

第5章 指数型分布族と一般化線型モデル

5.1 指数型分布族

$\Theta \subset \mathbb{R}$ を母数空間とし、母数 $\theta \in \Theta$ をもつ確率分布に従う確率変数 X を考える。

eq:exp-1

定義 5.1. 確率変数 X の p.d.f. または p.m.f.(これを p と記す) の対数をとったものが次の形で記述されるとき、その分布は指数型分布族に属すると言われる。

$$\log p(x|\theta) = t(x)b(\theta) + \kappa(\theta) + d(x).$$

ただし $\log 0 = 0$ と約束し、 t, b, κ, d は関数で

$$t: \mathbb{X} \longrightarrow \mathbb{R}, \quad b: \Theta \longrightarrow \mathbb{R}, \quad \kappa: \Theta \longrightarrow \mathbb{R}, \quad d: \mathbb{X} \longrightarrow \mathbb{R}$$

とする。ただしこれらの関数形は既知とし、 $\mathbb{X} = \{x \in \mathbb{R}; p(x|\theta) > 0\}$ である。

$t(x) = x$ のとき、その分布は正準型 (canonical form) であると言われ、 $b(\theta)$ は自然母数 (natural parameter) と呼ばれる。

re:exp-2

注意 5.2. もし関心のある未知母数 θ 以外に他の未知母数があるとき、それらを関数 b, κ を構成する局外母数 (nuisance parameter) と呼ばれる。
□

ex:exp-3

例 5.3. (Bernoulli 分布) X は $\text{Ber}(\theta)$ ($0 < \theta < 1$) に従うとき、 X の p.m.f. p は

$$p(x|\theta) = \theta^x(1-\theta)^{1-x} \quad (x = 0, 1)$$

と書ける。これは

$$\log p(x|\theta) = x \log \theta + (1-x) \log(1-\theta) = x \log \frac{\theta}{1-\theta} + \log(1-\theta)$$

と表現できるので

$$t(x) = x, \quad b(\theta) = \frac{\theta}{1-\theta}, \quad \kappa(\theta) = \log(1-\theta), \quad d(\theta) = 0.$$

□

Dobson の 3 章を借用して指数分布族と一般化線型モデルを借用。そして、岡留の『機械学習』の 4 章の分類のところを借用する。

ex:exp-4

例 5.4. (ポアソン分布) X は $\text{Pois}(\theta)$ ($\theta > 0$) に従うとき, X の p.m.f. p は

$$p(x|\theta) = \frac{\theta^x e^{-\theta}}{x!} \quad (x = 0, 1, \dots)$$

と書ける. ただし, $0! = 1$ と形式的に定める. これは

$$\log p(x|\theta) = x \log \theta - \theta - \log x!$$

と表現できるので

$$t(x) = x, \quad b(\theta) = \log \theta, \quad \kappa(\theta) = -\theta, \quad d(x) = -\log x!.$$

□

ex:exp-5

例 5.5. (正規分布) X は $N(\theta, \sigma^2)$ ($\theta \in \mathbb{R}, 0 < \sigma < \infty$) に従うとき, X の p.d.f. p は

$$p(x|\theta) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{(x-\theta)^2}{2\sigma^2}\right] \quad (-\infty < x < \infty)$$

と書かれる. ここで, 関心のある母数は θ で, σ は局外母数で既知とする. このとき,

$$\log p(x|\theta) = -\frac{x^2}{2\sigma^2} + \frac{x\theta}{\sigma^2} - \frac{\theta^2}{2\sigma^2} - \frac{1}{2} \log(2\pi\sigma^2)$$

と表現できるので,

$$t(x) = x, \quad b(\theta) = \frac{\theta}{\sigma^2}, \quad \kappa(\theta) = -\frac{\theta^2}{2\sigma^2} - \frac{1}{2} \log(2\pi\sigma^2), \quad d(x) = -\frac{x^2}{2\sigma^2}.$$

□

5.2 指数型分布族の性質

sec:exp-2

以下では連続型分布の場合で議論を進める. 離散型分布の場合には積分記号を和の記号に書きかえればよい. さらに積分記号と微分記号の交換が可能であることが保証されていると仮定¹して議論を進める.

