



日本アクチュアリー会の データサイエンス分野に係る取り組み

藤田 卓

自己紹介



藤田 卓
(Suguru Fujita)

- AKUR8
Actuarial Data Scientist
- 日本アクチュアリー会
データサイエンス関連基礎調査部会 部会長
- 某データサイエンス教育企業
外部講師
- 早稲田大学大学院会計研究科
兼任講師
- 某国立大学
特任講師

アクチュアリーとデータサイエンス



アクチュアリーとは

- “確率や統計などの手法を用いて、将来の不確実な事象の評価を行い、保険や年金、企業のリスクマネジメントなどの多彩なフィールドで活躍する数理業務のプロフェッショナル”

<https://www.actuaries.jp/actuary/>

データサイエンスとは

- 数学や統計、機械学習、プログラミングなどの理論を活用して、データからビジネスに活用可能な価値を引き出す技術

**アクチュアリーの持つ専門性は
データサイエンスとの親和性が非常に高い**

日本アクチュアリー会の取り組み



会員向け教育


- データサイエンス専門講座や特定分野研修（2024年度から正会員認定要件）を開催し、データサイエンスに関する基礎知識や実務的な技術を教育

調査研究

- 専門ワーキンググループを設置し（2019年～）、データサイエンスの技術・手法を会員が活用しやすくなるよう、基礎的な調査・研究の実施とその成果の会員共有を実施

**当該専門ワーキンググループが、
現在のデータサイエンス関連基礎調査部会（以下、DS部会）**

DS部会の活動実績



時期	内容
2017年7月	第3回例会「将来を見据えたアクチュアリー教育像～I A Aシラバス改定の議論～」
2017年11月	データサイエンスに関する会員アンケートを実施
2018年8月	「若手ディスカッション」を組成（後のDS部会の原型）
2018年12月	第7回例会 早稲田大学と共催 ■特別講演「会計に関するデータサイエンス」 ■「データサイエンスの技術」というテーマで4つのプレゼンとパネルディスカッションを実施
2019年6月	報告 データサイエンスへの取り組みについて（予備的報告書） アクチュアリーがデータサイエンスにどのように向き合うべきか？
2019年9月	データサイエンス関連基礎調査WG 設置
2020年3月	報告 予測モデリングにおける誤差評価に関する研究報告
2020年7月	報告 SOAのExam PA: Predictive Analyticsの翻訳（2018年12月、2019年6月のSOA試験）
2020年9月	報告 Rを用いたデータの可視化技術 解説書
2020年12月	第4回例会「予測モデリングにおける誤差評価に関する研究」
2022年6月	Actuarial Colloquia 2022（オンライン） 論文発表“A New Framework of Prediction Error Decomposition for the Machine Learning Era”

DS部会の活動実績



時期	内容
2022年9月	Convention A（オンライン） DSWGの研究成果の発表を含むデータサイエンスに関するセッションを実施
2022年12月～ 2023年3月	ムーンライトセミナー “Interpretable Machine Learning”というテーマで実施
2023年5月	ICA2023（シドニー） 論文発表 “Random Forest Model with Prediction Error Decomposition Function”
2023年6月	報告 SOAのExam PA: Predictive Analyticsの翻訳（2019年12月、2020年6月のSOA試験）
2023年9月	論文 予測モデリングとアクチュアリー実務：汎用的な誤差分解・推定手法の必要性と可能性
2023年11月	2023年度年次大会「アクチュアリー×データサイエンス どう使う？ どう学ぶ？」
2024年3月	Convention A（オンライン） ランダムフォレストに関するパネルディスカッションなどデータサイエンスのセッションを実施
2024年6月	解説書執筆 Interpretable Machine Learning
2024年9月	IAA Joint Colloquia 2024（ベルギー） 発表 "A New Framework to Quantify Insurance Liabilities Prediction Error Applicable to Machine Learning Models"
2024年11月	2024年度JARIP研究発表大会パネル「機械学習技術のアクチュアリー実務への活用に関する展望」

DS部会の活動実績



時期	内容
2024年11月	2024年度年次大会「データサイエンス関連基礎調査WGの活動報告」
2025年4月	データサイエンス関連基礎調査部会に改称
2025年11月	2025年度年次大会「アクチュアリー業務における新たな分析・解釈手法の活用～位相的データ解析（TDA）および最大解釈分解（MID）」（ASTIN関連研究会と共催）
2025年11月	第4回例会「一般化加法モデルを用いた脱退率推定の改善」
2025年12月～ 2026年2月	ムーンライトセミナー「新たなIML手法「MID」を用いて機械学習モデルを読み解く」
2026年3月	Convention A Asia（オンライン） DS部会の研究成果の発表を含むデータサイエンス・AIに関するセッションを実施

