


Subject:

Year. Month. Date. (d)



© یادگیری ماشین :

* راج *

Machine learning : Tom Mitchell

Reinforcement learning : S. Sutton

* استادی *

shiry@aut.ac.ir

seit.aut.ac.ir/~shiry

* کوش *

Kouresh Meshgi

0912-2129404

2nd Semester 1387-8

Subject :

Year : Month : Date : ()

* یادگیری

- کسب دانش ← تهیه و عملکرد
- تجربه ← سه مهارت
- دانش ← دانش

- یادگیری عبارتست از بهیچر و عملکرد از طریق تجربه
- یادگیری عبارتست از بدست آوردن دانش با کمک آن از طریق مطالعه ، آموختن و یا تجربه

* یادگیری ماشین

- پرورش ذهنی ← نوشتن برنامه (عامل) ← رفتار عاملانه ، ...
- یادگیری ماشین ← برنامه


که کسب تجربه
با تغییر ساختار برنامه

* ابزار

- Matlab
- Weka

* الگوریتم

برنامه‌های تولید که صورت آن را در دانش تصویر شخصی دهد.




دنیای واقعی (تصویر تهیه) ← دنیای کامپیوتر (مدل)

دنیای کامپیوتر ← در آوردن مدل ← تبدیل مدل در آوردن
 برنامه نویسی

بزار تلهی


مثال ، ±



دیتا سٹیم
یادگیری



برنامه ای که در این طریق
مثال یادگیری می کند
که + و - را جدا کند.



معمولاً بر مبنای داده های آماری

- * کاربرد:
- کنترل روبات
- داده آماری
- تشخیص کلمات
- شناسایی متن
- پردازش تصاویر
- بازی های کامپیوتری

- * طبیعت بندی یادگیری ماشین
- دسته بندی
- حل مسدود جراحی و عمل

- * مبنای ارزیابی الگوریتم های یادگیری
- وقت دسته بندی
- صحت راه حل و کیفیت آن
- سرعت عملکرد

* طبقه‌بندی مختلف یادگیری

- ← استنتاج
- ← مدل متر
- ← آمار احتمالات
- ← تجربه در محیط
- ← تدریجی کامل

- Inductive .
- Connectionist .
- Bayesian .
- Reinforcement .
- Evolutionary .

* انواع یادگیری از لحاظ نظر

- Supervised .
- Unsupervised .

این دسته‌بندی برای ML ← function approximation

Generalization

* یادگیری برای دست‌نویس تشخیص

- * اجزای طراحی یادگیری
- Task : وظیفه‌ای که ماشین باید انجام دهد.
- Performance : معیاری که کارایی برنامه را نشان می‌دهد.
- Training Exp : مراحل آموزش برنامه برای کسب تجربه.

* دانشی درمورد راه

- دردی : در بین روی سفت نویسی
- تجربه آموزشی : یاد دهنده ، دانشی می‌دهد ، کامپیوتر رفتار دانشی یاد می‌گیرد

Checkers بازی

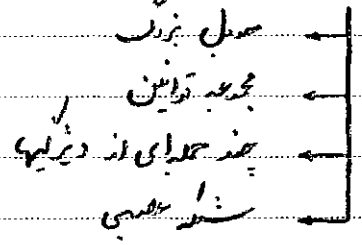
- تجربه آموختن ①
- چند نفر بازی می کنند و بازی آنها نظارت می شود. — برزین بر
- تجربه آموختن ②
- کامپیوتر بر علیه خودش بازی کند

• نتیجه یادگیری: در صفحه B را به کامپیوتر بدهیم، بهترین حرکت M را به ما بدهد
 این کار بسیار دشوار است.
 حال سعی می کنیم جای بر صفحه B تعداد مسکنه را یاد بگیریم که اندک صفحه را
 به ما بدهد.
 $move: B \rightarrow M$
 $\hat{V}: B \rightarrow IR$

• معیار ارزیابی: آرایش نهایی — برادتی تعداد دهی می شود
 و صفت دی میانی — چگونه آرایش نهایی می رود.

• فیدبک: مستقیم — حالت آرایش صفحه و حرکت صحیح بر حالت مرتبط برمی سنجی می شود.
 غیر مستقیم — محدودی از حرکات پشت سر هم از یک بازی و نتیجه آن بر صورت باشد.
 که بازی بر عمل یاداش نمی گیریم.

بازو بازی: Function Approximation: ($\hat{V} \rightarrow V$)



Trade-off: دقت ⇄ تعداد مثالها

Sample $\uparrow \Rightarrow \hat{V} \rightarrow V$

Subject:

Year. Month. Date. ()

$$\hat{y} \rightarrow w_i$$

تربیب زنی

$$f(B) = w_0 + w_1 x_1 + \dots + w_n x_n$$

↳ feature 1

جای تنظیم وزنها از روشهایی استنداره می شود. مثلاً Least Mean Square

استثنا این روش قادر نخواهد بود که انسان را نسبت به همین مسئله‌سازی آن، طرز نمایش داده‌ای مثلاً سطحی استنداره کند.

مراحل کار

۱- تعیین خرد آموختنی ← ابعاد

۲- تعیین تابع هدف



۳- نحوه نمایش تابع یاد گرفته شده

سطحی
چند جمله‌ای
شبه خطی

۴- تعیین الگوریتم یادگیری

* زمینه‌های مناسب الگوریتم یادگیری

• سرعت

• سادگی ← حجم حسابات + حافظه

• دقت ← قابلیت اطمینان

Real Time

* سدهای مطرح در باره مسائل یادگیری

• لوجان الگوریتم

• محدودیت داده آموزشی مورد نیاز است ← سبب بی‌پایداری تابع یادگیری

Subject :

Year Month Date (4)

- مثال آموزش بومی ← آموزش اذ اول
- تبدیل سند یادگیری به سند قریب تاج
- باز نایبی خودکار ← سازگاری بیشتر

* یادگیری ندعی سند حسنجو است
این حسنجو بر دنیال یک فرهنید است . ← یک تاج
این فرهنید باید با داده های آموزش ردانش تیلی سازگار باشند .
ایشان Bias کردن نام دارد . ← نیال بر لحن تاج انتخاب شده
یادگیری نیازمند برایش است .

Concept Learning

© یادگیری مفهوم

* مفهوم

- تعریف : یادگیری مفاهیم استیجاب، حرکات، یا ادراک که دارای مجموعه ویژگی متمایز است.
- هدف : دست‌یابی
- یادگیری مفهوم در انسان

Stimulus - Response Association ←

Hall ←

مثالهای متعدد در این زمینه


Rosh ←

- یادگیری در کامپیوتر
- دست آوردن یک مفهوم کلی از روی مثالهای مثبت و منفی
- یادگیری یک تابع بولی

- ✓ آیا این شیء کامپیوتر است؟
- x این شیء چیست؟

• برای یادگیری چند مفهوم، چند سیستم را آموزش می‌دهیم.

✓ یادگیری ارتقا



- مثال آموزش
- مجموعه از ویژگی‌ها
- دسته بندی مثبت یا منفی هر مثال

نمایشها

مثال

فرصت

بازگشت

تابع بین رنگها و جواب + یا -

که در این تابع نوع تابع نشان داده شده


تشفیر لخت

RGB

لخت ← چهره ← رنگ در بیت

نمایش مشابه برای تشخیص صورت

R	G	B	Face
0	0	0	N
⋮	⋮	⋮	⋮
100	73	24	Y



در جدول جابجایی شود (256³) ← اب تابع یاد می گیرد که این رنگ صورت

نسبت یا چیزی؟

Bias

شبدهایی یا تابع لسی




μ_B, σ_B^2



μ_G, σ_G^2



μ_R, σ_R^2



مهندسی در دنیای واقعی ← ویژگیها در دنیای کامپیوتر

ویژگیهای ساده: رنگ، اندازه

ویژگیهای مصنوعی: تبدیل فضا، تبدیل مرجع

چهره

• نمایش فرضیه

مقدار دیگری

?

بر تعدادی قابل قبول باشد

ϕ

هیچ تعدادی قابل قبول نباشد

تعداد خاصی در نتیجه نوترولیت

تابع فرضیه (h) — مجموعه تمام فرضیه (H)

کمی خواهیم در مثال درزش آبی به دنبال سطحی بگردیم که سوابق را مدل کند.

$\langle ? , ? , cold , high , ? , ? \rangle \rightarrow No$

• عمومی ترین فرضیه — همه روزها "؟" باشد

• اختصاصی ترین فرضیه — همه روزها "؟" باشد

• نمونه : مجموعه ای از روزها که مهمان را عزیمت می کند.

• تابع هدف — برای مثالهای مثبت = 1

— برای مثالهای منفی = 0

• فرض اساسی یادگیری استقراضی

پرتابچی که بتواند تقریب خوبی از تابع هدف برای یک مجموعه آموزشی به اندازه کافی بزرگ
باید، قادر خواهد بود که تابع هدف را در حدود مثالهای دیده نشده هم تقریب بخشد.

