

スポーツ外傷予測への信頼性解析の応用： 大相撲力士に対する実証分析

太田 修平¹・木村 光宏²

(受付 2024 年 11 月 30 日；改訂 2025 年 3 月 24 日；採択 3 月 25 日)

要 旨

スポーツ外傷予測とは、対象者に将来起こりうるスポーツ外傷の潜在的なリスクを評価することである。近年では、スポーツ選手が過去に負った外傷のイベントヒストリーデータに基づいて、時系列的に選手の外傷リスクを評価・予測する手法がいくつか提案されている。本稿では、点過程を用いた外傷発生を表す確率モデルを詳説し、そのモデルを用いた外傷予測の方法について述べる。また、大相撲力士に対する外傷予測の実証分析を通して、外傷の連鎖性を考慮できる自己励起型の点過程が、外傷予測に有効であることを示す。さらに本稿は、力士の外傷予測に関する先行研究では明らかにされなかった、予測モデルのパラメータ推定に使用されていない未知のデータに対する、モデルの予測精度の検証を新たに行い、モデルの妥当性を補強する。最後に、予測結果を外傷予防に応用する観点から、外傷予測の今後の課題を述べる。

キーワード：点過程，確率予測，スポーツ外傷，信頼性解析。

1. はじめに

スポーツ選手にとって、スポーツ外傷予防は、自身のパフォーマンスを維持し、キャリアを長く保つために重要である。ここで、スポーツ外傷は、外から加わる 1 回の大きな力(衝撃)によって起こる怪我を指し、例えば捻挫、脱臼、骨折などを含む。一方で、外傷予防には、選手の日常的な心身のケアが必要であり、そのためには時間的・経済的なコストがかかる。そしてそのコストの削減のために、選手に対する効率的な外傷予防の介入が求められている。とくに、選手ごとの外傷リスクを評価できれば、個別最適化された効率的な外傷予防が可能となる。このとき、スポーツ外傷予測は、外傷リスクの評価に有用な手法である。

スポーツ外傷予測は、対象者の健康状態や実績データから、将来起こりうる外傷の潜在的なリスクを評価することである(Bahr and Holme, 2003; Pfirrmann et al., 2016)。予測によって、対象者はリスクを事前に把握することができ、適切な予防措置を講じることで、自身の健康と安全を守ることができる。近年では、スポーツ選手らの日常的な活動量や健康状態のモニタリングデータの記録が進んでおり、データの利活用の観点から、外傷予測は挑戦的な研究分野となっている(Fiscutean, 2021; Rossi et al., 2021)。とくに、外傷予測では、外傷に関するモニタリングデータに対して、機械学習の手法が主に用いられている(Rossi et al., 2018; Rommers et al., 2020; 小笠原, 2021)。

¹ 神奈川大学 工学部：〒221-8686 神奈川県横浜市神奈川区六角橋 3-27-1; ota@kanagawa-u.ac.jp

² 法政大学 理工学部：〒184-8584 東京都小金井市梶野町 3-7-2; kim@hosei.ac.jp

スポーツ外傷は対象者に繰り返し発生すると考えると、いつ外傷が発生したかを記録した外傷履歴は、外傷予測の重要な情報である (Shrier et al., 2009; Parekh et al., 2012). 信頼性解析や生存時間解析の観点から、外傷履歴をイベントヒストリーデータとして扱うことで、不確実に生じる外傷を統計的にモデル化することができ、そのモデルを用いることで将来に起こりうる、潜在的な外傷の発生確率を予測することができる。例えば、Parekh et al. (2012)は定常ポアソン過程によって、学生ラグビー選手を対象とした外傷予測モデルを提案している。しかし、このモデルは、定常ポアソン過程の無記憶性により、外傷の再発など、過去に生じた外傷が将来の外傷の起こりやすさに与える影響を考慮できないという課題がある (Parekh et al., 2012; Rizoiti et al., 2017). すなわち、長期的に対象者の外傷予測を行う場合には、定常ポアソン過程は適していない。

スポーツ外傷予測において、定常ポアソン過程モデルの無記憶性の問題を解決するために、Ota and Kimura (2023)は大相撲力士を対象として、外傷の長期的な影響を考慮した外傷予測モデルを提案した。とくに提案手法は信頼性工学におけるシステムのモデリングと信頼性解析の手法を応用し、力士の休場をシステムの故障と見なして、その故障の発生を自己励起過程でモデル化した。このモデルは、自己励起過程の自己励起性によって、過去の外傷履歴が将来に起こりうる外傷に与える影響を考慮できる。その結果、予測精度の向上に成功している。しかし、提案されたモデルの予測精度は、モデルの学習データに対する適合度でのみ評価されており、学習に使用していない、未知のデータに対するモデルの予測精度は評価されていない。実用の観点からは、予測モデルの妥当性が解明されていないという課題がある。

本稿では、こうした近年のスポーツ外傷予測の背景を踏まえて、外傷予測のための点過程モデルを詳述する。2章では、点過程モデルに用いる外傷の分類と計測単位について述べる。さらに大相撲力士の外傷履歴データを例に、外傷発生の統計的な特徴を概観する。3章では Ota and Kimura (2023)を再訪し、点過程を用いた外傷予測手法を解説する。予測手法として、定常ポアソン過程と自己励起過程をそれぞれ用いた、2つの予測モデルを導入する。そして4章では、力士の外傷履歴データを例にとり、予測モデルの適合度の評価と、予測の数値例を示す。また、Ota and Kimura (2023)では明らかにされなかった、モデルのパラメータ推定に使用されていない未知のデータに対する、モデルの予測精度の検証を新たに行い、予測モデルの妥当性を補強する。

2. スポーツ外傷データ

2.1 準備

スポーツ現場で発生するスポーツ外傷には、擦り傷のように傷の処置を適切に実施すれば、対象者がすぐに競技に復帰できるものから、前十字靭帯損傷のように、競技への復帰に半年以上を要するものまでさまざまである (砂川, 2015)。そこで、まず、スポーツ外傷の分類について述べる。

スポーツ外傷の分類として、医療系国家資格や専門資格保有者に対応された外傷は、medical attention injury と定義される (砂川 他, 2022)。さらに、medical attention injury のうち、練習や試合に参加できないスポーツ外傷はタイムロス外傷、参加できるものはノンタイムロス外傷として定義される。

スポーツ外傷の調査では、対象者の活動単位を暴露 (exposure) と呼ぶ。暴露の代表的な数え方には、athlete-exposure (AE) と athlete-hour (AH) の2つが挙げられる。AE とは、対象者が1回の練習または試合に参加する単位を指し、比較的集計が容易である。一般的には、1,000AEあたりのスポーツ外傷件数が調査される。AH とは、対象者が1時間の練習または試合に参加

する単位を指すため、スポーツ外傷のリスクが総合時間の影響を受けやすいと考える場合は有用であるが、AE よりも集計が複雑である。

以上の定義を踏まえて、次節では、AE を活動単位としたタイムロス外傷の外傷履歴の例を示す。

2.2 大相撲力士のスポーツ外傷データ

本節では、大相撲力士を例にとり、スポーツ外傷履歴データの可視化と、外傷発生の統計的特徴を紹介する。なお、力士は平均体重が 160kg であり、他のスポーツ選手と比べて外傷を負いやすい（清水 他, 2021）。そのため、力士の外傷履歴データは多く存在するという特徴がある。これが、本研究が力士を例にとる理由である。