そして現在、ICA2026（東京）に向けて精力的に活動中

DS部会のあり方

AI時代におけるアクチュアリー者の使命とキャリア形成

- 会員が次のキャリアを切り拓くための学びを提供
- 伝統的な保険数理×データサイエンス技術を
- 実務で使えるものを

DS部会のミッション

1. 普及

- 会員へのデータサイエンス技術の展開
 - 次のキャリアを切り拓く学びのプラットフォーム

2. 研究

- アクチュアリアル・データサイエンスの調査研究
 - ドメイン知識×データサイエンス技術の独自領域

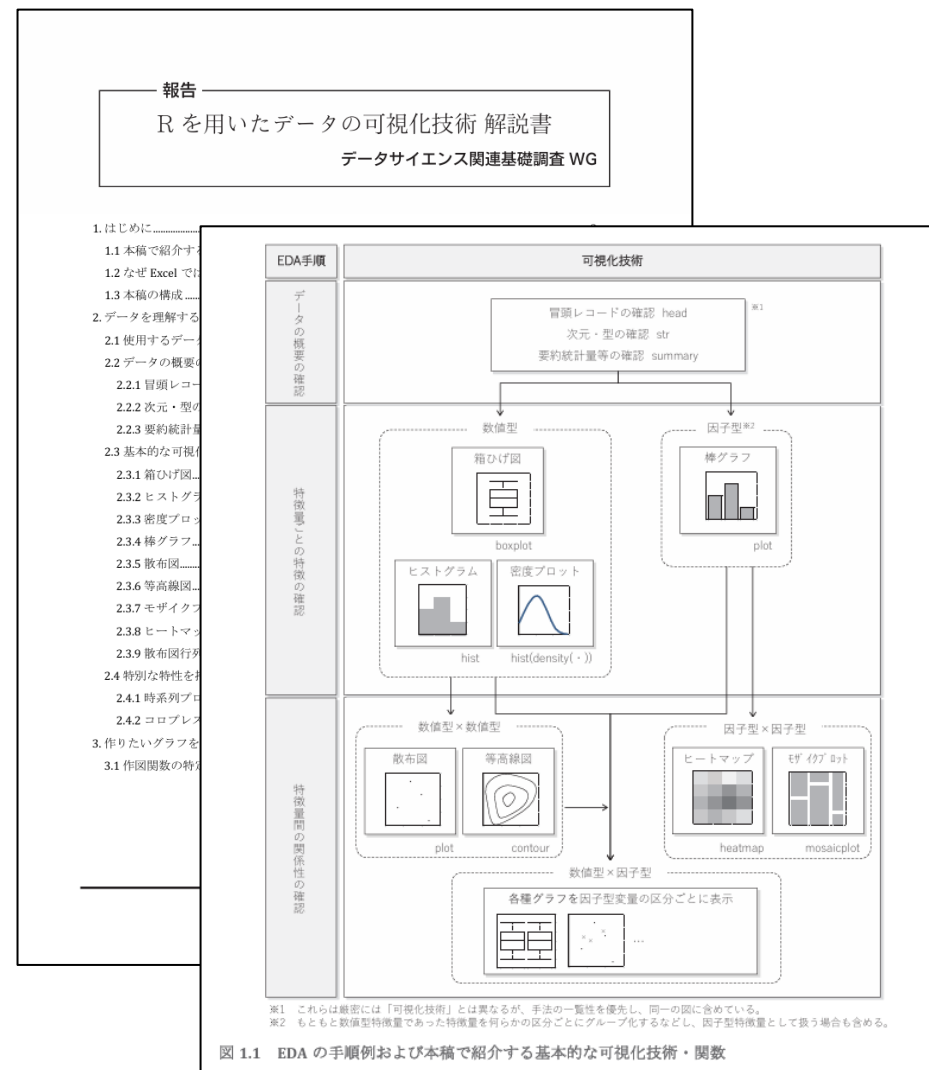
3. 実装

- アクチュアリー実務とデータサイエンス技術の橋渡し
 - 実務で実際に使えるものの追及

1. 普及：具体的な取り組み例

可視化技術の解説書

- アクチュアリーが身につけておきたいデータ可視化技術をまとめた解説書
- モデリング等の前段階で行うEDA（探索的データ解析）において、可視化は重要な役割を担う



