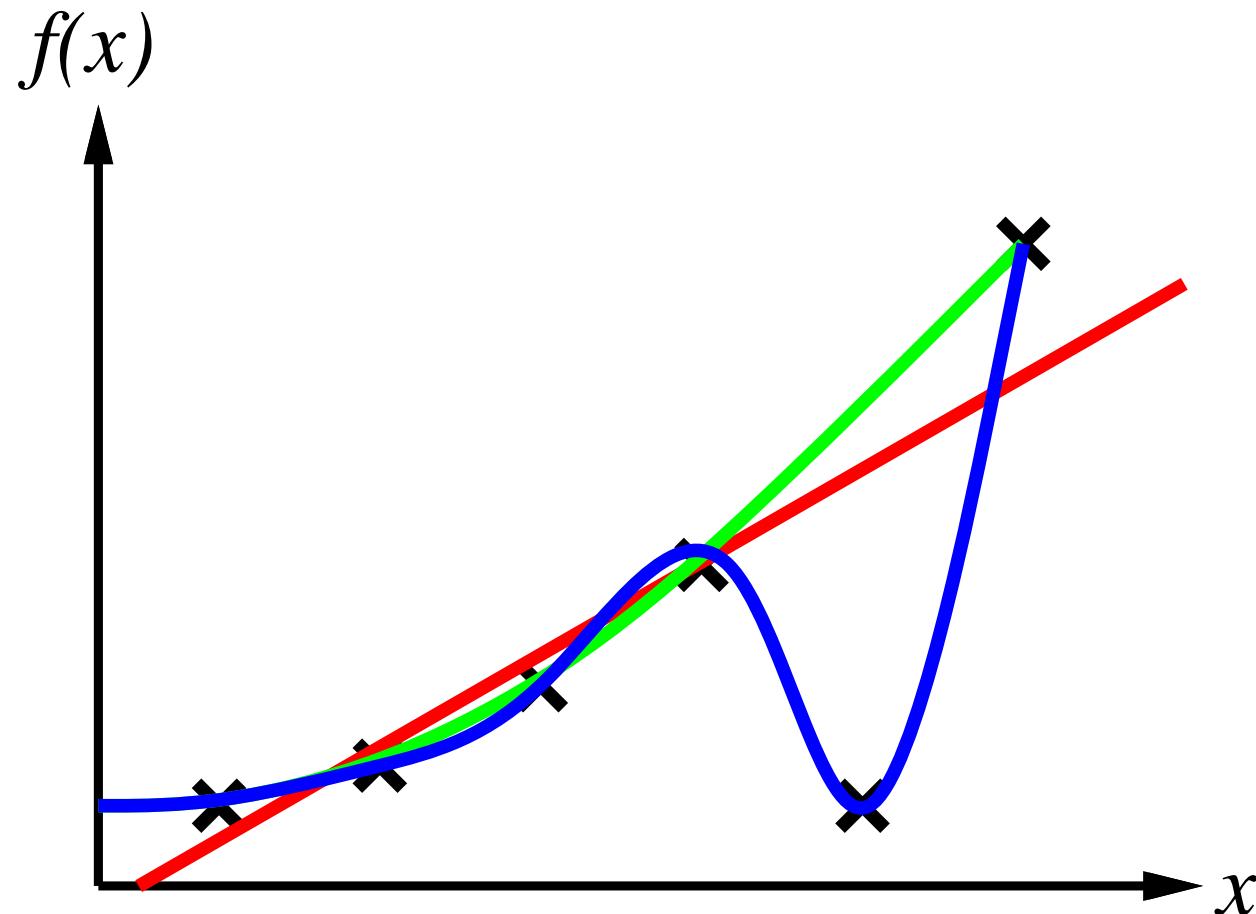
مثال: برازش منحنی (۳ از ۵)

SUPERVISED LEARNING METHOD

فرضیه ساده (چندجمله‌ای درجه دوم)، ناسازگار، تعمیم‌پذیری خوب

روش یادگیری بانظارت

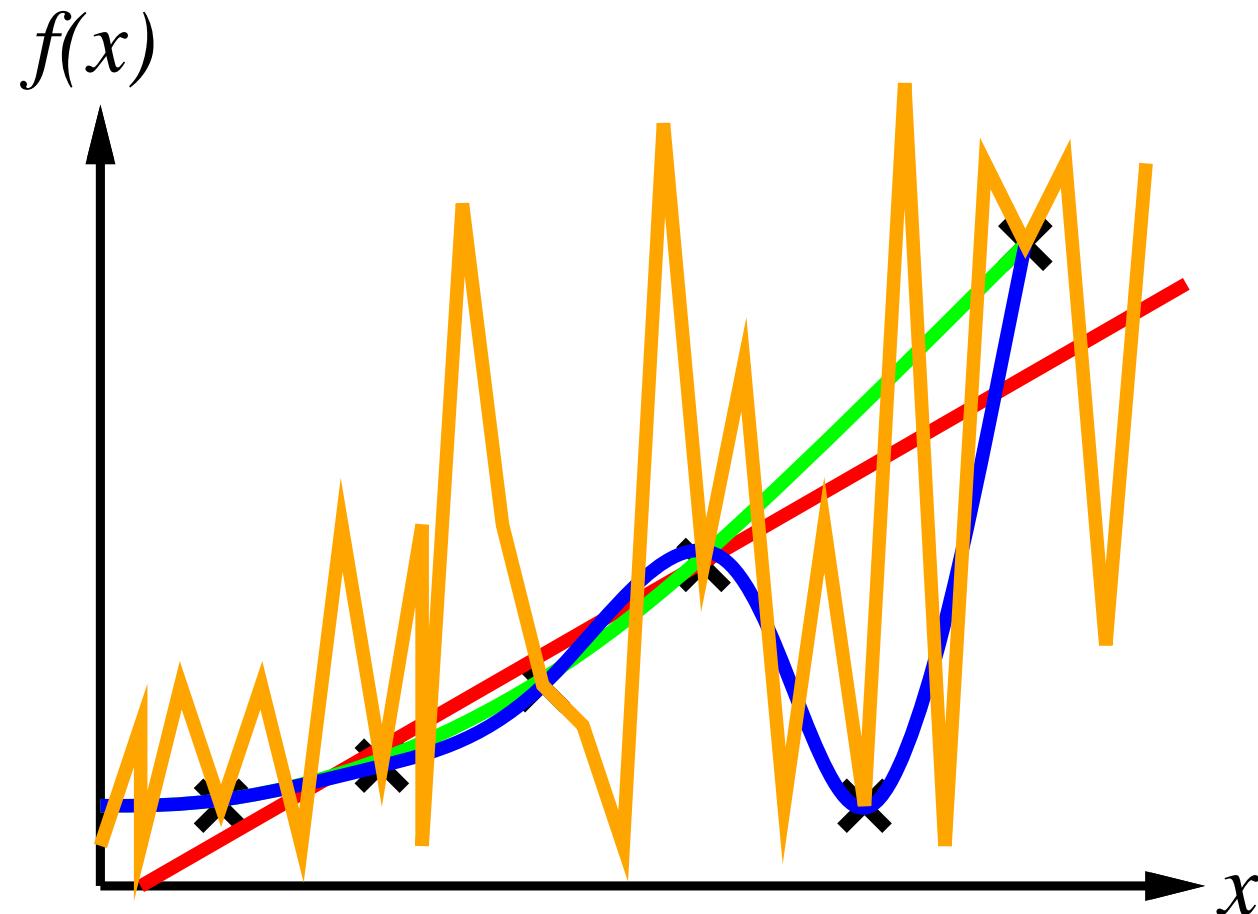
مثال: برازش منحنی (۴ از ۵)

SUPERVISED LEARNING METHOD

فرضیه پیچیده (چندجمله‌ای درجه بالا)، سازگار، تعمیم‌پذیری متوسط

روش یادگیری بانظارت

مثال: برازش منحنی (۵ از ۵)

SUPERVISED LEARNING METHOD

فرضیه بسیار پیچیده (چندجمله‌ای با درجه‌ی بسیار بالا)، سازگار، تعمیم‌پذیری پایین

یادگیری بانظارت

سازگاری و تعمیم

تعمیم

Generalization

یک فرضیه **تعمیم‌پذیر** است
اگر
مقادیر خروجی نمونه‌های جدید را
به درستی پیش‌بینی کند.

سازگاری

Consistency

یک فرضیه **سازگار** است
اگر
بر روی همهٔ نمونه‌های آموزشی
درست باشد.

بدهستان میان سازگاری - تعمیم‌پذیری:
فرضیه‌های **پیچیده** با سازگاری کامل و فرضیه‌های **ساده‌تر** با تعمیم‌پذیری بالاتر

بدهستان میان رسایی - پیچیدگی:
رسایی یک فضای فرضیه و پیچیدگی یافتن یک فرضیه‌ی خوب در آن فضا

تیغه‌ی اوخامی

OCKHAM'S RAZOR

یک مسئله‌ی بنیادی در یادگیری استقرائی:

چگونه بین چند فرضیه‌ی سازگار یکی را انتخاب کنیم؟

ترجیح با ساده‌ترین فرضیه‌ی سازگار با داده‌ها است.

بهترین مدل برای هر پدیده، ساده‌ترین مدل توصیف‌کننده‌ی آن است.

«به نام ویلیام اوخامی فیلسوف انگلیسی قرن 14 میلادی»

تیغه‌ی اوخامی

Ockham's Razor

یادگیری بانظارت

محتمل‌ترین فرضیه برای داده‌های موجود

یادگیری بانظارت، با انتخاب فرضیه‌ی h^* انجام می‌شود:

محتمل‌ترین فرضیه با داشتن داده‌ها

$$h^* = \operatorname{argmax}_{h \in \mathcal{H}} P(h | data)$$

عبارت معادل از طریق قاعده‌ی بیز

$$h^* = \operatorname{argmax}_{h \in \mathcal{H}} P(data | h) P(h)$$

هوش مصنوعی

یادگیری از مثال‌ها

۳

یادگیری
درخت‌های
تصمیم

بازنمایی‌های مبتنی بر خصیصه

مثال: انتظار برای میز در یک رستوران

ATTRIBUTE-BASED REPRESENTATIONS

مثال

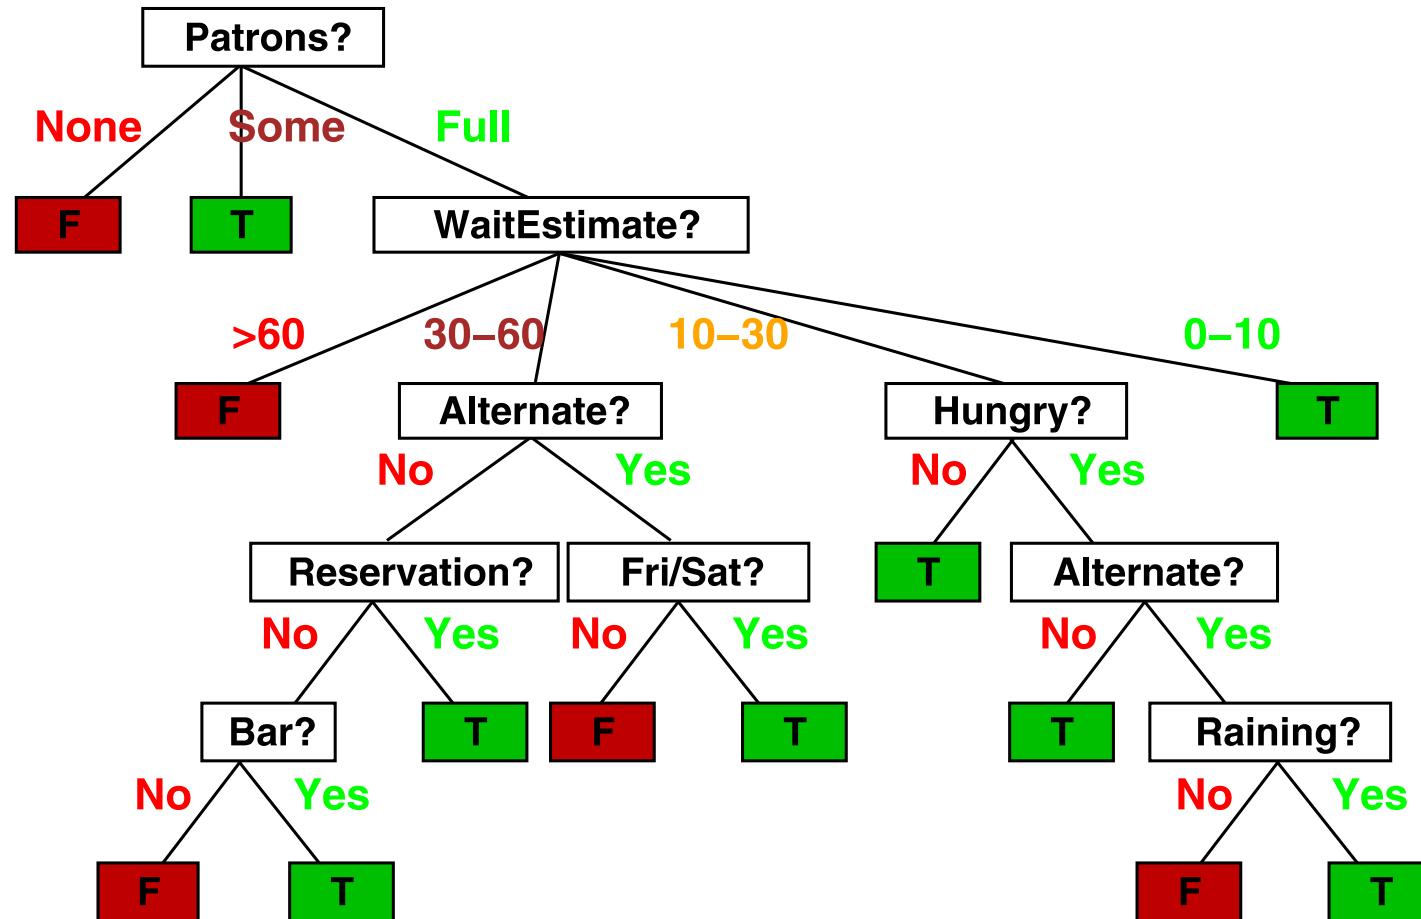
مثال‌هایی از موقعیت‌هایی که در آنها برای یک میز در رستوران صبر می‌کنیم یا خیر:

Example	Attributes											Target WillWait
	Alt	Bar	Fri	Hun	Pat	Price	Rain	Res	Type	Est		
X_1	T	F	F	T	$Some$	$\$\$\$$	F	T	$French$	$0\text{--}10$	T	
X_2	T	F	F	T	$Full$	$\$$	F	F	$Thai$	$30\text{--}60$	F	
X_3	F	T	F	F	$Some$	$\$$	F	F	$Burger$	$0\text{--}10$	T	
X_4	T	F	T	T	$Full$	$\$$	F	F	$Thai$	$10\text{--}30$	T	
X_5	T	F	T	F	$Full$	$\$\$\$$	F	T	$French$	>60	F	
X_6	F	T	F	T	$Some$	$\$\$$	T	T	$Italian$	$0\text{--}10$	T	
X_7	F	T	F	F	$None$	$\$$	T	F	$Burger$	$0\text{--}10$	F	
X_8	F	F	F	T	$Some$	$\$\$$	T	T	$Thai$	$0\text{--}10$	T	
X_9	F	T	T	F	$Full$	$\$$	T	F	$Burger$	>60	F	
X_{10}	T	T	T	T	$Full$	$\$\$\$$	F	T	$Italian$	$10\text{--}30$	F	
X_{11}	F	F	F	F	$None$	$\$$	F	F	$Thai$	$0\text{--}10$	F	
X_{12}	T	T	T	T	$Full$	$\$$	F	F	$Burger$	$30\text{--}60$	T	

درخت‌های تصمیم

مثال: انتظار برای میز در یک رستوران

DECISION TREES



درخت تصمیم: یک بازنمایی ممکن برای فرضیه‌ها

خصیصه‌های بی‌رابطه در تصمیم‌گیری (price و type) در این درخت استفاده نشده است.

درخت‌های تصمیم

رسایی

EXPRESSIVENESS

درخت‌های تصمیم می‌توانند هر تابعی از خصیصه‌های ورودی را بیان کنند.

مثالاً: برای توابع بولی: هر سطر جدول درستی ← یک مسیر از ریشه تا برگ در درخت تصمیم

برای هر مجموعه‌ی آموزشی، یک درخت تصمیم سازگار وجود دارد:
با یک مسیر از ریشه تا یک برگ برای هر نمونه
(مگر اینکه f بر حسب x غیر قطعی باشد).
اما احتمال دارد که تعمیم‌پذیری آن برای مثال‌های جدید پایین باشد.

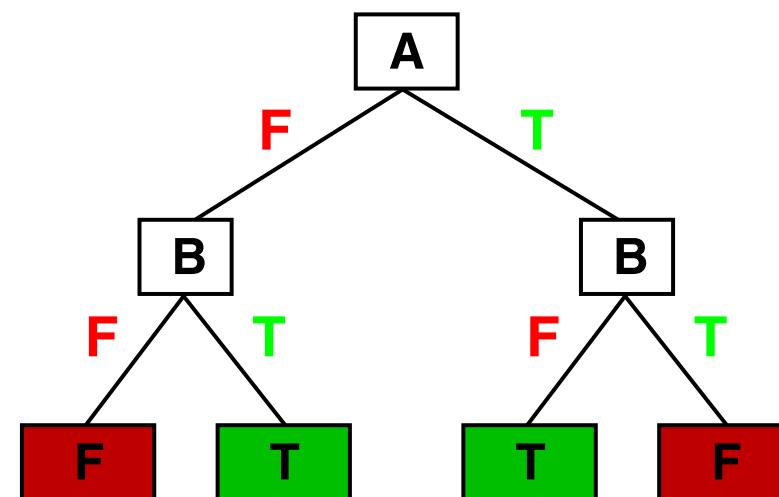
یافتن درخت‌های تصمیم متراکم‌تر ترجیح داده می‌شود.

درخت‌های تصمیم

مثال: تابع یای انحصاری

EXPRESSIVENESS

A	B	$A \text{ xor } B$
F	F	F
F	T	T
T	F	T
T	T	F



مثالاً: برای تابع بولی xor : هر سطر جدول درستی \leftarrow یک مسیر از ریشه تا برگ در درخت تصمیم

فضاهای فرضیه

HYPOTHESIS SPACES

How many distinct decision trees with n Boolean attributes??

= number of Boolean functions

= number of distinct truth tables with 2^n rows = 2^{2^n}

E.g., with 6 Boolean attributes, there are 18,446,744,073,709,551,616 trees

How many purely conjunctive hypotheses (e.g., $\text{Hungry} \wedge \neg \text{Rain}$)??

Each attribute can be in (positive), in (negative), or out

⇒ 3^n distinct conjunctive hypotheses

More expressive hypothesis space

- increases chance that target function can be expressed 
- increases number of hypotheses consistent w/ training set
⇒ may get worse predictions 

درخت تصمیم

الگوریتم یادگیری

DECISION TREE LEARNING

هدف: یافتن یک درخت تصمیم کوچک سازگار با مثال‌های آموزشی

ایده‌ی کلی: « مهم‌ترین » خصیصه را به عنوان ریشه‌ی (زیر) درخت انتخاب کنید (به صورت بازگشتی)

```

function DTL(examples, attributes, default) returns a decision tree
  if examples is empty then return default
  else if all examples have the same classification then return the classification
  else if attributes is empty then return MODE(examples)
  else
    best  $\leftarrow$  CHOOSE-ATTRIBUTE(attributes, examples)
    tree  $\leftarrow$  a new decision tree with root test best
    for each value vi of best do
      examplesi  $\leftarrow$  {elements of examples with best = vi}
      subtree  $\leftarrow$  DTL(examplesi, attributes – best, MODE(examples))
      add a branch to tree with label vi and subtree subtree
  return tree

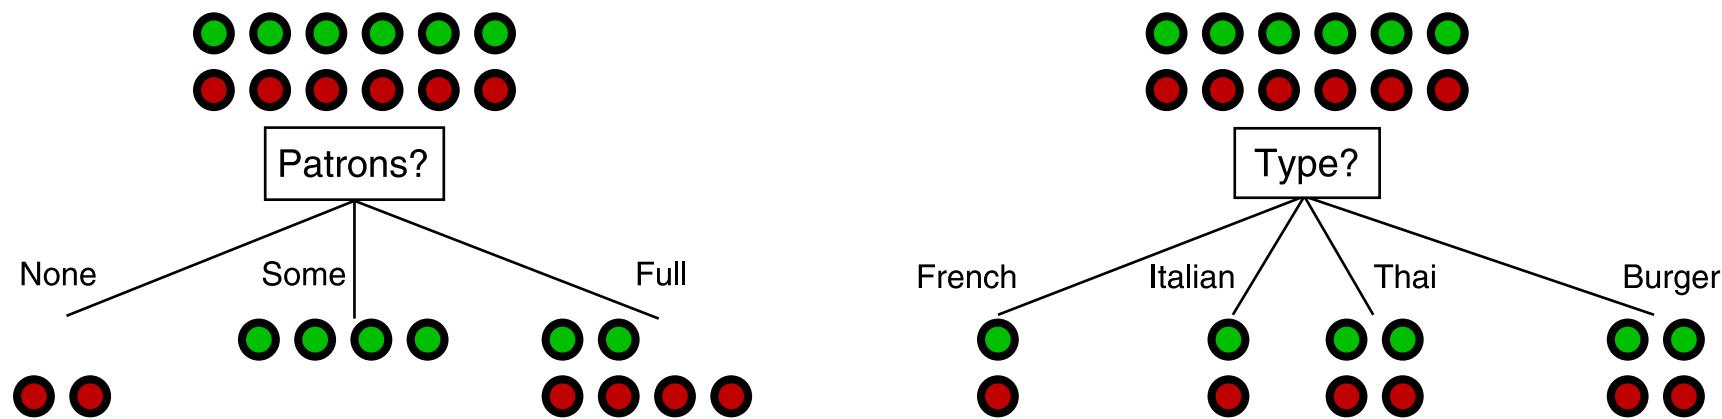
```