まず $p(x|\theta)$ は p.d.f. であることから

$$\int_x p(x|\theta) dx = 1. \quad (5.1)$$

eq:exp-1

¹実は, 指数型分布族の場合には積分記号と微分記号の交換が保証されることを示すことができる. Lehmann and Romano (2022, pp.52-53) を参照のこと.

ただし $\mathcal{X} = \{x \in \mathbb{R}; p(x|\theta) > 0\}$ である. θ に関して (5.1) の両辺を微分すれば,

$$0 = \frac{d}{d\theta} 1 = \frac{d}{d\theta} \int_{\mathcal{X}} p(x|\theta) dx = \int_{\mathcal{X}} \frac{d}{d\theta} p(x|\theta) dx$$

から

$$\int_{\mathcal{X}} \frac{d}{d\theta} p(x|\theta) dx = 0 \quad (5.2) \quad \text{ex:exp-2}$$

を得る. 同様に

$$\int_{\mathcal{X}} \frac{d^2 p(x|\theta)}{d\theta^2} dx = 0. \quad (5.3) \quad \text{eq:exp-3}$$

指数型分布族に属する分布の p.d.f. を (5.1) に代入すると

$$\begin{aligned} \int_{\mathcal{X}} \frac{d}{d\theta} p(x|\theta) dx &= \int_{\mathcal{X}} \left(\frac{d}{d\theta} \log p(x|\theta) \right) p(x|\theta) dx \\ &= \int_{\mathcal{X}} \{t(x)\dot{b}(\theta) + \dot{\kappa}(\theta)\} p(x|\theta) dx = 0. \end{aligned}$$

ただし

$$\dot{b}(\theta) = \frac{db(\theta)}{d\theta}, \quad \dot{\kappa}(\theta) = \frac{d\kappa(\theta)}{d\theta}.$$

期待値の定義から

$$\int_{\mathcal{X}} t(x)\dot{b}(\theta)p(x|\theta) dx = \dot{b}(\theta)E[a(X)], \quad \int_{\mathcal{X}} \dot{\kappa}(\theta)p(x|\theta) dx = \dot{\kappa}(\theta)$$

となるので,

$$\dot{b}(\theta)E[a(X)] + \dot{\kappa}(\theta) = 0. \quad (5.4) \quad \text{eq:exp-4}$$

よって $\dot{b}(\theta) \neq 0$ のとき

$$E[t(X)] = -\frac{\dot{\kappa}(\theta)}{\dot{b}(\theta)}. \quad (5.5) \quad \text{eq:exp-5}$$

同様に

$$\begin{aligned} \frac{d^2}{d\theta^2} p(x|\theta) &= \frac{d}{d\theta} \left[\left(\frac{d}{d\theta} \log p(x|\theta) \right) p(x|\theta) \right] \\ &= \left(\frac{d^2}{d\theta^2} \log p(x|\theta) \right) p(x|\theta) + \left(\frac{d}{d\theta} \log p(x|\theta) \right)^2 p(x|\theta) \\ &= \{a(x)\ddot{b}(\theta) + \ddot{\kappa}(\theta)\} p(x|\theta) + \{t(x)\dot{b}(\theta) + \dot{\kappa}(\theta)\}^2 p(x|\theta). \end{aligned} \quad (5.6) \quad \text{eq:exp-6}$$

ただし

$$\ddot{b}(\theta) = \frac{d^2 b(\theta)}{d\theta^2}, \quad \ddot{c}(\theta) = \frac{d^2 c(\theta)}{d\theta^2}.$$

(5.6) の最右辺の第 2 項に (5.5) を代入すると

$$\begin{aligned} \{t(x)\dot{b}(\theta) + \dot{\kappa}(\theta)\}p(x|\theta) &= \{\dot{b}(\theta)\}^2 \left\{t(x) + \frac{\dot{\kappa}(\theta)}{\dot{b}(\theta)}\right\}^2 p(x|\theta) \\ &= \{\dot{b}(\theta)\}^2 \{t(x) - E[t(X)]\}^2 p(x|\theta) \end{aligned}$$