1. はじめに
 - 1.1 本稿で紹介する
 - 1.2 なぜ Excel で
 - 1.3 本稿の構成
2. データを理解する
 - 2.1 使用するデータ
 - 2.2 データの概要の確認
 - 2.2.1 冒頭レコード
 - 2.2.2 次元・型の確認
 - 2.2.3 要約統計量
 - 2.3 基本的な可視化
 - 2.3.1 箱ひげ図
 - 2.3.2 ヒストグラム
 - 2.3.3 密度プロット
 - 2.3.4 棒グラフ
 - 2.3.5 散布図
 - 2.3.6 等高線図
 - 2.3.7 モザイク図
 - 2.3.8 ヒートマップ
 - 2.3.9 散布図行列
 - 2.4 特別な特性を持つデータ
 - 2.4.1 時系列プロット
 - 2.4.2 コロプレット
3. 作りたいグラフを作る
 - 3.1 作図関数の特

1. 普及：具体的な取り組み例

試験問題の調査

- SOAなどの海外のアクチュアリー会のデータサイエンスに関する試験問題・解答の翻訳
- グローバルな試験トレンドの分析を通じた、国内アクチュアリーが備えるべき知識水準・スキルの明確化

オープンソースライブラリの調査

- アクチュアリー実務と親和性の高いオープンソース系プログラミング言語のライブラリの調査
- 実務へのスムーズな導入に向けた、代表的なライブラリの機能検証と活用可能性の整理

2. 研究：調査研究テーマ例

汎用的な予測誤差評価および予測誤差分解手法

- 機械学習を含むあらゆる予測モデルに適用可能なデータドリブン手法を開発
- 以下のような重要な意義が存在
 - 予測誤差の要因（予測モデル or 学習データ等）の把握
 - モデル選択への活用
 - モデリングプロセスのレビュー、モデルを用いた意思決定への活用
 - モデルガバナンスの改善

2. 研究：調査研究テーマ例

ランダムフォレストの応用

- ランダムフォレストはアクチュアリーにとって強力なモデルになり得る
 - 広く知られモデルの原理的な解釈がしやすい
 - 予測精度が高いモデルである
 - ハイパーパラメータのチューニングが比較的容易である
 - 統計的性質に関する研究が近年進展している→ 誤差分布の一致性
- ランダムフォレストを活用した予測誤差分解手法を開発

予測誤差の定義とその分解

Kuriyama et al.(2022)の定義

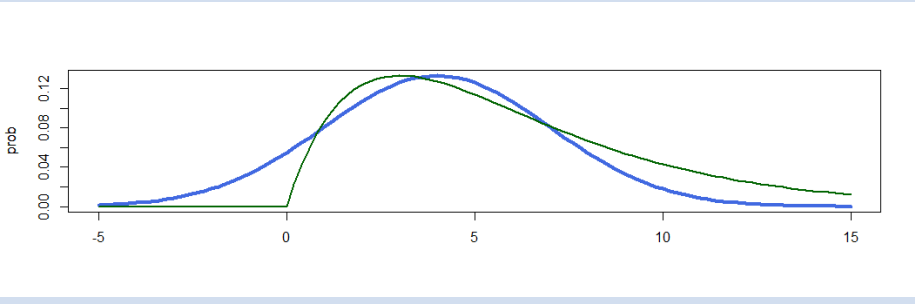
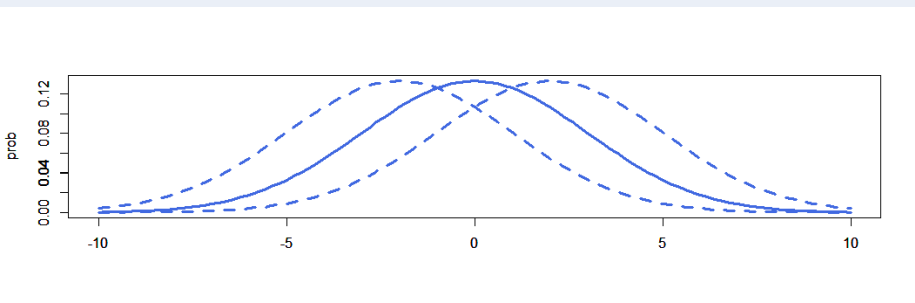
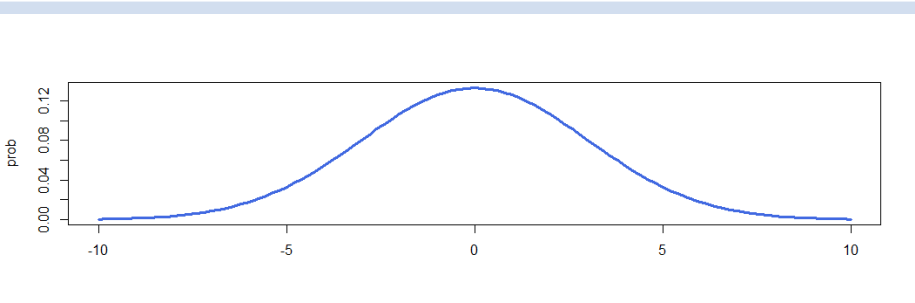
予測誤差は