درخت تصمیم

انتخاب یک خصیصه

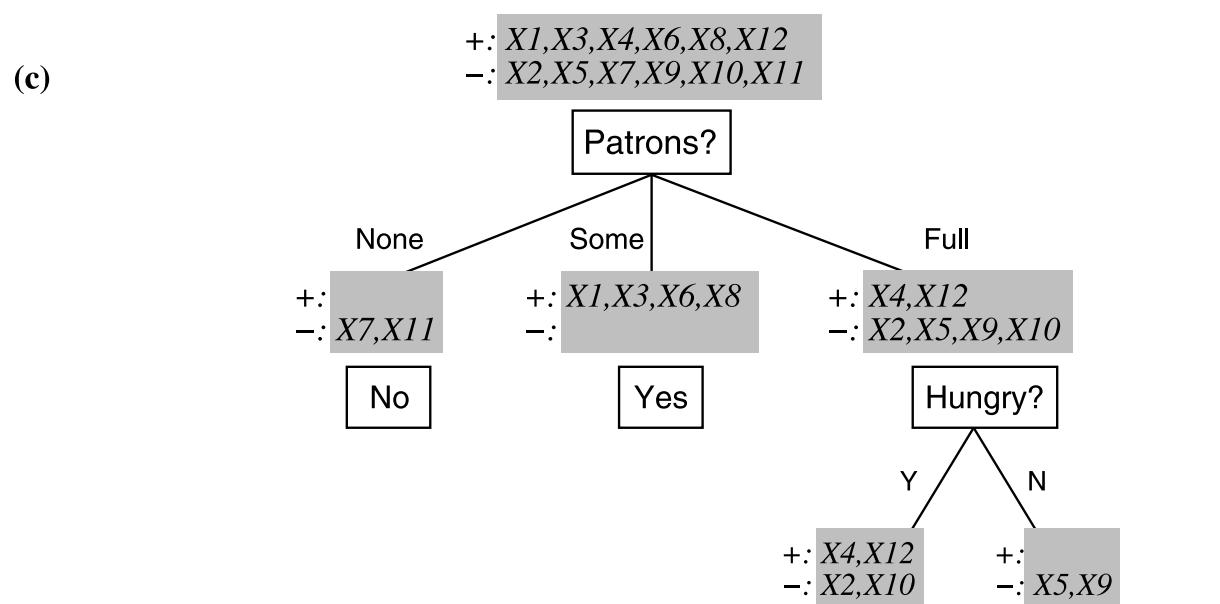
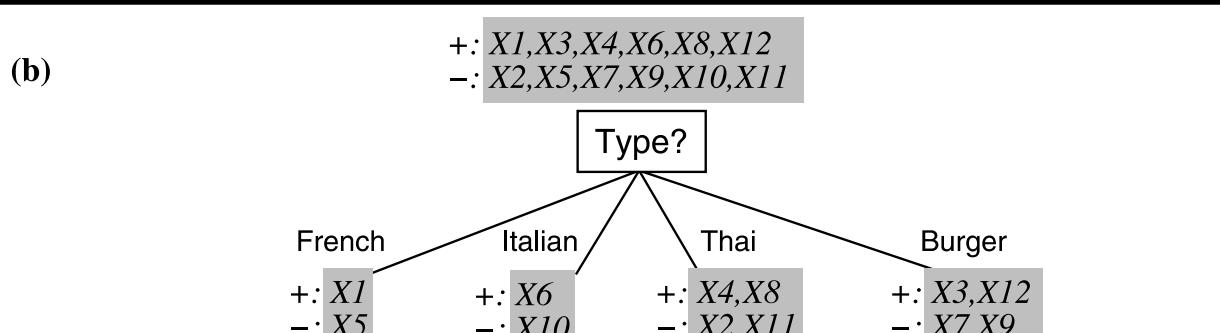
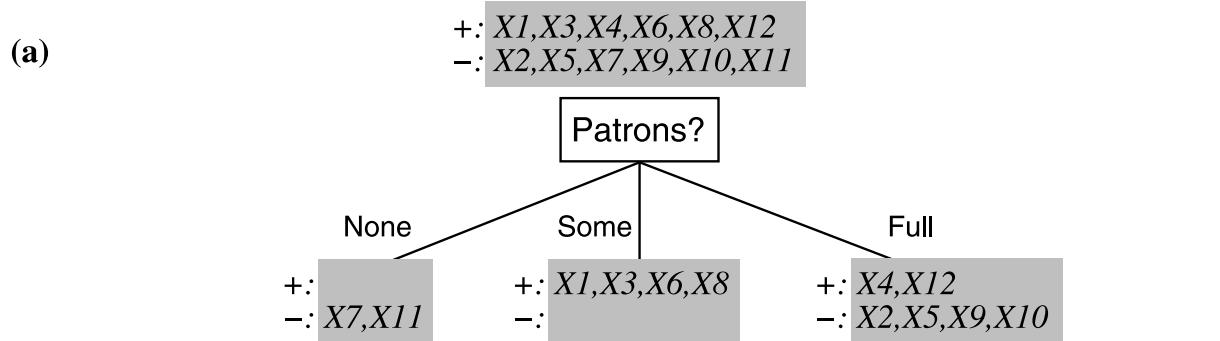
CHOOSING AN ATTRIBUTE

ایده: یک خصیصه‌ی خوب، مثال‌هارا به مجموعه‌هایی که (در حالت ایدهآل) «همه مثبت» یا «همه منفی» هستند، می‌شکند.



گزینه‌ی **Patrons?**

در مورد طبقه‌بندی اطلاعات می‌دهد.



اطلاعات

آنتروپی

INFORMATION

اطلاعات به پرسش‌ها پاسخ می‌دهد

اطلاعات

Information

هر چه در ابتدا من درمورد پاسخ ناآگاهتر باشم، اطلاعات بیشتری در پاسخ وجود دارد.

۱ بیت = پاسخ به پرسش دودویی با احتمال پیشین $\langle 0.5, 0.5 \rangle$

مقیاس اطلاعات
Information Scale

اطلاعات موجود در یک پاسخ وقتی احتمال پیشین برآمدها $\langle P_1, P_n, \dots \rangle$ است:

$$H(\langle P_1, \dots, P_n \rangle) = \sum_{i=1}^n -P_i \log_2 P_i$$

(موسوم به آنتروپی پیشین)

درخت تصمیم

استفاده از اطلاعات برای انتخاب خصیصه

USING INFORMATION

Suppose we have p positive and n negative examples at the root

$\Rightarrow H(\langle p/(p+n), n/(p+n) \rangle)$ bits needed to classify a new example

E.g., for 12 restaurant examples, $p=n=6$ so we need 1 bit

An attribute splits the examples E into subsets E_i , each of which (we hope) needs less information to complete the classification

Let E_i have p_i positive and n_i negative examples

$\Rightarrow H(\langle p_i/(p_i+n_i), n_i/(p_i+n_i) \rangle)$ bits needed to classify a new example

\Rightarrow **expected** number of bits per example over all branches is

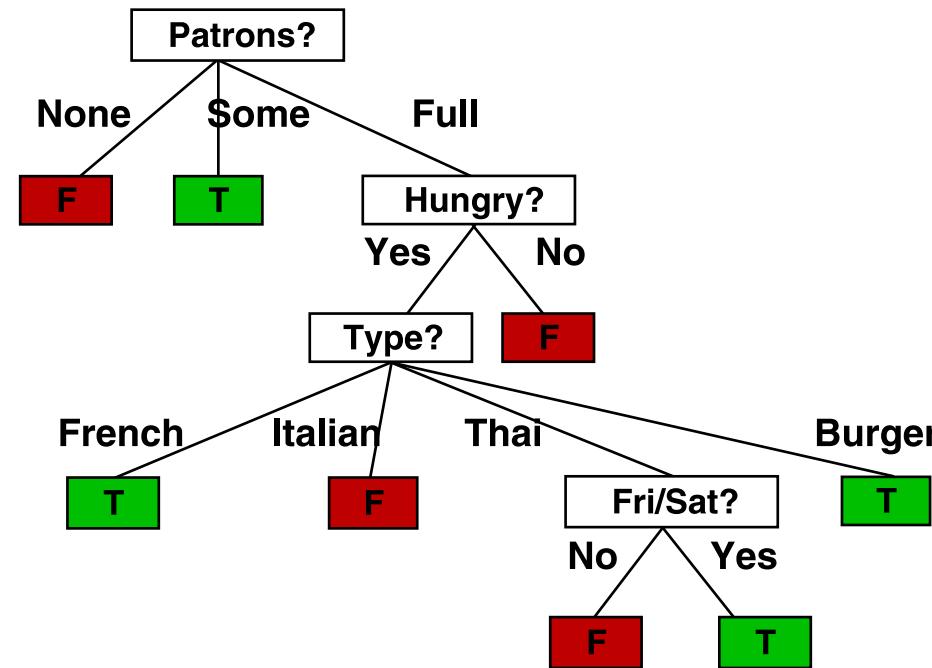
$$\sum_i \frac{p_i + n_i}{p + n} H(\langle p_i/(p_i+n_i), n_i/(p_i+n_i) \rangle)$$

For *Patrons?*, this is 0.459 bits, for *Type* this is (still) 1 bit

\Rightarrow choose the attribute that minimizes the remaining information needed

درخت تصمیم

مثال



درخت تصمیم یاد گرفته شده از روی ۱۲ مثال مسئله‌ی رستوران

ارزیابی کارآیی

PERFORMANCE MEASUREMENT

چگونه می‌توانیم بدانیم که $h \approx f$ ؟

(مسئله‌ی استقرای دیوید هیوم)

۱) استفاده از قضیه‌های نظریه‌ی یادگیری محاسباتی/آماری

۲) آزمایش h بر روی یک مجموعه‌ی آزمایشی جدید از مثال‌ها
(با استفاده از توزیع مشابهی مانند مجموعه‌ی آموزشی روی فضای مثال‌ها)

