

競馬予測の苦楽

AlphaImpact

NUKUI Shun

@ PyData.Tokyo One-day Conference 2018

自己紹介


- 貫井 駿 (NUKUI Shun, @heartz2001)
- 仕事
 - Fringe81株式会社 (Ad Tech, HR Tech)
 - 競馬予想家
- Python歴: 4年
- 競馬歴: 12年 (馬券は二十歳から)
 - 東工大競馬研究会元部長
- PyData.Tokyo登壇3度目
 - #11 競馬予測 (2016/11)
 - #18 データ分析コンペティションの勝ち上がり方 (2018/04)



第1回電脳賞（春）出場当時

AlphaImpact

- 競馬AI開発プロジェクト
- メンバー
 - NUKUI Shun: 機械学習、競馬ドメイン
 - OMOTO Tsukasa: 機械学習、システム設計、LightGBMコミッター
 - HARA Tomonori: 競馬ハッカー
- 活動
 - <https://alphaimpact.jp/>
 - netkeiba.com 『ウまい馬券』で予想販売
 - 中央: <http://yoso.netkeiba.com/>
 - 地方: <http://yoso.netkeiba.com/nar/>
 - 競馬専門紙『馬サブロー』で予想掲載



的中型人工知能



回収型人工知能

競馬新聞デビュー！



アジェンダ

- 競馬予測の楽しみ
- 競馬予測の苦しみ
 - 目的変数の選び
 - データ成形
 - 予測モデルの区分決め
 - 予測モデルの学習
 - 予測モデルの評価
 - 売れる馬券の探し方


アジェンダ

- 競馬予測の楽しみ
- 競馬予測の苦しみ
 - 目的変数の選び
 - データ成形
 - 予測モデルの区分決め
 - 予測モデルの学習
 - 予測モデルの評価
 - 売れる馬券の探し方

競馬予測が楽しい5つの理由

- 毎週（毎日）解くべき問題となるデータが新しく追加される
- 結果が出る過程をリアルタイムに映像で観ることができる
- 豊富なデータ
- 絶妙な難易度
- 成果がすぐに目に見える形（お金）になる

毎週データが追加される



リアルタイムに映像で



競馬のデータは豊富

- 構造化データ
 - レース情報、競走成績、騎手、調教師、オッズ、調教など
- テキストデータ
 - 掲示板/Twitter
- 時系列データ
 - 過去戦歴
 - 時系列オッズ
- 映像データ
 - レース映像

日本競馬の難易度

- 胴元に売上の20~25%が入るようにオッズが動的に変化する
 - 海外競馬だとブックメーカーが職人芸で固定オッズを決定する
 - パチンコは15%程度
- ランダムに購入した場合、回収率の期待値は75~80%程度
- 回収率100%の壁を超えることは難しいが、不可能ではない

成果が目に見える

回収型人工知能の予想

10R 瓢湖特別 500円
10月12日(土) 19時30分 芝225m

予想印	
○	12 キューンハイト (4人気)
○	11 マイネルユニブラン (6人気)
▲	3 ゴールドバッキョウ (2人気)
△	2 ビスカデール (11人気)
△	5 ウインタリズム (8人気)

買い目	
券種・買い目	組み合わせ・点数
星勝 (69円)	12 1,000円 払い戻し: 1,000円×5.7倍=5,700円
3連馬 (170円×2=340円)	馬1: 12 馬2: 2 3 5 11 馬3: 2 3 5 11 お買い得 赤500円 払い戻し 2-5-12: 800円×928.7倍=742,800円
合計	5,800円

レース結果				
順位	枠	馬番	馬名	人気(単勝マウス)
1	○	12	キューンハイト	4人気(5.7倍)
2	△	2	ビスカデール	11人気(99.9倍)
3	△	5	ウインタリズム	8人気(28.9倍)

