

# 個人の傾向を考慮したプロ野球投球データからの 反実仮想説明集合の抽出

武藤 暖<sup>1,a)</sup> 尾崎 知伸<sup>1,b)</sup>

**概要:** 本論文では、プロ野球投球データを対象に、個人にとって受け入れやすくまた実現が容易な反実仮想説明の生成を目指す。具体的には、打席ごとの結果を予測する LSTM モデルを構築し、そこから既存手法を用いて大量の反実仮想説明を生成する。次いで、新たに提案する典型性、実現容易性、適合性、正確性に関する基準を用いて反実仮想説明を順位付けし、少数の説明を選択する手法を提案する。実データを用いた評価の結果、特定のケースにおいて利用者にとって受け入れやすい反実仮想説明の生成が確認され、提案手法が一定の有用性を持つことが確認された。

**キーワード:** 説明可能 AI, 反実仮想説明, LSTM, 野球

## Extraction of Counterfactual Explanation Sets from Professional Baseball Pitching Data considering Individual Tendency

ATARU MUTO<sup>1,a)</sup> TOMONOBU OZAKI<sup>1,b)</sup>

**Abstract:** In this paper, from professional baseball pitching data, we propose a method for extracting counterfactual explanations that are acceptable to individuals and easy to realize. Specifically, we construct a LSTM model that predicts the outcome of each at-bat, and generate a large number of counterfactual explanations for each prediction using existing methods. Then, from the generated explanations, we select small number of top ranked ones based on newly proposed criteria for typicality, feasibility, suitability and accuracy. The usefulness of the proposed method was confirmed in the experiments using real datasets, in which, the method succeeded in generating counterfactual explanations that are easily acceptable to users in some certain cases.

**Keywords:** Explainable AI, Counterfactual Explanations, LSTM, Baseball

### 1. はじめに

チームスポーツの中でも日本で特に人気の高い野球では、試合に出場する選手一人一人に大切な役割があり、中でも投手は試合の結果を左右する非常に大切な役割を担っている。これまでに、投球タイプの予測や、勝敗の予測、選手のパフォーマンスの予測など、様々な観点から過去のデータを利用した戦術分析が提案されている [1, 2]。また、

投手や打者に着目する研究が多い中で、配球を決定する役割にある捕手に着目した分析も提案されている [3, 4]。現在では、プロ野球中継の一球速報など、リアルタイムでのデータ分析も行われており、これらを背景に、大量のデータがあるからこそ野球に関する様々な予測や分析などの研究が盛んに行われている。

一方、深層学習のような機械学習手法の発展により、機械学習モデルが実社会での意思決定の場面に応用され始めている。このことから、機械学習モデルの予測根拠や判断基準を人間が理解可能な形で提示することができる説明可能 AI 技術 [5-8] の重要性が高まっている。その中でも反実

<sup>1</sup> 日本大学文理学部情報科学科  
〒156-8550 東京都世田谷区桜上水 3-25-40

a) chat19078@g.nihon-u.ac.jp

b) ozaki.tomonobu@nihon-u.ac.jp

仮想説明法 [9, 10] は、機械学習モデルによる予測結果に対して、結果状態を覆すために必要な説明変数の変化量を算出し、例として提示する説明手法であり、具体的な目標や行動をイメージすることができるため注目を集めている。

本研究では、野球における投手の「配球」に注目する。投手目線の戦術として、球速や球種タイプ、投球コースなどが代表的であるが、それらに間合い（投球間隔）を加え、ピッチの場面の配球に着目した研究を展開する。具体的には、反実仮想説明の生成に DiCE (Diverse Counterfactual Explanations) [10] を用い、プロ野球投球データを対象とした受け入れやすく実現が容易な反実仮想説明の選択、抽出方法を提案する。すなわち、まず打席ごとの結果を予測する LSTM (Long Short Term Memory) モデルを構築し、DiCE に従い対象事例に対する大量の反実仮想説明を生成する。次いで、新たに提案する典型性、実現容易性、適合性、正確性の 4 因子を用いて各反実仮想説明を数値化した後、主成分分析に基づき総合力が高い少数説明を抽出する。

