

統計解析

古谷知之

授業概要

- * 履修者の状況に応じて変更される場合がありますが、全体としては以下のような授業構成となります。
- * 講義の中でR演習を行うこともあります。

第1回	ガイダンス・単回帰分析	第8回	一般化線形回帰モデル(5)
第2回	重回帰分析(1)	第9回	一般化線形回帰モデル(6)
第3回	重回帰分析(2)	第10回	一般化線形混合モデル
第4回	一般化線形回帰モデル(1)	第11回	状態空間モデル
第5回	一般化線形回帰モデル(2)	第12回	R演習(1)
第6回	一般化線形回帰モデル(3)	第13回	R演習(2)
第7回	一般化線形回帰モデル(4)	第14回	R演習(3)

統計モデルの種類

	主な推定方法	データ分布	回帰係数
線形回帰モデル (単回帰・重回帰など)	最小二乗法	正規分布	一変数に一つ
一般化線形モデル	最尤推定法	正規分布以外 の分布も可能	一変数に一つ
一般化線形混合モデル			変数の個体差に 応じて推定可能
階層ベイズモデル	ベイズ推定		

本授業で扱う統計モデル

- 線形回帰モデル
 - 単回帰モデル、重回帰モデル
- 一般化線形回帰モデル
 - 離散：ポアソン回帰モデル、二項反応モデル（ロジスティック回帰モデル、プロビット回帰モデル、補対数対数モデル）、負の二項分布モデル、ゼロ過剰ポアソン回帰モデル、ゼロ過剰負の二項分布モデル
 - 連続：ガンマ回帰モデル、ベータ回帰モデル、指数-ガウス回帰モデル
 - スパース：Lasso回帰モデル、Ridge回帰モデル
- 一般化線形混合モデル
 - マルチレベルモデル
- 状態空間モデル

代表的な一般化線形回帰モデル

- 被説明変数が離散変数
 - 0or1の2値：(二項)ロジスティック回帰モデル、(二項)プロビット回帰モデル、補対数対数モデル
 - 0以上の整数
 - 発生頻度が少ない：ポアソン回帰モデル、負の二項分布モデル
 - 発生頻度0が非常に多い：Hurdleモデル、ゼロ過剰モデル
- 被説明変数が連続変数
 - $[0, 1]$ の確率値：ベータ回帰モデル
 - 0より大きい値：ガンマ回帰モデル、指数-ガウス回帰モデル
- 被説明変数がスパース
 - Lasso回帰モデル、Ridge回帰モデル

一般化線形モデルの確率分布とリンク関数


モデル	被説明変数	確率分布	リンク関数
線形回帰モデル	実数	正規分布	恒等リンク
ロジスティック回帰モデル	0/1の二値	二項分布	logitリンク
プロビット回帰モデル	0/1の二値	二項分布	probitリンク
補対数対数モデル	0/1の二値	二項分布	cloglogリンク
ポアソン回帰モデル	非負の整数	ポアソン分布	logリンク
負の二項分布モデル	非負の整数	負の二項分布	logitリンク
ベータ回帰モデル	$[0,1]$ の実数	ベータ分布	logitリンク
ガンマ回帰モデル	非負の実数	ガンマ分布	逆logリンク
指数-ガウス回帰モデル	裾の長い実数	指数-ガウス分布	logリンクor 恒等リンク

授業内容

- 一般線形回帰モデルのモデル選択（ポアソン回帰モデルを例に）
- AIC
 - 最大対数尤度、逸脱度
- 尤度比検定
- Wald検定
- スコア検定


ポアソン分布

- 非常に多くの観測回数が繰り返されるが、観測ケースの発生頻度が非常に低い場合に用いられる確率分布
- 一定範囲内（時間、回数、空間）である事象が発生する平均= λ をもちいて計算される
- 試行回数 n 、発生頻度 p とすると、 $\lambda = np$
- ポアソン分布は次式で表される
$$P(y|\lambda) = \frac{\lambda^y \cdot \exp(-\lambda)}{y!}$$
- $E(y) = \lambda$ 、 $Var(y) = \lambda$



