

中央競馬におけるメタモデルを用いた馬券購入と回収率の評価

小林 正伸[†] 酒井 哲也[†]

[†] 早稲田大学基幹理工学部情報理工学科 〒169-8555 東京都新宿区大久保 3-4-1

E-mail: [†]kobamasa256@toki.waseda.jp, ^{††}tetsuyasakai@acm.org

あらまし 本論文では競馬における馬券購入の意思決定を対象に、予測モデルと購入戦略を統合したフレームワークを提案・検証する。予測モデルとして約 40 年分の過去レースデータに対し sliding window 方式を採用し、LightGBM による年次更新の学習・予測を行った。また予測モデルは、標準の二値分類に加え、オッズの平方根で重み付けした学習、ならびに LGBMRanker によるランキング学習を含む複数モデルを構築した。さらに、これら複数モデルの出力とレース状態を入力として、券種ごとに「買い目パターン（あるいは不購入）」を選択するメタモデルを学習した。最終的にテスト期間（2021～2025 年）の収益・回収率およびベット数により評価した。提案手法は学習の乱数（seed）により結果が変動するため、seed を 100 通り変更した評価を行った。その結果、良い場合には特定の券種（単勝）で回収率 107.89% を達成した一方、回収率やベット数は seed により大きく変動し、学習は不安定であることを確認した。

キーワード ランキング学習, メタモデル, 競馬

1 はじめに

競馬は日本で広く行われている公営ギャンブルであり、近年は過去レースデータを用いた機械学習による予測・購入戦略の検討が活発である。一方で、予測精度の向上がそのまま収益（回収率）に直結するとは限らず、オッズや券種の多様性、年次での傾向変化などにより、単一モデル・単一戦略では安定した収益を得ることが難しい。

競馬予測における統計的アプローチとして、多項ロジットモデルを用いたハンディキャップなどがあった [1]。国内競馬においても、市場オッズの歪み（割安）を検知し、機械学習と組み合わせることで効率的に馬券を購入する枠組みが議論されている [2]。

本研究は、予測モデルと購入戦略を統合し、「レース状態から券種別の買い目パターン（あるいは不購入）」を選択する枠組みとして馬券購入の意思決定を扱う。予測モデルとして LightGBM を使い、約 40 年分の過去レースデータに対して sliding window 方式の年次更新学習を行い、2006 年から 2025 年までを逐次予測する。さらに、標準の二値分類、オッズの平方根で重み付けした学習、ランキング学習など複数系列のモデル（計 10 個）を構築し、それらの出力を入力とする券種別メタモデルを学習する。

1.1 本研究で行っていること

本研究で行っていることは以下である。

- 長期データに対して年次更新学習を採用し、時代変化を考慮した予測出力を得る枠組みを設計した。
- 標準分類・重み付き分類・ランキング学習を並行して構築し、メタモデルに入力する多様な予測信号を設計した。
- 券種ごとに「買い目パターン（あるいは不購入）」を選択するメタモデルを導入し、意思決定をするモデルを構築した。

1.2 論文構成

第 2 章で関連研究を整理し、第 3 章で提案手法を述べる。第 4 章で実験設定（データ分割・ベースライン・評価指標）を示し、第 5 章で実験結果を報告する。第 6 章で考察を行い、第 7 章でまとめと今後の課題を述べる。

2 関連研究

競馬予想における機械学習の活用は、単なる的中率の向上を目指すものに加え、オッズの歪みを考慮して回収率の改善を狙う手法も提案されている。本節では、本研究に関連する先行研究を「予測モデルの構築手法」と「購入戦略と意思決定」の 2 点について分けて述べる。

2.1 機械学習アルゴリズムと学習手法

競馬予想のアプローチとして、中谷 [3] はロジスティック回帰分析を用い、1 着から 3 着以内に入る馬と 4 着以下の馬を分類する手法を検討した。ここで、全体的中率を向上することも大事であるが、1 着から 3 着以内的中率を上げるべきであることが示唆されている [3]。これに対し、勾配ブースティング決定木、特に LightGBM を用いた研究が多数ある。中村・宮崎 [4] は、LightGBM を用いた二値分類モデルにおいて、「穴馬バイアス (Favorite-Longshot Bias)」に着目した学習を行い、単勝・複勝回収率の向上を実現した。さらに、出走馬同士の相対的な能力差を考慮するため、ランキング学習も考慮されている。ランキング学習は、個体を独立に扱わず、順位間の相対関係を直接最適化する枠組みであり、RankNet から LambdaRank/LambdaMART といった手法が存在する [5]。韓国の競馬市場を対象とした研究でも、LambdaMART などの LTR 手法が従来の回帰的アプローチより有効であることが報告されている [6]。国内事例として、三枝ら [7] は、Factorization Machines (FM) を応用し、エンティティ同士の相互作用を考慮

した「組合せ依存型ランキング学習」を提案した。これは、特定の相手関係によって着順が変動する競馬の特性を捉えるものであり、従来の2段階条件付きロジスティック回帰を利用した予測モデル [8] を超える精度を達成している [7]。また、勝ち馬が少数で負け馬が多数となる不均衡データに対しては、SMOTE等のオーバーサンプリングが精度向上に寄与し得ることが報告されている [9]。

2.2 購入戦略の最適化と意思決定フレームワーク

予測精度が必ずしも収益に直結しないという課題に対し、予測モデルと購入戦略を統合する試みがなされている。杉山・山下 [10] は、部分的再帰型ニューラルネットワークを用いた馬の予測確率とオッズの期待値を基に、購入金額を決定する betting 戦略の重要性を説いた。また、田中ら [2] は、予測モデルの出力値と実際のオッズを比較して割安な馬券を選択する手法を提案し、回収率 100% 超を達成した。しかし、これらの先行研究の多くは特定の単一モデルや限定的な期間のデータに基づいたものであり、市場の動向や年次ごとの変化に柔軟に対応する仕組みについては課題が残されていた。さらに、穴馬バイアスは回収率向上に向けて考慮する必要がある、この市場の歪みをどのようにして捉えるかは重要な論点である [11]。また、予測モデル出力に基づく動的な賭け配置を学習するアプローチも提案されている [12]。

