



図 A 2.2 正規モデルの単一データについて対数尤度のグラフ

$$\log L(\mu) = \log(0.3989) - \log(15) - \frac{1}{2} \frac{(175 - \mu)^2}{15}$$

$\log L(\mu)$ の最大値は $\mu = 175$ のところである。これは別に驚くことではない。単一のデータしかなければ、それが平均の最良推定になる。

これに対応する対数尤度比は次のようになる^(*)。

$$\log LR(\mu) = -\frac{1}{2} \frac{(175 - \mu)^2}{15} \quad (\text{A 2.1})$$

μ の値を変えたものを、図 A 2.2 に示した。この種の曲線は 2 次 (quadratic) であるという。

データ x_1, x_2, \dots, x_n があれば、次のようになる。

$$\log LR(\mu) = -\frac{1}{2} \frac{\sum (x_i - \mu)^2}{15}$$

この尤度を最大化 (maximise) するということは、右辺の和を最小化

訳注：尤度比の分母は $\mu = 175$ のため $\log(L(\mu_{\max})) = \log(0.3989) - \log(15)$ となり、この項は尤度比の分子と相殺されるため。

(minimise) することになる。右辺符号がマイナスのためである。負の値であれば絶対値が小さいほうが大きくなる（ -1 は -2 よりも大きい）。こうして、データの平方和を最小化する μ の値を選ぶ必要がある。これは第2章で述べた最小二乗法（principle of least squares）であり、尤度の最大化に等しい。

仮説検定：尤度比検定

先に述べた母集団における身長の実の分布が正規分布で、平均 μ_0 だったとしよう。そうすると (A 2.1) 式より、対数尤度比の観察値は次のように計算できる。

$$\log LR(\mu_0) = -\frac{1}{2} \frac{(175 - \mu_0)^2}{15}$$

仮説検定統計量を計算する前に、まず私たちは正規分布に関する大変有用な結果を使わないといけない。その結果とは何かというと、正規分布を仮定すると

$$-2 \times (\text{対数尤度比の観察値})$$

は自由度 1 の χ^2 分布に従うということである。

μ_0 は 170 としよう。そうすると、 $-2 \times$ 対数尤度比は $2 \times (175 - 170)^2 / (2 \times 15) = 25/15 = 1.67$ になる。この値は、自由度 1 の χ^2 分布の 5% 水準値である 3.84 より大変小さい。したがって、175 というデータでは帰無仮説 $\mu_0 = 170$ を棄却できない。

出生データに戻って、帰無仮説が $\pi_0 = 0.5$ 、つまり男の子と女の子は同数だとしよう。対数尤度は $2 \times \log(0.5) + 3 \times \log(0.5) = -3.4657$ なので、対数尤度比は $-3.4657 - (-3.3651) = -0.1006$ である^(註)。正規でないデータであっても、 $-2 \times (\text{対数尤度比の観察値})$ が χ^2 分布に従うことは近似としては正しい。例数が増えれば増えるほど、その近似は良

訳注：124 頁の最大対数尤度が -3.3651 を用いて。

くなる。

ここで $-2 \times \log LR = 0.20$ なので、これは χ^2 値の 3.84 より随分小さい。したがって、私たちは帰無仮説を棄却できない。しかしこの場合、 χ^2 分布への近似は少数例ゆえあまり良くない。図 A 2.1 が 2 次曲線から随分外れていることから、直観的にそのことは分かる。例数が増えれば、それは 2 次曲線に近づくはずである。

対数尤度は、モデルの適合度 (goodness-of-fit) の指標である。対数尤度が大きければ、モデル当てはめはより良くなる。対数尤度の絶対値自身はあまり意味がないので、他のモデルと比較した対数尤度比を示すことが多い。多くのプログラムでは乖離 (deviance) も示すが、これは当てはめたモデルと飽和モデルの対数尤度比の (-2) 倍である。飽和モデルでは、そのモデルは最大数のパラメータを含んでいる。すなわち、データ数と同じだけのパラメータを含む。上の出生データでいうと、飽和モデルは 5 つのパラメータをもつ。このとき尤度は 1 であり、対数尤度は 0 であった。したがって、乖離はこのモデルの対数尤度の (-2) 倍に等しい⁽²⁰⁾。この乖離には自由度があり、それは飽和モデルのパラメータ数とこのモデルのパラメータ数の差に等しい。

