

機械学習による格安航空会社の業務支援の検討

堀口 裕士[†] 馬場 雪乃[†] 鹿島 久嗣[†] 鈴木 雅仁^{††} 栢原 宏樹^{††}
前野 純^{††}

[†] 京都大学情報学研究科 〒 606-8501 京都府京都市左京区吉田本町

^{††} Peach Aviation 株式会社 〒 549-0011 大阪府泉南郡田尻町泉州空港中 1 番地

E-mail: †{horiguchi,baba,kashima}@ml.ist.i.kyoto-u.ac.jp, ††{M.Suzuki,H.Kayahara,J.Maeno}@flypeach.com

あらまし 格安航空会社は低価格で航空サービスを提供する会社の総称である。LCC は安全性を確保した上で低価格なサービスを提供するために、様々なコストカットとサービス品質の改善に注力している。そして航空業界では定時出発率がサービス品質を測る上で一般的な指標となっている。本稿では航空会社により提供された実データに対して最新の予測手法を適用して、フライトが消費する燃料を予測する回帰問題とフライトの出発遅延を予測する二値分類問題をフライトの五ヶ月前、一週間前、前日の三つのタイミングで行う。燃料消費量予測では専門家による予測よりも少ない誤差で予測ができることを実験的に示し、フライト出発遅延予測では一部の路線において AUC の指標において 0.75 を達成した。

キーワード 格安航空会社, 燃料消費量予測, フライト出発遅延予測

1. はじめに

格安航空会社 (格安航空会社: *low-cost carriers*) は航空業界において一般的な航空会社と比べて安い価格帯でサービスを提供する航空会社の総称であり、近年非常に競争が激しくなっている業界である。日本においては航空業界の規制緩和が行われて以降多数の格安航空会社が市場に参入した。格安航空会社は一般的な航空会社と比較して、機内サービスを簡略化したり機体の利用効率を上げることで運営コストを節約して安い価格帯でのサービスの提供を行っている。

このような安価なサービス提供は簡単にできるものではなく格安航空会社間での価格競争も激しいものとなる。航空会社の支出の中で最も大きな割合を占めるものは燃料であり、いかにして燃料の消費を減らすかが最終的な支出に大きな影響を与える。燃料を節約する方法は主に二つあり、

- (1) 機体の重量を軽くする
- (2) 必要以上のスピードで飛行しない

ことで燃料が節約できる。(1)の理由は機体が重くなればなるほど飛行に必要なエンジンの出力は大きくなりそれに伴って燃料の消費も増加するからである。(2)の理由は機体の加速には燃料が必要なためである。実際に格安航空会社では安全性を損なわずに機体を軽くするために様々な努力が行われている。

またこのような多数の格安航空会社の競争の中で利用者の支持を得るにはサービス品質の向上も重要な課題となる。航空業界ではサービスの品質の指標の一つとして定時出発率、つまりスケジュールで定められた時間に出発できた割合が一般的に用いられている。格安航空会社では一つの機体を何度も利用することで機体の維持費等を節約するため、一般的に密なスケジュールが組まれることが多い。そのためあるフライトが遅延してしまった場合はそれに続くフライトにも遅延の影響が出る

可能性が高くなる。そのためあらかじめフライトの遅延を察知して遅延を避ける必要がある。

航空会社では運航実績と乗客に関するデータを多数所有している。本稿ではこれらのデータを用いて予測モデルを作成してコスト削減及びサービス品質向上に有用な予測を行う。本稿では、Peach Aviation 株式会社が収集した、日本国内外の三年間の運行実績と乗客データを用いる。

本稿では二つの予測問題に取り組む。燃料消費量予測とフライト出発遅延予測である。

本稿において主な貢献は以下のようにまとめられる。

(1) 燃料消費量予測について、8.8%の相対 RMSE (*root mean squared error*) で予測することを可能にした。これは専門家による予測よりも少ない誤差での予測である。さらに安全性の面から回帰モデルによる予測が実際の消費量と比較して過度に少なすぎないことも確かめた。

(2) フライト出発遅延予測について、フライトの前日時点で入手できる乗客の予約データとフライトの情報から一部の路線において ROC-AUC (*Area under the receiver operator curve*) が 0.75 を上回る予測を達成した。