本論文の構成は以下の通りである。2 章で先行研究について言及する。3 章で基礎技術として利用する DiCE の概要について説明したのち、4 章で反実仮想説明集合の抽出手法を提案する。5 章で日本プロ野球に関する実データを用いた評価実験を行い、最後に 6 章でまとめと今後の課題を述べる。

## 2. 関連研究

### 2.1 LSTM を用いた野球に関する研究

これまでに、野球の投球予測や成績予測に関する機械学習モデルの構築に関していくつかの提案が行われている。例えば、投手の球種に着目し、状況に応じて次の投球で投げる可能性のある球種を予測する [1] や、打者のホームラン数を重要な指標の一つと捉え、メジャーリーグにおけるホームラン予測を行う [11]、以前のシーズンでの成績に基づいて、特定のシーズンでの打撃や投球の統計などの選手の結果を予測するモデル [12] などが提案されている。また、打者成績からインニングの要約文を生成する研究 [13] も行われている。

本研究では、これらの既存研究と同様に、1 球目、2 球目と続いていく投球の流れを系列的に捉えることができる LSTM を採用し、打撃結果に影響を与える特徴量を入力とした予測モデルの構築を行う。

### 2.2 反実仮想説明に関する研究

反実仮想説明に着目した研究もいくつか報告されている。文献 [14] では、予測に基づいて意思決定した場合の結果の良さと、一様ランダムな行動選択方策の下での予測精度との関連を理論的に明らかにしている。具体的には、予測精度と同時に比較的良好な行動であるかどうかという判断誤差の最小化も考慮した損失関数を提案している。また文

献 [15–17] では、観測データから適切な反実仮想推論を行うために、深層学習技術の介入効果推定問題への適用が提案されている。さらに文献 [10] では、既存のモデルから反実仮想サンプルを生成し、直接的な改善案を提示することができる手法 DiCE (Diverse Counterfactual Explanations) が提案されている。

本研究では、DiCE により生成される反実仮想説明集合を、野球の観点から順序付ける手法を提案する。

## 3. 反実仮想説明生成手法 DiCE

DiCE [10] は、入力として訓練済み機械学習モデル  $f$  および  $d$  次元ベクトルとして与えられる説明対象事例  $x$  とそのクラス値  $y$ 、(反実仮想説明に) 期待するクラス値  $y_d (\neq y)$  を受け取り、超パラメタ  $\lambda_1, \lambda_2$  のもとで下式  $C(x)$  を満たす、すなわち評価値を最小化する  $k$  個の反実仮想説明 ( $d$  次元ベクトル) からなる集合  $\{c_1, \dots, c_k\}$  を出力する。

$$C(x) = \operatorname{argmin}_{c_1, \dots, c_k} \frac{1}{k} \sum_{i=1}^k \text{yloss}(f(c_i), y_d) + \frac{\lambda_1}{k} \sum_{i=1}^k \text{dist}(c_i, x) - \frac{\lambda_2}{k} \text{dpp\_diversity}(c_1, \dots, c_k)$$

ここで  $\text{yloss}$  は損失関数であり、モデル  $f$  による  $c_i$  の予測クラス値  $f(c_i)$  と利用者が期待する値  $y_d$  との誤差を算出する。これにより、利用者の期待に沿う結果をもたらす可能性が高い反実仮想説明群に対して良い値が与えられることになる。また具体的な損失関数としては、 $y \in \{-1, 1\}$  とする 2 クラス分類の場合はヒンジ損失  $\text{loss}(f(c), y) = \max(0, 1 - y \times \text{logit}(f(c)))$  などが利用される。

関数  $\text{dist}$  は、反実仮想説明  $c$  と説明対象事例  $x$  の間の距離を返す関数であり、これにより  $x$  と類似する説明に対して良い値が与えられることになる。具体的な距離関数は属性毎の  $l_1$  距離を基本とし、連続値変数に関しては中央絶対偏差 (Median Absolute Deviation, MAD) による正規化を伴う

$$\text{dist\_cont}(c, x) = \frac{1}{d_{\text{cont}}} \sum_{p=1}^{d_{\text{cont}}} \frac{|c^p - x^p|}{MAD_p}$$

を、カテゴリ変数に関しては指示関数  $I$  を用いた

$$\text{dist\_cat}(c, x) = \frac{1}{d_{\text{cat}}} \sum_{p=1}^{d_{\text{cat}}} I(c^p \neq x^p)$$