ポアソン回帰モデル

- ポアソン回帰モデルは、右図のような関係にあるデータに適用される
- 被説明変数は0以上の整数
- 適用事例
 - スポーツの得点分布
 - 感染症の感染者数
 - 事故発生件数
 - イベント来訪者数



ポアソン回帰モデル

- 被説明変数がポアソン分布に従うとするポアソン回帰モデルは、例えば次式のように表される。ここで y_i は被説明変数、 X_i は説明変数、 β は未知パラメータである

$$y_i = Po(\lambda_i)$$
$$f(y_i|\lambda_i) = \frac{\lambda_i^{y_i} \cdot \exp(-\lambda_i)}{y_i!}$$
$$g(E(y_i)) = \lambda_i = \exp(\eta_i)$$

- このとき **logリンク(対数リンク)** $\log(\lambda_i)$ と **線形予測子** $\eta_i = X_i\beta$ との関係は、次式のように対数リンク関数で表せる

$$\log(\lambda_i) = \eta_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_k x_{ik} = X_i^T \beta$$

ポアソン回帰モデルの最尤推定

- 尤度関数 L は

$$L = \prod_{i=1}^n \frac{\lambda_i^{y_i} \cdot \exp(-\lambda_i)}{y_i!} = \prod_{i=1}^n \frac{(\exp(X_i \boldsymbol{\beta}))^{y_i} \exp(-\exp(X_i \boldsymbol{\beta}))}{y_i!}$$


- 対数尤度関数 L は

$$\begin{aligned} \ln L &= \sum_{i=1}^n \left(y_i \cdot \ln \lambda_i - \lambda_i - \sum_{k=1}^{y_i} \ln k \right) \\ &= \sum_{i=1}^n \left(y_i \cdot \ln(X_i^T \boldsymbol{\beta}) - (X_i^T \boldsymbol{\beta}) - \sum_{k=1}^{y_i} \ln k \right) \end{aligned}$$

- 対数尤度関数を最大化する $\hat{\lambda}$ は
$$\frac{d \ln L}{d \lambda} = 0$$


ポアソン回帰モデルの尤度関数

- ポアソン回帰モデルの尤度関数は右図のように上に凸な関数となる
- この例では、 $\lambda = 3.0$ が最尤推定値 $\hat{\lambda}$ となる
- 最尤推定値 $\hat{\lambda}$ を代入した最大対数尤度は $\ln \hat{L} = -1101.96$



ポアソン回帰モデルの推定結果の例

- 500個のランダムなポアソン分布に従う被説明変数と正規分布に従う説明変数を用いてポアソン回帰モデルを推定
- 得られたモデルの曲線と95%信頼区間は右図のとおり



モデル間の比較

- ここで、以下のモデルを考えることにする
- 定数項のみのモデルをモデル0 (null model)
- 定数項と変数 x_1 を加えたモデル1
- x_1, \dots, x_p の p 個の変数を持つモデル p
- x_1, \dots, x_p, x_q の $q(> p)$ 個の変数を持つモデル q
- すべての変数 x_1, \dots, x_k を加えたモデル k (full model)

