

یادگیری با نظارت
و سبب بندی

درک سیمون خطی
انتخاب مدل


مقدمه‌ای بر
یادگیری ماشین
بخش دوم



دانشگاه شهید بهشتی
پژوهشکده‌ی فضای مجازی
پاییز ۱۳۹۸
احمد محمودی ازناوه

فهرست مطالب

- یادگیری کلاس
- تعداد نمونه‌های آموزشی مورد نیاز
- دسته‌بندی چندکلاسی
- مقدمه‌ای بر رگرسیون
- رگرسیون خطی تک‌متغیره
- انتخاب مدل



یادگیری کلاس

Class learning is finding a description that is shared by all positive examples and none of the negative examples.

• بحث را با داده‌هایی که از دو کلاس مجزا تشکیل شده‌اند، آغاز می‌کنیم.

– مثال مورد دسته‌بندی خودروها به دو دسته‌ی «خودروهای خانوادگی» و «سایر خودروها» ست.

– با این کار می‌توان


– کلاس یک نمونه‌ی نامشخص را **پیش‌بینی** کرد. **Prediction**

– یا این که دریافت کرده چه خودرویی را خودروی خانوادگی می‌دانند.

Knowledge extraction

– نمونه‌ی نمایش ورودی‌ها:

– x_1 : price, x_2 : engine power





Training set


مجموعه آموزشی

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

$$\mathcal{X} = \{\mathbf{x}^t, r^t\}_{t=1}^N \quad r = \begin{cases} 1 & \text{if } \mathbf{x} \text{ is positive} \\ 0 & \text{if } \mathbf{x} \text{ is negative} \end{cases}$$


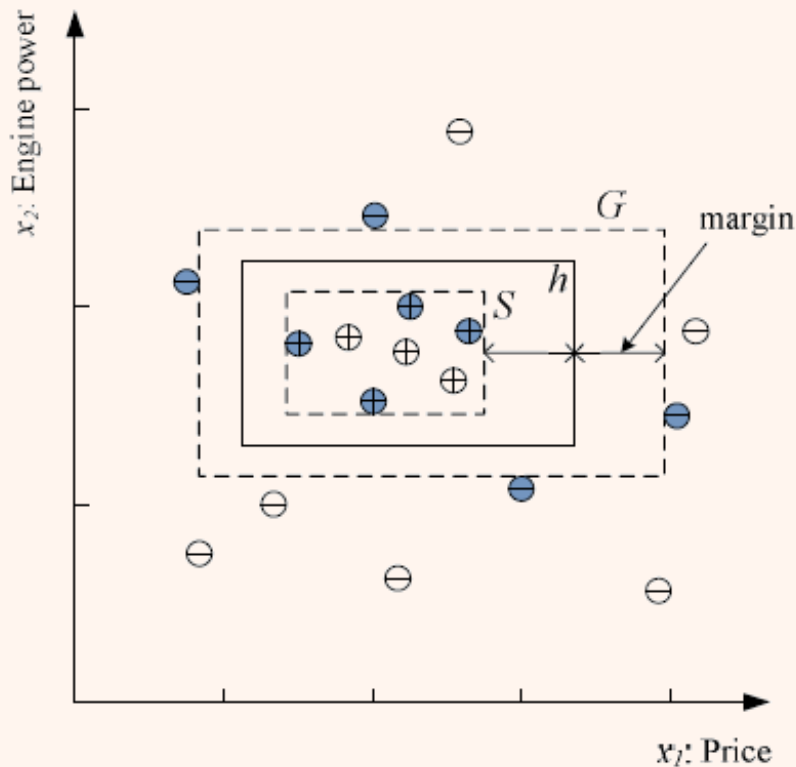


- بی‌شمار «**فرضیه**» می‌توان یافت که دارای فضای صفر باشند.
- یادگیری، را می‌توان جستجو برای یافتن بهترین پارامترها دانست.
- از بین تمامی فرضیه‌های درست، مناسب‌ترین فرضیه آن است که برای **نمونه‌های جدیدی که در آینده دیده می‌شود**، بهترین پاسخ را عرضه کند.