• تعداد کل فرضیه؟

مجموعی (تعداد تعدادی مجاز دیگری + ϕ + ?) π

مجموعه (تعداد تعدادی مجاز دیگری + ?) π + 1

یعنی هیچ جایی، مثال مثبت نسبت — حالت ناممکنی

روش List - Then - Eliminate

تاک فرضیه را رد می کند.
 با پرشال آموزش، نسبت فرضیه را بر می کند.
 در بیان تعدادی فرضیه باقی می ماند.

نسبت بودن تاک فرضیه؟ غیر ممکن است (فضای بزرگ)
 یادگیری: جستجو در میان تعدادی تاک مثلاً در آن صدق کند.

انتخاب بهتر: گزینه عمومی تر ← از طبقه بندی مثالهای + بالاتر می رود.

جستجو در یادگیری مهندسی

اجازه نمی دهد همه جا را ببرد.

دارای یک heuristic است.

Neural Network → Gradient Descent

Genetic Algorithm → Survival of Fittest

Particle Swarm → local / Global Experiment

مثالیه فرضیه؟

کدام فرضیه بهتر است؟ heuristic

معمولاً عمومی تر بودن فرضیه مطلوب است.

قابلیت تعمیم

عمومی تر

$$h_j \succ h_k : \forall x \in X : h_k(x) = 1 \rightarrow h_j(x) = 1$$

اختیاراً تعمیم پذیری

Find-S روش

- اختصاصی ترین فرضیه که با مثالهای آموزشی تطبیق دارد را پیدا می کند.
- آلا در بتم

به $\phi \leftarrow h$

با مثالهای + تقسیم می دهد. $h \leftarrow$

□

شرح	$\langle \phi, \phi, \phi, \phi, \phi, \phi \rangle$
مثال 1	$\langle \phi, \phi, \phi, \phi, \phi, \phi \rangle$
مثال 2	$\langle \phi, \phi, \phi, \phi, \phi, \phi \rangle$
مثال 3	مثال منفی را در نظر نمی گیرد.
مثال 4	$\langle \phi, \phi, \phi, \phi, \phi, \phi \rangle$

- آلا در بتم چگونه می منفی را در نظر نمی گیرد \leftarrow با فرض دست بودن مثالهای آموزشی C
 $h \leq g \leq C$

سوال \leftarrow آیا فرضیه سازگار دیگری وجود دارد؟
 آیا داده خالی از نظر است؟ \leftarrow کاملاً حساس به نویز
 آیا اختصاصی ترین فرضیه انتخاب است؟
 اگر چندین فرضیه اختصاصی وجود داشته باشد دست چندی شد؟
 اگر چندین فرضیه اختصاصی سوالگر وجود نداشته چندی شد؟

جمع بندی

فرضیه \leftarrow مناسب به یک تابع
 نایش دیگرها
 روش صحیح } یادگیری مهندسی

روش Candidate Eliminate

- برای رفع مشکل نهایی منفی Find-S
- در طبق به جزئی
- سازگاری

$$\text{Consistent } (h, D) \iff [\forall (x, c(x)) \in D] h(x) = c(x)$$

نقضیه ای که با بهیچم بدون سازگار است (برای مثال آموزشی)

Version Space

مجموعه تمام فرضیه های سازگار با مثال آموزشی (V.S.)


پیدا کردن VS های برحالت بقدر کیفیت نهیتم

$G_0 \leftarrow \phi$ تمام ϕ

$S_0 \leftarrow \phi$ تمام ϕ

G_1 تعیین G_0 که شامل مثال منفی نباشد

S_1 تعیین S_0 که شامل مثال مثبت باشد



الگوریتم

1. G_0, S_0

2. مثال + \rightarrow شامل سازگار S حذف

شامل سازگار G حذف

از S رد نشود \rightarrow حداقل تعیین G

3. مثال -

از G رد نشود \rightarrow حداقل اخصای S

4. جواب ندارد \rightarrow اگر S و G از هم رد شوند

5. G حداقل و S حداکثر

اگر تغییر بیش از دو عددی باشد، بهی ترتیب آنها را به ϕ تعیین داد که عمق می دلیل

زادگی است این ضعف جزئی است (چون بازگویی ترتیب عطنی OR ندارد) PACCO

نقضیه فرضیه ترتیب عطنی \rightarrow صف نقضی فرضیه ها

Subject:

Year:

Month:

Date:

()

G : < S, ?, ?, ?, ?, ? > < ?, ω, ?, ?, ?, ? >

✓

S : < S, ω, ?, S, ?, ? >


جواب : < S, ω, ?, ?, ?, ? >

< S, ?, ?, S, ?, ? >

< ?, ω, ?, S, ?, ? >

سوال : ① چو لست S ته شرد؟

② څو ارزيايي رابطه سمهيد



Japanese Economy Car

✓

G₀ : < ? ? ? ? ? >

G₁ : G₀

G₂ : < ? H ? ? ? > < ? ? B ? ? > < ? ? ? 80 ? > < ? ? ? ? E >

G₃ : < ? ? B ? ? > < ? ? ? ? E >

G₄ : < J ? B ? ? > < ? ? B ? E > < J ? ? ? E >

G₅ : < J ? ? ? E >

S₅ : < J ? ? ? E >

S₄ : S₃

S₃ : < J ? B ? E >

S₂ : S₁

S₁ : < J H B 80 E >

S₀ : < 0 0 0 0 0 >

هنگاري

جواب : < J ? ? ? E >

- فرض این الگوریتم اینست که مثال غلط وجود نداشته باشد

ادامه مثال

$G_5 : \langle J ? ? ? E \rangle$

$G_6 : G_5$

$G_7 : \text{algorithm collapses } x$

$S_7 : S_6$

$S_6 : \langle J ? ? ? E \rangle$

$S_5 : \langle J ? ? ? E \rangle$

- Collapse ← یک مثال نادر در دل داده وجود دارد

کامپوزیشن های مهم در دست نیست ← ترکیب عطفی
در آنها کافی نیست

- داده 4 ← تعیین غائب فرضیه ← تعیین تابع لایه شبکه عصبی

جمع ادوی مثال درست و صحیح

- در واقع الگوریتم زمانی collapse می کند که مهم ترین در فضای فرضیه باشد

برای این محدود به ترکیب عطفی نباشیم ← یادگیری بدون اباین ← گسترش فضا

در فضای فرضیه NOT و OR را هم اضافه کنیم

$S \rightarrow OR$ (مثبت)

$G \rightarrow OR$ (NOT منفی)

S تنها برای مثال های که تا حالا دیده جواب می دهد ← over fitting

مثال های آموزشی خط می شود

که جا به جا شدن عددی داده نادرست ، محدود کردن فضای فرضیه

Subject :

Year . Month . Date . ()

یک سیستم یادگیری که هیچ بین فرقی در مورد ماهیت تابع دقت نداشته باشد.
که قادر به دسته بندی داده های نادیده نخواهد بود.
که با دیدن صورت سند باید آنرا با پس کرد.

☑ دسته بندی داده خوبید در مثال Energy Sport
1. مقاله با پر 5 تا مثال - رای تیری

☐ نماین شماره 3، 4، 5 و 9 از فصل دوم + حلاله مقاله

☐ مشطات یادگیری مندی

• فریز در مثالهای آشنایی

• محدودیت فضای فرسند

• مدت تعیین مشکل را

• بدون باسکی یادگیری اما پذیرست

Decision Tree

© یادگیری درخت تقسیم

* سند یادگیری با درخت تقسیم

- نحوه نمایش رابطه؟ ← درخت تقسیم به صورت Sum of Products
- روش یادگیری ← ID3

* درخت تقسیم

- تعدادی گره؟
- تعدادی شاخه
- از سازی فرایند تقسیم گیری انسان

- گره؟ = درختی
- شاخه؟ = حالات مختلفی که درختی می پذیرد
- برهه؟ = تقسیم
- یادگیری ← مطالعه
- مثالهای آموزشی

این سیستم های خبره برای تشخیص پزشکی بکار می روند چون هم دانش آنها را دارند هم مثالهای آموزشی و می مشکلاتی دارند.

- مثالهای جدید ← مثالهای خیلی زیاد
- اختلاف تدابیر ← قدرت تقسیم زیاد
- اختلاف تدابیر

- نقش مدل

بر مدلی عطا است (دالته تا حدی)

ساده سازی دمای واقعی
 استفاده از دماهای که تغییر از مدل مغزی پزشک است
 وسیله پذیری ← قابل مدل روان است

- سپس نشتم!

* نمایش زلفیه

- دو طلاس + ر -
- باز نمایی در سخت

* کاربرد در سخت تصمیم

• برای سالی مناسب است که شلهای آندزشی به صورت زیر مشخص باشند.

< Feature , Value > → Class

• تابع پهن دارای خروجی بسته است دنیاز به بر حسب فعلی داشته باشند.


* سوالاتی در اسی ؟
 ؟ اول که آک دیگری آزمائش می شود ؟

برای
 تولید سندی بسته
 است
 سالی

• در سمارستان ، اول تب را می گیرند.

• بیماری تبی

گوشی
 ندارد طلب
 است
 دست درزش
 است
 بر برانی



هدو دینر

درخت تقسیم‌بندی استخراش ویژگی‌های پرمبانی قدرت تولید پذیری است داده
و بعضی دارد این روش ساده را در نظر نمی‌گیرد.

