

## 機械学習の手法を用いたスポーツタレント発掘・育成事業の合否予測モデルの構築

村田和隆<sup>1) 2)</sup>, 鶴木秀夫<sup>3)</sup>, 谷所 慶<sup>4)</sup>, 矢野琢也<sup>5)</sup>, 賀屋光晴<sup>6)</sup>, 長野 崇<sup>7)</sup>, 高田義弘<sup>8)</sup>, 平川和文<sup>9)</sup>

# The Prediction Model for Pass or Fail in the Sports Talent Identification and Development Project with Machine Learning.

Kazutaka Murata, Hideo Ikarugi, Kei Tanisho, Takuya Yano, Mitsuharu Kaya, Takashi Nagano,

Yoshihiro Takada, Kazufumi Hirakawa

### Abstract

The purpose of this study is to construct a prediction model for pass/fail of the selection meeting with machine learning using data of children who participated in the selection meeting of Hyogo Junior Sports Academy (HJSA), a sports talent identification and development project of Hyogo prefecture, and to indicate the features that have a large impact on the pass/fail prediction model. The subjects were 982 male and female children in the fourth grade who participated in the HJSA selection meetings between 2014 and 2019, and who were measured in all five fitness tests: the 30-m sprint test time, the standing triple jump, the medicine ball throw, the side-step test, and the T-run test. Twelve variables were used as features: the measured values of the five tests, the estimated values corrected for age, the average of the T-score of the five tests, and the average of the corrected overall T-score of the five tests. Machine learning was performed using decision trees and random forests, with pass/fail as the objective variable.

The AUC (Area Under the Curve) of the constructed pass/fail prediction model by random forest was 98.5% for both males and females, and we were able to construct a model that can predict pass/fail with very high accuracy. From the feature importance, it was found that the total T-score corrected by the age was important for predicting pass/fail for males, while the total T-score without correction by the age was important for females.

**Key Word : Talent Identification and Development, Relative Age Effect, Machine Learning, Random Forest**

キーワード：タレント発掘・育成, 相対年齢効果, 機械学習, ランダムフォレスト

## I. 緒言

独立行政法人日本スポーツ振興センターは、タレント

発掘・育成 (Talent Identification and Development : 以下, TID) に携わる関係団体等が連携し, 日本全体として国際舞台で活躍するアスリートを発掘・育成するシステム

- 1) 太成学院大学人間学部  
Faculty of Human Studies, Taisei Gakuin University  
〒587-8555 大阪府堺市美原区平尾1060-1  
1060-1 Hirao, Mihara, Sakai, Osaka, 587-8555, JAPAN
- 2) 神戸大学大学院人間発達環境学研究所 - 博士課程後期課程  
Graduate School of Human Development and Environment,  
Kobe University  
〒657-8501 兵庫県神戸市灘区鶴甲3丁目11  
3-11 Tsurukabuto, Nada, Kobe, Hyogo, 657-8501, JAPAN
- 3) 兵庫県立大学国際商経学部  
School of Economics and Management, University of Hyogo  
〒651-2197 兵庫県神戸市西区学園西町8-2-1  
8-2-1 Gakuennishi, Nishi, Kobe, Hyogo, 651-2197, JAPAN
- 4) 関西大学人間健康学部  
Faculty of Health and Well being, Kansai University  
〒590-8515 大阪府堺市堺区香ヶ丘町1-11-1  
1-11-1 Kaorigaoka, Sakai, Sakai, Osaka, 590-8515, JAPAN
- 5) 兵庫大学健康科学部  
Faculty of Health Science, Hyogo University  
〒675-0195 兵庫県加古川市平岡町新在家2301  
2301 Sinzaikae, Hiraoka, Kakogawa, Hyogo, 675-0195, JAPAN