をそれぞれ採用している。ここで  $MAD_p$  は第  $p$  属性の中央絶対偏差、 $c^p, x^p$  は  $c, x$  の第  $p$  属性の値であり、また  $d_{\text{cont}}, d_{\text{cat}}$  は連続性変数、カテゴリ変数の数である。

関数  $\text{dpp\_diversity}$  は、行列式点過程 (determinantal point

processes)に基づく反実仮想説明間の多様性を返す関数であり、より多様な説明集合に対して高い値を与えるものである。実際には、距離関数  $dist$  を用い

$$ddp\_diversity = det(K) \text{ where } K_{i,j} = \frac{1}{1 + dist(c_i, c_j)}$$

と定義される。

以上を纏めると、DiCE では与えられた事例に対して精度 (yloss) と類似度 ( $dist$ ), 多様性 (ddp\_diversity) の観点から最適な反実仮想説明の集合を生成する。

## 4. 投球データを対象とした反実仮想説明集合の集約

### 4.1 提案手法の概要と形式化

前章で概観した通り、DiCE は精度 (反実仮想説明と期待する結果との関係) と類似度 (反実仮想説明と事例の関係), 多様性 (反実仮想説明間の関係) を用いて反実仮想説明集合を評価している。しかし野球投球データへの適用を考えた場合、これらの一般的な指標だけでは必ずしも十分ではなく、投球としての適合性 (反実仮想説明と事例集合全体との関係) や実現容易性 (反実仮想説明と当該投手との関係) を考慮・反映することが必要であると考えられる。すなわち、例えば球速 150km を超える変化球は限られた投手しか投げることができず、また速球が持ち味の投手に多様な変化球を求めるのは受け入れ難いなど、野球の観点から反実仮想説明を評価し直すことが重要となると考えられる。これらの考えに基づき、本研究では、典型性、実現容易性、適合性、正確性の 4 つの観点を用いて、DiCE を用いて生成される反実仮想説明集合を評価・集約することを提案する。以下、提案手法の概要を形式的に示す。

本研究では野球における (打席内での投手の交代のない) 各打席を一つの事例とする。打席  $x$  で投球を行った投手を  $x_{pitcher}$ , 事例集合  $X$  において投手  $p$  が投球を行った打席の集合を  $X_p = \{x \in X \mid x_{pitcher} = p\}$  とそれぞれ表記する。また、 $f$  を打席の結果を予測する学習済みモデル、 $x$  を説明対象事例、 $C(x) = \{c_1, \dots, c_k\}$  を DiCE により得られる  $x$  に対する反実仮想説明集合とする。加えて、事例集合  $X$  と投手  $x_p$ , 学習済みモデル  $f$ , 反実仮想説明集合  $c(x)$  を基に得られる反実仮想説明  $c \in C(x)$  に対する典型性、実現容易性、適合性、正確性に関する総合的な評価値を  $v(c \mid c(x), x_p, X, f)$  とし、その  $c(x)$  内での降順順位を

$$rank(c) = \left| \left\{ c' \in c(x) \mid \begin{array}{l} v(c' \mid c(x), x_p, X, f) > \\ v(c \mid c(x), x_p, X, f) \end{array} \right\} \right| + 1$$

と表記する。以上の準備の下、本研究ではパラメタ  $\theta (\leq k)$  を与え、 $c(x)$  から評価値上位  $\theta$  位以内の集合

$$e(x) = \{c \in c(x) \mid rank(c) \leq \theta\}$$

を最終的な説明集合として獲得する。

なお本研究では、各反実仮想説明  $c \in c(x)$  を (次節で説明する) 4 評価値

- (1)  $v_1(c \mid c(x))$ : 典型性に関する評価値
- (2)  $v_2(c \mid x_p)$ : 実現容易性に関する評価値
- (3)  $v_3(c \mid X)$ : 適合性に関する評価値
- (4)  $v_4(c \mid f)$ : 正確性に関する評価値

を基に 4 次元データへと変換した上で主成分分析を適用し、結果として得られる第一主成分得点を  $c$  の総合評価値  $v(c \mid c(x), x_p, X, f)$  とする。

