

## データ分析コンペティションとアクチュアリー

Guy Carpenter 藤田 卓君

Guy Carpenter 崎村 沙羅氏

Guy Carpenter 久下 康太朗君

アメリカンホーム医療・損害保険 荒井 智弘君

三井住友海上火災保険 伊藤 健太君

藤田 皆さん、こんにちは。「データ分析コンペティションとアクチュアリー」のセッションにお越しいただき、ありがとうございます。

### アジェンダ

1. 本セッションについて・コンペについて (15分)
2. パネリストによるプレゼンテーション (45分)
3. Q&Aセッション (30分)

2

本セッションは 90 分間のパネルディスカッションで、4 人のパネリストをお招きしております。また、大きく 3 部構成になっており、まず私の方から今回取り上げるコンペの概要についてお話しします。次に、パネリストの方々からコンペに参加された経験談を交えながら、構築されたモデルや最終結果についてお話ししたいと思います。最後に、Q Aセッションを設けております。

## セッション概要

2020年度開催された自動車保険に関するデータ分析コンペティション「Insurance Pricing Game」の参加者から、コンペの概要・採用したモデルと結果について発表したのち、アクチュアリー業務におけるモデリング手法活用の可能性やコンペへの参加等についてディスカッションを行う。

 Insurance Pricing Game - Motor Insurance market simulation



<https://www.aicrowd.com/challenges/insurance-pricing-game>

4

このセッションでは 2020 年度に開催された自動車保険に関するデータ分析コンペティション「Insurance Pricing Game」の参加者から、コンペの概要・採用したモデルと結果について発表したのち、アクチュアリー業務におけるモデリング手法の活用の可能性やコンペの参加等についてディスカッションを行うというものになっています。このコンペは、Aicrowd という団体が運営したものです。

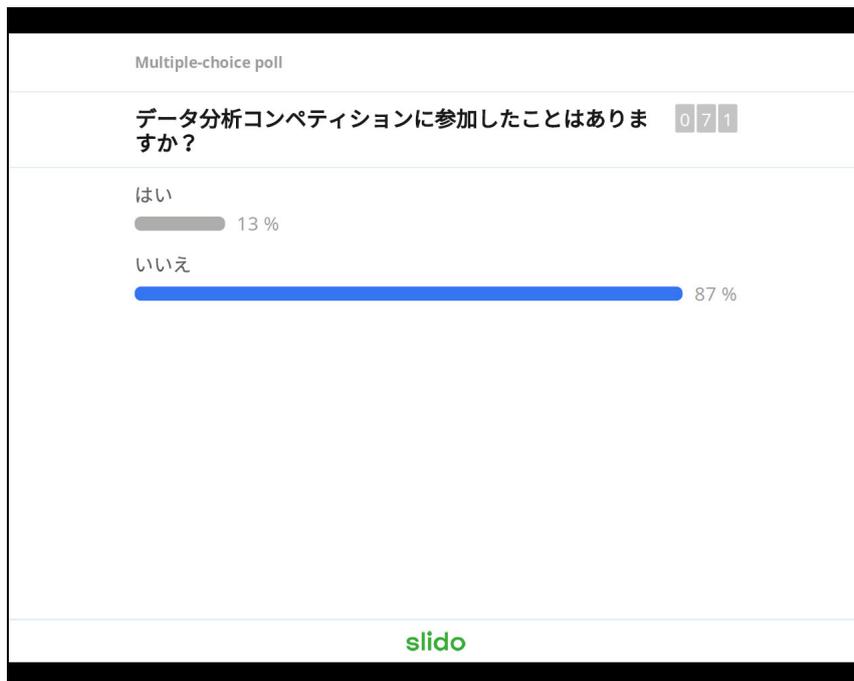
ここ最近、データサイエンスや機械学習にますます注目が集まる中、日本アクチュアリー会の会員で Kaggle Master や Kaggle Expert、また当該分野の第一線でご活躍されている方も少なくないと思います。そのような中、私自身、データサイエンスに興味はあって、いろいろ手は出しているのですが、コンペに関しては今回の「Insurance Pricing Game」が初めてでした。コンペ初心者としてのフレッシュな視点や、実体験について皆様に発信してシェアすることは、意義があると思いますし、また、このコンペ自体も世界的かつ大々的に開かれた保険アクチュアリー系コンペでしたので、データ分析コンペティションとアクチュアリーを議論する上ではうってつけのテーマだと考え、このセッションを開催する運びとなりました。

さて、ここでご視聴いただいている皆様に、Slidoを通して、いくつかご質問させていただきます。まず「データ分析コンペティションに興味はありますか？」



もちろん皆さん、「はい」を期待しているのですが、ありがとうございます。50人以上の方に、投票いただきました。90%以上の方は興味があるということでした。

続いて、「データ分析コンペティションに参加したことはありますか？」という質問です。

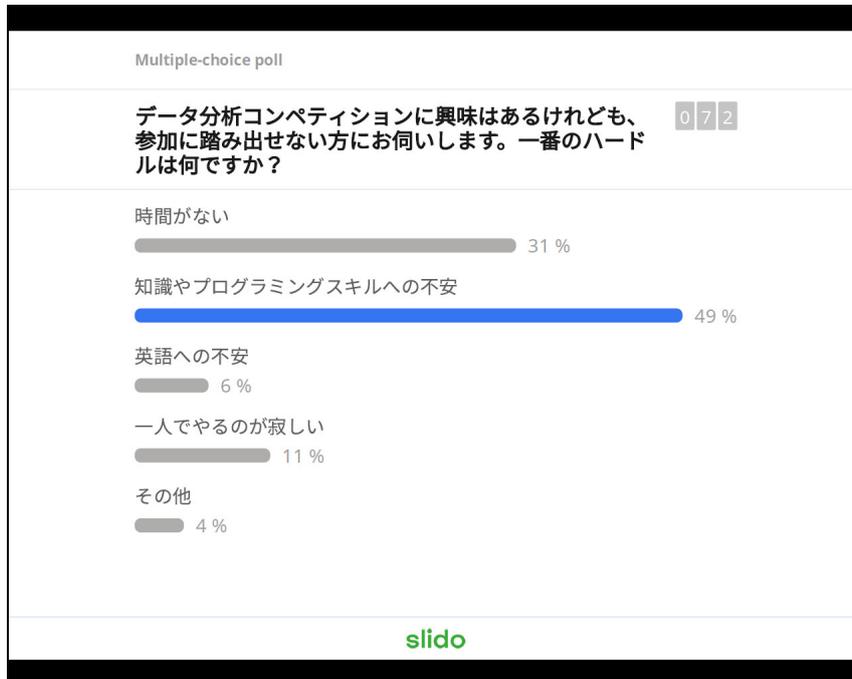


「いいえ」が8割9割程度になってきました。これは、面白いですね。皆様の周りも、このぐらいの分布でしょうか。

崎村 思ったより、参加していらっしゃる方が多いですね。

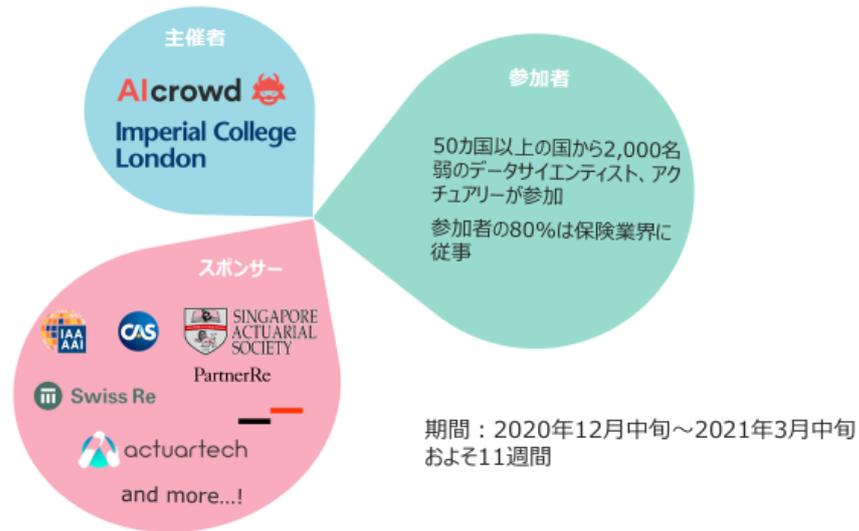
藤田 そのような印象ですか。とはいえ、やはり「いいえ」が多数派ですね。70人近くの人に投票いただきました。「いいえ」が87%、「はい」が13%という結果になりました。

では、もう一つだけ、ご質問させてください。「いいえ」の方々が多かったので、気になる点です。「データ分析コンペティションに興味はあるのだけれども、参加に踏み出せない方にお伺いします。一番のハードルは何ですか？」選択肢は「時間がないから」、「知識とかプログラミングスキルへの不安があるから」、「基本的に1人でやるのが寂しくて、仲間が欲しいから」、そしてコンペは基本的に英語で開かれているので「英語への不安があるから」、最後に「その他」、です。



「知識やプログラミングスキルへの不安」というものが最多です。2番目は、「時間がない」。確かに、普段の業務等やりながら、休日や時間外のところをどう工面するのかということが一つの課題になりますね。この質問も70人近くの方に投票いただいて、非常に興味深い結果が出てきました。こちらの結果は後ほどパネルディスカッションで、是非参考にさせていただければと思います。

## コンペの概要



7

では、「Insurance Pricing Game」について、解説させていただきます。データ分析コンペでは、企業などが抱えているビジネスや研究上の課題をテーマとしたタスクが取り上げられて、参加者は主催者により投稿されたデータを分析し、様々なモデルを構築して競い合います。提出されたモデルや結果は、予め定められた指標により順位付けされて、コンペによっては、上位の人に賞金やタイトルを付与するものもあります。このコンペは、AICrowd と Imperial College London という団体が運営主体となり、IAA（国際アクチュアリー会）や CAS（米国損保アクチュアリー会）などのアクチュアリー団体、また、スイス再保険等の再保険会社、インシュアテック企業である actuartech などがスポンサーとなり開催されました。参加者は 50 カ国以上の国から総勢 2,000 名弱集まり、その多くは保険業界で働くアクチュアリーやデータサイエンティストでした。期間は 2020 年の 12 月中旬から 2021 年の 3 月中旬、およそ 11 週間に亘り、賞金は総額 1 万 2,000 ドルという規模のものでした。

# コンペのルール

## ルール：



参加者は自動車保険を引き受ける  
保険会社となり、プライシングモデル  
を作成し、他社と利益を競い合う

- この仮想的市場では、顧客は常に最も安価な保険に加入する (the cheapest-wins-market)
- 保険契約の販売に成功した場合、保険料が収益に計上される一方、当該契約に将来クレームが発生した場合、損失に計上される

## 評価尺度：



### 予測精度

- クレーム総額に対するRMSE（平方平均二乗誤差）
- フィードバックは瞬時



### 利益

- 最終順位は利益の多寡で決定
- フィードバックは週次

8

コンペのルールです。参加者もしくは参加チームは、自動車保険を引き受ける保険会社となります。まず、学習データとして自動車保険のクレームデータが与えられます。それからプライシングモデルを構築して、他のチームとテストデータに対する利益を競い合うこととなります。つまり、参加者全員により、仮想的な保険市場が構成されることとなります。この市場では顧客は最も安い保険料を提示した保険会社の保険に加入するという the cheapest-wins-market ルールに従います。保障内容や過去の保険会社の実績など、現実世界の保険市場で比較され得るその他の要素は考慮されません。引き受けた保険契約に対する保険料は、全額が収益計上され、契約にクレームが発生した場合は、保険金支払が生じ、損失計上されます。その差額が、当該保険契約の利益となります。

評価尺度は、二つあり、一つはモデルの予測精度を示すもの、すなわちクレームの予測金額と実績金額の RMSE（平方平均二乗誤差）です。もう一つの評価尺度は利益額です。ただし、最終順位は利益額のみで決定されます。