- 6) 兵庫医療大学共通教育センター  
General Education Center, Hyogo University of Health  
Sciences  
〒650-8530 兵庫県神戸市中央区港島 1-3-6  
1-3-6 Minatojima, Chuo, Kobe, Hyogo, 650-8530, JAPAN
- 7) 大阪国際大学人間科学部  
Faculty of Human Sciences, Osaka International University  
〒570-8555 大阪府守口市藤田町6-21-57  
6-21-57 Fujita, Moriguchi, Osaka, 570-8555, JAPAN
- 8) 神戸大学大学院人間発達環境学研究所  
Graduate School of Human Development and Environment,  
Kobe University  
〒657-8501 兵庫県神戸市灘区鶴甲3丁目11  
3-11 Tsurukabuto, Nada, Kobe, Hyogo, 657-8501, JAPAN
- 9) 神戸大学名誉教授  
Professor Emeritus, Kobe University  
〒657-8501 兵庫県神戸市灘区鶴甲3丁目11  
3-11 Tsurukabuto, Nada, Kobe, Hyogo, 657-8501, JAPAN

を構築することを目的として WPN（ワールドクラス・パスウェイ・ネットワーク）を設立し、2021年12月時点で日本全国で43地域が加盟していると報告している（日本スポーツ振興センター、2021）。それぞれの地域 TID 事業の大きな特徴として、衣笠ら（2018）は3つの TID のタイプ（種目適正型、種目特化型、種目最適（転向）型）があると報告している。種目適正型での TID 事業を行っている福岡県タレント発掘実行委員会事務局（2010）の報告によると、福岡県では小学4年生から中学1年生を対象として、基本的な運動能力、神経系、コーディネーション能力の測定と個人面接、保護者ヒアリングを行い、TID 事業に参加できる児童を選考していると報告している。同じく種目適正型であり、2009年より兵庫県での TID 事業を実施しているひょうごジュニアスポーツアカデミー（以下、HJSA）は、県内の小学4年生から6年生を対象に毎年4月に選考会を行っている（矢野ら、2017）。測定項目は身長、体重の形態測定と、30m 走、立ち3段跳び、メディシンボール投げ、反復横跳び、T字ランの5種目としており、測定値を月齢によって補正する独自の選考方法を採用し、相対年齢効果（relative age effect：以下、RAE）の最小化を試みている（鶴木ら、2017）。真のタレントを発掘・育成するためには、過去の選考会のデータや HJSA を修了したアスリートのデータなどの様々な種類や形式のデータ（ビッグデータ）を基にして、将来世界で活躍する可能性が高いタレントを発掘する手法を検討していく必要がある。しかし、ビッグデータを手作業で処理するためには膨大な時間とコストが必要となり、地域 TID 事業のように潤沢な資金やマンパワーが確保できない環境においては、既存の方法に頼らざるを得ない状況が続いている。また、先述の月齢以外にも両親の身長や生活習慣、精神的な能力など、様々な要因がジュニアアスリートの成長には影響を及ぼすと考えられ、それらのデータを含めた将来予測を行うためには、従来の手法だけでは不十分であると考えられる。そこで、本研究では TID 事業の選考における新たな試みとして、人工知能（Artificial Intelligence：以下、AI）の研究テーマの一つである機械学習に注目した。

総務省（2016）は、平成28年版情報通信白書の中で AI を中心とする ICT（Information and Communication Technology）の進化は、非定型的な知的業務や複雑な手仕事業務においても将来的には代替が及ぶものと見られておりと報告しており、AI の研究テーマの一つである機械学習は大量のデータからルールや知識を自ら学習する（見つけ出す）技術であるとも報告している。機械学習には大きく分けて、教師あり学習、教師なし学習、強化学習の3つの分析手法があるとされており（秋庭ら、2019）、TID 事業の選考会のように参加者の合否が明確なデータを用い