که نیز حل یک سند ، تبدیل یک سند به ویژگی‌ها است

— هماری نقش داک ، شعوبی شتر ، قیمت هم ، نرخ سند
— کتاب ، مهاجر ، حجت
— در یادگیری ماشین فضای نرغینه هم است — باید

* ویژگی‌های درخت تقسیم

• ترتیب تدایع بسته

• معادله در برابر ندری دودی

• برای داده‌های با حجم بالا ← Data Mining

• قابل نمایش به صورت توابع if-then ← قابل فهم

• ترکیب عطفی و فصلی

• کار با داده‌ها در روشی مانند هم ویژگی‌ها ← Missing Features


↓
کندیم غلط نیست در این مورد باید در نظر

* درخت تقسیم \equiv Sum of Products (SoP)


AND \equiv مسیر از ریشه به برگ

OR \equiv خود درخت

* درخت تقسیم مناه با حفظ منی کند ← درخت ساده تر
 ↓
 ID3 با این الگوریتم



ساده سازی
 →



درخت اصل
 پیچیده ترین درخت ممکن

درخت تقسیم

تاج روی پیچیده
 تعداد سطحی برابر تعداد درختها

کدام استناد از نظر ترتیب زمانی در الگوریتم مندرکاتند درخت تقسیم است.

* چقدر تا درخت تقسیم درجه اول به با داده آموزشی ساده سازی دارد؟ « زیاد »



- کشیدن همه درختها ← آزمایش همه
- پیچیده ترین درخت ← پرسش کردن
- ساختن درخت با حفظ درختی ساختن ← قدرت تقسیم

Subject:

Year: Month: Date: 16

درسته؟

x_2	x_1	x_0	class	$F(x_2, x_1, x_0)$	نتیجه برت :
0	0	0	0		
0	0	1	0		
0	1	0	0		
0	1	1	0		
1	0	0	0		
1	0	1	1		
1	1	0	0		
1	1	1	1		



* بردن پای همه درختی هستیم ؟
 درخت کامل
 غیر قابل ساخت برای فضای بزرگ
 شاید خطای کمتری - تقسیم x

Inducing Decision Trees

ID3 درخت


ساخت Quinlan

بر مبنای اندرویدیم با C4.5


سخت جبرداشته C4.5

بر مبنای دیده : دنیا ذاتاً ساده است

ساخت درختی درخت تقسیم که داده سازگار باشد.



✓



سنجاری: مثالی 0, 1, 2, 3, 4
 دارای تعدادی خطا در داده آموزشی
 قابلیت تقسیم
 = ()


Subject :

Year .


Month .

Date .

()



افزودن ویژگی x_2
 سازگار با داده های آموزشی




x_1 در ریشه ← حداکثره نسبت
 x_1 می تواند بایست سوال تطبیق تعدادی از
 داده ها را مشخص کند.
 پس هزینه مناسبی برای ریشه نسبت.

ID3 *

- روش یادگیری
- یک Feature را در ریشه میگذاریم
- اگر $Y \in N$ رسید، متوقف شد.
- اگر در دو زیر درخت دوباره برگردیم و اجرا می کنیم
- حداکثری در ریشه
- نیاز به معیار نمی ← آنزوی

- $\{Y, Y, Y, Y\} \rightarrow S = 0$
- $\{N, N, N, N\} \rightarrow S = 0$
- $\{Y, Y, Y, N\} \rightarrow S = \frac{1}{4}$
- $\{Y, Y, N, N\} \rightarrow S = \frac{1}{2}$



Subject:

Year: .. Month: .. Date: .. (12)

• آنتروپی

– میزان بی نظمی

– ذریعہ

$$S = - P_{\oplus} \log_2 P_{\oplus} - P_{\ominus} \log_2 P_{\ominus}$$

P_{\oplus} : در صد شاہی مثبت


P_{\ominus} : در صد شاہی منفی

– مقدار

$$0 \times \log 0 = 0$$

• آنتروپی سنی می‌کند در هر مرحله آنتروپی را تا جایی ممکن کاهش دهد. (ΔS_{max})

□



• مجموع غلظت‌های S

درختی A

مقدار اطلاعات G (information gain)

$$\text{Gain}(S, A) = \text{Entropy}(S) - \sum_{r \in \text{value}(A)} \frac{|S_r|}{|S|} \text{Entropy}(S_r)$$

Subject:

Year:

Month:


Date:

()

کاربرد در درخت

۱- ساده ترین درخت

مجموعه تمام شاخه های آبرسانی (S)



$$G = E - \frac{S_1}{S} E_1 - \frac{S_2}{S} E_2 - \frac{S_3}{S} E_3$$

۲- حال یک دزخی انتخاب شده است، آنرا از مجموعه دزخیها حذف می کنیم
 در برای هر زیر درخت ارائه شده بالا داده می دهد.

Enjoy Water Sport ✓

تایم بدی

شاخه های بسته

دزخی ۴ < پاسخ > ، دردی

درخت تقسیم مناسب است. ←

$$P_{\oplus} = \frac{9}{14}$$

$$P_{\ominus} = \frac{5}{14}$$


$$E(S) = -\frac{9}{14} \log_2 \frac{9}{14} - \frac{5}{14} \log_2 \frac{5}{14} = 0.94$$

با فرض تعدادان هر لوان در رینه ، باید در لوان صحت می کند

Subject:

Year: Month: Date: 13

outlook



N: D₁, D₂, D₈

D₆, D₁₄

Y: D₃, D₁₁, D₃, D₇, D₁₂, D₁₃

D₄, D₅, D₁₀

$$w_1 = \frac{5}{14}$$

$$w_2 = \frac{4}{14}$$

$$w_3 = \frac{5}{14}$$


$$E_1 = -\frac{2}{5} \lg \frac{2}{5} - \frac{3}{5} \lg \frac{3}{5}$$

$$E_2 = 0$$

$$E_3 = E_1$$

$$G(S, outlook) = E(S) - w_1 E_1 - w_2 E_2 - w_3 E_3 = 0.246$$

humidity



N: D₁, D₂, D₈, D₁₄

D₆

Y: D₂, D₂, D₁₂

D₅, D₇, D₉, D₁₀, D₁₁, D₁₃

$$G(S, humidity) = 0.15$$

$$G(S, wind) = 0.05$$

$$G(S, temperature) = 0.03$$

پس outlook در ریشه قرار می گیرد.
چون اولین وضعیت « 0 » تطبیق آسانی مشخص است.

نرم افزار پایانه سازی C4.5 ← Weka

• نرم افزار سری دوم: درختهای تصمیم

Overfitting *

• کبده داده های آموزشی علت است.

☑ ترتیب مدل

۱- شیر ۲- شیر ۳- شیر ← پس اگر سله تراب شود شیر می آید

$$Err(train(h)) < Err(train(h_0))$$

یعنی داده های آموزشی را خوب یاد گرفته است.

$$Err(D(h)) > Err(D(h_0))$$


یعنی به طریقی بدتر عمل می کند.

• علت دیگر آن رسیدن بیش از حد در داده های آموزشی است.

☑ درخت تصمیم

↑ اندازه درخت ← درخت در داده های آموزشی
↓ درخت در داده های تست

علت : overfitting




☑ داده نامرئی در درخت تصمیم

درخت برای شامل شدن آن مثال غلط، بزرگتر می شود. فضای فرضیه پیچیده تر می شود.

مثال غلط

$$\langle outlook = S, tem = M, hum = N, w = S \rangle \in$$



• راههای جلوگیری

۱- جلوگیری از رشد درخت قبل از رسیدن به مرحله یادگیری کامل داده های آموزشی

۲- پس کردن درخت پس از رشد

• هرگز کردن

— نیاز به تقسیم داده ۷۰٪ آموزش + ۳۰٪ تست

✓ Cross-validation ← مجبور داده ۷۰٪
لازم داده ۳۰٪ تست باشند

— آلودگی

1. Train with ID3 over train set
2. Prune a branch
3. Replace branch with Y, N
choose Y, N regarding maximum vote of pruned leaves
4. Test Tree
5. If it performs better, keep it otherwise restore original tree
6. Go to 2 for next branch

• علت های دیگر overfitting

- فضای فرضیه بزرگ
- فضای بدون بایاس

← خطا کردن مشابه

• نشانه های overfitting

— اختلاف زیاد بین داده های آموزشی درست از لحاظ درست

— رسیدن به فضای فرضیه پیچیده و نامحدود

Subject:

Year:

Month:

Date:

()

• محلی است ویژگی خاصی برای Info Gain بالا باشد به طوری که یک سوال تقریباً تطبیق داشته باشد ولی قدرت تقسیم را از بین می برد.

✓ اضافه کردن تاریخ - Enjoy Sport

برای بیدار کردن چنین ویژگی می توان از ساختارهایی استفاده کرد:

- آزمایش داده های Validation
- آستانه گیری از تغییر آنتروپی
- تعداد زیاد ساختار



$$\text{Gain Ratio}(S, A) = \frac{\text{Gain}(S, A)}{\text{Split Information}(S, A)}$$

$$= - \sum_{i=1}^c \frac{|S_i|}{|S|} \log \frac{|S_i|}{|S|}$$

✓

$$\begin{aligned} \text{split} = n &\rightarrow \text{SI} = \log_2^n \\ \text{split} = 2 &\rightarrow \text{SI} = \log_2^2 = 1 \\ \text{split} = 1 &\rightarrow \text{SI} = \log_2^1 = 0 \end{aligned}$$

تطبیق معلوم است
اصلاً ویژگی خود است
فخرج 0 می شود

* ویژگی های بریده
• باید تقسیم سازی شود.