もっとみる

払い戻し・収支	
払い戻し金額	収支
748,860円	+742,860円



そもそも競馬自体が楽しい

アジェンダ

- 競馬予測の楽しみ
- 競馬予測の苦しみ
 - 目的変数の選び
 - データ成形
 - 予測モデルの区分決め
 - 予測モデルの学習
 - 予測モデルの評価
 - 売れる馬券の探し方

問題設定

関数 f を学習する → 機械学習



馬券の買い目

何を解くのか？

- 分類問題


- 0/1に丸めると情報が欠損する
- ラベル不均衡

- 回帰問題

- 自由度が高いため選択のセンスが必要

- ランキング問題

- 自然なアプローチだが、回帰よりも学習が重くて精度はそこまででもない



回帰問題の目的変数

基本となる目的変数

- 着順
- 走破タイム
- 1着からの秒差
- 本賞金
- スピード指数系
- 払戻オッズ

目的変数のエンジニアリング

- 特徴量作成やハイパーパラメータ調整よりも重要
- 試行錯誤を繰り返して見つけていくしかない
 - 30種類以上は試した
- ドメイン特化のエンジニアリング
 - レース内標準化
 - 馬券外の馬のスコアは同じにする
 - 着差0.0秒は同着とみなす

解く問題は1つである必要は無い

- 問題を切り分けることにより、解きやすくなる
 - 強さ
 - 美味しさ
 - 人気
- ただし、予測モデルをたくさん作る必要がある

アジェンダ

- 競馬予測の楽しみ
- 競馬予測の苦しみ
 - 目的変数の選び
 - データ成形
 - 予測モデルの区分決め
 - 予測モデルの学習
 - 予測モデルの評価
 - 売れる馬券の探し方

馬柱

レース情報

馬の属性

出走履歴

4歳

レース情報 オッズ

サテ系3歳 永勝利 (選白) [指定] 馬齢

コース 1600m 芝-左

本賞金(万円): 500, 230, 130, 75, 50

発走 11:25


馬牝の馬券

出走 回数	馬 番	馬名 / 登録名(人等) 馬名 馬主名 / 調教師名 / 血統	特記/身体 特徴/重さ 調教名	過去4走成績			
				前走	前々走	2走前	4走前
1	1	1馬一匹 460kg(前走) (有)キアノバファーム 新 育(高選) スコープオア 調(調) トリプル(2017年2月21日)	3.3 (重人馬) 54.0kg 調教名				
1	2	アルスタ 404kg(-6) (有)Oasis 調(調) 育(高選) スコープオア 調(調) トリプル(2017年2月21日)	240.9 (15人馬) 調教名 51.0kg 調教名	2016年1月23日 東京 本勝利 15番 16番 10番 12番人馬 417kg 調教名 52.0kg 400kg 調教名 1:28.0 54-14 24.4F ニシ(ジヤガー)X(1.3)	2016年2月6日 東京 新馬 14番 16番 15番 10番人馬 427kg 調教名 54.5kg 1800kg 調教名 1:22.5 16-12-11 34.3F ノーブルガ(ス.2)		
3	3	スーパースタ 458kg(+2) (有)キアノバファーム 新 育(高選) スコープオア 調(調) トリプル(2017年2月21日)	17.7 (7人馬) 調教名 54.0kg 調教名	2017年10月9日 東京 新馬 4番 17番 30番 12番人馬 458kg 調教名 54.0kg 1600kg 調教名 1:35.5 4-4 34.7F ニール(ジヤガー)X(0.6)			
3	4	ジュンファノエ 464kg(+4) (有)キアノバファーム 新 育(高選) スコープオア 調(調) トリプル(2017年2月21日)	141.2 (14人馬) 調教名 54.0kg 調教名	2016年1月11日 東京 本勝利 12番 13番 11番 10番人馬 458kg 調教名 54.0kg 1800kg 調教名 2:01.2 4-7 10 42.4F ニール(ジヤガー)X(0.6)	2016年2月21日 中山 本勝利 13番 16番 15番 12番人馬 475kg 調教名 56.0kg 1800kg 調教名 2:00.9 11-13 11 41.2F ライタ(ジヤガー)X(2.8)	2017年6月24日 東京 新馬 3番 16番 16番 5番人馬 476kg 調教名 54.0kg 1600kg 調教名 1:27.4 1-3 36.4F アビ(キアノバファーム)X(1.3)	