انتخاب بهترین فرضیه

- چنانچه مستطیلی که اضلاع آن موازی محورهای مختصات است به عنوان کلاس فرضیه در نظر گرفته شود، یک انتخاب مناسب برای فرضیه، در نظر گرفتن **بیشترین ماشیه** از اطراف است.
- بدین گونه، قابلیت تصمیم‌پذیری افزایش می‌یابد.
- برای یافتن چنین فرضیه‌ای آیا تابع خطای مطرح شده می‌تواند مفید باشد؟




نویز

- «نویز»، ناهنجاری‌های ناخواسته در داده‌هاست.
- بر اثر نویز، دسته‌بندی دشوارتر خواهد بود و ممکن است دست‌یابی به فضای صفر امکان‌پذیر نباشد.
 - عدم دقت در وسایل اخذ داده
 - خطا در برچسب‌گذاری داده
 - ممکن است برخی ویژگی‌ها در نظر گرفته نشده است و یا ویژگی‌هایی قابل مشاهده نبوده‌اند.



Teacher noise

Hidden or latent attribute



نویز و پیچیدگی مدل


- هنگامی که نویز وجود دارد، مدل به دست آمده پیچیده‌تر خواهد شد.



مزایای انتخاب مدل ساده‌تر



- استفاده از آن ساده‌تر است؛ پیچیدگی محاسباتی کمتری دارد. (نمونه‌های جدید به راحتی آموزش می‌بینند).
- فرآیند آموزش آن، ساده‌تر است.
- در صورت کم بودن داده‌های آموزشی، انتظار داریم با تخییر داده‌های آموزشی، مدل ساده **تخییرات** کمتری داشته باشد.
- از سوی دیگر اگر مدل خیلی ساده باشد، با توجه به انعطاف کم آن، دارای **سوگیری (bias)** بیشتری خواهد بود.
- برای انتخاب مدل مناسب، باید هر دو این عامل‌ها را کمینه کنیم.
- استخراج دانش از مدل ساده، به راحتی صورت می‌پذیرد.
- به ویژه در مواردی که با نویز مواجه هستیم، مدل‌های ساده‌تر که از یک نمونه تاثیر می‌پذیرند (واریانس کمتری دارند)، در این حالت هرچند دارای خطای بیشتری روی داده‌های آموزشی خواهند بود، ولی «تعمیم‌پذیری» بهتری خواهند داشت.

Less variance





تیغ Occam اصلی منسوب به William of Ockham منطق‌دان و فیلسوف انگلیسی است. در قرن ۱۴ میلادی ویلیام اوکام اصلی را مطرح کرد که به نام اصل «تیغ Occam» شناخته شد. طبق این اصل، هر گاه دربارهٔ علت بروز پدیده‌ای دو توضیح مختلف ارائه شود، در آن توضیحی که **پیچیده‌تر** باشد احتمال بروز اشتباه بیشتر است و بنابراین، در شرایط مساوی بودن سایر موارد، توضیح **ساده‌تر**، احتمال صحتش بیشتر است.

