

統計的モデリング基礎③

～重回帰・最大推定～

鹿島久嗣
(情報学科 計算機科学コース)

DEPARTMENT OF INTELLIGENCE SCIENCE
AND TECHNOLOGY

重回帰

重回帰：

複数の独立変数を用いて予測

- (単) 回帰では、ひとつの独立変数から予測を行う

$$g(x) = \beta x + \alpha$$

—例：年齢から年収を予測する

$$(年収) = \beta \times (年齢) + \alpha$$

- 重回帰では複数の (m 個の) 独立変数を用いる

$$g(x) = \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_m x_m + \alpha$$


—例：年齢と身長から年収を予測する

$$(年収) = \beta_{(年齢)} \times (年齢) + \beta_{(身長)} \times (身長) + \alpha$$

重回帰のイメージ：

(超) 平面でデータに当てはめる

- 单回帰では直線で近似、重回帰では (超) 平面で近似



重回帰モデルの推定問題： 最小二乗法によってパラメータを推定する

- 単回帰と同じく、モデルの予測と実際のデータとの食い違いを二乗誤差で測る

$$\begin{aligned}\ell(\alpha, \{\beta_i\}_{i=1}^m) &= \sum_{i=1}^n (y^{(i)} - \hat{y}^{(i)})^2 \\ &= \sum_{i=1}^n \left(y^{(i)} - \left(\beta_1 x_1^{(i)} + \beta_2 x_2^{(i)} + \dots + \beta_m x_m^{(i)} + \alpha \right) \right)^2\end{aligned}$$

- 最適化問題（最小化）を解いてパラメータ推定値を求める：
 $(\hat{\alpha}, \hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_m) = \operatorname{argmin}_{\alpha, \{\beta_i\}_{i=1}^m} \ell(\alpha, \{\beta_i\}_{i=1}^m)$
- すべてのパラメータについて偏微分して0とおき連立方程式を得る

行列とベクトルを用いた表記： 行列とベクトルを用いて書き換えると便利

- モデル : $y = \beta^\top \mathbf{x}$
 - パラメータ : $\beta = (\beta_1, \beta_2, \dots, \beta_m, \alpha)^\top$
 - 独立変数 : $\mathbf{x}^{(i)} = (x_1^{(i)}, x_2^{(i)}, \dots, x_m^{(i)}, 1)^\top$
- 目的関数 :
$$\begin{aligned}\ell(\beta) &= \sum_{i=1}^n (y^{(i)} - \hat{y}^{(i)})^2 \\ &= \sum_{i=1}^n (y^{(i)} - \beta^\top \mathbf{x}^{(i)})^2 = \|\mathbf{y} - \mathbf{X}\beta\|_2^2\end{aligned}$$
 - 計画行列 : $\mathbf{X} = (\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots, \mathbf{x}^{(N)})^\top$
 - 従属変数 : $\mathbf{y} = (y^{(1)}, y^{(2)}, \dots, y^{(N)})^\top$

例 :


家賃予測

- 計画行列 : 4件の賃貸住宅

$$\mathbf{X} = [\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \mathbf{x}^{(3)}, \mathbf{x}^{(4)}]^\top = \left[\begin{pmatrix} 15 \\ 10 \\ 1.0 \end{pmatrix}, \begin{pmatrix} 3 \\ 1 \\ 0.1 \end{pmatrix}, \begin{pmatrix} 35 \\ 5 \\ 7.0 \end{pmatrix}, \begin{pmatrix} 40 \\ 70 \\ 1.0 \end{pmatrix} \right]^\top$$

- 独立変数 (ベクトル) : 4件分の家賃

$$\mathbf{y} = (y^{(1)}, y^{(2)}, y^{(3)}, y^{(4)})^\top = (140, 85, 220, 115)^\top$$