乖離は当てはまりの悪さを示しており、当てはまりの良さを示している指標ではない。乖離が大きければ、当てはまりが良くないことを意味する。もしあるモデルが別のモデルの一部であるなら、この乖離の差で比較することができる。モデルの一部というのは、大きいほうのモデルが小さいほうのモデルのパラメータを含んでいるときに言う。乖離の差は、2 つのモデルに関する対数尤度比の (-2) 倍である。なぜなら、飽和モデルの対数尤度は両方の乖離に現れるのでキャンセルされるためである。この検定の自由度は、2 つの乖離の自由度の差になる。

訳注：乖離は (モデルの対数尤度 - 飽和モデルの対数尤度) \times (-2) であり、飽和モデルの対数尤度はここではゼロのため。

ワルト検定

データが正規分布でなければ、対数尤度比の型はもはや2次曲線ではなくなる。しかし、図 A 2.1 に見られるように、例数が大きければほぼそのような型になる。このため、真の尤度より2次式近似を用いたほうが簡単というメリットがある。

確率モデルのパラメータ θ の尤度を考え、 M を θ の最もそれらしい値としよう。シンプルな2次式とは以下のようなになる。

$$\log LR(\theta) = -\frac{1}{2} \left(\frac{M - \theta}{S} \right)^2$$

これは $M = \theta$ で最大値0をとり、真の対数尤度比を近似するために使われる。パラメータ S は推定値の標準誤差であり、曲線を標準化するために使われる。この値が小さければ2次曲線の鋭い山を意味し、大きければ平らな山になる。 S は真の尤度に対して、その近辺の範囲で最良の近似 (in the region of its most likely value) になるよう選ぶ。

二値データであればどうか。 N 人中 D イベントがあったとすると、 M と S は次のようになる。

$$M = D / N$$

$$S = \sqrt{\frac{M(1 - M)}{N}}$$

したがって、 $N = 5$ で $D = 2$ ならば、 $M = 0.4$ と $S = 0.22$ になる。

$\theta = 0.5$ という帰無仮説の下で、 $-2 \times \log LR$ は次のようになる。

$$\left(\frac{0.4 - 0.5}{0.22} \right)^2 = 0.21$$

これは、前頁の対数尤度比 0.20 に近い。同じく統計的には非有意である。この検定が普通に用いられるのは、プログラムが自動的にパラメータの標準誤差を算出するためである。この検定は Swinscow 本²で述べている、 $b/SE(b)$ による z 検定に等しい。

スコア検定

スコア検定はそれほどよく出てこないもので、あまり詳しく述べないことにする。この検定は、帰無仮説における対数尤度比曲線の勾配に基づく。この勾配のことを U と書き、スコアとよぶ。パラメータの帰無値 θ_0 における勾配値がスコアである。最大値での曲線の勾配は0なので、帰無仮説が最もそれらしい値に一致すると、 U はちょうど0になる。スコア検定においては、帰無仮説の下で U^2/V が近似的に自由度1の χ^2 分布に従うことを利用する。ここで、 V とはスコアの標準誤差推定値の2乗である。

どの方法を選んだらよいか？

非正規データの場合、上に述べた方法はすべて近似にすぎない。対数尤度比法の利点としては、パラメータが変換されても（例えば、対数変換） P 値は同じになることである。そこで、この方法が好まれる。もし3つの方法がかなり異なっていたら、それは帰無および尤もらしい値で、2次近似では真の対数尤度曲線を十分近似できないことになる。帰無の値と尤もらしい値とが大きく離れているとき、特にそのことは正しい。こういう場合どれを選択しても、結論はそんなに変わらない。ワルト検定は適切な変換をすれば良くなる。例えば、オッズ比についてのモデルでは、対数オッズ比のモデルに直せば2次近似は改善する。そのため第3章にも述べたように、対数オッズ比のモデルが適当ということになる。

これらすべての方法で、多くのパラメータを同時に検定することができる。しかし、もしコンピュータで2つのモデルを当てはめる場合、しかも1つのモデルはもう一方のサブセットなら、それぞれのモデルについて対数尤度か乖離が通常与えられるので、2つのモデル間の対数尤度

