

یادگیری با نظارت
و سبب بندی

درک سیمون خطی
انتخاب مدل


مقدمه‌ای بر
یادگیری ماشین
بخش دوم



دانشگاه شهید بهشتی
پژوهشکده‌ی فضای مجازی
پاییز ۱۳۹۹
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 استفاده 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:


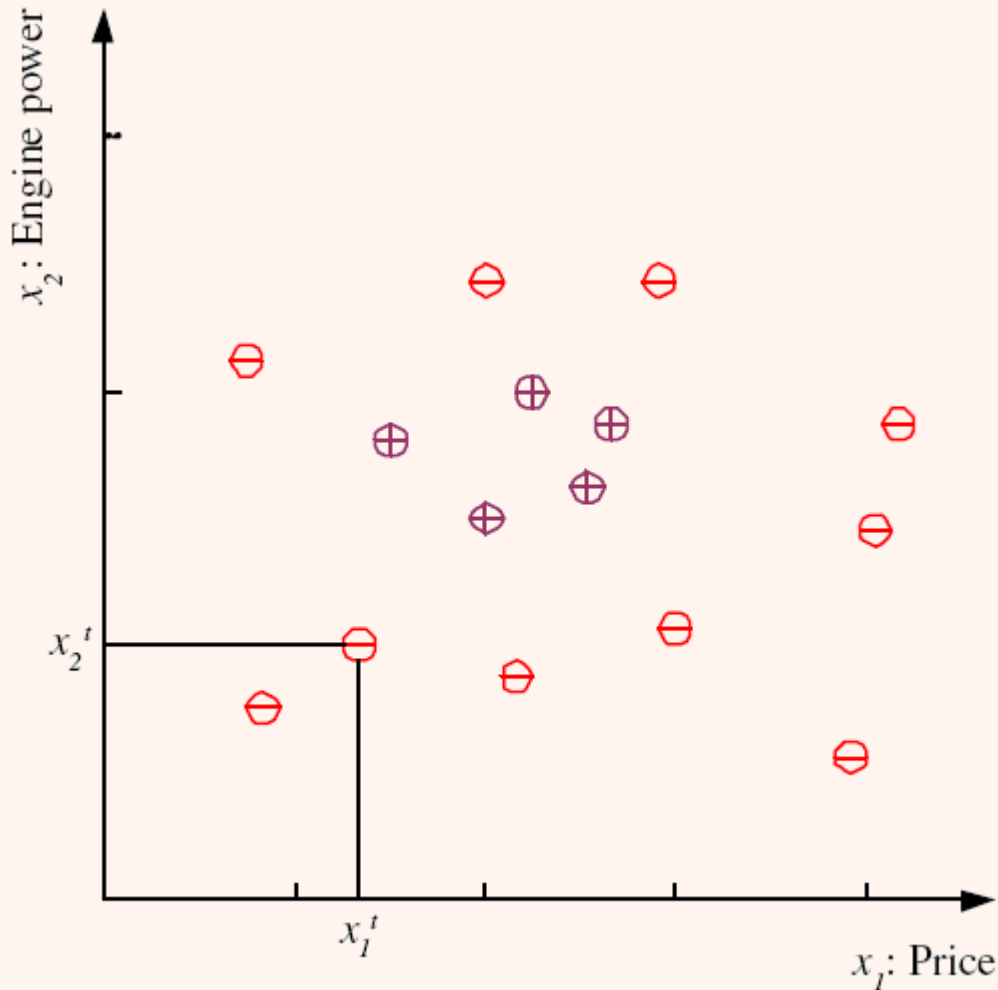


Training set

دسته‌ی آموزشی

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

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



Hypothesis class \mathcal{H}

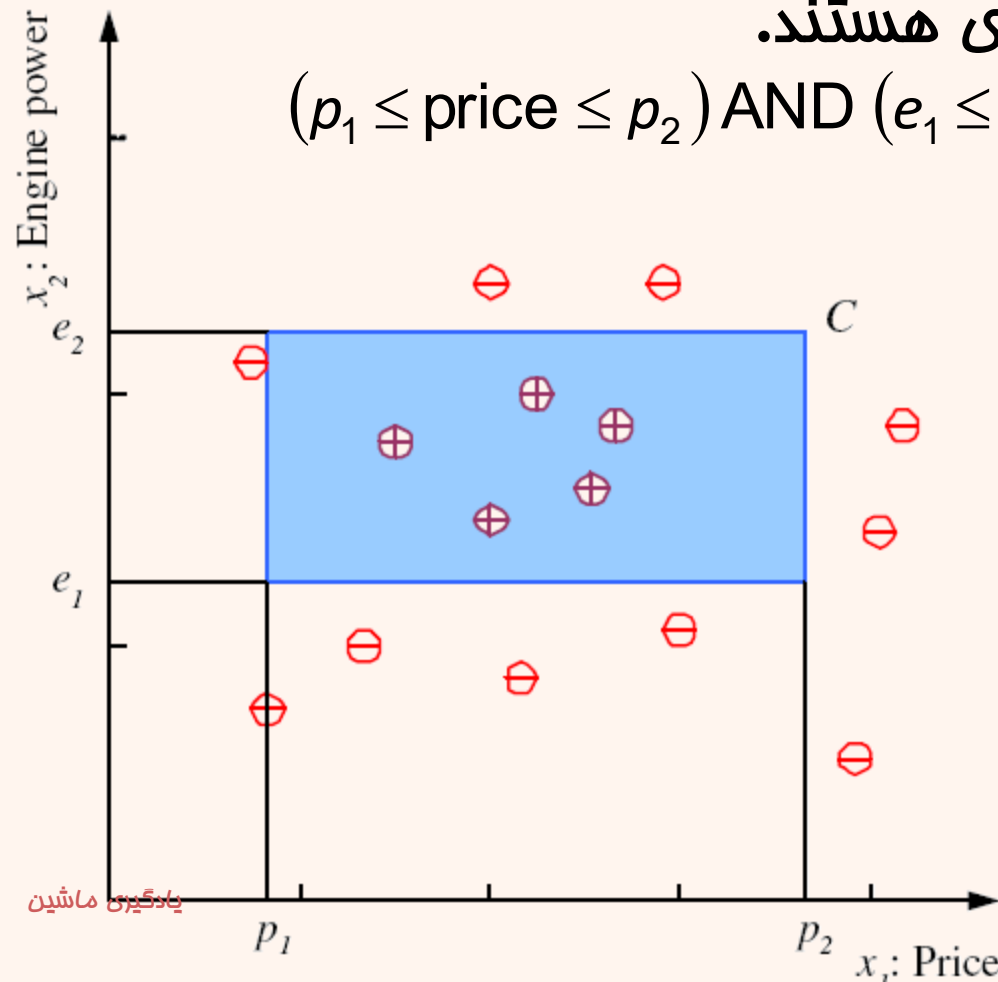
• «کلاس فرضیه» مدلی است که برای دسته‌بندی مورد استفاده

Hypothesis Class

قرار می‌گیرد.

• در این مثال شامل همه‌ی مستطیل‌هایی است که با محورهای مختصات موازی هستند.