重回帰モデルの解： 解析解が得られる

- 目的関数 : $L(\beta) = \|\mathbf{y} - \mathbf{X}\beta\|_2^2 = (\mathbf{y} - \mathbf{X}\beta)^\top(\mathbf{y} - \mathbf{X}\beta)$
- 解: $\beta^* = \operatorname{argmin}_{\beta} L(\beta) = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{y}$ ただし、本当に（数値的に）解くときには連立方程式のほうを解く
- ただし、解が存在するためには $\mathbf{X}^\top \mathbf{X}$ が正則である必要
 - モデルの次元数 m よりもデータ数 n が大きい場合はおおむね成立
- 正則化 : 正則でない場合には $\mathbf{X}^\top \mathbf{X}$ の対角成分に正の定数 $\lambda > 0$ を加えて正則にする
 - 新たな解: $\beta^* = \operatorname{argmin}_{\beta} L(\beta) = (\mathbf{X}^\top \mathbf{X} + \lambda \mathbf{I})^{-1} \mathbf{X}^\top \mathbf{y}$
 - 目的関数に戻すと : $L(\beta) = \|\mathbf{y} - \mathbf{X}\beta\|_2^2 + \lambda \|\beta\|_2^2$

パラメータのノルムに関する
ペナルティ項

多重共線性：

独立変数間に強い相関がある場合には注意

- 重回帰モデルにおいて、独立変数間に強い相関がある場合には推定されたパラメータの分散が大きくなり、信頼性が下がる
 - どちらでも説明できるので、パラメータの重みを奪い合う
 - 例：年齢と勤続年数など
- 予測には影響しないが、得られたモデル（パラメータ）を解釈したい場合には注意を要する
 - 相関が強い場合には、片方ずつ用いた結果を調べるなどを行う

質的変数の取り扱い

質的変数の扱い： ダミー変数の利用

- 独立変数が質的変数（記号を値としてとる）の場合
 - 例： {右, 左}、{京都, 大阪, 東京}
- ダミー変数：{0,1}の2値をとる変数
 - {右, 左}を{0,1}として表現
 - 3値以上の場合には、選択肢数-1個のダミー変数を用いる：
京都= (1,0)、大阪= (0,1)、東京= (0,0)

- 例：年齢と性別から年収を予測する

$$(年収) = \beta_1 \times (\text{年齢}) + \beta_2 \times (\text{性別}) + \alpha$$

- 性別が男性であるか {0(No), 1(Yes)} のダミー変数

東京をベースラインとして各
地域の差分を示す

従属変数が質的変数の場合：

ダミー変数を従属変数として回帰を適用（が、やや不適）

- 従属変数が質的変数の場合

- 例：年収と年齢から性別を当てる

- 従属変数をダミー変数として回帰を適用する

- 例：(性別) = $\beta_1 \times (\text{年齢}) + \beta_2 \times (\text{年収}) + \alpha$

- 回帰モデルの適用は厳密にはちょっと変

- 回帰モデルは連続値を出力するが、本来、性別にあたるダミー変数は{0,1}のいずれかの値のみをとる

- 最小二乗法が仮定している均一分散性が成立しない

- 「効率性」が満たされないため推定値のバラつきが大きい

非線形回帰

非線形回帰：

線形回帰に非線形性を導入する


- ここまで線形モデルを仮定してきた : $y = \beta^\top \mathbf{x}$
 - パラメータ : $\beta = (\beta_1, \beta_2, \dots, \beta_m, \alpha)^\top$
 - 独立変数 : $\mathbf{x} = (x_1, x_2, \dots, x_m, 1)^\top$
 - シンプルで安定して扱いやすい
- 線形モデルに非線形性を導入するにはどうしたらよいか ?
 1. 変数変換 (例 : $x \rightarrow \log x$)
 2. 交差項 (例 : $x_1, x_2 \rightarrow x_1 x_2$)
 3. カーネル法

変数変換 :