と表され

$$\int_{\mathbb{X}} \{t(x) - E[t(X)]\}^2 p(x|\theta) dx = \text{Var}[t(X)]. \quad (5.7) \quad \text{eq:exp-7}$$

一方, (5.3) と (5.7) から (5.6) は以下のように書き直せる.

$$\begin{aligned} 0 &= \int_{\mathbb{X}} \frac{d^2}{d\theta^2} p(x|\theta) dx = \int_{\mathbb{X}} \{t(x)\ddot{b}(\theta) + \ddot{\kappa}(\theta)\} p(x|\theta) dx + \{\dot{b}(\theta)\}^2 \text{Var}[t(X)] \\ &= \ddot{b}(\theta)E[t(X)] + \ddot{\kappa}(\theta) + \{\dot{b}(\theta)\}^2 \text{Var}[t(X)]. \end{aligned}$$

よって $\dot{b}(\theta) \neq 0$ のとき

$$\text{Var}[t(X)] = \frac{\ddot{b}(\theta)\dot{\kappa}(\theta) - \ddot{\kappa}(\theta)\dot{b}(\theta)}{\{\dot{b}(\theta)\}^3}. \quad (5.8) \quad \text{eq:exp-7a}$$

次に $X = x$ が観測されたときの対数尤度関数

$$\ell(\theta|x) = \log p(x|\theta)$$

の導関数の x に確率変数 X を形式的に代入して確率変数にしたもの $\ell(\theta|X)$ (これも対数尤度関数と乱暴に呼ぶことにする) の期待値と分散を求める.

$$S(\theta|x) := \frac{\partial \ell(\theta|x)}{\partial \theta} = \frac{\partial}{\partial \theta} \{t(x)b(\theta) + \kappa(\theta) + d(x)\} = t(x)\dot{b}(\theta) + \dot{\kappa}(\theta).$$

うえの式の x に形式的に X を代入したもの $S(\theta|X)$ をスコア関数という. すると (5.5) から

$$\begin{aligned} E[S(\theta|X)] &= E[t(X)\dot{b}(\theta) + \dot{\kappa}(\theta)] = \dot{b}(\theta)E[t(X)] + \dot{\kappa}(\theta) \\ &= \dot{b} \left[-\frac{\dot{\kappa}(\theta)}{\dot{b}(\theta)} \right] + \dot{\kappa}(\theta) = 0. \end{aligned} \quad (5.9) \quad \text{eq:exp-8}$$

$S(\theta|X)$ の分散を Fisher 情報量といい, $I(\theta)$ と記すことにする. このとき

$$I(\theta) = \text{Var}[S(\theta|X)] = \text{Var}[t(X)\dot{b}(\theta) + \dot{\kappa}(\theta)] = \{\dot{b}(\theta)\}^2 \text{Var}[t(X)].$$

([eq:exp-7](#))
(5.7) から

$$\text{Var}[S(\theta|X)] = \{\dot{b}(\theta)\}^2 \text{Var}[t(X)] = \frac{\ddot{b}(\theta)\dot{\kappa}(\theta)}{\dot{b}(\theta)} - \ddot{\kappa}(\theta).$$

さらに

$$\dot{S}(\theta|x) := \frac{dS(\theta|x)}{d\theta} = t(x)\ddot{b}(\theta) + \ddot{\kappa}(\theta)$$

と ([eq:exp-6](#))
(5.6) から

$$\begin{aligned} E[\dot{S}(\theta|X)] &= \ddot{b}(\theta)E[t(X)] + \ddot{\kappa}(\theta) = \ddot{b}(\theta) \left[-\frac{\dot{\kappa}(\theta)}{\dot{b}(\theta)} \right] + \ddot{\kappa}(\theta) \\ &= -\frac{\ddot{b}(\theta)\dot{\kappa}(\theta)}{\dot{b}(\theta)} + \ddot{\kappa}(\theta) = -I(\theta) = -\text{Var}[S(\theta|X)]. \end{aligned}$$

5.3 一般化線型モデル (Generalized linear models (GLM))

GLM は独立な確率変数列 Y_1, Y_2, \dots, Y_n に対する統計的モデルで以下で定める性質をみたす.