まず、力士の外傷履歴を、力士が休場するまでに要した試合数(取り組み数)と定義する。休場とは、力士が規定の休場届を日本相撲協会に提出して、本場所の取り組みに出場しないことである（金指, 2002）。力士は謹慎処分などの例外を除き、負傷または病気のため本場所に出場できない場合のみ休場できる。休場の多くはタイムロス外傷が原因であることを踏まえて、本研究は休場に関するデータで外傷履歴を定義する。

本研究は、力士の外傷履歴データとして、一般公開されているデータベース（相撲レファレンス, 2024）で公開されている、力士の生涯戦歴数[単位:1,000 AE]および休場時刻[単位:1,000 AE]を利用する。生涯戦歴数は、力士が初土俵を踏んでから数えた本場所での勝ち、負け、休場の試合数の総和である。休場時刻は力士が休場をした時点の生涯戦歴数である。このデータから Data-A と、Data-A には含まれない Data-B の 2 つのデータセットを作成する。なお力士の番付は階級があり、下から順に、前相撲、序ノ口、序二段、三段目、幕下、十両、幕内と呼ばれる。幕内の定員は 42 名である。また、大相撲では 1 年に 6 回開催される本場所において力士同士の対戦が行われる（伊藤, 2019）。

Data-A は、初土俵を 1973 年から 2003 年に踏み、幕内の番付を 1 場所以上維持したことがある力士(該当者数=209)のデータである。このデータはモデルのパラメータを推定するために使用する。Data-B は、2019 年の 1 年間における幕内力士のデータである。このデータは推定されたスポーツ外傷予測モデルを用いた、外傷予測の数値計算例のために使用する。また、未知のデータに対する予測精度の検証のために Data-B を使用する。なお、幕内経験者以外のデータを除外する理由は、データの層別化のためである。

図 1 は Data-A に含まれる 209 人の力士の休場データを示す。図において、力士によっては × 印が立て続けに並んだ箇所が見られる。このことから、多くの休場の発生が連鎖的に発生していることが分かる。これは、スポーツ外傷の長期的な影響によって、外傷を負った力士は、その外傷を再発しやすいことや、外傷部位をかばうことで他の部位に負担がかかり外傷を負いやすいという、実際の力士の特徴が表れていると考えられる。実際に、力士の前十字靱帯損傷の再発頻度は、他のスポーツ選手よりも高いことが知られている（Shimizu et al., 2020）。

次に、力士のスポーツ外傷の起こりやすさの時間変化を可視化するために、力士の平均的な休場の発生頻度を示す。時刻 t (≥ 0) を力士の生涯戦歴数として、力士が一定期間内で休場する頻度を示す指標として、時刻 t における平均休場率を次のように定義する。

$$(2.1) \quad \text{平均休場率} = \frac{\text{時刻 } t \text{ で出場かつ } (t, t + \Delta t] \text{ で休場した力士の人数}}{\text{時刻 } t \text{ で出場した力士の人数}}.$$

ただし、 Δt は正の実数とする。平均休場率は信頼性解析における故障率とも解釈できる（Chiodo and Lauria, 2015）。図 2 は Data-A に含まれる力士の平均休場率の振る舞いを表す。平均休場率はおよそ 1 回目の休場時刻の平均値 \bar{t}_1 まで一定であり、その後は t が大きくなるに




図 1. Data-A に含まれる 209 人の力士の休場データ。各線は各力士の休場データを意味する。力士の並びは引退までの生涯戦歴数についての昇順である。

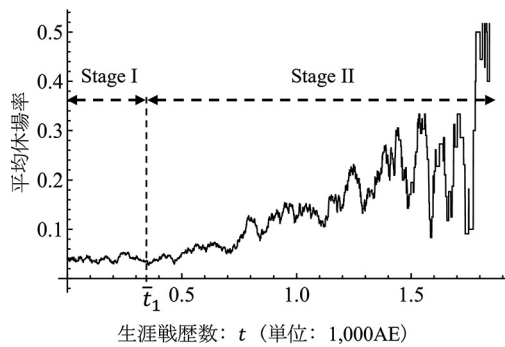


図 2. 平均休場率の振る舞い。

つれて増加する。このような平均休場率の振る舞いは、信頼性工学で良く知られたバスタブ曲線の偶発故障期と摩耗故障期として捉えることができる(真壁 他, 2002; Trivedi, 2016)。本研究は以上の点に着目し、3 章で休場予測モデルを導入する。

3. 予測モデル

本章では、2.2 節の議論を踏まえて、スポーツ外傷予測モデルとして定常ポアソン過程、および自己励起過程をそれぞれ用いたモデルを導入する。それぞれのモデルの入力は、ある時点までの対象者の外傷履歴データであり、出力は、 t 時間以内に新たに外傷を発症する確率である。 T_{ij} を対象者 i が j 回目の外傷を発症した時刻を表す確率変数とする ($i = 1, 2, \dots, n$, $j = 1, 2, \dots$)。ただし、外傷の発生の順序を考慮して、 $T_{i1} < T_{i2} < \dots$ とする。また、外傷の発生時刻の集合を $H_t = \{T_{ij} | T_{ij} < t\}$ とする。そして、 T_{ij} はある強度関数 $\lambda(t|H_t)$ に従っているとする。ここで、直感的には、強度関数とは時刻 t における瞬間的な外傷発生率を意味する (Rizoiu et al., 2017)。厳密には、時刻 t までに発生した外傷の発生回数 N_t に対して、強度関数は次式で与えられる (山中 他, 2017)。

$$(3.1) \quad \lambda(t|H_t) = \lim_{\Delta t \rightarrow 0} \frac{E[N_{t+\Delta t} - N_t | H_t]}{\Delta t}.$$

また強度関数は、ハザードレートとも呼ばれ信頼性工学では故障発生率の評価に用いられている (Ota and Kimura, 2017; Wu, 2019)。さらに、予測モデルには以下のことを仮定する。

仮定 1：対象者らのすべての外傷発生は独立で同一な確率過程に従う。

仮定 2：対象者が外傷を負っている時間は、調査期間に対して短く無視できるとする。すなわち、対象者の外傷は直ちに治癒され、競技を再開できるとする。

以上の定義と仮定に基づいて、次節から、2 種類の外傷予測モデルを導入する。

3.1 定常ポアソン過程モデル

本節では、定常ポアソン過程を用いたスポーツ外傷予測モデルを導入する。強度関数が時刻 t によらず定数 λ_0 としたとき、すなわち

$$(3.2) \quad \lambda_p(t) = \lambda_0,$$

ならば、 T_{ij} はパラメータ λ_0 の指数分布に従い、外傷の発生回数 N_t は定常ポアソン過程に従うと言う。定常ポアソン過程によるスポーツ外傷予測では、将来起こりうる外傷が過去の外傷履歴によらないという仮定が必要である。この性質は定常ポアソン過程の無記憶性とも呼ばれる。従って、もし T_{ij} が $j = 1, 2, \dots$ に関して互いに独立であり、かつ時刻 t に依存しないならば、定常ポアソン過程は、1 つのパラメータのみのシンプルな記述で外傷予測を行えるモデルである。例えば、Parekh et al. (2012) は定常ポアソン過程を用いて、ラグビーにおける男子生徒の外傷発生をモデル化した。しかし、先述のとおり、長い調査期間においては、対象者の外傷の起こりやすさは変化するため、定常ポアソン過程は外傷予測に適さない。