- 新しい観測対象 x に対する予測モデルの値 $\hat{f}_n(x)$ と実績値 y の乖離度
- 目的関数として二乗誤差を仮定しており、次のとおり表される

$$\text{Err}_n(x) := E \left[\left(y - \hat{f}_n(x) \right)^2 \mid x \right]$$

- 種々の条件の下、モデル誤差・パラメータ誤差・プロセス誤差の3つの要素に分解できる

3つの要素のイメージ

	イメージ図	補足
モデル誤差		<ul style="list-style-type: none">• 誤差の要因は不適切な予測モデル• 予測モデルと真のモデルの乖離度
パラメータ誤差		<ul style="list-style-type: none">• 誤差の要因は学習データの有限性• パラメータ（推定量）の分散
プロセス誤差		<ul style="list-style-type: none">• 誤差の要因は内在する不確実性• 予測モデルが真の下での条件付分散

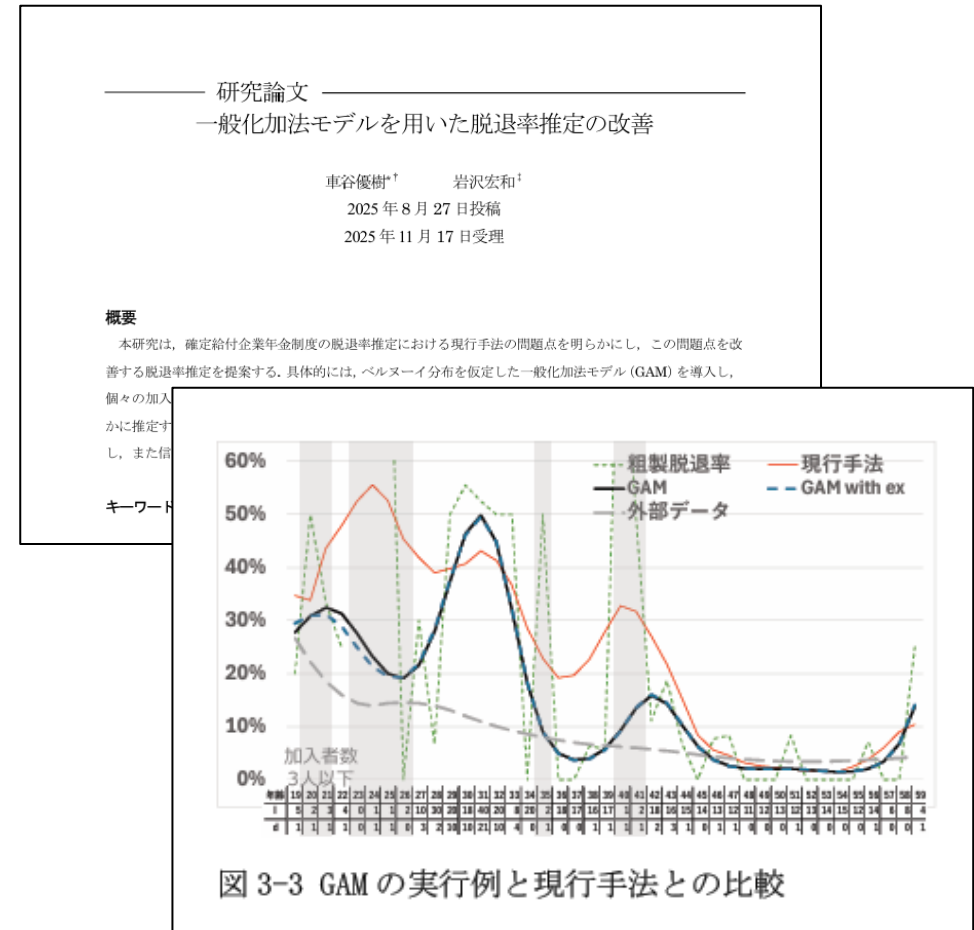
3つの要素のイメージ

	定義	Kuriyama et al. (2022)の数式
モデル誤差	予測モデルが適切でないことに起因する誤差	$\text{Err}_n^{\text{mod}}(x) := \left(\mathbb{E}[\hat{f}_n(x) x] - f(x) \right)^2$
パラメータ誤差	予測モデルが適切であったとしても、予測モデルを構成するパラメータ等が適切でないことに起因する誤差	$\text{Err}_n^{\text{par}}(x) := V[\hat{f}_n(x) x]$
プロセス誤差	予測モデルや予測モデルを構成するパラメータ等が適切であったとしても、内在する不確実性に起因する誤差	$\text{Err}_n^{\text{pro}}(x) := \mathbb{E} \left[(y - f(x))^2 x \right]$

2. 研究：調査研究テーマ例

DB年金制度の脱退率推定の改善

- 確定給付企業年金制度の脱退率推定において現行手法が抱える課題を整理し、一般化加法モデルを用いた改善策を提案