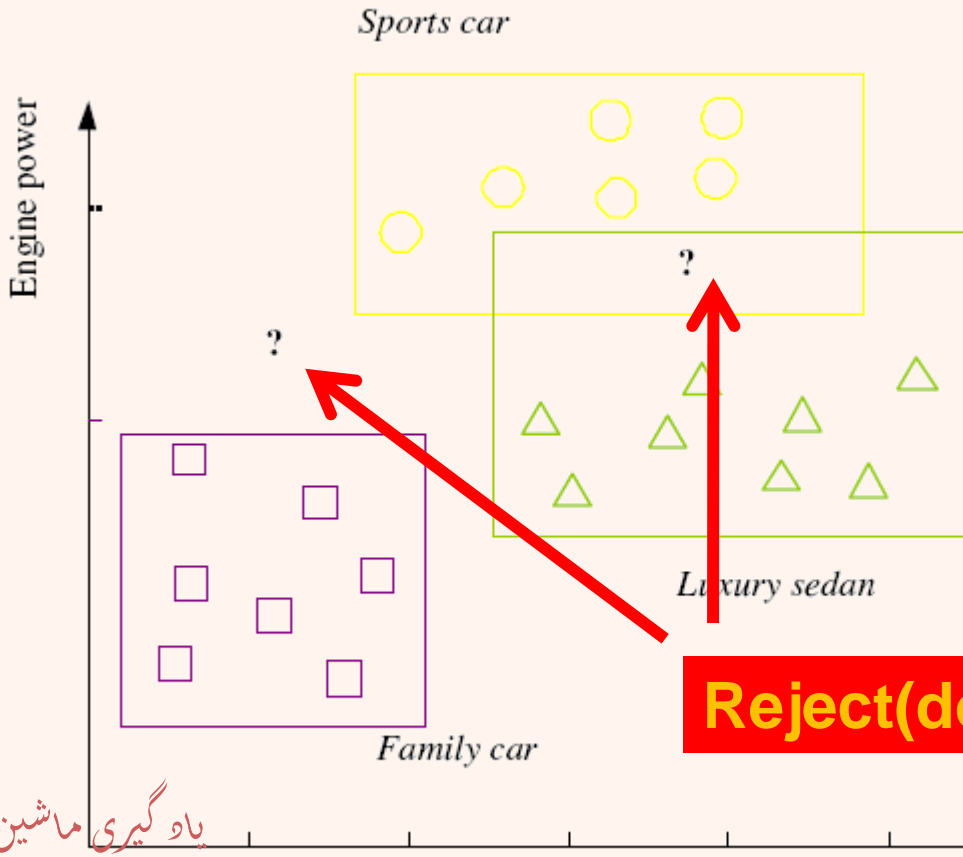


دسته‌بندی چندکلاسی (k)

می‌توان مسئله را به صورت K دسته‌بندی دو کلاسه در نظر گرفت.

k, r بعدی است.


$$\mathcal{X} = \{\mathbf{x}^t, r^t\}_{t=1}^N \quad r_i^t = \begin{cases} 1 & \text{if } \mathbf{x}^t \in C_i \\ 0 & \text{if } \mathbf{x}^t \in C_j, j \neq i \end{cases}$$



Train hypotheses

$h_i(\mathbf{x}), i = 1, \dots, K:$

$$h_i(\mathbf{x}^t) = \begin{cases} 1 & \text{if } \mathbf{x}^t \in C_i \\ 0 & \text{if } \mathbf{x}^t \in C_j, j \neq i \end{cases}$$



مقدمه‌ای بر رگرسیون

- در رگرسیون، برخلاف دسته‌بندی با یک تابع پیوسته مواجه هستیم:


$$\mathcal{X} = \{x^t, r^t\}_{t=1}^N \quad r^t \in \mathbb{R}$$

- برخلاف **درون‌یابی**، در رگرسیون وجود نویز در خروجی را هم باید در نظر گرفت.

- وجود نویز را می‌توان به مربوط به متغیرهای مخفی (غیرقابل مشاهده) دانست.

$$r^t = f^*(x^t, z^t)$$



- هدف، تخمین خروجی با استفاده از مدل پیشنهادی $g(x)$ است.



مقدمه‌ای بر رگرسیون (ادامه...)

- فضای داده‌های آموزشی را می‌توان به صورت زیر تعریف کرد:

$$E(g | \mathcal{X}) = \frac{1}{N} \sum_{t=1}^N [r^t - g(x^t)]^2$$




رگرسیون خطی تک متغیره

- با فرض این که $g(x)$ خطی است:

$$g(\mathbf{x}) = w_1 x_1 + w_2 x_2 + \dots + w_0 = \sum_{j=1}^d w_j x_j + w_0$$

- فرض می‌کنیم که مثال مورد نظر دوبعدی باشد، در نتیجه تابع خطی به صورت زیر خواهد شد:

$$E(w_1, w_0 | \mathcal{X}) = \frac{1}{N} \sum_{t=1}^N [r^t - (w_1 x^t + w_0)]^2$$



رگرسیون خطی تک متغیره (ادامه...)

$$E(w_1, w_0 | \mathcal{X}) = \frac{1}{N} \sum_{t=1}^N [r^t - (w_1 x^t + w_0)]^2$$

- برای پیدا کردن پارامترهای بهینه باید مشتق گرفته و آن را مساوی صفر قرار دهیم:

$$\frac{\partial E}{\partial w_0} = \frac{2}{N} \sum_{t=1}^N [r^t - (w_1 x^t + w_0)](-1)$$

$$\frac{\partial E}{\partial w_1} = \frac{2}{N} \sum_{t=1}^N [r^t - (w_1 x^t + w_0)](-x^t)$$