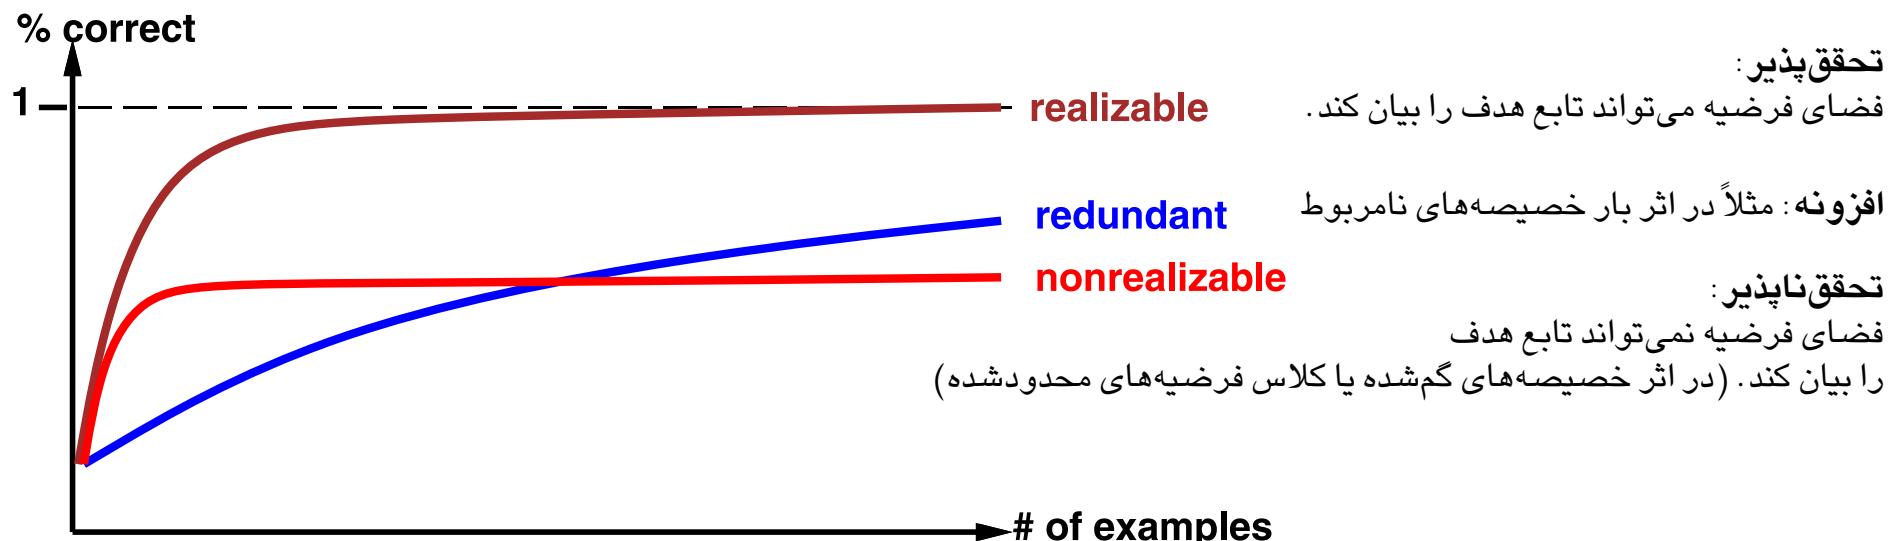
ارزیابی کارآیی

منحنی یادگیری

PERFORMANCE MEASUREMENT

% پاسخ‌های درست روی مجموعه‌ی آزمایشی به صورت تابعی از اندازه‌ی مجموعه‌ی آموزشی

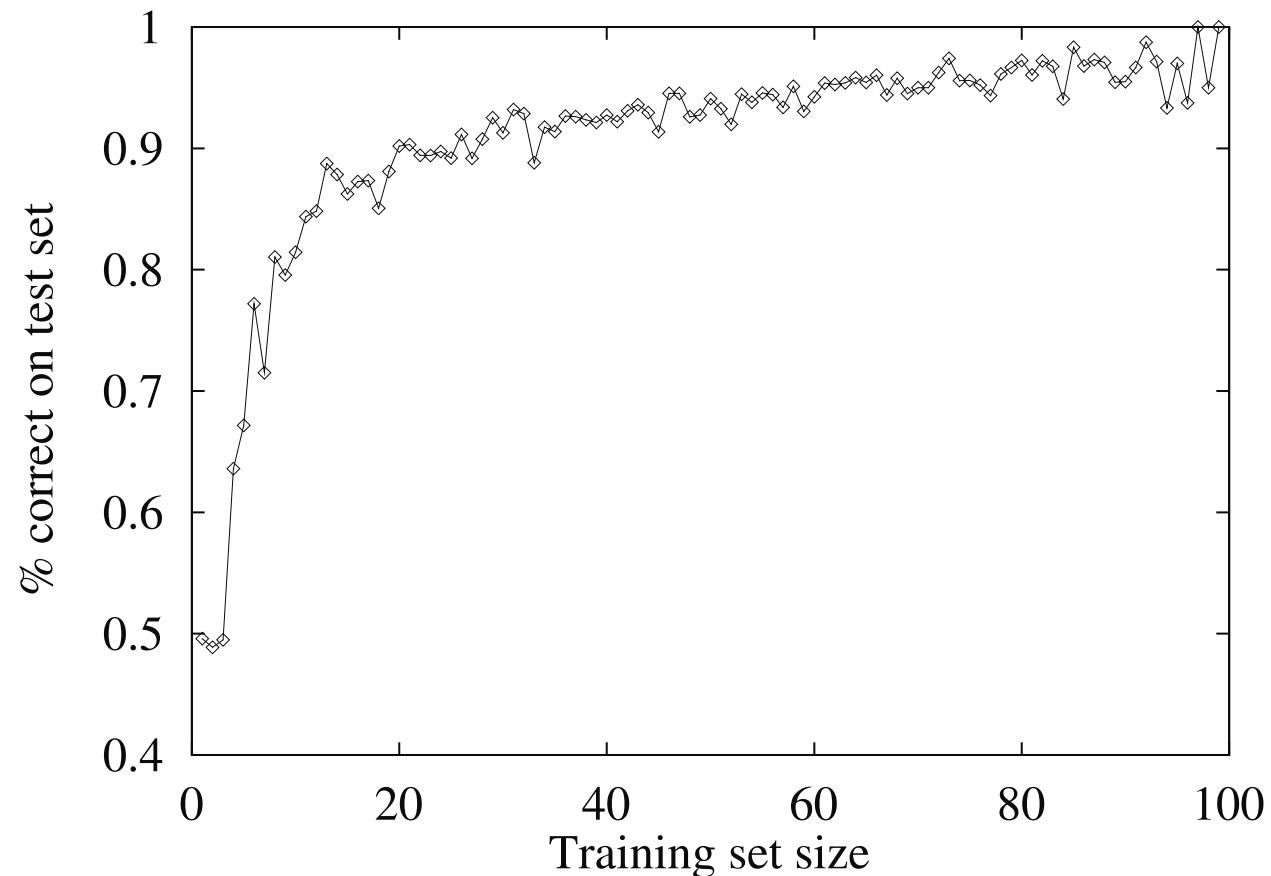
منحنی یادگیری
Learning Curve



ارزیابی کارآئی

منحنی یادگیری: مثال

PERFORMANCE MEASUREMENT



منحنی یادگیری الگوریتم درخت تصمیم با ۱۰۰ نمونه‌ی تصادفی برای مسئله‌ی رستوران

یادگیری از مثال‌ها

۱۴

ارزیابی
و
انتخاب
بهترین
فرضیه

هوش مصنوعی

یادگیری از مثال‌ها

۵

نظریه‌ی
یادگیری

هوش مصنوعی

یادگیری از مثال‌ها

۶

رگرسیون
و
طبقه‌بندی
با
مدل‌های خطی

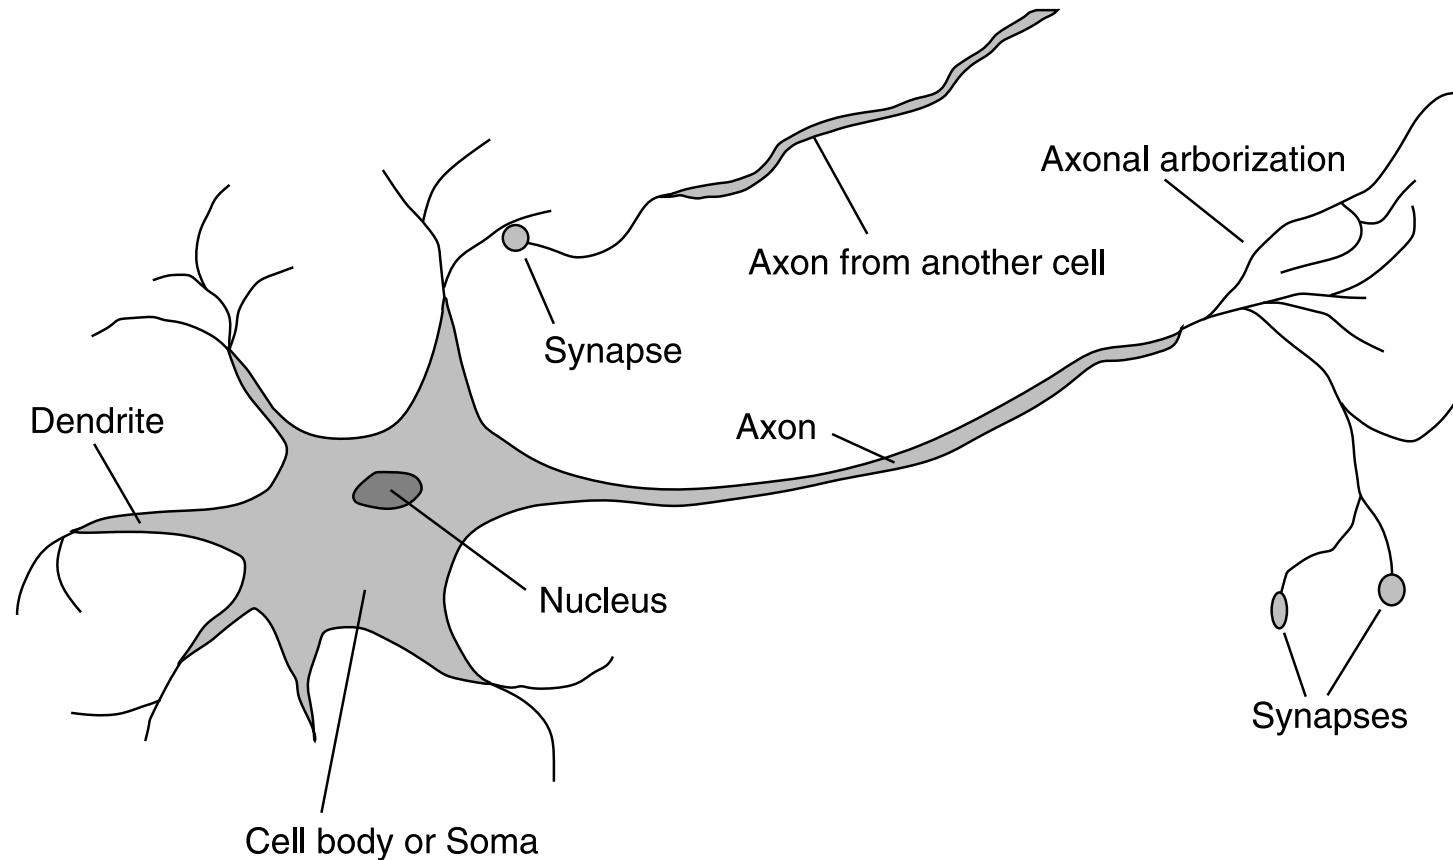
هوش مصنوعی

یادگیری از مثال‌ها

۷

شبکه‌های
عصبی
مصنوعی

مغز

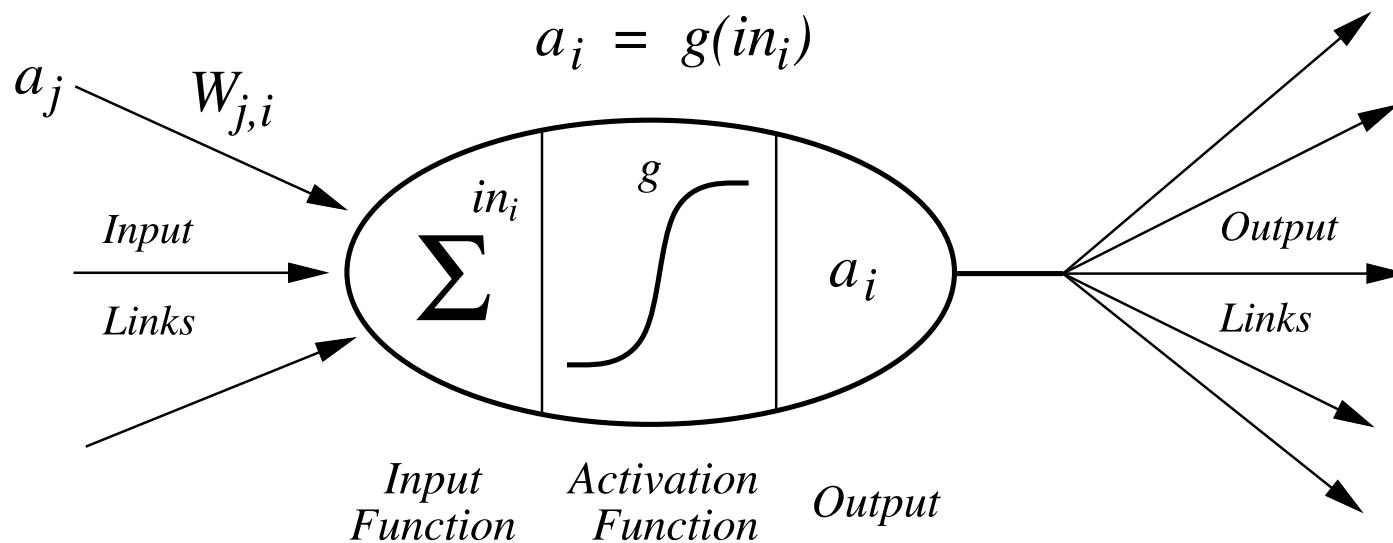
BRAIN

- 10^{11} neurons of > 20 types, 10^{14} synapses, 1ms–10ms cycle time
- Signals are noisy “spike trains” of electrical potential

شبکه‌های عصبی مصنوعی

واحد «مکللوچ-پیتز»

McCULLOCH-PITTS "UNIT"

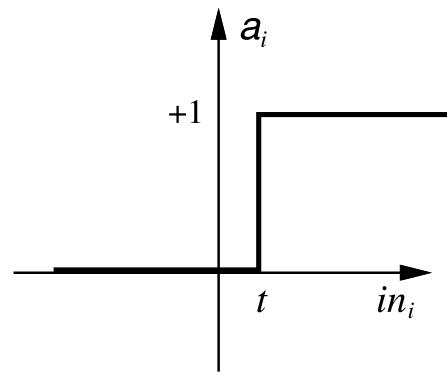


یک مدل بسیار ساده‌شده از نرون واقعی:

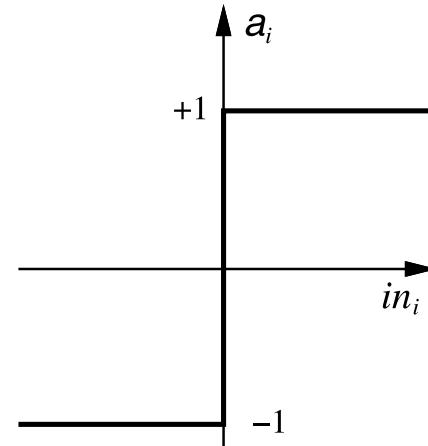
با هدف توسعه‌ی درک اینکه شبکه‌های متشكل از واحدهای ساده چه کاری می‌توانند انجام دهند.

شبکه‌های عصبی مصنوعی

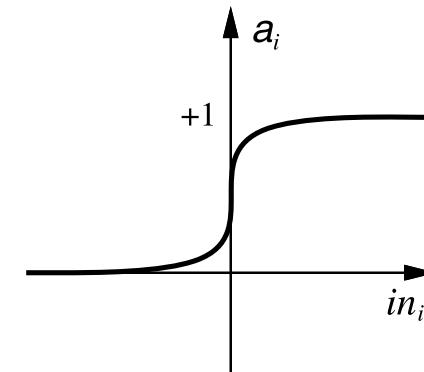
توابع فعال‌سازی

ACTIVATION FUNCTIONS

(a) Step function



(b) Sign function



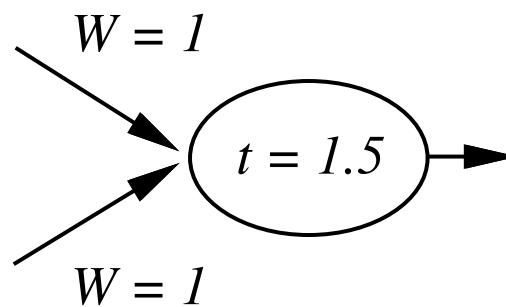
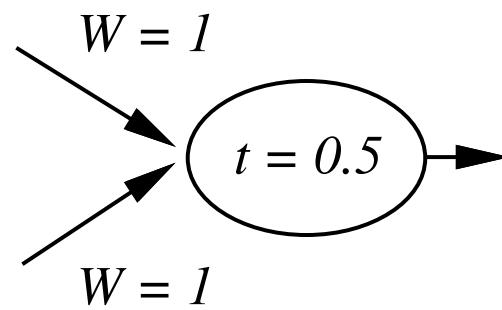
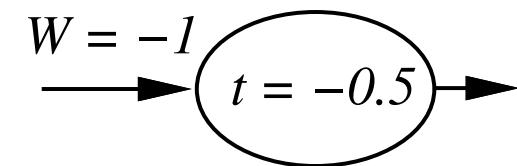
