

رگرسیون


گروه دایکه . dayche.com



معرفی مسئله رگرسیون

رگرسیون خطی تک متغیره □

○ ارتباط بین داده های خروجی و داده های ورودی توسط یک مدل خطی قابل توصیف است.



$y(x) = wx + w_0$
Single parameter linear regression

inputs	outputs
$x_1 = 1$	$y_1 = 1$
$x_2 = 3$	$y_2 = 2.2$
$x_3 = 2$	$y_3 = 2$
$x_4 = 1.5$	$y_4 = 1.9$
$x_5 = 4$	$y_5 = 3.1$

○ هدف تعیین پارامترهای مدل بر اساس داده های در دسترس است.

رگرسیون خطی - تک متغیره

□ مدل رگرسیون خطی برای مسئله عنوان شده به شکل ساده یک خط به صورت زیر قابل توصیف است:

$$\underbrace{\{x_i, y_i\}_i}_{\text{Given dataset}} \longrightarrow y_i(x) = WX_i + n_i, W = [w \quad w_0], X_i = \begin{bmatrix} x_i \\ 1 \end{bmatrix}$$

○ که در آن n_i یک فرآیند سفید گوسی مستقل با میانگین 0 و واریانس نامعلوم است.

□ مسئله:

○ برای چه مقداری از بردار وزن های W احتمال رخداد زوج داده های $\{x_i, y_i\}_i$ بیشینه است؟

$$W^* = \arg \max \prod_{i=1}^N P(y_i | x_i, W)$$

رگرسیون خطی - تک متغیره

□ توزیع شرطی داده های خروجی به شرط داده های ورودی و بردار وزن ها یک توزیع نرمال است. (چرا؟)

$$\prod_{i=1}^N P(y_i | x_i, W) = \prod_{i=1}^N \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(y - WX_i)^2}{2\sigma^2}\right)$$

○ به منظور تاثیر تمام نقاط داده شده، negative-log تابع فوق کمینه می شود. (چرا؟)

○ مسئله بهینه سازی جدید دارای پاسخ یکسان با مسئله اصلی است. (چرا؟)

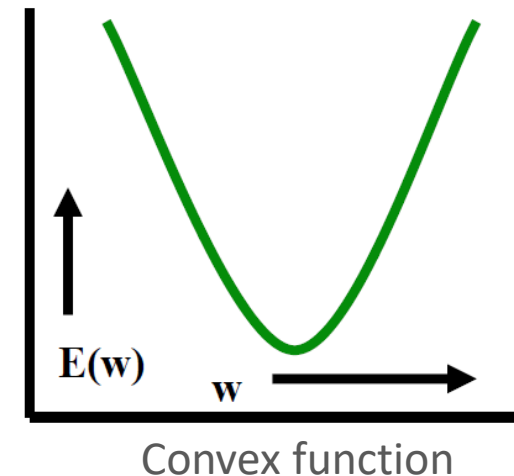
$$W^* = \arg \min -\log \prod_{i=1}^N P(y_i | x_i, W) \quad \longrightarrow \quad W^* = \operatorname{argmin} \sum_{i=1}^N (y - WX_i)^2$$

Least square problem ← Sum Squared Error (SSE)

رگرسیون خطی - تک متغیره

□ بردار پارامترهایی که رخداد داده های خروجی به شرط داده های ورودی را بیشینه می کند پاسخ مسئله بهینه سازی حداقل مربعات است.

$$W^* = \operatorname{argmin} \sum_{i=1}^N (y - WX_i)^2 \longrightarrow W^* = \frac{\sum_{i=1}^N y_i X_i}{\sum_{i=1}^N |X_i|^2}$$




□ آیا می توان واریانس نویز را تخمین زد؟


رگرسیون خطی - مثال

□ داده ها توسط یک خط با شیب 2 و عرض از مبدا 0 تولید شده اند

$W^* = 2.03, \quad \sigma = 1$



$W^* = 2.1, \quad \sigma = 8$



رگرسیون خطی - چند متغیره



□ رابطه بیان شده برای رگرسیون خطی تک متغیره، به صورت زیر قابلیت تعمیم دهی به حالت چند متغیره را داراست.

