

保険データサイエンス（IDS）における海外の動向

汪 金芳

横浜市立大学 DS 学部

2018 年 5 月 21 日（日）：14:30-16:00

- ✓ I D S の概略
- ✓ I D S の役割と期待
- ✓ 「Insurance Data Science Conference 2018」の紹介

- **保険業の中心的課題**：エビデンスに基づくリスク管理と決定
 - **データサイエンス**は、保険対象物のリスクに対して精細な分析をすることが可能
 - **データサイエンス**は、データ内に隠されている種々の関係性を特定し、データに基づくより良い予測をもたらす。
 - **データサイエンス、の新たな活用**：
 - 自動車保険のテレマティクス (Telematics) 機器の活用
 - 健康保険におけるウェアラブルフィットネス機器の活用
 - 生命保険における経験分析 (experience analysis) による高度なリスクの管理
 - **データサイエンス、の力を生かし**
 - 消費者ターゲティングと商品設計個別化
 - リスクアセスメント、契約査定 (underwriting) と適切な価格設定
 - 詐欺行為 (fraud) の特定と回避管理
- を可能にし、保険会社と消費者の双方に利益をもたらす。

I D S の役割と期待：顧客選別と商品設計

- 意図した顧客にターゲットを当てる
- より適切な商品を開発し、ターゲット顧客に勧める
- 顧客の好みや行動を分析し、顧客のニーズの変化を把握し、新たな商品開発に活用する

例

例えば、インターネット検索履歴の分析により消費者の好みや行動を予測することができる。これらの分析結果を用いて、消費者と商品間の適切なマッチングを行うことができる。

例

スマートアプリ (smart Apps) の増え続けている利用とそれに適切な分析により、特定の性質を持つ消費者集団に対して新たな保険領域の開拓なども考えられる。

I D S の役割と期待：契約査定と価格設定

- 保険業界におけるデータサイエンスの最も大きな役割は、
 - 契約査定
 - 価格設定における顧客のリスク評価である。
- データサイエンスの力を活かし、
 - 顧客のリスク・プロファイルをより詳細に分析することが可能。
 - 根拠に基づいたより良い契約査定に繋がる。
 - リスクに見合うより適切な保険料の設定が可能となる。
- 適切なリスクア評価は、顧客に恩恵をもたらす。

例

特定の若者に対して、運転を含めたより詳細なデータを解析すれば、標準より安い自動車保険料を設定できる。

IDSの役割と期待：顧客のより強い関与

データサイエンスは、

- 保険契約の過程を改良
- 顧客の積極的な関与の促進

することにより、保険契約者と保険会社の双方にとって利益をもたらす。

例

自動車保険の場合はテレマティクス機器を、また健康保険の場合はウェアラブルフィットネス機器を通して、顧客のリスク・プロファイルの改善が確認されれば、保険料を低く設定できる。保険料の引き下げにより、保険契約者は自分のライフスタイルの「危険性」を軽減する努力が奨励される。このように保険契約者にインセンティブを与えることにより、データサイエンスは社会全体に利益をもたらす。

例

顧客の積極的関与は、「オンデマンド保険」(on-demand insurance) というこれまでにないサービスを提供することが考えられる。例えば、自動車保険の場合、スマートフォンを介して保険のオン・オフを切り替えることが考えられる。

データサイエンスの力を活かし、

- クレームの客観的な順位付けを与えることができる。
- より複雑な案件には時間をかけて更なる分析や評価を行える。

例

SNS 活動や関連情報の分析により、一連の虚偽または過大化されたクレームを効果的見抜けることが期待される。デジタルデータの活用により、クレーム処理の速度の向上と共にビジネスの機会も同時に増える。

「Insurance Data Science Conference 2018」の概要：1

複数の Lasso ペナルティが混在する場合の予測モデルの構築について (Tom Reynkens, KU Leuven)