• یکی از راهها sort کردن داده ها است.

Subject:

Year: Month: Date: 15

Tem 40 48 60 72 80 90

N N Y Y Y N



Missing Values

- این راه در نظر گرفتن حالت اضافه برای کن درونی تحت عنوان «عقبنه»
- تکرار بر مثال و تکرار دادن مقادیر مختلف و تکرار برای آنها
- استفاده از دانش پیشین

سیاری بدون بهار نوشته نشده

۱- سیاری ← ۷ ، N ، ① ← درجه ندارد

۲- ← ۷ ، →
← ، N ، →

۳- اگر جامعه سیاری هستند / در این سن سیاری کشند (نوزاد) / ...

Rule Post Pruning چیست؟

© یادگیری بیزین

Spam Filtering

فیلتراسیون ایمیل های نامناسب - موضوع

لیست سیاه Email

تعداد زیادی از این آدرسها مشکوک

مانند موارد کاربردها - به عنوان مثال: تحلیل می شود.

HoneyPot - مثلاً


abaki @ aut.ac.ir

مراحل:

۱- جمع آوری Email تراکم

۲- تجزیه و تحلیل

۳- گرفتن نشانه های جدید و آشنایی



* استدلال بیزین

• برپایه احتمالات

• اساس این روش بر اینست که برای هر ایمیل یک توزیع احتمال وجود دارد.

• مشاهده داده جدید -> استدلال در مورد توزیع احتمال آن -> تقسیم بیزین

Spam

$P(x) =$ احتمال اولیه $= 50\%$ بودن ایمیل Email

نامه جدید رسیده است، حال کاربر بازشده می دهد.

$\rightarrow P(x) = \uparrow \text{ یا } \downarrow =$ احتمال تازه

• مزیت : کاملاً معلوم است که چکاری کند. — پایه یکی ریاضی نوی

* یادگیری با بیزین

• دانش موجود را به صورت احتمالاتی فرموله می کند. — توزیع احتمال

• داده را جمع آوری می نماید. — روش آماری — احتمال اولیه

• مشاهده داده — احتمال ثانویه

• احتمال ثانویه

↓ اندازه گیری عدم قطعیت

↓ بیشترین

↓ تقسیم گیری

* تفاوت با درخت تصمیم

• بیشترین احتمالاتی در برابر جواب ناطح

Yes / No ل 93.7 ل

* مشکلات عملی

• نیاز به دانش اولیه در مورد تعداد زیادی متاد برادریه

• احتمال دیدن هر کلمه در Email های سالم و Spam

• کرم کامپیوتری I Love U

• وجود نداشتن اطلاعات قبلی

• تخمین زدن احتمال

• معانیابی روابط

• محاسبات پر هزینه

Subject :

Year :

Month :

Date :

()

• انتخاب توزیع احتمال مناسب برای بایس کردن
 ✎ فرض توزیع نرمال برای استفاده از تئوریه ماکسن

* محاسبات

• h : فرضیه ای از میان فضای فرضیه H

• D : داده های آموزشی

$$P(h | D) = \frac{P(D | h) \times P(h)}{P(D)}$$

Spam Filtering ✎

$h_1 = \text{Spam}$

$h_2 = \text{not spam}$

$D =$ مجموعه email

✎ تشخیص ناآرشفه

$h_1 =$ فردوسی

$h_2 =$ حافظ

...

$h_5 =$ بیچاداک

$D =$ مجموعه اشعار

prior prb.

سختی از مثال مورد بررسی

• $P(h)$: احتمال اولیه

posterior prb.

پس از دیدن مثال

• $P(h | D)$: احتمال ثانویه

likelihood

داده خاصی به فرضیه خاصی منطبق باشد

• $P(D | h)$: احتمال ایده

evidance

• $P(D)$: احتمال دیدن داده

✎

$$P(h | D) \rightarrow P(\text{spam} | \text{email 1})$$

Subject:

Year:

Month:

Date: 17

$P(D) \uparrow \Rightarrow P(h|D) \downarrow$
احتمال اینکه از روی کلمه سلام بشود نتیجه گرفت اسپم است کم است
چنان این داده زیاد دیده می شود

* تصمیم گیری از روی احتمال نادره

Maximum A Posteriori Hypothesis (MAP)
ماکزیم اِپسِتیوَن

$P(\text{Spam}) = 70\%$

$P(\neg \text{Spam}) = 30\% \Rightarrow \text{Spam}$

$h_{\text{MAP}} = \arg \max_{h \in H} P(D|h) \times P(h)$

likelihood ← می توان از مجموع صورتها کرد
جمع بگیریم I_n نمی شود
ماکزیم اِپسِتیوَن $P(h)$ مقدار باشد یا کم نباشد می توان آنرا حذف کرد

$h_{\text{MAP}} = \arg \max_{h \in H} P(D|h)$

(ML) Maximum Likelihood Hypothesis

آزمایش سرطان

$$h_1 = \text{Cancer} \rightarrow P(\text{Cancer}) = 0.008$$

$$h_2 = \sim \text{Cancer} \rightarrow P(\sim \text{Cancer}) = 0.992$$

$$P(+ | \text{Cancer}) = 0.98$$

$$P(- | \sim \text{Cancer}) = 0.97$$

شخصی به آزمایشگاه می رود، نتیجه آن مثبت می شود، آیا سرطان دارد؟


$$P(\text{Cancer} | +) = ?$$

حساب

$$P(C | +) = \frac{P(+ | C) \times P(C)}{P(+)} = \frac{0.0078}{P(+)}$$

$$P(\sim C | +) = \frac{P(+ | \sim C) \times P(\sim C)}{P(+)} = \frac{0.0298}{P(+)}$$

$$\rightarrow h_{\text{MAP}} = \sim \text{Cancer}$$

کتاب پزشکی به بیمارستان می آید می گویم سالم است. }
 سالم باشد ← از نتیجه آزمایشگاه دانسته می کند }
 سرطان باشد ← سرطان اورا می کند }


$$P(h_1 | D) = 0.4$$

$$P(h_2 | D) = 0.3$$

$$P(h_3 | D) = 0.3$$

انتخاب MAP فرسوده h_1 است. حال اگر هزینه ای باشد α موجود باشد که:

$$P(h_1) = +, \quad P(h_2) = -, \quad P(h_3) = -$$

استان از MAP هزینه مثبت

Subject:

Year: Month: Date: 18

Bayes optimal classifier

* ترکیب کینه

$$h = \arg \max_{v_j \in H} \sum_{h_i \in H} P(v_j | h_i) P(h_i | D)$$

- v_j : دسته بندی
- $P(v_j | h_i)$: دستی بردار از ترکیب
- Optimal: تاثیر وزن و مقدار در احتمال تأثیر دادن

د

- $h_1 =$ spam due to email subject +
- $h_2 =$ spam ... context -
- $h_3 =$ spam ... sender -
- $h_4 =$ spam ... subject + context +

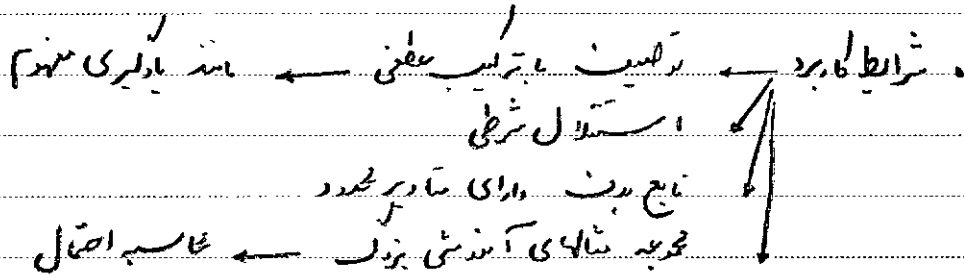
$$\text{spam} = \sum P(+ | h_i) \times P(h_i | D)$$

یونانی برای فضای ترکیب بزرگ

Naive Bayes classifier

* دسته بندی کننده بیزین ساده

دسته بندی متن ← روزنامه



Subject:

Year:

Month:

Date: ()

نایب

$$f: X \rightarrow V$$

$$x \in X: a_1, a_2, \dots, a_n$$

$$v_{\text{MAP}} = \arg \max_{v_j \in V} P(v_j | a_1, \dots, a_n)$$

$$= \arg \max_{v_j \in V} \frac{P(a_1, \dots, a_n | v_j) P(v_j)}{P(a_1, \dots, a_n)}$$

$$= \arg \max_{v_j \in V} P(a_1, \dots, a_n | v_j) P(v_j)$$

$P(v_j)$ = تعداد دفعات رخ دادن v_j در شاخه آماری

محاسبه $P(a_1, \dots, a_n | v_j)$

- داده آماری زیاد

احتمالاً چند مثال موجود است.