(c) Sigmoid function

$$1/(1 + e^{-x})$$

Changing the bias weight $W_{0,i}$ moves the threshold location

شبکه‌های عصبی مصنوعی

پیاده‌سازی توابع منطقی

IMPLEMENTING LOGICAL FUNCTIONS**AND****OR****NOT**

شبکه‌های عصبی مصنوعی

ساختارهای شبکه

NETWORK STRUCTURES

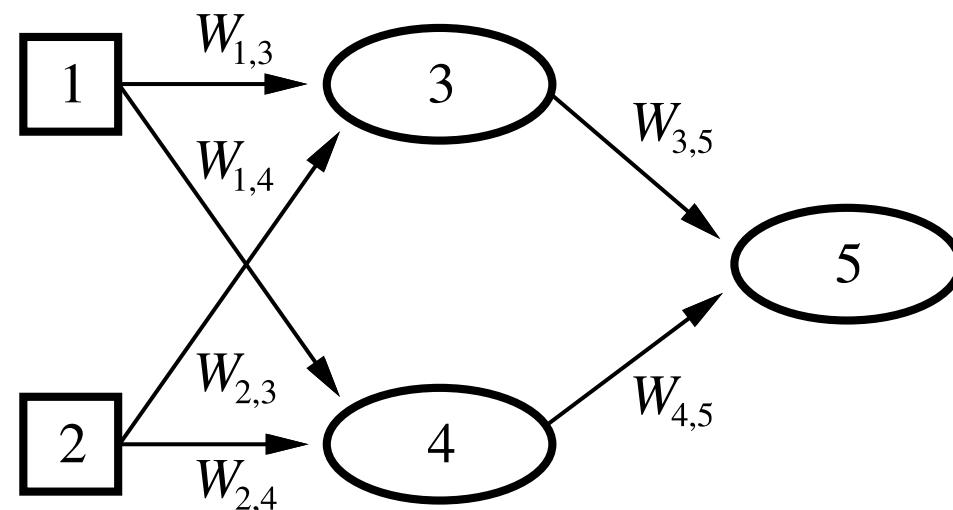
ساختارهای شبکه‌های عصبی مصنوعی			
شبکه‌های بازگشتی <i>Recurrent Networks</i>	شبکه‌های پیش‌خور <i>Feed-forward Networks</i>		
توابع دارای حالت داخلی (مانند فلیپ‌فلاپ) را پیاده‌سازی می‌کنند.	توابع بدون حالت داخلی را پیاده‌سازی می‌کنند.		
با فیدبک / چرخه‌های جهت‌دار با تاخیرها	بدون فیدبک		
ماشین‌های بولتزمن <i>Boltzmann Machines</i>	شبکه‌های هاپفیلد <i>Hopfield Networks</i>	پرسپترون چندلایه <i>Single-Layer Perceptron</i>	پرسپترون تک‌لایه <i>Single-Layer Perceptron</i>
تابع فعال‌سازی اتفاقی ≈ در شبکه‌های بیزی MCMC	دارای وزن‌های متقارن تابع فعال‌سازی علامت حافظه‌ی انجمانی هولوگرافیک		

$$g(x) = \text{sign}(x), \quad a_i = \pm 1$$

شبکه‌های عصبی مصنوعی

ساختارهای شبکه: شبکه‌ی پیش‌خور: مثال

FEED-FORWARD EXAMPLE



شبکه‌ی پیش‌خور = یک خانواده‌ی پارامتری شده از توابع غیرخطی

$$\begin{aligned}
 a_5 &= g(W_{3,5} \cdot a_3 + W_{4,5} \cdot a_4) \\
 &= g(W_{3,5} \cdot g(W_{1,3} \cdot a_1 + W_{2,3} \cdot a_2) + W_{4,5} \cdot g(W_{1,4} \cdot a_1 + W_{2,4} \cdot a_2))
 \end{aligned}$$

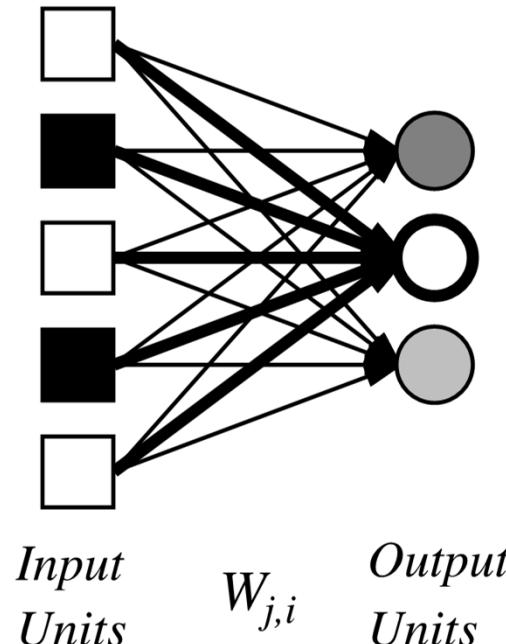
تنظیم وزن‌ها، تابع را تغییر می‌دهد: انجام یادگیری از این طریق