簡単に非線形性を導入する方法

- 独立変数に対して非線形の変換を適用する :

$$x \rightarrow \log x, e^x, x^2, \frac{1}{x}, \dots$$



変数の対数変換：

傾きパラメータ β の意味が異なる

- $y = \beta x + \alpha$ の独立変数 (x) と従属変数 (y) は対数変換して用いられることがある
- 変換と係数の意味

		従属変数	
		y	$\log y$
独立変数	x	$y = \beta x + \alpha$ x が1単位増加すると y が β 単位増加する	$\log y = \beta x + \alpha$ x が1単位増加すると y が $1 + \beta$ 倍になる
	$\log x$	$y = \beta \log x + \alpha$ x を2倍すると y が β 単位増加する	$\log y = \beta \log x + \alpha$ x を2倍すると y が $1 + \beta$ 倍になる

交差項：

変数の組み合わせを導入

- もともとの独立変数 x_1, x_2, \dots, x_m に加えて、2変数の交差項 $\{x_d x_{d'}\}_{d,d'}$ を用いる
 - ダミー変数の交差項は2変数のANDに相当
- すべての交差項を採用すると行列パラメータ \mathbf{B} を導入して $y = \mathbf{x}^\top \mathbf{B}^\top \mathbf{x}$ と書くことができる


$$y = \text{Trace} \left(\begin{bmatrix} \beta_{1,1} & \cdots & \beta_{1,m} \\ \vdots & \ddots & \vdots \\ \beta_{m,1} & \cdots & \beta_{m,m} \end{bmatrix}^\top \begin{bmatrix} x_1^2 & x_1 x_2 & \cdots & x_1 x_m \\ x_2 x_1 & x_2^2 & \cdots & x_2 x_m \\ \vdots & \ddots & \ddots & \vdots \\ x_m x_1 & x_m x_2 & \cdots & x_m^2 \end{bmatrix} \right)$$

\mathbf{B} $\mathbf{x} \mathbf{x}^\top$

カーネル回帰：

カーネル関数を用いた非線形性の導入

- 前述の変数変換アプローチを一般化する
- 線形モデル $y = \beta^\top \mathbf{x}$ において、 d 番目の独立変数 x_d を「カーネル関数」をもちいた基底 $\phi_d(\mathbf{x})$ で与える
 - カーネル関数 $\phi_d(\mathbf{x})$ ：
独立変数 \mathbf{x} に何らかの非線形変換を適用したもの
- カーネルの例：ガウスカーネル $\phi_d(\mathbf{x}) = \exp(-\gamma \|\mathbf{x} - \mathbf{x}^{(d)}\|_2^2)$
 - 要するに、 d 番目のデータとの「類似度」のようなもの



カーネル回帰：

カーネル関数を用いた非線形性の導入

- カーネル回帰モデル：


$$y = \beta^\top \Phi(\mathbf{x}) = \beta_1 \phi_1(\mathbf{x}) + \beta_2 \phi_2(\mathbf{x}) + \cdots + \beta_n \phi_n(\mathbf{x}) + \alpha$$

- モデルの次元数 n は、もとの \mathbf{x} の次元数 m とは異なることに注意

- 通常はモデルの次元数 $n = \text{データサイズ}$ にとる


- $\phi_d(\mathbf{x})$ は \mathbf{x} と $\mathbf{x}^{(d)}$ の類似度を表すカーネル関数

- $n = 2, m = 1$ の例 : $y = 1.5 \exp(-x^2) + 2 \exp(-(x - 3)^2)$



さまざまなカーネル関数： カーネル関数を変えれば様々なデータに対応可能


- カーネル回帰はカーネル関数の定義を変えることで、任意の対象を扱うことができる
 - 独立変数がベクトル $\mathbf{x} = (x_1, x_2, \dots, x_m, 1)^\top$ である必要すらない
- カーネル関数によって、系列、木、グラフなども扱うことができる



最尤推定

(あらためて) 統計モデリングの考え方： 部分から全体について知る

- 母集団：確率分布で表される、我々が本当に興味のある集合
 - 分布のクラスやパラメータで指定されるとする
- 標本：実際に観測できる母集団の一部
 - 確率分布に従って抽出された具体的なデータ
- 目的：
標本から母集団について推測する
(標本抽出の逆)
 - パラメータを推定する (どうやって?)