て分析を行う際には、教師あり学習を用いることができる。また、教師あり学習の中でも合格、不合格というカテゴリを予測する問題を分類問題と呼び、AI に過去の選考会の合否結果を学習させることによって、選考会に参加した児童の合否を予測する機械学習モデルを構築することができる。機械学習を行うための手法は様々考案されているが、鈴木（2004）は決定木に基づく方法は最も頻繁に用いられる機械学習手法といっても過言ではない、と報告しており、実際に決定木を用いた機械学習の手法は、工業、商業、農業、科学、医学、法学などの種々の領域において用いられているとされている。決定木を利用して機械学習を行うことの利点として、学習に使用した特徴量がどのくらい予測値に影響を与えるかという重要度を示すことができることが挙げられる（飯山、2015）。この特徴量重要度は、特徴量がモデルの精度にどの程度寄与しているかを示すことができる指標であり、どの特徴量が最も予測精度に影響を及ぼしているかを示すことができる。さらに、決定木を進化させた手法にランダムフォレスト（Random Forest：以下、RF）があり、これは Breiman（2001）によって提案された機械学習のアルゴリズムの一つで、複数の決定木の弱学習器を統合させて汎化能力を向上させるアンサンブル学習アルゴリズムであり、波部（2016）は、RF は気軽に利用できる機械学習アルゴリズムとして識別・回帰・クラスタリングなどのタスクに広く利用されていると報告している。McKenzie（2015）は、RF の手法を用いて NFL（National Football League）に入団する大学選手の選考を支援する機械学習モデルを構築し、クォーターバック、ランニングバック、ワイドレシーバーの各ポジションについて、NFL ドラフトの精度を向上させることが可能であるとの報告をしている。また、Karnuta et al.（2020）は、2000年から2017年の MLB（Major League Baseball）選手データ（野手：1931人、投手：1245人）の年齢、パフォーマンス指標、傷害歴などのデータから、傷害リスクと傷害部位ごとの機械学習モデルを構築し、投手の背部の傷害予測では RF を用いた手法が最も優れた予測精度を示していたと報告している。しかし、日本国内でこのような機械学習の手法を用いた TID 事業に関する研究は見られず、AI を活用した選考がどのくらいの精度で行え、活用できるかについては未知数である。

そこで、兵庫県の TID 事業である HJSA の選考会に参加した児童のデータを利用し、機械学習の手法を用いて選考会の合否予測モデルを構築すること、並びに特徴量重要度から、合否予測モデルに及ぼす影響が大きい特徴量を示すことを、本研究の目的とした。

## II. 方法

### 1. 調査対象者と調査の手続き

対象者は2014年から2019年の間にHJSAの選考会に参加した小学4年生の男女児童のうち、後述する30m走、立ち3段跳び(以下、立3段跳)、メディシンボール投げ(以下、MB投)、反復横跳び(以下、反復横跳)、T字ランの5種目を全て測定した児童982名(男子635名、女子347名)とした。表1に選考会参加者の男女別合否人数を示す。

表1 選考会参加者の男女別合否人数

	男子	女子	計
合格	77	70	147
不合格	558	277	835
計	635	347	982

### 2. HJSAの選考方法について

HJSAの選考基準は事業開始以来、RAEを考慮した選考方法を用いてきた(鷗木ら, 2017)。これは、この年代の運動能力にはRAEが大きいこと、つまり生まれ月によって運動能力の差ではなく、発育能力の差が大きいことを考慮し、過去の選考会参加者全員を学年・性別に分けて、月齢と各測定値の直線回帰式を算出し、内挿法による同一月齢時の推定値を用いて補正を行うものである。これら補正值のTスコアの総合点を基準とし、競技成績なども加味し、HJSA実行委員会が総合的に判断をして、各学年男女あわせて25名程度になるように選考を行っている。