3.2 自己励起過程モデル

本節では、自己励起過程を用いたスポーツ外傷予測モデルを導入する。自己励起過程とは、比較的短い時間内に、複数のイベントが集中して起こりやすいという規則性を持った点過程であり、イベントの発生が過去のすべてのイベントの発生に依存する現象を表せる (Hawkes, 1971; Hawkes, 2018)。外傷予測においては、外傷発生の連鎖性を考慮するのに有用な点過程である。Ota and Kimura (2023) は、次の強度関数 $\lambda_i(t|H_t)$ で T_{ij} をモデル化した。

$$(3.3) \quad \lambda_i(t|H_t) = \begin{cases} \lambda_0 & (t \leq T_{i1}) \\ \lambda_0 + ab(t - T_{i1})^{b-1} + \sum_{T_{ij} < t} \alpha e^{-\beta(t-T_{ij})} & (t > T_{i1}). \end{cases}$$




図 3. 自己励起過程による予測モデルの強度関数の振る舞い例 ($b > 1$).

ただし, $\lambda_0, a, b, \alpha, \beta > 0$ であり, さらに $H_t = \{T_{ij} | T_{ij} < t\}$ は対象者 i において時刻 $[0, t)$ に発生したすべての外傷発生時刻の集合であり, 外傷履歴を意味する.

式(3.3)は, 外傷発生率の2段階の振る舞いを表現するために場合分けされている. すなわち, 対象者の1回目の外傷が発生するまでの $t \leq T_{i1}$ に対して, 式(3.3)は外傷発生率が一定であることを表している. 一方で $t > T_{i1}$ の場合, 式(3.3)の第2項は外傷発生率が時間とともに増減する振る舞いを表しており, 第3項は過去に発生したすべての外傷が, 将来の外傷発生に与える長期的な影響を表している. このように外傷発生率を場合分けすることで, 本モデルでは休場するほどの外傷を一度負った力士は, その後その外傷をかばうことで, 体の他の部位に負担がかかり, 戦歴とともに外傷の可能性が高まることを表現している. 一方で, 一度も休場していない力士は引退するまで外傷発生率の変化がしにくいことも, 本モデルは表現している.

このモデルにおいて, 時刻 T_{i1} は強度関数の変化点になっている. 変化点を含む強度関数のモデリングに関しては, 例えば, ソフトウェア信頼性の分野で研究されている (Inoue and Yamada, 2015). また, $a = \alpha = 0$ の場合, $\lambda_i(t|H_t)$ は定常ポアソン過程の強度関数に一致するため, このモデルは定常ポアソン過程モデルの拡張モデルである. モデルのパラメータは, 対象者らの外傷履歴データから統計的に推定することが可能である. 具体的な推定方法は, 次節で述べる.

図3は, $b > 1$ における $\lambda_i(t|H_t)$ の振る舞いの例を表している. 強度は $t = 0$ から1回目のスポーツ外傷が発生した \bar{t} まで一定であるが, \bar{t} の直後に強度は α だけジャンプする. このジャンプによって, 対象者は外傷直後に再び外傷を負いやすいことを表現している. その後, 強度は指数関数的に減少し, 再び外傷が発生した時点でジャンプし, このことを時間とともに繰り返している. そして, 外傷が発生せず十分に時間が経過したおよそ $t = 1.2$ 以降は, 強度が単調増加している. このように, 自己励起過程による外傷予測モデルは, 時刻と外傷履歴に応じた外傷発生率の変化を表現可能である.

一方で, $0 < b < 1$ の場合, 強度は時間に対して減少して一定の値に収束する. これは, 対象者が時間とともに体の使い方を覚えていくことで, 対象者のスポーツ外傷のリスクが低下する現象を, 自己励起過程による外傷予測モデルは表現できると言える. このような現象は, 分析する期間を限定すれば観測できると考えられる. 例えば, 齊藤 他 (2020) および大垣 他 (2022) によれば, サッカー選手の外傷発生数がシーズン後期に近づくにつれて, 徐々に減少していることが報告されている. この場合, 分析期間を1シーズンに限定してスポーツ外傷の予測モデルを構築する場合は, $0 < b < 1$ となる可能性がある.

対象者の将来時点におけるスポーツ外傷の発生確率は, 式(3.3)から求められる. $p_{ij}(w|t)$ を, 時刻 t において対象者 i に次の j 回目の外傷がその後 $w (> 0)$ 時間以内に発生する確率とする. このとき, $p_{ij}(w|t)$ は次式で与えられる.

$$(3.4) \quad p_{ij}(w|t) = \begin{cases} 1 - e^{-\lambda_0 w} & (j = 1) \\ 1 - e^{-\int_t^{t+w} \lambda_i(s|H_t) ds} & (j \geq 2). \end{cases}$$

対象者が時刻 t までに一度も外傷を負っていない場合、式(3.4)は t によらず定数で求められ、それ以外の場合、 w, t, H_t に依存する。例えば、対象者が大相撲力士の場合、15 日間(= 0.015AE)開催される本場所中の外傷の発生確率は $p_{ij}(0.015|t)$ で求められる。

また、個々の対象者の外傷の発生確率から、対象集団全体での外傷発生数の評価ができる。対象者の人数を N 、確率変数 X を本場所中に外傷が発生する対象者数、および X の確率質量関数を $q_x \equiv \Pr[X = x]$ とする。そして、時刻 t_i を対象者 i の AE とすると、その後 w 時間以内に各対象者に外傷が発生する確率は $p_{ij}(w|t_i)$ となる。このとき、 X はポアソン二項分布(Chen and Liu, 1997)に従うことが知られており、 q_x は次式で与えられる。

$$(3.5) \quad q_x = \sum_{S' \in S_x} \left\{ \prod_{i \in S'} p_{ij}(w|t_i) \prod_{i \in (I \setminus S')} (1 - p_{ij}(w|t_i)) \right\}.$$

ここで、 $I = \{1, 2, \dots, N\}$ であり、 S_x は集合 I から選択可能な x 個の整数からなる、すべての部分集合である。さらに、 X の期待値と分散は以下ようになる。

$$(3.6) \quad E[X] = \sum_{i=1}^N p_{ij}(w|t_i),$$

$$(3.7) \quad V[X] = \sum_{i=1}^N (1 - p_{ij}(w|t_i)) p_{ij}(w|t_i).$$

このように、特定の対象者の集団に潜在する外傷リスクを、 $q_x, E[X], V[X]$ で要約することが可能である。

3.3 パラメータの最尤推定

本節では、スポーツ外傷予測モデル $\lambda_i(t|H_t)$ のパラメータ $\lambda_0, a, b, \alpha, \beta$ の推定方法として、最尤推定を紹介する。

変数 ν_i を対象者 i が引退するまでのスポーツ外傷の発生回数とする。このとき、式(3.3)で与えられる自己励起過程モデルに対する対数尤度関数 $\log \mathcal{L}$ は、以下のように表される。

$$(3.8) \quad \log \mathcal{L}(\lambda_0, a, b, \alpha, \beta|H_t) = \sum_{i=1}^n \left\{ \sum_{j=1}^{\nu_i} \log \lambda_i(t_{ij}|H_t) - \int_0^{t_{i\nu_i}} \lambda_i(s|H_t) ds \right\}.$$

