

میان ترم ۱ : شماره ۵ ← بعد از ترمین ۵.۵ فصل

پایان ترم ۲ : شماره ۶

تشریحات : شماره ۴

ارائه : شماره ۳

پروژه پایانی : شماره ۳

← از بیان تئوری مقالات منتخب موضوع تأیید شود و پس ارائه شود پس یک مقاله دیگر هم باید انتخاب دارا ارائه شود (مجموعاً باید دو مقاله ارائه شود با هم تکیه شود و در نهایت پیشنهادی در رابطه با بسود عملی مقاله‌ای داده شود)

(ی توایم مقالات را از وبسایت‌های دریاوت کنیم که که علی برنا هم موجود باشد. احتمالاً باید در Github یا CodeOcean موجود باشد.)

فرم انزهارها در زبان‌های مورد استفاده

MATLAB -

Python -


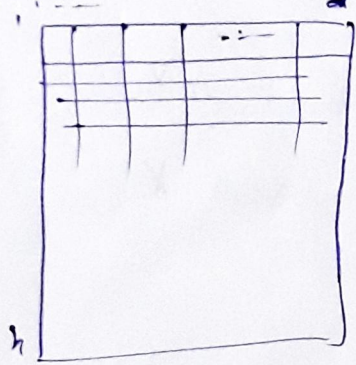
در درس بررسی پروژه پایانی، ی توایم روشی را که جهت بسود مقاله‌ی ارائه انجام دهیم، به صورت پیاده‌سازی نرم‌انزای درآمده در بررسی بصورت عملی صورت گیرد

- داستان مربوط به مایکلی رویه‌های ما سطح‌ها (توضیحات مربوط بسیار زیاد بود ولی مجبوراً خلاصه‌ای از تمامی مباحث مربوط به این درس سطح شده که صرفاً برای اصلی‌ترین درس را مطرح می‌کرد.)



- ۱. ۱۴.۱، ۷، ۱۷ : درجه‌بندی داده‌ها داشتن ماهیگیری و دستبندی صحبت شد درباره 1nn و feature ماهیگیری شد
  - ۲. ۱۴.۱، ۷، ۱۲ : درباره تقاطع ISI گفتاری و در زمانی صحبت شد اما چیزی تدریس نشد
- ۱۴.۱، ۷، ۱۷

Data



روش خوشه‌بندی K-means (X)

- ۱- تعدادی تصادفی به k مرکز خوشه
- ۲- براب‌اندازی داده‌ها بر اساس نزدیک‌ترین مرکز خوشه

۳- مراکز خوشه جدید تولید می‌کنیم (میانگین داده‌های یک خوشه)





۴- مرحله ۲، ۳، ۴ استفاده تکرار شود تا براب‌اندازی مراکز خوشه‌ها در ۲ تکرار سوالی تغییر نکرده

**K-medoid**

(X) روش خوشه‌بندی K-medoid : مانند روش قبل است اما این تفاوت که مراکز خوشه‌ها از میان نقاط موجود در میان نقاط داده ما انتخاب می‌شود. (در روش اول، نقاط مراکز مجازی هستند)



⊗ رگرسیون خطی، هدف رسیدن به رابطه ی  $Y = \alpha + \beta X$



$$\alpha = \bar{Y} - \beta \bar{X}$$

$$\beta = \frac{\sum_{i=1}^n (\cancel{x_i - \bar{X}})(\cancel{y_i - \bar{Y}})}{\sum_{i=1}^n (x_i - \bar{X})^2}$$

$\bar{Y}$  میانگین  $Y$  های داده های Train

$\bar{X}$  میانگین  $X$  های داده های Train

۱۴، ۱۷، ۱۹

داده }  
تغییر }  
بسته }  
لته

انواع داده :  
کی ، قابل شمارش و یا اندازه گیری هستند  
مابعد نمایش داده می شوند  
[نمونه داین نوع تغییر قابل تعریف است]

کیفی ، بر اساس یک یا چند خاصیت در دسته های مختلف قرار می گیرند  
رتبه ای / ordinal

[نمونه قابل تعریف است]

رتبه ای (ordinal) ، رتبه داشتن ، عملگر سفید < > = دارد


اسمی (nominal) ، دسته بندی عبارتست ، فقط عملگر = ، ≠ دارد

انواع داده ها ، فرض کنیم ۱۱ داده داریم بعد داریم . اگر بخواهیم با حفظ چگالی این داده ها را به ۵ دسته تقسیم کنیم به

۱۱ داده نیاز داریم داشت .