- 各 Y_j ($j = 1, 2, \dots, n$) の分布は同じ指数型分布族に属する. Y_j の p.d.f. または p.m.f. $p_Y(y_j|\theta_j)$ は母数 $\theta_j \in \Theta \subset \mathbb{R}$ で添え字づけられ

$$p_Y(y_j|\theta_j) = \exp\{y_j b(\theta_j) + \kappa(\theta_j) + d(y_j)\} \quad (5.10)$$

[eq:glm-1](#)

で与えられる.

- 母数 θ_j は直接興味ある対象ではなく, 母数 $\beta_1, \beta_2, \dots, \beta_d$ ($d < n$) に興味がある. ここで

$$\mu_j = E[Y_j]$$

と書いたとき

$$g(\mu_j) = \mathbf{x}_j^\top \boldsymbol{\beta}$$

と表現される. ただし $g: \mathbb{R} \rightarrow \mathbb{R}$ は狭義単調関数で連続微分可能である. したがって μ_j は θ_j の関数で ([eq:exp-5](#))
(5.5) から

$$\mu_j = -\frac{\dot{\kappa}(\theta_j)}{\dot{b}(\theta_j)}$$

と書ける. さらに \mathbf{x}_j は非ランダムな説明変数 (既知のもの) で $\boldsymbol{\beta} = (\beta_1, \beta_2, \dots, \beta_d)^\top$ は未知の回帰係数ベクトルで

$$\boldsymbol{\beta} = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_d \end{bmatrix} \in \mathbb{R}^d, \quad \mathbf{x}_j = \begin{bmatrix} x_{j1} \\ x_{j2} \\ \vdots \\ x_{jd} \end{bmatrix} \in \mathbb{R}^d,$$

$$\mathbf{X} = \begin{bmatrix} \mathbf{x}_1^\top \\ \mathbf{x}_2^\top \\ \vdots \\ \mathbf{x}_n^\top \end{bmatrix} = \begin{bmatrix} x_{11} & \cdots & x_{1d} \\ x_{21} & \cdots & x_{2d} \\ \vdots & \vdots & \vdots \\ x_{n1} & \cdots & x_{nd} \end{bmatrix}$$

である.

したがって (Y_1, Y_2, \dots, Y_n) の同時 p.d.f. または p.m.f. $p(y_1, y_2, \dots, y_n | \theta_1, \theta_2, \dots, \theta_n)$ は

$$\begin{aligned} p(y_1, y_2, \dots, y_n | \theta_1, \theta_2, \dots, \theta_n) &= \prod_{j=1}^n \exp\{y_j b(\theta_j) + \kappa(\theta_j) + d(y_j)\} \\ &= \exp\left\{ \sum_{j=1}^n y_j b(\theta_j) + \sum_{j=1}^n \kappa(\theta_j) + \sum_{j=1}^n d(y_j) \right\} \end{aligned} \quad (5.11) \quad \boxed{\text{eq:glm-2}}$$

となる.

ex:glm-1

例 5.6. (ロジスティック回帰モデル)

書くこと.

□

5.4 GLM の最尤推定法

Y_1, Y_2, \dots, Y_n は eq:glm-1 (5.10) で与えられる GLM に従うとする. すると $Y_j = y_j$ ($j = 1, 2, \dots, n$) を観測したときの対数尤度関数 $\ell_j(\theta_j)$ は

$$\ell_j(\theta_j) = y_j b(\theta_j) + \kappa(\theta_j) + d(y_j)$$

と書くことができる。さらに [\(5.5\)](#) と [\(5.8\)](#) から

$$E[Y_j] = \mu_j = -\frac{\dot{\kappa}(\theta_j)}{\dot{b}(\theta_j)} \quad (5.12) \quad \text{eq:glm-3}$$

$$\text{Var}[Y_j] = \frac{\ddot{b}(\theta_j)\dot{\kappa}(\theta_j) - \dot{\kappa}(\theta_j)\dot{b}(\theta_j)}{\{\dot{b}(\theta_j)\}^3} \quad (5.13) \quad \text{eq:glm-4}$$

$$g(\mu_j) = \mathbf{x}_j^\top \boldsymbol{\beta} =: \eta_j, \quad \mathbf{x}_j = (x_{j1}, x_{j2}, \dots, x_{jd})^\top \quad (5.14) \quad \text{eq:glm-5}$$