さらに、式(3.8)は以下のように再帰的に計算できる (Ogata, 1988)。

$$(3.9) \quad \log \mathcal{L}(\lambda_0, a, b, \alpha, \beta|H_t) = \sum_{i=1}^n \left\{ \sum_{j=1}^{\nu_i} \log(h_i(t_{ij}|H_t) + \alpha R(j)) - \int_0^{t_{i\nu_i}} h_i(s|H_t) ds - \sum_{j=1}^{\nu_i} \frac{\alpha}{\beta} (1 - e^{-\beta(t_{i\nu_i} - t_{ij})}) \right\}.$$

ただし、

$$(3.10) \quad h_i(t|H_t) = \begin{cases} \lambda_0 & (t \leq t_{i1}) \\ \lambda_0 + ab(t - t_{i1})^{b-1} & (t > t_{i1}), \end{cases}$$

$$(3.11) \quad R(j) = \begin{cases} 0 & (j = 1) \\ e^{-\beta(t_{ij} - t_{ij-1})}(1 + R(j-1)) & (j \geq 2). \end{cases}$$

そして、式(3.9)を最大化することで、パラメータ $\lambda_0, a, b, \alpha, \beta$ の最尤推定量として $\hat{\lambda}_0, \hat{a}, \hat{b}, \hat{\alpha}, \hat{\beta}$ が得られる。また、推定量の標準誤差は対数尤度関数のヘッセ行列から求められる (Serfling, 1980)。

4. 実証分析

本章では、大相撲力士を対象としたスポーツ外傷予測の結果を示す。大相撲において、力士の外傷をいかに減らすかということは長年の課題である。例えば、2019 年において幕内力士 42 人の内、本番所当たり平均して 5.2 人が休場している。しかし、依然として各力士がどれだけ外傷を負いやすいかは明らかになっておらず、外傷予防の導入が進んでいない。そのため、力士の外傷リスクを把握するために、外傷予測は重要である。

本章の流れを図 4 に示す。図 4 において、四角は工程を表し、矢印は各工程の入力と出力を表している。まず、過去に引退した力士のスポーツ外傷の履歴データから、予測モデルのパラメータを推定し、モデルの適合度の評価を行う。そして、推定されたモデルを用いて外傷予測の数値例を示す。

4.1 パラメータ推定結果

大相撲力士のスポーツ外傷の発生をモデル化するために、2.2 節で定義した Data-A を用いて、式(3.3)のパラメータを最尤推定 (Ogata, 1981; Lehmann and Casella, 1998) する。Data-A は力士の休場と引退を、外傷の発生とみなしたデータである。パラメータの最尤推定量は、式(3.9)で与えられる対数尤度関数を最大化することで得られる。ここで $\hat{\lambda}_0, \hat{a}, \hat{b}, \hat{\alpha}, \hat{\beta}$ を、それぞれパラメータ $\lambda_0, a, b, \alpha, \beta$ の最尤推定量とする。そして、パラメータの最尤推定量を $\lambda_i(t|H_t)$, $p_{ij}(w|t, q_x)$ に代入したものを、それぞれ $\hat{\lambda}_i(t|H_t)$, $\hat{p}_{ij}(w|t, q_x)$ とする。

なお、休場は引退により打ち切られるが、この打ち切り (Blanche et al., 2013; Emura and Chen, 2018) が推定結果に与える影響は小さく、無視できるものと仮定する。ここでは打ち切りの影響を無視するが、推定結果の妥当性は、次節以降のモデル検証および予測精度の検証で保証される。

表 1 にパラメータの推定値を示す。この表は、推定値、標準誤差、および AIC (Akaike Information Criterion; 赤池情報量規準) をまとめている。AIC はモデルのパラメータ数 k および最大対数尤度 $\log \mathcal{L}$ に対して、 $AIC = 2k - 2\log \mathcal{L}$ で与えられる。AIC の第一項はパラメータ数に対する罰則項であり、第二項はデータに対するモデルに当てはまりの良さを表している。このことから AIC が小さいモデルほど、データに適合しているといえる。よって、より小さい値の AIC をもつ自己励起過程によるモデルは、定常ポアソン過程によるモデルよりも Data-A に適




図 4. スポーツ外傷予測モデルの検証と予測の流れ。

表 1. パラメータの推定結果と各モデルの AIC (括弧の中身は標準誤差である)。

モデル	$\hat{\lambda}_0$	\hat{a}	\hat{b}	$\hat{\alpha}$	$\hat{\beta}$	AIC
定常ポアソン過程	4.671 (0.149)	—	—	—	—	-1058.03
自己励起過程	2.685 (0.170)	1.399 (0.298)	2.689 (0.300)	2.866 (0.630)	7.626 (2.663)	-1267.93

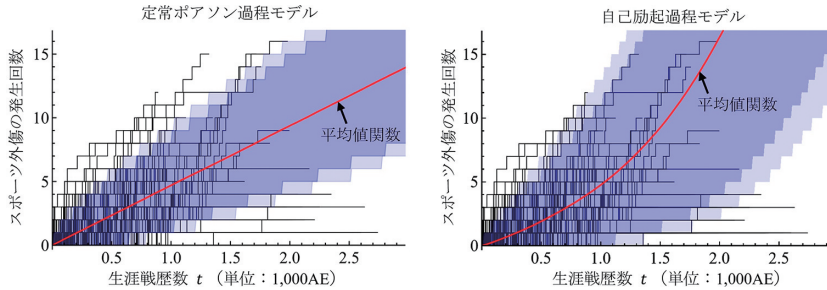


図 5. 予測モデルの信頼区間。黒線は Data-A に含まれる 209 名の力士のスポーツ外傷の発生パス、薄いおよび濃い領域はシミュレーションにもとづく平均値関数の 99% および 95% 信頼区間をそれぞれ表している。

合していることが分かる。

推定結果について考察する。自己励起過程による予測モデルにおいて、 $\hat{\lambda}_0 = 2.685$ であるから、1 回目の外傷が発生するまでの時間の期待値は $0.372 (= 1/\hat{\lambda}_0)$ ということが分かる。初土俵を踏んで間もない力士が、この期待値までに休場する確率は以下のように求められる。

$$(4.1) \quad \hat{p}_{i1}(0.372|t) = 1 - e^{-\hat{\lambda}_0 \cdot 0.372} = 1 - e^{-1} = 0.632.$$

また、1 度も外傷が発生していない力士が、15 日間開催される本場所において、休場する確率は $\hat{p}_{i1}(0.015|t) = 0.0395$ と推定できる。そして、 $\hat{b} > 1$ より、力士は 1 回目の休場後に図 2 の Stage II の摩耗故障期 (Shooman, 2003) に入り、 $\hat{\alpha} > 0$ より、外傷発生の長期的な影響があることが分かる。

