

## یادگیری ماشین (۰۱-۸۰۵-۱۱-۱۳) بخش سوم




دانشگاه شهید بهشتی  
پژوهشکده‌ی فضای مجازی  
پاییز ۱۳۹۶  
احمد محمودی ازناوه

# فهرست مطالب


## • یادگیری بیزی

- معیارهای تصمیم‌گیری
- قوانین تداعی (وابستگی)



# احتمال و استنتاج

- داده‌هایی که مورد استفاده قرار می‌دهیم، حاصل فرآیندی است که کاملاً شناخته شده نیست.
- در پدیده‌های تصادفی، متغیرهای غیرقابل مشاهده، موجب پیدایش عدم قطعیت می‌شود.
- $x=f(z)$
- با توجه به این که چنین فرآیندهایی بدین شیوه قابل مدل کردن نیستند، فروجی را به صورت یک متغیر تصادفی تعریف می‌کنیم:
- $P(X=x)$
- بر اساس نمونه‌های ورودی می‌توان این توزیع را تخمین زد، به عنوان مثال برای سکه



$$p_o = \# \{Heads\} / \# \{Tosses\} = \sum_t x^t / N$$

• مسأله‌ی دسته‌بندی اعتبار مشتریان:

– ورودی: درآمد و پس‌انداز

– خروجی: مشتری High risk و low risk

– Input:  $\mathbf{x} = [x_1, x_2]^T$ , Output:  $C \in \{0, 1\}$

– پیش‌بینی:


– high risk ( $C=1$ ) or low risk ( $C=0$ )

choose  $\begin{cases} C = 1 \text{ if } P(C = 1 | x_1, x_2) > 0.5 \\ C = 0 \text{ otherwise} \end{cases}$

or

choose  $\begin{cases} C = 1 \text{ if } P(C = 1 | x_1, x_2) > P(C = 0 | x_1, x_2) \\ C = 0 \text{ otherwise} \end{cases}$

امتثال شرطی



# دسته‌بندی (ادامه...)

- با فرض این ورودی  $x$ ، متخیر مشاهده شده است، مسأله یافتن احتمال  $P(C|x)$  است.

## Bayes' Rule

posterior

احتمال پسین

با چه احتمالی  $C$ ، کلاس مربوط به  $x$  است.

احتمال پیشین

prior

درست‌نمایی کلاس

Class likelihood


با چه احتمالی  $x$  توسط کلاس  $C$  تولید می‌شود.

$$P(C | \mathbf{x}) = \frac{P(C) p(\mathbf{x} | C)}{p(\mathbf{x})}$$


evidence

$$P(C = 0) + P(C = 1) = 1$$

$$p(\mathbf{x}) = p(\mathbf{x} | C = 1)P(C = 1) + p(\mathbf{x} | C = 0)P(C = 0)$$




# دسته‌بندی (ادامه...)



*pattern recognition using neural networks theory and algorithms for engineers and scientists, by Carl G. Looney*

$$P(C | \mathbf{x}) = \frac{P(C) p(\mathbf{x} | C)}{p(\mathbf{x})}$$



# دسته بندی چندکلاسی


امتمال رخداد  $x$  هنگامی که می دانیم به  
کلاس  $C_i$  تعلق دارد  
*Class likelihood*

$$P(C_i | \mathbf{x}) = \frac{P(C_i) p(\mathbf{x} | C_i)}{p(\mathbf{x})}$$

$$P(C_i | \mathbf{x}) = \frac{P(C_i) p(\mathbf{x} | C_i)}{p(\mathbf{x})} = \frac{P(C_i) p(\mathbf{x} | C_i)}{\sum_{k=1}^K P(C_k) p(\mathbf{x} | C_k)}$$

$$P(C_i | \mathbf{x}) = \max_k P(C_k | \mathbf{x})$$

در این صورت کلاس  $C_i$  انتخاب می شود.