$$y(x) = w_0 + w_1x_1 + w_2x_2 + \dots + w_Dx_D$$

□ پارامترهای مدل در این حالت مشابه حالت اسکالر تخمین زده میشوند:

$$Y = XW + n, Y = \begin{bmatrix} y_1(x) \\ \vdots \\ y_n(x) \end{bmatrix}_{n \times 1}, X = \begin{bmatrix} 1 \\ x_1 \\ \vdots \\ x_D \end{bmatrix}_{n \times (D+1)}^T, W = \begin{bmatrix} w_0 \\ \vdots \\ w_D \end{bmatrix}_{(D+1) \times 1}$$

$$W^* = (X^T X)^{-1} X^T Y$$

رگرسیون خطی با نویز متغیر



□ اگر نویز خروجی اضافه شده دارای مشخصات آماری متغیر با زمان باشد، مدل رگرسیون خطی توسعه داده شده دارای بایاس است. (چرا؟)

○ برای مسئله تک متغیره


$$W^* = \operatorname{argmin} \sum_{i=1}^N \frac{(y - WX_i)^2}{\sigma^2} \quad \longrightarrow \quad W^* = \operatorname{argmin} \sum_{i=1}^N \frac{(y - WX_i)^2}{\sigma_i^2}$$

Weighted Least Square (WLS) ← Weighted Sum square error

$$W^* = \frac{\sum_{i=1}^N \frac{y_i X_i}{\sigma_i}}{\sum_{i=1}^N \frac{|X_i|^2}{\sigma_i}} \quad \text{For Gaussian colored noise}$$

رگرسیون خطی با نویز متغیر

هر نمونه متناسب با نویزی که می گیرد وزن دهی می شود. □




$$W^* = (X^T Q^{-1} X)^{-1} X^T Q^{-1} Y, \quad Q^{-1} = \begin{pmatrix} 1 & \dots & 0 \\ \sigma_1 & & \\ \vdots & \ddots & \vdots \\ 0 & \dots & 1/\sigma_n^2 \end{pmatrix}$$

For multivariate case

رگرسیون غیرخطی

x_i	y_i
1/2	1/2
1	2.5
2	3
3	2
3	3



داده های زیر را در نظر بگیرید: □

$$y_i(x_i) = \sqrt{w + x_i} + n_i$$

$$w^* = \arg \min \sum_{i=1}^N (y_i - \sqrt{w + x_i})^2$$

For white Gaussian noise

حل بسته ریاضی برای مسئله فوق وجود ندارد. (چرا؟) راه حل چیست؟ □

Numerical Optimization ←



□ در بسیاری از موارد تابع هزینه بدست آمده برای مسئله رگرسیون غیرخطی محدب نیست.
(با فرض شناخته بودن ارتباط ورودی و خروجی)

□ **نگاشت فضای ورودی**

- ارتباط بین ورودی و خروجی در فضای داده های در دسترس خطی نیست.
- فضای ورودی داده ها را به فضایی نگاشت می دهیم تا ارتباط بین ورودی و خروجی خطی شود (یا با خط قابل تقریب باشد)

$$y(x) = w_0 + w_1\phi_1(x_1) + w_2\phi(x_2) + \dots + w_D\phi(x_D)$$



نگاشت فضای ورودی

$$y(x) = w_0 + w_1\phi_1(x_1) + w_2\phi(x_2) + \dots + w_D\phi(x_D)$$

- کلیه مطالب ذکر شده بر اساس فضای ورودی قابل تعمیم دهی به فضای جدید هستند.

نگاشت های رایج

- چند جمله ای
- توابع شعاعی پایه
- تبدیلات مختلف بر روی فضای ورودی (تبدیل فوریه، تبدیل موجک، و ...)