また、参加者は提出したモデルのフィードバックを得ることができます。利益額は週に一度、RMSE については提出の都度、確認することができます。

## コンペのルール 例

	Company 1	Company 2	Claim amount
Policy 1	120	90	100
Policy 2	30	25	10
Policy 3	10	15	0
Policy 4	5	10	0
Total revenue	15	115	
Total loss	0	110	
Total profit	15	5	
予測精度 (小さいほど良い)	15.2	12.7	

• 予測精度の高低が利益の多寡に必ずしもつながらない  
 • 理想的には、実際のクレーム総額に可能な限り近いが、わずかに高いプライスを設定することが望ましい

Most profit: 15 (Company 1)  
 Most Accurate: 12.7 (Company 2)

ここで、the cheapest-wins-market について、具体例を用いて解説します。このスライドは、Company 1 と Company 2 の 2 社が 4 つの保険契約、Policy 1 から Policy 4 に対して、プライシングを行った例になります。例えば、一番上の Policy 1 に着目すると、Company 1 より Company 2 の方が安い保険料を提示していることが分かります。したがって、Policy 1 の顧客は、Company 2 の保険に加入することになります。そして Company 1 にはゼロ、Company 2 には 90 の収入が計上されます。一方で、Policy 1 には、100 というクレームが発生しました。そうすると、その分 Company 2 には損失が計上されて、結果的には、Policy 1 に対する Company 1 と Company 2 の利益は、それぞれゼロとマイナス 10 となります。つまり Company 1 の利益の方が高いこととなります。

同様に Policy 4 まで見ていくと、予測精度は Company 2 の方が良いのですが、利益は Company 1 の方が高いため、Company 1 の勝利となります。つまり、予測精度の高さは利益の大きさに必ずしもつながらないことを示す例になります。上位を狙うためには、保険契約ごとの期待クレーム額を適切に見積もって、まずは、保険契約を勝ち取ることができるような競争力のあるプライスを提示して、その上で、利益を上げる必要があります。

# データとフィードバック



## ポリシー情報

- 補償範囲
- タイプ
- 保険料払方



## 運転者情報

- 年齢
- 性別
- 事故履歴



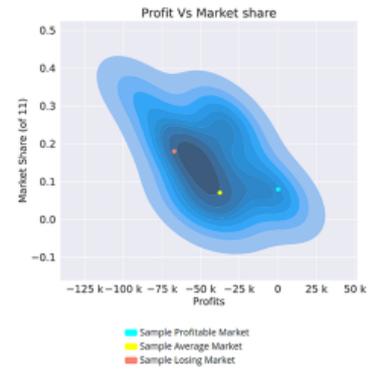
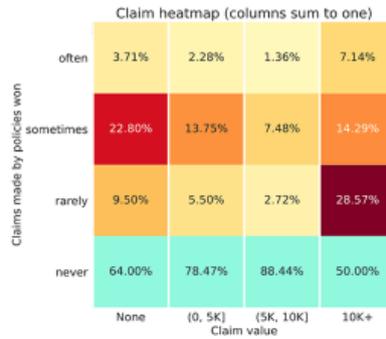
## 車両情報

- 価格
- 重量
- 最高速度



## 地理情報

- 人口
- 街の面積



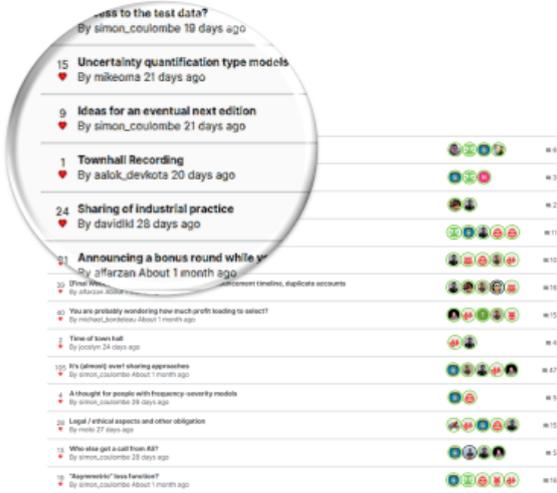
10

このコンペで用いられたデータは、あるヨーロッパの保険会社の自動車保険契約、約 10 万件を対象として、それらに対する連続した過去 5 年間のクレームデータを匿名化したものです。データの特徴量は、補償内容等の契約情報、運転者の年齢や性別等の運転者情報、車両価格や車両重量等の車両情報、契約者が住む土地の人口や面積等の地理情報を含む数十個のもので構成されています。コンペの規約上、これ以上の詳細は話すことができませんが、ご承知おきください。

またスライドの右側に示すように、提出したモデルのパフォーマンスに関するフィードバックが毎週得られます。例えば、右上は参加した市場における利益および市場シェアの分布、中央下図は横軸にクレーム額のレンジ、縦軸にはその引き受けた度合いを表したヒートマップ、それ以外にも種々の KPI などが得られます。これらをもとに、翌週の戦略を考えていくことになります。

# ディスカッションボードとリーダーボード

## ディスカッションボード

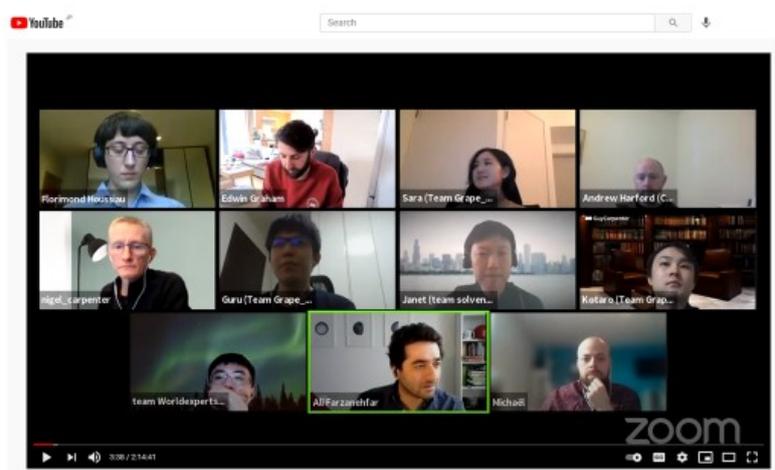


## リーダーボード (ランキング)



また、ディスカッションボードが設置されており、コンペのルールやデータに関する疑問点の解消、モデリングに関する議論を行うことができます。そして、リーダーボードでは、自身の現在の順位を把握したり、他のチームの状況を見ることができます。

# タウンホールと最終結果



<https://www.youtube.com/watch?v=GkU2IqZu1qA>

こうして、およそ 11 週間という時間が過ぎて、最終締切日を迎え、そこから約 2 週間後、本コンペに関するタウンホールがオンラインで開かれました。そこでは、最終結果や優れたモデルの紹介、パネルディスカッションなどが行われました。タウンホールは、YouTube 上で公開されていますので、ご興味ある方は、是非、お時間のあるときにご覧ください。

## パネリストのご紹介



荒井 智弘 様

- アメリカンホーム医療・損害保険株式会社
- 社会人11年目
- 決算、リスク管理
- コンペの経験：無し



伊藤 健太 様

- 三井住友海上火災保険株式会社
- 社会人3年目
- 決算、リスク管理
- コンペの経験：無し



崎村 沙羅 様

- Guy Carpenter Japan, Inc.
- 社会人4年目
- 再保険プライシング
- コンペの経験：無し



久下 康太郎 様

- Guy Carpenter Japan, Inc.
- 社会人12年目
- 自然災害リスク分析
- コンペの経験：無し

14

では、私からの説明は以上です。ここからは、パネリストによるプレゼンテーションに移っていきたいと思います。パネリストの方々をご紹介します。まず、アメリカンホーム医療・損害保険株式会社の荒井智弘様、続いて、三井住友海上火災保険株式会社の伊藤健太様、最後に、ガイカーペンタージャパンの崎村沙羅様、久下康太郎様、以上の4名をお招きしております。どうぞよろしくお願ひします。スライドに簡単にプロフィールも掲載しましたが、それぞれの一番下に着目ください。皆様この「Insurance Pricing Game」が初めてのコンペ参加でしたので、初参加の感想や、どのようなものだったのかという経験談を、共有していただければと思います。

## テーマ

1. データ分析コンペティション体験談  
～ **Accurate GLM**を使って世界に挑戦 ～
2. 保険データへの**NGBoost** モデルの適用  
－ Insurance Pricing Game 参加報告 －
3. 保険データ分析コンペの参加体験談  
－ **STACKING GLM** の紹介 －

15

まず、荒井様から「データ分析コンペティションの体験談～Accurate GLM を使って世界に

挑戦～」続いて、伊藤様から「保険データへの NGBoost モデルの適用—Insurance Pricing Game 参加報告—」という題でご発表いただきます。最後に「保険データ分析コンペの参加体験談—STACKING GLM の紹介」を崎村様からご発表いただければと思います。

それでは、荒井様、よろしくお願いいたします。



荒井 皆さんこんにちは。アメリカンホーム医療・損害保険株式会社の荒井と申します。よろしくお願いいたします。私からは、データ分析コンペに今回参加してみて、その経験談などをお話しさせていただければと思います。

まず、データ分析コンペに参加したきっかけですが、副題にも書きましたとおり、Accurate GLM に興味を持っていたことでした。Accurate GLM 自体は、オーガナイザーの藤田様が 2018 年の年次大会で発表された内容でして、当時、とてもいいモデルだなと思って聞いていたところ、ちょうどいいコンペがありましたので、これを機に参加してみようという経緯です。実際、AGLM は、とても使いやすく、コンペ初心者であったとしても、それなりに精度がいいモデルを作ることができたので、その点を中心にお伝えできればと思っています。

## 始めに

### 初参加の漠然とした不安

- データ提出するだけでもハードル高そう
  - 難しいモデルを知らないと世界では勝てなそう
  - Rは業務で多少使うレベル、Pythonは趣味レベル
- ➡ それでもコンペに参加してみたい！



### 参加してみて感じたこと

- サイト内でTutorial が充実している
  - 一般化線形モデルの拡張であるAGLM\*を使えば戦える
  - サイト内のDiscussion機能での論議が参考になる
- ➡ コンペに参加する意義は大きい  
(知識の深化、順位が付くことの楽しさ etc.)

#### \*AGLM: Accurate Generalized Linear Model

一般化線形モデル(GLM)に次の3つのコンセプトを組み込んだもの

- ① 離散化 (Discretization/Binning)
- ② 0ダミー変数 (Ordinal Dummy Variables)
- ③ 正則化 (Regularization)

参考：2018年度 日本アクチュアリー会 年次大会  
「アクチュアリーとモデル選択 (Accurate GLM)」

注意事項：本資料は個人の見解であり、所属する組織を代表するものではありません。 2

まず、私自身が初参加でしたので、初参加者なりの不安や対応など、そのようなところをまとめました。実際、データ分析のコンペの Web サイトを見ると、そもそも何を求められているのか、何を提出したらいいのか、それらを把握するだけでも結構大変なことです。さらに中身を見ていくと、XGBoost など格好いい言葉がたくさん並んでいて不安にもなりますし、自分自身のスキルも、R や Python を多少は使っているけれどもといったレベルでしたし、いろいろな障壁があって、なかなか踏み出せない分野だと思っております。

しかし、実際に参加してみて感じたことは、そこまで思ったよりハードルが高くないということです。まず、データを提出するということが最初のハードルですが、コンペ主催者もいろいろな人にコンペに参加してもらいたいという思いがあると思いますので、チュートリアルがとても充実しています。なので、簡単なモデルを提出するだけに限って言えば、それほど苦労はなかったように思います。また、XGBoost などそのようなモデルを知らなくても、アクチュアリーが慣れ親しんでいる一般化線形モデル、その発展系の AGLM を使えば、十分世界で通用するということも分かりました。サイト内でのディスカッションボードに R や Python などのコードを公開している方もいらっしゃるのでも、それも非常に勉強になりました。参加した結論としては、とても有意義で、良かったと思います。なお、今回のプレゼンのテーマである AGLM について詳しく説明することは省きますが、簡単に言えば、一般化線形モデルに「離散化」、「0 ダミー変数」、「正則化」、という三つのコンセプトを組み込んだモデルになります。