4.2 適合度評価

本節では、前節で推定されたモデルの妥当性を検証する。推定された強度関数 $\hat{\lambda}_i(t|H_t)$ に基づくシミュレーション (Ogata, 1981) により、時間に対するスポーツ外傷の発生回数の期待値および信頼区間を求める。なおシミュレーションでは有意水準 γ に対して $100(1-\gamma)\%$ 信頼区間 (Dohi et al., 2020) を、シミュレーション結果の $\gamma/2$ および $1-\gamma/2$ パーセント点で導出する。図 5 は推定された定常ポアソン過程モデルと自己励起過程モデルに基づくシミュレーション結果、および Data-A の経験的な結果の重ね合わせを、それぞれ示している。例えば、自己励起過程モデルによる予測モデルによれば、 $t = 1.0$ までの外傷の発生回数の期待値 (すなわち平均値関数の値) は 4.8 となる。図 5 より、定常ポアソン過程による予測モデルでは、信頼区間に含まれないデータがグラフ左上および右下で見受けられるが、自己励起過程による予測モデルでは信頼区間に含まれないデータが減っていることが分かる。

次に予測モデルの残差 (Ogata, 1988) を調べることで、Data-A に対する予測モデルのそれぞれの適合度を評価する。 $i = 1, 2, \dots, n$ に対して、 $\{t_{i1}, t_{i2}, \dots, t_{i\nu_i}\}$ を、強度関数が $\lambda_i(t|H_t)$ で




図 6. Data-A に含まれる力士 1 名の休場時刻データを予測モデルで変換した $\{u_{i1}, u_{i2}, \dots, u_{i\nu_i}\}$ の経験分布関数.

ある点過程の実現値とする. 連続した t_{ij-1} と t_{ij} に対して, 以下の $\lambda_i(t|H_t)$ の積分を考える.

$$(4.2) \quad \Lambda_i(t_{ij-1}, t_{ij}) = \int_{t_{ij-1}}^{t_{ij}} \lambda_i(s|H_t) ds.$$

点過程の時間変換により, $\{\tau_{i1}, \tau_{i2}, \dots, \tau_{i\nu_i}\}$ を以下のように定義する.

$$(4.3) \quad \tau_{i1} = \int_0^{t_{i1}} \lambda_i(s|H_t) ds,$$

$$(4.4) \quad \tau_{ij} = \tau_{ij-1} + \Lambda_i(t_{ij-1}, t_{ij}).$$

ここで, $\tau_{ij} - \tau_{ij-1} = \Lambda_i(t_{ij-1}, t_{ij})$ は, 期待値が 1 の指数分布に従う. また, $\{\tau_{i1}, \tau_{i2}, \dots, \tau_{i\nu_i}\}$ は残差と呼ばれる. さらに, $j = 1, 2, \dots, \nu_i$ に対して, $u_{ij} = 1 - e^{-\tau_{ij}}$ は区間 $[0, 1]$ 上の独立で同一な一様分布に従う. 従って, もし推定された強度関数 $\hat{\lambda}_i(t|H_t)$ が真の強度関数 $\lambda_i(t|H_t)$ の精度の良い近似であれば, $\{u_{i1}, u_{i2}, \dots, u_{i\nu_i}\}$ は区間 $[0, 1]$ 上の独立で同一な一様分布に従うことが分かる.

図 6 は u -plot (Abdel-Ghaly et al., 1986) として知られ, 推定された定常ポアソン過程と自己励起過程による, それぞれの予測モデルの強度関数から得られた $\{u_{i1}, u_{i2}, \dots, u_{i\nu_i}\}$ の経験分布関数を表している. これら経験分布が理論分布である一様分布に適合しているかを, コルモゴロフ・スミルノフの適合度検定 (有意水準 5%) で調べる. 結果として, Data-A に含まれる 209 人の力士に対して, 定常ポアソン過程による予測モデルでは 31 人の力士データが適合しなかったが, 自己励起過程による予測モデルでは 8 人の力士のみが適合しなかった. このことから, 自己励起過程による予測モデルの方が定常ポアソン過程による予測モデルよりも Data-A に適合しているといえる. 以上の議論を踏まえて, 以降では自己励起過程による予測モデルのみを分析する.

最後にキャリブレーション (Gerds and Kattan, 2021) によって, 予測モデルの予測精度を検証する. キャリブレーションとは, 予測モデルが出力した確率がどの程度, 実際のイベントの発生率を近似しているかを評価し, さらに, 必要に応じて出力を補正する手法である. キャリブレーションの手順は以下のとおりである.

(1) Data-A に含まれる各力士が, 初土俵から引退するまでの各本場所で休場する確率の推定値を求める. このとき, 力士は幕下以下の場合に本場所で 7 日間対戦し, 幕下よりも上の場合は 15 日間対戦することを考慮して, 対象力士が休場する確率の推定値を, それぞれ $\hat{p}_{ij}(0.007|t)$ と $\hat{p}_{ij}(0.015|t)$ で求める.

(2) 区間 $[0, 0.3]$ を 0.05 刻みで分割し、推定された確率をそれらが含まれる区間ごとにグループ化する。そして、各グループに含まれる推定された確率の平均値を求め、各グループの代表値とする。

(3) 各グループにおける実際の休場の発生率を求める。すなわち、各グループが含むデータに対して、データ数で実際に休場した力士の人数を割った値を求める。

(4) 手順(2)で求めた推定された確率と、手順(3)で求めた実際の休場の発生率の 2 変量データを散布図にする。

図 7 は Data-A に対するキャリブレーションの結果を示す。ここで各区間 $[0, 0.05]$, $[0.05, 0.1]$, $[0.1, 0.15]$, $[0.15, 0.2]$, $[0.2, 0.25]$, $[0.25, 0.3]$ のサンプルサイズは、それぞれ 9438, 7075, 1485, 217, 39, 5 となった。例えば、区間 $[0.1, 0.15]$ に含まれるデータでは、休場する確率の推定値の平均が 0.118 で、実際の休場の発生率は 0.122 であった。この 2 つの値が近いほど、予測が実際の結果を再現できたと言える。従って、図 7 において各点が対角線付近にあることから、予測モデルは平均的に精度よく力士のスポーツ外傷の発生を予測できているといえる。

ただし、区間 $[0.25, 0.3]$ における点は、休場する確率の過小評価により、対角線から最も離れるという評価結果となった。この過小評価の主な要因として、(i) サンプルサイズが 5 と小さいこと、(ii) 引退による外傷発生の打ち切りを無視する仮定の影響が考えられる。まず、サンプルサイズが小さいことに関しては、休場する確率が 0.25 以上となる力士の数が少ないことが影響している。そのような力士は、生涯戦歴数が多く、休場が多くても力士を続けられるほどの高位の番付を維持できる実力を有している必要がある。これらの条件を満たす力士として、唯一休場しても番付が下がらない特例が適用される横綱が該当する可能性が高い。実際に、図 7 において区間 $[0.25, 0.3]$ における点は、すべて同一の横綱のサンプルのみから計算された。このように、区間 $[0.25, 0.3]$ における点は限られたデータのみから導出されたため、過小評価が生じたと考えられる。次に、引退による打ち切りの影響を無視する仮定の影響について考える。生涯戦歴数が大きくなるにつれて、引退によるデータの打ち切りの影響は強くなるため、休場する確率が過小評価されやすい。以上より、自己励起過程による予測モデルは、とくに横綱のような生涯戦歴数の多い力士に対して、スポーツ外傷の発生確率を過小評価する可能性があると言える。

4.3 予測結果例

本節では、前節のパラメータ推定と検証の結果を踏まえて、Data-B に含まれるすべての力士




図 7. 自己励起過程による予測モデルのキャリブレーション。

表 2. 2019 年 1 月場所における幕内力士 42 名のデータ.