شبکه‌های عصبی مصنوعی

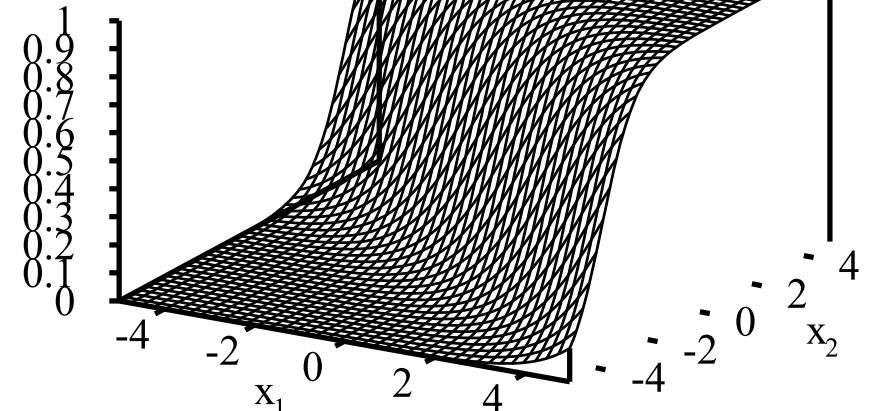
پرسپترون‌های تک‌لایه

SINGLE-LAYER PERCEPTRONS

خروجی همهٔ واحدها همگی جداگانه عمل می‌کنند (هیچ وزن مشترکی وجود ندارد).



Perceptron output



شكل کلی رویهٔ تصمیم‌گیری (حالت دو متغیر ورودی): تنظیم وزن‌ها، مکان، جهت و شیب صخره را حرکت می‌دهد.

شبکه‌های عصبی مصنوعی

پرسپترون تکلایه: رسایی پرسپترون‌ها

EXPRESSIVENESS OF PERCEPTRONS

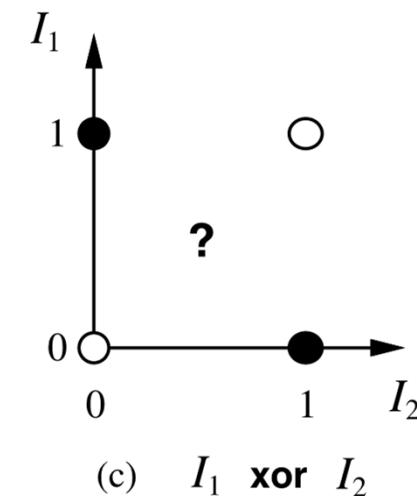
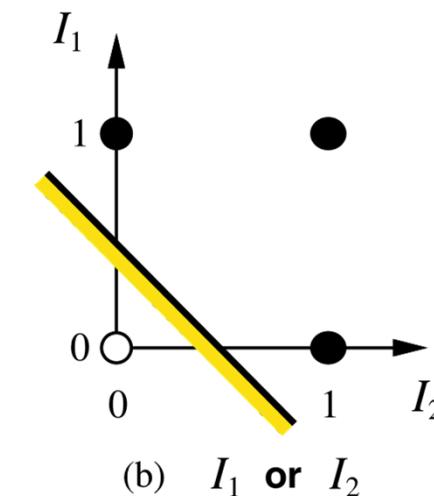
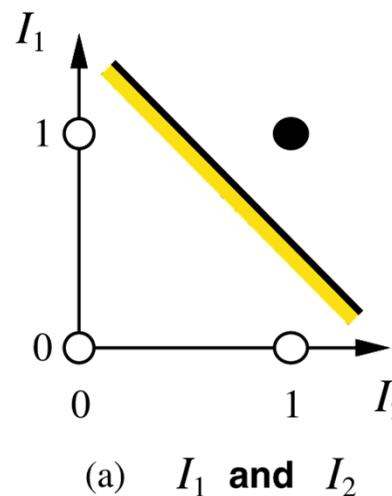
پرسپترون با تابع فعال‌سازی $\text{پله} = g$

پرسپترون یک جداساز خطی را در فضای ورودی بازنمایی می‌کند:

$$\sum_j W_j x_j > 0 \quad \text{or} \quad \mathbf{W} \cdot \mathbf{x} > 0$$

پرسپترون می‌تواند توابع NOT, OR, AND و Majority و ... را بازنمایی کند.

پرسپترون نمی‌تواند تابع XOR را بازنمایی کند.



شبکه‌های عصبی مصنوعی

پرسپترون تکلایه: یادگیری پرسپترون

PERCEPTRON LEARNING

یادگیری با تنظیم وزن‌ها برای کاهش خطا بر روی مجموعه‌ی آموزشی

مجدور خطا برای یک مثال با ورودی \mathbf{x} و خروجی واقعی y :

$$E = \frac{1}{2} Err^2 \equiv \frac{1}{2} (y - h_{\mathbf{W}}(\mathbf{x}))^2 ,$$

انجام جستجوی بهینه‌سازی با کاهش گرادیانی:

$$\begin{aligned} \frac{\partial E}{\partial W_j} &= Err \times \frac{\partial Err}{\partial W_j} = Err \times \frac{\partial}{\partial W_j} (y - g(\sum_{j=0}^n W_j x_j)) \\ &= -Err \times g'(in) \times x_j \end{aligned}$$

قاعده‌ی ساده برای بهنگام‌سازی وزن‌ها:

$$W_j \leftarrow W_j + \alpha \times Err \times g'(in) \times x_j$$

برای مثال:

خطای مثبت \Leftarrow افزایش خروجی شبکه

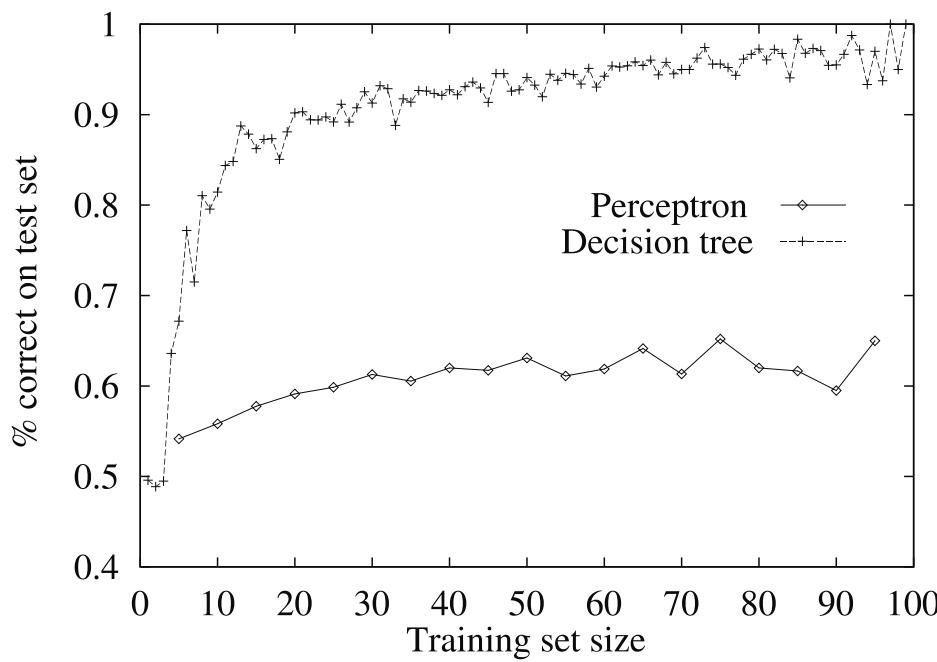
\Leftarrow لزوم افزایش وزن‌ها روی ورودی‌های مثبت، کاهش وزن‌ها روی ورودی‌های منفی

شبکه‌های عصبی مصنوعی

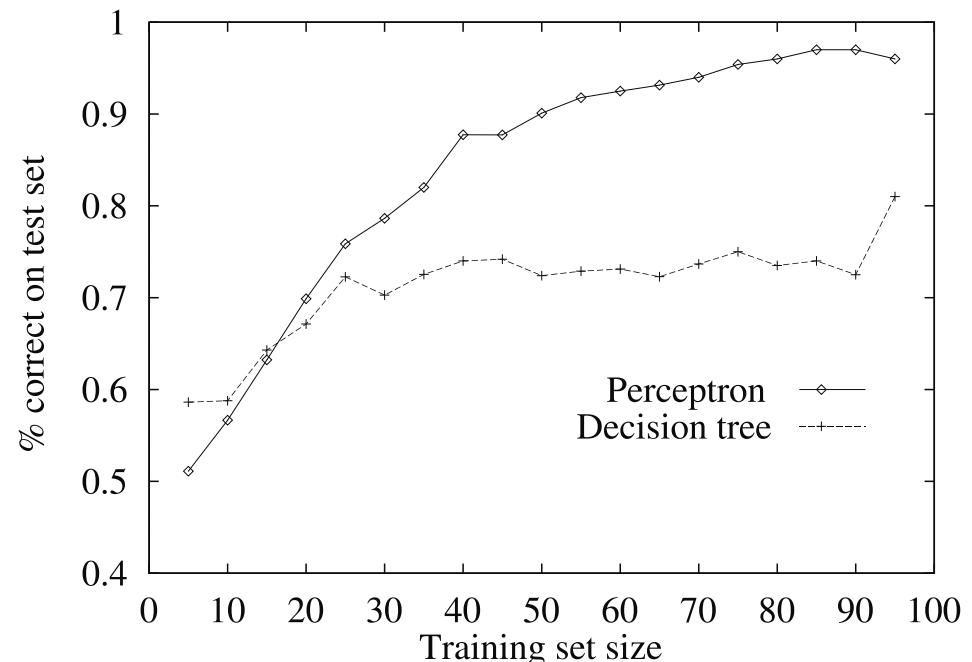
پرسپترون تکلایه: یادگیری پرسپترون: ویژگی‌ها

PERCEPTRON LEARNING

قاعده‌ی یادگیری پرسپترون، به یک تابع سازگار همگرا می‌شود
برای هر مجموعه داده‌ی جدایی‌پذیر خطی