$$(p_1 \leq \text{price} \leq p_2) \text{ AND } (e_1 \leq \text{engine power} \leq e_2)$$



Hypothesis

$$h \in \mathcal{H}$$

• از بین کلاس فرضیه

یک «فرضیه» با


کمترین خطا جستجو

می‌شود.

• هر چهارتایی مرتب

یک فرضیه را مشخص

می‌کند.



فرضیه

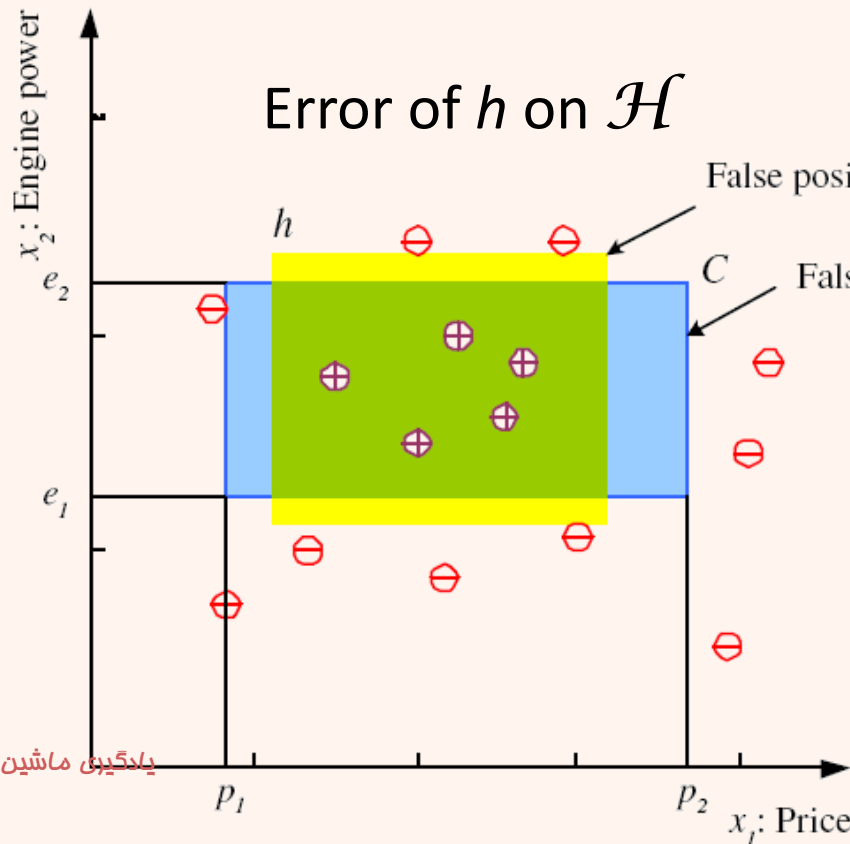
• هدف یافتن h به نحوی است که حداکثر شباهت به C را داشته باشد.

$$h(\mathbf{x}) = \begin{cases} 1 & \text{if } h \text{ says } \mathbf{x} \text{ is positive} \\ 0 & \text{if } h \text{ says } \mathbf{x} \text{ is negative} \end{cases}$$


Error of h on \mathcal{H}

$$E(h | \mathcal{X}) = \sum_{t=1}^N 1(h(\mathbf{x}^t) \neq r^t)$$


empirical error (training error)




• خطای آموزشی، میزان
نمونه‌های آموزشی است که
توسط h به درستی پیش‌بینی
نمی‌شوند.