2.3 本研究の位置づけ

上述の先行研究を踏まえ、本研究は以下の点で既存研究とは異なる。第一に、約 40 年という極めて長期間のデータを対象に、sliding window 方式と LightGBM を用いた年次更新を行うことで、時代によるレース傾向の変化をモデルに組み込ませた点である。第二に、先行研究 [4] [7] で個別に行われていたモデルを参考とした上で、「二値分類」「オッズ重み付け学習」「ランキング学習 (LGBMRanker)」を並行して実施し、複数の予測出力を得ている点である。第三に、これら複数モデルの出力とレース状態を入力とする「メタモデル」を構築し、券種ごとに「買い目パターン」や「不購入」を選択する意思決定フレームワークを提案している点にある。これにより、予測モデルが持つ得意・不得意をメタレベルで学習し、最終的な回収率を最大化させる戦略的購入を実現している。

3 提案手法

3.1 全体像

本研究では、予測モデル群の出力と入手可能なレース状態から、券種ごとに購入行動（買い目パターン、あるいは不購入）を選択する。全体像を図 1 に示す。

3.2 問題設定

本研究では券種ごとに独立に購入戦略を学習する。以降、券種を $b \in \mathcal{B}$ (単勝, 複勝, 馬連, ワイド, 三連複) で表し、券種 b を固定して議論する。

各レース r について、入手可能なレース状態を s_r とし、購

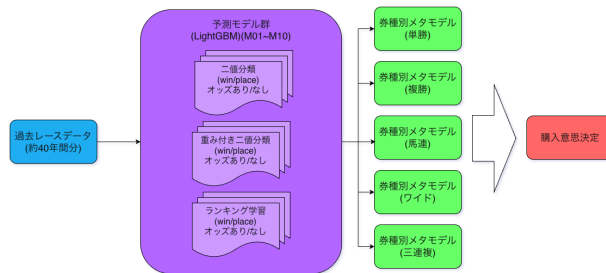


図 1 提案手法の全体像（予測モデル群→券種別メタモデル→購入意思決定）

表 1 入力として用いるレース状態（概要）

| 項目 | 内容 |
|---------|------------------------------|
| レース条件 | 場名、芝/ダート、距離、回り、馬場状態、天気、クラス等 |
| 出走馬情報 | 性別、年齢、斤量、馬体重、馬体重増減等 |
| オッズ情報 | 単勝オッズ、人気（人気順） |
| 過去成績の要約 | 過去 5 走に基づく馬スコア・騎手スコア (3.3 節) |
| 予測モデル出力 | 予測モデル群 (3.4 節) の出力 (確率/スコア) |

入行動 $a_r^b \in \mathcal{A}^b$ を選択する。ここで \mathcal{A}^b は券種 b の「購入パターン候補（買い目集合）」の集合であり、 $a = 0$ として「賭けない (no_bet)」を含む。

行動 a を選択したときのコスト（投下資金）を $c(r, a)$ 、払い戻し金合計を $u(r, a)$ 、純利益（損益）を

$$p(r, a) = u(r, a) - c(r, a)$$

と定義する。テスト期間 \mathcal{R}_{test} における回収率

$$\text{Rec}^b = \frac{\sum_{r \in \mathcal{R}_{test}} u(r, a_r^b)}{\sum_{r \in \mathcal{R}_{test}} c(r, a_r^b)}$$

として評価する。また、買い行動頻度の指標としてベット数 ($c(r, a) > 0$ のレース数) も併せて報告する。

3.3 データと前処理

本研究では過去レース情報から特徴量を構成し、予測モデルおよびメタモデルの入力に用いる。データは「1行=1レースにおける1頭（レース×馬）」で整理し、race_id（レース識別子）をキーとして、同一レース内の馬をグループ化できる形式とする。各行には (i) 入手可能なレース条件・出走馬属性、(ii) 過去成績の要約特徴量、(iii) オッズ由来特徴量、および (iv) 学習・評価に用いる目的変数や払い戻し関連の列を含める。以下では特に本研究で導入した集約特徴量と正規化を述べる。

a) データ取得

本研究で用いた過去レース情報・オッズ情報・払い戻し情報は、netkeiba.com の公開情報を参照し、スクレイピングにより収集した^(注1)。取得時にはサーバ負荷を避けるため、リクエ

注 1 : <https://www.netkeiba.com/>

スト間に適切な待機時間を設け、短時間に大量のアクセスを行わないよう配慮した。

b) データ規模と前処理の概要

取得時点のデータは 1,757,517 行 (29 列) であり, `race_id` は 130,760 レースに対応する. 前処理を経て, 最終的に 1,750,605 行 (48 列) を学習・評価に用いた (`race_id` の件数は同数). 列数の増加は特徴量生成・エンコードによる. また欠損値の扱いとして, 発走前の事象 (出走取消・競走除外) については当該出走が存在しなかったものとして除外し, 発走後の事象 (競走中止) については当該レースの最下位着順として扱った. 競走中止の場合でも, 学習に必要な説明変数 (オッズ等) は取得できるため, 除外せずに学習対象へ含めた.

c) 基礎スコア (`base_point`)

レース r における馬 h の着順を $\text{pos}_{r,h}$, 出走頭数を n_r とする. 複勝圏ボーダー B_r (頭数に応じて 1~3), 善戦圏ボーダー $L_r = \lfloor n_r/3 \rfloor$ を用いて, 基礎スコア $bp_{r,h}$ を次式で定義する.