مركزیت آوردن آلودی میان داده ها ، هر چه انحراف بالاتر باشد ، نیاز به

داده های بیشتری است .





ساختیم آمار،

تأخیرهای مرکزی

۱- میانگین

$$M_A = \frac{\sum_{i=1}^n x_i}{n}$$

همگی

$$M_G = \left( \prod_{i=1}^n x_i \right)^{\frac{1}{n}}$$

همگی

۲- میانگین (داده‌های)

$$M_H = \frac{n}{\sum_{i=1}^n \frac{1}{x_i}}$$

همگی

۳- عدد (نم)

$$M_W = \frac{\sum_{i=1}^n w_i x_i}{\sum_{i=1}^n w_i}$$

داده‌های

$M_H \leq M_G \leq M_A$

توجه‌های براندگی

۱- دانه تغییرات:  $M_{\max}(x_1, x_2, \dots, x_n) - M_{\min}(x_1, x_2, \dots, x_n)$

۲- میانگین انحرافات:  $\frac{1}{n} \sum_{i=1}^n |x_i - M_A|$

۳- واریانس:  $S^2 = \frac{1}{n} \sum_{i=1}^n (x_i - M_A)^2$

۴- انحراف معیار:  $S = \sqrt{S^2}$

نمونه: از هر مورد از میانگین برای کالیبراسیون کاربرد مثال بزنند


شخص‌های برای دو ویژگی

کواریانس:  $Cov(x, y) = \frac{1}{n} \sum_{i=1}^n (x_i - M_x)(y_i - M_y)$

(در معنوم که براند رابطه بین دو ویژگی را نشان دهد)


فهرست همبستگی

$$Correlation(x, y) = \frac{Cov(x, y)}{\sqrt{Var(x) \cdot Var(y)}}$$




$$S_{z_i} = \frac{1}{n} \sum_{k=1}^n (x_{k_i} - M_{z_i})(x_{k_j} - M_{z_j})$$

نمونه: آماده‌سازی یک سری Data مرتبط با کانال‌های سیگنالی (داده‌ها از هم جدا می‌شوند). کواریانس برای این داده‌ها محاسبه شود و اطلاعات فیچرهای انتخاب شده به یک دسته بندی کته  $n \times n$  داده شود.








Correlation  $\alpha = -$   
 Correlation  $\alpha = +$   
 Correlation  $- = 0$

مثال

فردانی (تعداد داده‌ها)



(\*) داده‌های نرمال

$\mu$  = میانگین  
 $\delta$  = انحراف معیار

(\*) داده‌های نرمال استاندارد

$$\mu = 0$$

$$\delta = 1$$

مثال فرض کنیم داده‌های  $x_i$  که مثل  $\{x_1, \dots, x_n\}$  در نظر هستند را اختیار داریم. آن‌ها را به نرمال استاندارد تبدیل می‌کنیم.


$$y_i = \frac{x_i - \mu_x}{\delta_x}$$

$$\mu_y = \frac{\sum_{i=1}^n y_i}{n} = \frac{\sum_{i=1}^n \left( \frac{x_i - \mu_x}{\delta_x} \right)}{n} = \frac{\sum_{i=1}^n \frac{x_i}{n} - \sum_{i=1}^n \frac{\mu_x}{n}}{\delta_x} = \frac{\mu_x - \mu_x}{\delta_x} = 0$$



$$\begin{aligned} \delta_y &= \sqrt{\frac{\sum_{i=1}^n (y_i - \mu_y)^2}{n}} = \sqrt{\frac{\sum_{i=1}^n (y_i^2 - 2y_i \mu_y + \mu_y^2)}{n}} = \sqrt{\frac{\sum_{i=1}^n y_i^2}{n}} = \sqrt{\frac{\sum_{i=1}^n \left( \frac{x_i - \mu_x}{\delta_x} \right)^2}{n}} \\ &= \sqrt{\frac{\sum_{i=1}^n (x_i - \mu_x)^2}{\delta_x^2 n}} = \frac{1}{\delta_x} \sqrt{\frac{\sum_{i=1}^n (x_i - \mu_x)^2}{n}} = \frac{1}{\delta_x} \times \delta_x = 1 \end{aligned}$$



کاهش ابعاد



خطی  
غیر خطی



انتخاب دترتی  
استخراج دترتی

روش PCA برای استخراج دترتی

تحلیل مؤلفه‌های اصلی (Principle Component Analysis)