- فرض استقلال شرطی
حاصلگردد احتمال تحت دیزلها
در همه مسائل صادر نیست.

$$P(a_1, \dots, a_n | v_j) = P(a_1 | v_j) \times \dots \times P(a_n | v_j) \\ = \prod_{i=1}^n P(a_i | v_j)$$

$$v_{\text{NB}} = \arg \max_{v_j \in V} P(v_j) \prod_{i=1}^n P(a_i | v_j)$$

Subject:

Year: Month:

Date: 19

Play Tennis ✓

query: $\alpha = (O = s, T = c, H = h, W = s)$

$$V_{NB} = \arg \max_{V_j \in V} P(V_j) \prod_{i=1}^n P(a_i | V_j)$$

مادگیری \equiv محاسبه متادیر احتمال به طر Offline

$V = \{yes, no\}$

$P(yes) = 9/14$

$P(no) = 5/14$

Outlook = Sunny	Temp = Cool	Hum = Normal	Wind = Strong
$P(O = s yes) = 2/9$	$P(T = c yes) = 3/9$	$P(H = h yes) = 3/9$	$P(W = s yes) = 3/9$
$P(O = s no) = 3/5$	$P(T = c no) = 1/5$	$P(H = h no) = 4/5$	$P(W = s no) = 3/5$

$$P(yes | \alpha) = 9/14 \times (2/9 \times 3/9 \times 3/9 \times 3/9) = 0.0053$$

$$P(no | \alpha) = 5/14 \times (3/5 \times 1/5 \times 4/5 \times 3/5) = 0.0203 \quad \checkmark$$

- متادیر برابر Noise
- ویژگیهای مستقل نباشد \rightarrow جواب معنی ندارد
- اعداد درست آمده همه را چک میکنم

Subject:

Year: Month: Date: ()


گاهی ب دیرگی در نتایج آموختنی دیده نمی شود ($P(a; 1, 1) = 0$)
از m-estimate of prob. استفاده می شود.

Naive $\rightarrow P(i) = \frac{n_i}{n}$

m-estimate $\rightarrow P(i) = \frac{n_i + m \cdot p}{n + m}$

معمولاً اگر k دسته وجود داشته باشد $p = 1/k$ که عموماً مثل اینست که به تمام دسته $m \cdot p$ مثال اضافه کرده باشد.

بین مرهم و دلال



از دادن هر بیت ، ۱۰۰ کلمه اول را برمی داریم و آنرا به عنوان نمونه در نظری می گردانیم

۲. استقلال شرطی تقریباً متبلی می کنیم.

۳. تابع بیت محدود: دوزخی ، داستان ، خاطرات ، ...


۴. مجموعه آموختنی: مجموعه ای و مطالب های مختلف با آموختنی محدود

Subject:

Year: Month: Date: 20

مجلس یادگیری

دست یادگیری
100%



Subject:

Year:


Month:

Date: ()


Bayesian Belief Net

شبکه باور بیزی

شبکه باور بیزی



دسته بندی کننده باور بیزی *



Node : Concept

Arc : Depedancy

ادامه دارد ...

Hypothesis Evaluation

© ارزیابی فرضیه

* یادگیری

Data

↳ Learning Algorithm

↳ Hypothesis

↳ Performance Assessment

* محدود داده های آموزشی

• تفاوت توزیع کلی داده

• اندازه داده مناسب

• استفاده از داده های مرجع

• توزیع داده های تست مناسب نباشد

• مشکلات کمبود داده

- مابین اختلاف بین دست واقعی و دست تخمین زاده شده

- در باین براندگی نتایج در آزمونهای مختلف

* مدل کمی

$P(x) =$ احتمال رخداد هر نمونه x (نامعوم)

• خطای نمونه

خطای فرضیه روی مثالهای جدید

$error_s(h) = \frac{e}{n}$

• خطای واقعی

خطای فرضیه روی کل داده های موجود = احتمال اینکه یک نمونه به خاطر دسته بندی شود

بدن و بدست آوردن خطای واقعی از روی خطای نمونه است

Subject:

Year:

Month:

Date: ()

در واقع صورت مسئله عبارتست از بچین سطحی واقعی از روی سطحی نظری

خطا

$$\delta (f(x), h(x)) = \begin{cases} 0, & f(x) = h(x) \\ 1, & f(x) \neq h(x) \end{cases}$$

$$\text{error}_D(x) = \sum_{x \in D} p(x) \cdot \delta(x)$$

$$S \subseteq D$$

$$\text{error}_e(x) = \sum_{x \in S} p(x) \cdot \delta(x)$$

اگر اطلاعات بیشتری موجود باشد، محتملترین مقدار برای e_0 همان e_S است

با احتمال 95% سطحی واقعی در بازه زیر است:

$$\text{error}_S \pm 1.96 \times \sqrt{\frac{\text{error}_S \times (1 - \text{error}_S)}{n}}$$

ذهن ← مثالی مستقل از بزرگی $n \geq 5$

زمانی که n بزرگتر باشد، تقریب بدست می آید:

$$n \times \text{error}_S \times (1 - \text{error}_S) \geq 5$$

$$N \% \iff Z_n$$

$$95 \% \iff 1.96, \quad 99 \% \iff 2.58$$

د

Subject :

Year . Month . Date . 22

• این رابطه از توزیع دو جمله‌ای ناشی می‌شود

$p =$ احتمال ارزیابی عطل یک نمونه (مجدول) \rightarrow احتمال مرخصیت یک آزمائش
 $r =$ تعداد دل‌نمایی‌های عطل از بین r نمونه \rightarrow تعداد مرخصیت ؟
 $N =$ تعداد کل نمونه ؟

$$P(r) = \frac{N!}{r! (N-r)!} p^r (1-p)^{N-r}$$

$$E\{P(r)\} = N \cdot p$$

$$Var\{P(r)\} = N \cdot p \cdot (1-p)$$

$$\begin{aligned}
 \text{Bias} &= \text{error}_D - \text{error}_S \\
 &= E\{P(r)\} - P(r) \\
 &= (N-1) \cdot p
 \end{aligned}$$

$$\sigma_{\text{error}_S} = \frac{\sigma_r}{S} = \sqrt{\frac{P(1-P)}{n}}$$

مجید \rightarrow خطای واقعی \rightarrow اغراض معیار خطای نمونه

رایج ترین زدن این مقدار از رابطه زیر استفاده می‌شود

$$P \approx \text{error}_S \Rightarrow \sigma_{\text{error}_S} \approx \sqrt{\frac{\text{error}_S \times (1 - \text{error}_S)}{n}}$$

• فاصله اطمینان برای توزیع دو جمله‌ای سخت است.
 با فرض n بزرگ توزیع دو جمله‌ای به سمت توزیع نرمال میل می‌کند.

$$N\% \text{ فاصله اطمینان} = \text{Bias} \pm T_N \times \text{Variance}^{1/2}$$

Subject :


Year . Month . Date . ()

* مقایسه الگوریتم های یادگیری

1 روش $\rightarrow E_1$ % خطا $\rightarrow E_1 \pm \sigma_1$ خطای رانش


2 روش $\rightarrow E_2$ % خطا $\rightarrow E_2 \pm \sigma_2$ خطای رانش

* K-Fold Cross-Validation



T : train

S : test



Bias & Variance

Instant Based Learning

یادگیری بر پایه نمونه

Concept Learning


Decision Tree

Bayesian Learning

دین در نهایت از استفاده از نمونه برای ساختن مدل، و بر به نمونه کاری نداریم. در یادگیری بر پایه نمونه از خود نمونه؟ استفاده می شود.

IBL

- مثالهای آموزشی ذخیره می شود.
- Memory Based
- مشاهده مثال جدید، تا مرحله آنها، مثالهای ذخیره شده بعدی می شود و یک مقدار برای تابع هدف بر ست می آید.
- سردرگمی در مرحله آموزش ندارد ← lazy
- ترتیبی ای اهمیت نمی شود.
- تقسیم دادن تا مشاهده مثال جدید به تعیین می آید.