$$bp_{r,h} = \begin{cases} 1.0 & (\text{pos}_{r,h} = 1) \\ 0.8 & (\text{pos}_{r,h} \leq B_r) \\ 0.2 & (\text{pos}_{r,h} \leq L_r) \\ 0.0 & (\text{otherwise}) \end{cases}$$

d) 過去 5 走の集約 (馬スコア・騎手スコア)

馬 (あるいは騎手) e の直近 5 走における基礎スコア列を $bp_e^{(1)}, \dots, bp_e^{(5)}$ ((5) が直近) とし, 重みを

$$w_t = \frac{t}{15} \quad (t = 1, \dots, 5)$$

とする ($\sum_t w_t = 1$). このとき集約スコアを

$$\text{score}_e = \sum_{t=1}^5 w_t bp_e^{(t)}$$

で定義する. 本研究ではこれを `horse_score` および `jockey_score` として用いる. また, 勝率特徴として過去 5 走の勝率 (`horse_win_rate_5`, `jockey_win_rate_5`) も併用する.

e) レース内正規化 (シェア)

同一レース内の相対的位置を表すため, 馬 h のスコアをレース内合計で正規化したシェアを用いる. ここで \mathcal{H}_r はレース r の出走馬集合を表す. 例えば騎手スコアについて,

$$\text{share}_{r,h}^{\text{jockey}} = \frac{\text{jockey_score}_{r,h}}{\sum_{h' \in \mathcal{H}_r} \text{jockey_score}_{r,h'}}$$

を `jockey_score_share_in_race` とする (馬スコアも同様).

f) オッズ由来特徴

単勝オッズを $o_{r,h}$ とし, 逆数オッズを $\text{inv}_{r,h} = 1/o_{r,h}$ と定義する (`inv_odds`). さらにレース内正規化として

$$\text{invshare}_{r,h} = \frac{\text{inv}_{r,h}}{\sum_{h' \in \mathcal{H}_r} \text{inv}_{r,h'}}$$

を `inv_odds_share_in_race` とする. また, オッズが 10 未満

表 2 予測モデルに入力する主な特徴量 (概要)

| カテゴリ | 例 (列名) |
|----------|---|
| 馬のプロフィール | sex, age, horse_weight, horse_weight_diff, carried_weight |
| レース条件 | racecourse, surface, distance, track_direction, track_condition, weather, race_class, class_category, distance_category |
| オッズ情報 | odds_win, popularity, inv_odds, inv_odds_share_in_race, odds_lt10_ratio_in_race |
| 過去成績要約 | base_point, horse_score, jockey_score, horse_score_share_in_race, jockey_score_share_in_race |

の馬の割合

$$\text{ratio10}_r = \frac{|\{h \in \mathcal{H}_r \mid o_{r,h} < 10\}|}{|\mathcal{H}_r|}$$

を `odds_lt10_ratio_in_race` として用いる.

g) カテゴリ特徴量

`sex`, `surface`, `track_direction`, `track_condition`, `weather`, `racecourse` などのカテゴリ列はラベルエンコード済みの数値として扱う.

3.4 予測モデル

予測モデルには LightGBM を用いる. 競馬では年次で環境が変化し得るため, 時系列を考慮した sliding window 学習を採用する.

a) ロール学習 (年次更新)

予測対象年を Y とし, 学習期間を直近 20 年 ($Y - 20$) ~ ($Y - 1$) とする. この 20 年をさらに訓練 (例: ($Y - 20$) ~ ($Y - 6$)) と検証 (例: ($Y - 5$) ~ ($Y - 1$)) に分割し, 早期終了に用いる. テストは Y 年とし, $Y = 2006, \dots, 2025$ を順に予測する.

b) モデル系列

メタモデルに多様な入力を与えるため, 以下の 3 系列の予測モデルを構築する.

- 標準二値分類: 目的変数を単勝 (`win_flag`) または複勝 (`win_three`) とし, 確率 \hat{p} を出力する.
- 重み付き二値分類: 勝ち馬 ($y = 1$) に対し $w = \sqrt{o}$ (単勝オッズ o の平方根) をサンプル重みとして損失に反映し, 高オッズ勝ち馬の取りこぼしを相対的に重視する.
- ランキング学習: `race_id` を `group` とし, 着順が小さいほど大きい順位スコアをラベルとして LambdaRank (`lambdarank`) を学習し, レース内の相対順位スコアを入力する.

3.5 メタモデル

本研究のメタモデルは券種 b ごとに独立に構築する. 入力 is 予測モデル群の出力 (表 3) とレース状態 (表 1) から構成されるレース表現 s_r , 出力は券種 b のアクション集合 A^b に対する効率 (期待効率) の回帰値である. この枠組みは, 複数のベース学習器の出力を上位モデルで統合するスタッキングの形態と見なせる.

a) レース表現 (state)

各レースについて, 人気順 (`inv_odds_share_in_race` 降順) に最大 $N = 18$ 頭を並べ, 馬ごとの特徴ベクトル (例:

表 3 予測モデル群 (M01~M10) の定義

| ID | 学習方式 | 特徴量セット | 目的/出力 |
|-----|-------------------------|--------|-----------------------|
| M01 | 標準二値分類 | オッズあり | win (win_flag) の確率 |
| M02 | 標準二値分類 | オッズあり | place (win_three) の確率 |
| M03 | 標準二値分類 | オッズなし | win の確率 |
| M04 | 標準二値分類 | オッズなし | place の確率 |
| M05 | 重み付き二値分類 (\sqrt{o}) | オッズあり | win の確率 |
| M06 | 重み付き二値分類 (\sqrt{o}) | オッズあり | place の確率 |
| M07 | 重み付き二値分類 (\sqrt{o}) | オッズなし | win の確率 |
| M08 | 重み付き二値分類 (\sqrt{o}) | オッズなし | place の確率 |
| M09 | ランキング学習 (Lamb-daRank) | オッズあり | レース内順位スコア |
| M10 | ランキング学習 (Lamb-daRank) | オッズなし | レース内順位スコア |

odds_lt10_ratio_in_race, inv_odds_share_in_race, および M01~M10 の予測値などを連結し、固定長ベクトル t_r を構成する。頭数が N 未満の場合はゼロ埋めする。

b) 券種別アクション集合

各券種 b について、no_bet に加えて複数の「買い目パターン」を定義し、その中から 1 つを選択する。買い目の候補は人気順に加え、ランキングモデルのスコア順 (M09/M10) から生成し、多様な並びに対して同型の戦略を適用できるようにする。

買い目生成の基準となる順位列を、人気順 (inv_odds_share_in_race 降順), ランキングスコア順 (M09 降順), ランキングスコア順 (M10 降順) の 3 種類として用意する。順位列を $\pi = (\pi_1, \pi_2, \dots)$ (π_i は i 位の馬番) と表す。

c) 単勝・複勝のベース戦略 (top- k)

単勝・複勝では、順位列 π に対し $k \in \{1, \dots, 6\}$ として「 π_k を 1 点買い」をベース戦略とする (no_bet を含む)。

d) 馬連・ワイドのベース戦略 (20 戦略)

馬連・ワイドでは、順位列 π に対して表 4 の 20 戦略をベース戦略とし、それぞれ対応する買い目集合 (組) を生成する。例えば box_1-4 は上位 4 頭の全組合せ, axis_2_all は 2 番人気の馬を軸として他の全馬への総流しを表す。

e) 三連複のベース戦略 (15 戦略)

三連複では、順位列 π に対して表 5 の 15 戦略をベース戦略とし、対応する買い目集合 (三つ組) を生成する。例えば axis_1-2_all は 1・2 番人気の馬を 2 頭軸として、残り 1 頭を他の全馬から選ぶ総流しを表す。

f) 目的変数

各レース r について、アクション a に対応する買い目集合を $T^b(r, a)$ と表す (単勝・複勝は 1 点, 馬連・ワイドは 2 頭組の集合, 三連複は 3 頭組の集合)。本研究では 1 点あたりの購入単位を $B = 100$ 円とし、コスト (投下資金) を

$$c(r, a) = B \cdot |T^b(r, a)|$$

と定義する (no_bet のとき $T = \emptyset$)。

表 4 馬連・ワイドのベース戦略 (順位列 π から買い目集合を生成)

| ID | 戦略名 (例) | 買い目集合の定義 |
|----|------------|---|
| 1 | 1-2 | $\{(\pi_1, \pi_2)\}$ |
| 2 | box_1-3 | $\{(\pi_i, \pi_j) \mid 1 \leq i < j \leq 3\}$ |
| 3 | box_1-4 | $\{(\pi_i, \pi_j) \mid 1 \leq i < j \leq 4\}$ |
| 4 | box_1-5 | $\{(\pi_i, \pi_j) \mid 1 \leq i < j \leq 5\}$ |
| 5 | 2-3 | $\{(\pi_2, \pi_3)\}$ |
| 6 | box_2-4 | $\{(\pi_i, \pi_j) \mid 2 \leq i < j \leq 4\}$ |
| 7 | box_2-5 | $\{(\pi_i, \pi_j) \mid 2 \leq i < j \leq 5\}$ |
| 8 | axis_1_all | $\{(\pi_1, \pi_j) \mid j \neq 1\}$ |
| 9 | axis_2_all | $\{(\pi_2, \pi_j) \mid j \neq 2\}$ |
| 10 | axis_3_all | $\{(\pi_3, \pi_j) \mid j \neq 3\}$ |
| 11 | axis_4_all | $\{(\pi_4, \pi_j) \mid j \neq 4\}$ |
| 12 | axis_5_all | $\{(\pi_5, \pi_j) \mid j \neq 5\}$ |
| 13 | box_1-6 | $\{(\pi_i, \pi_j) \mid 1 \leq i < j \leq 6\}$ |
| 14 | box_2-6 | $\{(\pi_i, \pi_j) \mid 2 \leq i < j \leq 6\}$ |
| 15 | 3-4 | $\{(\pi_3, \pi_4)\}$ |
| 16 | box_3-5 | $\{(\pi_i, \pi_j) \mid 3 \leq i < j \leq 5\}$ |
| 17 | box_3-6 | $\{(\pi_i, \pi_j) \mid 3 \leq i < j \leq 6\}$ |
| 18 | 4-5 | $\{(\pi_4, \pi_5)\}$ |
| 19 | box_4-6 | $\{(\pi_i, \pi_j) \mid 4 \leq i < j \leq 6\}$ |
| 20 | 5-6 | $\{(\pi_5, \pi_6)\}$ |