۰ (معمولاً) ابتدا ماین داره ما را معرفی کنیم

۱ ماتریس کواریانس دترتی طابقت آورده  $C_{D \times D}$

۲ بردارهای ویژه و مقادیر ویژه ماتریس C را محاسبه می‌کنیم

$$C \times E_{vector} = \lambda \times E_{vector}$$

۳ حالت  $|\lambda I - C| = 0$  را حل می‌کنیم، مقادیر ویژه را مرتب می‌کنیم. (به صورت نزولی)

$$\begin{vmatrix} \lambda I - C_{11} & \dots & \dots \\ \dots & \lambda I - C_{22} & \dots \\ \dots & \dots & \lambda I - C_{dd} \end{vmatrix}$$

$D \times D$

$$\lambda_1 > \lambda_2 > \lambda_3 \dots > \lambda_0$$

۴ تعداد ابعاد فضای جدید ممکن است توسط کاربر مشخص شود

اگر توسط کاربر مشخص شود،


$$\frac{\sum_{i=1}^d \lambda_i}{\sum_{i=1}^p \lambda_i} \geq 0.95$$

d را از طریق فرمول متناهی بیت می‌گیریم

یعنی ۹۵ درصد از خصوصیات داده اصلی حفظ شود

حالت D مجبوری  
↓  
را در رابطه با فرمول دترمینان  
E vector طابقت آورده






در ماتریس  $Y$  به عبارتی  $Y_{n \times d} = X_{n \times d} \times W_{D \times d}$

نکته: بردارهای ویژه باید مرتباً بچینند (به عبارتی با هم رابسته ندارد و Correlation آن صاف است)

Data

1	1
2	2
3	2
4	4
5	5
6	6
7	7
8	8
9	9
10	10

برای آن صورت  
حل می‌کنیم



$$\text{Cov}(x_1, x_2) = \frac{\sum_{i=1}^n (x_{1i} - \mu_1)(x_{2i} - \mu_2)}{n} = \frac{1 + 1 + 0 + 1 + 1}{5} = 2$$

$$C = \begin{bmatrix} 2 & 2 \\ 2 & 2 \end{bmatrix}, C \times E = \lambda \times E \rightarrow \begin{bmatrix} 2 & 2 \\ 2 & 2 \end{bmatrix} \begin{bmatrix} E_1 \\ E_2 \end{bmatrix} = \lambda \begin{bmatrix} E_1 \\ E_2 \end{bmatrix}$$


$$\rightarrow \begin{matrix} 2E_1 + 2E_2 = \lambda E_1 \\ 2E_1 + 2E_2 = \lambda E_2 \end{matrix} \Rightarrow E_2 = \begin{bmatrix} 1 \\ 1 \end{bmatrix}, E_1 = E_2 \rightarrow \text{طول } E \text{ باید برابر باشد}$$

$$(2 - \lambda)E_1 - \lambda E_2 = 0 \rightarrow \lambda = 2, 0 \quad \begin{vmatrix} \lambda - 2 & 2 \\ 2 & \lambda - 2 \end{vmatrix} = 0$$

$$E = \begin{bmatrix} \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \end{bmatrix}$$

$$Y = X \times W, W = \begin{bmatrix} \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \end{bmatrix} \rightarrow Y = \begin{bmatrix} 1 & 1 \\ 2 & 2 \\ 3 & 2 \\ 4 & 4 \\ 5 & 5 \end{bmatrix} \times \begin{bmatrix} \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \end{bmatrix} = \begin{bmatrix} \frac{2}{\sqrt{2}} \\ \frac{4}{\sqrt{2}} \\ \frac{5}{\sqrt{2}} \\ \frac{8}{\sqrt{2}} \\ \frac{10}{\sqrt{2}} \end{bmatrix}$$





روش دسته بندی درخت تصمیم :

دریخت برای طبقه بندی ها Decision Tree  
 و رگرسیون Regression Tree

- تعدادی از ویژگی ها
- بزرگ جادای بزرگ کلاس
- گروه های بیانی دارای بزرگ و بزرگی هستند
- روی هر حال، بازه یا مقدار ویژگی گروه بالای (بزرگ) نوشته می شود.