تابع مسئله‌ی رستوران



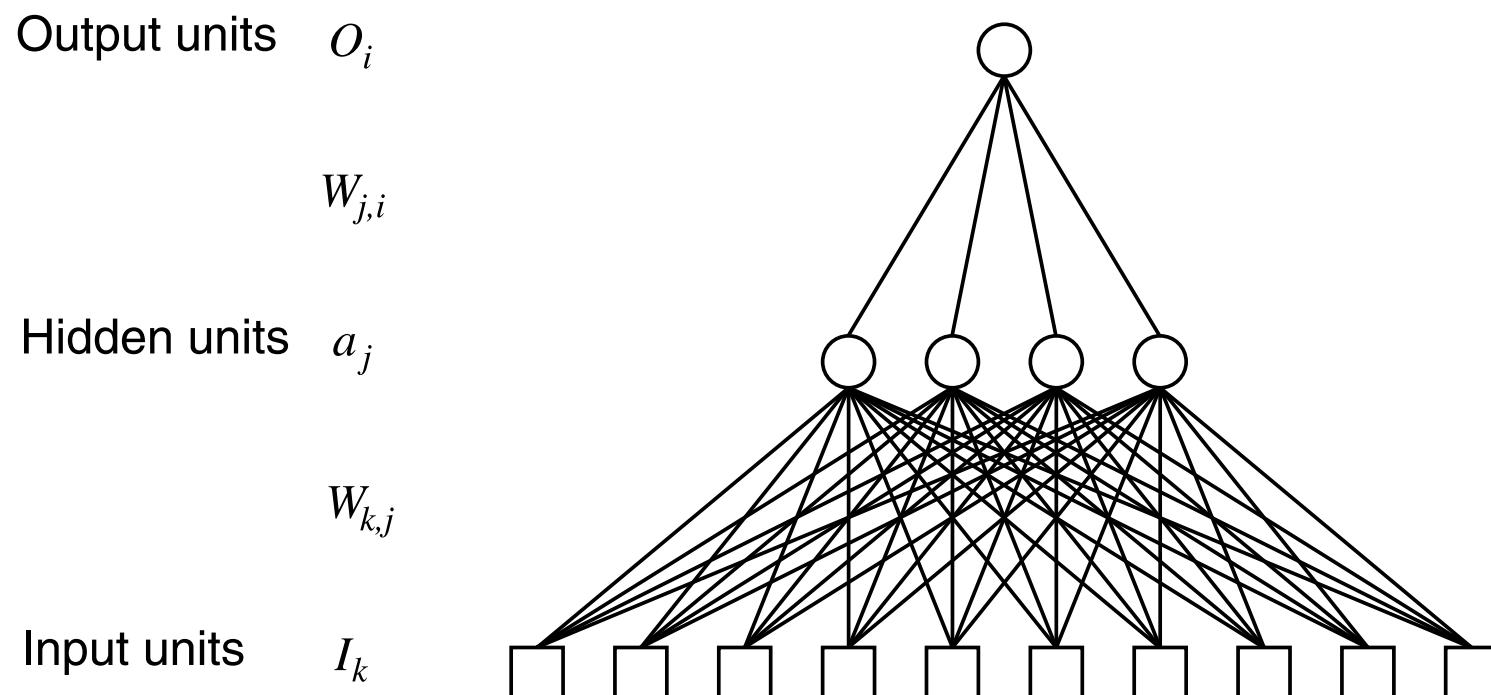
تابع اکثریت Majority

شبکه‌های عصبی مصنوعی

پرسپترون‌های چندلایه

MULTILAYER PERCEPTRONS

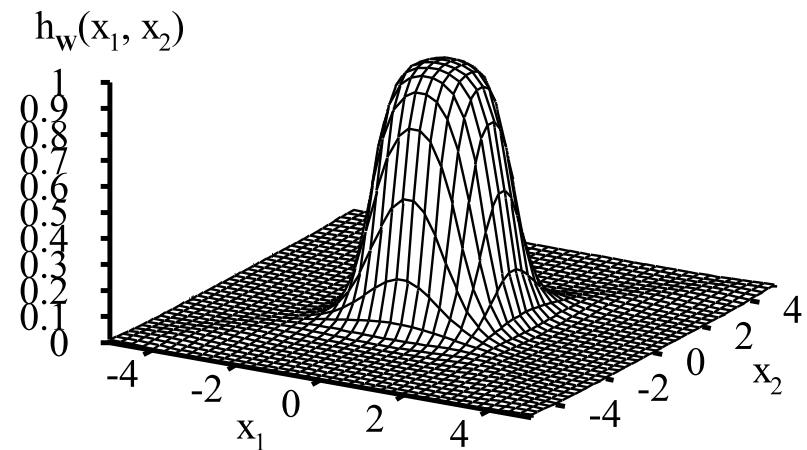
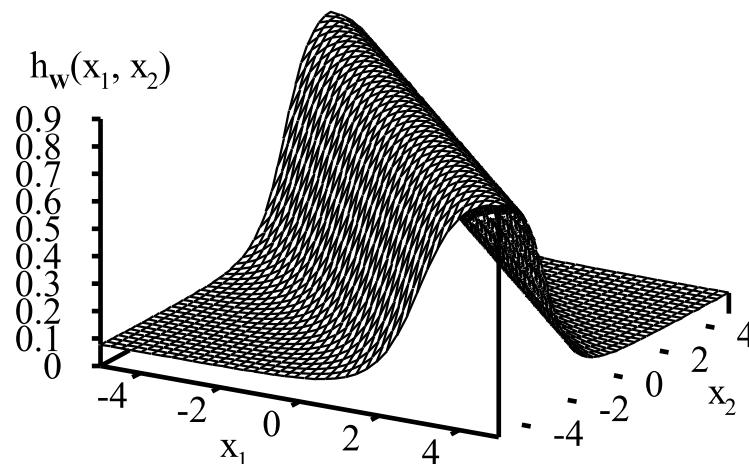
لایه‌ها معمولاً به طور کامل به هم متصل هستند.
تعداد واحدهای لایه‌ی پنهان معمولاً دستی تعیین می‌شود.



شبکه‌های عصبی مصنوعی

پرسپترون‌های چندلایه: رسائی

EXPRESSIVENESS OF MLPs



همهی توابع پیوسته با دو لایه
همهی توابع با سه لایه

ترکیب دو تابع آستانه با وجوده مخالف \Leftarrow ایجاد تیغه

ترکیب دو تیغه‌ی متعامد \Leftarrow ایجاد یک برآمدگی

اضافه کردن برآمدگی‌ها با اندازه‌ها و مکان‌های گوناگون برای برازش هر رویه‌ی دلخواه
(نیاز به تعداد نمایی واحد پنهان)

شبکه‌های عصبی مصنوعی

پرسپترون‌های چندلایه: یادگیری پس انتشار

BACK-PROPAGATION LEARNING

لایه‌ی خروجی: مشابه لایه‌ی پرسپترون تک‌لایه

$$W_{j,i} \leftarrow W_{j,i} + \alpha \times a_j \times \Delta_i$$

$$\Delta_i = Err_i \times g'(in_i)$$

لایه‌ی پنهان: خطای خروجی به پشت منتشر می‌شود (back-propagate)

$$\Delta_j = g'(in_j) \sum_i W_{j,i} \Delta_i$$

قاعده‌ی به‌هنگام‌سازی برای وزن‌ها در لایه‌ی پنهان:

$$W_{k,j} \leftarrow W_{k,j} + \alpha \times a_k \times \Delta_j$$

(بسیاری از نروساینتیست‌ها انکار می‌کنند که در مغز پس انتشار رخ می‌دهد!)

شبکه‌های عصبی مصنوعی

پرسپترون‌های چندلایه: یادگیری پساننتشار: استخراج فرمول (۱)

BACK-PROPAGATION LEARNING

مجدور خطاب روی یک مثال واحد به صورت زیر تعریف می‌شود:

$$E = \frac{1}{2} \sum_i (y_i - a_i)^2 ,$$

که در آن مجموع روی همه گره‌ها در لایه خروجی محاسبه می‌شود.

$$\begin{aligned} \frac{\partial E}{\partial W_{j,i}} &= -(y_i - a_i) \frac{\partial a_i}{\partial W_{j,i}} = -(y_i - a_i) \frac{\partial g(in_i)}{\partial W_{j,i}} \\ &= -(y_i - a_i) g'(in_i) \frac{\partial in_i}{\partial W_{j,i}} = -(y_i - a_i) g'(in_i) \frac{\partial}{\partial W_{j,i}} \left(\sum_j W_{j,i} a_j \right) \\ &= -(y_i - a_i) g'(in_i) a_j = -a_j \Delta_i \end{aligned}$$

شبکه‌های عصبی مصنوعی

پرسپترون‌های چندلایه: یادگیری پساننتشار: استخراج فرمول (۲)

BACK-PROPAGATION LEARNING

$$\begin{aligned}
 \frac{\partial E}{\partial W_{k,j}} &= -\sum_i (y_i - a_i) \frac{\partial a_i}{\partial W_{k,j}} = -\sum_i (y_i - a_i) \frac{\partial g(in_i)}{\partial W_{k,j}} \\
 &= -\sum_i (y_i - a_i) g'(in_i) \frac{\partial in_i}{\partial W_{k,j}} = -\sum_i \Delta_i \frac{\partial}{\partial W_{k,j}} \left(\sum_j W_{j,i} a_j \right) \\
 &= -\sum_i \Delta_i W_{j,i} \frac{\partial a_j}{\partial W_{k,j}} = -\sum_i \Delta_i W_{j,i} \frac{\partial g(in_j)}{\partial W_{k,j}} \\
 &= -\sum_i \Delta_i W_{j,i} g'(in_j) \frac{\partial in_j}{\partial W_{k,j}} \\
 &= -\sum_i \Delta_i W_{j,i} g'(in_j) \frac{\partial}{\partial W_{k,j}} \left(\sum_k W_{k,j} a_k \right) \\
 &= -\sum_i \Delta_i W_{j,i} g'(in_j) a_k = -a_k \Delta_j
 \end{aligned}$$

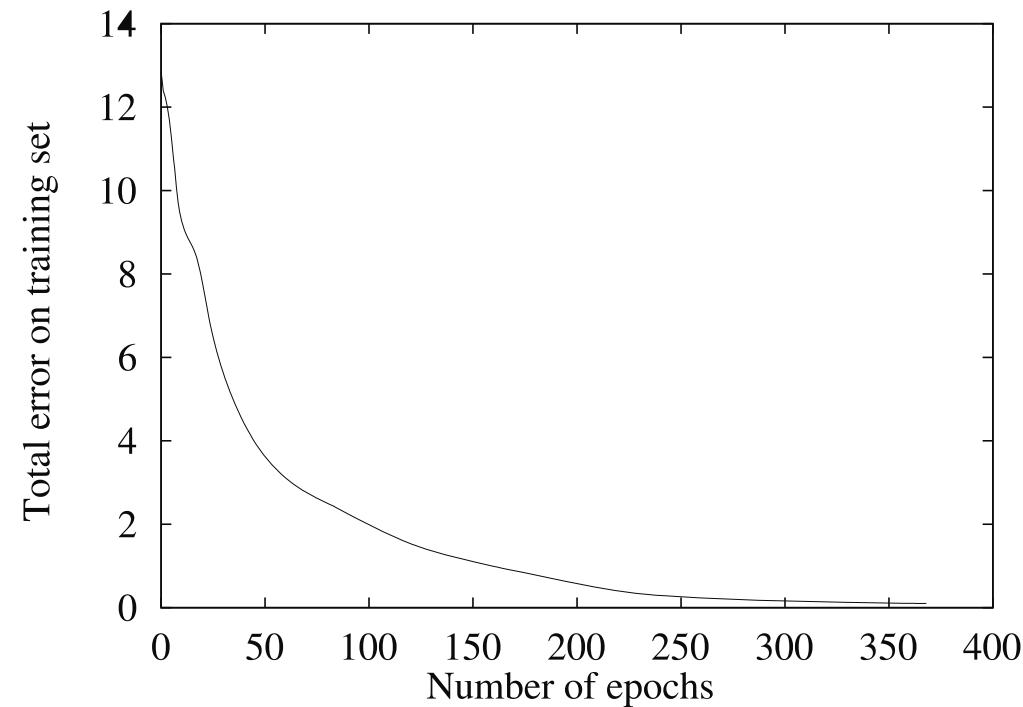
شبکه‌های عصبی مصنوعی

پرسپترون‌های چندلایه: یادگیری پس انتشار: ویژگی‌ها

BACK-PROPAGATION LEARNING

در هر اپک (epoch)، بهنگام سازی‌های گرادیان را برای همهٔ مثال‌ها جمع بزنید و اعمال کنید.