- 『確定給付企業年金に関する数理実務ガイダンス』に成果が反映



2. 研究：調査研究テーマ例

新たなIML手法

- アクチュアリーが高度な機械学習モデルを実務で使用するには、そのモデルが解釈できる（説明できる）ことが必要
- 機械学習のブラックボックスモデルにおける既存の解釈可能性手法の課題を検証し、それらを克服する新たな手法を開発
- 関数分解の考え方を応用したMID（Maximum Interpretation Decomposition）

MIDの定義

- 岩沢・松森（2024）が提案する **MID**（Maximum Interpretation Decomposition）は、次の条件により**ブラックボックスモデルの予測関数 f を分解**する手法

<条件>

- 予測関数 f に対する、 **k 次以下の項**と残差を表す $f_{1,\dots,d}$ からなる関数分解である。

$$f(x_1, \dots, x_d) = \sum_{J \subseteq \{1, \dots, d\}, |J| \leq k} f_J(x_J) + f_{1, \dots, d}(x_1, \dots, x_d)$$

- そのような関数分解で、**平均2乗残差** $E \left[\left(f_{1, \dots, d}(X) \right)^2 \right]$ **が最小**。
- かつ各項に**中心化**されている。すなわち $J \subseteq \{1, \dots, d\}, |J| \leq k$ および $J' \subsetneq J$ に対し

$$E[f_J(X_J) | X_{J'}] = 0$$

- 上記で一意に定まらない場合は、そのうち $\sum_{J \subseteq \{1, \dots, d\}, |J| \leq k} E \left[\left(f_J(X_J) \right)^2 \right]$ が最小となるもの。

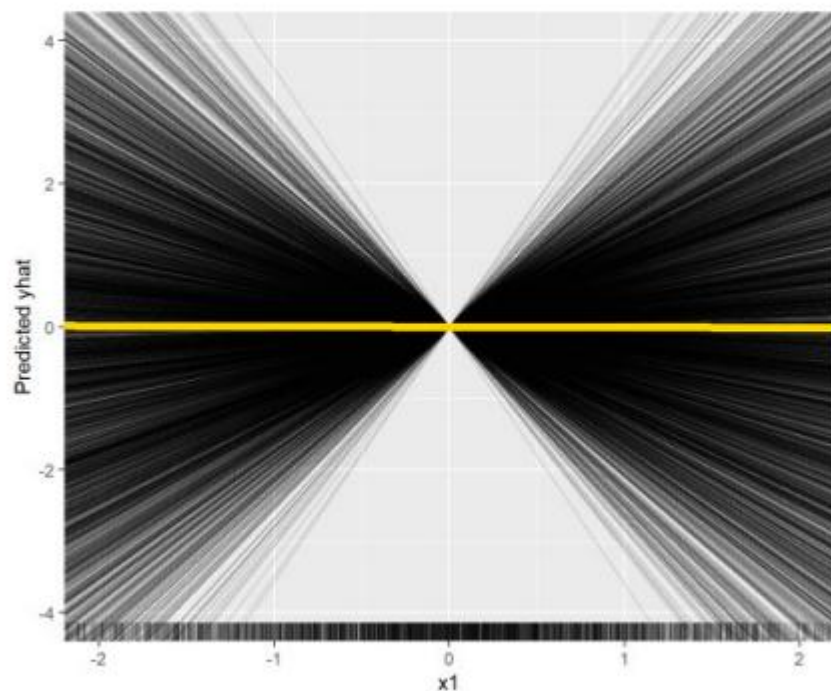
➢ k 次までの項の分解であることを明示するときは「 **k 次MID**」と呼ぶ。