- بی شمار فرضیه می توان یافت که دارای خطای صفر باشند.
- یادگیری، را می توان جستجو برای یافتن بهترین پارامترها دانست.
- از بین تمامی فرضیه های درست، مناسب ترین فرضیه آن است که برای **نمونه های جدیدی که در آینده دیده می شود**، بهترین پاسخ را عرضه کند.



- بی شمار «**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.



A **machine learning hypothesis** is a candidate model that approximates a target function for mapping inputs to outputs

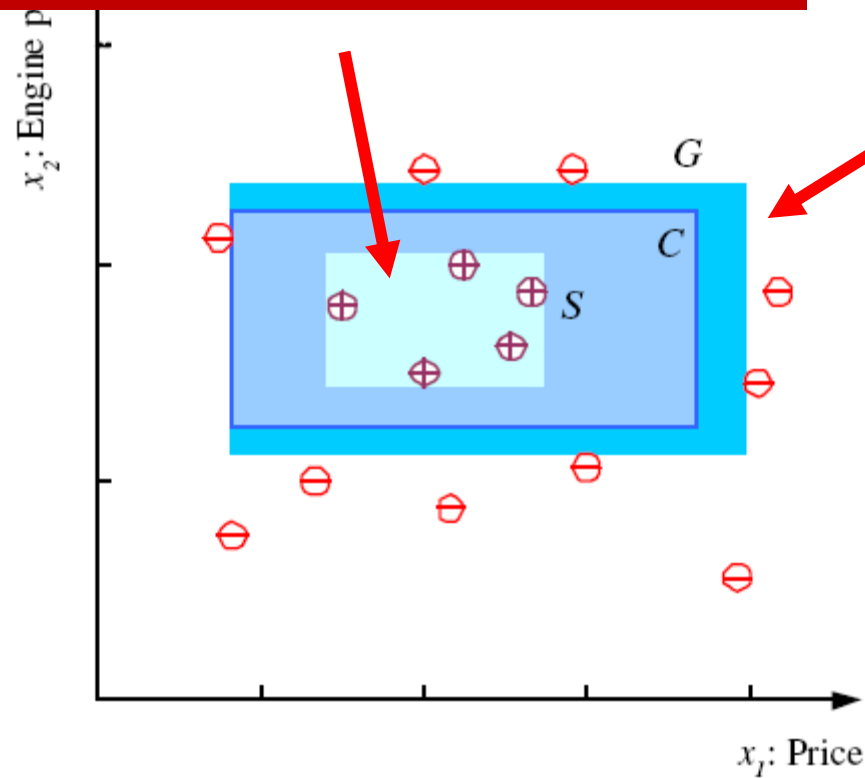
<https://machinelearningmastery.com/what-is-a-hypothesis-in-machine-learning/>



Version Space Learning

اقتصاصی ترین فرضیه


most specific hypothesis, S



most general hypothesis, G

عمومی ترین فرضیه


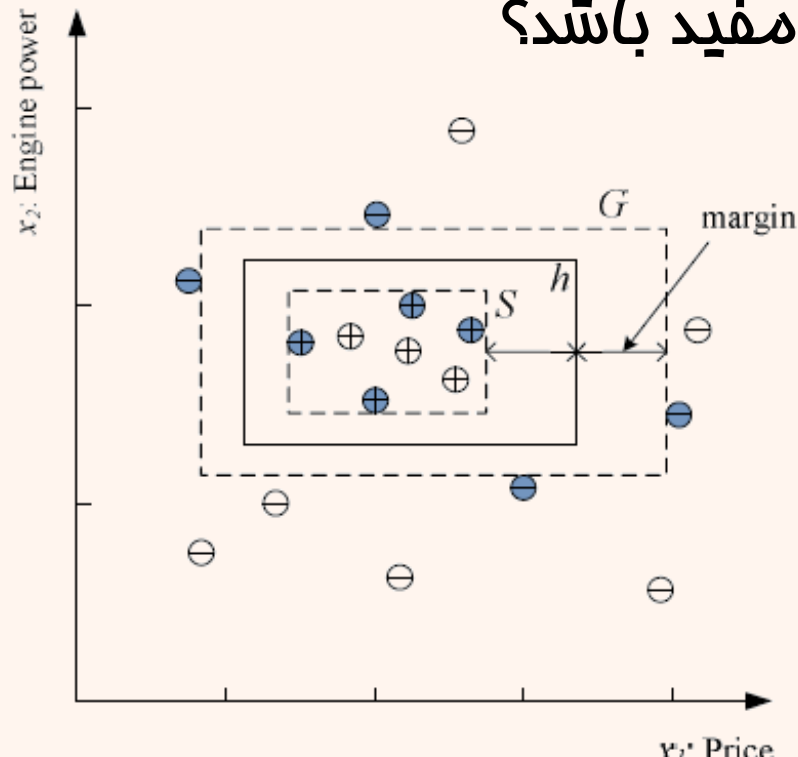
$h \in H$, between S and G is consistent and make up the version space (Mitchell, 1997)



$$\text{Consistent}(h, D) \equiv (\forall \langle x, c(x) \rangle \in D) h(x) = c(x)$$