である。 $(Y_1, Y_2, \dots, Y_n)^\top$ の対数尤度関数 ℓ は

$$\ell = \sum_{j=1}^n \ell_j(\theta_j) = \sum_{j=1}^n y_j b(\theta_j) + \sum_{j=1}^n \kappa(\theta_j) + \sum_{j=1}^n d(y_j)$$

となる。 $\boldsymbol{\beta}$ の最尤推定値を求めるために ℓ を $\boldsymbol{\beta}$ に関して偏微分をする。連鎖偏微分律から

$$\frac{\partial \ell}{\partial \beta_k} = \sum_{j=1}^n \frac{\partial \ell_j}{\partial \beta_k} = \sum_{j=1}^n \frac{\partial \ell_j}{\partial \theta_j} \cdot \frac{\partial \theta_j}{\partial \mu_j} \cdot \frac{\partial \mu_j}{\partial \beta_k} \quad (k = 1, 2, \dots, d) \quad (5.15) \quad \text{eq:glm-6}$$

と書ける。最右辺の各項を計算して行く。 [\(5.12\)](#) に注意すると

$$\frac{\partial \ell_j}{\partial \theta_j} = y_j \dot{b}(\theta_j) + \dot{\kappa}(\theta_j) = \dot{b}(\theta_j) \left\{ y_j + \frac{\dot{\kappa}(\theta_j)}{\dot{b}(\theta_j)} \right\} = \dot{b}(\theta_j) \{y_j - \mu_j\} \quad (5.16) \quad \text{eq:glm-7}$$

を得る。次に

$$\frac{\partial \theta_j}{\partial \mu_j} = 1 / \frac{\partial \mu_j}{\partial \theta_j}$$

であることと [\(5.12\)](#) に注意すると

$$\begin{aligned} \frac{\partial \mu_j}{\partial \theta_j} &= -\frac{\partial}{\partial \theta_j} \left(\frac{\dot{\kappa}(\theta_j)}{\dot{b}(\theta_j)} \right) = -\frac{\ddot{\kappa}(\theta_j)}{\dot{b}(\theta_j)} + \frac{\ddot{b}(\theta_j)\dot{\kappa}(\theta_j)}{\{\dot{b}(\theta_j)\}^2} \\ &= \dot{b}(\theta_j) \left\{ \frac{\ddot{b}(\theta_j)\dot{\kappa}(\theta_j) - \dot{b}(\theta_j)\ddot{\kappa}(\theta_j)}{\{\dot{b}(\theta_j)\}^3} \right\} = \dot{b}(\theta_j) \text{Var}[Y_j] \end{aligned} \quad (5.17) \quad \text{eq:glm-8}$$

を得る。最後の等号は [\(5.13\)](#) からわかる。最後に

$$\frac{\partial \mu_j}{\partial \beta_k} = \frac{\partial \mu_j}{\partial \eta_j} \cdot \frac{\partial \eta_j}{\partial \beta_k} = \frac{\partial \mu_j}{\partial \eta_j} x_{jk} \quad (5.18) \quad \text{eq:glm-9}$$

を得る。 [\(5.16\)](#) - [\(5.18\)](#) を [\(5.15\)](#) に代入することでスコア関数は

$$S_k := \sum_{j=1}^n \frac{(Y_j - \mu_j)}{\text{Var}[Y_j]} x_{jk} \left(\frac{\partial \mu_j}{\partial \eta_j} \right) \quad (k = 1, 2, \dots, d) \quad (5.19) \quad \text{eq:glm-10}$$