2. データセット

本稿では Peach Aviation 株式会社^(注1)より提供されたデータセットを用いて実験を行う。この章でははじめにデータセットに含まれるデータの詳細に触れて、次に予測モデルに入力する特徴ベクトルの表現方法について述べる。

2.1 データの詳細

データセットは三つのデータで構成されており、それぞれフライト情報、乗客情報、予約情報と呼ぶ。これらのデータは 2012 年 6 月から 2015 年 5 月にかけて記録・収集されたもの

(注1): <http://www.flypeach.com/>

表 1 利用する特徴の一覧。本稿の実験では予測するタイミングによって異なる特徴を使用する：出発前日 (D)、出発一週間前 (W)、出発五ヶ月前 (M) の三つのタイミングである。

特徴名	予測タイミング		
	D	W	M
フライト情報			
出発年	✓	✓	✓
出発月	✓	✓	✓
出発日の週番号	✓	✓	✓
出発日の月	✓	✓	✓
元日からの日数	✓	✓	✓
予定出発時刻	✓	✓	✓
予定到着時刻	✓	✓	✓
出発地空港	✓	✓	✓
目的地空港	✓	✓	✓
国際線・国内線フラグ	✓	✓	✓
機体 ID	✓	✓	✓
機体停泊場所の ID	✓	-	-
搭載燃料量	✓	-	-
予測飛行時間	✓	-	-
予約情報			
総予約数	-	✓	-
年齢ごとの総予約数	-	✓	-
性別ごとの総予約数	-	✓	-
乗客情報			
総乗客数	✓	-	-
総乗客数における大人の数	✓	-	-
総乗客数における子供の数	✓	-	-
年齢ごとの乗客数	✓	-	-
性別ごとの乗客数	✓	-	-

であり 54,000 回のフライトと 9,900,000 人分の乗客に関するデータが含まれている。Peach Aviation 株式会社の展開する路線の中で本稿の実験データとして用いる路線を図 1 に路線図を示す。

フライト情報: このデータセットはフライトのスケジュール上の出発日時、出発予定時刻、乗客数、予定された搭載燃料量等のフライト一便に関係する一般的な情報を含む。燃料に関する情報はこのデータセットに含まれており、専門家によって予測された燃料消費量と実際に消費された燃料消費量もこのデータセットに含まれる。

乗客情報: 乗客個人の年齢、性別の情報を含む。

予約情報: 乗客がフライトを予約した日時と予約したフライトの情報が記録される。このデータからフライト当日から指定した日時だけ前のタイミングでの予約状況を再現することができる。

2.2 特徴ベクトルの表現方法

燃料消費量予測と出発遅延予測問題にとりくむために用いる予測モデルへの入力となる特徴の詳細を述べる。また予測はフライトの五ヶ月前、一週間前、前日の三つのタイミングで行う。これは航空会社が行動を取れるタイミングとしてフライトの予約がない状態、ある程度予約がある状態、完全に予約が決まっている状態という三つのタイミングが想定されるため、これ

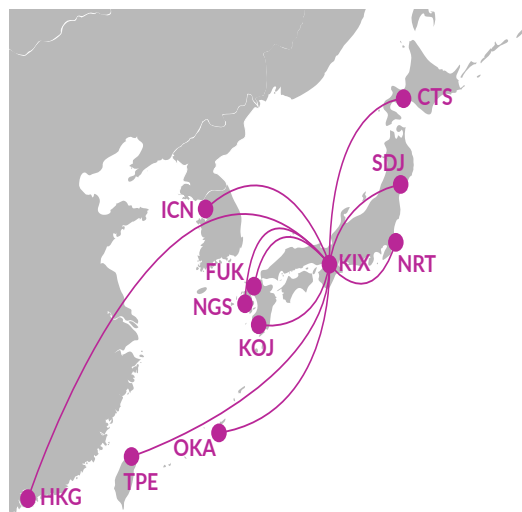


図 1 本稿の実験において対象となる路線

らはそれぞれ五ヶ月前、一週間前、前日に対応している。タイミングごとに入手できる情報は異なっており、それに伴って予測モデルに入力する特徴も異なる。タイミングごとに利用可能な情報を表 1 にまとめる。