### 4.2 反実仮想説明の評価

典型性に関する評価値  $v_1(c \mid c(x))$  は、DiCE によって生成された反実仮想説明集合  $c(x)$  において、当該の説明  $c$  がどれだけ典型的かを評価するものである。本研究では典型性を、説明対象事例  $x$  と反実仮想説明  $c$  の差  $d(x, c) = \{(x^p, c^p) \mid x^p \neq c^p\}$  の  $c(x)$  における出現確率

$$v_1(c \mid c(x)) = |\{c' \in c(x) \mid d(x, c) \subseteq d(x, c')\}| / |c(x)|$$

と定義する。

実現容易性に関する評価値  $v_2(c \mid x_p)$  は、投球内容の変更  $d(x, c)$  が投手  $x_p$  にとってどの程度実現可能で、また受け入れやすいのかを定量化するものである。当然のことではあるが、野球における投手はそれぞれの個性や持ち味を持ち、得意なコースや球種、球速は選手ごとに異なる。そのような状況において、例えば、球威が低い投手に対して、球速を大幅にあげるような反実仮想説明を提示することは現実的ではない。また球種においても同様であり、曲がる変化球が得意な投手に対し、落ちる変化球を提示することは必ずしも望ましくない。逆に言えば、当該投手が得意な球種や球速への変更を要求することは、実現が容易であり受け入れやすいと考えられる。

このことから本研究では、当該投球内容の得意度が出現確率で定義できること、および反実仮想説明が、当該投手において苦手な (すなわち確率の小さな) 投球内容から得意な (すなわち確率の大きな) 投球内容への変化を含むときに実現容易性が高いと仮定し、反実仮想説明  $c$  の実現容易性  $v_2(c \mid x_p)$  を、投手  $x_p$  に関するデータ  $X_{x_p}$  において (変化前の)  $d_x(x, c)$  が出現する確率を分母、(変化後の)  $d_c(x, c)$  が出現する確率を分子とする下式で定義する。

$$v_2(c \mid x_p) = \frac{|d_c(x, c)| / |X_{x_p}|}{|d_x(x, c)| / |X_{x_p}|} \text{ where}$$

$$d_x(x, c) = \{x' \in X_{x_p} \mid \{c^p \mid (x^p, c^p) \in d(x, c)\} \subseteq x'\}$$

$$d_c(x, c) = \{x' \in X_{x_p} \mid \{x^p \mid (x^p, c^p) \in d(x, c)\} \subseteq x'\}$$

なおこの評価値は、一人の投手が複数の打席を担当するという野球投球データ固有の特徴を利用したものであり、その点で反実仮想説明集合の生成に、新たな視点を与えるものであると考えている。

第三の評価値  $v_3(c | X)$  は、反実仮想説明  $c$  の事例集合  $X$  に対する適合性を評価するものである。先述した通り、例えば高速な変化球は限られた投手しか投げることができず、そのような変更を提案されても一般には受け入れられない。逆に言えば、広く一般に見られる投球内容を提案された場合は受け入れやすいと考えられる。このことから本研究では、反実仮想説明  $c$  の事例集合  $X$  に対する適合度を、 $X$  における  $c$  の外れ値度合い（の逆数）と定義する。具体的には局所外れ値因子（Local Outlier Factor）法 [18] を用い、LOF 値が低い反実仮想説明に対して高得点を与えるものとする。

最後の評価値  $v_4(c | f)$  は、DiCE においても考慮されている正確性を評価するものである。本研究では、学習済みモデル  $f$  より算出される反実仮想説明  $c$  が期待されるクラス値  $y_d$  を取る確率（実際にはソフトマックス値）を  $v_4(c | f)$  の値とする。

## 5. 評価実験

### 5.1 実験設定

本研究では、データスタジアム株式会社<sup>\*1</sup>が提供する日本プロ野球のあるチームの 2021 年シーズンデータを対象に、各投球を下記の入出力でモデル化した上でパディング等を用いて各打席の長さを 7 と統一し、many-to-many の形式をした LSTM モデル（精度 0.87）を構築した。

**入力：** 投球速度、球種タイプ（直球・曲がる・落ちる）、投球コース（{外角, 真ん中, 内角}×{低め, 真ん中, 高め}), 投球間隔, ストライク数, ボール数, アウト数, ランナー状況, イニング, 得点差, 投手情報, 打者情報, スタジアム情報