となることがわかる。

S_1, S_2, \dots, S_d の共分散行列を $J = (J_{kl})$ は

$$J_{kl} = E[S_k S_\ell] \quad (k, \ell = 1, 2, \dots, d)$$

と書くことができる. すると (5.19) から

$$\begin{aligned} J_{kl} &= E \left[\sum_{i=1}^n \left\{ \frac{(Y_i - \mu_i)}{\text{Var}[Y_i]} x_{ik} \left(\frac{\partial \mu_i}{\partial \eta_i} \right) \right\} \sum_{j=1}^n \left\{ \frac{(Y_j - \mu_j)}{\text{Var}[Y_j]} x_{j\ell} \left(\frac{\partial \mu_j}{\partial \eta_j} \right) \right\} \right] \\ &= \sum_{i=1}^n \frac{E[(Y_i - \mu_i)^2]}{\{\text{Var}[Y_i]\}^2} x_{ik} x_{i\ell} \left(\frac{\partial \mu_i}{\partial \eta_i} \right)^2 \end{aligned}$$

を得る. 最後から 2 番目の等号は $E[(Y_i - \mu_i)(Y_j - \mu_j)] = 0$ ($i \neq j$) からわかる. 結局

$$J_{kl} = \sum_{i=1}^n \frac{x_{ik} x_{i\ell}}{\text{Var}[Y_i]} \left(\frac{\partial \mu_i}{\partial \eta_i} \right)^2 \quad (k, \ell = 1, 2, \dots, d) \quad \text{eq:glm-11}$$

がわかる.

$m = 1, 2, \dots$ とする. $\hat{\beta}^{(0)}$ を β の初期推定値とし, 繰り返し計算で得られる m 回目の β の推定値を $\hat{\beta}^{(m)}$ と書くことにする. $J^{(m)} = (J_{kl}^{(m)})$ の $\beta = \hat{\beta}^{(m)}$ での値とし, $\mathbf{S}^{(m)} = (S_1^{(m)}, S_2^{(m)}, \dots, S_d^{(m)})^\top$ を S_k の $\beta = \hat{\beta}^{(m)}$ での値とする. したがって (3.4) から

$$\hat{\beta}^{(m)} = \hat{\beta}^{(m-1)} + [\mathbf{J}^{(m-1)}]^{-1} \mathbf{S}^{(m-1)} \quad \text{eq:glm-12}$$

を得る. 上式の両辺に $\mathbf{J}^{(m-1)}$ を掛けると

$$\mathbf{J}^{(m-1)} \hat{\beta}^{(m)} = \mathbf{J}^{(m-1)} \hat{\beta}^{(m-1)} + \mathbf{S}^{(m-1)} \quad \text{eq:glm-13}$$

を得る.

いま

$$\mathbf{W} = (W_{ij})_{i,j=1,2,\dots,n}, \quad W_{ij} = \begin{cases} \frac{1}{\text{Var}[Y_i]} \left(\frac{\partial \mu_i}{\partial \eta_i} \right) & (i = j) \\ 0 & (i \neq j) \end{cases} \quad \text{eq:glm-13a}$$

とおき, $\beta = \hat{\beta}^{(m)}$ での値を $\mathbf{W}^{(m)}$ と書く. すると

$$\mathbf{J}^{(m)} = \mathbf{X}^\top \mathbf{W}^{(m)} \mathbf{X}$$

と書ける. (5.22) の右辺のベクトルの第 j 成分 ($j = 1, 2, \dots, d$) は

$$\sum_{k=1}^d \sum_{i=1}^n \frac{x_{ij} x_{ik}}{\text{Var}[Y_i]} \left(\frac{\partial \mu_i}{\partial \eta_i} \right)^2 \hat{\beta}_k^{(m-1)} + \sum_{i=1}^n \frac{(Y_i - \mu_i) x_{ij}}{\text{Var}[Y_i]} \left(\frac{\partial \mu_i}{\partial \eta_i} \right)$$