それぞれのフライトを予約した乗客について総数を求めてそれを特徴に用いる。予約情報には性別や年齢が含まれており、これらの総数を集計したものも同様に特徴とする。年齢については“0-2”, “3-11”, “12-19”, “20-24”, “25-29”, ..., “65-69”, “70 以上” の 14 の区分に分割して、それぞれの年齢区分における乗客数及び予約数を集計して特徴として用いる。また乗客を 18 歳以上 (大人) と 18 歳以下 (子供) に分けて、同様に総数を求めて特徴として用いる。

本データには出発地空港などのカテゴリカル変数が複数含まれており、これらは one-of- K 記法で変換したものを特徴として用いる。周期的に変化する値を特徴として利用するために、元日からの日数を三角関数で変換する。 d を元日からの日数とすれば $\sin(2\pi d/365)$ と $\cos(2\pi d/365)$ をフライト情報の元日からの日数についての特徴ベクトルとして用いる。こうすることで年末と年始をカレンダー上で連続する日付として扱うことができる。同様の変換を予定出発時刻などの時刻に関する特徴にも適用して、 m を午前 0 時からの経過分数として $\sin(2\pi m/1440)$ と $\cos(2\pi m/1440)$ を特徴として用いる。最後に全ての特徴を 0 以上 1 以下の範囲に収まるようにスケーリングする。

3. 燃料消費量予測問題

本稿では、はじめに燃料消費量予測問題にとりくむ。最終的には、予測を通してコスト削減を行うことが目的である。フライトの燃料予測をする背景は、航空会社の支出のもっとも大きな部分を占めているのが燃料でありこれを削減するために必要な情報を得たいというものである。

燃料コストを削減する方法は主に二つあり、一つはフライトの消費燃料量を過大に評価せずにもっとも適切な燃料量を搭載する事である。ただし燃料量は安全性を損なわない範囲での操

作しかできないことに注意する。もう一つは、特定の期間に使用する燃料量を正確に見積もり燃料を過剰に購入しない事である。これらを達成するために本稿では、フライト単位に必要な燃料量を求めることで飛行機に搭載する燃料量を最適化すると同時に1日あたりの燃料消費量を事前に予測することで特定期間における燃料の使用量を見積もる。

3.1 ベースライン

航空会社はフライトに搭載する燃料量を専門家により決定された燃料量(フライトディスパッチャーによる予測)と法的な規制に基づいて決定する。この専門家予測はフライトの前日に行われるものであり本稿ではEX-Dと表記される。

3.2 予測モデル

消費燃料予測問題を回帰問題として定義して三つの予測モデルを適用する。Random Forest [15], XGBoost [16], Deep neural networkの三つを用いて予測を行う。Random Forestはscikit-learn(注2)における実装を、Deep neural networkは三層のネットワークであり最適化手法としてAdaDelta [1]を用いる。

3.3 フライト一便ごとの燃料消費量予測問題

フライト一便あたりの消費燃料量予測はフライトの前日と一週間前に行く。このフライト一便あたりの消費量予測によって過剰な燃料の搭載を抑制して燃料を節約することができる。問題設定: フライトの前日と一週間前に入手できるデータから実際のフライトで消費した燃料量を予測する。予測モデルへの入力予測タイミングで入手可能な情報から得た特徴ベクトルを用いる。

評価指標: 実際の燃料消費量の平均値で正規化されたRMSEである相対RMSEを用いる。また、少なすぎる燃料は安全上の懸念があるため過小評価率(実際の消費量に対して3%以上少ない値を予測燃料量としたフライトの割合)を評価指標として取り入れる。フライトが飛行した後の実際の燃料消費量を正解として用いる。

実験結果: 図2に出発地点、もしくは目的地の空港ごとの相対RMSEを示す。XGB-Dが12の空港のうち10の空港で専門家より少ない誤差で予測していることがわかる。図3は週ごとの相対RMSEを示したものでXGB-DとRF-Dが常にEX-Dよりも少ない誤差で予測していることがわかる。また表2が過小評価率の結果でありXGB-Dが相対RMSEで小さい誤差に留めていることに加えて過小評価も少ないことが確認できた。

XGBoostによる予測において有効な特徴量を分析する。訓練済みのXGBoostは「元日からの日数」、「cos(元日からの日数)」、「総乗客数」が燃料消費に関係する因子であると示唆しており同時に「出発時刻」も重要な特徴であるとわかった。飛行する航路の混雑具合や飛行航路が離着陸や飛行時間に関係していることがこのような特徴から示唆される。もう一つ考えられる要因としては、全てのフライトは緊急時の代替着陸空港まで飛行できる分の燃料を搭載する必要がありこの代替着陸空港は時間帯によって異なる場合がある。搭載燃料量は機体の重