パラメータの推定問題：

サイコロの各目の出る確率を実際の出目から推定する

- 母集団は離散分布に従うとする

- $P(X = k) = f(k)$ (ただし $\sum_{k \in \chi} f(k) = 1, f(k) \geq 0$)

- たとえば（厳密な）サイコロであれば $P(X = k) = \frac{1}{6} \approx 0.17$

- 標本抽出：

- サイコロを20回（独立に）振ったところ、

- 6 3 5 1 3 1 4 1 2 2 6 1 2 2 5 4 4 4 6 5 が出た

出目	1	2	3	4	5	6
回数	4	4	2	4	3	3

- 母集団のパラメータ（それぞれの目の出る確率）を推定したい

サイコロのパラメータ推定問題へのひとつの解：

出た目の回数の割合で推定する

- ひとつのアイディア：

20回中で1が4回出たのだから $P(X = 1) \approx \frac{4}{20} = 0.2$ と推定する

出目	1	2	3	4	5	6
回数	4	4	2	4	3	3
確率の推定値	0.2	0.2	0.1	0.2	0.15	0.15

- 正解が約0.17なので悪くない...
- この推定値はどのような原理に基づいているのか？

最尤推定： 確率分布の代表的な推定手法のひとつ

- 標本からの母集団確率分布の推定
- 代表的な推定手法
 - 最尤推定
 - モーメント推定
 - ベイズ推定
 - ...

最尤推定とは：

標本をもっともよく再現するパラメータを推定値とする

- n 個のデータ : x_1, x_2, \dots, x_n が生成される確率 (尤度) :

$$L = P(X = x_1)P(X = x_2) \cdots P(X = x_n) = \prod_{i=1}^n P(X = x_i)$$

独立性を仮定しているので積になる

- サイコロの例 :

- 目 k が出る確率を p_k , 目 k が出た回数を n_k とする

- 尤度 $L(p_1, p_2, \dots, p_n) = p_1^{n_1} p_2^{n_2} \cdots p_6^{n_6} = \prod_{k=1}^6 p_k^{n_k}$

- これを最大化する p_1, p_2, \dots, p_n を求める (最大化問題を解く) と

$$\hat{p}_k = \frac{n_k}{n_1 + n_2 + \cdots + n_6}$$

サイコロ（離散分布）の最尤推定： ラグランジュの未定乗数法によって推定値が求まる

- 尤度の代わりに対数尤度を最大化すると扱いやすい（解は変わらない）：

$$\log L(p_1, p_2, \dots, p_n) = \sum_{k=1}^6 n_k \log p_k$$

- 確率分布の制約: $\sum_{k=1}^6 p_k = 1, p_k > 0$
- ラグランジュ未定乗数法：

$\{p_k\}_{k=1}^6, \lambda$ について最大化する


$$G(\{p_k\}_{k=1}^6, \lambda) = \sum_{k=1}^6 n_k \log p_k + \lambda \left(1 - \sum_{k=1}^6 p_k \right)$$

練習：

正規分布のパラメータの最尤推定

- 正規分布 : $f(x) = N(x|\mu, \sigma^2) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$
- パラメータ : 平均 μ と分散 σ^2 の最尤推定量を求めてみよう
 - データ : x_1, x_2, \dots, x_n に対する対数尤度をつくる
 - パラメータについての最大化問題を解く

$$f(x)$$



ベイズ決定

応用問題：

どちらのサイコロが使われた？

- 2つの（いびつな）サイコロA, Bがある

- サイコロAを20回振ったところ：

出目	1	2	3	4	5	6
回数	5	1	4	2	4	4

- サイコロBを16回振ったところ：

出目	1	2	3	4	5	6
回数	2	8	2	2	1	1

応用問題：

どちらのサイコロが使われた？

- （いびつな）サイコロA, Bのパラメータの最尤推定値は：
 - サイコロA :

出目	1	2	3	4	5	6
確率	5/20	1/20	4/20	2/20	4/20	4/20

- サイコロB :