と書ける. ただし $\text{Var}[Y_i]$, μ_i , $\frac{\partial \mu_i}{\partial \eta_i}$ も $\beta = \hat{\beta}^{(m-1)}$ での値であることに注意せよ. さらに

$$\begin{aligned} \mathbf{z}^{(m)} &= (z_1^{(m)}, z_2^{(m)}, \dots, z_d^{(m)})^\top, \\ z_i^{(m)} &= \sum_{k=1}^d x_{ik} \hat{\beta}_k^{(m)} \left(\frac{\partial \mu_i}{\partial \eta_i} \right) + (Y_i - \mu_i) \end{aligned} \quad (5.24) \quad \text{eq:glm-14}$$

とおくと (5.22) の右辺は

$$\mathbf{X}^\top \mathbf{W}^{(m-1)} \hat{\mathbf{z}}^{(m-1)}$$

と書けるので

$$\mathbf{X}^\top \mathbf{W}^{(m-1)} \mathbf{X} \hat{\beta}^{(m)} = \mathbf{X}^\top \mathbf{W}^{(m-1)} \mathbf{z}^{(m-1)}$$

を得る. なぜならば $\mathbf{X}^\top \mathbf{W}^{(m-1)} \mathbf{z}^{(m-1)}$ は第 j 成分を $\{\mathbf{X}^\top \mathbf{W}^{(m-1)} \mathbf{z}^{(m-1)}\}_j$ ($j = 1, 2, \dots, d$) と書くと

$$\begin{aligned} \{\mathbf{X}^\top \mathbf{W}^{(m-1)} \mathbf{z}^{(m-1)}\}_j &= \sum_{i=1}^n x_{ij} W_{ii}^{(m-1)} \hat{z}_i \\ &= \sum_{i=1}^n x_{ij} \frac{1}{\text{Var}[Y_i]} \left(\frac{\partial \mu_i}{\partial \eta_i} \right) \left\{ \sum_{k=1}^d x_{ik} \hat{\beta}_k^{(m)} \left(\frac{\partial \mu_i}{\partial \eta_i} \right) + (Y_i - \mu_i) \right\} \\ &\quad \left(\because \begin{array}{l} \text{eq:glm-13} \\ \text{eq:glm-14} \end{array} \text{を代入} \right) \\ &= \sum_{k=1}^d \sum_{i=1}^n \frac{x_{ij} x_{ik}}{\text{Var}[Y_i]} \left(\frac{\partial \mu_i}{\partial \eta_i} \right)^2 + \sum_{i=1}^n \frac{(Y_i - \mu_i) x_{ij}}{\text{Var}[Y_i]} \left(\frac{\partial \mu_i}{\partial \eta_i} \right) \end{aligned}$$

からわかる.

例 5.7. (Poisson 回帰)

y_j	2	3	6	7	8	9	10	11	12
x_j	-1	-1	0	0	0	0	1	1	1

応答変数 Y_j は Poisson 分布に従う確率変数とする. すると

$$\mu_j = E[Y_j] = \text{Var}[Y_j] \quad (j = 1, 2, \dots, n; n = 9) \quad (5.25) \quad \text{eq:glm-15}$$

となる. μ_j と x_j の間に線型関係を仮定する.

$$\begin{aligned} E[Y_j] &= \mu_j = \beta_1 + \beta_2 x_j = \mathbf{x}_j^\top \boldsymbol{\beta}, \\ \boldsymbol{\beta} &= \begin{bmatrix} \beta_1 \\ \beta_2 \end{bmatrix}, \quad \mathbf{x}_j = \begin{bmatrix} 1 \\ x_j \end{bmatrix} \quad (j = 1, 2, \dots, n) \end{aligned}$$

である。したがってリンク関数 g は恒等関数である。

$$g(\mu_j) = \mu_j = \mathbf{x}_j^\top \boldsymbol{\beta} =: \eta_j.$$

これより

$$\frac{\partial \mu_j}{\partial \eta_j} = 1$$

となる。eq:glm-13(5.23) と eq:glm-15(5.25) から

$$W_{jj} = \frac{1}{\text{Var}[Y_j]} = \frac{1}{\beta_1 + \beta_2 x_j} \quad (j = 1, 2, \dots, n)$$