- 統計的予測モデルの役割：
 - 適切な価格設定 (pricing)
 - マーケティングキャンペーン (marketing campaigns) の展開
 - 詐欺 (fraud) の検出
 - 倒産 (churn) の検出
- 予測モデルに含まれる複雑なリスク要因：
 - 連続変数
 - 順序尺度
 - 名目変数
 - 空間的変数
- 予測モデルに対する評価基準：
 - 予測性能が優れている
 - 保険契約者 (policyholder) や規制当局 (regulator) をはじめとして、ステークホルダー (利害関係者; stakeholder) にとって解釈可能性
 - 実装が容易
 - 継続的な運用が可能

「Insurance Data Science Conference 2018」の概要：2

複数の Lasso ペナルティが混在する場合の予測モデルの構築について (Tom Reynkens, KU Leuven)

既存のアプローチ：

- アドホックな方法を用いて変数を除去
- アドホックな方法を用いてレベルを結合
- 一般化線形モデルの適用

データサイエンス（統計学および機械学習）における新たなアプローチ：

- 罰則付き回帰分析（penalised regression）
- data-driven 変数の選択（variable selection）
- data-driven 変数の結合（ビン化, binning）

従来の罰則付き回帰分析の問題点：

- Lasso (Tibshirani, 1996) は連続変数を想定
- Fused Lasso (Tibshirani et al., 2004) は序数変数を想定

本研究の目的：

- 連続変数には Lasso 型ペナルティを設定。
- 序数変数には Fused Lasso 型ペナルティを設定。
- 異なるペナルティを混在させる。
- 近接勾配法（(Proximal Gradient Method)）を用いて推定を行う。

ケーススタディ：自動車保険における価格設定

LASSO

(least absolute shrinkage and selection operator)

Tibshirani, Robert (1996). Regression Shrinkage and Selection via the lasso.
Journal of the Royal Statistical Society, Series B. **58** (1), 267–88.

- n 個の観測値が得られていて、 i 番目の観測対象に対して、 y_i を反応変数、 $\mathbf{x}_i = (x_1, x_2, \dots, x_p)^T$ を共変量とする。
- 通常の最小自乗法では、次の最適化問題

$$\min_{\beta_0, \boldsymbol{\beta}} \left\{ \frac{1}{n} \sum_{i=1}^n (y_i - \beta_0 - \mathbf{x}_i^T \boldsymbol{\beta})^2 \right\}$$

を解き、パラメータ $\beta_0, \boldsymbol{\beta}$ の推定を行う。

- LASSO では、次の条件付き最適化問題

$$\min_{\beta_0, \boldsymbol{\beta}} \left\{ \frac{1}{n} \sum_{i=1}^n (y_i - \beta_0 - \mathbf{x}_i^T \boldsymbol{\beta})^2 \right\} \text{ subject to } \sum_{i=1}^p |\beta_i| \leq t.$$

を解き、パラメータ $\beta_0, \boldsymbol{\beta}$ の推定を行う。ただし、 t は正則化の度合いを決める自由パラメータである。

Fused LASSO

Tibshirani, Robert, Michael Saunders, Saharon Rosset, Ji Zhu, and Keith Knight. 2005. Sparsity and Smoothness via the Fused lasso. *Journal of the Royal Statistical Society, Series B.* **67** (1), 91–108.

Fused LASSO とは

- 時空間データのように、共変量間に順序制約を持つことがしばしばある。
- Fused LASSO では、次の条件付き最適化問題

$$\min_{\beta} \left\{ \frac{1}{n} \sum_{i=1}^n (y_i - x_i^t \beta)^2 \right\}$$

$$\text{subject to } \sum_{j=1}^p |\beta_j| \leq t_1 \text{ and } \sum_{j=2}^p |\beta_j - \beta_{j-1}| \leq t_2.$$

を解く。ただし、 t_1, t_2 は正則化の度合いを決める自由パラメータである。

- 2 番目の正則化項 $\sum_{j=2}^p |\beta_j - \beta_{j-1}| \leq t_2$ は、時空間的連続変化を実現させるため、パラメータの滑らかな変化を制限している。
- Clustered LASSO は Fused LASSO を一般化し、次の正則化項

$$\sum_{i < j} |\beta_i - \beta_j| \leq t_2.$$

を加え、グループ化されたデータを解析することができる。

近接勾配法 (Proximal Gradient Method)