**出力：** 打席結果（打たれた, 打ち取った, 継続）

入力における“投手情報”とは、投手毎の平均投球速度と球種タイプ・投球コース（横）・投球コース（縦）の各出現確率からなる 10 次元ベクトルであり、また“打者情報”とは、打者毎の（投球時点での）出塁率をホームラン数で正規化したものである。一方、“スタジアム情報”は球場の大小を表す二値変数である。なお入力における欠損については、球種タイプ・投球コースはそれぞれ最頻値である直球・外角低めで補完をし、また球速に関しては 128 ~ 148km（平均 ± 標準偏差）の範囲でランダムに補完を行っている。

出力は、一球毎の投手目線での結果として“打たれた”, “打ち取った”, “継続”の 3 値を準備した。なお実際には、投手立場での良し悪しを基準としており、エラーは“打ち取った”, 四球・死球・犠打は“打たれた”に分類している。また“打たれた”, “打ち取った”以外は“継続”となり、全体の 75%を占めている。

実験では、得点圏にランナーがいる状況での投手 T.S. の

表 1 説明対象事例

	O.C.*	得点差	イニング	ランナー状況	投手	打者
事例 1	2	+1	3	3 塁	T. S.	中距離
事例 2	2	0	2	2 塁	T. S.	長距離
事例 3	1	-1	8	2・3 塁	T. S.	長距離

\*O.C.: アウトカウント

表 2 事例 1 の配球

	S.C**.	B.C**.	球速	球種	コース	間隔
1	0	0	149km	直球	外角真ん中	14 秒
2	1	0	125km	曲がる	内角真ん中	27 秒
3	2	0	147km	直球	外角低め	33 秒
4	2	1	149km	直球	外角低め	31 秒
5	2	2	134km	曲がる	外角真ん中	31 秒
6	2	3	149km	直球	内角真ん中	39 秒

\*S.C.: ストライクカウント, \*\*B.C.: ボールカウント

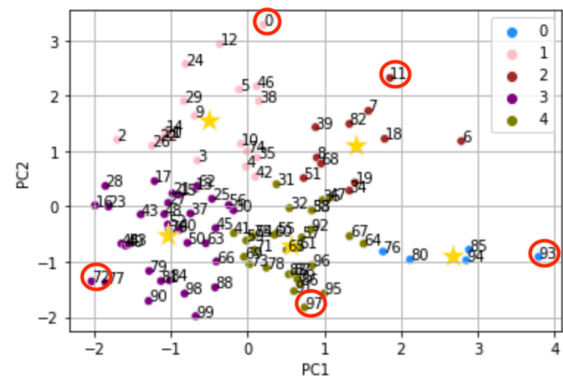


図 1 事例 1 に対する反実仮想説明の主成分分析結果

6 球目被打 3 事例（表 1 参照）を対象とし、DiCE によるサイズ  $k = 100$  の反実仮想説明集合を生成し、提案手法による  $\theta = 5$  の説明の抽出を行った。また参考として表 2 に事例 1 の配球を示す。

### 5.2 反実仮想説明集合に対する主成分分析

提案する反実仮想説明に対する評価値  $v_1 \sim v_4$  の妥当性を評価するために、各事例に対して得られた DiCE による  $k = 100$  の反実仮想説明群に対して主成分分析を適用した。その結果、各事例において第 1 主成分で固有ベクトルが正値をとり、総合力を表していると考えられる。また第 2 主成分では、典型性と正確性が正値、適合性と実現容易性が負値となり、正方向は正確性・典型性、負方向は実現性容易性を表していると考えられる。なお各事例において、第 2 主成分における累積寄与率が 0.7 を上回る結果となった。

次に、具体的な反実仮想説明の妥当性を確認するため、事例 1 に対する主成分分析結果（図 1 参照）から特徴的な説明を抽出し、その内容を考察した。その結果、図中の右下に位置する説明 93 は、総合力が高く、曲がる系を得意としているこの投手にとって実現性が高い変化であった。また右上に位置する説明 11 は、総合力が高く、投げやすい球