دو مسأله مهم در ساخت درخت :

۱- مناسبترین ویژگی برای هر گره کدام است ؟

۲- شرط پایان ؟

- تمام نمونه های یک بزرگ متعلق به یک کلاس باشند
- به حد اکثر عمق درخت رسیده باشیم
- تعداد نمونه های گره از یک حد قابل تعداد کمتر باشد

معیارهای انتخاب صفات :

Information Gain  $IG(A) = Entropy(D) - Entropy_A(D)$

برای ویژگی A مقدار فنون را محاسبه کنیم ،

D - داده های آموزشی است :

$$Entropy(D) = - \sum_{i=1}^C (P_i \times \log_2 P_i)$$

$$Entropy_A(D) = \sum_{j=1}^V \frac{|D_j|}{|D|} \times Entropy(D_j)$$

C : تعداد بزرگ کلاس ها

$P_i$  : احتمال اینکه نمونه متعلق به کلاس i باشد

V : تعداد اعضای دانه ویژگی A

$D_j$  : قسمتی از داده های اولیه که مقدار ویژگی آن ها j است

|D| :

اندازه داده های D



ID	Age	income	job	computer
1	old	M	st	No
2	middle	H	T	No
3	old	L	T	No
4	young	M	T	Yes
5	young	L	T	Yes
6	old	M	S	Yes
7	middle	M	S	Yes
8	young	H	T	No
9	old	H	S	No
10	middle	H	S	No

$$\text{Entropy}(D) = \dots$$

$$-\frac{4}{11} \times \log_2 \frac{4}{11} - \frac{7}{11} \times \log_2 \frac{7}{11} = 0.91$$

$$\begin{aligned} \text{Entropy}(D)_{\text{Age}} &= \left( \frac{4}{11} \times \left( -\frac{4}{4} \log_2 \frac{4}{4} - \frac{0}{0} \log_2 \frac{0}{0} \right) \right) \\ &+ \left( \frac{7}{11} \times \left( -\frac{3}{7} \log_2 \frac{3}{7} - \frac{4}{7} \log_2 \frac{4}{7} \right) \right) \\ &+ \left( \frac{0}{11} \times \left( -\frac{0}{0} \log_2 \frac{0}{0} - \frac{0}{0} \log_2 \frac{0}{0} \right) \right) \\ &= 0.1870 \end{aligned}$$

$$\text{Entropy}(D)_{\text{income}} = 0.24$$

$$\text{Entropy}(D)_{\text{job}} = 0.91$$

$$\Rightarrow IG(\text{Age}) = 0.1870$$

$$IG(\text{income}) = 0.1996$$

$$IG(\text{job}) = 0$$

موضوع پردگی : راه حل های کوتاه کردن امتناع درخت تصمیم

$$\text{ک: Entropy}(\text{قسم کلاس}) = -1 \log_2 1 - 0 \log_2 0 = 0$$

$$\text{.. } \left( \begin{matrix} \text{بف} \\ \text{ر} \end{matrix} \right) = -\frac{1}{2} \log_2 \frac{1}{2} - \frac{1}{2} \log_2 \frac{1}{2} = 1$$



- معیارهای انتخاب دینری در تیره دقت تصمیم (ارائه)

Information Gain - ۱ ✓

Gini Index - ۲ ←

Gain Ratio - ۲ ←

- Likelihood Ratio (به عنوان بهترین مطالعه شود)

①  $Gini(D) = 1 - \sum_{i=1}^C P_i^2$

C: تعداد کلاس‌ها  
 $P_i$ : احتمال تعلق داده‌ها به کلاس‌ها

$$Gini_A(D) = \frac{|D_L|}{|D|} * Gini(D_L) + \frac{|D_R|}{|D|} * Gini(D_R)$$



ارزندی A داده‌ها را به دو سطح تقسیم کند

$$Gini(A) = Gini(D) - Gini_A(D)$$

هر دینری که مقدار Gini بزرگ‌تری داشته باشد انتخاب شود

$$Gain Ratio_A(D) = \frac{Information Gain(A)}{Split Info(A)}$$

$$Split Info(A) = - \sum_{j=1}^V \frac{|D_j|}{|D|} \log \frac{|D_j|}{|D|}$$

① در فرمول ۱، اگر خالص تعلق به یک کلاس باشد ← به صفر میل می‌کند. اگر نباشد، یعنی بی‌نظمی داشته باشیم، از صفر بیشتری شود.