図2 フライト一便ごとの燃料消費量予測問題における出発地・目的地の空港ごとの相対RMSE。XGB-Dが12の空港の内10の空港でEX-Dよりも小さい相対RMSEを得た。




図3 フライト一便ごとの燃料消費量予測問題における週ごとの相対RMSE。XGB-DとRF-Dがほとんど全ての週でEX-Dより小さい相対RMSEを得ている。

量に直接関係しているため、時間に関する特徴が燃料消費量に関わる要因として示されたと考えられる。

3.4 路線一日ごとの燃料消費量予測問題

路線一日ごとの燃料消費量予測はフライトの五ヶ月前のタイミングでのみ利用される。燃料の価格は変動が激しいためなるべく正確に必要な量を把握して価格高騰時の購入量を抑える必要があり、正確な予測がこのようなリスクヘッジにおいて有用な情報となる。

問題設定: 訓練データとテストデータについては燃料消費量予測問題と同様の設定で行う。予測モデルへの入力となる特徴についてはフライトの五ヶ月前のタイミングで入手できる情報のみを利用して構成する。

実験結果: 表3に相対RMSEを示す。五ヶ月前の時点での予測にかかわらず、前日に予測した専門家が算出した値を用いて計算した消費量(EX-D)よりも少ない誤差での予測ができることを確認できた。XGB-MとRF-MがEX-Dに勝る一方でDL-Mの相対RMSEが非常に大きくなってしまった理由は、五ヶ月前の時点では使用できる特徴が少なくDeep neural networkのモデルは過度に複雑なモデルだったためと考える。本実験によってアンサンブルによる予測モデルが路線一日ごとの燃料消費量予測問題に対して有効であることがわかった。

4. フライト出発遅延予測問題

航空会社のサービス品質の基準の一つに、定時出発率というものがある。これはフライトが予定時刻から15分以上遅れる

(注2): <http://scikit-learn.org/>

表 2 フライト一便ごとの燃料消費量予測問題における過小評価率。XGB-D の過小評価率は相対 RMSE が小さいにもかかわらず低い値に抑えられていることがわかる。

EX-D	DL-D	XGB-D	RF-D	DL-W	XGB-W	RF-W
0.082	0.002	0.007	0.040	0.030	0.041	0.093

表 3 路線一日ごとの燃料消費量予測問題における相対 RMSE。XGB-M と RF-M が EX-D よりも小さい相対 RMSE を得ている。

EX-D	DL-M	XGB-M	RF-M
0.071	0.120	0.064	0.070

事なく出発・到着したかどうかを測る指標であり、高いほど時間に正確なサービスを提供している事になる。顧客に時間に正確な航空会社として利用してもらうためには、当然遅延を少なくする必要がある。

LCC では一つの機体をなるべく多く利用することで運営コストを節約するためにフライトのスケジュールが密であり、一つのフライトの遅延が後続のフライトの遅延にも影響する。そのため LCC にとってフライトの遅延をあらかじめ察知して対策をすることは重要である。

問題設定: 定時出発率を参考にして、本稿ではフライトの予定出発時刻から“15分以上出発が遅れるか遅れないか”を予測する二クラス分類問題とする。

評価指標: ROC-AUC が評価手法となる。

実験結果: 表 4 はそれぞれの手法での三つのタイミングにおける AUC スコアを表している。DL-D, XGB-D, RF-D の AUC スコアを除けば全てが 0.6 を下回っていることから予約のタイミングに得られるデータだけでは遅延の予測は難しい問題であることがわかる。訓練済みの予測モデルを分析した結果、「搭載燃料量」「総乗客数」「予定出発時刻」が遅延予測に有効であることがわかり、このうち「搭載燃料量」「総乗客数」はフライト当日のタイミングでしか判明しない。これが XGB-D を含む前日のタイミングでの予測モデルだけが高い AUC スコアを得ている原因と考えられる。これらの分析を元にして「搭載燃料量」「総乗客数」「予定出発時刻」の関係を図示したものが図 6 であり、遅延するフライトがそうでないフライトとはっきり分離されていることが確認できる。