ID	しこ名	ID	しこ名	ID	しこ名
1	稀勢の里	15	正代	29	宝富士
2	白鵬	16	松鳳山	30	阿炎
3	鶴竜	17	琴奨菊	31	佐田の海
4	高安	18	隠岐の海	32	勢
5	豪栄道	19	碧山	33	輝
6	栃ノ心	20	嘉風	34	明生
7	貴景勝	21	千代大龍	35	矢後
8	玉鷲	22	阿武咲	36	琴勇輝
9	妙義龍	23	竜電	37	豊山
10	御嶽海	24	大栄翔	38	千代翔馬
11	栃煌山	25	魁聖	39	千代の国
12	逸ノ城	26	朝乃山	40	琴恵光
13	錦木	27	貴ノ岩	41	大奄美
14	北勝富士	28	遠藤	42	大翔丸




図 8. 2019 年 1 月場所における幕内力士 42 名の休場する確率の推定値 $\hat{p}_{ID,j}(0.015|t_{ID})$. ID と四股名の対応は表 2 に記載されている. * は実際の休場力士を表す.

に対するスポーツ外傷の予測例を示す. 本例題では, 自己励起過程モデルで外傷予測を行い, モデルのパラメータには, 4.1 節で得られたパラメータの推定値を用いる. 予測モデルの入力は, $i = 1, 2, \dots, 42$ および $j = 1, 2, \dots$ に対して, 第 i 力士の生涯戦歴数 t_i と j 回目までの休場時刻であり, 出力は第 i 力士が休場する確率の推定値 $\hat{p}_{ij}(0.015|t_i)$ である. 表 2 は Data-B に含まれる力士の名前と便宜的に割り付けた ID を表している. なお, 6 人の力士 (ID = 1, 2, 3, 10, 36, 39) が, 実際に本場所で休場した.

図 8 は, 各力士が本場所において休場する確率の推定値 $\hat{p}_{ID,j}(0.015|t_{ID})$ を表している. この図から, 各力士が他の力士と比べてどれだけスポーツ外傷を負いやすい状態にあるかが分かる. 例えば, 42 人の力士の内, 白鵬 (ID = 2, $j = 10$) は休場する確率が 21.7% で最も高く, 次いで鶴竜 (ID = 3, $j = 9$) が 18.5% で豪栄道 (ID = 5, $j = 8$) が 15.9% である. 14 人の力士は過去に休場したことが一度もないため, 休場する確率は 3.95% であった. とくに, 玉鷲 (ID = 8, $j = 1$) は休場したことが一度もない力士のなかで最も長い生涯戦歴数 1.151 を有しており, こ




図 9. 白鵬 (ID=2, $j=10$), 鶴竜 (ID=3, $j=9$), 豪栄道 (ID=5, $j=8$) の次のスポーツ外傷発生時間の累積分布関数. 原点 $w=0$ は 2019 年 1 月の本場所初日に該当する.




図 10. 2019 年 1 月の本場所における休場者数の推定値の分布.

それは $e^{-1.151\hat{\lambda}_0} = 0.0455$ の確率で起こりうる稀な事象であることが分かる.

図 9 は, 白鵬, 鶴竜, 豪栄道の将来における休場発生確率 $\hat{p}_{ID,j}(w|t_{ID})$ の変化を示している. この図から, それぞれの力士が生涯戦歴数 0.05 以内, すなわち 50 回の取り組み以内, に休場する確率は 50% 以上あることが分かる. また, 白鵬は分析対象の本場所において, もっとも生涯戦歴数が長く休場回数も多いため, この図においても将来における休場の確率が最も大きいことが分かる.

2019 年 1 月の本場所において, 潜在的にスポーツ外傷で休場する人数 X を推定することも可能である. この人数 X は, 大相撲を運営する日本相撲協会が, 本場所においてどれくらいの力士が休場するリスクがあるのかを把握することができ, 日々の取り組みの組み合わせを考える際に有用である. 図 10 は X の推定された確率分布を表している. X の期待値は 3.401, 標準偏差は 1.746 である. また, この本場所において, 実際には ID=1, 2, 3, 10, 36, 39 の計 6 人の力士が休場したが, その発生確率は式 (3.5) より $\hat{q}_6 = 0.070$ であったことが分かる.

4.4 予測精度の評価

本節では, Ota and Kimura (2023) では検証されなかった, パラメータの推定に用いていない未知のデータに対する, 予測モデルの予測精度を検証する. 具体的には, パラメータの推定に使用していない Data-B を用いて, 2019 年の各本場所における全幕内力士の実際の休場または出場の同時確率を, 定常ポアソン過程モデルと自己励起過程モデルでそれぞれ求め, 比較・評価する.

ここで M を, ある本場所で休場した力士の ID の集合とする. そして以下の \bar{p} のように, その本場所で実際に休場した力士らの休場する確率の推定値と, 実際に出場した力士らの出場する確率 (= $1 -$ 休場する確率) の推定値の積を考える.

表 3. 2019 年の各本場所における予測精度 \hat{p} の評価結果. 記号*は値が大きいモデルを表す.

モデル	2019 年 1 月	2019 年 3 月	2019 年 5 月	2019 年 7 月	2019 年 9 月	2019 年 11 月
定常ポアソン過程	7.71×10^{-9}	3.83×10^{-3}	1.46×10^{-6}	7.71×10^{-9}	7.71×10^{-9}	5.59×10^{-10}
自己励起過程	$2.25 \times 10^{-7*}$	$4.89 \times 10^{-3*}$	$4.37 \times 10^{-6*}$	$2.30 \times 10^{-7*}$	$4.37 \times 10^{-7*}$	$8.91 \times 10^{-9*}$

$$(4.5) \quad \hat{p} = \underbrace{\left(\prod_{m \in M} \hat{p}_{mj_m}(0.015|t_m) \right)}_{\text{休場した力士の休場する確率の推定値の積}} \underbrace{\left(\prod_{m \in \{1,2,\dots,42\} \setminus M} 1 - \hat{p}_{mj_m}(0.015|t_m) \right)}_{\text{実際に出場した力士の出場する確率の推定値の積}}.$$

ただし, j_m は m 番目の力士が, 対象とする本場所で休場した場合の入門してからの累積休場回数を表す. 式 (4.5) は, $m = 1, 2, \dots, n$ に対して, 成功確率が \hat{p}_{mj_m} で失敗確率が $1 - \hat{p}_{mj_m}$ の n 回の独立なベルヌーイ試行の同時確率と言える (浜田, 2022). この確率が大きいモデルほど, 実際に起きたイベントの発生確率を大きく見積もったことを意味するので, 予測精度が高いと言える.