- モデル k 以外はreduced modelなどとも呼ばれる

モデル間の比較

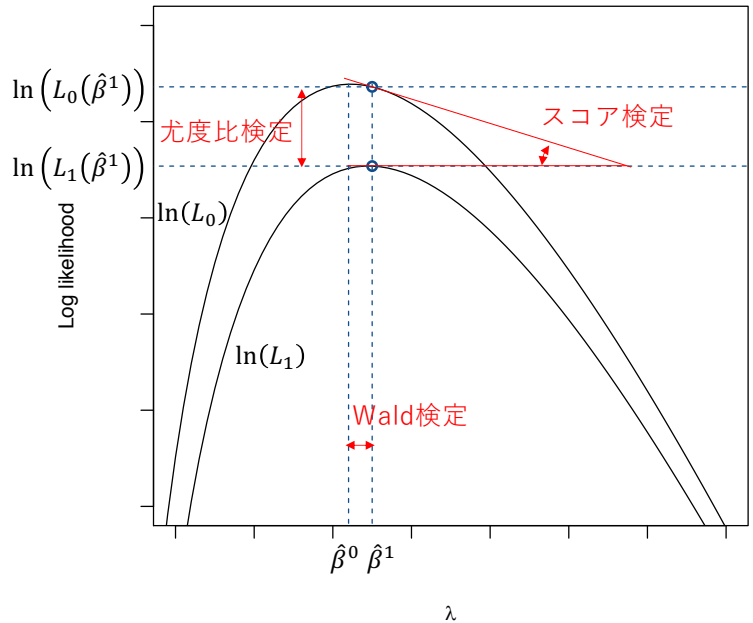
- ポアソン回帰モデルを例に挙げると、考えうる説明変数が k 個あるとき、比較対象となる対数リンク関数は以下のようなになる
- モデル0: $\log(\lambda_i) = \beta_0$
- モデル1: $\log(\lambda_i) = \beta_0 + \beta_1 x_{i1}$
- :
- モデル p : $\log(\lambda_i) = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip}$
- モデル q : $\log(\lambda_i) = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \beta_q x_{iq}$
- :
- モデル k : $\log(\lambda_i) = \beta_0 + \beta_1 x_{i1} + \dots + \beta_k x_{ip} + \beta_k x_{iq} \dots + \beta_k x_{ik}$

ネスト関係にあるモデル間の比較

- モデル1の線形予測子はモデル0の線形予測子を含む
- モデル q の線形予測子はモデル p の線形予測子を含む
- このとき、モデル1はモデル0をネスト化している、モデル q はモデル p をネスト化している、という
- ネスト関係にあるモデルを比較するときには、赤池の情報量基準 (AIC) を用いることが有効であることが知られている

一般化織系モデルの比較方法

- モデル間の比較には、尤度比検定、Wald検定、スコア検定も用いられる
- それぞれの比較方法をモデル0とモデル1で示すと、およそ右図のとおり
- **尤度比検定**：モデル0とモデル1の尤度比を検定
- **Wald検定**：回帰係数の差のWald統計量を検定
- **スコア検定**：対数尤度関数の一次導関数（スコア関数）のスコア統計量を検定



赤池の情報量基準 (AIC)

- 赤池の情報量基準AICは、対数尤度関数を最大化する解が得られた場合、対数尤度 $\ln \hat{L}$ と変数の数 k を用いて、次式で表される

$$AIC = -2\ln \hat{L} + 2k$$

- ポアソン回帰モデルの場合、最尤推定値 $\hat{\lambda}$ が得られた場合の最大対数尤度 $\ln \hat{L}$ は次式のようにになる

$$\ln \hat{L} = \sum_{i=1}^n \left(y_i \cdot \ln \hat{\lambda} - \hat{\lambda} - \sum_{k=1}^{y_i} \ln k \right)$$

赤池の情報量基準 (AIC)

- AIC はどの値が良いというわけではなく、 AIC が（相対的に）より小さい値を取るモデルが良いとされる
- 最大対数尤度は「観測データへの当てはまりが最も良いモデルを推定する」という発想
- AIC は「良い予測をするモデルが良いモデル」という発想
 - AIC は「当てはまりが良いモデル」や「真のモデル」を選ぶというわけではない

逸脱度 (deviance)

- 最大対数尤度 $\ln\hat{L}$ が得られたとき、最大対数尤度に-2を乗じたものを逸脱度 D という

$$D = -2\ln\hat{L}$$

- モデル0 (null model)のとき **最大逸脱度**
- モデル k (full model)のとき **最小逸脱度**
- モデル p とモデル q のを比較する際、各モデルの逸脱度の差 $D_{p,q}$ を考えることで、「どちらのモデルがより当てはまりが良いか」を把握することができる