図 4 に路線ごとに AUC スコアを示しており NRT, NGS 路線では AUC スコアが 0.75 を超えることがわかる。図 5 にて NRT, NGS 路線の週ごとの AUC スコアを確認すると幾つかの週で 0.8 を超えることが確認でき、一部の路線ではフライト前日での予測モデルが有効であることがわかった。

まとめると予測モデルによって遅延に関係するいくつかの規則を知り、フライト前日のタイミングならば一部の路線で予測が可能になる。

5. 関連研究

航空業界において機械学習の応用研究はすでに多く存在する [2-4, 6-10] が、燃料消費量とフライト出発遅延に関する研究は少ない。

クイックアクセスレコーダーと呼ばれるシステムの運用デー




図 4 フライト出発遅延予測問題における路線ごとの AUC スコア。NRT と NGS において 0.75 を超えるスコアを達成した。

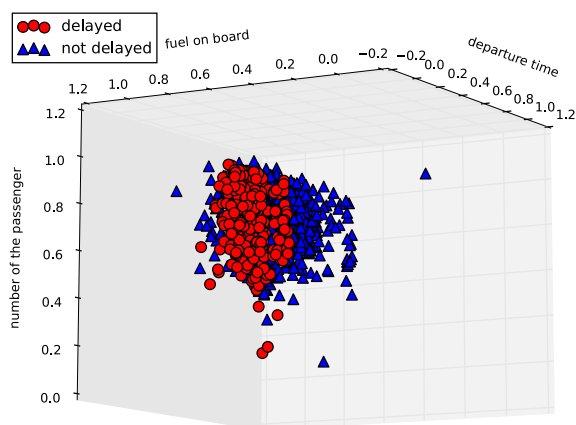


図 6 搭載燃料量、予定出発時刻、総乗客数とフライト出発遅延との関係図。それぞれの軸の値は正規化されている。図から遅延をするフライトと遅延をしないフライトがはっきりと分かれていることが確認できる。

タなどフライト中の運行記録を保存するシステムを用いて燃料消費を予測する研究が少数行われている [11]。運航業務品質保証の観点から燃料消費を予測する研究は存在する [12] が、この研究では乗客に関する情報を利用していない。

フライト出発遅延予測について、フライトの航路やスケジュールを一種の最適化問題として解いて遅延を少なくする研究が行われている [13, 14] が、本稿の研究では航路やスケジュールの変更はせずに予約情報などから予測モデルを作成する。

6. おわりに

本稿では格安航空会社における支出削減とサービス品質の向上を同時に達成するために、予測モデルによる航空会社の業務支援の実現可能性を調査するための実験を行った。支出削減の

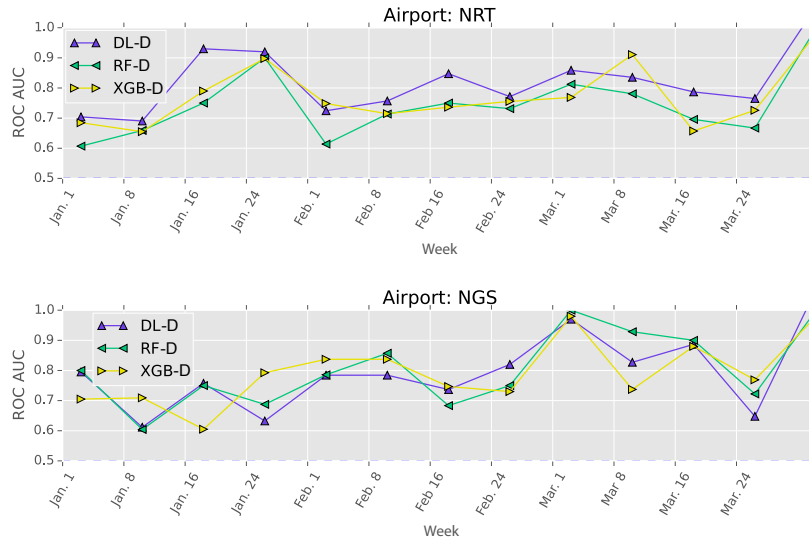


図 5 NRT と NGS 路線についてのフライト出発遅延予測問題における AUC スコア。週ごとに変動が見られるが、複数の週で 0.8 を超える AUC を達成していることが確認できる。