オッズ

騎手

馬柱をモデル化してデータ処理を簡潔に



出走履歴


- 過去N走の成績を横に並べる
 - カテゴリ変数が大量にあるとNが+1ただけで次元数が爆発的に増える
 - 出走数は競走馬ごとに異なるので、欠損値が多く発生する
 - 次元数の割に情報量が少ない
- 集計値に丸める
 - 次元数を抑えて、情報密度が高い
- RNNのような可変長な入力をとれるモデルを選択するアプローチも考えられる

出走履歴例

2018年3月11日 中央 未勝利 12着 13頭 11番 10番人気 468kg Dノバルジュ 56.0kg 1800ダ 例重 2:01.2 6-7-10-10 42.4F バギュートハート(6.4)	2018年2月25日 中山 未勝利 13着 16頭 15番 12番人気 476kg 栗田大知 56.0kg 1800ダ 良 2:00.9 11-12-11-13 41.3F ライクアロケット(2.8)	2017年6月24日 東京 新馬 8着 16頭 16番 5番人気 436kg 栗田大知 54.0kg 1600ダ 良 1:37.4 9-3 36.4F マイネルサイレン(1.5)
--	---	---

出走履歴の集計特徴量

- 「レース条件」の切り分け方は競馬のドメイン知識が必要
- 組み合わせ的に次元数が増えるので、計算コストは増加する
 - 2000個以上を作成



オッズ

- 的中したときの賭け金に対する払戻し倍率
- オッズは馬券発売締切まで刻一刻と変動する
- 過去データで学習したときに確定オッズを特徴量として使うと、シミュレーションの性能と実運用したときの性能に乖離が起きる
- 前日予測では使えない
 - 発売されていても確定オッズと乖離が大きすぎる
- 時系列オッズ解析だけで馬券を選択するアプローチも可

アジェンダ


- 競馬予測の楽しみ
- 競馬予測の苦しみ
 - 目的変数の選び
 - データ成形
 - 予測モデルの区分決め
 - 予測モデルの学習
 - 予測モデルの評価
 - 売れる馬券の探し方

レース区分

- 競馬場
- 芝・ダート・障害
- 距離
- 内回り・外回り
- クラス条件（新馬、未勝利、1600万下など）



適切なレース区分ごとに予測モデルを選択




適切なレース区分ごとに予測モデルを作成

- どの粒度が適切かは、**特徴量**と**目的変数**に大きく依存する
 - 走破タイムはコースに依存する
 - オッズはコースに依存しない
- 学習データと予測対象データの区分は必ずしも一致する必要は無い

例)

予測データ区分

学習データ区分




芝1400m予測モデル
は芝1200-1600mで
学習する

アジェンダ

- 競馬予測の楽しみ
- 競馬予測の苦しみ
 - 目的変数の選び
 - データ成形
 - 予測モデルの区分決め
 - 予測モデルの学習
 - 予測モデルの評価
 - 売れる馬券の探し方

LightGBM

- 勾配ブースティングの高速・軽量・高精度な実装
- カテゴリ変数をカテゴリ変数として扱うことができる
- 欠損値を欠損値として扱うことができる
- AlphaImpactのOMOTOはLightGBMのcommitter
- <https://github.com/Microsoft/LightGBM>



ハイパーパラメータのチューニング

- hyperoptを利用
 - ベイズ最適化
 - <https://github.com/hyperopt/hyperopt>
- 5-fold cross validation
- 探索パラメータ数が多いので、計算コストが高い
- 200回ほど探索