American Home  
**Direct**  
Member of AIG

## 戦略を考える

### コンペの特徴

#### モデルの最適化

- 🎯 いかに正確にロス予測できるか
- 🔑 モデルや説明変数の選択、交互作用項の付加 etc.
- 🔍 RMSE Leaderboardでモデルの正確性を確認可能  
RMSE: Root Mean Square Error

Try & errorでモデルの改善が可能

#### プロフィットの最大化

- 🎯 いかに競争市場で利益獲得できるか
- 🔑 リスクマージンの大きさ、他参加者の動向 etc.
- 🔍 週次のフィードバックで、獲得できた利益及び順位を確認可能

運の要素が強い

### 個人的な想い

- ◆ AGLMを使ってみたい
- ◆ 初参加ゆえ、難しいことは出来ないだろう



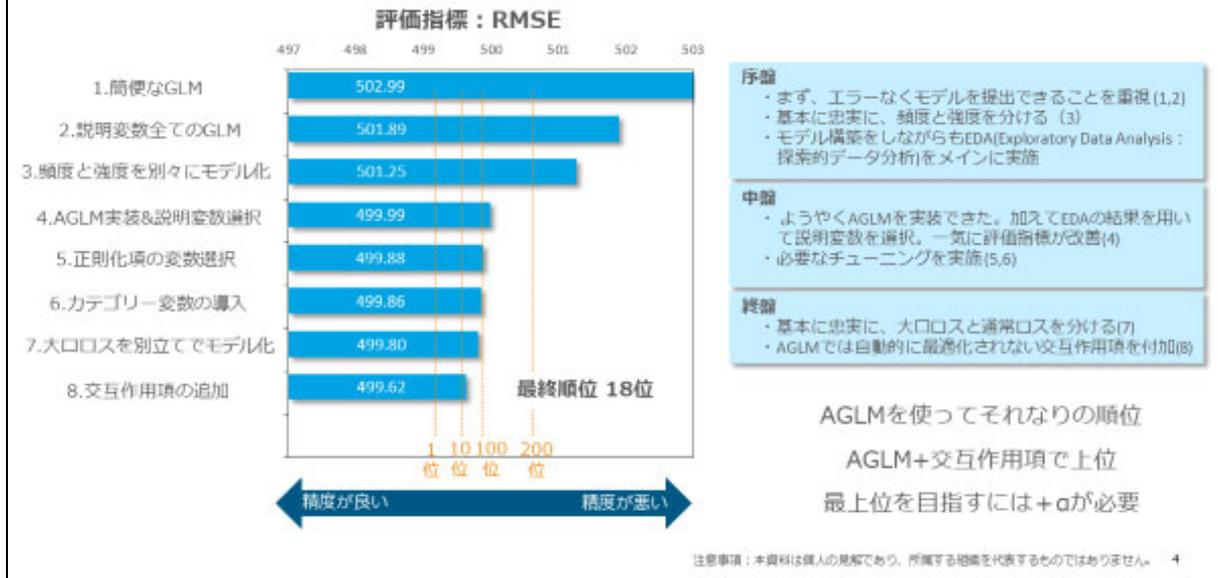
- ◆ モデルの最適化を一番に考える
  - AGLMを使って、どこまで精度を高められるか
- ◆ プロフィットの結果は楽しむ程度

注意事項：本資料は個人の見解であり、所属する組織を代表するものではありません。 3

では、早速内容に入っていきます。まず、戦略について、です。藤田様のイントロダクションにもあったとおり、このコンペの特徴は二つに分かれると思います。一つが、保険金のロスをいかに予測できるかというモデルの最適化の問題、もう一つが、保険料にマージンを乗せて、どのぐらい利益が取れるかというプロフィットの最大化の問題になります。一つ目のモデルの最適化にあたって RMSE という評価指標で正確性を順位付けしていくのですが、RMSE はモデルを提出すると直ちにフィードバックが得られます。なので、何度も Try & error を繰り返すことで、モデルを改善することが可能です。一方で、プロフィットの最大化に関しては、リスクマージンをいかに乗せるか、また、他の参加者がどのような料率設定をしているのかなどにも依存しますので、運の要素が強いという特徴があります。

加えて、AGLM を使ってみたい、初参加なので難しいこともできないだろうなどといった個人的な想いもあり、王道路線を取ることにしました。つまり、スライドの一番下に書いたとおり、モデルの最適化を一番に考えよう、ということです。なので、AGLM を使って、どこまで精度が上げられるのか挑戦してみることにしました。一方、プロフィットの最大化の方は、フィードバックを見ながらマージンを決定して、楽しむ程度で考えていました。

## モデルを最適化する



このスライドは、今回、自分がメインテーマにしたモデルの最適化について、です。左の図が、作成した各モデルに対する評価指標を表しています。ただ、必ずしもこの順番でモデルを開発していったわけではなく、どの改善指標で、どのぐらいの改善度合いがあったかということ、コンペ後に分かりやすくまとめたものになります。したがって、例えば、最後の8番で交互作用項の追加をしています。その際に、4番にある説明変数を調整したりなど、行ったり来たりしている部分もありますので、ご承知おきいただければと思います。

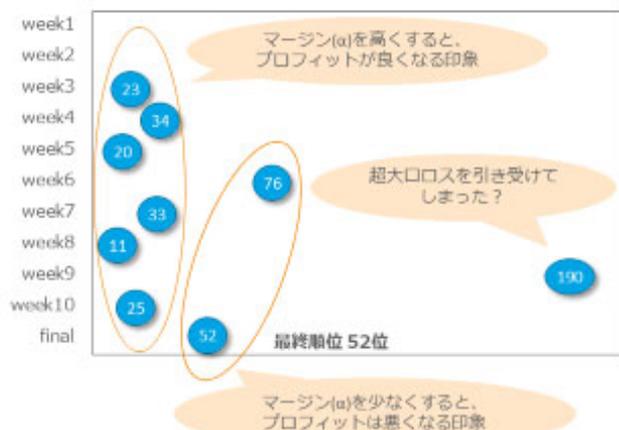
モデルを作る過程では、やはりエラーなくモデルを提出するといったところが最初が一番難しいところでした。まずは簡単なGLMや頻度、強度を分けたモデルを作りつつ、EDAと言われるデータ分析などを中心に行っておりました。その後、ようやくAGLMを実装することができたのが4番のあたりで、評価指標がかなり改善しています。この3番から4番の評価指標の改善からもAGLMの強さや、使い勝手の良さが、分かっていただけだと思います。

AGLMの良さは三つの要素がバランスよく組み込まれているところだとは思いますが、私自身の考察としては、0ダミー変数化のところが一番強力ではないかと思います。0とはOrdinaryの頭文字で、順序を意味しています。自動車保険の場合、年齢によってロスの変化が大きくて、若年層はロスが高く、中年層はロスが低く、高年層がまた高くなると、そのように曲線を描きます。そのような特性をどうやってモデルで表現するのかというのが、結構悩みどころです。AGLMの0ダミー変数のような、順序の要素を含んだモデルを使うことで実態をうまく表現できるのだらうと思っています。

AGLMの実装後も、パラメーターのチューニングをしていきましたが、どうにもこうにも評価指標があまり良くなり悩んでいたところ、とある恩師の方から、「AGLMの場合、交互作用項を自分で判断して入れないといけないですね」というアドバイスをいただいて、交互作用項のデータ分析を行いました。分析した交互作用項をモデルに入れ込んだところ、かなり評価指標が改善され、最終的には値は499.62、順位では18位、初心者としてはそれなりに良い順位が取れたのではないかと思います。まとめると、AGLMを使うだけでも、一定程度の順位になる上、そこに交互作用項を入れると、さらに上位でも戦えるということが分かりました。

## プロフィットを最大化する

### 順位の変遷



#### 全般

- ・ロスの期待値に一定割合( $\alpha$ )を乗せて保険料設定
- ・通常ロス  $\times (1+\alpha1)$  + 大口ロス  $\times (1+\alpha2)$  とマージンは分けて設定
  - $\alpha1$  を小さくし、リスクの低い集団の利率競争力を確保
  - $\alpha2$  を大きくし、リスクの高い集団でも収益性確保 (大口ロスの可能性のある契約も一定引き受ける戦略)
- ・  $\alpha1$  と  $\alpha2$  は週次のフィードバックを見て決定

マージンが高すぎると、獲得契約が減少  
マージンが小さすぎると、損害率が上昇  
適切なマージン設定が難しい

注意事項：本資料は個人の見解であり、所属する組織を代表するものではありません。 5

続いては、プロフィットの最大化の問題になります。こちらは、ロスの期待値がまずあって、どの区分にどの程度のマージンを含めるかが、勝負の分かれ目になります。個人的には、不確実性に応じてリスクマージンを設定するという、いわゆるリスクベースプライシングをやりたかったのですが、時間が取れなかったため、簡便的な手法を採用しました。具体的には、通常ロスと大口ロスを分けて、それぞれに対して違うマージンを乗せるというような形で挑戦してみました。どのぐらいマージンを乗せるかは、フィードバックを見て決定していました。

左の図が順位の変遷になります。ご覧のとおり、かなり変動が大きい印象です。利益を上げようとマージンを高くすると、契約が減少します。一方で、契約をたくさん取ろうとマージンを少なくすると、損害率が上昇してしまう。モデルが正しいのであれば、損害率の上昇は抑えられるような気がするのですが、実際にはモデルに使うデータと、競争に使うデータが違うという、いわゆるパラメータリスクがありますので、このような結果になったのではないかと考察しています。

## 終わりに

- AGLMは初心者でも使いやすい
  - ◆ 世界と比肩できる程度に精度が良いモデルを簡単に作成できる
  - ◆ 自身で設定したい変数は自分でも設定できる（説明変数やリンク関数の選択 etc.）
  - ◆ 自身で設定するのが難しい変数は自動で最適化できる（正則化の重みの程度 etc.）
- モデルの精緻化と同じくらいEDAも重要
  - ◆ データの裏にある事象を想像する力
  - ◆ 定量的・定性的観点から説明でき、評価指標が改善される要素を危険標識として採用した
    - ➔ 人口密集度が高い地域の高齢者の通常ロスの多い
    - ➔ ブレーキとアクセルの踏み間違いによる事故が多い？
    - ➔ 地域・年齢の交互作用をモデルに組み込むと評価指標改善→採用
- さらに上位に行くためには、気合と根性

ご清聴頂き、ありがとうございました。  
ご興味を持たれた方、次の機会と一緒に参加しましょう♪

注意事項：本資料は個人の見解であり、所属する組織を代表するものではありません。 6

最後に、まとめです。これまでお話したとおり、AGLM はコンペ初心者でもかなり使いやすく、簡単に精度が良いモデルを作ることができます。私自身、AGLM で良いと思うところは、バランスの良さだと感じました。例えば、説明変数を決めるときに、ステップワイズなどを使えば自動で選択することもできますが、今回、私はどの変数を選択するかは自分で行いたいと思いました。一方で、正則化の重みなどは、自分で決定することはなかなか難しく、AGLM を使って自動で設定することができます。そういった、自分で設定したいところと、自動で最適化したいところが自由に選択できるという汎用性の高さは、AGLM の良いところだと思います。

もう一点感じたことは、モデルの精緻化を進める上で、EDA も重要だと思っています。EDA の定量的な結果に対して、定性的に説明できる要素をモデルに入れ込むというようなプロセスで今回やりました。そうすることによって、モデルの改良度や改良スピードが速くなったかなという印象を受けています。

最後、反省点になりますが、さらに上位に行くためには、より多くのモデルを提出して、評価指標に用いるデータの中身を探りに行く、そのような気合と根性が必要なのかなと感じました。私からは以上になります。ご清聴頂き、ありがとうございました。続きましては、伊藤様の発表になりますので、よろしくお祈いします。

# 保険データへのNGBoostモデルの適用

## — Insurance Pricing Game参加報告 —

2021年11月5日  
三井住友海上 伊藤 健太

**MS&AD** 三井住友海上火災保険株式会社

※本発表に含まれる内容・意見は個人の見解であり、所属する組織を代表するものではありません。

Copyright 2021 © Mitsui Sumitomo Insurance Co., Ltd. All rights reserved.