منحنی آموزش (training curve)



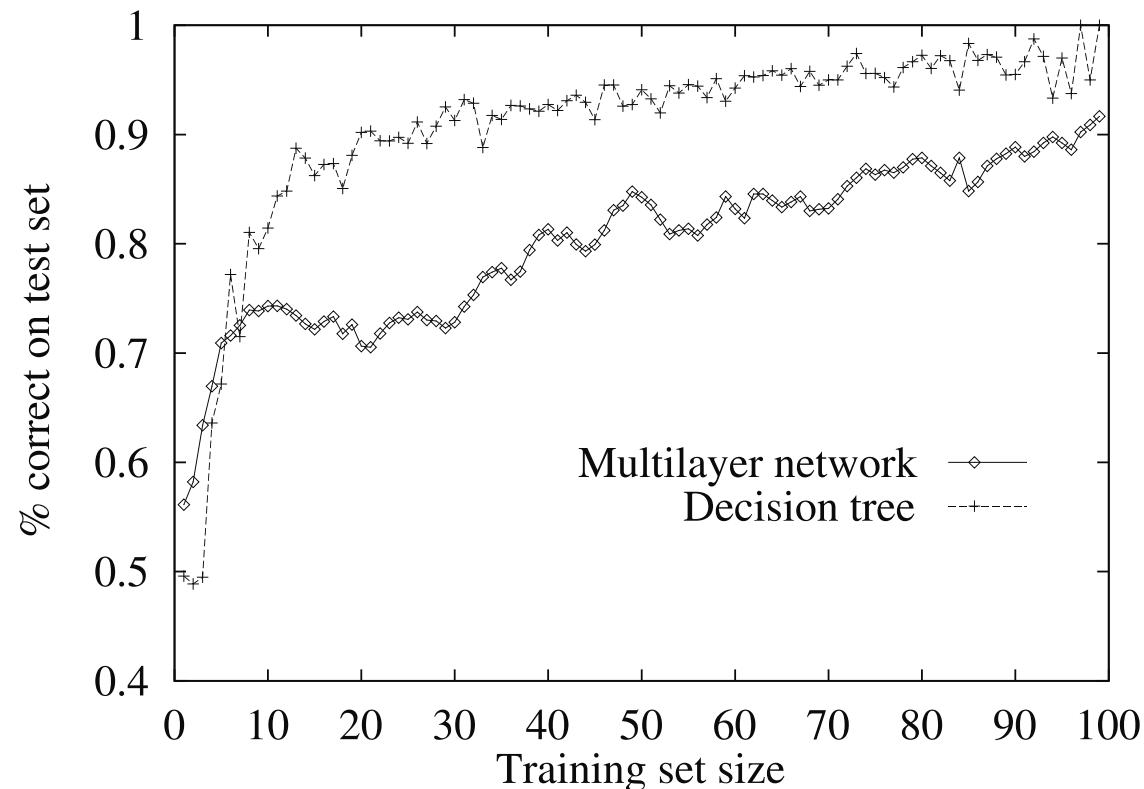
مشکل نوعی: همگرایی کند، می‌نیم‌های محلی

شبکه‌های عصبی مصنوعی

پرسپترون‌های چندلایه: یادگیری پسانشار: ویژگی‌ها

BACK-PROPAGATION LEARNING

منحنی یادگیری برای MLP با ۴ واحد پنهان



MLP‌ها برای وظایف بازشناسی الگوی پیچیده بسیار خوب هستند،
اما فرضیه‌های حاصل نمی‌توانند به سادگی فهمیده شوند.

هوش مصنوعی

یادگیری از مثال‌ها



مدل‌های ناپارامتری

هوش مصنوعی

یادگیری از مثال‌ها

۹

ماشین‌های
بردار
پشتیبان

هوش مصنوعی

یادگیری از مثال‌ها

۱ •

یادگیری
دسته‌جمعی

هوش مصنوعی

یادگیری از مثال‌ها

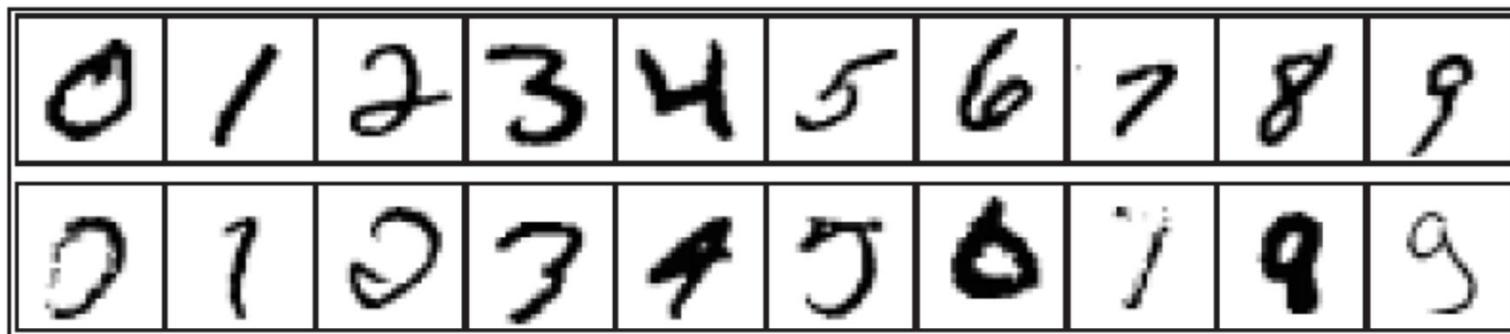
۱۱

یادگیری
ماشینی
عملی

بازشناسی اعداد دستنویس

مثالی از یادگیری بانظارت

HANDWRITTEN DIGIT RECOGNITION



3-nearest-neighbor = 2.4% error

400–300–10 unit MLP = 1.6% error

LeNet: 768–192–30–10 unit MLP = 0.9% error

Current best (kernel machines, vision algorithms) \approx 0.6% error

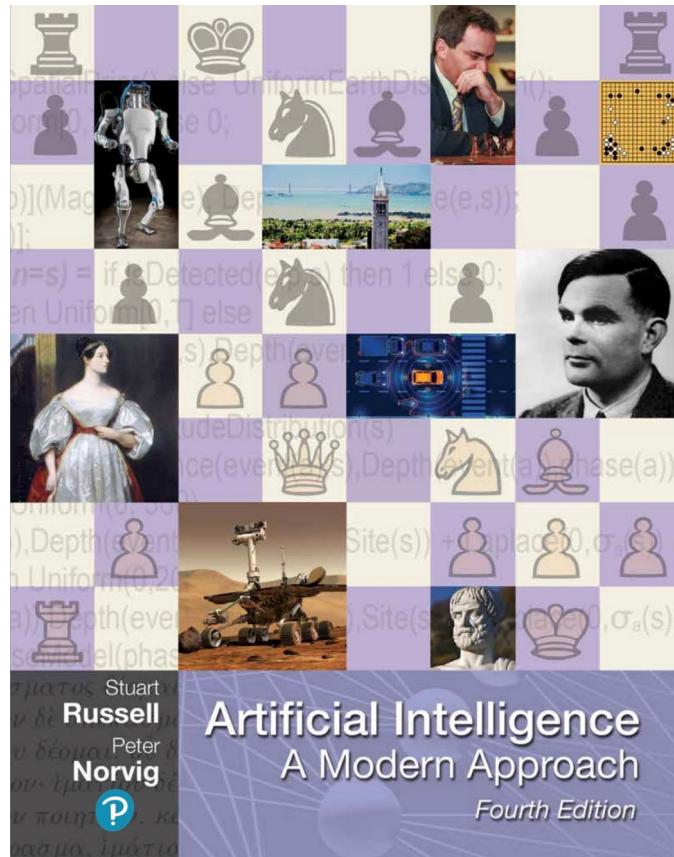
هوش مصنوعی

یادگیری از مثال‌ها

۱۲

منابع

منبع اصلی



Stuart Russell and Peter Norvig,
Artificial Intelligence: A Modern Approach,
4th Edition, Prentice Hall, 2020.

Chapter 19

CHAPTER 19

LEARNING FROM EXAMPLES

In which we describe agents that can improve their behavior through diligent study of past experiences and predictions about the future.

An agent is **learning** if it improves its performance after making observations about the world. Learning can range from the trivial, such as jotting down a shopping list, to the profound, as when Albert Einstein inferred a new theory of the universe. When the agent is a computer, we call it **machine learning**: a computer observes some data, builds a **model** based on the data, and uses the model as both a **hypothesis** about the world and a piece of software that can solve problems.

Machine learning

Why would we want a machine to learn? Why not just program it the right way to begin with? There are two main reasons. First, the designers cannot anticipate all possible future situations. For example, a robot designed to navigate mazes must learn the layout of each new maze it encounters; a program for predicting stock market prices must learn to adapt when conditions change from boom to bust. Second, sometimes the designers have no idea how to program a solution themselves. Most people are good at recognizing the faces of family members, but they do it subconsciously, so even the best programmers don't know how to program a computer to accomplish that task, except by using machine learning algorithms.

In this chapter, we interleave a discussion of various model classes—decision trees (Section 19.3), linear models (Section 19.6), nonparametric models such as nearest neighbors (Section 19.7), ensemble models such as random forests (Section 19.8)—with practical advice on building machine learning systems (Section 19.9), and discussion of the theory of machine learning (Sections 19.1 to 19.5).

19.1 Forms of Learning

Any component of an agent program can be improved by machine learning. The improvements, and the techniques used to make them, depend on these factors:

- Which *component* is to be improved.
- What *prior knowledge* the agent has, which influences the *model* it builds.
- What *data* and *feedback* on that data is available.

Chapter 2 described several agent designs. The **components** of these agents include:

1. A direct mapping from conditions on the current state to actions.
2. A means to infer relevant properties of the world from the percept sequence.
3. Information about the way the world evolves and about the results of possible actions the agent can take.