出目	1	2	3	4	5	6
確率	2/16	8/16	2/16	2/16	1/16	1/16

応用問題：

どちらのサイコロが使われた？

- （いびつな）サイコロA, Bのパラメータの最尤推定値は：

—サイコロA：

出目	1	2	3	4	5	6
確率	5/20	1/20	4/20	2/20	4/20	4/20

—サイコロB：

出目	1	2	3	4	5	6
確率	2/16	8/16	2/16	2/16	1/16	1/16

- 今、2つのサイコロのいずれかを選んで（Cとする）5回振ったところ：

出目	1	2	3	4	5	6
回数	1	1	0	2	0	1

- 使われたサイコロはA, Bのいずれだろうか？ ($C=A$ or $C=B$?)

ベイズ決定：

事後確率によって決定する

- A, B どちらのサイコロを選んだかを確率変数 X で表す
 - 事前確率：でたらめに選ぶと $P(X = A) = P(X = B) = 1/2$
 - 何も情報がなければこれ以上はわからない
- 事後分布：C (A, Bのいずれか) を振って出たデータ \mathcal{D} を見たあと の、 X の確率分布 $P(X|\mathcal{D})$
- ベイズ決定：事後確率が $P(X = A|\mathcal{D}) > P(X = B|\mathcal{D})$ であれば、A が使われた可能性が高いと判断できる
- 事後確率の計算： $P(X|\mathcal{D}) = \frac{P(\mathcal{D}|X)P(X)}{P(\mathcal{D})}$ (ベイズの定理)

出目	1	2	3	4	5	6
回数	1	1	0	2	0	1

事後確率の計算：

ベイズの定理と最尤推定で事後確率を計算

- 事後確率の計算には「ベイズの定理」をつかう：

$$P(X|\mathcal{D}) = \frac{P(\mathcal{D}|X)P(X)}{P(\mathcal{D})}$$

$P(X)$ は事前確率
(今回は $1/2$)

J. Bayes.



– 判断基準： $P(X = A|\mathcal{D}) \geq P(X = B|\mathcal{D})$

$$\leftrightarrow P(\mathcal{D}|X = A)P(X = A) \geq P(\mathcal{D}|X = B)P(X = B)$$

– 注意：分母 $P(\mathcal{D}) = \sum_X P(\mathcal{D}|X)P(X)$ は今回は計算する必要はない

- サイコロのパラメータ $\{p_k^A\}_{k=1}^6, \{p_k^B\}_{k=1}^6$ は最尤推定によって推定

サイコロCの出目回数

$$\bullet P(\mathcal{D}|X = A) = \prod_{k=1}^6 p_k^A {}^{n_k^C} \geq P(\mathcal{D}|X = B) = \prod_{k=1}^6 p_k^B {}^{n_k^C} \text{ で判断}$$

線形回帰モデルの確率的解釈

最尤推定：

データをもっともよく再現するパラメータを推定値とする

- n 個のデータ x_1, x_2, \dots, x_n から確率モデル $f(x | \theta)$ のパラメータ θ を推定したい
- n 個のデータが（互いに独立に）生成される確率（尤度）：

$$L(\theta) = \prod_{i=1}^n f(x_i | \theta)$$

- 尤度最大になるパラメータを推定値 $\hat{\theta}$ とする

$$\hat{\theta} = \operatorname{argmax}_{\theta} \prod_{i=1}^n f(x_i | \theta) = \operatorname{argmax}_{\theta} \sum_{i=1}^n \log f(x_i | \theta)$$