表 4 フライト出発遅延予測問題における AUC スコア。前日での予測 (DL-D, XGB-D, RF-D) が他のタイミングの予測よりも高いスコアを得た。

DL-D	XGB-D	RF-D	DL-W	XGB-W	RF-W	DL-M	XGB-M	RF-M
0.647	0.634	0.604	0.584	0.573	0.560	0.500	0.542	0.534

ために燃料消費量予測を、サービス品質向上のためにフライト出発遅延予測を行った。航空会社が予測結果に基づいて行動を取れるタイミングを考慮してフライトの前日、一週間前、五ヶ月前の三つのタイミングでこれらの予測問題を扱った。この前日、一週間前、五ヶ月前のタイミングはそれぞれ乗客情報が完全に揃った状態、乗客情報が一部欠けている状態、乗客情報が一切なくフライトスケジュールに関する情報のみ取得できる状態に対応している。

我々の回帰モデルによってフライト一便あたりの燃料消費量を相対 RMSE 8.8%で予測した。これは専門家による予測において相対 RMSE 39.9%であったことと比較するとより少ない誤差での予測ができています。また出発遅延予測問題において一部の路線にて 0.75 を上回る AUC を達成した。

今後の課題として予測精度の向上のためにフライトレコーダーの記録や気象情報を考慮すること、売上向上のために機内販売や各種サービスの推薦システムを開発することなどが挙げられる。

文 献

- [1] Matthew D. Zeiler. "ADDELTA: an adaptive learning rate method." arXiv preprint arXiv:1212.5701 (2012).
- [2] Igor Melnyk, Arindam Banerjee, et al. "Semi-Markov switching vector autoregressive model-based anomaly detection in aviation systems." arXiv preprint arXiv:1602.06550 (2016).
- [3] Bo An, Haipeng Chen, et al. "MAP: Frequency-Based Maximization of Airline Profits based on an Ensemble Forecast-

- ing Approach." Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2016.
- [4] Samet Ayhan, Hanan Samet. "Aircraft trajectory prediction made easy with predictive analytics." Proceedings of the 22nd International Conference on Knowledge Discovery and Data Mining. 2016.
- [5] Ashok Srivastava. "Discovering system health anomalies using data mining techniques." (2005).
- [6] Amit Mathur. "Data mining of aviation data for advancing health management." AeroSense 2002. International Society for Optics and Photonics, 2002.
- [7] Lishuai Li, Maxime Gariel, et al. "Anomaly detection in onboard-recorded flight data using cluster analysis." Digital Avionics Systems Conference (DASC), 2011 IEEE/AIAA 30th. IEEE, 2011.
- [8] Santanu Das, Bryan L. Matthews, et al. "Multiple kernel learning for heterogeneous anomaly detection: algorithm and aviation safety case study." Proceedings of the 16th ACM SIGKDD international conference on Knowledge discovery and data mining. ACM, 2010.
- [9] Chunxiao Zhang, Nan Wang. "Aero-engine condition monitoring based on support vector machine." Physics Procedia 24 (2012): 1546-1552.
- [10] Nektarios Karanikas. "Exploiting data from safety investigations and processes to assess performance of safety management aspects." Policy and Practice in Health and Safety 14.2 (2016): 115-127.
- [11] Jiaxue Liu, Ma Tao. "A method of aircraft fuel consumption performance evaluation based on RELAX signal separation." Cyber Technology in Automation, Control, and Intelligent Systems (CYBER), 2015 IEEE International Conference on. IEEE, 2015.
- [12] Alan J. Stolzer. "Fuel consumption modeling of a transport category aircraft using flight operations quality assurance data: a literature review." (2002).
- [13] Shervin AhmadBeygi, Amy Cohn, et al. "Analysis of the po-

tential for delay propagation in passenger airline networks.”
Journal of air transport management 14.5 (2008): 221-236.

- [14] Shervin AhmadBeygi, Amy Cohn, et al. ”Decreasing airline delay propagation by re-allocating scheduled slack.” IIE transactions 42.7 (2010): 478-489.
- [15] Andy Liaw, Matthew Wiener. ”Classification and regression by randomForest.” R news 2.3 (2002): 18-22.
- [16] Tianqi Chen, Carlos Guestrin. ”XgBoost: A scalable tree boosting system.” Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2016.