انتخاب بهترین فرضیه

- یک انتخاب مناسب برای فرضیه، در نظر گرفتن **بیشترین ماشیه** از اطراف است.
- بدین گونه، قابلیت تعمیم پذیری افزایش می یابد.
– برای یافتن چنین فرضیه ای آیا تابع خطای مطرح شده می تواند مفید باشد؟



ظرفیت

- در برخی کاربردها هزینهی اشتباه بسیار بالاست، از این رو در صورتی که نمونه در ناحیهی ماشیهی باشد، به جای دسته‌بندی برچسب «مشکوک» خواهد خورد و بررسی بیشتر آن به یک متخصص سپرده خواهد شد.


doubt

- تا این‌جا مطرح شد، هدف از یادگیری یافتن فرضیه‌ای با خطای صفر است.

$$E(h|X) = 0$$


- اما همیشه، یافتن چنین فرضیه‌ای امکان‌پذیر نیست، در واقع برای هر کاربرد، باید مطمئن باشیم که کلاس فرضیه «ظرفیت کافی» برای آموختن C را دارد.

capacity

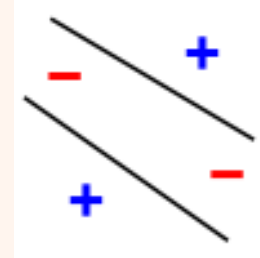
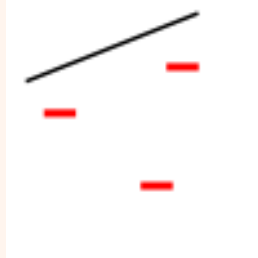
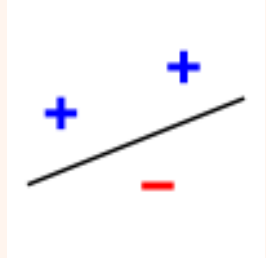
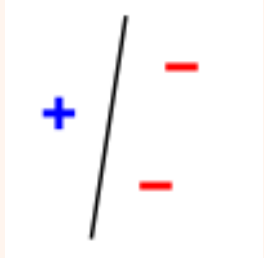


VC Dimension

- در صورتی که یک مجموعه داده شامل N نمونه باشد، می‌توان آن را به 2^N شیوهی متفاوت برچسب زد (دسته‌بندی دوکلاسه).
- در صورتی که بتوان برای همهی این 2^N حالت، یک فرضیه $h \in \mathcal{H}$ یافت که کلاس‌ها قابل جداسازی باشند، گفته می‌شود که \mathcal{H} ، N نمونه (نقطه) را جدا (**shatter**) می‌کند. به بیان دیگر، این فرضیه قابلیت آموختن N نمونه را بدون خطا دارد.
- به بیشترین مقدار N ، **Vapnik-Chervonenkis (VC) Dimension** گفته می‌شود و به صورت $VC(\mathcal{H}) = N$ نمایش داده می‌شود.


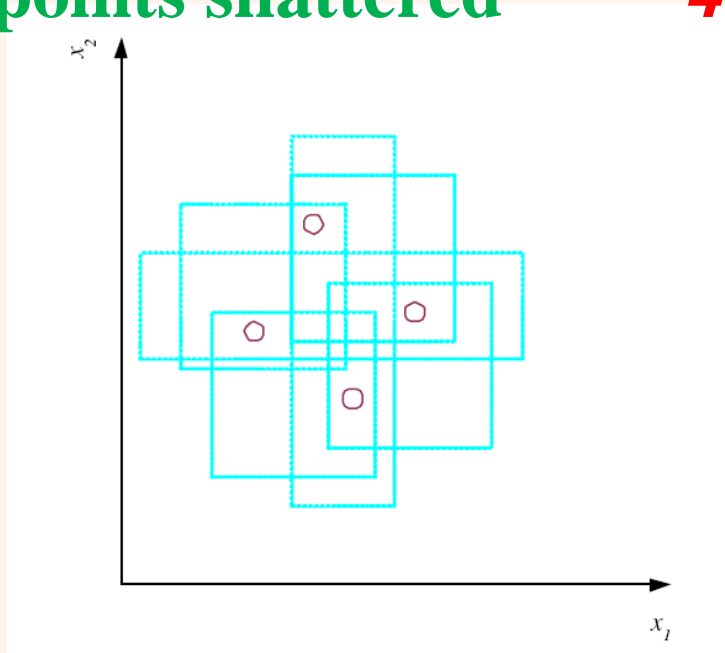


VC Dimension



3 points shattered

4 points impossible



در مورد یک جدول مراجعه (look up table) چه می‌توان گفت؟


Probably Approximately Correct (PAC) Learning

- هر چه تعداد نمونه‌های آموزشی بیشتری در اختیار داشته باشیم، فرضیه‌ی به دست آمده، پاسخ دقیق‌تری خواهد داشت.

