

# トービットモデルを用いたソフトウェア欠陥数予測

<sup>1</sup>村上 優佳紗 <sup>1</sup>角田 雅照 <sup>2</sup>戸田 航史

<sup>1</sup>近畿大学理工学部情報学科, <sup>2</sup>福岡工業大学情報工学科

## 1はじめに

近年, プロジェクトは大規模化しており, 納期の遅れ, 品質の低下, コストの超過などを防止する重要性が高まっている。それらを防止するためには, 定量的なプロジェクト管理は欠くことができない要素の一つであり, プロジェクトのコストや品質などを予測し, テストや人員配置などの計画を立案する必要がある。

予測するために用いられる数学的モデルとして重回帰分析などがあり, 過去に得られたデータを基に構築される。しかし, ソフトウェアプロジェクトのデータを用いた場合, ソフトウェアの欠陥数など, 最小値が0となる変数があるため, 最小二乗法では適切なモデルが構築されず, 欠陥数や開発工数の予測値が負の値となる可能性がある。この問題を解決するために, 本稿ではトービットモデルをソフトウェア欠陥数予測に適用することを提案する。

## 2 トービットモデル

トービットモデルとは, データの分布の偏りを考慮したモデルである。データの偏りの分布は以下の3つに分類される[1]。

- 打ち切り (censored)
- 切断 (truncated)
- 付隨的切断 (incidental truncation)

打ち切りとは, 欠陥数など, 変数の最小値が0以上と値域があらかじめ決まっている場合である。切断とは, 欠陥数が0のデータを除外する場合である。付隨的切断とは, レビュー指摘数の省略などが理由で本来0でない数値が0となる場合である。本稿では, ソフトウェア欠陥数を予測するため, 打ち切り, 切断に有効なタイプIのトービットモデルを適用する。

## 3 実験

トービットモデル (Tobit), 最小二乗法 (OLS), 対数変換を適用したトービットモデル (Tobit\_ln), 対数変換を適用した最小二乗法 (OLS\_ln) の計4つを用いてソフトウェア開発プロジェクトにおける欠陥数の予測を行い, 精度を比較した。ここで, 対数変換を適用したとは, 0は対数変換できないため, 各変数にあらかじめ1を足した上で対数変換し, モデルを構築したことを指す。分析に用いたデータセットはISBSG (International Software Benchmarking Standards Group) が20ヶ国組織

から収集したものである。分析では, プロジェクトにおける総欠陥数を目的変数とし, 未調整FP, 新規開発, 金融業, メインフレーム, ミッドレンジを説明変数として採用した。なお, 対象のプロジェクトは221件である。

モデルの予測精度を評価するために, 5-fold cross validationによる実験を行い, 評価指標は, 絶対誤差 (AE), Balanced Relative Error (BRE) それぞれの平均値, 中央値とPred25を用いた。AE, BREは値が小さいほど精度が高いことを示す。Pred25は, 誤差25%以内のデータの割合を指し, 数値が高いほど精度が良いことを示す。

実験結果を表1に示す。評価値は, OLSの各評価指標から, Tobitの各評価指標を引いた値である (Pred25のみTobit - OLS)。OLSとTobitを比較すると, AE中央値, BRE中央値の評価値が共に正であるが, BRE平均値とPred25の評価値が負であるため, どちらが適切なモデルであるかはいえない。一方, OLS\_lnとTobit\_lnを比較すると, AEの評価値はほとんど差がなく, BRE平均値の評価値も負の値を示している。しかし, BRE中央値とPred25の評価値が正であるため, Tobit\_lnは検討すべきモデルであるといえる。

表1 各モデルの予測精度

	AE 平均値	AE 中央値	BRE 平均値	BRE 中央値	Pred25
OLS	10.74	4.11	284%	165%	12%
Tobit	9.66	2.04	378%	115%	8%
評価値	1.08	2.06	-94%	49%	-4%
OLS_ln	8.24	1.86	226%	107%	21%
Tobit_ln	8.45	1.53	260%	93%	28%
評価値	-0.21	0.33	-34%	14%	7%

## 4 おわりに

本稿では, ソフトウェア欠陥数の予測にトービットモデルを用いることを提案した。今後の課題としては, その他のデータセットを用いて評価を行い, どのようなデータセットに有効かを検証することが重要となる。

**謝辞** 本研究の一部は, 文部科学省科学研究補助費 (基盤C: 課題番号 25330090) による助成を受けた。

## 参考文献

- [1] 水落 正明: 打ち切り・切断データの分析, 理論と方法, Vol. 24, No. 1, pp. 129-13, 2009.