### 3. 測定項目と測定方法

測定種目は30m走、立3段跳、MB投、反復横跳、T字ランの5種目とし、体格要素として身長と体重を測定し

た。全ての測定は屋内体育館で実施し、説明および示範の後、1回の練習試技を行い、測定を行った。

#### 1) 30m走

光電管(TP-20, 玉川商店)をスタートラインとゴール30mに配置し、スタートラインから1m後方にスタンディングスタートの姿勢で位置し、測定員の合図でスタートしてゴールまでの所要時間を測定した。試技は1回とし、スリップなどで走行に明らかな支障が生じたと思われる場合は、再試技を行うものとした。

#### 2) 立3段跳

ライン中央に両つま先を合わせ、左右交互での3歩跳躍を行わせた。ライン中央から、着地した後ろ足の踵の地点までの距離を測定した。後方に足以外の部位が着いた場合にはその地点を測定し、2回の試技で良い方の記録を採用した。

#### 3) MB投

1kgのメディシンボールを両手で保持し、助走をつけずに下手投げで投げさせ、ラインからボールの中心が着地した地点までの距離を測定した。投球後は足が線を踏み越しても良いこととし、連続して2回の投球後、良い方の記録を採用した。

#### 4) 反復横跳

文部科学省が実施する新体力テスト実施要項(6歳~11歳対象)(文科省, 2000)の反復横跳の測定プロトコルに従い、中央ラインから両側100cmのところに2本の平行ラインを引いた。児童は中央ラインをまたいで立ち、測定員の合図でスタートさせた。それぞれのラインを通過するごとに1点を与え、20秒間の合計点数を測定した。2回の試技で良い方の記録を採用した。

#### 5) T字ラン

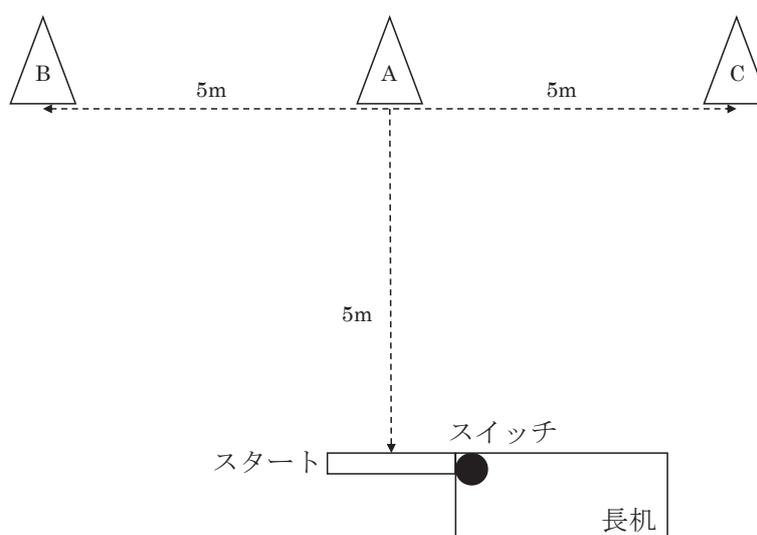


図1 T字ランの測定方法

図1に示す通り、児童はスタートラインから足がはみ出さないように立ち、右手で長机上のスタートスイッチを押してスタートする。Aを回ってスタート位置に戻ってラインを踏むあるいは踏み越した後に再びAに走り、Aの上側を回ってBまたはCの下側を回る。Bの下側を回った場合はAの上側を通過してCの下側を回り、Cの下側を回った場合はAの上側を通過してBの下側を回る。その後Aの上側を回って長机上のスイッチを押し、経過した時間を測定した。2回の試技で良い方の記録を採用した。

#### 4. 月齢による補正とTスコアの算出

##### 1) 月齢による補正

前述の通り、過去の選考会参加者全員を男女別に分け、月齢と各測定値の直線回帰式を算出し、内挿法による同一月齢時の推定値を補正值として扱った(以下、補正值)。

##### 2) 測定値と補正值のTスコアの算出

男女別に各測定種目ごとのTスコアを算出し、5種目のTスコアの平均値を総合Tスコアとして算出した。補正值についても同様に各測定種目ごとのTスコアを算出し、5種目の補正值のTスコアの平均値を補正総合Tスコアとして算出した。