表 5 三連複のベース戦略 (順位列 π から買い目集合を生成)

| ID | 戦略名 (例) | 買い目集合の定義 |
|----|--------------|--|
| 1 | box_1-3 | $\{(\pi_i, \pi_j, \pi_k) \mid 1 \leq i < j < k \leq 3\}$ |
| 2 | box_1-4 | $\{(\pi_i, \pi_j, \pi_k) \mid 1 \leq i < j < k \leq 4\}$ |
| 3 | box_1-5 | $\{(\pi_i, \pi_j, \pi_k) \mid 1 \leq i < j < k \leq 5\}$ |
| 4 | box_1-6 | $\{(\pi_i, \pi_j, \pi_k) \mid 1 \leq i < j < k \leq 6\}$ |
| 5 | box_2-4 | $\{(\pi_i, \pi_j, \pi_k) \mid 2 \leq i < j < k \leq 4\}$ |
| 6 | box_2-5 | $\{(\pi_i, \pi_j, \pi_k) \mid 2 \leq i < j < k \leq 5\}$ |
| 7 | box_2-6 | $\{(\pi_i, \pi_j, \pi_k) \mid 2 \leq i < j < k \leq 6\}$ |
| 8 | box_3-5 | $\{(\pi_i, \pi_j, \pi_k) \mid 3 \leq i < j < k \leq 5\}$ |
| 9 | box_3-6 | $\{(\pi_i, \pi_j, \pi_k) \mid 3 \leq i < j < k \leq 6\}$ |
| 10 | box_4-6 | $\{(\pi_i, \pi_j, \pi_k) \mid 4 \leq i < j < k \leq 6\}$ |
| 11 | axis_1-2_all | $\{(\pi_1, \pi_2, \pi_k) \mid k \notin \{1, 2\}\}$ |
| 12 | axis_2-3_all | $\{(\pi_2, \pi_3, \pi_k) \mid k \notin \{2, 3\}\}$ |
| 13 | axis_3-4_all | $\{(\pi_3, \pi_4, \pi_k) \mid k \notin \{3, 4\}\}$ |
| 14 | axis_4-5_all | $\{(\pi_4, \pi_5, \pi_k) \mid k \notin \{4, 5\}\}$ |
| 15 | axis_5-6_all | $\{(\pi_5, \pi_6, \pi_k) \mid k \notin \{5, 6\}\}$ |

g) 払い戻しデータと払い戻し金 $u(r, a)$ の計算

単勝・複勝については、各 (レース \times 馬) 行に付与された的中フラグ (win_flag, win_three) および払い戻し金 (payout_win, payout_place; 円) を用いる。単勝の 1 点買い (馬番 h) では

$$u(r, a) = \begin{cases} \text{payout_win}(r, h) & (\text{win_flag}(r, h) = 1) \\ 0 & (\text{otherwise}) \end{cases}$$

複勝も同様に payout_place と win_three を用いる。

馬連・ワイド・三連複については、レースごとの払い戻し情報 (race_id, 馬券の種類, 馬番, 払い戻し金額) から、レース ID ごとに「買い目 \rightarrow 払い戻し金額 (円)」の対応表 $P^b(\cdot)$ を作成する。ここで馬番は「 i - j 」または「 i - j - k 」形式で表される。馬番の順序によらず同一の買い目として扱うため、「 i - j 」形式は $(\min(i, j), \max(i, j))$, 「 i - j - k 」形式は昇順にソートした三つ組へ正規化してから対応表を作成する。

買い目集合 $T^b(r, a)$ に対する払い戻し金合計を

表 6 データ分割 (予測モデル・メタモデル)

| 対象 | 分割 |
|-----------------|--|
| 予測モデル (rolling) | 予測対象年 $Y = 2006, \dots, 2025$. 学習: $(Y - 20) \sim (Y - 1)$, 検証: $(Y - 5) \sim (Y - 1)$ (例) |
| メタモデル | 学習: ~ 2015 年, 検証: $2016 \sim 2020$ 年, テスト: $2021 \sim 2025$ 年 |

$$u(r, a) = \sum_{t \in T^b(r, a)} P_r^b(t)$$

と定義し、 $P_r^b(t)$ が存在しない買い目は 0 とする。

h) 効 率

払い戻し $u(r, a)$ とコスト $c(r, a)$ に基づき純利益 $p(r, a) = u(r, a) - c(r, a)$ を定義し、効率を

$$\text{eff}(r, a) = \begin{cases} 0 & (c(r, a) = 0) \\ \frac{p(r, a)}{c(r, a)} & (c(r, a) > 0) \end{cases}$$

と定義する。学習の安定化のため、eff は券種ごとに設定した範囲 $[\alpha^b, \beta^b]$ にクリップして回帰する。

i) 学習と意思決定

メタモデルには多層パーセプトロンを用い、入力 t_r から全アクションの効率推定値 $\hat{\text{eff}}(r, a)$ を同時に回帰する (損失は回帰損失)。テスト時は $\max_{a \neq 0} \hat{\text{eff}}(r, a)$ をとるアクションを候補とし、その最大値が券種ごとの閾値以上の場合にのみ購入し、それ以外は no_bet とする。

4 実験設定

4.1 データ分割と学習手順

予測モデルは 3.4 節のロール学習により 2006~2025 年の各年を予測し、モデル出力をレース・馬単位で保存する。続いてメタモデルは、予測結果が得られる期間を年次で分割し、学習期間 (~2015 年)、検証期間 (2016~2020 年)、テスト期間 (2021~2025 年) とする時系列分割で学習する。

4.2 評価指標

購入戦略 (券種別メタモデル) は、テスト期間 (2021~2025) における回収率、総投下資金、総払い戻し、総利益、ベット数を集計し、ベースラインと比較する。さらに、学習の乱数 (seed) による変動を評価するため、seed を 100 通り変更した評価を行い、回収率分布 (箱ひげ図) を可視化する。

4.3 ベースライン

本研究では、提案手法 (券種別メタモデル) の有効性を検証するため、以下のベースライン群を最初から定義し、テスト期間 (2021~2025 年) で比較する。

a) 市場ベースライン (1 番人気の 1 点買い)

券種ごとに「各レースで人気が 1 位の買い目を 1 点買い (100 円)」を用意する。なお、本稿では人気は単勝人気 (単勝オッズに基づく順位) を指す。組み合わせ券種でも同様に、馬連・