# Support Vector Machine (SVM) -

# ماشین بردار پشتیبان



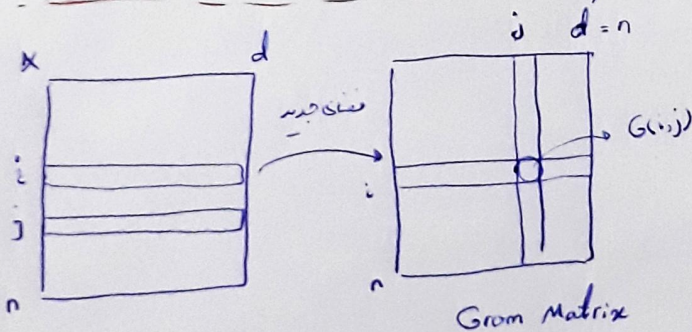
پایه این روش برای دسته بندی دو کلاس است.

+ کلاس  
\* کلاس

نکته: خطی را انتخاب می کنیم که بیشترین حاشیه (margin) را ایجاد کند.

تمرین: یک مقاله (یادوتا) مراجعه به موضوعاتی که تا امروز تدریس شد برای هفته آینده (۸، ۸، ۱۴) آماده شود.

موضوع پژوهش: استفاده از SVM برای تایز Node های Decision Tree



نکات مربوط به توابع Kernel:

$$G_{(i,j)} = \text{kernel}(\vec{X}_i, \vec{X}_j)$$

$$\text{kernel} \begin{cases} \text{Linear} \rightarrow \vec{X}_i \cdot \vec{X}_j = |\vec{X}_i| \times |\vec{X}_j| \times \cos(\theta) \\ \text{Polynomial} \rightarrow (X_i^T \cdot X_j + C)^d \\ \text{RBF} \rightarrow \frac{e^{-\frac{\|X_i - X_j\|^2}{2\sigma^2}}}{e} \end{cases}$$

شماره بین نمونه‌های داده


داده‌ها صرف برای تفاوت داده می شوند

اختلاف و شمار بین نمونه‌ها را به صورت نمای نشان می دهد



# Random Forest:


۱۴.۱.۱۷




Train 80%  
Test 20%

تکسیری دسته‌بند  
ابتدا آموزش داده‌ی شوند  
پس ضربی آن‌ها به نوبت با هم دستخوردگی شوند  
تا داده‌ی تست برپیکر گزای شود  
Combination of classifiers

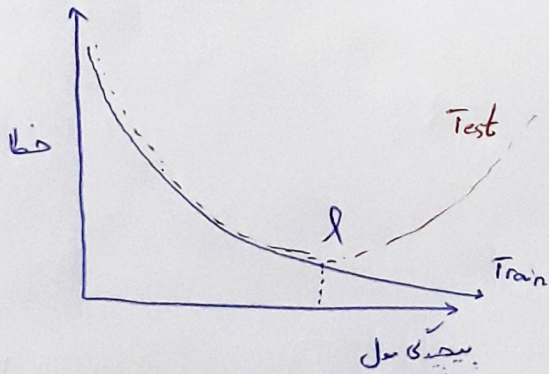
نکته:  $\therefore$  overfitting



چند جمله‌ای درجه ۱۰  
دقت Train ۱۰۰٪  
دقت تست <



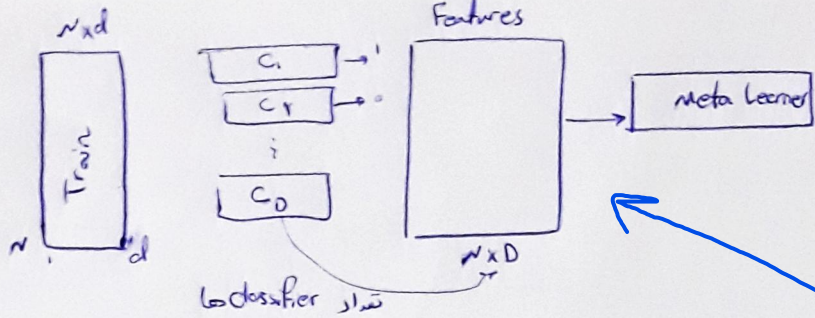
چند جمله‌ای درجه ۲  
دقت Train 80%  
دقت تست >



پیچیدگی مدل از یک نقطه به بالاتر برود  
می‌شود مدل روی داده‌های Train اصطلاحاً  
fit شود و قابلیت تعمیم (generalization)  
روی داده‌های تست کم شود.