逸脱度の差

- モデル q の方がモデル p よりデータへの当てはまりが良いとき、 $\ln\hat{L}^p < \ln\hat{L}^q$ となり、逸脱度の差 $D_{p,q}$ は次式であらわされる

$$D_{p,q} = -2\phi(\ln\hat{L}^p - \ln\hat{L}^q) = 2\phi(\ln\hat{L}^q - \ln\hat{L}^p)$$

- 当てはまりの良さを意味する対数尤度の差に -2ϕ をかけている
- ϕ はdispersion parameterと呼ばれるばらつきに関するパラメータであり、確率分布ごとに想定された値がある
 - 正規分布： $\phi = \sigma^2$ 、二項分布・ポアソン分布： $\phi = 1$
- パラメータを増やすほどモデルの当てはまりは良くなる

逸脱度の差

- 逸脱度の差 $D_{p,q}$ は「当てはまりの悪さの差」なので、 $\ln\hat{L}^p < \ln\hat{L}^q$ のときには、モデル p よりモデル q の方が、 $D_{p,q}$ の値の分だけ当てはまりの悪さが改善されているといえる
- 自身が提案したモデル p とフルモデル k の逸脱度との差 $D_{p,k}$ を残差逸脱度 (residual deviance) という。これは最小逸脱度を基準とする当てはまりの悪さを意味する

$$D_{p,k} = 2\phi(\ln\hat{L}^k - \ln\hat{L}^p)$$

- 最大逸脱度と最小逸脱度の差 $D_{1,k}$ をNull逸脱度 (null deviance) という

$$D_{1,k} = 2\phi(\ln\hat{L}^k - \ln\hat{L}^1)$$

過分散 (over dispersion)

- ばらつきに関する dispersion parameter ϕ は、以下の方法により計算できる

- 残差自由度 (*Residual D.F.*) と残差逸脱度の比

$$\phi = \frac{\text{Residual Deviance}}{\text{Residual D.F.}}$$

- Pearson's χ^2 値と残差逸脱度の比

$$\phi = \frac{\text{Pearson's } \chi^2}{\text{Residual D.F.}}$$

- 前者は計算が簡単だが安定性にかけることがあるため、後者のほうが正確との意見も多い

過大分散と過小分散

- 過大分散

- Dispersion parameter ϕ が想定している値より大きい場合のこと
- 本来統計的に有意でない説明変数が有意であると判断される場合（第1種の過誤）が多い
- ϕ がいくつ以上だと過大分散という明確な区分はない（1.5程度？）
- 変数に異なる種類のデータが混合している場合などに生じる

- 過小分散

- ϕ が想定している値より小さい場合のこと
- サンプル数を増やすなどする？

尤度比検定

- 尤度比検定は、2つのモデル間の尤度比を用いた検定
- 例えば、モデル0のパラメータベクトルを β^0 、モデル1のパラメータベクトルを β^1 とすると、帰無仮説 \mathcal{H}_0 と対立仮説 \mathcal{H}_1 は以下のようなになる

$$\begin{aligned}\mathcal{H}_0: \beta^0 &= \beta^1 \\ \mathcal{H}_1: \beta^0 &\neq \beta^1\end{aligned}$$

- 帰無仮説 \mathcal{H}_0 は、「モデル1とモデル0は同じ変数の組み合わせになるので、モデル1で追加した変数のパラメータは0である」ことと同じ意味
- 帰無仮説 \mathcal{H}_0 が棄却されれば、「モデル0は採用すべきでない」といえる→「モデル0ではなくモデル1を採用すべきだ」というわけではない（後ほど説明）

尤度比と逸脱度

- モデル0とモデル1の尤度関数をそれぞれ L_0 、 L_1 とする
- また各モデルの最大尤度を \hat{L}^0 ・ \hat{L}^1 、最尤推定量を $\hat{\beta}^0$ ・ $\hat{\beta}^1$ とする
$$\hat{L}^0 = L_0(\hat{\beta}^0), \hat{L}^1 = L_1(\hat{\beta}^1)$$
- 任意の点において尤度関数 L_1 は L_0 より大きくなることから、 $\hat{\beta}^1$ に関する尤度比 LR は次式のようなになる

$$LR = \frac{\hat{L}^0}{\hat{L}^1} = \frac{L_0(\hat{\beta}^1)}{L_1(\hat{\beta}^1)}$$