➢ “Maximum Interpretation” は「予測値と関数分解の平均2乗残差が最も小さい」という意味。


既存手法の課題の解決

- PDPは説明変数間の相関が強い場合に主効果を捉えることが出来なかったが、MIDではそのような場合でも主効果を捉えることができる

➢ PDPの頁の2変数関数の例では、以下のように放物線の形のグラフが得られる。



x_1 のPDP・ICE

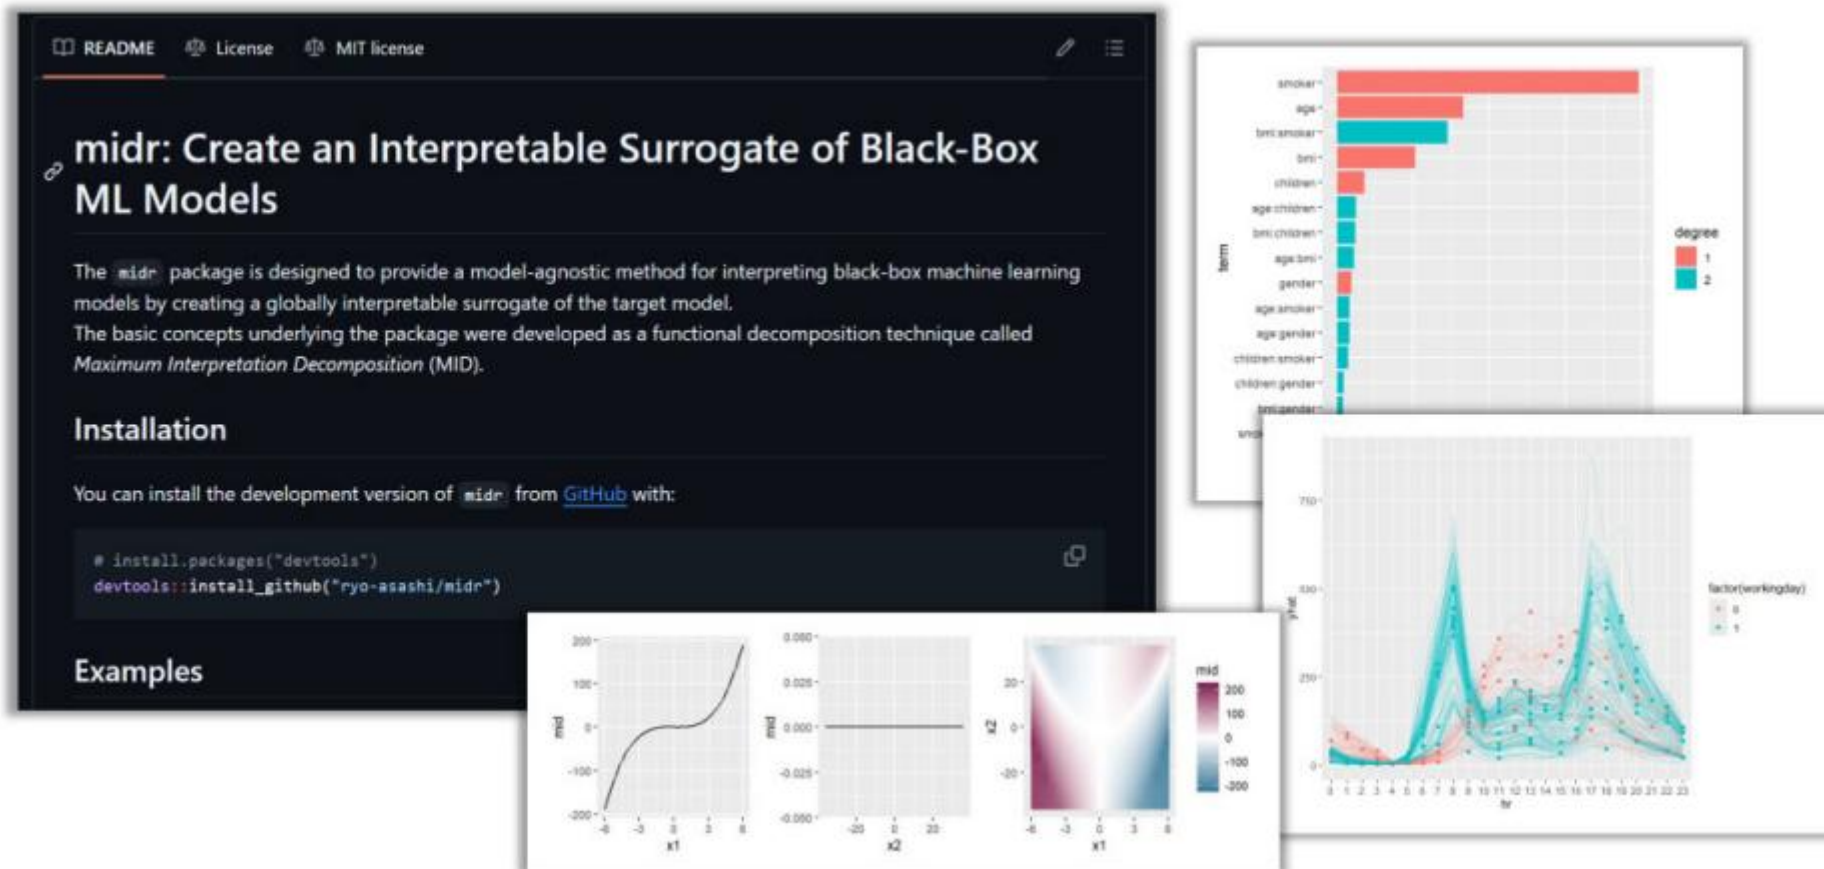


$\rho = 0.9$ の場合における x_1 のMID(関数項のグラフ)

(*1) 説明変数が独立である場合、PDPとMIDの主効果は一致

Rパッケージ

- CRAN <https://CRAN.R-project.org/package=midr>



The image displays the README page for the `midr` package on CRAN. The page title is "midr: Create an Interpretable Surrogate of Black-Box ML Models". The text describes the package as a model-agnostic method for interpreting black-box machine learning models by creating a globally interpretable surrogate. The basic concepts were developed as a functional decomposition technique called Maximum Interpretation Decomposition (MID).

Installation

You can install the development version of `midr` from [GitHub](#) with:

```
# install.packages("devtools")
devtools::install_github("ryo-asashi/midr")
```

Examples