- ← نمونه
- ← جمله ویژگی
- ← در حافظه
- ← جمله ویژگی
- ← تابع هدف
- ← جمله تا چگونه؟

تقریب صدای از تابع هدف را ایجاد می کند. این ترتیب فقط به سبب نمونه جدید قابل اعمال بوده و برتری نمونه بر روی فضای نمونه عمل می کند ← ترتیب عملی



DT: درخت → تاک داده ۶
 BL: نوع احصال → تاک داده ۶ } ترتیب سراسری

• قدرت یادگیری تابعهای پیچیده ← ترتیب زنجیره ساده تر محلی

* محدود زمانی استفاده می کنند؟

- مشابه به فضای قابل شناخت باشند
- تعداد ویژگیهای محدود
- تعداد داده آموختنی زیاد ← پرسش فضای داده ۶

* مزایا

- آموختن سریع ← ذخیره در حافظه داده
- تابع هدف پیچیده را آیدمی نبود
- اطلاعات از دست نمی دهند

* معایب

- زمان جستجوی زیاد
- صفیفت در برابر ویژگیهای نامرتبط

✓ راه ارتقا ← خنثی سازی دودوی ۱ و ۲ متغیر با هم تراسته؟

* تابع شناخت

- تابع فاصله
- عمل متغیر ویژگیها اعطای وزن باشند

* انتخاب نمونه ها

- تعداد زیاد
- پریشانی کل فضا
- حتی اگر اطمینان فیزیکی نباشد
- تدریج یادداشت

* تابع دسته بندی

• با مشاهده یک مثال دسته بندی آن را تعیین می کند

* روش های مختلف

- K - Nearest Neighbor
- Locally weighted Regression
- Radial Basis Function Network
- Case - Based Reasoning
- General Regression Neural Networks

تابع دیتا هستند ، می بینند و می یادند

* KNN


- ساده ترین و ابتدایی ترین روش
- فضای n بعدی حقیقی
- نااهل n دی (تلفظی)
- k همسایه نزدیک ← انتخاب مناسب این مقدار (شماره است)

تابع دیتا هستند ← می بینند و می یادند

می بینند ← می یادند

Subject:

Year. Month. Date. ()



$k=1$



$k=3$

• $k=1$ ← همان به نوبت
 ترتیب بکتر برای فضای چهار

• فضای نزدیکه k -NN = voronoi diagram
 فضا را به چند جهتهایی تقسیم می کند
 تا آنجا که این جهتهایی دسته بندی مشابهی دارد.


• مابین استراده
 دسته بندی نمونه مشابه دسته بندی نمونه های دیگری خواهد بود در نزدیکی آنها دارد.

• برای محاسبه ناهمبستگی چون در زیرها، در این چنین دسته بندی آنرا نرمال می کنیم.

$$x' = \frac{x - \bar{x}}{\sigma}$$

• نسخه بهبود یافته $k = NN$

در حالت عادی اگر k بزرگ باشد، اثر نامطلوبی از داده‌های دوری لبرود



می‌توان تأثیر داده‌های دورتر را کم کرد، اینکار با وزن دادن به آنها امکانپذیر است. این وزن عکس مجذور فاصله است.
 $w_i = d^{-2}$

Curse of Dimensionality

فاصله تا تمام ویژگی‌ها اندازه لبری می‌شود. در برخلاف روشهایی مانند درخت تقسیم که در آن سعی می‌شود تا فقط از ویژگی‌های مرتبط استفاده شود.

در اینجا تفاوت وجود ویژگی‌های نامرتبط کلن است به طوری که راه‌نمایی برای فاصله تأثیر ندارد باشد

یکی از راه‌ها دادن وزن بیشتر به ویژگی‌های مرتبط است.

جای قبضه وزن ویژگی‌های بی‌توان از روش cross-validation استفاده کرد. و زمانی که بخواهیم تغییر می‌کنند که خطای دست‌نمایی به باقیمانده مثالها کاهش یابد. اگر ضریب برابر صفر شود می‌توان یک ویژگی را حذف کرد. این عمل در واقع دادن یادگیری به خودیست است.

• چگونه داده‌ها را در DB قرار دهیم که جستجو سریعتر باشد برای مثال دران نزدیکترین همسایه

Indexing - مرتب کردن مثالهای آموزشی

استاندارد از روشهایی مانند kd-tree که در آن نمونه‌ها در سطح یک درخت ذخیره شده و نمونه‌های نزدیک به هم در همان گره ذخیره می‌شوند. هم ذخیره شوند. هدف اینست که همه نمونه‌ها بررسی نشود.

Subject :


Year .

Month .

Date .


()

kd-tree



داده های انتخاب می کنیم نه نهایی
 ورودی را قسمت کند. روی هر محور تعیین
 b- را برای می کنیم

نصف $x_0 = 3$ → x
 داده مرتب $\langle 3, -3 \rangle$



- بزرگترین خطای انجام دسته بندی کم است
- تعیین ب تابع نامناسب
- تاثیر منفی دیگری می نامرکز
- حافظه پرداز برای حفظ همه داده

Regression :


ترتیب داده با مقدار مشخص

Residual :

خطای حاصل از ترتیب

kernel :


تابع مرتب در آن ؟
 رابطه مشخص با نامعده دارد.



Locally Weighted Regression *

- تعیین k -NN
- ترتیب همجای از تابع f حول ناحیه محلی درجه اولیافته نمونه مورد بررسی
- کل مثال را با دینی گیرد بلا برای هر ناحیه یک تابع ساده یاد می گیرد.

LWR ، k -NN



LWR

k -NN



• حالت خطی

وزن تابع خطی برای ترتیب تابع f در نزدیکی مثال مورد بررسی استفاده می شود
برای تنظیم وزن از شیب نرددی استفاده می شود.

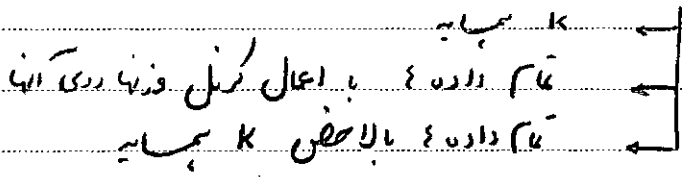
$$\hat{f}(x) = w_1 a_1 + w_2 a_2 + \dots + w_n a_n$$

$$Err = \frac{1}{2} (f - \hat{f})^2$$


$$\Delta w = \eta \sum (f - \hat{f}) a_i$$

$$w' = w - \Delta w$$

انتخاب نرددی برای ترتیب خطی



• سده آن ترمیم زنده است



Radial Basis Functions



• تابع در هر نقطه با یک تابع گوسیین « نظری تیرد » (به طوری تابع کرنل K_u) بیان می رود داده آموزشی دارایی روی K همبستگی


• عدد درابع - مقدار شایه آموزشی

• شباهت با LWR - ترمیم زنده


• ترمیم همبستگی برای همبستگی، شایه درابع برای همبستگی شایه

$$\hat{F} = \sum w_u \cdot K_{uu}$$

• برای تابع گوسی سه چیز باید یاد گرفت: همبستگی، دارایی، وزن



استاندارد (تمام شایه)



2-NN

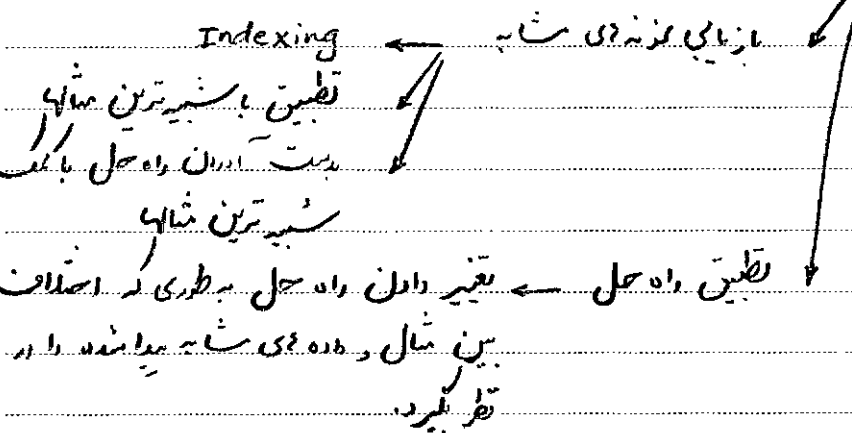
• همبستگی ترمیم درستی برای همبستگی (ایجاب شود)

Case Based Reasoning *

• مسئله روز
 • یک مسئله یادگیری گذشته
 گذشته در یک فضای n بعدی
 دسته بندی با توجه به گذشته های مشابه
 یادگیری تقابلی


• CBR ← ارائه مسئله

• اجرای CBR ← DB از مثالهای قبلی



• چرخه

New Problem → Retrieve Similar → Adapt → Solution



مانند سیستم انسانی

Subject :

Year . Month . Date . ()

• در CBR ، مثالهای مشابه هم است را پیدا می کند و از روی آنها تا حدن استخراج می کند
اینکار با خودکار انجام می شود با توسط Expert قدرت می گیرد (دی و تکنیکه CBR خت)

• پس از پیدا کردن قوانین ، مشورت بین مثال و داده های DB پیدا می شود و شبیه ترین
داده استخراج می شود

• پس از استخراج داده ، نتایجی آنها با مثال پیدا کرده و تا حدن مورد نظر اعمال می شود


Bayesian Belief Network شبکه باور بیزی

* **دب** : راحت شدن از دست شرطی استلال در شرایط Naive Bayesian

دربات - تعدادی مسدود در اطراف خود دارد - **دب** : خارج شدن از در


مسئله : آیا با خارج شدن از درب ، مقادیر مسدود از هم مستقلند ؟

$$\langle S_1, S_2, S_3, \dots, S_n, h \rangle \quad h = \text{door} / \bar{\text{door}}$$



مسدود بالا و البته اند

در مسدود سمت چپ و البته لطیف



* **مدلهای گرافیکی** : نام دیگر شبکه های بیزی است چون اجزای را با گرهان بهم مرتبط می کنند
امکان ترکیب دانش قبلی (جزءه) در حل مسئله با این روش میرسد