図 2 全券種まとめ: seed を 100 通り変更した評価における回収率 (Rec) の分布 (箱ひげ図)。赤破線は Rec=1 を表す。

ワイド・三連複の券種において、1 番人気の組み合わせを購入する。

b) 固定戦略ベースライン

買い目構造 (box/流し等) の影響を分離するため、典型的な固定戦略を比較対象に加える。馬連・ワイドは 1-2 (1 番人気と 2 番人気の組合せ) と axis_1_all (1 番人気の馬を軸とした総流し)、三連複は box_1-5 と axis_1-2_all (1・2 番人気の 2 頭軸総流し) を用いる。

c) 予測閾値ベースライン

予測モデル出力に基づく単純な購入規則として、閾値 τ^b を用いる。(ここで購入閾値 τ^b は、検証期間の回収率とベット数のトレードオフに基づき券種ごとに決定し、テスト期間では固定して運用する。) 単勝は M01, 複勝は M02 の確率を用い、 $\hat{p} \geq \tau^b$ を満たす買い目を購入する。馬連・ワイド・三連複では、同一レース内で $\hat{p} \geq \tau^b$ を満たす馬集合から買い目集合 (全組合せ) を生成して購入する。点数爆発を避けるため、候補馬は上位 K 頭 (馬連・ワイドは $K = 6$, 三連複は $K = 7$) に制限する。

d) 市場シェア閾値ベースライン

市場情報のみを用いた対照として、inv_odds_share_in_race (レース内シェア) に閾値 τ^b を適用し、invshare $\geq \tau^b$ を満たす馬集合から買い目集合 (全組合せ) を生成する (上位 K 制限は予測閾値ベースラインと同じ)。

5 実験結果

5.1 券種別購入戦略の成績

本節では、提案手法 (券種別メタモデル) を購入戦略として運用した際の最終成績を示し、ベースラインと比較する。券種ごとにメタモデルを学習し、テスト期間 (2021~2025) における回収率 (Rec)、総投下資金、総払い戻し、総利益、ベット数を集計する。総括的な成績は表 7 に示す。提案手法は学習の乱数 (seed) により結果が変動するため、seed を 100 通り変更した評価を行った。回収率 (Rec) の分布を全券種まとめで可視化した結果を図 2 に示す。さらに、年次での変動と不確実性を把握するため、年ごとの回収率 (Rec) 推移と年末資金推移 (中央値と 5-95% 区間) を図 3 および図 4 に示す。

5.2 ベースラインとの比較

本節では、4.3 節で定義したベースライン群と比較して、提案手法の回収率とベット数を報告する。提案手法は seed によ

表 7 提案手法（券種別メタモデル）の成績要約（seed を 100 通り変更した評価，テスト期間 2021～2025）

| 券種 | 指標 | 回収率 (%) | ベット数 |
|-----|---------|---------|-------|
| 単勝 | 平均 | 81.50 | 493 |
| | 中央値 | 81.51 | 452 |
| | 最良 (参考) | 107.89 | 407 |
| 複勝 | 平均 | 90.76 | 2,393 |
| | 中央値 | 90.79 | 2,314 |
| | 最良 (参考) | 93.85 | 1,627 |
| 馬連 | 平均 | 77.98 | 365 |
| | 中央値 | 78.80 | 347 |
| | 最良 (参考) | 90.19 | 533 |
| ワイド | 平均 | 92.20 | 257 |
| | 中央値 | 91.37 | 240 |
| | 最良 (参考) | 107.53 | 140 |
| 三連複 | 平均 | 86.93 | 580 |
| | 中央値 | 86.62 | 543 |
| | 最良 (参考) | 101.63 | 352 |

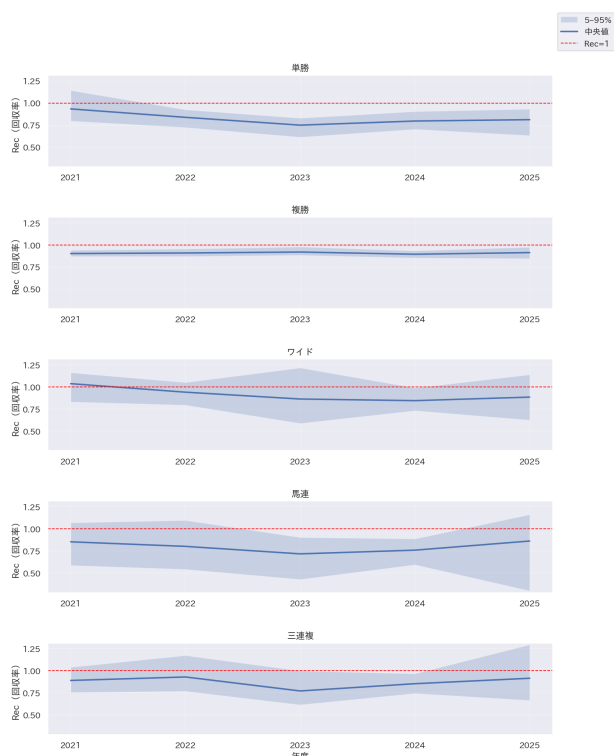


図 3 全券種まとめ：テスト期間（2021～2025）における年ごとの回収率（Rec）推移。seed を 100 通り変更した評価について中央値と 5-95% 区間を示す。

り変動するため、平均値に加えて、参考として最良 seed の成績も併記する（選択によるバイアスの可能性については 6 章で述べる）。結果を表 8 および表 9 に示す。

6 考 察

6.1 ベースラインとの比較に基づく所見

表 8 および表 9 より、提案手法はベット数を大きく削減しつつ、一部の券種では最良の場合、100%超の回収率を達成した。一方で、seed を変えた評価における平均・中央値や、1 番人気の 1 点買い、固定戦略（1-2 や流し）、予測閾値、市場シェア閾値といった単純なベースラインでは、概ね回収率は 100%未満である。また、提案手法の平均成績は券種によりばらつきがあ