伊藤 それでは、私の発表に移らせていただければと思います。先ほどご紹介をいただきました、三井住友海上の伊藤と申します。本日はよろしくお願いたします。

まず、このコンペに参加した経緯をご説明すると、私も、データサイエンスや機械学習といった分野は、流行していることもあり興味を持っていたのですが、コンペとなると、先ほどのアンケートの多くの皆さんと同じように、少しハードルが高いと思っておりました。そのような中で今回、保険のデータを使った、さらにアクチュアリー向けのちょうどよいコンペがあるということで、思い切って参加してみた次第です。私の発表では、コンペに取り組んだ中での戦略や最終的に使ったモデル、結果などについて具体的にお話ししていきたいと思います。

### コンペ概要

次の2要素が組み合わさったタスクと捉えることができる：

①個々の契約者における事故発生予測の最適化  
(通常の機械学習タスクにおける回帰問題に帰着)

+

②保険料の上乗せ水準の最適化  
(本コンペティション特有、絶対評価ではなく他の参加者との相対評価  
アクチュアリー的観点：保険料算出原理、プライシング)

①については「RMSE Leaderboard」、②については毎週の「Profit Leaderboard」によりそれぞれ見積もり可能(いずれも本番とは別データ)

立ちどまらない保険。  
**MS&AD** 三井住友海上

Copyright 2021 © Mitsui Sumitomo Insurance Co., Ltd. All rights reserved.

1

先ほど、藤田様、荒井様からもご説明があったとおりですが、このコンペは自動車保険のプ

ライシングを行うコンペとなります。私はこのコンペを、次の二つの要素が組み合わさったタスクとして捉えました。一つ目は、①個々の契約者における事故発生予測の最適化、各契約においてどのくらい事故が起きるのかを予測することで、これは、典型的な機械学習における回帰の問題に帰着できるかと思えます。二つ目は、②保険料の上乗せ水準の最適化で、これが、このコンペ特有の面白い点ですが、他の参加者よりも利益を出すというところが最終的な評価指標になっているため、①の事故発生予測をもとに、保険料の水準を最適化していくということが必要になります。当然、他の参加者がどのくらい保険料を上乗せするのかということが影響しますので、絶対評価ではなく相対評価になります。また、プライシングという意味では、アクチュアリー的な観点も含まれているかと思えます。

モデルに対するフィードバックとして、①に対しては「RMSE Leaderboard」、誤差の平均の順位表が、②に対しては毎週の「Profit Leaderboard」、利益の順位表があります。これら二つの Leaderboard によって、それぞれ最適化の程度の見積もりが可能となっています。これらのフィードバックを活かしながら、自分のモデルを毎週バージョンアップしていきました。

### 戦略・取組内容①

---

○ コンペ序盤～中盤

- LightGBMモデルを用いてロス発生額を予測、予測結果を一律 $\alpha$ 倍して価格設定  
→上乗せ水準 $\alpha$ の調整によりそこそこ奮闘(20位前後)も、最上位層とは大きな差あり…

LightGBM :

多くのコンペ等で実績を残している、  
勾配ブースティング決定木(GBDT)系モデルの一つ

良い点 ・ハイパーパラメータ設定の幅が広く、設定次第で  
多様な問題設定において高精度な予測が可能  
・不要な特徴量(=変数)の追加についてロバスト

悪い点 ・ハイパーパラメータのチューニングには、一定の“慣れ”や“経験”が必要な部分も…  
・説明可能性・解釈性の問題(近年では多くの解決手法が提案されている)

勾配ブースティング(概略図)

```

graph TD
    A[元データ] -- 学習 --> B[h0(x)]
    A -- 学習 --> C[予測誤差データ]
    C -- 学習 --> D[h1(x)]
    C -- 学習 --> E[予測誤差データ]
    E -- 学習 --> F[予測誤差データ]
    F -- 学習 --> G[hm(x)]
    B -- 予測 --> H[F(x) = sum yi hi(x)]
    C -- 予測 --> H
    E -- 予測 --> H
    G -- 予測 --> H
            
```

立ちどまらない保険。  
MS&AD 三井住友海上

Copyright 2021 © Mitsui Sumitomo Insurance Co., Ltd. All rights reserved.

2

では、具体的な取り組み内容の説明に移ります。まず、コンペの序盤では、LightGBM というモデルを用いてロス発生額を予測した上で、その予測結果を定数倍して価格設定するという方針を進めました。LightGBM とは、聞きなれない方もいらっしゃるかもしれませんが、多くのコンペ等で実績を残している、勾配ブースティング決定木と呼ばれるモデルの一種です。勾配ブースティング決定木は、決定木を組み合わせたモデルとして、同じように決定木を組み合わせるモデルにランダムフォレストというものがありますが、ランダムフォレストがたくさんの決定木を一斉に並列的に組み合わせるのに対して、ブースティングは、たくさんの決定木を数珠つなぎのように直列的に組み合わせるモデルと考えていただければよいと思います。勾配ブースティング決定木系のモデルの利点として、ハイパーパラメーターの設定が大変なもの、設定次第では、多くの問題設定において、特に精度という点においては、非常に高いパフォーマンスを発揮できるということがあります。今回は、先ほどの①の通り、予測精度

を高めることが一つの重要な目標になりますので、最初のうちはこの LightGBM モデルを用いて取り組みました。

このモデルでは、毎週の「Profit Leaderboard」において、予測結果の定数倍部分を調整することによって、ある程度は善戦できていたものの、最上位の層とは大きな隔たりがありました。より上位に行きたいと思ったとき、何か別のことをしないといけないだろうと思い、次の戦略を考えることにしました。

### 戦略・取組内容②

---

○ コンペ序盤～中盤(続き)

- 「RMSE Leaderboard」の順位と「Profit Leaderboard」の順位にあまり相関が無い
- 最上位層の参加者が利益を独占し、それ以外の参加者は赤字
  - (期待値一点の) 予測精度を上げるよりも、価格設定の工夫に注力すべきと判断
  - (“予測値を一律  $\alpha$  倍” とは別の価格設定を考えたい)
- 『損保数理』教科書の「保険料算出原理」を思い出す…
  - 価格設定に、ロス発生額の期待値のみでなく、標準偏差など他の統計量も用いていた

$$P(X) = \frac{\log M_X(h)}{h} \quad P(X) = \mu_X + h \cdot \sigma_X$$

$$P(X) = \min\{p \mid F_X(p) \geq 1 - h\}$$

$$P(X) = (1 + h)\mu_X$$

$$P(X) = \mu_X + h \cdot \sigma_X^2$$

⋮

⇒ 個々の契約について、ロス発生額の分布まで予測できるモデルを導入することを考える

立ちどまらない保険。  
MS&AD 三井住友海上

Copyright 2021 © Mitsui Sumitomo Insurance Co., Ltd. All rights reserved. 3

次の戦略を考える中で、いくつかの分析を行った結果、「RMSE Leaderboard」、精度の順位と「Profit Leaderboard」、利益の順位、この 2 つに思ったよりも相関がないということに気付きました。また、週によっては、最上位層の参加者が利益を独占して大きく利益を上げている一方、それ以外の参加者はほとんど赤字、ということもありました。

これらを踏まえ、予測精度を追求していくことももちろん大事ですが、そちらの方面で頑張るよりも、価格設定の工夫に注力すべきだろうと判断しました。特に、予測結果を一律定数倍するのは別の価格設定方法を考えたいと思いました。そうした中で今回は、アクチュアリー向けのコンペということもあり、アクチュアリー会、損保数理の教科書の、保険料算出原理の章を思い出しました。保険料算出原理では、価格設定の際にロス発生額の期待値だけではなく、例えば、標準偏差や%値などといったような、他の統計量も用いていたかと思います。これを踏まえ、私のプライシングモデルにも、個々の契約についてロス発生額の分布まで予測できるようなモデルを導入して、その分布から標準偏差などの統計量を計算し、これも価格設定に反映させることを考えました。

### 戦略・取組内容③

LEVEL 0: 全体の期待値を予測



例)  
・平均値  
(一律に適用)

LEVEL I: 個々の契約について期待値を予測



例)  
・XGBoost, LightGBM  
・Random Forest  
・ニューラルネット

LEVEL II: 個々の契約について分布(≒期待値・標準偏差)を予測



例)  
・GLM及びその派生  
・ベイズモデリング  
・NGBoost

より直感的に、こちらの図で考え方を説明させていただければと思います。まず、一番上の最も単純なモデル (LEVEL 0) として、全体の期待値を一律に予測するモデルを考えることにします。そこから1歩進めたもの (LEVEL I) として、個々の契約についてそれぞれ期待値を予測するようなモデルが考えられます。これは、先ほどご説明した LightGBM や、スライドの右の例に書いてあるようなモデルも含まれるかと思います。今回私がやろうとしたことは、さらにもう一段階進めて (LEVEL II)、個々の契約について分布まで予測できないかということです。個々の契約について分布を予測したいとなったときに、いくつかの方法が考えられますが、例えば、誤差の分布の仮定を残したまま GLM をやったり、その派生形であったり、あるいは、ベイズモデリングなども候補になりますが、今回は、NGBoost というモデルを使って、これを達成しようと試みました。

## 戦略・取組内容④

### ○ コンペ終盤

- ロス発生額分布の予測モデルとして、NGBoostを導入した。

NGBoost: <https://stanfordmlgroup.github.io/projects/ngboost/>, <https://arxiv.org/abs/1910.03225>

- ・ XGBoost, LightGBM等と同様、勾配ブースティング法の派生モデルの一つ
- ・ 予測値一点の値ではなく、予測値の確率分布を返す
- ・ XGBoost, LightGBMがノンパラメトリック(=分布を仮定しない)モデルであるのに対し、NGBoostでは予測値  $y$  について確率分布  $P(y|\theta)$  を仮定し、パラメータ  $\theta$  についてブースティングを行う

- NGBoostモデルより得られた予測分布から個々の契約について統計量(期待値  $\mu$ 、標準偏差  $\sigma$ )を算出し、これらを組み合わせることで最終的な保険料を算出した。



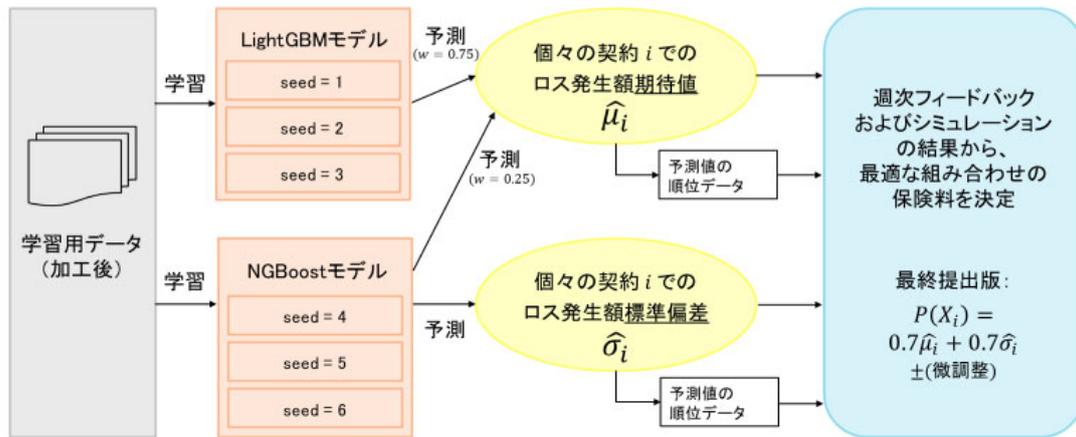
(図: 上論文より引用)

いまご説明した通り、コンペの終盤には、ロス発生額分布の予測モデルとして、NGBoost モデルというものを導入しました。これは、XGBoost や LightGBM といった勾配ブースティング系モデルの派生形の一つとなります。特徴としては、一点の予測値ではなく、予測値の確率分布を返すようなモデルになっており、まさに今回やりたい目的と一致しています。XGBoost や LightGBM がノンパラメトリック、つまり、分布を仮定せずに予測値  $y$  をそのまま当てにいくようなモデルであるのに対して、NGBoost では、この予測値  $y$  について、まずパラメトリックな確率分布を仮定して、そのパラメーター  $\theta$  についてブースティングを行うモデルになります。2019年頃に出てきたモデルです。よろしければこちらのリンク先をご参照ください。