– کلاس مفروض C که در آن نمونه‌ها از یک توزیع ثابت استخراج شده‌اند، **PAC-learnable** نامیده می‌شود چنانچه با احتمال $1 - \delta$ بتوان فرضیه‌ای یافت که خطای آن کمتر از ϵ باشد.

- $\delta \leq 1/2$, $\epsilon > 0$

– با فرض این که اختصاصی‌ترین فرضیه در نظر گرفته شود، چه تعداد نمونه آموزشی (N) مورد نیاز است، تا با حداقل احتمال $1 - \delta$ میزان خطا حداکثر ϵ باشد؟



می‌خواهیم فرضیه‌ی مورد استفاده در «بیشتر موارد»، «تقریباً درست» باشد

Probably Approximately Correct (PAC) Learning

Each strip is at most $\epsilon/4$

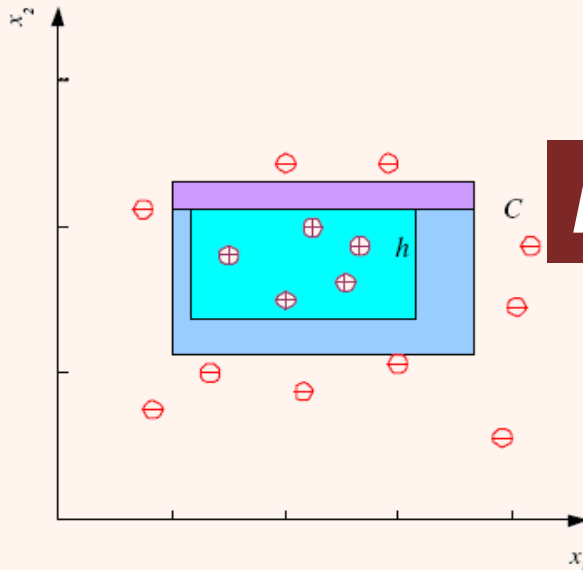
Pr that we miss a strip $1 - \epsilon/4$

Pr that N instances miss a strip $(1 - \epsilon/4)^N$


Pr that N instances miss 4 strips is **at most** $4(1 - \epsilon/4)^N$

$4(1 - \epsilon/4)^N \leq \delta$ and $(1 - x) \leq \exp(-x)$

$4\exp(-\epsilon N/4) \leq \delta$ and **$N \geq (4/\epsilon)\ln(4/\delta)$**



$$P\{C \Delta h \leq \epsilon\} \geq 1 - \delta$$



نویز

- «نویز»، ناهنجاری‌های ناخواسته در داده‌هاست.
- بر اثر نویز، دسته‌بندی دشوارتر خواهد بود و ممکن است دست‌یابی به خطای صفر امکان‌پذیر نباشد.


– عدم دقت در وسایل اخذ داده

Teacher noise

– خطا در برچسب‌گذاری داده


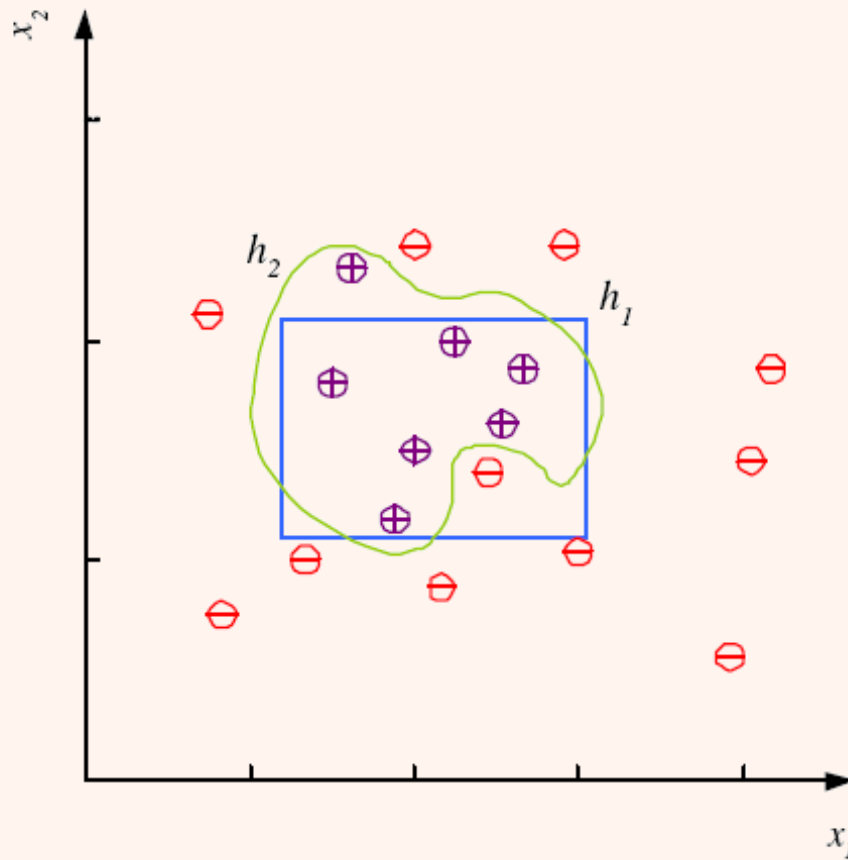
- ممکن است برخی ویژگی‌ها در نظر گرفته نشده است و یا ویژگی‌هایی قابل مشاهده نبوده‌اند.