比を求めることができる。もし大きいほうのモデルが小さいほうのモデルより2個以上パラメータが多いときには、尤度比検定は大きいほうのモデルでデータ当てはめが著しく改善するかを見ており、同時に追加分のパラメータすべてに関して検定している。

パラメータ推定値とその標準誤差はモデルの各パラメータについて与えられるので、ワルト検定はそれから求められる。このようにシンプルなワルト検定とは、同時に一つ一つのパラメータを検定するのである。複数個のパラメータを同時には検定できない。例は各章に与えられている。

信頼区間

信頼区間を求める従来のアプローチはワルト検定に基づく。母集団パラメータの近似95%信頼区間は、(推定値 $-2\times SE$)から(推定値 $+2\times SE$)で与えられる。出生データについて見ると、 $0.6-2\times 0.22\sim 0.6+2\times 0.22=0.16\sim 1.04$ となる。この近似は良くない (poor) ことは自明である。なぜなら、割合というのは1より大きくなり得ないためである (より良い近似はAltmanを参考)³。ただワルト検定であっても、適当な変換をすれば近似は良くなる。このことは第3章の対数オッズ比で示した。オッズ比そのものではなく、対数オッズ比に関して信頼区間を構成した。しかし、尤度から直接信頼区間を計算することも可能である。そこでは変換などする必要はない。これらについては時々文献中にも見られるが、詳しくはClayton and Hills¹を参照のこと。

■文献

- 1 Clayton D, Hills M. *Statistical Models in Epidemiology*. Oxford: OUP, 1993.
- 2 Swinscrow TDV. *Statistics at Square One, 9th edn* (revised by MJ Campbell). London: BMJ Books, 1996.
- 3 Altman DG, Machin D, Bryant TN, Gardner MJ, eds. *Statistics with Confidence, 2nd edn*. London: BMJ Books, 2000.

付録3：ブートストラップ法

ブートストラップ法 (bootstrapping) とは、モデルのパラメータや信頼区間を推定するためのコンピュータを駆使した方法 (computer-intensive method) である。しかもこれまで述べてきたパラメトリック法に比べて、データ分布への仮定がほとんど必要ない。最近は大変実行しやすくなり、ほとんどのソフトウェアに備わっている。

これまで述べてきたモデルはすべて、関心ある推定値の標本分布に仮定を設けている。もし症例数が大きく平均の信頼区間を推定したいなら、母集団分布が何かというのは問題にはならない。その理由は、**中心極限定理** (central limit theorem) により標本分布は近似的に正規が保証されているためである。しかし、症例数が小さいときはどうだろうか。もし母集団での分布が正規なら t 分布だと仮定できるが、もしそうでなければ、信頼区間がある信頼度で母集団値を含まないかもしれない。しかし、私たちは標本データの分布から母集団分布に関する情報をもっている。いわば「ブートストラップ (bootstrap)」推定値はこうした情報を用いる。この用語は、「独力でやり遂げる (pulling oneself up by one's bootstraps)」という起源がある。オリジナルの標本データと同じ例数のランダム標本をくり返して作る。ランダム標本を作るときにはコンピュータを用いて行うが、その際に反復を許すのである。文献としては、Efron and Tibshirani¹ と Davison and Hinkley² が適当であろう。

標本が母集団から取られるのと同じ手法により、観察データからブートストラップ標本を選んでくる。「反復して (with replacement)」というのは、どのデータも2回以上選ばれることを意味する。もし反復を許さずサンプルを選ぶと、オリジナルデータのランダムな並び替えにすぎない。したがって、平均などを取っても全く等しくなってしまう。「反復

付録3：ブートストラップ法

して (with replacement)』選ぶという方法は、もしデータが独立であれば最適な方法であることが分かる。もし独立でなかったら他の方法が必要となるが、それはこの付録の範囲を超える。標準誤差 (SE) あるいは信頼区間は、ブートストラップ標本から得られる統計量のバラツキで推定する。ブートストラップのポイントは何かというと、いろいろな値を作りだして、そのバラツキで標準誤差を得るということである。これは、標本を母集団からくり返し抽出するのと同じ要領なのである。

平均値の95% 信頼区間を求めるとしよう。今あるデータからランダム標本 (オリジナルデータと同サイズで) を作り、それについて平均値を計算する。この作業を例えば999回くり返す。そうすると999個の平均値が得られる⁽⁹⁹⁹⁾。それを小さい順に並べると、25番目と975番目の範囲がブートストラップ95% 信頼区間になる。これはパーセント法 (percentile method) と呼ばれ、分かりやすいが、バイアスをもつので最適な方法ではない。そこでそのバイアスを推定し、補正しないとけない。そうした方法はバイアス修正法 (bias corrected method) やバイアス修正改善法 (bias corrected and accelerated (BCa) method) として知られる。後者のほうがよく使われるだろう。また『パラメトリック・ブートストラップ (parametric bootstrap)』というのもある。ここではパラメータの標準誤差を推定するために、パラメトリックモデル (parametric model) の残差をブートストラップする。一例を挙げると、重回帰の回帰係数の標準誤差を推定するような場合である。

上に述べたような方法を用いると、割合やメジアンや平均値の差など推定値に対して、ブートストラップP値と信頼区間が求まる。その時の仮定としては、データが独立であることと同一の母集団からのデータであることがある。

必要標本数は推定値のタイプに依存する。平均値の信頼区間については50~200例で十分だが、たとえば2.5%または97.5%点の信頼区間

訳注：オリジナルデータから平均値が1つ得られるので、全部で1000個になる。

では 1,000 例ほど必要である。

【例】

Dale ら³による 11 人のランナーの β -endorphin 濃度を考えてみよう。Altman らの本の第 13 章⁴に見られる。ブートストラップを使って中央値の 95% 信頼区間を計算してみると、次のようになる。

ベータ・エンドルフィン濃度 (pmol/l)	中央値
元データ : 66, 71.2, 83, 83.6, 101, 107.6, 122, 143, 160, 177, 414	107.6
ブートストラップ 1 : 143, 107.6, 414, 160, 101, 177, 107.6, 160, 160, 160, 101	160
ブートストラップ 2 : 122, 414, 101, 83.6, 143, 107.6 101, 143, 143, 143, 107.6	122
ブートストラップ 3 : 122, 414, 160, 177, 101, 107.6, 83.6, 177, 177, 107.6, 107.6	122
など 999 回	

中央値を小さい順に並び替える。1,000 個の値の 25 番目から 975 番目が、95% 信頼区間のパーセント推定になる。999 回繰り返すことで、BCa 法で 95% ブートストラップ信頼区間は 71.2~143.0 pmol/l だとわかる。Altman ら⁴が第 5 章で示した通常の方法では 71.2~177 pmol/l なので、標準的方法でも下限のほうは多分よいかもしれないが、上限は少し高めなことを示唆している。もし標準的方法とブートストラップ法とが一致すれば、私たちはその推論に自信がもてる。

付録3：ブートストラップ法

これがブートストラップの重要な使い方である。もし一致しなければちょっと注意が必要になる。しかし、ブートストラップ法に課せられている仮定は比較的シンプルなので、こちらのほうが一般的にはお勧めであろう。

母集団の中央値推定量としてベストなのは、ブートストラップ推定と思うかもしれないが、実はそうではないのである。標本中央値こそが、母集団中央値のベストな推定値として引用すべきなのである。

ブートストラップの主な利点とは、推論する際、推定値の分布について不適切な仮定を置いたりしなくてもよい点にある。特に公式がないときには、ブートストラップは最大のメリットがある。公式が近似式のときでも、より良い推定値が得られるだろう。

いわゆる「ナイーブ (naive)」ブートストラップでは、その標本は研究母集団からの不偏であって、しかも単純確率標本であることを仮定している。層別確率サンプリングのような複雑なサンプリングではそうはいかない。そこでもっと複雑なブートストラップが必要となる。大変小さな標本（まあ9例未満）では、ナイーブなブートストラップはうまくいかないだろう。なぜなら、そのように小さな標本は研究母集団の代表とは思えないからである。「大変小さな標本では、あまりよくフィットしていないパラメトリック解析でも、ノンパラメトリック解析よりすぐれているだろう。バイアスについて許容値を犠牲にした代わりに、結果のバラツキを低く抑えたことで優れている」。

医学研究でブートストラップをよく用いるのは、多分何か導出した統計量（例えば、費用対効果比）に関する信頼区間を計算するときである。その理論分布を数学的に示すのは難しいときである。また、ブートストラップ標本のいくつかで分母がゼロに近くなるときには、注意が必要である。

ブートストラップの実際

医療経済の分野で Lambert ら⁵ は、活動型リウマチ患者における 1 人当たりの医療費は 1,789 ポンド^(註)、ブートストラップ 95% 信頼区間は 1,539~2,027 ポンド (1,000 回の反復) と報告した。この医療費は大変歪んだ分布をしているので、彼らはブートストラップ法を用いたのである。しかし、どのブートストラップ法を用いたかは述べていなかった。

文献中のブートストラップを報告するには

- パーセント法あるいはバイアス補正法など、用いた方法を示すこと。
- 反復の回数を述べること。

■文献

- 1 Efron B and Tibshirani RJ. *An Introduction to the Bootstrap*. New York: Chapman and Hall, 1993.
- 2 Davison A, Hinkley D. *Bootstrap Methods and their Applications*. Cambridge: Cambridge University Press, 1997.
- 3 Dale G, Fleetwood JA, Weddell A, Ellis RD, Sainsbury JRC. β -endorphin: a factor in "fun-run" collapse. *BMJ* 1987; 294: 1004.
- 4 Altman DG, Machin D, Bryant TN, Gardner MJ, eds *Statistics with Confidence, 2nd edn*. London: BMJ Books, 2000.
- 5 Lambert CM, Hurst NP, Forbes JF, Lochhead A, Macleod M, Nuki G. Is day care equivalent to inpatient care for active rheumatoid arthritis? Randomised controlled clinical and economic evaluation. *BMJ* 1998; 316: 965-9.

訳注：1 ポンド 180 円として約 32 万円。

付録 4 : ベイズ流の方法

まず、頭痛の治療に関する同サイズの臨床試験二つを考えてみよう。一つは頭痛薬とプラシーボとの比較試験、もう一つはホメオパシー治療とプラシーボとの比較試験である。しかも、どちらも同じP値(<0.05)だったとする。このときあなたはどちらを信じるだろうか。この本でも述べてきた従来の頻度論的アプローチをとる限り、実験前に抱いていた治療効果の信念を加味することはできない。しかし、ベイズ流の方法 (Bayesian methods)¹ を用いればそれが可能になる。

ベイズの定理は1763年、トマス・ベイズの死後に出た論文で知られるようになった。トマス・ベイズとは、Tunbridge Wells出身の非国教徒の神父である。彼の唱えたことは、確率論ではシンプルで議論の余地もない結果である。すなわち、**実験前** (a priori) の事象確率と、**実験後** (a posteriori) の事象確率とを関連付けるものである。事前と事後をリンクするのが尤度 (likelihood) ([付録2] に述べた) である。この定理の応用に関して、特に何年ものあいだ議論の的になってきた。最近になってやっと、公平で実践的な見方が出てくるようになってきた²。

ベイズの定理が応用されるのが多いのは、診断検査の分野である。患者が特定の病気を有していると医師が事前にもつ信念 (某地区でのその病気の有病率の知識と、その患者の症状に基づいて) が、検査結果で修飾される³。このベイズ定理を使えば、「新治療が旧治療より優れている確率は0.95である」などと言うことができる。従来の (頻度論) アプローチで計算される95%信頼区間は、ある意味で「パラメータの真値が95%の確信度で入っている区間」、と解釈できる⁴。このようにして、ベイズ流のアプローチから意思決定に最適な結果が得られる。ベイズ法では、研究データに外部情報あるいは判断を加味して解釈する。した

がって、結論の導きだし方は意思決定に自然に向いている⁵。事前の仮定に対する尤もらしさを勘案するのである。それは診断検査の解釈と同じである。あまりに治療効果が大きいときの疑惑はちゃんと表現するし、驚きの結果を注意深く解釈するうえでも役立っている。

ベイズ流の方法を用いるときの難点の1つは、事前分布の選択である。解析する人によって違う事前分布を使えるので、同じデータにもかかわらず研究者によって異なる結論になりかねない。ふつうに使われるのは、情報のない事前分布 (uninformative prior) である。それは、取りうるすべての値に等しい確率を当てたものである⁽⁶⁾⁽⁷⁾。これを使えば、臨床判断に基づくような事前分布よりは主観的ではなくなる。ベイジアンと頻度論者には哲学上の違いがある。それは確率についての考え方の違いなどであるが、いずれにせよ、データをよく見て解釈することには異論はなかろう。