予測モデルの実験

- 目的変数
- 特徴量
- モデル区分
- ハイパーパラメータ

試すべき条件が多く計算時間が非常にかかる

GCEのプリエンプロティブインスタンスの活用

- Google Compute Engineの計算余剰資源を利用しているため、利用料金が約70%オフ
- 1 プロジェクト 72CPUまでなので、それ以上必要な場合はプロジェクトを分ける必要がある
 - プロジェクト間でイメージのコピーはできない
- 予告なしに落ちる（最大24時間）なので、探索状態を逐次保存しておき、再開できるようにしておく
 - `hyperopt.Trials`をpickle保存しておけばOK
- 実験の進捗は逐次Slackに通知

アジェンダ

- 競馬予測の楽しみ
- 競馬予測の苦しみ
 - 目的変数の選び
 - データ成形
 - 予測モデルの区分決め
 - 予測モデルの学習
 - 予測モデルの評価
 - 売れる馬券の探し方

nDCG


- ランキング問題でよく使われるnDCGを利用
- 高い関連度がより上位に予測できていれば大きな値になる（最大値1）
- 関連度は自分で定義する必要あり
 - 非負値かつ大きい＝良いとなる数値
 - 賞金がおすすめ

$$DCG = rel_1 + \sum_{i=2}^n \frac{rel_i}{\log_2 i}$$

$$nDCG = \frac{DCG}{idealDCG}$$

評価データの期間

- 競馬のデータは少なくて貴重
 - 年間3千レース程度
- 季節性なども考慮して最低1年間は評価に必要
- コースの改修があるので、あまりに古いデータや役に立たない



コースの改修工事

- 競馬場は不定期に改修が行われる
- 大改修の場合は傾向が大きく変わってしまうので、注意が必要
- 最近の主な大改修
 - 2006年 阪神競馬場大改修
 - 2010年4月~2012年1月 中京競馬場大改修

アジェンダ

- 競馬予測の楽しみ
- 競馬予測の苦しみ
 - 目的変数の選び
 - データ成形
 - 予測モデルの区分決め
 - 予測モデルの学習
 - 予測モデルの評価
 - 売れる馬券の探し方

「勝てる馬券」 ≠ 「売れる馬券」


1. 100週間のうち99週間は回収率0%だが、**通算回収率200%**になる馬券
2. 100週間のうち90週間は回収率100%超えだが、**通算回収率105%**になる馬券

⇒ (1) の馬券を買い続けるには強靱な忍耐力が必要＝売れない馬券

1週間回収率100%超え確率

- 馬券購入者の気持ちとして、週間単位で安定してプラスになると嬉しい
- 3場開催の場合、1週間に72Rが行われる
- 評価データから72Rを繰り返し復元抽出し、100%超えの確率を計算する

1週間回収率100%超え確率



馬券の利用性

- 3連単などの購入点数が多くなりやすい馬券種では、ボックスやフォーメーションなどの賭け方で一括購入ができる
- 等価な馬券をバラで購入可能だが、大変面倒くさい

3連単フォーメーション

A, B - A, B, C - A, B, C, D, E 各100円	展開 →	A - B - C 100円	B - A - C 100円
		A - B - D 100円	B - A - D 100円
		A - B - E 100円	B - A - E 100円
		A - C - B 100円	B - C - A 100円
		A - B - D 100円	B - A - D 100円
		A - B - E 100円	B - A - E 100円


馬券の利用性

- フォーメーションで買えないような多点数馬券はユーザにとって買いづらい

A - B - C	800円		B - A - C	200円
A - B - D	200円		B - A - D	300円
A - B - E	500円	• • •	B - A - E	800円
A - C - B	300円		B - C - A	300円
A - B - D	100円		B - A - D	1000円
A - B - E	1000円		B - A - E	900円

計120点

馬券の3つの評価軸



まとめ

- 競馬は楽しい、競馬予測はもっと楽しい
- 競馬データはクセがある
- 予測モデル実験は目的変数・特徴量・レース区分・ハイパーパラメータを探索
- 競馬は意外とデータが少なく評価が難しい
- 馬券の良し悪しは「収益性」「安定性」「利用性」で判断する