Hidden or latent attribute



نویز و پیچیدگی مدل


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



مزایای انتخاب مدل ساده‌تر


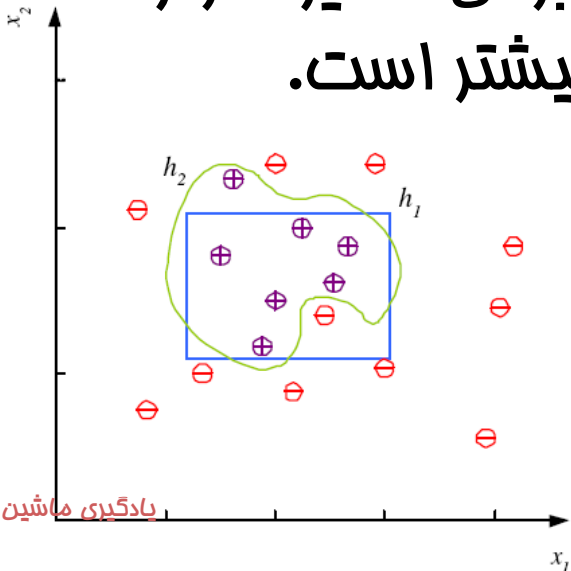
- استفاده از آن ساده‌تر است؛ پیچیدگی محاسباتی کمتری دارد. (نمونه‌های جدید به راحتی آموزش می‌بینند).
- فرآیند آموزش آن، ساده‌تر است.
- در صورت کم بودن داده‌های آموزشی، انتظار داریم با تخییر داده‌های آموزشی، مدل ساده **تخییرات** کمتری داشته باشد.
- از سوی دیگر اگر مدل خیلی ساده باشد، با توجه به انعطاف 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 **پیمیده‌تر** باشد احتمال بروز اشتباه بیشتر است و بنابراین، در شرایط مساوی بودن سایر موارد، توضیح **ساده‌تر**، احتمال صحیح بودنش بیشتر است.

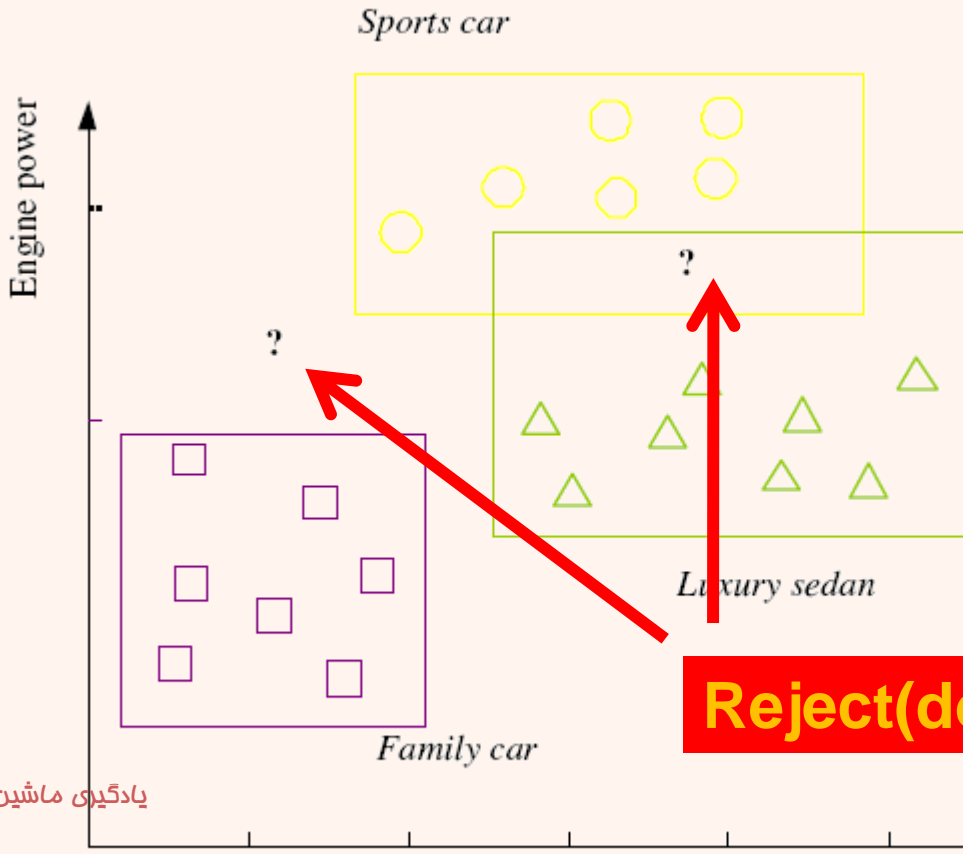


دسته‌بندی چندکلاسی (k)

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

k ، 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


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

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



دسته بندی چندبرچسبی

- در این حالت به هر داده می‌تواند به صورت همزمان به چند دسته متعلق باشد.



مقدمه‌ای بر رگرسیون (پس‌نمایی)

- 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.