尤度比と逸脱度

- 尤度比 $LR = \frac{\hat{L}^0}{\hat{L}^1} = \frac{L_0(\hat{\beta}^1)}{L_1(\hat{\beta}^1)} = 1$ のとき、2つのモデルは同じになる
- このとき、モデル1 (reduced model) に含まれる変数はモデル構築の際に有効でないことを意味する
- 検定を行う際には、尤度比を対数変換した次式の逸脱度の差 $D_{0,1}$ を用いる

$$\begin{aligned} D_{0,1} &= -2\ln LR = -2(\ln \hat{L}^0 - \ln \hat{L}^1) \\ &= -2\left(\ln\left(L_0(\hat{\beta}^1)\right) - \ln\left(L_1(\hat{\beta}^1)\right)\right) \end{aligned}$$

- モデル0とモデル1とのパラメータ数の差は1個である。このとき、逸脱度 D は自由度1の χ^2 分布に従う

尤度比と逸脱度

- 逸脱度の差 $D_{0,1}$ はどう解釈すればよいか？

$$\begin{aligned} D_{0,1} &= -2\log \lambda = 2(\ln \hat{L}^0 - \ln \hat{L}^1) \\ &= -2\left(\log\left(L_0(\hat{\beta}^1)\right) - \log\left(L_1(\hat{\beta}^1)\right)\right) \end{aligned}$$

- 逸脱度は「当てはまりの悪さ」を意味する（≠当てはまりの良さ）→当てはまりの良さを意味する対数尤度に-2をかけている
- 逸脱度の差は「当てはまりの悪さの差」なので、 $D_{0,1}$ の値が大きいほどモデル1の方が当てはまりの悪さが（ $D_{0,1}$ の値の分だけ）改善されているといえる

尤度比と逸脱度

- モデル q の方がモデル p よりデータへの当てはまりが良い ($\ln\hat{L}^p < \ln\hat{L}^q$) とする
- 変数が p 個のモデル p と変数が $q(> p)$ 個のモデル q を比較する場合、その逸脱度の差 $D_{p,q}$ は自由度 $q - p$ の χ^2 分布に従う

$$\begin{aligned} D_{p,q} &= -2\log\lambda = -2(\ln\hat{L}^p - \ln\hat{L}^q) \\ &= -2\left(\log\left(L_p(\hat{\beta}^1)\right) - \log\left(L_q(\hat{\beta}^1)\right)\right) \sim \chi^2(q - p) \end{aligned}$$

- χ^2 検定を用いてモデル間の差が統計的に有意であるかどうかを把握することができる (ただし、サンプル数が多い場合)
- χ^2 検定の結果、 p 値 < 0.05 だと95%水準で有意となり帰無仮説 \mathcal{H}_0 は棄却できる→モデル0を採用しない (モデル1を採用すべきかはさらに検討が必要)

分散分析 (ANOVA)

- 尤度比を用いて説明変数を抜く場合、分散分析ANOVAを用いることがある
- TYPE I
- TYPE II
- TYPE III

統計的過誤

- 第一種の過誤（偽陽性）は、有意水準 α により検出可能
- 対立仮説 \mathcal{H}_1 が正しいときに第二種の過誤（偽陰性）を犯さない確率を検出力 $1 - \beta$ という
- 第二種の過誤を犯す確率 β は直接計算できないが、有意水準 α と帰無仮説 \mathcal{H}_0 が主張する仮定と真実との解離度に依存する