#### 5. 決定木とRFの手法を用いた機械学習

##### 1) 機械学習モデルの構築

機械学習を行う際は全てのデータを学習に用いるのではなく、例えば80%対20%の割合でデータを分割し、80%のデータを訓練データとして機械学習を行い、作成した学習モデルに20%のテストデータを適用して、どのくらいの誤差があるかを検証する手法が一般的である。本研究では2014年から2018年のデータを訓練データ、2019年のデータをテストデータとして設定し、表2に示す通りデータセットを設定して機械学習を行った。まず初めに訓練データを利用して、5種目の測定値、5種目の補正值、総合Tスコア、補正総合Tスコアの合計12個の変数の特徴量とし、合格を1、不合格を0とした2分類値を目的変数と設定して、決定木とRFの手法を用いた機械学習を行うことによって、合否予測モデルを構築した。

決定木は学習するデータを条件分岐によって分割していくことで分類問題を解く手法であり、分割する際には、不純度という乱雑さを数値化したものを利用する。決定木では、データの乱雑さを表す不純度が小さくなるようにデータを分割していき、分割されたグループに同一の特徴量ラベルが多く存在するときに不純度は小さくなり、逆に、分割されたグループに異なる特徴量ラベルが多く存在すると不純度が大きくなる。不純度の指標として、本研究ではジニ係数(G)を利用し、式(1)を用いて算出した。

ここで、 $c$ は分類の数を示しており、本研究においては

$$G = 1 - \sum_{i=1}^c p(i)^2 \quad (1)$$

合格と不合格の2である。 $p(i)$ はある特徴量の数をデータ数で割ったものである。決定木の学習は、図2のような空間の分割を繰り返すことで行われ、最終的に合格か不合格の予測を行うことができる。それぞれのデータグループをノードと呼び、あるノードに対して分岐前のノードを親ノード、分岐後のノードを子ノードと呼ぶ。

RFは複数の決定木を利用することで精度を高めることができる手法で、ブートストラップ法と呼ばれる1つの訓練データから何度もランダムに復元抽出を行うことで学習データを水増しする方法を用いる。さらに、訓練データから決定木を学習させる際に、一部の特徴量だけをランダムに用いて学習させることによって学習を行っている。このように「ブートストラップ法」と「特徴量のランダムな選択」という2つの工夫によって、多様性をもった決定木を学習させることができる。

構築した合否予測モデルにテストデータの5種目の測定値、5種目の補正值、総合Tスコア、補正総合Tスコアの合計12個の変数の特徴量として適用することで、合否の予測確率を0%から100%で算出することができる。本研究では50%を閾値として設定し、合格確率が50%以上の場合は合格、50%未満の場合は不合格と予測した。図3に本研究で行った機械学習のプロセスイメージを示した。

表2 男女のデータセット

	訓練データ	テストデータ	合計
男子	525(82.7%)	110(17.3%)	635
女子	283(81.6%)	64(18.4%)	347

##### 2) 構築した合否予測モデルの検証方法

テストデータは2019年に行われた選考会の実際の合否情報を含んでいるため、合否予測モデルに適用して予測した合否を実際の合否と比較することによって、構築した合否予測モデルの精度を検証することができる。機械学習の分類の手法で一般的に用いられている手法として、混合行列を作成し、正解率(Accuracy)を算出する手法がある。混合行列はTP(True Positive)、TN(True Negative)、FP(False Positive)、FN(False Negative)の4つで示される行列のことであり、図4のように示すことができる。TPはAIが合格と予測し、実際に合格であった人数を示し、一般に真陽性と評価される。また、TNはAIが不合格と予測し、実際に不合格であった人数を示し、一般