برای بالا بردن قابلیت تعمیم درختان، ۲ کار انجام می‌شود؛ اصطلاحاً داده‌ها را در یک سری Bag (کیسه) قرار  
می‌دهیم. به تعداد درختان این Bag ها را تولید می‌کنیم. ① به صورت تصادفی (مثلاً ۷۰٪) داده‌های Train را به  
۵۰ تا ۵۵ درصدی در این عمل مجدد برای tree های دیگر تکرار شود. ② علاوه بر آن، (مثلاً) ۴.۱ feature ها را در این  
Bag ها دستخوردگی می‌گیریم و باقی ۱.۱ به صورت تصادفی حذف شود.





روش های تقسیم گری برای :

- ۱- رای گیری
- ۲- تریب میانین وزن دهی شده
- ۳- boosting
- ۴- bagging
- ۵- stacking


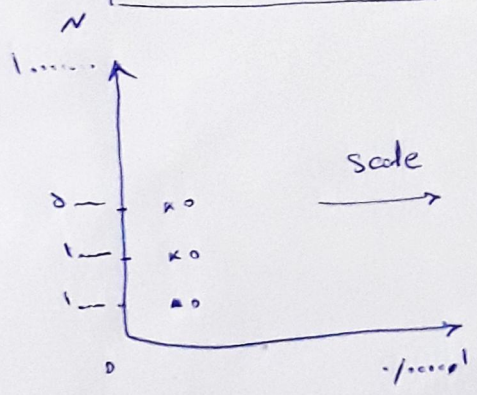
train each model on X% of data then averages the predictions

مجموعه ویژگی‌ها متنوع باشند X

۱۲	۷۹	۱	۸۵
۸	۱۸۰	۲	۹۰
۹	۲۰۰	۱	۶۴
۱۱	۵۰	۸	۵۷
⋮	⋮	⋮	⋮

تربیت بیشتر

با توجه به اینکه بازه عددی مقادیر Features های مختلف در بازه یکسان قرار ندارند، در نتیجه دسته بندی در نظام مثل سازی اجرا، کار بیخود و بی‌فایده می‌شود و بعضاً ممکن است خطا ایجاد کند.



روش Linear :

$$x' = \frac{x - \min}{\max - \min}$$

روش کوسینوس :

$$x' = \frac{x - \mu}{\delta}$$

۱۴۰۱/۰۸/۲۹ امتحان میان ترم

۱۴۰۱/۰۸/۲۲ ←

۱۴۰۱/۰۹/۰۶ مقاله انتخاب شده ارائه شود

لگت در رابطه با SVM ، استفاده از دسته بندی برای سائل چندکلاسه (مانند SVM)   
 ① اگر برای کلاس ۲ ، کلاس های ۳ ، ۲ ، ۱ داشته باشیم چه کار کنیم ؟ می‌توانیم به تعداد  $\frac{m(m-1)}{2}$  SVM جداگانه برای   
 سائل های مختلف درست کنیم . نهایتاً در فاز تست رأی گیری می‌کنیم . (مثل one to one)   
 $SVM_{1,2}$    
 $SVM_{1,3}$    
 $\vdots$    
 $SVM_{1,m}$




مل one to other : کلاس اول را به کلاس دومی کلاس ها حتماً یک کلاس


- 1 → 1 ۲, ۳, ..., m SVM<sub>1</sub>
- 2 → 2 ۱, ۳, ..., m SVM<sub>2</sub>
- ...
- m → m ۱, ۲, ..., m-1 SVM<sub>m</sub>

یک راه این است که از stacking در فاز Train استفاده کنیم و در نهایت یک Metalearner بیادده شود. هر چند این روش احتمالاً خوب نیست، چون بایاس را در استفاده از نتایج دسته بندی لایه می بریم.

شده عصبی :



سلول های عصبی (نورون ها) } عصبی حرکتی



مل می سبای نورون :



پرستیزون

$$\text{if } \sum_{i=1}^d x_i w_i > \theta \xrightarrow{\text{fire}} \text{output} = +1 \text{ else output} = 0$$

↓  
threshold

∴  $x_0 = 1$


مثال : در سانه دسته بندی نیز الراج پرستیزون استفاده کنیم، لولیک معادله خط ایجاد کرده ایم :



$$\sum_{i=1}^d x_i w_i = x_1 w_1 + x_2 w_2 + b_0 > 0$$



نکته: ممکن است نتوانیم به صورت خطی ساده را جدا کنیم. در این حالت باید از MLP (Multi-Layer Perceptron) استفاده کنیم.



نکته: در تابع انتقال، می توانیم بجای آنکه فرمی  $\sum$  فقط 0 یا 1 باشد، خود مقدار  $\sum$  را برتبه در تابع دیگری نگاشت کنیم. مثلاً:

