

## 研究

数理統計学の中でノンパラメトリック及びセミパラメトリック論に特に興味がある。その内容をまず次で論述する。

### パラメトリック・ノンパラメトリック・セミパラメトリック

確率変数  $X_i$  が連続型の密度関数  $f(x - \mu)$  ( $i = 1, \dots, n$ ) をもち、各  $X_i$  は互いに独立である 1 標本の単純なモデルを例に採って説明する。ここでは  $f(x)$  は 0 について対称、すなわち、 $f(-x) = f(x)$  を仮定するものとする。このとき、 $E(X_i) = \int_{-\infty}^{\infty} xf(x - \mu)dx = \mu$  となり、 $\mu$  は平均である。興味ある仮説検定の帰無仮説として  $H_0: \mu = \mu_0$  を考える。この仮説検定として t 検定がよく知られている。また、位置パラメータ  $\mu$  の点推定量は標本平均  $\tilde{\mu} = \bar{X}_n$  で与えられ、基本的な統計解析法としてよく使われる。これらの t 検定、標本平均は、 $f(x)$  が正規分布の密度関数であるとき、すなわち標本データが正規分布に従うとき最良な手法となり、パラメトリック論による手法と呼ばれている。パラメトリック論による手法にはいくつかの欠点がある、第一に、データの中に異常値 (外れ値) を含む場合には、検定結果や推定結果が異常値を含まない場合に比べて大きく変わってくる。すなわち、データ解析の結果が異常値に振り回され易い。第二に  $f(x)$  が裾の重い分布のときには推測法として良くない。第三に、標本サイズが大きくないとき  $f(x)$  が既知でなければ検定の有意水準が固定できないため、パラメトリック論による検定手法は使うことが難しい。

$f(x)$  が未知としても検定または推定が行える便利な手法をノンパラメトリック論による手法と呼び、5.3 節で紹介する順位に基づく方法が代表的である。順位統計量を  $T$  とするとき、この値が大きいならば  $H_0$  を棄却する。 $H_0$  の下で定数  $c_0$  に対して  $P\{T \geq c_0\}$  は  $f(x)$  に依存しない、すなわち、この順位検定は標本データの従う分布が未知であっても検定が行えることとなる。その後、漸近理論 ( $n \rightarrow \infty$  とした理論) により順位検定は  $f(x)$  が正規分布のときは t 検定より少し悪く、 $f(x)$  が正規分布から離れた分布のときは t 検定より検出力が良いことが示されている。特に裾の重い分布に対しては順位検定は有効であることが解っている。さらに  $n$  が大きくななくても漸近理論と同じ結論であることが計算機シミュレーション (模擬実験) により検証できる。このように  $f(x)$  が正規分布のときは、正規分布のときの最良方法に少し劣るが  $f(x)$  が正規分布から離れた分布であるときに正規分布のときの最良方法より良い手法を、分布に関する頑健性をもつ手法と呼んでいる。すなわち順位検定法は分布に関する頑健性をもっている。順位による位置パラメータ  $\mu$  の推定はホッジス・レーマン (Hodges and Lehmann (1963)) によって提案される理論も同時に述べられている。順位検定法の場合と同じように、この順位推定法は標本平均  $\tilde{\mu} = \bar{X}_n$  による推定との比較において  $f(x)$  が正規分布のときは標本平均による推定より少し悪いが、 $f(x)$  が正規分布以外の分布であるときには標本平均による推定より良いことが示された。またこの順位推定法が異常値に関する頑健性をもっていることが、フーバー (Huber (1981)) のテキストで理論的に示されている。

$f(x)$  が正規分布の  $\varepsilon$  近傍  $U_\varepsilon \equiv \{f(x) = (1 - \varepsilon)\varphi(x) + \varepsilon h(x)\}$  :

$\varphi(x)$  は標準正規分布の密度関数,  $h(x)$  はすべての  $x$  に対して  $h(-x) = h(x)$  を満たすある密度関数 } の中にあるときの最良な手法をパラメトリックとノンパラメトリックの間という意味でセミパラメトリック論による手法と呼ばれている. フーバー (Huber (1964)) は関数  $\psi(x) = x (|x| < b \text{ のとき}); = b (x \geq b \text{ のとき}); = -b (x \leq -b \text{ のとき})$  を導入し方程式  $\sum_{i=1}^n \psi(X_i - \theta) = 0$  の解  $\hat{\theta}$  を  $\mu$  の点推定量として提案し, これを M 推定と呼び,  $\varepsilon$  に依存して  $b$  をうまく採れば  $f(x)$  が  $U_\varepsilon$  に入るとき M 推定が最良となることを示し, その後の研究成果を フーバーはテキスト (Huber (1981)) でレビューしている. 一方, 検定についても関数  $\psi(x)$  を使った M 検定を提案することができ, フーバーの M 推定のとおり同じように標本データの分布が正規分布の  $\varepsilon$  近傍に入るときに最良であることを示すことができる. すなわち,  $f(x)$  が近傍  $U_\varepsilon$  に入るとき平均に対する最良な検定である. さらに M 推定も M 検定も分布と異常値に関する頑健性をもっている.

生のデータが手元にあるときパラメトリック, ノンパラメトリック, セミパラメトリック論による 3 つの手法のうちいずれを適用すればよいかは, 5 章で紹介する正規性の検定, 分布の探索, エフロン (Efron (1979)) によって提唱されたブートストラップと呼ばれる計算機シミュレーションを使った手法等から解る. 研究の概要

多変量の分散分析や回帰モデルに対して位置パラメータの頑健なノンパラメトリック及びセミパラメトリック理論に基づく検定, 推定, 信頼領域に興味をもって研究を進めている. モデルが多変量正規分布に従っている場合に多くの理論ができたが, 正規分布からはずれたゆるい仮定の分布に従っている場合はあまり研究進んでいない. 正規分布の下で導かれた手法は一般的に分布の崩れや異常値などに弱いことが知られている. 私の研究では分布仮定をゆるめた理論だけをつくるのではなく, 分布が正規に従っているときでも効率が落ちず, 正規分布以外の時は従来の手法よりもよく, 異常値に対しても頑健な手法を確率論を使って導くことである. これらの研究を進めるために数学的基礎が重要であるが計算機によるシミュレーションやグラフィックスなどからの検証も必要である. また, 手法が実際に可能であることを示すためのソフトウェアにも興味をもって研究を進めている. 統計学は社会調査のデータや生物医学データの計算機情報処理に大きな影響を与えている.

キーワード ノンパラメトリック統計学, 頑健性の数理統計理論, 多変量解析, 分散分析, 計算機統計学

所属学会

日本数学会, 日本統計学会, 日本計算機統計学会, American Atatistical Association.

主要担当科目

[ 学部 ] 統計科学, 統計学各論 [ 大学院 ] 応用数学特論