仮説検定の結果	真実	
	\mathcal{H}_0 が正しい	\mathcal{H}_1 が正しい
\mathcal{H}_0 を棄却する	第一種の過誤 確率：有意水準 α	正しい検出結果 確率：検出力 $1 - \beta$
\mathcal{H}_0 を棄却しない	正しい検出結果 確率： $1 - \alpha$	第二種の過誤 確率： β

有意水準 α の設定と統計的判断


- 有意水準 α は、分析者が分析の精度に応じて任意に設定できる
- この授業では $\alpha = 0.05$ を多く使うが、それは信頼区間を95%に設定しておけば、そこから外れるような事象はほとんど起きないだろうと「勝手に」想定しているから
- 社会科学分野では便宜上 $\alpha = 0.05$ を多用するが、 $\alpha = 0.1$ や $\alpha = 0.001$ などであってもよい。
- 医療・薬学分野などでは、非常に小さい有意水準（ $\alpha = 0.001$ など）が採用されることがある
- 有意水準を小さくすれば、統計的判断が厳しくなり、例えば冤罪や偽陽性などの誤検出の可能性を少なくできる。他方、完全犯罪や偽陰性（検出失敗）を増やしてしまう。

統計的過誤

- 第一種の過誤（偽陽性）：帰無仮説 \mathcal{H}_0 が正しいにもかかわらず帰無仮説 \mathcal{H}_0 を棄却してしまう誤り
- 第二種の過誤（偽陰性）：帰無仮説 \mathcal{H}_0 が正しくないにもかかわらず帰無仮説 \mathcal{H}_0 を棄却できない誤り


仮説検定の結果	真実	
	\mathcal{H}_0 が正しい	\mathcal{H}_1 が正しい
\mathcal{H}_0 を棄却する	第一種の過誤 確率：有意水準 α	正しい検出結果 確率：検出力 $1 - \beta$
\mathcal{H}_0 を棄却しない	正しい検出結果 確率： $1 - \alpha$	第二種の過誤 確率： β

統計的過誤と有意水準 α



- 有意水準が厳しくなると、第一種の過誤の確率 α は小さくなるが、第二種の過誤の確率 β は大きくなる（トレードオフの関係）

統計的過誤と標本サイズ



- 帰無仮説の標本分布を知ることができないので動かさないが、標本数を増やし分散を小さくすることで、 α は一定でも β を小さくできる

Wald統計量

- パラメータを採用すべきかどうかは、帰無仮説 $\mathcal{H}_0: \hat{\beta} = 0$ を棄却すればよい
- パラメータの最尤推定量 $\hat{\beta}$ をその標準誤差 $SE_{\hat{\beta}}$ で割った $z = \frac{\hat{\beta}}{SE_{\hat{\beta}}}$ 値は平均 z 、分散1の正規分布に従う
- 帰無仮説 $\mathcal{H}_0: \hat{\beta} = 0$ のもとでは、 Z 値は平均0、分散1の標準正規分布に従う
- Z 値を2乗した Z^2 値をWald統計量 W といい自由度1の χ^2 分布に従う

$$W = Z^2 = \left(\frac{\hat{\beta}}{SE_{\hat{\beta}}} \right)^2 \sim \chi^2(1)$$

Wald統計量

- z 値の絶対値またはWald統計量は、0より大きければ多いほど、帰無仮説を棄却できると言える
- z 値の確率分布について、0以下の区間 $Pr(< |z|)$ は、 z 値（あるいはWald統計量の）信頼区間と近似的に考えることができる
- $Pr(< |z|)$ が小さいほど、帰無仮説 $\mathcal{H}_0: \hat{\beta} = 0$ を棄却することができ、 z 値（あるいはWald統計量）は統計的に有意であると見立てることができる

Wald統計量

- 一般に説明変数 p 個のモデル p のパラメータ $\hat{\beta}^p$ のWald統計量 W は、次式のように表される

$$W = (\hat{\beta}^p)' [Cov(\hat{\beta}^p)]^{-1} \hat{\beta}^p = (\hat{\beta}^p)' (XV'X) \hat{\beta}^p$$