スライド右下の図が直感的なイメージに近いのですが、黒い実線が期待値一点の予測値だとすると、そこからの散らばり具合まで予測できるようなモデルとなっています。このモデルから得られた予測値の分布から、個々の契約について、期待値・標準偏差を算出し、これら統計量を組み合わせることで、最終的な保険料を算出しました。

## 戦略・取組内容⑤

### ○ 最終モデル全体図



最終モデルの全体図です。いま説明した NGBoost が、ちょうど下半分の赤四角になっており、個々の契約  $i$  でのロス発生額の期待値と標準偏差をそれぞれ予測しています。また、上半分には前半に説明した LightGBM モデルがありますが、こちらは期待値の予測を補強するために用いています。こうして、二つのモデルから予測した黄色の丸二つ、個々の契約  $i$  でのロス発生額の期待値と標準偏差を組み合わせることによって、最終的なプライシングを行いました。また、この組み合わせるときの係数としては、週次の Profit Leaderboard (利益のフィードバック) の結果や、手元でのシミュレーションの結果を踏まえて、最終的には  $(0.7, 0.7)$  と設定しました。

## 最終結果

### ● 全体12位

	Overview	Leaderboard	Notebooks	Resources	Submissions	Pick submission for profit leaderboard			
10	Grape_Century	Yes	1453.249	0.006	1	Mon, 8 Mar 2021 12:5			
11	mohith_k_sakt...	Yes	487.231	0.000	1	Tue, 2 Feb 2021 18:0			
12	tmon01	Yes	198.359	0.000	1	Mon, 8 Mar 2021 04:C			
13	iminokhi	Yes	10.161	0.003	1	Sat, 6 Mar 2021 21:1			
14	Jeremiedb	Yes	8.803	0.000	1	Sun, 17 Jan 2021 05:5			
15	dmitri	Yes	-33.749	0.001	1	Tue, 2 Mar 2021 19:5			
16	themathsguy	Yes	-107.520	0.000	1	Mon, 1 Mar 2021 05:5			

この最終モデルを提出し、全体で 12 位という結果が得られました。参加人数が 2,000 人弱

で、うち何人かはチームを組んでいるところで、初参加にしてはまあまあ良い順位が出せたのではないかと考えております。ちなみに、10位に3人チームが見えますけれども、これが実は日本人のチームで、こちらが次の発表になっております。楽しみにしていただければと思います。

## 反省・展望

### ○ コンペの反省

- 最上位層と比較すると、低リスク契約の保険料を十分に下げることができず、結果市場シェアを確保できなかった。
- NGBBoostモデルを導入するタイミングが遅く、保険料の水準を十分に調整することができなかった。

### ○ NGBBoostについて

- 現在公開されているバージョンでは、選択できる確率分布の種類は少ない  
(例えばガンマ分布等も理論的には実装可能と思われるが、未だ実装されていない)
- XGBoostやLightGBMと比較すると、期待値一点の予測精度ではやや劣ることが経験的に知られている
- 他の機械学習モデルと比べると、アクチュアリーとの親和性は高い…?  
(パラメトリックな確率分布を仮定、期待値だけでなくリスクまで含めて予測、…)
- Boosting系モデル周辺は急速かつ多様に発展しており、今後の動向にも大いに注目が集まる

コンペの反省としては、結果論ではありますが、最上位層と比較するとリスクの低い契約の保険料を十分に下げることができなかったため、市場シェアを確保できず、あまり利益を上げられなかったというところがあります。また、途中から先ほどのNGBBoostモデルを導入したのですが、導入するタイミングがもう少し早ければ、もっと多くの回数の利益のフィードバックに参加でき、係数の調整などもよりできたのではないかと考えています。

最後に、今後の展望として、特にNGBBoostについてコメントしたいと思います。まず、現在公開されているバージョンでは、選択できる確率分布の種類が少ないという点が挙げられるかと思っています。理論的には、例えばガンマ分布や、他の保険のモデリングで使われるようなパラメトリックな分布も適用可能と思われそうですが、現在公開されているバージョンにおいては、実装されている分布の種類はあまり多くありません。また、XGBoostやLightGBMといった、コンペでよく使われているような勾配ブースティングモデルと比較すると、確率分布を経由する分、期待値一点の予測精度ではやや劣るということが経験的に知られています。

ただ、この二つを考慮した上でもなお、われわれアクチュアリーが慣れ親しんでいる、パラメトリックな確率分布を仮定している点や、期待値のみならず、分布、リスクまで含めて予測できるという点を踏まえると、他の機械学習モデルと比べたとき、相対的にアクチュアリーとの親和性は高いと言えるのではないかと考えています。

最近ではディープラーニング系のモデルもますます台頭してきており、Boosting系モデル周辺は少し引け気味にはなっているのですが、それでも依然として、急速かつ多様に発展している分野でないかと考えており、今後の動向にも大いに注目が集まる分野だと考えています。これで、私のパートの発表を終わります。

# 保険データ分析コンペの 参加体験談

## STACKING GLMの紹介

2021年11月5日  
Guy Carpenter Japan | Global Strategic Advisory

崎村 沙羅

A business of Marsh McLennan

崎村 では、最後に私たちガイカーペンターチームの今回のコンペの体験談とモデルについて、紹介させていただこうと思います。私たちは3人チームで参加をしました。今回が初めてのコンペだったのですが、初心者で初めてでも、これだけ楽しく参加できるのだということを感じながら聞いていただけたらと思います。よろしくお願いいたします。

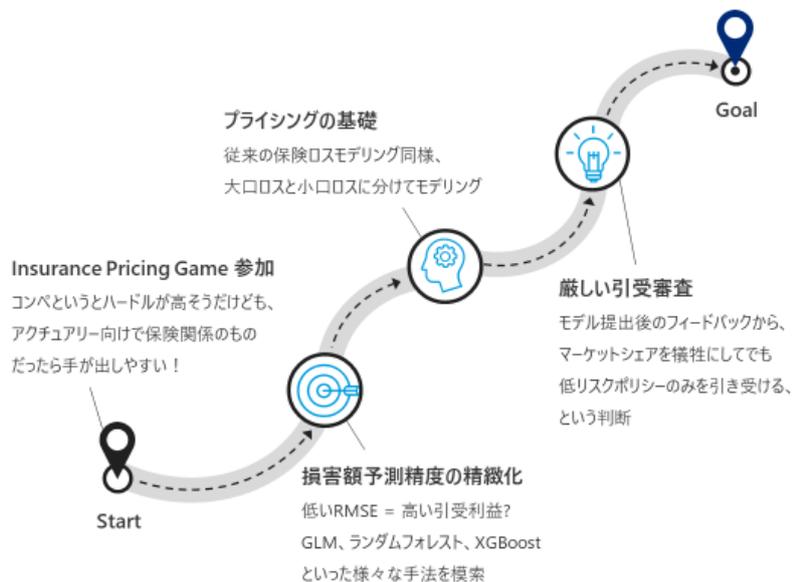
## はじめに

### 社内機械学習勉強会

機械学習の基礎から新しい手法等の  
情報交換  
気象データや保険クレームデータを使用  
した社内サイドプロジェクトも！



GuyCarpenter

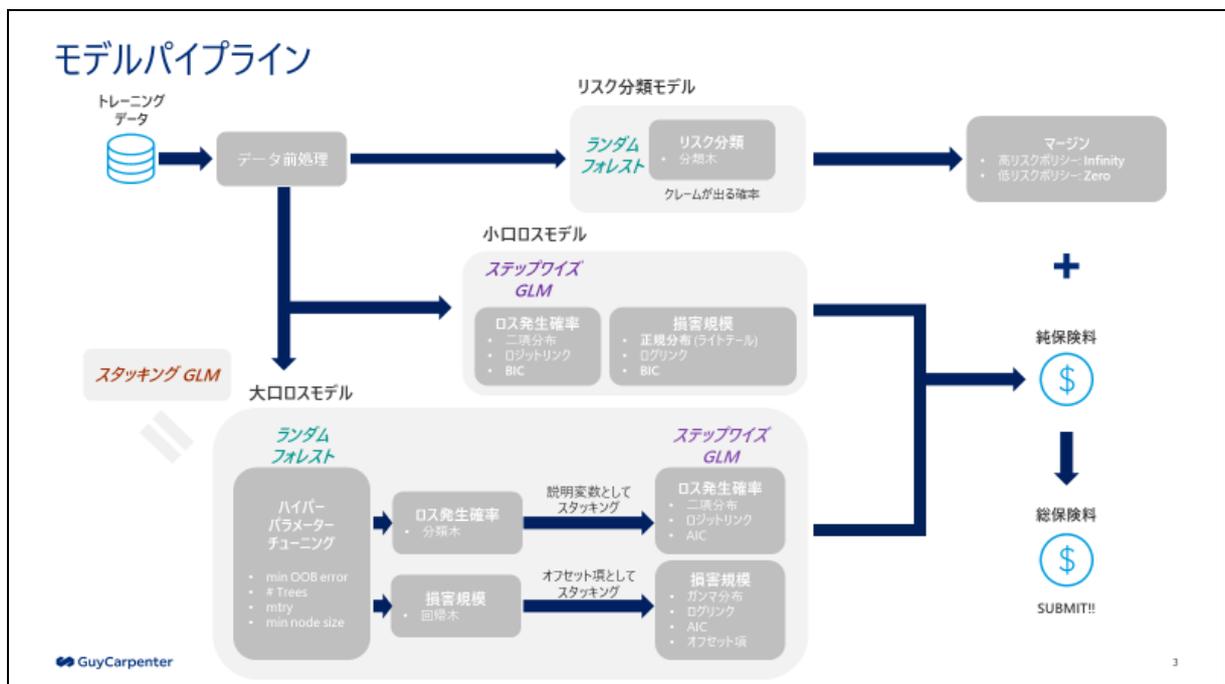


はじめに、私たちのチームについて、紹介します。私たちはアクチュアリーの藤田さん、自然災害リスクを分析されている久下さん、ジュニアアクチュアリーの崎村、の3人で構成されています。われわれは元々機械学習に興味があり、基礎を一緒に勉強したり、新しい手法の情報交換などを行っています。また、持っているデータを使用して、実際にどのような機械学習

手法を使っていけるかといった、社内でのサイドプロジェクトも行っております。

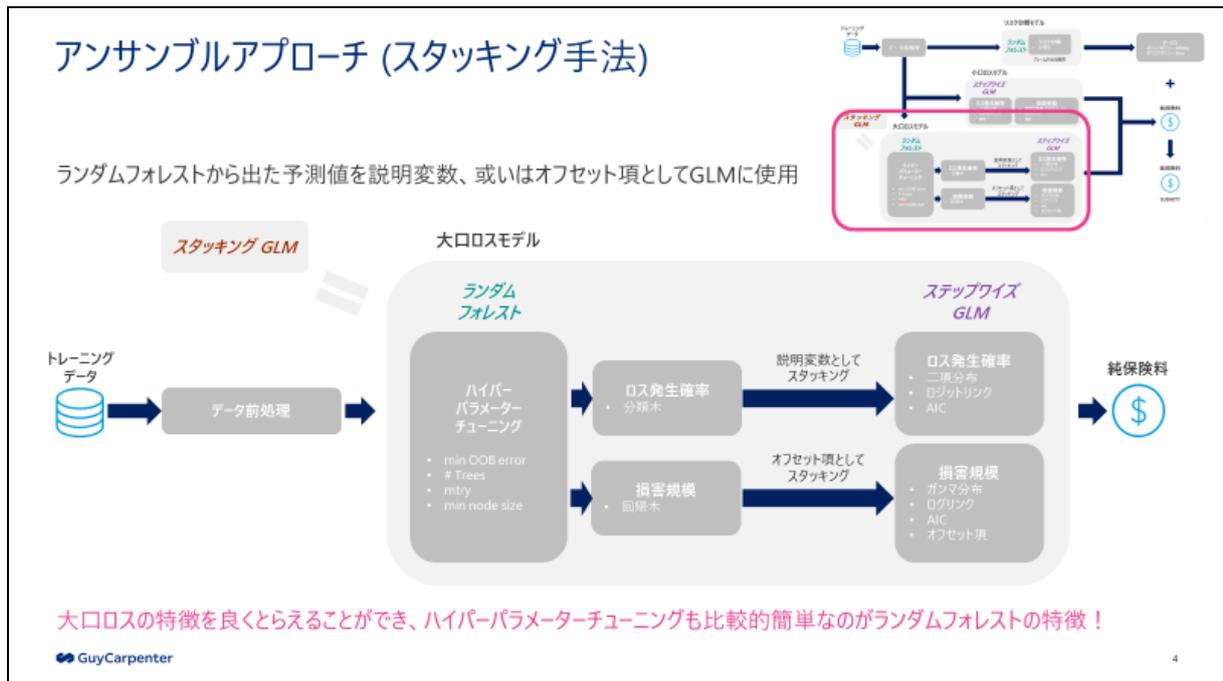
今回の「Insurance Pricing Game」に参加した経緯として、やはり、コンペはなかなかハードルが高く、画像処理といったテーマもどうしても手が出しにくい印象なのですが、今回は、アクチュアリー向けのコンペである上、データも保険関係、かつテーブルデータということで、少し手が出しやすいのではないかとということで参加しました。初めは、取りあえず登録してみよう、という感じで始めたのですが、いざ始めてみると、なかなかハマってしまい、とても良い経験になったと思います。