\*1 <https://www.datastadium.co.jp/>

速の直球系ということもあり、データ全体を通して起こりやすい変化であった。下中央に位置する説明 97 は、総合力は普通で、曲がる系を得意としているこの投手にとって実現性が高い変化であった。上中央に位置する説明 0 は、総合力は普通で、データ全体を見ると起こりやすい変化であったが、大きな投球間隔を有しており、一定の間隔で投げることが多いこの投手にとってあまり得意でない変化が起きていることも分かった。最後に左下に位置する説明 72 は、総合力は低い、落ちる系が決め球のこの投手にとって実現性の高い変化であった。これらの結果から、投球に対する反実仮想説明の抽出において、提案する評価基準が概ね有効に働いていることが推察される。

### 5.3 定量評価：因子の基本統計量

提案手法を定量的に評価するため、ベースライン手法を「DiCE によるサイズ  $k = \theta = 5$  の反実仮想説明集合の抽出」とし比較実験を行った。

最初の実験では、DiCE によるサイズ  $k = 100$  の反実仮想説明集合  $c(x)$  を生成した後、ベースライン手法による  $\theta = 5$  件の反実仮想説明の第一主成分得点が、 $c(x)$  に対してどのような順位になるかを算出した。なお提案手法では、第一主成分得点第 1~ $\theta = 5$  位の説明が抽出されることになる。実験結果を表 3 に示す。結果より、事例 3 における説明 1 の 7 位が最も高順位であり、他の説明は平均しておよそ中位となっていることが確認できる。

次に、ベースライン手法および提案手法で得られる  $\theta = 5$  件の反実仮想説明に対し、各評価値  $v_1 \sim v_4$  の平均値を比較する。比較結果を表 4 に示す。なお参考として表中には、提案手法の抽出元となる  $k = 100$  個の反実仮想説明集合に対する評価値平均も示している。

結果より、正確性 ( $v_4$ ) においては、すべての事例でベースライン手法が上回る結果となった。また適合性 ( $v_3$ ) に

表 3 ベースライン手法による反実仮想説明の第一主成分得点の順位

	説明 1	説明 2	説明 3	説明 4	説明 5
事例 1	24 位	35 位	40 位	51 位	77 位
事例 2	18 位	34 位	52 位	64 位	91 位
事例 3	7 位	41 位	53 位	69 位	88 位

表 4 得られた反実仮想説明集合の各評価値の平均

事例	手法	典型性	実現容易性	適合性	正確性
事例 1	$k = 100$	0.14	0.69	-1.05	0.66
	ベースライン	0.17	0.62	-1.08	0.81
	提案手法	0.46	1.23	-1.00	0.77
事例 2	$k = 100$	0.10	1.30	-1.11	0.67
	ベースライン	0.16	1.06	-1.10	0.87
	提案手法	0.28	1.87	-1.06	0.81
事例 3	$k = 100$	0.11	1.14	-1.10	0.66
	ベースライン	0.14	0.77	-1.07	0.80
	提案手法	0.37	1.63	-1.21	0.76

おいては、事例 1 と事例 2 で提案手法が上回っているが、事例 3 では大きく下回っているため、互角であると言える。一方、典型性 ( $v_1$ ) と実現容易性 ( $v_2$ ) に関しては、すべての事例において提案手法が良い成績を示していることが確認できる。

以上 2 つの定量評価実験により、提案手法では、単純な DiCE の適用では得ることの難しい質の高い反実仮想説明の抽出が達成できていることが確認できる。

### 5.4 定性評価：有識者へのアンケート

提案手法を定性的に評価するため、有識者へのアンケートを行った。アンケート回答者は現役で野球を続けている大学生 4 人（投手 3 名、捕手 1 名）である。アンケートでは、各事例と共にベースライン手法 (A) と提案手法 (B) で生成した各  $\theta = 5$  件の反実仮想説明を示し、以下の 3 項目に対して文章で回答を行ってもらった。

- (1) 変化例 A, B の 5 つずつを見てそれぞれ気付いたことや感じたことを記入してください。
- (2) 投手 T.S. になったつもりで自分ならどうするか過去の経験も交えて教えてください。
- (3) それらを踏まえた上で総合的に受け入れやすい方を選択してください。