# Losses and Risks

- در برخی موارد، تصمیم‌ها پی‌آمد یکسانی ندارند.  
– «کنش  $\alpha_i$ » به عنوان انتخاب کلاس  $C_i$  تعریف شده است.
- $\lambda_{ik}$  به عنوان میزان ریسک انتخاب کلاس  $i$  در زمانی که ورودی به این کلاس  $k$  تعلق دارد.
- در این صورت، **expected risk** به صورت زیر محاسبه می‌شود:

$$R(\alpha_i | \mathbf{x}) = \sum_{k=1}^K \lambda_{ik} P(C_k | \mathbf{x})$$

$$\text{choose } \alpha_i \text{ if } R(\alpha_i | \mathbf{x}) = \min_k R(\alpha_k | \mathbf{x})$$






# بررسی 0/1 Loss

$$\lambda_{ik} = \begin{cases} 0 & \text{if } i = k \\ 1 & \text{if } i \neq k \end{cases}$$

$$\begin{aligned} R(\alpha_i | \mathbf{x}) &= \sum_{k=1}^K \lambda_{ik} P(C_k | \mathbf{x}) \\ &= \sum_{k \neq i} P(C_k | \mathbf{x}) \\ &= 1 - P(C_i | \mathbf{x}) \end{aligned}$$

برای داشتن کم‌ترین ریسک **متمثل‌ترین** حالت  
را انتخاب می‌کنیم




# هزینه‌ی بالای انتخاب اشتباه

- در برخی کاربردها، انتخاب اشتباه کلاس هزینه‌ی بالایی دارد، به نحوی که بهتر است هیچ انتخابی توسط سیستم خودکار صورت نپذیرد. در این حالت نمونه به عنوان «مشکوک» تلقی شده و «رد» می‌شود.

– «کنش» جدیدی تعریف می‌شود: رد (reject) :  $\alpha_{k+1}$

*choose  $C_i$  if  $R(\alpha_i|\mathbf{x}) < R(\alpha_k|\mathbf{x}) \quad \forall k \neq i$  and*  
 *$R(\alpha_i|\mathbf{x}) < R(\alpha_{k+1}|\mathbf{x})$*

*reject  $R(\alpha_{k+1}|\mathbf{x}) < R(\alpha_i|\mathbf{x}) \quad i = 1, 2, \dots, k$*



# هزینه‌ی بالای انتخاب اشتباه (ادامه...)

- به عنوان مثال تابع ریسک به صورت زیر تعریف می‌شود:


$$\lambda_{ik} = \begin{cases} 0 & \text{if } i = k \\ \lambda & \text{if } i = K + 1, \quad 0 < \lambda < 1 \\ 1 & \text{otherwise} \end{cases}$$

$$R(\alpha_{K+1} | \mathbf{x}) = \sum_{k=1}^K \lambda P(C_k | \mathbf{x}) = \lambda$$

$$R(\alpha_i | \mathbf{x}) = \sum_{k \neq i} P(C_k | \mathbf{x}) = 1 - P(C_i | \mathbf{x})$$

choose  $C_i$  if  $P(C_i | \mathbf{x}) > P(C_k | \mathbf{x}) \quad \forall k \neq i$  and  $P(C_i | \mathbf{x}) > 1 - \lambda$

reject otherwise



# Discriminant Functions

choose  $C_i$  if  $g_i(\mathbf{x}) = \max_k g_k(\mathbf{x})$


$$g_i(\mathbf{x}) = \begin{cases} -R(\alpha_i | \mathbf{x}) \\ P(C_i | \mathbf{x}) \\ p(\mathbf{x} | C_i)P(C_i) \end{cases}$$

$K$  decision regions  $\mathcal{R}_1, \dots, \mathcal{R}_K$

$$\mathcal{R}_i = \{\mathbf{x} | g_i(\mathbf{x}) = \max_k g_k(\mathbf{x})\}$$

# توابع جداساز


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



# Dichotomizer


$$g(x) = g_1(x) - g_2(x)$$

choose  $\begin{cases} C_1 & \text{if } g(\mathbf{x}) > 0 \\ C_2 & \text{otherwise} \end{cases}$