では、どのような流れでモデルを構築していったかを紹介させていただきます。最初は、予測精度にフォーカスしており、GLM やランダムフォレスト、XGBoost といったような様々な手法を使ってみて、どのように予想精度を上げていけるかというところに時間を使っていました。しかし、途中で、保険ロスのモデリングをするときは、大口ロスと小口ロスに分けてモデルしますねということを思い出し、モデルにも反映することにしました。そのあとは、マージンについて考え始めました。毎週の練習試合から得られる順位やフィードバックを見ていますと、意外とマーケットシェアを持っていないチームが上位にいるということに気が付き、そのような方たちは、低リスクのポリシーを引き受けていて、大きなリスクはそれほど引き受けていないのではないかと想像をしたので、われわれも似たような戦略を取った上で、最終モデルを提出しています。



では次に大まかなモデルのパイプラインの説明です。まず、データの前処理を行ったら、大口のロスモデルと小口のロスモデル、それぞれ別のモデルを作成しています。そこから出てきた純保険料を使用していまして、このモデルとは別に、リスクを分類するモデルというものを作っています。このモデルでは、クレームが発生する確率を予測しており、その予測結果をもとに、高リスクのポリシーと低リスクのポリシーにグループ分けして、低リスクか高リスクかによって、マージンの乗せ方を変えています。では、ここから大きく三つに分けて、もう少し

細かくポイントについてお話しさせていただきます。

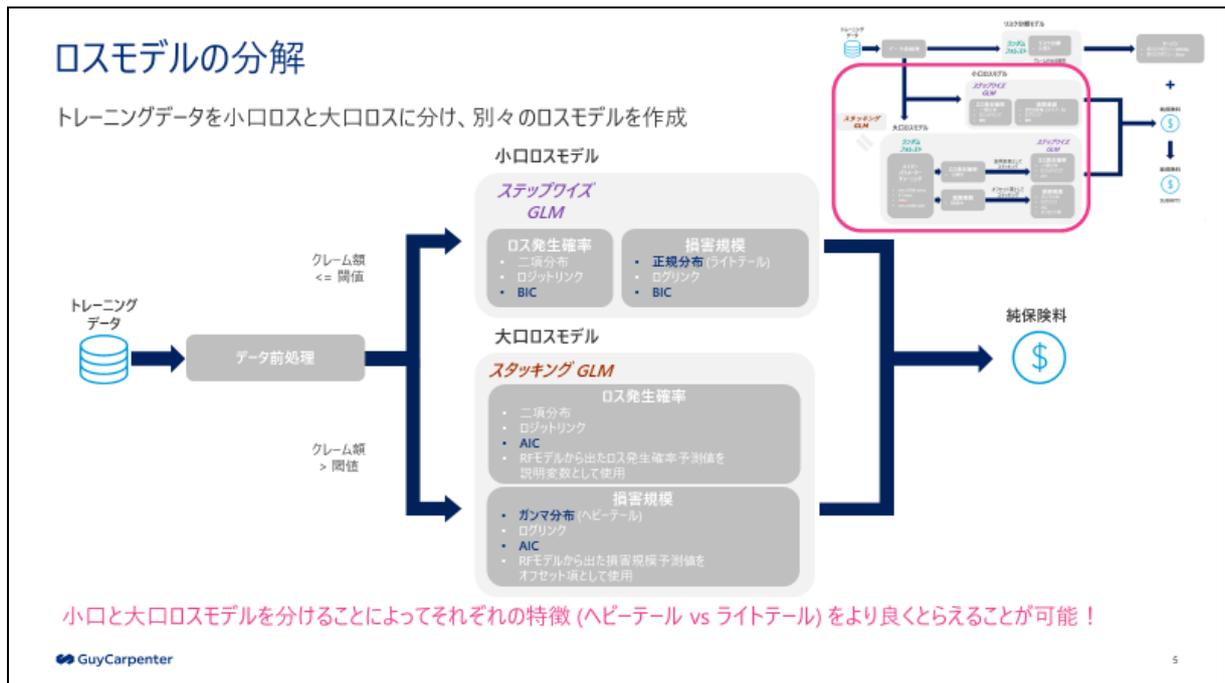


まず一つ目は、アンサンブルアプローチです。アンサンブルアプローチとは、複数の機械学習モデルをミックスしてモデル作成するものです。その中でも特にスタッキング手法という、一つのモデルの予測結果を、他のモデルの中に組み込む手法を用いています。今回、大口ロスモデルを作るときに、このスタッキング手法を使いました。まず、ランダムフォレストを使用したモデルを作成しています。先ほど、伊藤さんに少し紹介していただいた、いくつかある決定木系モデルの中でも、多くの決定木を並列的に考えるモデルです。今回はFD法を使用し、ロスの発生確率と損害規模、それぞれ別モデルを作り、その予測結果を、ステップワイズ GLM の中に組み込んでいます。

ここの組み込み方なのですが、まず、損害規模に組み込んでいます。やはり、大きくてまねな大口ロスの特徴はなかなか GLM のみではキャプチャーすることが難しいため、ランダムフォレストによって、その欠点を補うようなモデルとなっています。ランダムフォレストは、非線形の部分をうまくピックアップしてくれますので、予測結果を GLM の中のオフセット項として使用し、さらに GLM の線形性も使ってサポートするという形で損害規模の予測に使っています。

一方、ロスの発生確率に関しては、せっかくランダムフォレストモデルを作ったので、試しに GLM の説明変数の一つとして組み入れてみたところ、なかなか効いてくる変数でしたので、説明変数として、スタッキングしています。

この組み合わせを今回はスタッキング GLM と呼んでおります。このランダムフォレストを組み合わせることで、大口ロスの特徴をうまく捉えるモデルとなっていますし、また、ハイパーパラメータチューニングも比較的に簡単なため、今回ランダムフォレストを採用しています。

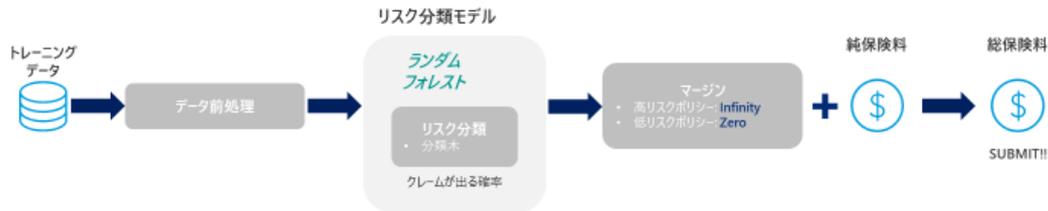


次に、ロスモデルの分解です。先ほど、少し申し上げましたが、小口ロスと大口ロスで異なるモデルを作っています。特に、小口モデルにはステップワイズ GLM を使用し、大口モデルには、先ほど説明した、スタッキング GLM を使用しています。こうすることによって、それぞれの違った特徴をうまく捉えることができるのではないかと考えておりました。小口の方では、例えば損害規模の正規分布の仮定をおいています。大口ロスモデルの方ではガンマ分布といった仮定を置いており、テールが長いものを採用しています。また、どちらでもステップワイズ GLM を使用して、説明変数を自動で選ぶといったプロセスを経ているのですが、そのときに、小口ロスモデルでは、比較的シンプルで安定しているモデルを作りたいため、BIC を指標とした一方、大口ロスモデルでは、あまり説明変数の量を減らしすぎないように、ペナルティが少し低めの AIC を指標とした、といった点で差異を設けました。

## プライシングストラテジー

RMSEの低いモデルが必ずしも練習試合で高順位に来るわけではない

- ロスが起きうる可能性のあるポリシーを避ける戦略
- 低リスクのポリシーを低い値段で確実に取りに行く



ランダムフォレストを使用したリスク分類フラグを使用し、低リスクポリシーのみを安い値段で提供することによって着実に保険引受利益を出す戦略

GuyCarpenter

6

最後に、プライシングの戦略です。RMSE の小さいモデルが必ずしも利益を出しているというわけではなかったこと、また、毎週のフィードバックを見る限り、高順位に来ている人たちが意外とマーケットシェアを取っていないということを踏まえ、われわれのチームも低リスクのポリシーを狙う戦略を取っています。そのために、ランダムフォレストを使ってリスクの分類モデルというものを構築しました。ここではクレームが発生する確率を予測し、その確率を基に、高リスクなものと同リスクなものにグループ分けを行います。ここではかなり保守的に分類しており、ほぼほぼロスが出ないであろうというものだけを低リスクポリシーに入れて、それ以外は全て高リスクポリシーの方に振り分けています。

高リスクポリシーに対しては、無限大の margins を設定し、「私たちは、このポリシーは売れません」といった意思表示をする一方、低リスクポリシーに対しては、margin を全く乗せずに純保険料で販売するという少し極端なリスク選択をしています。つまり、ロスが出ないであろうポリシーのみをこつこつ安く売って利益を出すといった戦略を取っています。

## 最終結果



2000名弱の参加者の中で  
総合順位10位



主催者から**優秀なモデル**として選ばれ、  
他の上位4チームと共に  
タウンホールにてモデルの紹介

GuyCarpenter

Rank	Participant	Participation	Average F1	Method Used	Status	Last Submission	Submission Trend	View
10	majestic-kernel	Yes	5803	Yes	1	Mon, 8 Mar 2021 02:07	[Line Graph]	View
11	Grape_Century	Yes	1453.2	Yes	1	Sun, 7 Mar 2021 02:07	[Line Graph]	View
12	mohith_k_sakt...	Yes	48	Yes	1	Mon, 8 Mar 2021 02:07	[Line Graph]	View
13	tmon01	Yes		Yes	1	Fri, 2 Feb 2021 18:04	[Line Graph]	View

7

このようなモデルを作った結果、全体の中で総合順位 10 位をいただきました。また、主催者から優秀なモデルの一つとして選ばれ、グローバルのタウンホールにて、モデル紹介もしました。タウンホールでは、他のチームのモデルについても聞きましたが、われわれのモデルの特徴として、割とシンプルなモデルだという部分が特に目立っていた点だと思います。他のチームは、10 個以上のモデルを合算したアンサンブルモデルになっていたり、機械学習の手法も 4 個、5 個と組み合わせていたりするチームも多いのです。その中で、比較的シンプルなモデルで十分戦えたというのは、なかなか面白い結果だったのではないかと思います。

## おわりに

従来のGLMにランダムフォレストを組み合わせた“スタッキングGLM”を使用

→ 高い解釈可能性と説明責任を求められる保険業界にもおいても受け入れられやすいと想定

コンペティションに参加してみた



コモンタスクフレームの強みを肌で感じることできた経験となった



絶好の学習機会！



予測精度以外のアスペクトの面白さと大変さ

GuyCarpenter

8

最後にまとめです。今回、従来の GLM にランダムフォレストを組み合わせたスタッキング GLM を使用しましたが、やはり、アクチュアリーの皆様が聞き慣れている GLM を使っています