なおこれらの項目は、質問 1 で配球の流れを理解すること、質問 2 で有識者だから分かる説得力のある例を問うこと、質問 3 でベースラインと提案法の総合的な比較を行うことをそれぞれ狙いとしている。事例 1 (表 2) に対して生成された反実仮想説明を表 5 に、また質問 3 に対するアンケート結果を表 6 にそれぞれ示す。

事例 1 に対しては、質問 3 においてすべての回答者が提案手法を選択した。またその理由として、「自身も一定のリズムで投げたいという思いがあり、投手 T.S. にはキレのあるスライダーのイメージが強いから一定のリズムで曲がる系を投げる」という意見や、捕手目線では「2 アウトランナー 3 塁であることから最悪歩かせるという選択肢も頭に入れた上で変化球を粹いばいに要求する」という意見が寄せられた。ベースライン手法では、直前の 5 球目に対する緩急を用いたような直球系が多く見受けられる。これに対し提案手法では、有識者の意見のように変化球が多く、投手の得意な球を提案していると考えられる。

事例 2 に対しては、意見が割れる結果となった。ベースライン手法を選んだ理由として「ランナーが 2 塁で長打を打たれなければ失点にならない可能性もある」として、間合い（投球間隔）をとって落ち着いてから投げる」という意見や、また提案手法を選んだ理由として「A にある 159km の豪速球を投手 T.S. が投げているイメージがない」という意見があった。ここから提案手法では、事例によって変化する投手ごとの実現容易性が良い方向に作用していることが伺える。

表 5 事例 1 に対する反実仮想説明

	ベースライン手法				提案手法			
	球速	球種	コース	間隔	球速	球種	コース	間隔
説明 1	147km	直球	内角高め	41 秒	123km	曲がる系	外角低め	29 秒
説明 2	149km	直球	内角低め	43 秒	109km	曲がる系	内角低め	33 秒
説明 3	145km	曲がる	外角低め	39 秒	131km	曲がる系	外角低め	39 秒
説明 4	149km	直球	外角高め	24 秒	156km	直球系	外角高め	48 秒
説明 5	155km	直球	内角真ん中	39 秒	140km	落ちる系	真ん中低め	16 秒
事例 1	149km	直球	内角真ん中	39 秒	149km	直球	内角真ん中	39 秒

表 6 アンケート項目 3 の結果

	投手 R	投手 O	投手 S	捕手 M
事例 1	B	B	B	B
事例 2	B	B	A	A
事例 3	A	B	B	B

事例 3 に対しては、一人の投手を除き提案手法が支持された。この事例は 1 アウトランナー 2・3 塁と他の事例と比べてもかなり厳しい状況であり、決め球である落ちる球を真ん中低めに投げるも打たれてしまったという事例である。提案手法を選んだ理由として「このような場面で下手に間合いを空けると自滅するパターンも多いので、5 球目までとあまりリズムを変えずに、5 球目までには見せていない曲がる球を低めに投げる」という意見があげられた。一方ベースライン手法を選択した理由は、心理的に打者が曲がる球を待っていると推測して落ちる球を投げるという判断は間違っていないとし、「曲がる球がすっぽ抜けてしまうのはとても怖いので、一呼吸おいてから決め球である落ちる球をとにかく浮かないように低めに投げる」というものであった。事例 3 では、投球間隔についての言及で一定のリズムで投げるべきという意見と一呼吸空けるべきという意見に分かれた。投手 T.S. は、全投手の平均に比べて投球間隔が短く、実際に今回使用した事例 3 では、最終球で投球間隔を長めにとっていることから、6 球目でもあまりリズムを変えずに投げるべきであると考え。ベースライン手法と比較すると提案手法で抽出された反実仮想例は投球間隔が短めであり、このことから投手の特徴を捉えた配球を提案することができていると考えられる。

## 6. まとめと今後の課題

本研究では、状況や投手によってより受け入れやすい反実仮想説明の抽出手法を提案することを目的に、ランナー得点圏で打たれてしまった打席の反実仮想説明集合の抽出を試みた。有識者へのアンケートによる定性評価と、提案した各評価値の基本統計量に対する定量評価を行った結果、提案評価値を考慮した反実仮想説明の方が、状況や投手個人の傾向を考慮した上で受け入れやすいとされ、提案手法の有用性が確認された。