□ رابطه بین ورودی و خروجی توسط یک چند جمله ای مشخص می شود

○ مدل رگرسیون چندجمله ای درجه 2 برای یک متغیر

$$y(x) = w_0 + w_1x + w_2x^2 + w_3x^3 + \dots + w_nx^n$$

□ برای حالت چند متغیر مدل چند جمله ای از بسط نیوتن محاسبه می شود

○ مدل رگرسیون چندجمله ای درجه 2 برای دو متغیر



$$y(x) = w_0 + w_1x_1 + w_2x_2 + w_3x_1^2 + w_4x_2^2 + w_5x_1x_2$$

○ آیا می توان از مدل های فوق برای رگرسیون خطی استفاده کرد؟

توابع پایه شعاعی

این توابع عمدتاً برای سنجش فاصله مورد استفاده قرار می‌گیرند. بنابراین مدل بدست آمده بر اساس فاصله نقاط فضای ورودی از مرکز این توابع است.

$$y(x) = 2\phi_1(x) + 0.05\phi_2(x) + 0.5\phi_3(x)$$

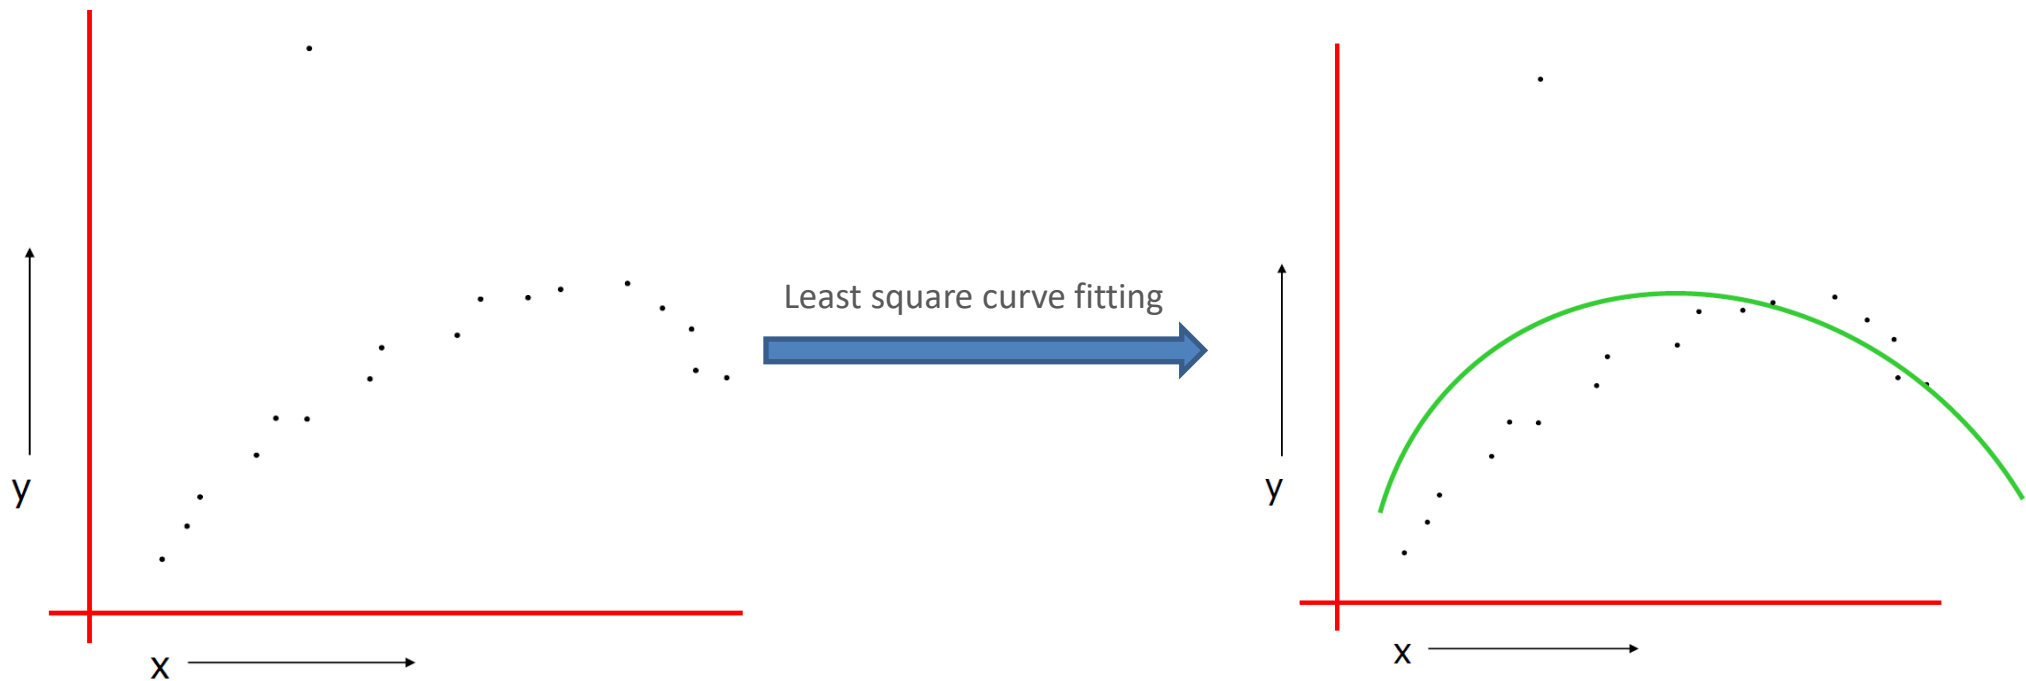


پارامترهای کرنل چگونه تعیین می‌شوند؟

در فضای n بعدی توصیف این توابع به چه شکل است؟




□ وجود داده های پرت چه تاثیری بر مدل خواهند داشت؟






- مدل سازی رگرسیون بر اساس فرض نرمال بودن نویز انجام شده است که نسبت به داده های پرت حساسیت بالایی دارد.
- یک راه حل استفاده از توزیع های long tail است.



LS for Laplacian noise





□ مشکلی که فرض نرمال بودن نویز ایجاد می کند، هم ارز کردن تابع بیشینه شباهت با تابع هزینه حداقل مربعات است.

○ در صورتی که داده پرت وجود داشته باشد، مربع فاصله این داده تا منحنی برازش شده باعث افزایش تابع هزینه خواهد شد.


○ یک راه حل استفاده از تابع هزینه Huber است.

○ حل این مسئله سریعتر از فرض توزیع لاپلاس برای نویز است

$$L_H(r, \delta) = \begin{cases} \frac{r^2}{2}, & |r| \leq \delta \\ \delta|r| - \frac{\delta^2}{2}, & |r| > \delta \end{cases}$$

□ رویکرد ساده دیگری نیز وجود دارد که نیازی به تغییر تابع هزینه و یا فرضیات مسئله ندارد.

○ استفاده از کرنل برای وزن دهی بردار خطا



$$\alpha_k = \exp(-(y_k - y_{est})^2)$$

□ الگوریتم:

○ تخمین حداقل مربعات بر اساس داده های موجود

○ تعیین بردار تخمین خروجی y_{est} بر اساس مدل آموزش دیده شده

○ تشکیل بردار وزن بر اساس بردار تخمین زده شده α_k

○ تکرار مرحله 1 با بردار خروجی $\alpha_k y_k$

بیش برآزشی در مدل رگرسیون



□ همانطور که گفته شد، برای یک مدل رگرسیون بردار پارامترها به نحوی تعیین می شود تا احتمال تولید دنباله ورودی و خروجی بر اساس داده های داده شده پیشینه شود.

تکرار آزمایش	پیشامد
1	رو
2	رو
.	.
.	.
.	.
100	رو



○ مسئله پرتاب سکه را در نظر بگیرید:

○ اگر سکه را برای بار 101 ام پرتاب کنیم، بر اساس مشاهدات بدست آمده چه پیشامدی رخ خواهد داد؟

○ آیا نتیجه آزمایش با دانش پیشین ما از پرتاب سکه همخوانی دارد؟

○ برای جلوگیری از مسئله بیش برآزش، نیاز داریم تا عدم قطعیت ناشی از آزمایش را نیز در مدل سازی دخیل کنیم.

بیش برازشی در مدل رگرسیون




□ در مدل های یادگیری ماشین بیش برازشی به دلایل زیر اتفاق می افتد:


○ تعداد ناکافی داده ها در فاز آموزش مدل

○ پیچیدگی مدل

رگرسیون چند جمله ای با درجه 3



رگرسیون چند جمله ای با درجه 9



از دیدگاه آماری، بیش برازشی یک مدل، هم ارز افزایش واریانس تخمین است

تنظیم کنندگی مدل Regularization



افزودن نویز خروجی

- این اقدام هم ارز لحاظ کردن مقدار عدم قطعیت در برچسب داده هاست.

جمع آوری داده

- داده های حجیم نقش تنظیم کنندگی در مدل را دارند.
- در شرایطی که داده های زیادی در دست باشد، رویکرد بیشینه شباهت قابلیت تعمیم دهی مدل را افزایش می دهد

تنظیم کنندگی مدل Regularization

رویکرد بیزین □

$$y(x) = W^T \phi(x) + n \rightarrow \underbrace{P(y(x)|W)}_{\text{Evidence}}, \underbrace{P(W)}_{\text{Prior}}$$

○ توزیع پارامترها هر توزیع دلخواهی می تواند باشد (بر اساس دانش ما از مسئله تعیین می شود)

$$P(Y, W) = P(Y|W)P(W) \rightarrow W^* = \arg \max \log P(Y, W) \quad \text{Maximum a Posterior}$$

بهترین توزیع پیشین □

○ خانواده توزیع های نمایی

تنظیم کنندگی مدل Regularization



تنظیم کنندگی بر اساس نرم - 2 پارامترها □

$$y(x) = W^T \phi(x) + n \rightarrow P(y(x)|W) \sim N(W^T \phi(x), \sigma^2), P(W) \sim N(\mu, \sigma_w^2)$$

○ اگر میانگین توزیع پیشین را صفر در نظر بگیریم:

$$W^* = \operatorname{argmin} \sum_{i=1}^N (y - WX_i)^2 + \underbrace{\frac{\sigma^2}{\sigma_w^2}}_{\lambda} |W|^2$$

L2 Regularization (Ridge Regression)

○ مسئله فوق را می توان به صورت یک مسئله بهینه سازی مقید بیان کرد (چگونه؟)

○ رابطه بردار وزن ها چگونه محاسبه می شود؟

تنظیم کنندگی مدل Regularization



□ تنظیم کنندگی بر اساس نرم - 1 پارامترها

$$y(x) = W^T \phi(x) + n \rightarrow P(y(x)|W) \sim N(W^T \phi(x), \sigma^2)$$

○ اگر توزیع پیشین پارامترها را یک توزیع لاپلاس با مقدار پارامتر location صفر فرض کنیم:


$$W^* = \operatorname{argmin} \sum_{i=1}^N (y - WX_i)^2 + \lambda |W| \quad \text{L1 Regularization}$$

○ مسئله فوق را می توان به صورت یک مسئله بهینه سازی مقید بیان کرد (چگونه؟)

تنظیم کنندگی - دید هندسی

$$W^* = \operatorname{argmin} \sum_{i=1}^N (y - WX_i)^2$$

کانتورهای سطوح ثابت تابع هزینه (?)



کدام مدل بهتر است؟

از کدام مدل می توان به عنوان مدل انتخاب ویژگی

استفاده کرد؟

حداقل مربعات گام به گام

□ پاسخ مسئله حداقل مربعات چند متغیره به تابع هزینه حداقل مربعات به صورت زیر محاسبه شد:

$$W^* = (X^T X)^{-1} X^T Y$$

□ اگر ابعاد ماتریس X بزرگ باشد، اپراتور معکوس گیری با مشکلات زمانی جدی مواجه خواهد شد. راه حل چیست؟

- الگوریتم های آنلاین آموزش – گرادیان نزولی
- پاسخی که الگوریتم گرادیان نزولی برای مسئله رگرسیون با فرضیات داده شده بدست می دهد یک بهینه سراسری است (چرا؟)