- دو معادله و دو مجهول

$$w_0 = \bar{r} - w_1 \bar{x}$$

$$w_1 = \frac{\sum_t x^t r^t - \bar{x} \bar{r} N}{\sum_t (x^t)^2 - N(\bar{x})^2}$$



$$\bar{x} = \frac{\sum_t x^t}{N}$$

$$\bar{r} = \frac{\sum_t r^t}{N}$$







رگرسیون

- در صورتی که مدل خطی برای داده‌ها ساده باشد، می‌توان از تابع درجه‌ی دو و یا درجات بالاتر استفاده کرد:





چند عملیاتی با درجات بالاتر




Over fitting

Best fit




انتخاب مدل و تصمیم‌پذیری


- یادگیری، یک مسأله‌ی **ill-posed** است؛ داده‌های آموزشی به تنهایی برای یافتن یک راه حل یکتا، کافی نیستند.
- در یادگیری استقرایی، افزون بر داده‌ها باید مفروضاتی را نیز در نظر گرفت. بدون پیش‌فرض قادر به حل مسأله نخواهیم بود.



- در نتیجه، علاوه بر داده‌ها باید مفروضات دیگری در نظر گرفت که پاسخ یکتایی به دست آید. این پیش‌فرض‌ها «**inductive bias**» نامیده می‌شود.
 - **کلاس فرضیه**، پیش‌فرض مذکور تلقی می‌شود.
- هر چه **ظرفیت** فرضیه افزایش یابد، **پیچیدگی** آن نیز بیشتر خواهد شد.
 - دو مستطیل ناهمپوشان در مقابل یک مستطیل و انتخاب مستطیل به بیشترین ماشیه
 - یا انتخاب خط برای رگرسیون و یا معیار مینیمم خط
- در «**انتخاب مدل**» باید تصمیم‌پذیری را در نظر داشت.



انتخاب مدل و تعمیم پذیری



برای افزایش «قابلیت تعمیم» باید پیچیدگی مدل متناسب با پیچیدگی داده‌ها انتخاب شود.


• در صورتی که پیچیدگی مدل کم‌تر از داده باشد، اصطلاحاً گفته می‌شود **underfitting** رخ داده است.

– مانند زمانی که یک منحنی درجه‌ی سه با یک خط تقریب زده شود.

– در چنین حالتی فضای آموزشی و فضای مرزهای validation (validation error) هر دو بالا خواهند بود.

• در صورتی که مدل پیچیده‌تر انتخاب شود، **overfitting** رخ می‌دهد.


– با افزایش داده‌های آموزشی می‌توان اثر آن را تا حدی کاهش داد.



Tradeoff سه‌گانه


- بین عوامل زیر tradeoff وجود دارد:
 - پیچیدگی کلاس فرضیه \mathcal{H} ، $c(\mathcal{H})$
 - اندازهی مجموعهی آموزشی، N
 - خطای تعمیم، E

$N, E \downarrow$
 $c(\mathcal{H})$, first $E \downarrow$ and then E



- برای بررسی تصمیم‌پذیری، بخشی از داده‌ها را در آموزش مورد استفاده قرار نمی‌دهیم (validation set)، و تنها برای بررسی تصمیم‌پذیری از آن‌ها استفاده می‌شود.
- در نتیجه، فرضیه‌ای که با داده‌های validation بهترین پاسخ را دارند، به عنوان فرضیه‌ی مناسب انتخاب می‌شود.
- بعد از آموزش، برای مقایسه روش مورد استفاده، داده‌های آزمایش که باید متفاوت از داده‌های آموزشی و داده‌های validation هستند، مورد استفاده قرار گیرد.

Test set (publication set)



ابعاد متفاوت الگوریتم‌های یادگیری ماشین

- مدل $g(\mathbf{x}|\theta)$
- تابع هزینه (cost or loss function)

$$E(\theta | \mathcal{X}) = \sum_t L(r^t, g(\mathbf{x}^t | \theta))$$

- فرآیند بهینه‌سازی

$$\theta^* = \arg \min_{\theta} E(\theta | \mathcal{X})$$

- در صورتی که مدل پیچیده‌تر شود، به روش‌های پیچیده‌تری برای یافتن پارامترهای بهینه احتیاج خواهیم داشت.
- برای انجام مناسب آموزش به مدلی با ظرفیت مناسب، تعداد نمونه‌های آموزشی مناسب و یک فرآیند بهینه‌سازی خوب احتیاج داریم.