ベイズ流の考え方を臨床試験に応用すると、従来の方法よりも柔軟かつ論理的な解釈が得られるかもしれない。

ベイズ流の方法が従来の方法を凌駕することはないが、補完し合うだろう。この本でこのあたりの議論で関係するのは、第5章の変量効果モデルのところである。詳しいことは Berry and Stangl⁷ をみられたい。

文献にベイズ流の方法を報告するには

- 実験前の確率を報告し、それをどのようにして決めたかを述べること。たいていの場合は、事前分布を何にしたかということが最終結論に影響することは少ない。なぜなら、実験で得られた情報のほうのウェイトが大きいからである。
- 実験後の確率とその区間を報告しなさい。事後分布の最頻値(モード)が報告されることが多い。それに加えて、2.5 および 97.5 パーセント

訳注：一様分布のこと。

点(95%予測区間)を示す。事後分布をプロットするのもよいかもしれない。

■文献

- 1 Bland JM, Altman DG. Bayesians and frequentists. *BMJ* 1998; 317: 1151-2.
- 2 Spiegelhalter DJ, Myles JP, Jones DR, Abrams KR. Methods in health service research: an introduction to Bayesian methods in health technology assessment. *BMJ* 1999; 319: 508-12.
- 3 Campbell MJ, Machin D. *Medical Statistics: A commonsense approach, 3rd edn.* Chichester: John Wiley, 1999.
- 4 Burton PR, Gurrin LC, Campbell MJ. Clinical significance not statistical significance: a simple Bayesian alternative to P values. *J Epidemiol Community Health* 1998; 52: 318-23.
- 5 Lilford RJ, Braunholtz D. The statistical basis of public policy: a paradigm shift is overdue. *BMJ* 1996; 313: 603-7.
- 6 Kadane JB. Prime time for Bayes. *Control Clin Trials* 1995; 16: 313-18.
- 7 Berry DA, Stangl DK. *Bayesian Biostatistics.* New York: Marcel Dekker, 1996.
- 8 Hughes MD. Reporting Bayesian analyses of clinical trials. *Statist in Med* 1993; 12: 1651-63, .

索引

- あ 行
- アスベスト 77
安定 12
- 一元配置分散分析 28
一般化最小二乗法 113
一般化推定式 85, 93
一般化線形モデル 3
- うつ病 29, 91
打ち切りデータ 69
運動療法 98
- 影響データ 33
影響度 15, 33
影響統計量 56
- オッズ 44
オッズ比 45
横断時系列モデル 94
- か 行
- カテゴリー 4
 Kaplan-Meier 72
回帰 2
回帰パラメータ 2
- 回帰モデル viii
回帰係数 16
開業医 54
階層的データ構造 86
乖離 122, 128
乖離残差 78
確率 43
過剰分散 53
加速故障モデル 77
加法的 52
監査 9
冠動脈死 103
感度検定 64
感度分析 64
- 気管支拡張器 63
擬似 R² 値 49
基準ハザード 71
基点 102
帰無仮説 6
級内相関 87
吸入ステロイド薬 92
共分散分析 15
共変量 93
近似相対リスク 64
- クラスター 89
クラスター別モデル 85

索引

グループ化 47
グループ別ロジスティック回帰
103
群内相関 87

ケースコントロール研究 43
傾向 111
経口避妊薬 65
系列相関 112
研究デザイン viii
検証的解析 9

コイン投げ 44
コックスモデル 69
コックス回帰 viii
コックス回帰モデル 72
コックス比例ハザードモデル 69
コード化 39
コンピュータを駆使した方法
133
降圧薬 90
効果修飾 52
交換可能 95
交換可能モデル 87
高血圧 1
交互作用 20
交絡因子 1
誤差 3
個人間 85
個人間変動 90
個人内 85
個人内変動 90
個人別データ 44
固定効果 59
固定効果モデル 88

混合モデル 87

さ 行

サンドイッチ推定値 93
最小二乗 16
最小二乗原理 23
最小二乗法 112, 127
最尤推定 123
最尤法 94
残差 3, 33
残差分散 53

自家製 11
死腔 18
時系列 31
時系列回帰 101
自己回帰モデル 90, 113
自己回帰過程 112
自殺 66
事象 69
自然対数 120
事前分布 139
実験後 138
実験前 138
質的データ 4
重回帰 viii
従属変数 2, 15
自由度 123
自由度調節済み 24
周辺モデル 85
出力変数 1
受動喫煙 59
瞬間死亡率 71
順序 5