実際には対数尤度で扱うことが多い

- もっともデータを生成する確率が高い（「最も尤もらしい」）

線形回帰モデルの最尤推定： 線形回帰の確率モデルを考える

- データ : $\mathbf{x} = (x^{(1)}, x^{(2)}, \dots, x^{(n)})$ と $\mathbf{y} = (y^{(1)}, y^{(2)}, \dots, y^{(n)})$ に
線形モデル : $g(x) = \beta x + \alpha$ を当てはめる
- 最小二乗法 : $\ell(\alpha, \beta) = \sum_{i=1}^n \left(y^{(i)} - (\beta x^{(i)} + \alpha) \right)^2$ を最小化
- 一方、線形回帰モデルに対応する確率モデルを仮定する：
 - 正規分布 : $y^{(i)}$ は平均 $\beta x^{(i)} + \alpha$, 分散 σ^2 の正規分布に従う
 - 確率密度 : $f(y^{(i)} | x^{(i)}) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(y^{(i)} - (\beta x^{(i)} + \alpha))^2}{2\sigma^2}\right)$
 - 「平均的に」回帰直線 $y = \beta x + \alpha$ に乗るデータを生成するモデル

線形回帰モデルの最尤推定：

線形回帰の確率モデルの最尤推定 = 最小二乗法

- 線形回帰モデルに対応する確率モデルを考える：

- 確率密度関数： $f(y^{(i)} | x^{(i)}) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(y^{(i)} - (\beta x^{(i)} + \alpha))^2}{2\sigma^2}\right)$

- 対数尤度： $L(\alpha, \beta) = \sum_{i=1}^n \log f(y^{(i)} | x^{(i)})$

$$= -\frac{1}{2\sigma^2} \sum_{i=1}^n (y^{(i)} - (\beta x^{(i)} + \alpha))^2 + \text{const.}$$

- 対数尤度を α, β について最大化すること（最尤推定）

= 二乗誤差を α, β について最小化すること（最小二乗法）

線形回帰モデルの最尤推定： 分散の最尤推定量

- 確率密度関数 : $f(y^{(i)} | x^{(i)}) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(y^{(i)} - (\beta x^{(i)} + \alpha))^2}{2\sigma^2}\right)$

- 分散については、対数尤度 :

$$L(\sigma^2) = n \log \frac{1}{\sigma} - \frac{1}{2\sigma^2} \sum_{i=1}^n (y^{(i)} - (\beta x^{(i)} + \alpha))^2 + \text{const.}$$

- $L(\sigma^2)$ を最大化する最尤推定量は :

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (y^{(i)} - (\beta x^{(i)} + \alpha))^2$$

※ 以上の議論は重回帰モデルの場合も同様

最尤推定の性質

最尤推定量の性質： 一致性

- パラメータ θ の推定量として $\hat{\theta}$ を得たとする（例えば最尤推定で）
- 推定量の良さはどのように評価するか？
 - 不偏性 $E[\hat{\theta}] = \theta$ ：推定量の期待値が真の値に一致する
 - E は様々な標本の採り方についての期待値を表す
 - たとえば、平均の最尤推定量は不偏性をもつが、分散の最尤推定量はもたない
 - 一致性：標本サイズを大きくしていくと真の値に一致する：
$$\hat{\theta} \xrightarrow[n \rightarrow \infty]{} \theta$$
- 最尤推定は、適当な条件のもと一致性をもつ

漸近正規性：

最尤推定は漸近正規性をもつ

- 最尤推定量の分布は $n \rightarrow \infty$ で、真のパラメータ θ を平均とする正規分布に従う
- もう少し厳密にいうと：
 $\sqrt{n}(\hat{\theta} - \theta)$ の分布が平均 0、分散 $I(\theta)^{-1}$ の正規分布に近づく

- $I(\theta)$ はフィッシャー情報量：

$$\begin{aligned} I(\theta) &= -E \left[\frac{\partial^2}{\partial \theta^2} \log f(x|\theta) \right] \\ &= - \int \left(\frac{\partial^2}{\partial \theta^2} \log f(x|\theta) \right) f(x|\theta) dx \end{aligned}$$