• نرد = متغیره ، دژیمی ؟

• یال = وابستگی

• جهت یال = رابطه علیت

* مزایای BN در مقابل NN

• استفاده از دانش جزه

• ساده و قابل فهم


• کاربرد آسان در نقلی

* استلال شرطی

$$P(X | Y, Z) = P(X | Z)$$

Subject :

Year . Month . Date . ()



A	B	C=0	C=1
0	0		
0	1		
1	0		
0	0		


استخراج دانش اولیه ← ساخت شبکه ← با استفاده از دانش موجود
احتمالات ← توزیع شمارش داده؟

- * یادگیری BN
- ساختار مدل
 - ساختار مدل
 - ساختار یادگیری

Neural Networks

شبکه های عصبی


- * مزایای یادگیری رایج خنثی گسترده و یاد برداری
- مدل در برابر خطای داده های آموزشی
- پرکاربرد و سادگی



- رابطه دردگی و خروجی بر مبنای محکم غنیت و
- راحت است که نزدیک زده شود به جدول
- در واقع فیزیکی در رابطه باید گشت نمود در عمل
- ساخته شود

وجه تشبیه

- بر پایه محاسبه
- بر پایه انتقال واحد های پردازشی (Connectionism زیر مجموعه)
- هر واحد : نود
- ساختار : دردگی ← واحد پردازشی ← واحد پردازشی دیگر ← خروجی



- مدل استاندارد : هر واحد پردازشی به تمام خروجیهای لایه قبلی متصل است
- الهام از طبیعت : از مغز پروردگار زنده


- * قابلیت های شبکه های عصبی
- محاسبه بی تابع معلوم

Subject:

Year: Month: Date: ()


- ترتیب آید تابع ناشناخته
- شناسایی الگو
- پردازش سیگنال
- یادگیری

Perceptron *
 • نوعی از شبکه عصبی بر مبنای یک واحد محاسباتی
 • عمل آن : جمع وزن دار ورودیها (رابطه محلی)
 • آستانه گیری از نتیجه



- در واقع یک صفحه جدا کننده را معرفی می کند.
- قابلیت ترتیب تابع محلی
- نمی تواند توابعی که محلی جدا پذیر نیستند را نمایش دهد XOR
- ورودی ثابت : بایاس

$$\hat{f}(\alpha_i) = \text{Sign}(\sum w_i \alpha_i)$$



- AND تابع
- دو ورودی
- آید خوبی
- آید واحد پردازشی
- ب بایاس

- یادگیری پرسپترون : مقدارین متادیر دستی برای w_i
- فضای فرضیه : مجموعه تمام متادیر ممکن برای برداری وزن
فضای جستجو بسیار بزرگ
نیاز به روشی برای جستجو

روش آموزش پرسپترون

- 1- مقدار اولیه وزنها ← تصادفی
- 2- پرسپترون را به کمک مثالهای آموزشی اعمال می کنیم
آزمایی خطا ← تصحیح وزنها
- 3- آیا تمام مثالها درست آزمایه شده اند؟
بله ← پایان
خیر ← برود به مرحله 2

w_0	w_1	w_2	x_2	x_1	y
0	0	0	0	0	0
0.1	0.1	0.1	0	1	0
⋮			1	0	0
			1	1	1

$S_+ : \Delta = 1$

قانون آموزش پرسپترون

- استفاده از Δ
- اعمال ضریب (بخش یادگیری)
- اعمال در ردی (برای شخصی کردن سهم آن از خطا)

$$w'_i = w_i + \eta (o - t) x_i$$

- تکوینی : در خطای صاف پذیر باشند

• قانون آموزش دلت

- استاندارد Δ Gradient Descent
- دو دسته Δ Least Square Error
- اول خطا را نزدیک می کند
- Δ متداول ترین خطا

$$E = \frac{1}{2} \sum_i (t_i - o_i)^2$$

روی تمام مثالهای آموزشی

$$o_i = \sum \omega_k x_k$$

به وزن ω رابطه است

- جایی بکشد است که خطا برابر هموار شود، پس باید به سمت آن دلت
- Δ در ادیان حکمت شیب را بدست می دهد. پس از خطا مستقیم حرکت می شود.
- Δ قانون اصلاح وزن

$$\Delta \omega_i = -\eta \frac{\partial E}{\partial \omega_i}$$


حرکت به سمت Δ پس از آن

Δ برای پرسپترون

$$E = \frac{1}{2} \sum_i (t_i - o_i)^2$$

$$\frac{\partial E}{\partial \omega_i} = \sum_i (t_i - o_i) (-x_i)$$

$$\Delta \omega_i = \eta \sum_i (t_i - o_i) (x_i)$$



- Δ شطرات شیب نزودی
- Δ مینیمم محلی (نقصینی برای رسیدن به
- Δ حداب محلی وجود ندارد)

• راه انزالی (online)

استفاده از Stochastic gradient desc.

محاسبه خطاهای تک ورودی؟

گاهی اوقات با فرار از مینیمم محلی کمتر عمل می کند

* پیمایی

↳ تعداد تکرارها

↳ تعداد روزها

↳ فضای جستجو

↳ یادگیری عمیق

* کار طراحی

• مشخص کردن ورودیها ← بردار و نوری؟

• مثالهای آموزشی

• تعیین تعداد لایه؟

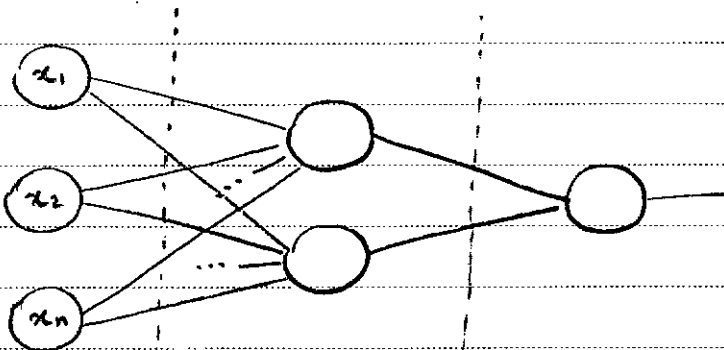
• تعیین واحدی پردازشی هر لایه

• تعیین تابع پردازشی

(کاربرد دسته بندی ، اندازه ۰.۶ ، ...)

↳ از روی تابع خروجی

↳ پیمایی



تابع لینک tanh

برای نشان دادن روابط

پیمایی

تابع دالسنده نوع

تابع خروجی

Subject :

Year . Month . Date . ()

Reinforcement learning

یادگیری تقویتی

* انواع یادگیری

• یادگیری با ناظر : نظری داریم که کار او صحیح آوری نموده و دستهبندی آن است.


دسته بندی : نمونه < ورودی >

ترتیب تابع یاد دابطه : خروجی

• یادگیری بدون ناظر : یادگیری خودکار دسته بندی

• یادگیری تقویتی

* یادگیری تقویتی



* استراتژی های اصلی

- الگوریتم های ترتیب
- استفاده از روشهای آماری در برنامه نویسی پروبا
- آدیتای یادگیری


* مدل های

- محیط محدود برای از S حالت
- مجموعه عملهای ممکن برای عامل A
- پاداش محیط در برابر عملی که عامل انجام داده است ، r

Subject:

Year: Month: Date: ()

ک خارج شدن روایت از آن



- * عامل : انتخاب عمل
- مجموعه : پاداش + حالت بعدی
- * عامل سعی می کند طوری رفتار کند که تابع پاداش ما را بیشترین کند.

* انداخ پاداش
• مجموعی

$$R_t = r_{t+1} + \gamma r_{t+2} + \gamma^2 r_{t+3} + \dots$$

$$= \sum (\gamma)^k r_{t+k+1}$$


$$0 < \gamma < 1$$

- $\gamma = 0 \rightarrow$ تنها حاکمیت بعدی را می بیند
- $\gamma = 1 \rightarrow$ حساب بینه درست نمی آید

* اعمال عامل از محیط پستی π تبعیت می کند.
دنباله R_t است که محیط پستی بینه π^* را بداند - طوری که مقدار امید ریاضی بودن را برای تمام حالات ما را بیش کند

راه حل همان سند با NN

< یاد ، ذات > زوج
دستی در حالت S: سببی ، بهترین حرکت
a. است.



Subject :

Year : Month : Date : ()

Support Vector Machine

© ماشینهای بردار پشتیبان

* ایده اصلی: نامرئی‌ترین خطی جدا پذیر باشد، اگر صفحه‌های جدا کننده دست
می‌آورد. اگر هم جدا پذیر نباشند، بعد داده‌ها را بالای می‌برد خطی آنها جدا می‌کند.

* مزایای نسبت به شبکه عصبی
• یادگیری بیشینه نسبت به نوزیر
• overfit شدن

* شرط بکینه

$$w^T x + b = 0$$

ابتدا از هر صفحه، دو صفحه موازی جدا می‌شود و آنگاه از آن دوری شود تا به داده‌ها برسد. همین موازی
آنها را این کار قدرت تعمیم را بالای برد.

Subject:

Year. Month. Date. ()

Subject:

Year. Month. Date. ()

Bellman

* اصل بیدلی

یک خط مشی همیشه دارای این خاصیت است که بدون توجه به حالات و تقسیمات
تغییر از این به بعد با در نظر گرفتن حالات جدید خط مشی همیشه برود.