- $f(\mathbf{x})$ を微分可能な凸関数で、 $g(\mathbf{x})$ を微分不可能な点を含む凸関数で、目的関数 $F(\mathbf{x}) = f(\mathbf{x}) + g(\mathbf{x})$ の最小化問題を考える。
- テップ幅 η に対して、近接勾配法は

$$\mathbf{x}_{k+1} = \text{prox}_{\eta g}(\mathbf{x}_k - \eta \nabla f(\mathbf{x}_k))$$
$$\text{prox}_g(\mathbf{y}) \equiv \underset{\mathbf{x}}{\text{argmin}} \left\{ g(\mathbf{x}) + \frac{1}{2} \|\mathbf{x} - \mathbf{y}\|^2 \right\}$$

と更新します。

- prox_g は g の proximal operator (近接写像) である。入力 \mathbf{y} との二乗距離による罰則項 $\frac{1}{2} \|\mathbf{x} - \mathbf{y}\|^2$ の和を最小化する点に移される。制約付き最適化で、制約を無視して勾配方向に更新してから、実行可能領域に射影する勾配射影法 (Gradient Projection Method) と同様の手続きになっていて、proximal operator は射影の一般化になっています。

- <https://qiita.com/msekino/items/9f217fcd735513627f65>
- 金森敬文, 鈴木大慈, 竹内一郎, 佐藤一誠. 機械学習のための連続最適化 (機械学習プロフェッショナルシリーズ), 講談社, 2016.

L2 正則化の Proximal Operator

L2 正則化の場合, g が滑らかな関数なので, 近接勾配法は必要ない。確認のため, この場合の Proximal Operator は

$$\text{prox}_{\frac{\lambda}{2}\|\cdot\|^2}(\mathbf{x}) = \operatorname{argmin}_{\mathbf{y}} \left\{ \frac{\lambda}{2} \|\mathbf{y}\|^2 + \frac{1}{2} \|\mathbf{x} - \mathbf{y}\|^2 \right\} \quad (1)$$

となる。

目的関数を \mathbf{y} で微分すると, $(1 + \lambda)\mathbf{y} - \mathbf{x}$ となり, \mathbf{y} について解くと,

$$\text{prox}_{\frac{\lambda}{2}\|\cdot\|^2}(\mathbf{x}) = \frac{1}{1 + \lambda} \mathbf{x} \quad (2)$$

を得る。

L1 正則化の Proximal Operator

L1 正則化の場合,

$$\text{prox}_{\lambda \|\cdot\|_1}(\mathbf{x}) = \underset{\mathbf{y}}{\text{argmin}} \left\{ \lambda \|\mathbf{y}\|_1 + \frac{1}{2} \|\mathbf{x} - \mathbf{y}\|^2 \right\} \quad (3)$$

となる。目的関数を y_i で偏微分すると、

$$\begin{cases} \lambda + y_i - x_i & y_i \geq 0 \\ -\lambda + y_i - x_i & y_i < 0 \end{cases} \quad (4)$$

(5)

となり、

$$\left(\text{prox}_{\lambda \|\cdot\|_1}(\mathbf{x}) \right)_i = \begin{cases} x_i - \lambda & x_i > \lambda \\ 0 & |x_i| \leq \lambda \\ x_i + \lambda & x_i < -\lambda \end{cases} \quad (6)$$

$$= \text{sign}(x_i)(|x_i| - \lambda)^+ \quad (7)$$

を得る。

重複のない Group LASSO の場合は, 近接写像が

$$\text{prox}_{\lambda\|\cdot\|}(\mathbf{x}) = \begin{cases} \mathbf{x} - \lambda \frac{\mathbf{x}}{\|\mathbf{x}\|} & \|\mathbf{x}\| > \lambda \\ \mathbf{0} & \|\mathbf{x}\| \leq \lambda \end{cases} \quad (8)$$

$$= \frac{\mathbf{x}}{\|\mathbf{x}\|} (\|\mathbf{x}\| - \lambda)^+ \quad (9)$$

となる。