ので、解釈可能性が高いこと、説明責任を求められる保険業界においては、とても受け入れられやすいものではないかと考えています。プライシングの中に機械学習を取り込んでいくということは、なかなか難しいところだと思うのですが、実は、ヨーロッパなどでは、スタッキング GLM のように、GLM の中に少し忍び込ませるというような形で機械学習が使われてきているようで、これからどんどん増えていくのではないかと考えています。

コンペティションに参加した感想として、まず一番にコモンタスクフレームの強みを実感することができました。ディスカッションボードというものがあり、そこでは EDA の結果が出ていたり、あるいは、コードをそのまま貼付けている参加者もいたり、活発なディスカッションが行われていて、みんなで協力していいモデルを作っていきたいという文化が感じられる場所でした。また、自分にとってもいい勉強の機会になりました。やはり、実際にデータを使って自分の手を動かしてやるということは、机上で勉強することとはまた違った経験や知識を吸収することができるのではないかと考えています。最後に、機械学習というと、どうしても予測精度をいかに高めるかという点にフォーカスしがちなのですが、今回のコンペでは、他のチームと戦うという相対評価の要素が加わり、面白いと同時に、とても大変なところだと感じました。

以上で、私たち、ガイカーペンターチームの発表とさせていただきます。ご清聴ありがとうございました。では、司会の藤田さんにバトンタッチしたいと思います。

藤田 パネリストの皆様、ありがとうございました。大変、興味深く聞かせていただきました。次の Q A セッションに移る前に、3 名の方々の内容を簡単にまとめたいと思います。

## まとめ

	荒井様	伊藤様	崎村様チーム
個人 or チーム	個人	個人	チーム
参加した期間	第3週目～（約9週間）	第3週目～（約9週間）	第6週目～（約6週間）
最終提出したモデル	AGLM	NGBoost	GLM + RF (スタッキング)
最高予測精度ランキング	<b>18位</b>	126位	43位
最終利益ランキング	52位	12位	<b>10位</b>

17

今回、世界 50 か国以上の国々から 2,000 名弱の方が参加したコンペの中で、日本の 3 チームがどのようなモデルを作ったのか、その結果どうだったのかを、表にしてみました。多くのコンペと同様、今回のコンペは個人でもチームでも参加することが可能になっていました。荒井様と伊藤様は個人で、崎村様のところは 3 人チームで参加されたということです。このコン

ペ自体は全 11 週間に亘って行われましたが、荒井様・伊藤様は第 3 週目から 9 週間ほど参加されています。崎村様のチームは 6 週目からですので、約 6 週間の参加期間ということです。

最終的に提出したモデルは、偶然にもそれぞれ別のモデルになっています。荒井様が AGLM、伊藤様が NGBoost、崎村様のチームが GLM とランダムフォレストのスタッキングモデルです。興味深いのは、内 2 チームが長年アクチュアリーに親しまれている GLM ベースのモデルを使用しています。荒井様は GLM から派生した AGLM を使っており、崎村様チームも GLM をランダムフォレストに組み込んで使用しています。伊藤様は Boosting をベースとした手法を使っていますが、プレゼンの中でもコメントされたように、この NGBoost というモデルは、 $y$  そのものを予測するだけではなく、その分布すなわち不確実性も予測するモデルなので、アクチュアリーにとって親和性が高い手法なのでは、ということです。ふたを開けてみると、3 チームとも、アクチュアリーにとって親和性の高いモデルを選ばれたことがわかりました。

表の下 2 行が、順位の最終結果です。予測精度のランキングは、荒井様が 18 位、伊藤様が 126 位、崎村様チームが 43 位で、荒井様の AGLM が 18 位と非常に好成績を収めています。そして、利益のランキングは、荒井様は 52 位、伊藤様が 12 位、崎村様チームが 10 位で、皆様、本当に初心者とは思えないくらい上位にランクしていることが分かります。初心者でもこのぐらいまで目指せるということ、裏付ける結果ではないかと思えます。冒頭にアンケートを取らせていただきましたが、コンペに興味はあるけれどもまだ参加したことはない方々の背中を後押しできれば幸いです。

## Q&Aセッション

18

では、Q Aセッションに移っていきたいと思います。パネリストの皆様、改めましてよろしく申し上げます。まず、私から三つほど質問をご用意いたしました。

## Q1.

# コンペを通じて一番苦労したことは何ですか。どのようにお仕事と両立し取り組んでいきましたか。

19

一つ目です。「このコンペを通じて一番苦労したことは何ですか。どのようにお仕事と両立し取り組んでいきましたか」、視聴者の方々からも「休日を利用してコンペに参加されているのは大変ではないですか」という質問や、「どのぐらい時間をかけましたか」という質問を頂いております。では、荒井様からよろしくお願ひします。

荒井 ありがとうございます。コンペを通じて一番苦労したところというと、やはり、モデルの提出です。チュートリアルの中で、モデルの提出の仕方の解説があるので、簡単なモデルは誰でも提出できます。ただ、複雑なモデルを作ろうとすると、やはり、RやPythonなどの知識が相当必要だということを感じています。具体的に言いますと、今回のコンペでは、各契約に対してロスがいくらですということ、テーブルデータとして出すのではなく、RやPythonなどのモデルを提出する形式なのです。提出の枠組みにかなり制約があり、自分のやりたいことを、その枠組みの中で表現するということが難しかったです。例えば、頻度と強度を分けるという二つのモデルにするだけでも、かなり大変でした。

藤田 ありがとうございます。やはり、初めてコンペに参加をする際、そのような仕様の面は、なかなか苦労される部分ですね。伊藤様はいかがでしょう。

伊藤 私も同じく、モデルの提出で苦労しました。私はPythonを使ったのですが、いざモデルを送ったとしても、主催者側で動かしたところエラーで止まっていますというような案内が来たり、うまくライブラリを読み込んでくれなかったり、そのようなプログラミングの面で苦労したということが一番大変だったかと思っております。仕事との両立に関しては、私は主に土日を使ってコンペに取り組んでいたのですが、そうですね、先ほどご紹介があったように、3週目ぐらいから平均して、土日のうちどちらか1日ぐらいを毎週使っていたように記憶しております。

藤田 ありがとうございます。提出してエラーが返ってきたときに、どのように解決されたのですか。

伊藤 そうですね。かなり詳細にエラーコードまで教えていただけましたので、それを Google で検索したり、何回も送ってみたりして、何とか自力で解決していったという感じです。

藤田 なるほど。崎村様、いかがでしょうか。

崎村 週に1回練習試合のような形で、利益のフィードバックが得られましたが、その解釈がなかなか難しかったです。週に1度、一つのモデルしか提出することができないため、毎週、どんどん良いモデルにしていこうとあちこちを変更したため、どの部分がどう寄与したのを見ることが大変でした。また、他の参加者のモデルもどんどん変わっていきますので、相対評価の中で、自分のしたことが何か改善につながったのか、たまたま周りのモデルが何か違うことをしたために結果が変わったのか、その判断も難しかったですね。

藤田 ありがとうございます。そうですね、やはりコンペは、ある意味ゲームなので、定められた制約条件の中で、どのように原因を分析して、解決していくのかということは、なかなか難しい部分ではあると同時に、面白さや醍醐味の一つなのだろうと思います。

視聴者の方々から関連する質問を頂いております。「休日を利用してのコンペの参加という話がありましたが、今回のコンペでは、1日当たり大体どのぐらいの時間をかけて参加されましたか」というご質問です。崎村様、いかがですか。

崎村 やはり、仕事との兼ね合いで、ほとんど作業ができない週もあれば、平日も含めて休日も、がっつりとこのコンペに取り組むことができた週もあり、週によってばらばらだったかなと思います。ただ、毎週末、締め切りが日曜日でしたので、やはり、その直前はどうしても、できるだけいいものを提出したくて、ついつい夜な夜なやってしまいました。

藤田 何時間ぐらいやりましたか。具体的に覚えていますか。

崎村 どうでしょう。私は、少し朝が弱いので、午後からがっつり、夜中ぎりぎりまで取り組んでいたという日もありました。

藤田 コンペに参加すると、夜型になってしまうということも、よく聞きますね。伊藤様、いかがですか。

伊藤 私も同じような状況でしたが、土日がメインだったかと思います。やり出すと、結構夜遅くまでやってしまうこともあったかと記憶しています。

藤田 ありがとうございます。荒井様、いかがでしょうか。

荒井 私も休日ほぼほぼ、具体的に言うと 12 時間や 13 時間など、かなりの時間を使っていました。暇な人と思われてしまうかもしれないのですが、ちょうど、コンペに参加したのが去年の 12 月中旬からですので、新型コロナの影響で外に出られない状況でもあり、一気にぎりぎりやった感じです。

## Q2.

**コンペで得た知見や経験を業務にどう活かせる  
と思いますか and/or どう活かしていきたい  
ですか。**

20

藤田 ありがとうございます。それでは、次の質問に移りたいと思います。二つ目「コンペで得た知見や経験を業務にどう活かせると思いますか。もしくは、どう活かしていきたいですか」、では、こちらも荒井様から、よろしくお願いします。

荒井 やはり、高度なモデルを実際の業務に使うことは、なかなか難しいところがあると思いますが、一方で今回コンペに参加したことで、EDA の幅が広がったと思います。コンペでいい成績を取ろうとすると、どうしても EDA をかなりやり込むことになります。具体的にいいますと、今回、交互作用項を結構分析したのですけれども、データを入れれば、すぐに可視化してくれるような R のパッケージがあることが分かり、それで分析していました。業務でも今後同じような状況になった時、「R を使えばいいや」というような選択肢が増えるという意味では、とても良かったのではないかと思います。

藤田 EDA とは、まさにデータそのものをくまなく調べるという作業で、アクチュアリーにとっても、クレームデータを使ってロスモデリングをしていく際など、普段の業務で行うところと思うので、そちらの知識は確かに広がりますね。伊藤様、いかがでしょうか。

伊藤 私もまた同じで恐縮なのですが、やはり、データを実際に触ってみるという経験は、業務にも直接生きてくると思います。データにどのような特徴があるのだろう、どのように考えたらいいのだろうということを探していく、まさに EDA になりますが、これは、アクチュアリー業務も広い意味ではデータ分析であると捉えれば、かなり業務に活かせるところではない

かと思えます。また、知見という点では、コンペに参加する前までは、保険のプライシングは、様々な規制などを仮に全部考えなければ、比較的機械学習による予測を活用しやすい分野なのではないかという印象を持っていました。しかし、実際に自分でやってみると、あくまでも今回のデータやルールの中での話ですが、考えていたほど簡単な話ではない、という知見が得られたので、良かったと思えます。

藤田 ありがとうございます。久下様、いかがでしょうか。

久下 少し話をさせていただきたいと思えます。今回のパネラーの方々は、アクチュアリー会の中でということで、コンペティションは「初めまして」とおっしゃっていましたが、統計処理に関してはよくよくご存じの方々であったと感じております。今、聞いていらっしゃる方の中で、本当に初心者な方という方がいらっしゃったら、私の意見も是非、聞いていただければと思えます。

私のバックグラウンドとしては、自然災害リスクに関する、地震や台風に関するエンジニアで、その中で統計処理なども使っておりますが、そこで、アクチュアリー技術が、何かしらコラボレーションできないかということで、会社の中で3人チームとなって、このコンペティションに参加した次第です。私自身は統計学に関して、本当に初心者で、今回コンペに参加して実際のデータを使いながら、どのような統計の処理の手法があるのかということだけを学べただけでも、非常に有意義であったと思えます。私のエンジニア側の話で申し上げますと、やはり非線形の動きが肝になります。地震や台風リスクは線形では図れませんので、非線形の動きというものを統計的にどのように処理すればいいのだろうと考えたとき、GLMや基礎的な統計処理手法だと、非線形の動きというものをなかなか捉えられないというところを感じていたところ。もちろん、GAMのような非線形を捉えようという統計処理手法もありますが、分布を一定仮定しないと分からないなど、その分布を設定することにもかなり時間を要してしまう欠点があります。