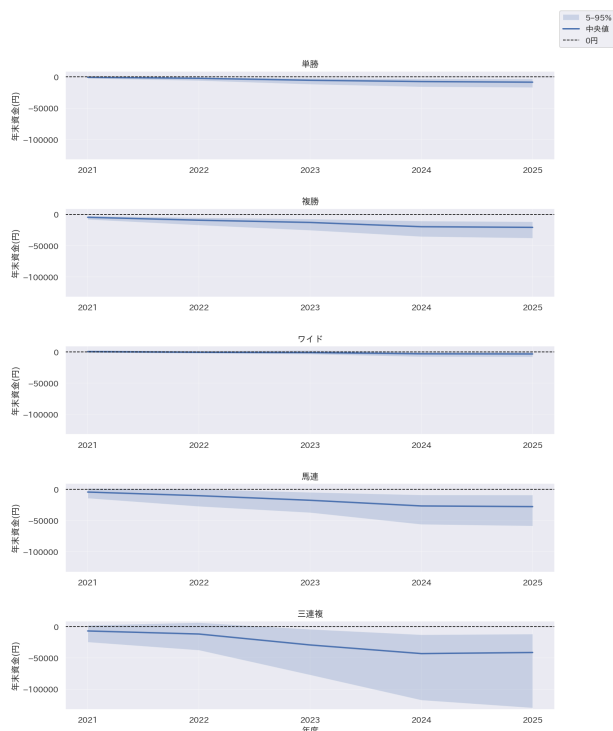


図 4 全券種まとめ：テスト期間（2021～2025）における年末資金推移（円）。seed を 100 通り変更した評価について中央値と 5-95% 区間を示す。

り、単勝・馬連・三連複では予測閾値ベースラインを下回っている。このことは、学習の不安定性や閾値最適化の難しさにより、学習が不十分な場合は単純な閾値処理よりも悪化し得ることを示唆する。

さらに、seed を変更した評価では、同一の設定でも回収率（Rec）やベット数が大きく変動することが確認された（図 2）。したがって、最良 seed の成績は参考値として位置づけるべきであり、現状の学習・意思決定は総じて不安定である。実運用を見据えるなら、この安定性の低さを解決すべき主要課題として扱う必要がある。

6.2 回収率とベット数のトレードオフ

提案手法では、メタモデルが出力する効率推定値の最大値が購入閾値を上回る場合にのみ購入する（3.5 節）。そのため閾値を上げるほど購入は厳選され、ベット数（購入レース数）は減少する。実験でも、市場ベースライン（全レースで 1 点購入）と比べてベット数を大きく抑えた（例：ワイドは 14,557→140）。一方で、ベット数を絞ると「損失を抑えやすい」反面、評価対象のレース数が減るため回収率のばらつきは大きくなり得る。したがって購入閾値は回収率のみで決めるのではなく、ベット数（購入頻度）、総投下資金、年次変動（図 3）などを合わせて、運用目的に応じて決定する必要がある。

6.3 限界と実運用上の論点

本評価は、テスト期間のレース結果と払い戻し・オッズ情報に基づくバックテストであり、実運用に存在する制約（例：オッズ取得タイミングのずれ、購入によるオッズ変動、購入上

表 8 ベースライン群との比較 (テスト期間 2021~2025, 単勝・複勝)

| 券種 | 手法 | 回収率 (%) | ベット数 |
|----|----------------------------|---------|--------|
| 単勝 | 提案 (平均) | 81.50 | 493 |
| | 提案 (中央値) | 81.51 | 452 |
| | 提案 (最良, 参考) | 107.89 | 407 |
| | 1 番人気の 1 点買い | 80.24 | 14,557 |
| | 予測閾値 (M01, $\tau = 0.20$) | 82.60 | 20,096 |
| | 市場シェア閾値 ($\tau = 0.12$) | 79.78 | 41,171 |
| 複勝 | 提案 (平均) | 90.76 | 2,393 |
| | 提案 (中央値) | 90.79 | 2,314 |
| | 提案 (最良, 参考) | 93.85 | 1,627 |
| | 1 番人気の 1 点買い | 83.62 | 14,557 |
| | 予測閾値 (M02, $\tau = 0.35$) | 83.18 | 46,993 |
| | 市場シェア閾値 ($\tau = 0.10$) | 82.11 | 49,719 |

表 9 ベースライン群との比較 (テスト期間 2021~2025, 馬連・ワイド・三連複)

| 券種 | 手法 | 回収率 (%) | ベット数 |
|-----|----------------------------|---------|---------|
| 馬連 | 提案 (平均) | 77.98 | 365 |
| | 提案 (中央値) | 78.80 | 347 |
| | 提案 (最良, 参考) | 90.19 | 533 |
| | 1 番人気の 1 点買い | 80.35 | 14,557 |
| | 固定 (1-2, 1 点) | 80.95 | 14,557 |
| | 固定 (axis_1_all) | 73.71 | 185,381 |
| | 予測閾値 (M01, $\tau = 0.18$) | 84.69 | 10,817 |
| | 市場シェア閾値 ($\tau = 0.10$) | 78.30 | 65,977 |
| ワイド | 提案 (平均) | 92.20 | 257 |
| | 提案 (中央値) | 91.37 | 240 |
| | 提案 (最良, 参考) | 107.53 | 140 |
| | 1 番人気の 1 点買い | 76.40 | 14,557 |
| | 固定 (1-2, 1 点) | 80.19 | 14,557 |
| | 固定 (axis_1_all) | 74.40 | 185,381 |
| | 予測閾値 (M01, $\tau = 0.18$) | 83.92 | 10,817 |
| | 市場シェア閾値 ($\tau = 0.10$) | 80.89 | 65,977 |
| 三連複 | 提案 (平均) | 86.93 | 580 |
| | 提案 (中央値) | 86.62 | 543 |
| | 提案 (最良, 参考) | 101.63 | 352 |
| | 1 番人気の 1 点買い | 77.60 | 14,557 |
| | 固定 (box_1-5) | 77.73 | 145,564 |
| | 固定 (axis_1-2_all) | 73.81 | 170,824 |
| | 予測閾値 (M01, $\tau = 0.15$) | 90.78 | 6,223 |
| | 市場シェア閾値 ($\tau = 0.08$) | 76.74 | 85,180 |