Data-B に含まれる 2019 年の各本場所における予測精度 \hat{p} の評価結果を表 3 に示す. 例えば, 2019 年 1 月の本場所では, $M = \{1, 2, 3, 10, 36, 39\}$ であり, 定常ポアソン過程モデルの場合, $\hat{p} = 7.71 \times 10^{-9}$, 自己励起過程モデルの場合, $\hat{p} = 2.25 \times 10^{-7}$ となり, 自己励起過程モデルの方が値が大きく予測精度が高いと言える. とくに, 図 8 において, 自己励起過程モデルは ID=2, 3 の力士のように実際に休場した力士ほど休場する確率を高く評価し, 出場している力士ほど休場する確率を低く評価している. このことから, 自己励起過程モデルは実際のデータとの整合性があると言える. 一方で, 定常ポアソン過程モデルの場合, 生涯戦歴数や外傷履歴に関わらず, どの力士でも同一の確率で休場すると予測するため, 実際のデータとの整合性の評価が難しい. 以上の理由から, 自己励起過程モデルの \hat{p} は定常ポアソン過程モデルのものより高くなっている. 同様に, すべての本場所において自己励起過程モデルの方が \hat{p} が大きく, 予測精度が高いことが分かる. したがって, 4.2 節の適合度評価の結果と同様に, スポーツ外傷予測において, 過去のスポーツ外傷の影響を考慮した自己励起過程によるモデルのほうが, それを考慮していない定常ポアソン過程によるモデルよりも, 予測精度が高いことが分かった.

4.5 予測モデルの限界

本節では, 本稿で紹介したスポーツ外傷の予測モデルの限界について述べる. 限界の 1 つとして, 本稿で紹介した外傷予測手法を, 力士以外のスポーツ選手へ適用した場合に, その予測精度が保証されない点がある. 自己励起過程モデルは, 大相撲力士の外傷履歴の特徴から考案されたモデルであり, 他のスポーツ選手の外傷予測に適用できるかは確認されていない. 今後は, 相撲以外のスポーツ選手の外傷履歴データから, モデルのパラメータ推定および外傷予測の精度検証が求められる.

また, スポーツ外傷予防への予測結果の応用の限界がある. 外傷予測に利用できるデータは, Modifiable なデータと, Non-modifiable なデータに分類される (Bahr and Holme, 2003; Joyce and Lewindon, 2016). Modifiable なデータとは, BMI 指数, 筋力, 柔軟性といった, トレーニングや生活習慣で修正可能なデータであり, Non-modifiable なデータとは, 年齢, 性別, 過去の外傷履歴といった, 修正不可能なデータを意味する (Häggglund et al., 2006). 本稿で紹介した外傷予測は, Non-modifiable なデータである外傷履歴と AE のみを使用しているため, 外傷の発生確率を低減させるような外傷予防をするために, 対象者が何をすべきかは明らかにできない. 今後はこの問題を解決するために, Modifiable なデータを共変量として考慮できる外傷

予測モデルの開発が必要である (Therneau and Grambsch, 2000; Meira-Machado et al., 2009). 例えば、力士に関する Modifiable なデータとして、小川 他 (1973) が調査した力士の筋力や運動能力が共変量として利用可能である。また、対象者の心理的要因が外傷のリスクと関係すること (Bahr and Krosshaug, 2005; Kimotsuki et al., 2024) を踏まえて、モデルに心理的要因を導入することも今後の研究に期待される。

5. おわりに

本稿では、対象者の外傷履歴を用いた統計的なスポーツ外傷予測手法について詳説した。外傷予測では、繰り返し発生するスポーツ外傷をイベントヒストリーデータと見なして、信頼性解析・生存時間解析の観点から、スポーツ外傷の発生を点過程でモデル化した。モデルでは自己励起過程によって外傷発生の連鎖性や、時間に対する発生率の単調増加性が考慮された。そして、大相撲力士を例に、自己励起過程モデルによる外傷予測の妥当性を示した。その結果、外傷発生の連鎖性を考慮できない定常ポアソン過程モデルよりも、自己励起過程モデルの方が、より正確に外傷予測できることが確認できた。

今後の課題としては、4.5 節で述べたように、他のスポーツ選手の外傷予測への自己励起過程モデルの適用や、スポーツ外傷予防に効果的な変数を予測モデルに追加した新しいモデルの開発が挙げられる。

謝 辞

本稿の作成にあたって、編集委員および匿名の査読者 2 名から内容を改善する貴重なコメントを多く頂きました。ここに記して感謝いたします。本研究の一部は、JSPS 科研費 (課題番号 19K04892 および 21K14373) および神奈川大学工学研究所共同研究 (A) の助成を受けたことを付記します。

参 考 文 献

- Abdel-Ghaly, A. A., Chan, P. Y. and Littlewood, B. (1986). Evaluation of competing software reliability predictions, *IEEE Transactions on Software Engineering*, **SE-12**(9), 950–967.
- Bahr, R. and Holme, I. (2003). Risk factors for sports injuries—A methodological approach, *British Journal of Sports Medicine*, **37**(5), 384–392.
- Bahr, R. and Krosshaug, T. (2005). Understanding injury mechanisms: A key component of preventing injuries in sport, *British Journal of Sports Medicine*, **39**(6), 324–329.
- Blanche, P., Dartigues, J. F. and Jacqmin-Gadda, H. (2013). Estimating and comparing time-dependent areas under receiver operating characteristic curves for censored event times with competing risks, *Statistics in Medicine*, **32**(30), 5381–5397.
- Chen, S. X. and Liu, J. S. (1997). Statistical applications of the Poisson-binomial and conditional Bernoulli distributions, *Statistica Sinica*, **7**(4), 875–892.
- Chiodo, E. and Lauria, D. (2015). Some basic properties of the failure rate of redundant reliability systems in industrial electronics applications, *IEEE Transactions on Industrial Electronics*, **62**(8), 5055–5062.
- Dohi, T., Zheng, J. and Okamura, H. (2020). Data-driven software reliability evaluation under incomplete knowledge on fault count distribution, *Quality Engineering*, **32**(3), 421–433.