今回、機械学習というテーマでこのコンペに参加し、ここまで見てきたように非線形の動きを捉えられる統計処理手法もたくさんあるのだということを知ることができただけでも良かったです。その処理手法に関して、うまくいきますというものだけではなくて、実はうまくいかないですということも、データを使いながら感じることもできたということは、勉強の機会になっただけでも、とても良かったと思えます。非線形のモデルというものを、自然災害リスクのところを持ち込んでいきたいと感じることもできました。

もう一点、別の切り口で話をさせていただきたいと思えます。崎村さんから、コモンタスクフレームワークの強みを感じたということをお話いただきました。同じ課題を、みんなで解決していこうというようなことで、ディスカッションボードが活発だったことは、とても驚きでした。これまでの時代だと、1人の天才が何かしら新しいものを作れば、それにみんな乗っかってくるということだったかもしれませんが。今の時代は知識が飽和してきており、みんなで知識を持ち寄って、より良い精度のモデルをどんどん、スピーディーに作っていくというような文化が、機械学習の中ではすでにあるということを感じることができました。自然災害リスクでも、産学官が連携して、地震や台風に対する対策を進めていこうとはしていますけれども、民間企業だけでも、コモンタスクフレームワークのような課題を一緒に解決していこうと

いう文化を作ることができれば、より良い世の中がよりスピーディーに展開できるのではないかとこのことを考えるきっかけになった点でも、コンペティションへの参加はとても有意義だったと思っております。

藤田 コモンタスクフレームワークのお話まで、ありがとうございます。近年、ディープラーニングや機械学習の名前をあちこちで聞くことになったきっかけの一つが、コモンタスクフレームワークというものなのですね。また、久下様が最初におっしゃっていましたが、普段、われわれが漠然と持っている知識も、コンペティションを通じて、実際に使ってみて、メリット、デメリットというものを肌で感じるができるという点も参加する意義ではないかと思っております。ありがとうございます。

### Q3.

**コンペに参加するメリットは何だと思えますか。  
今後も参加する予定はありますか。  
また、コンペに興味があるけれどもなかなか一歩  
が踏み出せない方々に向けてコメントをお願いします。**

21

では、三つ目の質問に移ります。「コンペに参加するメリットは何だと思えますか。今後も参加する予定はありますか。また、コンペに興味はあるけれどもなかなか一歩が踏み出せない方々に向けてコメントをお願いします」ということで、逆順で崎村様からお願いいたします。

崎村 コンペに参加するメリットは、皆さんおっしゃっていましたが、実際に手を動かしてみて、このモデルは、このような場合にはうまく使えないのだということや、この組み合わせはとてもうまくいくということや、本当に身に染みて感じられるところかと思っております。今後も参加できるものがあれば、是非参加していきたいと思っております。

なかなか一歩が踏み出せない方々に向けては、先ほど、知識やプログラミングへの不安が大きくて参加できないという方が一番多かったかと思うのですが、コモンタスクフレームワークという文化があることをお伝えしたいと思います。例えば、一般的なコンペにはディスカッションボードがあり、私も今回、モデルの提出の仕方など詰まってしまう部分をディスカッションボードで質問しました。皆様、レスポンスもとても早くて、ここをこのように変えたらいいのではないかとこのことを、すぐに教えてくださるような環境でした。初心者でも分からないこ

とがあれば、すぐ聞いてしまうという形で参加ができると考えれば、一歩踏み出しやすいかと思えます。

藤田 ありがとうございます。伊藤様、よろしくお願いします。

伊藤 私も今回参加してみて、実際にまず手を動かしてみることが、とても大事だと思いました。教科書的な知識があったとしても、実際にやってみて初めて分かる部分というものも多くあるのだと改めて感じました。また、データを触ってみると、単純に、「こういうデータと、こういうデータって、このような関係があるんだ」という知見や、プログラムのパッケージの動き方、コンペのスコアを向上させていく中での発見などもたくさんありました。今後も面白いコンペがあれば、是非、参加しようと思っております。

藤田 ありがとうございます。荒井様、いかがでしょうか。

荒井 はい。まず、コンペに参加するメリットとしては、何の制約もなく、楽しく知識や経験が得られる点だと思います。やはり、業務であれば、会社の戦略や法令上の規制など、いろいろな制約がある中進める必要がありますが、コンペであれば、完全に自由です。今回でいえば、保険料が料率三原則に従う必要はないので、普段ではあり得ない条件の中で、自由に分析・料率設定できるところが、なかなか面白かったところです。

次に、なかなか一歩踏み出せない方々に向けてのコメントですが、私自身まだ1回目の参加なので、アドバイスできるようなことはありません。ただ、一つあるとすると、やはり興味のある分野のコンペに参加することが一番ではないかと考えています。例えば、データサイエンスの勉強を始めようとする、最初はタイタニックやアヤメなどから始めるのでしょうけれども、そこで興味がないといずれ飽きが来ると思います。自分の興味がある分野であれば、ここをこうしようなど、どんどんひらめきがあり、深堀することができるのではないかと思います。以上です。

## 視聴者様からご質問をお願いします！

22

藤田 ありがとうございます。次は視聴者の方から頂いた質問です。「このコンペに向けてのデータサイエンスの専門知識は、いつ、どのように勉強しましたか」、やはり、アンケートでハードルとして挙げられていた一番は、プログラミングや専門知識とのことでしたので、こちらについてお伺いしたいと思います。荒井様、いかがでしょうか。

荒井 はい。私の場合は、アクチュアリー会のムーンライトセミナーで、AGLM もそうですし、データ分析のコンペなどもあったので、そこで知識を得られたと考えています。

藤田 ありがとうございます。伊藤様、いかがですか。

伊藤 私の場合は、書籍やインターネットが中心ですが、数年前データサイエンスがはやり出した頃にちょうど大学にいたこともあって、大学の講座や、あとは社内の講座なども受講して、知識を得ることができました。

藤田 社内でも、何かやられているのですか。

伊藤 そうですね。弊社にはデータサイエンス研修のようなものがたくさんあって、大変、勉強になっています。

藤田 結構、細かいモデルの話などもあるのですか。

伊藤 はい、なかなかレベルが高くて、大変、勉強になっています。

藤田 ありがとうございます。崎村様、いかがですか。

崎村 プログラミング自体は、学校で学習する機会がありましたが、社会人になる頃には正直使い方も忘れてしまっており、再勉強が必要でした。伊藤さんと同じように社内のトレーニングがあったり、オーガナイザーの藤田さんに引っ張っていただけたことも恵まれていました。周りで一緒に興味がある人を探してということは、とてもいい方法ではないかと思います。

藤田 ありがとうございます。会社によっては、独自で機械学習部やデータサイエンス部のような、サークル活動のようなものを作って、勉強会や輪読会を開催したりするという話は、たまに聞きますね。久下様、いかがですか。

久下 先ほど、崎村さんからも話がありましたとおり、RやPythonに関しては、実は業務でかなり使っていることもあり、特にハードルはなかったです。一方で機械学習に関しては、学ぶ機会がとても少なく感じていまして、自然災害に是非使っていかなければいけないという意識のもと、藤田さん、崎村さんを巻き込んで、機械学習について学ぼうというようなチームを作り、週次か隔週で勉強会を行う体制が取ることができていました。会社の中で興味がある方が集まって勉強会をするというケースもありますし、大手の企業だと、講座のようなものもあるようですね。そのような場に積極的に参加することが良いのではないかと考えております。

藤田 ありがとうございます。続いて「現在開催中、もしくは近いうちに開催予定のデータ分析コンペティション（アクチュアリー向け）」とのことですが、久下様もいらっしゃいますので、自然災害モデラー向けも付け加えさせてください。「そのようなコンペを探すには、どうすればいいでしょうか」、久下様から、いかがでしょうか。

久下 話が少し重複してしまうかもしれませんが、先ほどのチームの勉強会の中でコンペを探すこともしました。方法の1つとしては、Kaggleや他のプラットフォームのメールマガジンに登録するとよいです。そうすると、コンペティションの案内が配信されますので、その中から興味のあるコンペを選んで参加するとよいのではないのでしょうか。

藤田 ありがとうございます。崎村様、いかがですか。

崎村 久下さんと同じように、メールマガジンに登録していくとEメールにお知らせが来ますので、気になったら見てみるというスタンスが、とても良いのではないかと考えています。また、個人的にはLinkedInにも、データサイエンスが好きなグループもあるので、そのようなグループに入っていると、ちらちらと見ているだけで「このコンペに今、参加しています」という情報が流れてくるので、それもいい情報源になりそうです。

藤田 では、伊藤様、いかがでしょうか。

伊藤 そうですね、私もSNSやメールの配信がメインになるかと思っています。

藤田 はい。ありがとうございます。荒井様、いかがでしょうか。

荒井 全く同じです。

藤田 Twitter、LinkedIn 等の SNS に登録して、メールマガジンの配信等から、興味を持ったものをピックアップしていくというアプローチがいいのではないのでしょうか、ということになりそうですね。

全体向けの質問です。「他のチームの手法、戦略で興味深かったものはありますか」、挙手制にしましょうか。

崎村 伊藤様のモデルで NGBoost を使われていて、正直なところ、私たちのチームはぶれの部分まで予測するという余裕がなかったので、次の機会があったら是非使ってみたい手法だと思いました。

藤田 他の方々はいかがですか。

伊藤 私は、FD 法のような形で、頻度や件数を分けて分析するという、業務ではやったことがあるのに、今回のコンペではすっかり頭から抜け落ちていたアプローチを聞いて、なるほどと思いました。

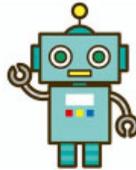
藤田 ありがとうございます。荒井様、お願いします。

荒井 崎村様チームの保険料設定のところ、小口ロスに対してはマージンを一切設けないという、その戦略があまりにも斬新で、そういった戦略を採るチームがあったのであれば、料率競争で勝てないだろうというところが、反省点というか、面白かったところです。

藤田 ありがとうございます。次の質問は崎村様に対してですね。「ロスモデルを大口とそれ以外に分けて作成することは理解できますが、提供されているデータから保険金の金額で、何らかしらのバーを設けたということでしょうか。もしくは、上位何%を取ったという感じでしょうか」。

崎村 はい。今回は、バーを設けました。練習用のデータの平均値より大きいか、小さいかで大口、小口というように分けています。ただ、結果的にはそこに落ち着いたのですが、そこに至るまで、バーをどこに設定するかということは何パターンも試しております。

# ご清聴ありがとうございました。



23

藤田 ありがとうございます。他にも多くのご質問を頂いておりますが、一旦、ここで締め切らせていただきます。時間の都合上、申し訳ありません。

クロージングということで、私から一言コメントしたいと思います。今回、AICrowdが運営した保険系コンペを取り上げて、初心者としての立場からコンペの経験談や構築したモデルについて、パネルディスカッションを行いました。問題設定に関しては、あくまでもゲームなので、現実のビジネスとは多少のギャップがありますけれども、データの前処理からモデリング、結果の解釈など、実務プロセスの一連を深く学べたのではないかと思います。また、本コンペでは、予測精度の高さを競うだけではなく、他のチームの動きを踏まえた利益競争という観点が組み込まれていて、アクチュアリー的にも大変興味深かったのではないのでしょうか。

近年の機械学習系ソフトウェアの発展、普及によって、機械学習手法というものが誰もが簡単に使える時代になってきておりますが、やはり、第一義的には、利用目的を明確にすることが重要ではないかと思います。われわれが現実に従事しているビジネス、保険金融業界を例に取りますと、不確実性の評価やモデルの解釈可能性、あるいは、モデルガバナンスといったことが強く要求されていて、単に予測精度を追求したモデルを適用することは難しい点があるかと思えます。

一方で、説明や解釈が難しいから機械学習は、やはり使えないと断定はせずに、今後は、保険業界なりの機械学習手法やフレームワークが必要になると考えられます。そのためにも、このようなコンペティションをはじめとする種々の活動を通じた連携を加速していくことも重要になるだろうと思えます。最後になりますが、本セッションを機に、多くのアクチュアリーの方々がデータ分析コンペティションに少しでもご興味を持っていただければ幸いです。ご清聴ありがとうございました。