

仮想的に再現した打撃成績に基づくプロ野球の勝率予測

西脇 友哉

芝浦工業大学 数理科学研究会

May 19, 2019

- ① 導入
- ② 準備
- ③ プログラムの実装
- ④ 結果と考察
- ⑤ 終わりに

- ① 導入
- ② 準備
- ③ プログラムの実装
- ④ 結果と考察
- ⑤ 終わりに

- プロ野球のデータ分析 (Part 4)
- 昨年 11 月の芝浦祭及び今年 3 月の第 8 回サイエンス・インカレで発表した OPS の研究¹に付随する内容
- データ分析にはデータの収集が付きものだが、プロ野球のデータは無限に使えるわけではない². その上収集には手間もかかる
- シミュレーション（仮想実験）を行えば大量のデータを獲得できるのではないかと考えた

¹西脇友哉, 『OPS の計算式における出塁率と長打率の最適な価値配分～一見手抜きだが便利な指標～』, 2018

²楽天球団が参入する以前などの古いデータは, さすがに使いづらい

- プログラムは **MATLAB** で記述する
- 方向性：「現在の環境が維持されると仮定してプロ野球のペナントレースを 6000 年繰り返した場合、どのような結果が得られるか？」³
- 公式戦全試合を再現したいのであれば野球ゲームの“ペナントモード”をオート進行すれば良い
- 発表者はプログラミングが大の苦手なので、なるべく簡素な設定でシミュレーションを行いたい
- チームの年間成績のみを再現し、1 つ 1 つの試合結果と個人成績は完全に無視する

³もちろん現実には観測できる訳は無いので、コンピューター上で擬似的に結果を得る.

- ① データの収集（※先行研究で実施済）
- ② モデリング（シミュレーションの計画を立てる）
- ③ 実装（プログラムを組む）
- ④ 分析, 考察

- ① 導入
- ② 準備
- ③ プログラムの実装
- ④ 結果と考察
- ⑤ 終わりに

- ① 基本情報（サンプル番号, 年度, リーグ）
- ② 得点数
 - 出塁率 (OBP) On-base percentage
 - 長打率 (SLG) Slugging percentage
 - OPS (On-base Plus Slugging)
- ③ 失点数
- ④ 勝率（ピタゴラス勝率）
- ⑤ 順位

用語 (実データ)

実際のプロ野球の試合結果に基づくデータ

用語 (仮想データ)

実データの数値を元にシミュレーションを行い, 擬似的に生成したデータ

野球の指標


出塁率 (OBP) = (安打 + 四球 + 死球) ÷ (打数 + 四球 + 死球 + 犠飛)

長打率 (SLG) = 塁打 ÷ 打数


OPS = 出塁率 + 長打率

出塁率と長打率の散布図 ('11~'18)

NPB の公式 HP より収集した実データ



OPS, 総得点の散布図と回帰直線 ('11~'18)



OPS(\hat{y}) と総得点数⁴(x) の単回帰式は

$$\hat{y} = -757.003 + 1890.903x$$

⁴各チームにおける 1 年間の得点数


ピタゴラス勝率とは

- ビル・ジェームズにより提唱
- 得点と失点から勝率を推定するために用いられる
- 名前の由来は式の形がピタゴラスの定理と似ている事
- '11~'18の8年間について、実際の勝率との相関係数は $r_{xy} = 0.920$
(母相関係数に対する95%信頼区間は [0.883, 0.946])

ピタゴラス勝率

$$\text{ピタゴラス勝率} = \frac{(\text{総得点})^2}{(\text{総得点})^2 + (\text{総失点})^2} = \frac{1}{1 + \rho^2} \quad \left(\rho = \frac{\text{総失点}}{\text{総得点}} \right)$$

ピタゴラス勝率と実際の年間勝率の散布図 ('11~'18)



厳密には競技の種類によって異なる指数を要するため、 ρ^2 を ρ^x で置き換えて最適化する

平均絶対偏差 MAD(mean absolute deviation)

$$\begin{cases} \omega_i & = \text{チーム } i \text{ のシーズン中の勝率} \\ \rho_i & = \frac{\text{チーム } i \text{ の失点数}}{\text{チーム } i \text{ の得点数}} \end{cases} \quad (1)$$

とする。リーグに m チームいるとき、 x の与えられた値に対する平均絶対偏差は

$$\text{MAD}(x) = \frac{1}{m} \sum_{i=1}^m \left| \omega_i - \frac{1}{1 + \rho_i^x} \right| \quad (2)$$

となる。

① 一般化したピタゴラス勝率

$$\frac{1}{1 + \rho^x} \quad \left(\rho = \frac{\text{失点数}}{\text{得点数}} \right)$$

② 平均絶対偏差 (MAD)

$$\text{MAD}(x) = \frac{1}{m} \sum_{i=1}^m \left| \omega_i - \frac{1}{1 + \rho_i^x} \right|$$

- 指数 x の最適な値 x^* を求めたい
- 方法: x の十分多くの異なる値 (1 から 4 まで 0.002 刻みの x) に対して $\text{MAD}(x)$ を計算し、 $\text{MAD}(x)$ を最小にする x を特定する

ピタゴラス勝率の最適化 (3/3)

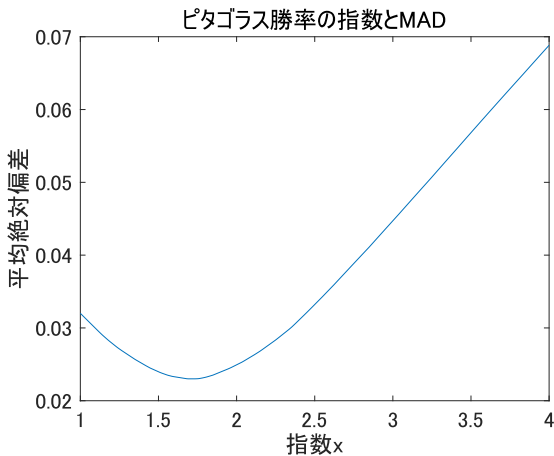


Figure : x に対する $MAD(x)$ の関係

計算結果 : $x^* = 1.69$, $MAD(x^*) = 0.0230$

勝率に影響する要素 (イメージ)