The examples section shows three plots: a line plot of `mid` vs `x1`, a line plot of `mid` vs `x2`, and a heatmap of `mid` vs `x1` and `x2`. Additionally, there are two other plots: a horizontal bar chart showing the degree of terms (e.g., smoker, age, bmi, etc.) and a scatter plot of `mid` vs `hr` with points colored by `factor(workingday)`.

3. 実装：具体的な取り組み例

ワークショップの開催

- IML手法の理論や具体例に関する講義の実施と、それを踏まえたテーマ別のグループワークの開催
- IMLに関する考察や議論を行うことで、単なる知識のインプットに留まらない、実務に直結する分析スキルの習得や会員間のノウハウ共有を実現

アクチュアリー実務との橋渡し

- 保険実務で実際に使用されるデータを用いた、IML手法の具体的な適用プロセスの研究を通じ、橋渡しの仕組みを具現化

3. 実装：具体的な取り組み例

実務ガイダンスの作成

- データサイエンス技術を実務で活用するにあたっては、以下の点に関する指針やベストプラクティスを含むガイダンスが必要
 - 用途によって求められる予測精度や説明可能性が異なるなか、用途に応じてどのような手法を用いるべきか
 - 公平性や透明性をどのようにレビューするか
- 会員が、実務においてデータサイエンスの手法を利用するにあたって参照できるような、教育的文書の作成を検討中

ガイダンス目次イメージ

DS技術を活用する際の実務ガイダンスと事例集

I. 実務ガイダンス

1. はじめに（目的・背景）
2. DSプロセスの概要と保険数理業務への応用
 - i. DSプロセス
 - ii. 保険数理業務における具体的な応用分野
 - iii. 応用において留意すべき観点（透明性・公平性等の倫理的観点）
3. DSプロセスの各段階におけるポイント
 - i. モデリング
 - ii. モデルの検証・評価・選択（予測精度・解釈可能性等の技術的観点）
 - iii. モデルの運用・継続的モニタリング
 - iv. 第三者レビュー
4. 関連法規制
5. ガイダンスの今後の運用方法

