

変数選択法の性能比較：マーケティングデータを例に

川崎 能典 モデリング研究系 教授

概要: 預金マーケティングデータを用い、契約の成否を判別・予測するモデルを構成する際の変数選択に関して、様々な手法を比較検討する。用いたデータはMoro et al. (2014) *Decision Support Systems*で分析されたものであり、UC Irvine Machine Learning RepositoryにBank Marketing Data Setとして公開されている。[本報告は植木優夫氏(現・長崎大学情報データ科学部, 執筆当時は久留米大学バイオ統計センター)との共同研究である。より詳細な報告はKawasaki and Ueki (2015)を参照されたい。]

1. 預金マーケティングデータ

記録された顧客接触記録は41,188件、応答変数は定期預金を契約してくれたか($y = 1$) 否か($y = 0$)の2値。説明変数は、連続・カテゴリカル合わせて19個用意されている。カテゴリカル変数としては、職種(job)、配偶者の有無(marital)、学歴(education)、事故歴(default)、住宅ローンの有無(housing)、その他借入(loan)、接触方法(contact)、最終接触月(month)、最終接触曜日(day_of_week)、以前のキャンペーン時の結果(poutcome)がある。連続型変数としては、年齢(age)、今回キャンペーンでの接触回数(campaign)、前回キャンペーン最終接触日からの経過日数(pdays)、今回キャンペーン以前の接触回数(previous)といった顧客属性と、雇用変動率(emp.var.rate)、消費者物価指数(cons.price.idx)、消費者信頼指数(cons.conf.idx)、欧州3ヶ月指標金利(euribor3m)、雇用者数(nr.employed)といったマクロ経済指標が含まれる。

カテゴリカル変数に関しては、当該変数が m 個のカテゴリを有するときは、そこから $m-1$ 個のダミー変数を生成する。例えば貸出事務履歴(default)では、yes, no, unknownの3つのカテゴリがあるが、default-yesとdefault-unknownに対してそれぞれダミー変数を用意する。このようにして今回の問題では、最終的に連続・カテゴリ合わせて52個の説明変数を用意した。

2. 円滑閾値型推定方程式

いま d 個の説明変数の未知係数を $\theta = (\theta_1, \dots, \theta_d)'$ と書くことにし、 $L(\theta) + \sum_{j=1}^d w_j \theta_j^2 / 2$ という形の罰則付き損失関数を考えよう。これはすなわち、 $\frac{\partial L(\theta)}{\partial \theta_j} + w_j \theta_j = 0$ ($j = 1, \dots, d$)に等しい。

ここで $\delta_j \in [0, 1]$ を使って $w_j = \delta_j / (1 - \delta_j)$ とパラメータを取り直すことができる。このとき、上掲の推定方程式は $(1 - \delta_j) \partial L(\theta) / \partial \theta_j + \delta_j \theta_j = 0$ ($j = 1, \dots, d$)という形になる。 $\delta_j = 1$ (このとき $w_j = \infty$)ならば $\theta_j = 0$ すなわちスパース解となることに注意。この方法を、円滑閾値型推定方程式(Smooth-Threshold Estimating Equation, 略してSTEE)と呼ぶ。

δ_j の決め方は、adaptive lassoにおける議論の類推から、 \sqrt{n} -一致性を持つ何らかの初期推定量 $\hat{\theta}_j^{\text{ini}}$ を使って、 $\hat{\delta}_j = \min(1, \lambda / |\hat{\theta}_j^{\text{ini}}|^{1+\gamma})$ とする。チューニング・パラメータ (λ, γ) はBIC型規準で選択する。

STEEでは変数選択と同時に変数のグルーピングも考慮できる。更に $\sum_{j=1}^d \sum_{k>j}^d \hat{w}_{jk} (\theta_j - \theta_k)^2 / 2$ という罰則項を加えればよい。罰則の重み \hat{w}_{jk} は、 $\hat{\delta}_{jk} = \min(1, \lambda / |\hat{\theta}_j^{\text{ini}} - \hat{\theta}_k^{\text{ini}}|^{1+\gamma})$ により $\hat{w}_{jk} = \hat{\delta}_{jk} / (1 - \hat{\delta}_{jk})$ と決めればよい。