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


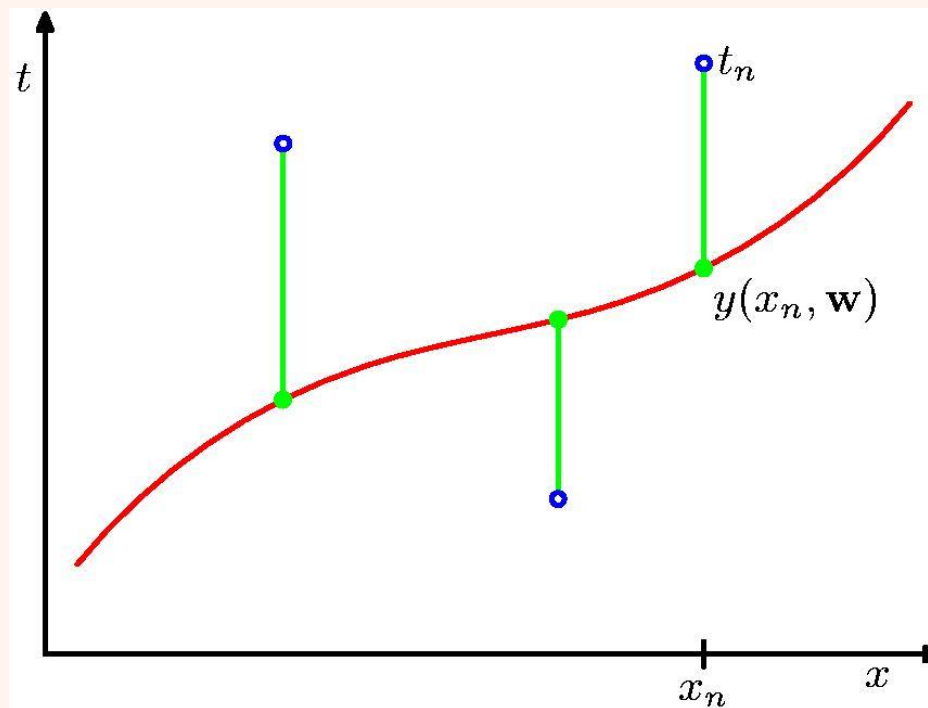
- هدف، تخمین خروجی با استفاده از مدل پیشنهادی $g(x)$ است.