II. 事例集

1. 国内外の分野別ベストプラクティス
2. 具体例や課題から得る教訓

米国の状況 (NAIC)

- 全米保険監督官協会 (NAIC: National Association of Insurance Commissioners) には、予測モデリングのレビューに特化したタスクフォースとブッククラブが存在し、予測モデリングに関するガイドラインをホワイトペーパーとして公表
- 以下のガイドラインを定義
 - GLM (右図)
 - スプラインGAM
 - ペナルティ付回帰 (RGLM: Regularized GLM)

9/9/2020
Adopted by the Casualty Actuarial and Statistical (C) Task Force, 9/15/20
Adopted by the Property and Casualty Insurance (C) Committee, 12/8/20

Casualty Actuarial and Statistical (C) Task Force
Regulatory Review of Predictive Models
White Paper

Table of Contents

I. Introduction	2
II. What is a "Best Practice?"	2
III. Some Issues in Reviewing Today's Predictive Models	3
IV. Do Regulators Need Best Practices to Review Predictive Models?	5
V. Scope	5
VI. Confidentiality	6
VII. Best Practices for Regulatory Review of Predictive Models	6
VIII. Proposed Changes to the <i>Product Filing Review Handbook</i>	8
IX. Proposed State Guidance	12
X. Other Considerations	13
Appendix A – Best Practice Development	14
Appendix B – Information Elements and Guidance for a Regulator to Meet Best Practices' Objectives (When Reviewing GLMs)	15
Appendix C – Glossary of Terms	46
Appendix D – Sample Rate-Disruption Template	53

米国の状況 (NAIC)

- NAICはRGLMに関するガバナンス規定の公開

Types of Regularized GLMs

- Lasso
 - Can penalize coefficients to zero
- Ridge
 - Can penalize coefficients to near zero
- Elastic Net
 - Combination of Lasso and Ridge
 - Can penalize coefficients to zero
- Derivative Lasso and Accurate GLM (AGLM)
 - Can penalize categorical variable coefficients to zero
 - Can group ordinal variable levels with adjacent levels
- Lasso Credibility
 - Can penalize toward a selected complement of credibility

AGLM: A Hybrid Modeling Method of GLM and Data Science Techniques

Suguru Fujita* Toyoto Tanaka† Kenji Kondo‡ Hirokazu Iwasawa§

2020-03-15

Abstract

In recent years, one of the most critical tasks for actuaries is to adopt data science techniques in predictive modeling practice. However, due to the peculiarity of insurance data as well as the priorities taken by actuaries in decision-making, such as the interpretability of models and regulatory requirements, most actuaries may find difficulties in applying them. We believe some original modeling methods with a good balance of high predictive accuracy and strong explanatory power is what is required. We propose, from this standpoint, AGLM (Accurate GLM), a simple modeling method with a desirable good balance accomplished by combining data science techniques and conventional Generalized Linear Models. For practitioners' convenience, we have also developed an R package named `aglm` (<https://github.com/kkondo1981/aglm>). Since the first version released in January 2019, the `aglm` can make numeric features segmented optimally exactly as Fused LASSO does when the L1 regularization is designated. In addition, the current version can, alternatively if preferable, change them from linear variables to the optimal piece-wise linear variables. Those functions make the constructed predictive model much more flexible than a conventional GLM hopefully still keeping sufficient explanatory power.

1 Introduction

In recent years, it has become an essential task for actuaries to integrate machine learning and data science techniques into actuarial practices as those techniques have been developing remarkably. There are many types of recent research on the implementation of machine learning methods, including the gradient boosting machine (GBM) and the neural network (NN), for pricing, reserving evaluation, and so on (Yang, Qian, and Zou 2018), (Poon and others 2019). These modeling methods achieve high prediction accuracy by specifying the important features among many candidates and fully capturing the complicated non-linear relationship between the features and the response variable. These methodologies will be indispensable to evaluate risks precisely for actuaries who are working in the information society, where a massive amount of data is being produced every second.

DS部会としての展望



ユーザーの裾野拡大

- 調査研究や成果の会員への共有にとどまらず、データサイエンスユーザーの裾野拡大に貢献する取り組みを継続

プレゼンス向上

- 海外ではアクチュアリー団体が、データサイエンス手法に関するチュートリアルやモノグラフの執筆を実施し（そしてそれが資格試験教材に）、規制当局がモデルガバナンス規程にデータサイエンス手法を導入している事例がある
- 日本としても、データサイエンスの導入を一層推進するべく、教育体制の強化や適切な情報提供が求められる