STEEの一致性、漸近正規性、神託性、チューニング・パラメータ選択に関するBIC型規準の一致性等、理論的性質についてはUeki (2009), Ueki and Kawasaki (2011)を参照。

3. 模擬予測実験

41,188ケースはランダムに2:1に訓練データと検証用データに分割される。このデータ分割は実験中独立に10回繰り返される。予測力はAUCで比較する。この時、比較される予測モデル構成法(変数選択法)は以下の10類型14通りのやり方である。

1. 多重ロジスティック回帰 (MLR): 全52変数を投入
2. L_2 -罰則項付き多重ロジスティック回帰 (L2): Rのパッケージglmnetを使用
3. 自動変数選択型STEE (STEE.AVS): MLRの推定結果を初期値として利用

4. 自動変数選択型STEE (STEE.AVS-L2): L_2 の推定結果を初期値として利用
5. 自動変数グルーピング型STEE (STEE.AG): 変数選択に加えて変数のグルーピングも実施、初期値はMLRの結果を利用
6. 自動変数グルーピング型STEE (STEE.AG-L2): 変数選択に加えて変数のグルーピングも実施、初期値は L_2 の結果を利用
7. Lasso: パッケージglmnetを利用。チューニング・パラメータを10分割交差検証法で選ぶ場合 (LASSO-CV10) とBIC型規準を用いる場合 (LASSO-BIC) とを考察
8. Elastic net: パッケージglmnetを利用。チューニング・パラメータを10分割交差検証法で選ぶ場合 (ENET-CV10) とBIC型規準を用いる場合 (ENET-BIC) とを考察。 L_1 罰則と L_2 罰則との混合率は0.1刻みで $\{0, 0.1, 0.2, \dots, 1\}$ から選択。
9. Smoothly-clipped absolute deviation (SCAD): Rのパッケージncvregを利用。チューニング・パラメータを10分割交差検証法で選ぶ場合 (SCAD-CV10) とBIC型規準を用いる場合 (SCAD-BIC) とを考察。
10. Minimum concave penalty (MCP): Rのパッケージncvregを利用。チューニング・パラメータを10分割交差検証法で選ぶ場合 (MCP-CV10) とBIC型規準を用いる場合 (MCP-BIC) とを考察。

4. 実験結果

ランダムなデータ分割を10回繰り返したときの、AUCの平均と標準偏差が以下の表に示す。驚くほど結果に差がない。UCIリポジトリにデータを提供する際、原著者たちは入念に変数選択を行って提供したと思われる。精度の改善には交互作用項の導入等、何らかの追加的試みが必要だろう。

方法名	AUC平均	AUC-SD	方法名	AUC平均	AUC-SD
MLR	79.3	0.7	LASSO-BIC	79.1	0.8
L2	79.3	0.7	ENET-CV10	79.4	0.7
STEE.AVS	79.3	0.7	ENET-BIC	79.1	0.8
STEE.AVS-L2	79.3	0.6	SCAD-CV10	79.3	0.7
STEE.AG	79.2	0.8	SCAD-BIC	79.1	0.7
STEE.AG-L2	79.2	0.7	MCP-CV10	79.3	0.7
LASSO-CV10	79.4	0.7	MCP-BIC	79.3	0.7

予測力に大きな差は出なかったが、STEE.AGとSTEE.AG-L2では変数のグルーピングを考慮ことができ、効果が同じ大きさの変数群ではパラメータを節約することができる。以下に10回反復の実験過程で一定頻度(6回以上)観察されたグルーピングの結果を報告しておく。

頻度	変数1	変数2
7	job-services	job-blue-collar
7	education-basic.9y	jon-entrepreneur
8	euribor3m	job-student
7	day_of_week-fri	education-basic.4y
6	education-high.school	education-basic.4y
6	previous	day_of_week-fri

参考文献

- [1] Ueki, M. (2009), A note on automatic variable selection using smooth-threshold estimating equations, *Biometrika*, 96, 1005–1011.
- [2] Ueki, M. and Kawasaki, Y. (2011) Automatic grouping using smooth-thresholding estimating equations, *Electronic Journal of Statistics*, Vol. 5, 309–328.
- [3] Kawasaki, Y. and Ueki, M. (2015) Sparse predictive modeling for bank telemarketing success using smooth-threshold estimating equations, *J. Jpn. Soc. Comput. Statist.*, 28, 53–66.