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

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

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


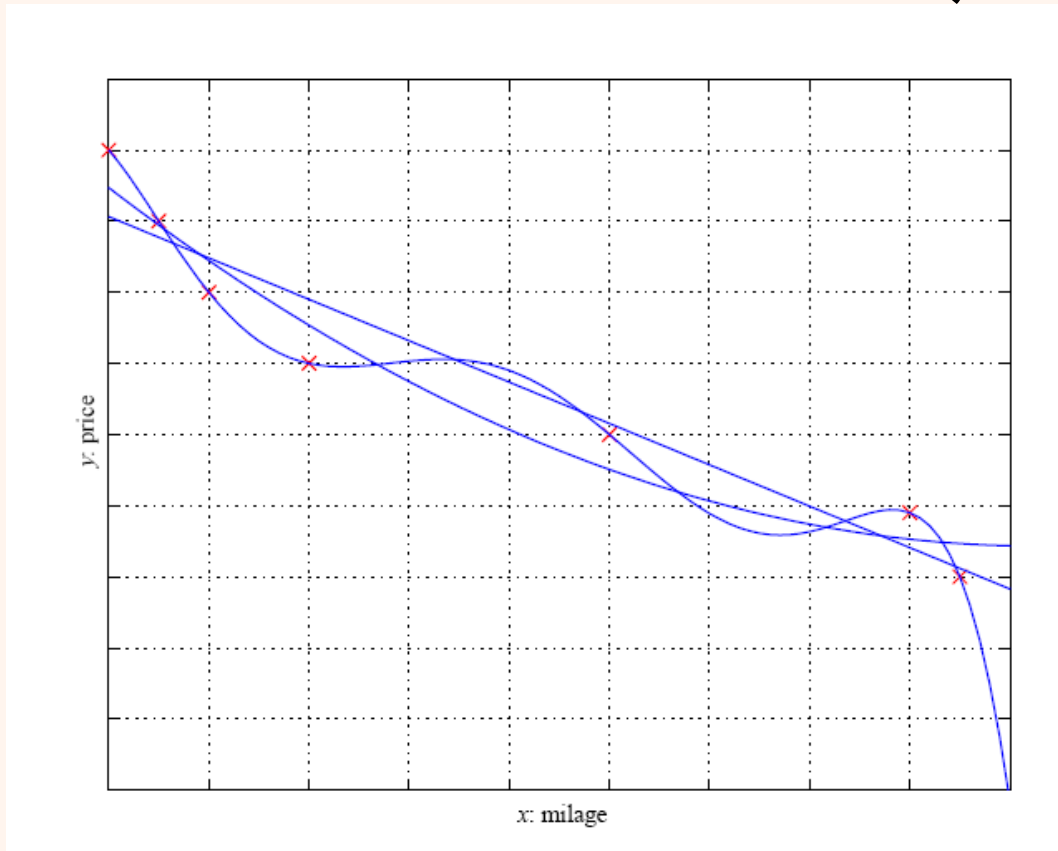
$$\bar{x} = \frac{\sum_t x^t}{N}$$

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

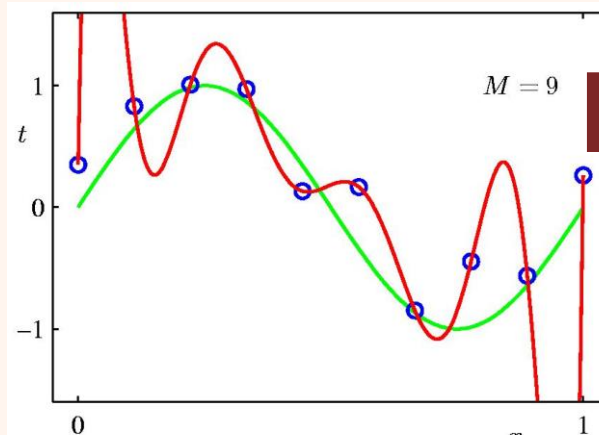
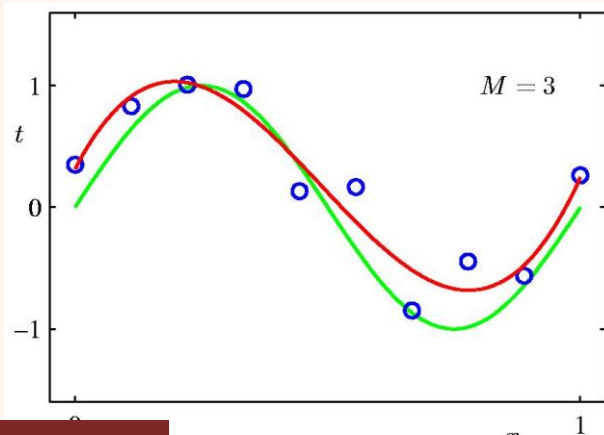
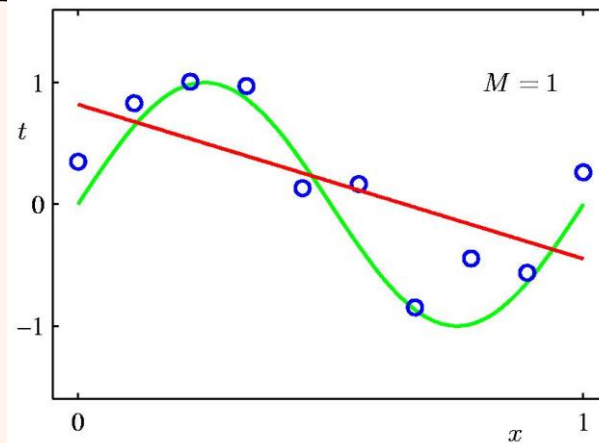
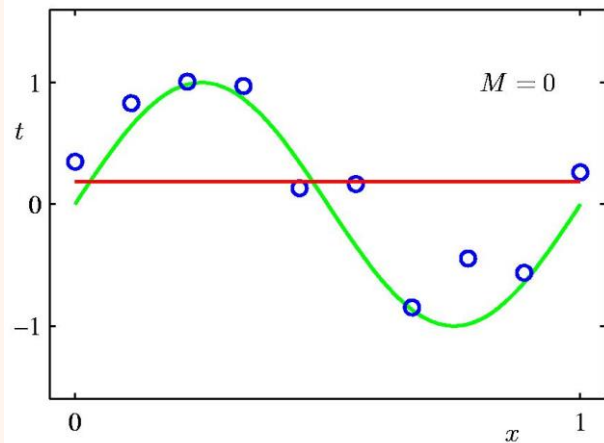


رگرسیون

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


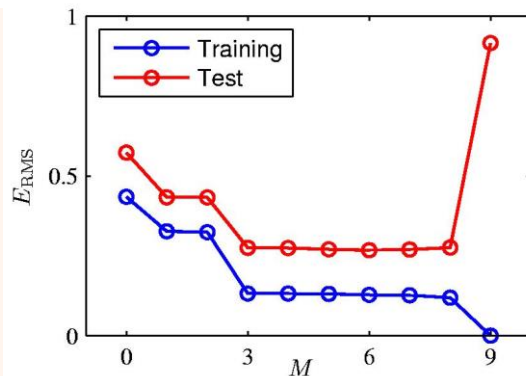


چند عملیاتی با درجات بالاتر




Over fitting

Best fit




انتخاب مدل و تصمیم‌پذیری

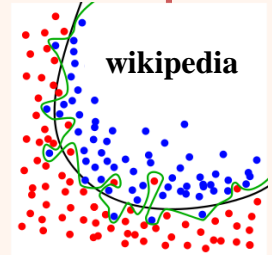
- یادگیری، یک مسأله‌ی **ill-posed** است؛ داده‌های آموزشی به تنهایی برای یافتن یک راه حل یکتا، کافی نیستند.
- در یادگیری استقرایی، افزون بر داده‌ها باید مفروضاتی را نیز در نظر گرفت. بدون پیش‌فرض قادر به حل مسأله نخواهیم بود.



- 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
 - فضای تصمیم، E

$N \uparrow, E \downarrow$
 $c(\mathcal{H}) \uparrow$, 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.