- このとき、Wald統計量 W は自由度 $p + 1$ の χ^2 分布に従う

Wald統計量

- $p = 1$ のとき、 $[Var(\hat{\beta}^{p=1})]^{-1} = \begin{bmatrix} \phi_{00} & \phi_{01} \\ \phi_{10} & \phi_{11} \end{bmatrix}$ とすると、Wald統計量 W は以下のようなになる

$$\begin{aligned} W &= \begin{pmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \end{pmatrix}' \begin{bmatrix} \phi_{00} & \phi_{01} \\ \phi_{10} & \phi_{11} \end{bmatrix} \begin{pmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \end{pmatrix} \\ &= \hat{\beta}_0^2 \phi_{00} + \hat{\beta}_0 \hat{\beta}_1 \phi_{01} + \hat{\beta}_0 \hat{\beta}_1 \phi_{10} + \hat{\beta}_1^2 \phi_{11} \\ &= \frac{Var(\hat{\beta}_1) \hat{\beta}_0^2 + Var(\hat{\beta}_0) \hat{\beta}_1^2 - Cov(\hat{\beta}_0, \hat{\beta}_1) \hat{\beta}_0 \hat{\beta}_1}{Var(\hat{\beta}_0) Var(\hat{\beta}_1) - Cov^2(\hat{\beta}_0, \hat{\beta}_1)} \end{aligned}$$

Wald統計量

- fullモデル k のパラメータ $\hat{\beta}^k$ に対して reduced モデル q のパラメータ $\hat{\beta}^q$ を比較したいとき
- 帰無仮説 $\mathcal{H}_0: \hat{\beta}^q = \hat{\beta}^k$ が成り立つなら $E[\hat{\beta}^q] = \hat{\beta}^k$ となる
- Wald統計量 W は、次式のように表される

$$W = (\hat{\beta}^p - \hat{\beta}^k)' [Cov(\hat{\beta}^p)]^{-1} (\hat{\beta}^p - \hat{\beta}^k)$$

- このとき、Wald統計量 W は自由度 $k - p$ の χ^2 分布に従う

スコア検定

- 対数尤度関数の一次導関数をスコア関数 U という
- 任意の説明変数変数 $j = (1, \dots, k)$ の回帰係数 β_j のスコア関数 $U_j(\boldsymbol{\beta})$ は、次式のように表せる

$$U_j(\boldsymbol{\beta}) = \frac{\partial \ln L}{\partial \beta_j} = 0$$

スコア検定

- ポアソン回帰モデルの対数尤度関数 L は

$$\begin{aligned} \ln L &= \sum_{i=1}^n \left(y_i \cdot \ln \lambda_i - \lambda_i - \sum_{k=1}^{y_i} \ln k \right) \\ &= \sum_{i=1}^n \left(y_i \cdot \ln (X_i^T \boldsymbol{\beta}) - (X_i^T \boldsymbol{\beta}) - \sum_{k=1}^{y_i} \ln k \right) \end{aligned}$$

- スコア関数は次式のようになる

$$U_j(\boldsymbol{\beta}) = \frac{\partial \ln L}{\partial \beta_j} = \sum_{i=1}^n \left(\frac{(y_i - \lambda_i) X_{ij}}{\text{Var}(y_i)} \cdot \frac{\partial \lambda_j}{\partial \eta_j} \right)$$

スコア検定

- スコア統計量を用いてパラメータを採用すべきかどうかを仮説検定するとき、棄却すべき帰無仮説は $\mathcal{H}_0: E[U_j(\hat{\beta})] = 0$ となる
- 説明変数 p 個のモデル p のパラメータ $\hat{\beta}^p$ に関するスコア統計量は次式のように表される

$$U_j(\hat{\beta}^p)' [Cov(U_j(\hat{\beta}^p))]^{-1} U_j(\hat{\beta}^p) = U_j(\hat{\beta}^p)' (XV'X) U_j(\hat{\beta}^p)$$

- このとき、スコア統計量は自由度 $p + 1$ の χ^2 分布に従う