# بررسی حالات مختلف


Equal losses



Unequal losses



With reject



- احتمال این که با در اختیار داشتن ورودی  $x$ ، در حالت  $S_k$  باشیم:  $P(S_k | x)$
- سودمندی کنش  $\alpha_i$  وقتی در حالت  $k$ ام هستیم:

$$- U_{ik}$$

$$EU(\alpha_i | \mathbf{x}) = \sum_k U_{ik} P(S_k | \mathbf{x})$$

Choose  $\alpha_i$  if  $EU(\alpha_i | \mathbf{x}) = \max_j EU(\alpha_j | \mathbf{x})$

Expected utility



- «قانون تداعی» (قانون وابستگی) الگوهایی را که بر اساس آن یک رویداد به دیگری مربوط می‌شود، جستجو می‌کند، به عنوان مثال وابستگی خرید قلم به خرید کاغذ.


– یک روش مناسب برای یافتن روابط بین متغیرهای موجود در مجموعه داده‌های بزرگ است.

Association rule:  $X \rightarrow Y$

مقدمه

antecedent

consequent تالی




# معیارهای وابستگی - پشتیبان

- Support ( $X \rightarrow Y$ ):

$$P(X, Y) = \frac{\#\{\text{customers who bought } X \text{ and } Y\}}{\#\{\text{customers}\}}$$

- در صورتی وابستگی  $X \rightarrow Y$  اهمیت خواهد داشت، که نسبت تراکنش‌های  $X$  و  $Y$  به مجموعه‌ی کل تراکنش‌ها مقدار قابل قبولی باشد.
- معیار «پشتیبان» اهمیت آماری قانون مورد نظر را نشان می‌دهد.





# معیارهای وابستگی - اطمینان


- Confidence ( $X \rightarrow Y$ ):

$$P(Y | X) = \frac{P(X, Y)}{P(X)}$$

$$= \frac{\#\{\text{customers who bought } X \text{ and } Y\}}{\#\{\text{customers who bought } X\}}$$

- این معیار طبیعی‌ترین چیزی است که محاسبه می‌شود، در واقع بیانگر این است که تا چه مدی قانون قابل اطمینان است. به بیان دیگر «قدرت» قانون را نشان می‌دهد.

- برای «اطمینان» کافی، باید این معیار به یک نزدیک بوده و مقدار آن تا حد قابل قبولی از  $P(Y)$  بیشتر باشد.



# معیارهای وابستگی - lift

- Lift/interest ( $X \rightarrow Y$ ):

$$= \frac{P(X, Y)}{P(X)P(Y)} = \frac{P(Y | X)}{P(Y)}$$

– Lift=1

–  $X$  و  $Y$  مستقل هستند.

– Lift>1


–  $X$  موجب افزایش رخداد  $Y$  می‌شود.

– Lift<1

–  $X$  احتمال بروز  $Y$  را کاهش می‌دهد.

این روابط به راحتی قابل تعمیم به بیش از دو آیتم (itemset) است.

$$(X, Z \rightarrow Y): P(Y|X, Z)$$



# مثال

Transaction	Items in basket
1	milk, bananas, chocolate
2	milk, chocolate
3	milk, bananas
4	chocolate
5	chocolate
6	milk, chocolate


SOLUTION:

milk  $\rightarrow$  bananas : Support = 2/6, Confidence = 2/4

bananas  $\rightarrow$  milk : Support = 2/6, Confidence = 2/2

milk  $\rightarrow$  chocolate : Support = 3/6, Confidence = 3/4

chocolate  $\rightarrow$  milk : Support = 3/6, Confidence = 3/5



- این الگوریتم در دو مرحله انجام می‌پذیرد:
  - یافتن itemset های مکرر (frequent) (آن‌هایی که معیار پشتیبان بالایی دارند).
  - در صورتی که  $(X, Y, Z)$  دارای میزان پشتیبان بالایی باشند،  $(X, Y)$ ،  $(X, Z)$  و  $(Y, Z)$  هم باید دارای پشتیبان بالایی باشند.

## Anti-monotone property

- اگر یک itemset، مکرر نباشد، هیچ‌کدام از supersets آن مکرر نخواهند بود.
- یافتن قانون وابستگی بین itemset های یافت شده
  - تقسیم آیتم‌ها به دو دسته‌ی تالی و مقدمه