- 順序回帰 viii, 101
 条件付きロジスティック回帰
 43, 60
 条件付き尤度 60
 情報のない打ち切り 70
 情報のない事前分布 139
 乗法的 52
 職業 49
 食事療法 8
 死力 71
 診断統計量 35
 人年 101
 人年分のリスク 71
 信頼区間 7

 スコア化 5
 スコア検定 7
 スコア統計量 50
 ステップワイズ回帰 36
 ストレス 1
 睡眠障害 51
 頭痛 138

 セミパラメトリックモデル 70
 正確法 63
 精神疾患 111
 生存時間 69
 生存時間解析 54
 説明変数 16
 線形モデル 3
 線形重回帰 15
 線形予測子 16
 喘息 18

 相対ハザード 76

 相対リスク 45, 64, 72
 層別コックスモデル 77

 た 行
 ダミー変数 15
 対数 119
 対数線形モデル 56
 対数尤度比 127
 大腸がん 74
 第1種の過誤 90
 高いてこ比 33
 多枝選択問題 40
 多重検定 28
 多水準モデル 87
 探索的解析 9
 断面調査 46

 中心極限定理 133
 中皮腫 82
 調整済みR² 25
 超二項変動 53, 106
 直線回帰 49

 てこ比 15, 33
 定義のインデックス 111
 適合度 53, 128
 適合度検定 76

 トマス・ベイズ 138
 統計モデル 1
 糖尿病 7, 91
 独立変数 2, 15

索引

な行

ナイーブ 136
 二項分布 45, 122
 二値 4
 乳がん 65
 入力変数 1, 15
 妊娠 30
 認知行動療法 13

は行

はじめて学ぶ医療統計学 vii, 3
 バイアス修正法 134
 バイアス修正改善法 134
 ハザード 70
 ハザード率 71
 バックワード回帰 36
 パラメータ 2
 パラメトリック・ブートストラップ
 134
 肺機能 17, 88
 曝露 57
 外れ値 33
 発生率の比 103
 反復測定 31
 判別分析 47
 比 5
 比尺度 108
 非正規分布 4
 表形式データ 44
 標識変数 15

標準化回帰係数 29
 標準死亡比 102
 費用対効果比 136
 標本 44
 比例オッズモデル 107
 比例ハザード 72
 比例ハザードモデル 69
 頻度データ 4, 108
 頻度論 viii
 頻度論的 10

フォワード回帰 36
 ブートストラップ信頼区間 135
 ブートストラップ法 10
 ブートストラップP値 134
 プロビット 54
 不一致 61
 不等分散 31
 部分尤度 73
 不偏 136
 分散分析 15
 分点 108

ペア 61
 ベイズの定理 138
 ベイズ法 viii
 ベイズ流 10, 94, 138
 ベキ乗 119
 ベースライン 22
 平方和 48
 変量係数モデル 87
 変量効果モデル 54, 86
 変量効果ロジスティック回帰 94
 変量切片モデル 87

ポアソン回帰 viii, 101
 ポアソン分布 102
 飽和モデル 105, 123, 128
 母集団 2
 補助的パラメータ 110
 母乳 47
 哺乳瓶 47

ま行

マクネマー検定 60
 マッチング 47
 マルチンゲール残差 78
 前向き研究 72
 メタアナリシス 58
 名義 4

や行

有意性検定 50
 尤度比 49, 124
 尤度比検定 7, 131
 要約指標 92
 予測変数 16, 85

ら行

リウマチ 136
 リスク期間 102
 リンク 122
 離散データ 3
 量的データ 4
 量的離散 12

量的離散変数 102
 臨床試験 9
 臨床的に有意 12

累積ロジットモデル 107

ログランク検定 69
 ロジスティック回帰 viii, 43
 ロジット変換 45

わ行

ワイブル分布 77
 ワルト検定 6, 7
 ワルト信頼区間 50
 ワルト統計量 50

欧文

APACHE 54
 at risk 101
 BMI 30
 Breslow の方法 74
 Cochrane-Orcutt 113
 CONSORT 声明 11
 Cornfield 92
 dbeta 56
 Durbin-Watson 検定 31
 Gauss 94
 gee 94