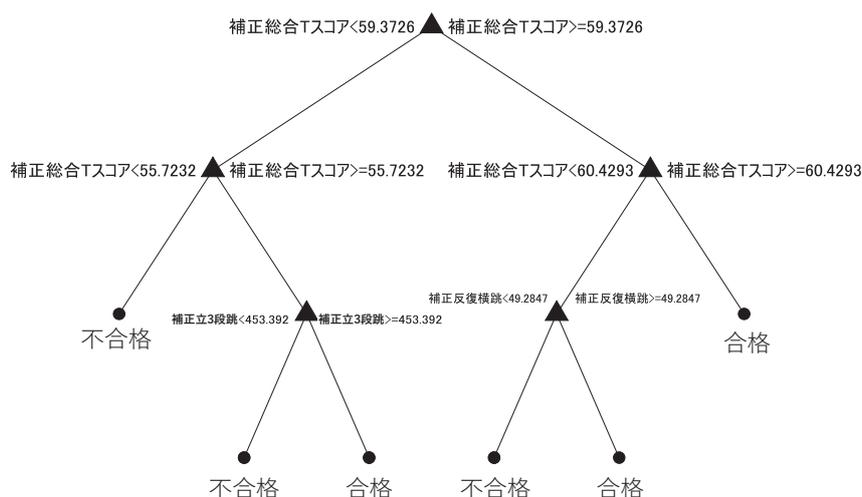


図2 決定木の学習イメージ

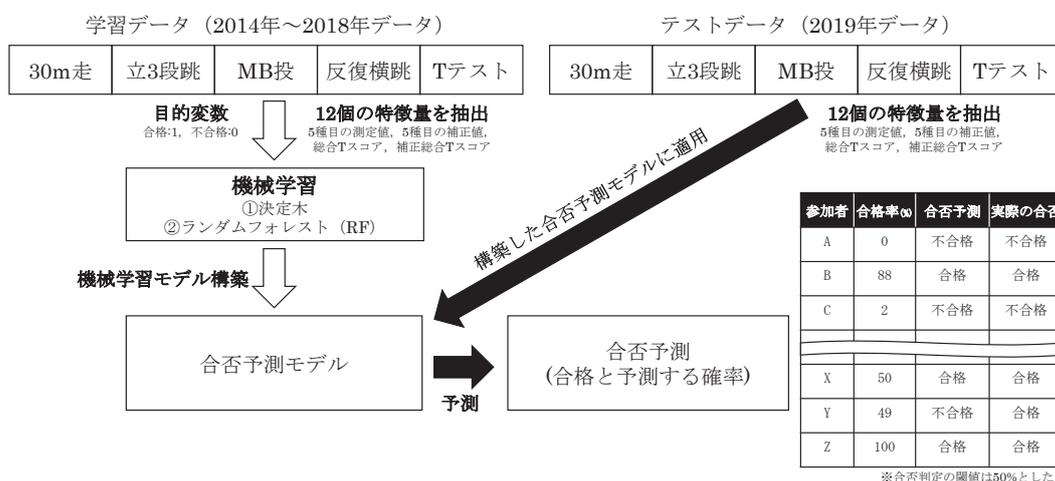


図3 機械学習のプロセスイメージ

に真陰性と評価される。一方でFPはAIが合格と予想したにも関わらず、実際は不合格であった人数を示し、一般に偽陽性と評価される。FNはAIが不合格と予想したにも関わらず、実際は合格であった人数を示し、一般に偽陰性と評価される。学習モデルの精度を検証するために、AIがどのくらいの割合で正しく予測ができていたかを検証するために、Accuracyを式(2)を用いて算出した。