限, 締切時刻, 欠場情報の反映遅れ等) を明示的には扱っていない. これらは回収率に直接影響するため, 実運用を想定した評価設計 (どの時点のオッズで意思決定し, どの条件で購入できたと見なすか) の明確化が必要である. また, 本研究では購入単位を一定 (1 点 100 円) としているが, 予測と市場オッズの乖離に基づいて資金配分を最適化する代表的手法として Kelly 基準がある [13]. 一方で実運用ではリスク管理の観点から, Fractional Kelly 等の保守的な配分が推奨されることが多い [14]. 本枠組みにおいても, 券種間の同一レース内での資金配分 (ポートフォリオ化) や, ドローダウン等のリスク指標を目的関数に組み込む拡張が課題である. さらに, 多数のモデル候補や閾値候補, seed などから最終戦略を選択する場合, 選択によるバイアスが生じ得る. 順序統計量を用いた補正などが提案されており, 汎化性能評価の厳密化は今後の課題である [15].

加えて, 本研究で確認された seed 値を変更したことによる変化は, メタモデルの最適化や閾値決定が局所解・過学習の影響を受けやすいことを示唆する. 安定化に向けては, 複数回学習の平均化, 評価関数にリスク (分散・ドローダウン) を組み込む設計などが考えられる.

7 おわりに

本研究では, 競馬における馬券購入を「レース状態から購入パターンを選択する問題」として定式化し, sliding window 方式の学習で得た複数の予測モデル出力を入力とする券種別メタモデルを提案した. 予測モデルとして標準分類・重み付き分類・ランキング学習を併用することで多様な観点のスコアを得て, メタモデルがレースごとに適切な買い目パターン (あるいは不購入) を選択できるようにした. 提案手法は seed を 100 通り変更した評価において, ベット数を大きく抑えつつ, 最良 seed では単勝で 100%超 (107.89%), ワイドでも 100%超 (107.53%) の回収率を達成した. 一方で, 平均的には回収率 100%未満の券種も多く, 学習結果は seed によって大きく変動する. このため, 本研究の枠組みは良い結果が得られる場合があることを示した段階であり, 安定した改善を再現性高く得ることは未解決である.

今後の課題として, オッズ取得タイミングや購入上限など実運用上の制約の明示, リスク (ドローダウン) を考慮した目的関数の導入, ならびに券種間の相互作用を考慮した統合的意思

決定（同一レースでの複数券種配分）の検討が挙げられる。

文 献

- [1] Ruth Bolton and Randall Chapman. Searching for positive returns at the track. *Management Science*, Vol. 32, pp. 1040–60, 08 1986.
- [2] 田中奎帆, 出口雅也, 山田敬士. 国内競馬における機械学習及びオッズの歪みを用いた購入法, 2020. 長倉大輔研究会.
- [3] 中谷翼. 機械学習を用いた競馬予想, 2021. 卒業論文.
- [4] 中村心大, 宮崎嵐. 機械学習による競馬予想, 2023. 卒業論文.
- [5] Christopher Burges. From ranknet to lambdarank to lambdamart: An overview. *Learning*, Vol. 11, , 01 2010.
- [6] Junhyoung Chung, Donguk Shin, Seyong Hwang, and Gunwoong Park. Horse race rank prediction using learning-to-rank approaches. *Korean Journal of Applied Statistics*, Vol. 37, pp. 239–253, 04 2024.
- [7] 三枝守輝, 加藤誠, 浅野泰仁. 組合せ依存型ランキング学習 – 競馬への応用事例. 2018. DEIM Forum 2018 F5-2.
- [8] William Benter. *Computer Based Horse Race Handicapping and Wagering Systems: A Report*, pp. 183–198.
- [9] Meenakshi Gupta and Latika Singh. Predicting outcomes of horse racing using machine learning. *International Journal on Recent and Innovation Trends in Computing and Communication*, Vol. 11, pp. 38–47, 2023.
- [10] 杉山航太, 山下遙. 部分再帰型ニューラルネットワークを用いた最適な競馬の betting 戦略. 人工知能学会全国大会論文集, Vol. JSAI2023, pp. 2L6GS302–2L6GS302, 2023.
- [11] Jinook Jeong, Jee Young Kim, and Yoon Ro. On the efficiency of racetrack betting market: a new test for the favourite-longshot bias. *Applied Economics*, Vol. 51, pp. 1–12, 06 2019.
- [12] Chawin Terawong and Dave Cliff. Xgboost learning of dynamic wager placement for in-play betting on an agent-based model of a sports betting exchange, 2024.
- [13] J. L. Kelly. A new interpretation of information rate. *The Bell System Technical Journal*, Vol. 35, No. 4, pp. 917–926, 1956.
- [14] Uhrín Matej, Šourek Gustav, Hubáček Ondřej, and Železný Filip. Optimal sports betting strategies in practice: an experimental review. *IMA Journal of Management Mathematics*, Vol. 32, No. 4, p. 465–489, February 2021.
- [15] Yann McLatchie and Aki Vehtari. Efficient estimation and correction of selection-induced bias with order statistics. *Statistics and Computing*, Vol. 34, No. 4, June 2024.