となる。 $\mu_j = \mathbf{x}_j^\top \hat{\boldsymbol{\beta}} = \hat{\beta}_1 + \hat{\beta}_2 x_j$ を eq:glm-14(5.24) に代入すると

$$z_j = \hat{\beta}_1^{(m-1)} + \hat{\beta}_2^{(m-1)} x_j + y_j - \hat{\beta}_1^{(m-1)} - \hat{\beta}_2^{(m-1)} x_j = y_j$$

となる。また

$$\mathbf{J} = \mathbf{X}^\top \mathbf{W}^{(m-1)} \mathbf{X} = \begin{bmatrix} \sum_{j=1}^n \frac{1}{\hat{\beta}_1^{(m-1)} + \hat{\beta}_2^{(m-1)} x_j} & \sum_{j=1}^n \frac{x_j}{\hat{\beta}_1^{(m-1)} + \hat{\beta}_2^{(m-1)} x_j} \\ \sum_{j=1}^n \frac{x_j}{\hat{\beta}_1^{(m-1)} + \hat{\beta}_2^{(m-1)} x_j} & \sum_{j=1}^n \frac{x_j^2}{\hat{\beta}_1^{(m-1)} + \hat{\beta}_2^{(m-1)} x_j} \end{bmatrix}$$

$$\mathbf{X}^\top \mathbf{W}^{(m-1)} \mathbf{z} = \begin{bmatrix} \sum_{j=1}^n \frac{y_j}{\hat{\beta}_1^{(m-1)} + \hat{\beta}_2^{(m-1)} x_j} \\ \sum_{j=1}^n \frac{x_j y_j}{\hat{\beta}_1^{(m-1)} + \hat{\beta}_2^{(m-1)} x_j} \end{bmatrix}$$

となる。よって

$$\mathbf{X}^\top \mathbf{W}^{(m-1)} \mathbf{X} \hat{\boldsymbol{\beta}}^{(m)} = \mathbf{X}^\top \mathbf{W}^{(m-1)} \mathbf{y}$$

を得る。

$\hat{\beta}_1^{(0)} = 7, \hat{\beta}_2^{(0)} = 5$ とする。

$$\mathbf{y} = \mathbf{z} = \begin{bmatrix} 2 \\ 3 \\ \vdots \\ 12 \end{bmatrix}, \quad \mathbf{X} = \begin{bmatrix} \mathbf{x}_1^\top \\ \mathbf{x}_2^\top \\ \vdots \\ \mathbf{x}_9^\top \end{bmatrix} = \begin{bmatrix} 1 & -1 \\ 1 & -1 \\ \vdots & \vdots \\ 1 & 1 \end{bmatrix}$$

なので

$$\mathbf{X}^\top \mathbf{W}^{(0)} \mathbf{X} = \begin{bmatrix} 1.821429 & -0.75 \\ -0.75 & 1.25 \end{bmatrix}, \quad \mathbf{X}^\top \mathbf{W}^{(0)} \mathbf{y} = \begin{bmatrix} 9.869048 \\ 0.583333 \end{bmatrix}$$

なので

$$\begin{aligned} \hat{\boldsymbol{\beta}}^{(1)} &= [\mathbf{X}^\top \mathbf{W}^{(0)} \mathbf{X}]^{-1} \mathbf{X}^\top \mathbf{W}^{(0)} \mathbf{y} \\ &= \begin{bmatrix} 0.729167 & 0.4375 \\ 0.4375 & 1.0625 \end{bmatrix} \begin{bmatrix} 9.869048 \\ 0.583333 \end{bmatrix} = \begin{bmatrix} 7.4514 \\ 4.9375 \end{bmatrix} \end{aligned}$$

のように計算される。最尤推定値は

$$\hat{\beta}_1 = 7.45163, \quad \hat{\beta}_2 = 4.93530$$

となり, この値における \mathbf{J} の逆行列の値は

$$\mathbf{J}^{-1} = \begin{bmatrix} 0.7817 & 0.4166 \\ 0.4166 & 1.1863 \end{bmatrix}$$

となる。繰り返し計算の結果は下記のようになった。

m	0	1	2	3
$\hat{\beta}_1^{(m)}$	7	7.45139	7.45163	7.45163
$\hat{\beta}_2^{(m)}$	5	4.93750	4.93531	4.93530

□