$I(\theta)$ が大きいほど、対数尤度関数が、真値の周りで「尖っている」イメージ

- $n \rightarrow \infty$ で $\hat{\theta} \rightarrow \theta$

ポアソン回帰

最尤推定：

データをもっともよく再現するパラメータを推定値とする

- n 個のデータ x_1, x_2, \dots, x_n から確率モデル $f(x | \theta)$ のパラメータ θ を推定したい
- n 個のデータが（互いに独立に）生成される確率（尤度）：

$$L(\theta) = \prod_{i=1}^n f(x_i | \theta)$$

- 尤度最大になるパラメータを推定値 $\hat{\theta}$ とする

$$\hat{\theta} = \operatorname{argmax}_{\theta} \prod_{i=1}^n f(x_i | \theta) = \operatorname{argmax}_{\theta} \sum_{i=1}^n \log f(x_i | \theta)$$

- もっともデータを生成する確率が高い（「最も尤もらしい」）

実際には対数尤度で扱うことが多い

ポアソン分布の最尤推定： 標本平均がパラメータの最尤推定量になる

- ポアソン分布 : $P(Y = y | \lambda) = \frac{\lambda^y}{y!} \exp(-\lambda)$


$\lambda > 0$ は平均に相当するパラメータ

- データ : y_1, y_2, \dots, y_n に対する対数尤度 :

$$L(\lambda) = \sum_{i=1}^n \log P(Y = y_i | \lambda) = \log \lambda \sum_{i=1}^n y_i - n\lambda + \text{const.}$$

- パラメータの最尤推定量 :

$$\hat{\lambda} = \frac{\sum_{i=1}^n y_i}{n}$$



https://en.wikipedia.org/wiki/Poisson_distribution#/media/File:Poisson_pmf.svg

ポアソン回帰：

非負整数の回帰モデル

- 例えば、ある機械の各日の故障件数をモデル化したいとする
 - 曜日や気温などに依存して平均的な故障件数が変わるとする
- 独立変数（曜日など）に依存する回数のモデル：ポアソン回帰

$$P(Y = y \mid \mathbf{x}, \boldsymbol{\beta}) = \frac{(\exp(\boldsymbol{\beta}^\top \mathbf{x}))^y}{y!} \exp(-\exp(\boldsymbol{\beta}^\top \mathbf{x}))$$

– ポアソン分布の平均が線形モデルで表されるとする：

- ポアソン分布： $P(Y = y \mid \lambda) = \frac{\lambda^y}{y!} \exp(-\lambda)$
 - 重回帰モデル： $\lambda = \exp(\boldsymbol{\beta}^\top \mathbf{x})$
- 組み合わせる

ポアソン回帰の最尤推定： 解析解は得られなさそう...

- 独立変数 : $(\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots, \mathbf{x}^{(n)})$ # n 日分の測定
- 従属変数 : $(y^{(1)}, y^{(2)}, \dots, y^{(n)})$ # n 日分の故障数
- 対数尤度（最大化問題）：

$$\begin{aligned} L(\boldsymbol{\beta}) &= \sum_{i=1}^n \log \frac{\left(\exp(\boldsymbol{\beta}^\top \mathbf{x}^{(i)})\right)^{y^{(i)}}}{y^{(i)}!} \exp(-\exp(\boldsymbol{\beta}^\top \mathbf{x}^{(i)})) \\ &= \sum_{i=1}^n y^{(i)} \boldsymbol{\beta}^\top \mathbf{x}^{(i)} - \sum_{i=1}^n \exp(\boldsymbol{\beta}^\top \mathbf{x}^{(i)}) + \text{const.} \end{aligned}$$

- これを最大化する $\boldsymbol{\beta}$ を求めたいが、解析解は得られない

最尤推定の利点： モデリングの自動化

- 最尤推定の利点：確率モデルの形（データの生成プロセスの仮定）を決めればモデルパラメータが自動的に決まる
 - ただし、最後に最大化問題を解いて、パラメータ推定量を求める必要がある
 - 離散分布、ポアソン分布、正規分布などは解析的に解が求まる
 - 線形回帰（正規分布でノイズが載る）は連立方程式（いちおう解析的な解）
 - ただし、他の多くのモデルでは、最適化問題を数値的に解く必要がある