今後の課題として、より多様な事例を用いた提案手法の

評価があげられる。また、事例を超えて反実仮想説明を集約するとともに、条件付きの一般化を通じたルールが発見を行うことで、より受け入れやすくとまた説得力があり納得性の高い反実仮想説明の生成を行う技術を開発することを検討している。

**謝辞** 本研究では、データスタジアム株式会社から提供を受けたデータセットを利用した。またアンケート調査にご協力を頂いた有識者の皆様に感謝いたします。なお、本研究の一部は、JSPS 科研費 JP22K12173 の助成を受けたものである。

## 参考文献

- [1] C.-C. Yu, C.-C. Chang, and H.-Y. Cheng : Decide the Next Pitch: A Pitch Prediction Model Using Attention-Based LSTM, *Proc. of the 2022 IEEE International Conference on Multimedia and Expo Workshops*, pp.1-4, 2022.
- [2] 仁志 敏久, 鳥越 規央 : 日本プロ野球におけるデータ活用の現状, 日本計算機統計学会シンポジウム論文集, Vol.26, pp.33-34, 2012.
- [3] 稲福 和史, 伏見 卓恭, 佐藤 哲司 : 最終球への配球推移に基づくキャッチャー成績分析, 第 11 回データ工学と情報マネジメントに関するフォーラム, 2019.
- [4] 桑原 崇, 岸 義樹 : 野球における捕手の配球予測に関する方法, 情報処理学会第 71 回全国大会講演論文集, 3R-8, pp.213-214, 2009
- [5] 原 聡 : 私のブックマーク「説明可能 AI」, 人工知能 34(4):577-582, 2019.
- [6] 大坪 直樹 他 : 『XAI(説明可能な AI)-そのとき人工知能はどう考えたのか?』, リックテレコム, 2021.
- [7] 森下 光之助 : 『機械学習を解釈する技術~予測力と説明力を両立する実践テクニック』, 技術評論社, 2021.
- [8] C. Molnar : *Interpretable Machine Learning*, Lulu.com, 2019.
- [9] I. Stepin, J. M. Logo, A. Catala, and M. Pereira-Farina : A Survey of Contrastive and Counterfactual Explanation Generation Methods for Explainable Artificial Intelligence, *IEEE Access*, 9:11974-12001, 2021.
- [10] R. K. Mothilal, A. Sharma, and C. Tan : Explaining Machine Learning Classifiers through Diverse Counterfactual Explanations, *Proc. of the 2020 Conference on Fairness, Accountability, and Transparency*, pp.607-617, 2020.
- [11] H.-C. Sun, T.-Y. Lin, and Y.-L. Tsai : Performance Prediction in Major League Baseball by Long Short-Term Memory Networks, *International Journal of Data Science and Analytics*, 15:93-104, 2023.

- [12] D. Calzada : Deepball: Modeling expectation and uncertainty with recurrent neural networks. *SABR Analytics Conference*, 2019.
- [13] 田川 裕輝, 嶋田 和孝 : スポーツ要約生成におけるテンプレート型手法とニューラル型手法の提案と比較, 自然言語処理, 25(4):357-391, 2018.
- [14] 谷本 啓, 坂井 智哉, 竹之内 高志, 鹿島 久嗣 : 多数の介入候補の下での意思決定のための因果効果評価, 2021 年度人工知能学会全国大会, 3G2-GS-2h-03, 2021.
- [15] F. D. Johansson, U. Shalit, and D. Sontag : Learning Representations for Counterfactual Inference, *Proc. of the 33rd International Conference on Machine Learning*, pp.3020-3029, 2016.
- [16] 竹内 孝, 西田 遼, 鹿島 久嗣, 大西 正輝 : 因果推論を用いた群衆移動の誘導における介入効果推定, 2021 年度人工知能学会全国大会, 2I3-GS-5b-03, 2021.
- [17] U. Shalit, F. D. Johansson, and D. Sontag : Estimating individual treatment effect: generalization bounds and algorithms, *Proc. of the 34th International Conference on Machine Learning*, pp.3076-3085, 2017.
- [18] M. M. Breunig, H.-P. Kriegel, R. T. Ng, and J. Sander : LOF: Identifying Density-Based Local Outliers, *Proc. of the 2000 International Conference on Management of Data*, pp.93-104, 2000.