- Emura, T. and Chen, Y. H. (2018). *Analysis of Survival Data with Dependent Censoring: Copula-Based Approaches*, Springer, Singapore.
- Fiscutean, A. (2021). Data scientists are predicting sports injuries with an algorithm, *Nature*, **592**(7852), 10–11.
- Gerds, T. A. and Kattan, M. W. (2021). *Medical Risk Prediction Models: With Ties to Machine Learning*, Chapman and Hall/CRC, Boca Raton.
- Häggglund, M., Waldén, M. and Ekstrand, J. (2006). Previous injury as a risk factor for injury in elite football: A prospective study over two consecutive seasons, *British Journal of Sports Medicine*, **40**(9), 767–772.
- 浜田宏 (2022). ベイズで広がる数理社会学の世界, 理論と方法, **37**(1), 124–137.
- Hawkes, A. G. (1971). Spectra of some self-exciting and mutually exciting point processes, *Biometrika*, **58**(1), 83–90.
- Hawkes, A. G. (2018). Hawkes processes and their applications to finance: A review, *Quantitative Finance*, **18**(2), 193–198.
- Inoue, S. and Yamada, S. (2015). Software reliability assessment with multiple changes of testing-environment, *IEICE TRANSACTIONS on Fundamentals of Electronics, Communications and Computer Sciences*, **E98-A**(10), 2031–2041.
- 伊藤勝治 (2019). 『相撲見物』, 青幻舎, 京都.
- Joyce, D. and Lewindon, D. (eds.) (2016). *Sports Injury Prevention and Rehabilitation*, Routledge, New York.
- 金指基 (2002). 『相撲大事典』, 現代書館, 東京.
- Kimotsuki, Y., Ogasawara, I., Iwasaki, S., Nagai, K., Nishida, K., Kanzaki, N., Hoshino, Y., Matsushita, T., Kuroda, R., Uchida, R., Take, Y. and Nakata, K. (2024). Goal orientation and desire for approval were associated with sports injuries among young Japanese athletes, *AJPM Focus*, **3**(4), <https://doi.org/10.1016/j.focus.2024.100236>.
- Lehmann, E. L. and Casella, G. (1998). *Theory of Point Estimation*, 2nd ed., Springer, New York.
- 真壁肇, 鈴木和幸, 益田昭彦 (2002). 『品質保証のための信頼性入門』, 日科技連, 東京.
- Meira-Machado, L., de Uña-Álvarez, J., Cadarso-Suárez, C. and Andersen, P. K. (2009). Multi-state models for the analysis of time-to-event data, *Statistical Methods in Medical Research*, **18**(2), 195–222.
- 大垣亮, 陣内峻, 八田倫子 (2022). スポーツ外傷・障害・疾病における疫学データの活用方法, 日本アスレティックトレーニング学会誌, **8**(1), 33–41.
- 小笠原一生 (2021). 機械学習によるスポーツ外傷予測, 予防の可能性, 体育の科学, **71**(11), 778–784.
- Ogata, Y. (1981). On Lewis' simulation method for point processes, *IEEE Transactions on Information Theory*, **27**(1), 23–31.
- Ogata, Y. (1988). Statistical models for earthquake occurrences and residual analysis for point processes, *Journal of the American Statistical Association*, **83**(401), 9–27.
- 小川新吉, 古田善伯, 山本恵三, 永井信雄 (1973). 相撲力士の体力科学的研究 (その 2) (関取の体力と発達), 体力科学, **22**(2), 45–55.
- Ota, S. and Kimura, M. (2017). A statistical dependent failure detection method for n-component parallel systems, *Reliability Engineering & System Safety*, **167**, 376–382.
- Ota, S. and Kimura, M. (2023). Statistical injury prediction for professional sumo wrestlers: Modeling and perspectives, *PLoS ONE*, **18**(3), <https://doi.org/10.1371/journal.pone.0283242>.
- Parekh, N., Hodges, S. D., Pollock, A. M. and Kirkwood, G. (2012). Communicating the risk of injury in schoolboy rugby: Using Poisson probability as an alternative presentation of the epidemiology, *British Journal of Sports Medicine*, **46**(8), 611–613.
- Pfirrmann, D., Herbst, M., Ingelfinger, P., Simon, P. and Tug, S. (2016). Analysis of injury incidences in

- male professional adult and elite youth soccer players: A systematic review, *Journal of Athletic Training*, **51**(5), 410–424.
- Rizoiu, M. A., Lee, Y., Mishra, S. and Xie, L. (2017). Hawkes processes for events in social media, *Frontiers of Multimedia Research* (ed. S. F. Chang), 191–218, Association for Computing Machinery and Morgan & Claypool, San Rafael.
- Rommers, N., Rössler, R., Verhagen, E., Vandecasteele, F., Verstockett, S., Vaeyens, R., Lenoir, M., D'Hondt, E. and Witvrouw, E. (2020). A machine learning approach to assess injury risk in elite youth football players, *Medicine & Science in Sports & Exercise*, **52**(8), 1745–1751.
- Rossi, A., Pappalardo, L., Cintia, P., Iaia, F. M., Fernández, J. and Medina, D. (2018). Effective injury forecasting in soccer with GPS training data and machine learning, *PloS ONE*, **13**(7), <https://doi.org/10.1371/journal.pone.0201264>.
- Rossi, A., Pappalardo, L. and Cintia, P. (2021). A narrative review for a machine learning application in sports: an example based on injury forecasting in soccer, *Sports*, **10**(1), <https://doi.org/10.3390/sports10010005>.
- 齊藤和快, 安斎健太郎, 岡林務, 今城栄祐, 五十子圭佑, 竹内真太, 西田裕介 (2020). Jリーグ・ディビジョン2に所属するチームにおける2年間の傷害調査, *理学療法科学*, **35**(1), 33–39.
- Serfling, R. J. (1980). *Approximation Theorems of Mathematical Statistics*, John Wiley & Sons, Toronto.
- Shimizu, S., Nagase, T., Tateishi, T., Nakagawa, T. and Tsuchiya, M. (2020). Second anterior cruciate ligament injuries after anterior cruciate ligament reconstruction in professional sumo wrestlers: A case series, *Orthopaedic Journal of Sports Medicine*, **8**(2), 1–5.
- 清水禎則, 長瀬寅, 立石智彦, 佐藤哲也, 中川照彦, 土屋正光 (2021). 平成時代の大相撲力士の傷害統計, *日本整形外科学スポーツ医学会雑誌*, **41**(3), 201–208.
- Shooman, M. L. (2003). *Reliability of Computer Systems and Networks: Fault Tolerance, Analysis, and Design*, John Wiley & Sons, New York.
- Shrier, I., Steele, R. J., Hanley, J. and Rich, B. (2009). Analyses of injury count data: Some do's and don'ts, *American Journal of Epidemiology*, **170**(10), 1307–1315.
- 相撲レファレンス (2024). 力士, <https://sumodb.sumogames.de/Rikishi.aspx?l=j> (最終アクセス日 2025年3月26日).
- 砂川憲彦 (2015). 『スポーツ現場の傷害調査』, ブックハウス・エイチディ, 東京.
- 砂川憲彦, 真鍋知宏, 半谷美夏, 細川由梨, 奥脇透, 広瀬統一, 増島篤 (2022). スポーツ外傷・障害および疾病調査に関する提言書：日本臨床スポーツ医学会・日本アスレティックトレーニング学会共同声明, *日本アスレティックトレーニング学会誌*, **7**(2), 155–171.
- Therneau, T. M. and Grambsch, P. M. (2000). *Modeling Survival Data: Extending the Cox Model*, Springer, New York.
- Trivedi, K. S. (2016). *Probability & Statistics with Reliability, Queuing and Computer Science Applications*, 2nd ed., John Wiley & Sons, Hoboken.
- Wu, S. (2019). A failure process model with the exponential smoothing of intensity functions, *European Journal of Operational Research*, **275**(2), 502–513.
- 山中卓, 中川秀敏, 杉原正顕 (2017). Hawkes過程による信用リスク伝播のモデリングとその応用, *応用数理*, **27**(1), 5–12.

Application of Reliability Analysis to Sports Injury Prediction: A Case Study for Sumo Wrestlers

Shuhei Ota¹ and Mitsuhiro Kimura²

¹Faculty of Engineering, Kanagawa University

²Faculty of Science and Engineering, Hosei University

Sports injury prediction is a way to evaluate the risks of injuries that may occur in athletes in the future. In recent years, based on event history data, several methods have been proposed to assess and predict injury risk in athletes over time. In this paper, we explain stochastic models using point processes to model sports injury occurrences and how to apply the model to injury prediction. Besides, via a case study of injury prediction for professional sumo wrestlers, a self-exciting point process that can consider sequential injury occurrences is useful for precise injury prediction. Furthermore, to reinforce the validity of the model, we newly investigate the predictive accuracy of the model using data that is not used to estimate the parameters of the predictive model, which was not revealed in previous studies on predicting injuries to sumo wrestlers. Finally, we discuss some future works of injury prediction from the viewpoint of its application to injury prevention.