به اندازه نرمی برآید ، بر این می نهد که هر حالت جدیدی خط مشی بگیرد خود است و بنابراین
حکمت این حالت خود را انتخاب می کند و کاری به پس از آن ندارد.

Subject:

Year . Month . Date . ()

* روشهای بدون مدل

در حالت مادی دنبال رسیدن به π^* هستیم و از زوج $\langle state, reward \rangle$

سعی کردیم به آن برسیم.

حین انتظار به طور مستمر دستور بود، اول به هر state یک مقدار تخصیص داده می شد

پس policy از آن استخراج می شد.

این راه حلها نیاز به داشتن مدل محیط داشت تا بدانند از هر حالت به چه حالت دیگری

منتقل می شود. $(S \rightarrow V \rightarrow \pi)$

حالت دیگری این است که تنها نیاز داریم بدانیم کدام action بهترین است و آنرا

انجام می دهیم و نیاز به مدل هم نداریم. محیط تنها از طریق تجربه شناخته می شود.

روش های Monte Carlo روشهای Stochastic هستند که داده ها به صورت

تصادفی تولید می شوند.

* روش تخمین محیط Monte Carlo

• هدف: یادگیری V^{π} برای یک سیاست مشخص

• ملاقات: هر بار که در یک ایستاد به حالت خاصی رسیدیم آن ملاقات می کنیم

• داده ها: تعداد ایستاد تحت π که شامل S است.

* روشهای MC

• Every-visit MC: مابین بازدیدها برای هر بار که S دید ایستاد ملاقات می شوند.

• First-visit MC: " " " " اولین " " " "

* یادگیری TD

• تابع ارزش: $\langle states \rangle$ ، $\langle state, action \rangle$

• Markov Decision Process: MDP: عملی که از آن انجام می دهیم مستقل

از سابقه تقسیم است

• TD learning: چند عمل بعد از تقسیم رخالت می دهیم.

Subject:

Year. Month. Date. ()


Policy Iteration •
 ← off policy : سیاست نامیرگی با سیاست بینه سیاست است
 ← on policy : سیاست اجرایی همان سیاستی که یاد گرفته شده است

* بینه های مختلف R_h در الگوریتم های مختلف
 • Function Approximation ← تقریب تابع نگاشت فضای حالت - فضای ارزشها
 • Trace ← جدولی استفاده از مسیر قبلی
 • Backup ← جدولی استفاده از ادانش در اینست شده

MDP *

- S : states
- A : actions possible in each state.
- P : prob. of transition from s to s' .
- R : expected reward
- γ : discount rate for delayed reward

* درین R_h
 • بیشینه کردن پاداش در اینست « دراز مدت
 ↓
 استخراج ریاضی تخمین حفظ مسیر بینه
 ↓
 حوصانه



Subject:

Year: Month: Date: ()

On-policy Monte Carlo Control *

- انسان ← یاد کردن تمام راه های ممکن سیر
- Greedy - ϵ
- On-policy ← سعی کند سیاست در حال اجرا را از پای کند و بهبود بخشد

• راه های Greedy - ϵ

$$\frac{\epsilon}{|A|} \quad \text{یا} \quad 1 + \epsilon - \frac{\epsilon}{|A|}$$

Off-policy Monte Carlo Control *

- سیاست رفتاری ← رفتاری که حاصل طبق آن عمل می کند یاد بگیرد
- Evolutionary
- سیاست تخمینی ← سیاستی که حاصل آنرا یاد می گیرد

Exploring Start

* فرقی

- هر حالتی احتمال این را دارد که عامل از آن گذرد و آنرا کند
- شکل: $unvisited \langle s, a \rangle pairs$

SARSA *

State - Action - Reward - State - Action

• استفاده از یک مرحله بعدی $TD(0)$

- یاد این نسبت به Q تغییر می دهد و جدول بخش می شود
- Backup
- سرعت یادگیری کمی کندتر از Q به دلیل انباشت بیشتر و اینکه هرگز
- On-policy

• Value Function Q

• استفاده از Q یعنی، حالت یادگیری تغییر می دهد و یادگیری می دهد

Subject:

Year: Month: Date: ()

Simulation *

- اهمیت آزمایش‌های واقعی عمل‌گرایی و هزینه‌بر بودن.
- برای مدل‌سازی نیاز به مدل خطی در حال داریم که با مفهوم *Model Free* سیستم‌های
- در تافلن است.

Action Selection *

- Greedy ← تقسیم حرلهای در تمام مراحل
- ϵ -Greedy ← تقسیم حرلهای در گام‌های حالت تصادفی

Function Approx *

- Table
- NN
- CMAC
- Decision Tree
- RBF

Eligibility Traces *

- بهاری روی (s, a)
- سرعتی پدید آمدن
- به حالت‌های برپایه بهینه توجهی کند.

Subject:

Year: Month: Date: ()

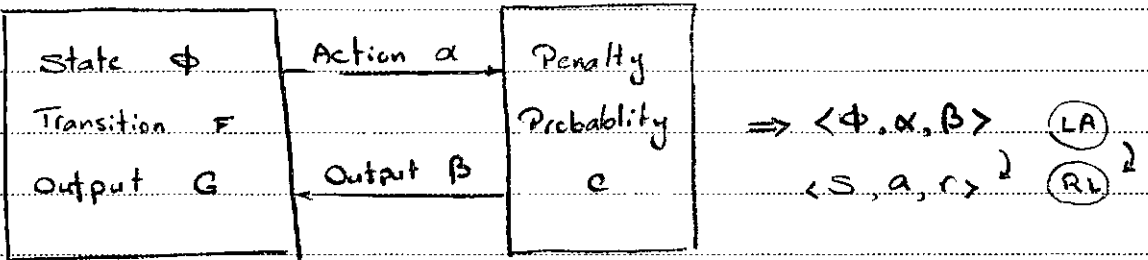
* اتوماتا یادگیری

* اتوماتای یادگیری تقویدنی

• سیستم تقویدی ← در آن معلوم نیست
• مدل دارای عدم قطعیت زیادی است.
• سیستم یادگیری تقویدی

* اتوماتا
• تطبیق تقویدی

• برای تقویت دنباله‌های از عملیات یا پاسخ به دستور العمل لوسنده



• تقویدگیری سیستم بر مبنای پاسخ محیط و دانشهای گذشته

MDP به معنای

• تفاوت LA، RL، و MDP نیست

* برتیب

environment: $\langle \alpha, c, \beta \rangle$

α : finite action/output set

β : input/response set

PAPCO c : set of penalty probability of each action

Subject:

Year. Month. Date. ()

* انواع مدل LA

- P- Model \rightarrow خودی
- Q- Model \rightarrow نسبت
- W- Model \rightarrow بویسته

* مدل LA

- State $\Phi \rightarrow$ حالت‌های ورودی LA (نیمه‌مستقیم)
- Action α
- Input β
- Next State $F \rightarrow F: \Phi \times \beta \rightarrow \Phi'$
- Next Action $H \rightarrow H: \Phi \times \beta \rightarrow \alpha$

$$LA: \langle \Phi, \alpha, \beta, F(\Phi, \beta), H(\Phi, \beta) \rangle$$

$$\alpha = G(\Phi)$$

state-output automaton

* آمارهای صادراتی

- سوالی بین از نتایج F و G صادراتی است.
- مایلترین دی این احتمالات حالت می‌گردد.

$$F(\beta_i) = \begin{matrix} & \beta_1 & & \beta_n \\ \beta_1 & \left[\begin{array}{c} p_{11} \\ \vdots \\ p_{1n} \end{array} \right] \\ \vdots & & & \\ \beta_n & \left[\begin{array}{c} p_{n1} \\ \vdots \\ p_{nn} \end{array} \right] \end{matrix}$$



* تجزیه مدلهای معادله صادراتی

$$P_i(n) = \frac{1}{r}, \quad i=1, 2, \dots, r$$

Subject:

Year: Month: Date: ()

$$M(n) = E[\beta(n) | P(n)] = \sum c_i \cdot P_i(n)$$

جمعیه متوسط اربابیتی به ازای نوع احتمال P_i
در حالت فقدانی ممکن

$$M_0 = \frac{1}{r} \sum c_i$$

$$E[M(n)] = E[\beta(n)]$$

Expedient ← اگر خطایین از حالت متوسط کمتر باشد

$$\lim_{n \rightarrow +\infty} E[M(n)] < M_0$$

$n \rightarrow +\infty$

Optimal ← اگر خطایش کمینه باشد

$$\lim_{n \rightarrow +\infty} E[M(n)] = c_e$$

$n \rightarrow +\infty$

e-optimal ← اگر در نزدیکی خطای کمینه باشد

$$\lim_{n \rightarrow +\infty} E[M(n)] = c_e + \epsilon$$


$n \rightarrow +\infty$

pure chance

expedient

e-optimal

optimal



Subject :

Year . Month . Date . ()

* آرزوی ما اولاد پرستداری

• شبیه ای از سوره که بر لایم ای سوره است

• عمل هر سوره علاوه بر رفتار خودش است به رفتار دیگران بهم بستگی دارد