Accuracyは直感的に機械学習モデルの精度を評価できる簡便さがある反面、不均衡なデータを扱う場合にはうまく機能しない場合があるとされている(秋庭ら, 2019)。本研究においては2019年の選考会に参加した4年生男子のうち、合格者は14名、不合格者は96名であり、その割合は12.7%対87.3%であった。また、4年生女子のうち、合格者は10名、不合格者は54名であり、その割合は15.6%対84.4%であった。これらのことから、例えば全ての参加者を不合格と予測するような合否予測モデルを構

築すると、4年生男子のAccuracyは87.3%、4年生女子のAccuracyは84.4%という予測を出力することになる。このような不均衡データに対応するための指標として、AUC (Area Under the Curve) が用いられている。AUCを算出するためには、まずはROC (Receiver Operating Characteristic) 曲線と呼ばれる偽陽性率 (False Positive Rate) というFPの割合を横軸に、真陽性率 (True Positive Rate) というTPの割合を縦軸にしたグラフで表現することができ、予測確率に対してどこから陽性にするかという閾値を1からすこしずつ下げていったときの、FPとTPの関係を示すものである。このROC曲線の下側面積がAUCであり、AUCが1に近づく(面積が大きい)ほど精度が高いことを示し、0.5付近の値では精度が低いことを示している。

$$\text{Accuracy} = \frac{TP+}{TP+TN+FP+FN} \quad (2)$$

		予測	
		不合格	合格
実測	不合格	TN (True Negative) 真陰性	FP (False Positive) 偽陽性
	合格	FN (False Negative) 偽陰性	TP (True Positive) 真陽性

図4 機械学習の分類における混合行列

## 3) 特徴量の重要度の算出

一般に、予測モデルには予測精度と解釈性のトレードオフが存在するといわれており、従来の統計モデルは比較的シンプルな設計なので解釈性が高く、近年の機械学習モデルは高い精度を誇るが解釈性は低いという特徴を持つとされている(森下, 2021)。そこで、決定木を作成する中で特徴量の重要度を示すことによって、機械学習モデルの解釈性を高める工夫がなされている。それぞれの決定木は特徴量のある値を境に分割することで、不純度をできるだけ小さくするように学習を行う。そこで、ある特徴量で分割したときの不純度を、RF に用いた決定木全体で平均することによって、ある特徴量  $j$  における重要度  $I(j)$  を算出することができる(式(3))。

$$I(j) = \sum_{i=1}^{n \in F(j)} (N_{parent}(i) \times G_{parent}(i) - (N_{left\_child}(i) \times G_{left\_child}(i) + N_{right\_child}(i) \times G_{right\_child}(i))) \quad (3)$$

ここで、 $F(j)$  はある特徴量  $j$  が分割対象となるノードの集合、 $N_{parent}(i)$  はあるノード  $i$  におけるサンプル数、 $N_{right\_child}(i)$  はあるノード  $i$  の子ノードのうち左側のノードのサンプル数、 $N_{right\_child}(i)$  はあるノード  $i$  の子ノードのうち右側のノードのサンプル数、 $G_{parent}(i)$  はあるノード  $i$  におけるジニ係数、 $G_{left\_child}(i)$  はあるノード  $i$  の子ノードのうち左側のノードにおけるジニ係数、 $G_{right\_child}(i)$  はあるノード  $i$  の子ノードのうち右側のノードにおけるジニ係数を示している。

## 4) データ処理

機械学習モデルを構築する際に必要となるデータ処理は、MATLAB R2021a (Mathworks 社製) の Statistics and Machine Learning Toolbox を利用して行った。

## III. 結果

## 1. 構築した合否予測モデルの精度

表3に決定木とRFによって構築した合否予測モデルの精度に関する指標

表3 決定木とRFによって構築した合否予測モデルの精度に関する指標

	決定木						RF					
	TP	TN	FP	FN	Accuracy	AUC	TP	TN	FP	FN	Accuracy	AUC
男子	11	94	2	3	95.5%	97.4%	10	95	1	4	95.5%	98.5%
女子	9	50	4	1	92.2%	90.7%	10	48	6	0	90.6%	98.5%

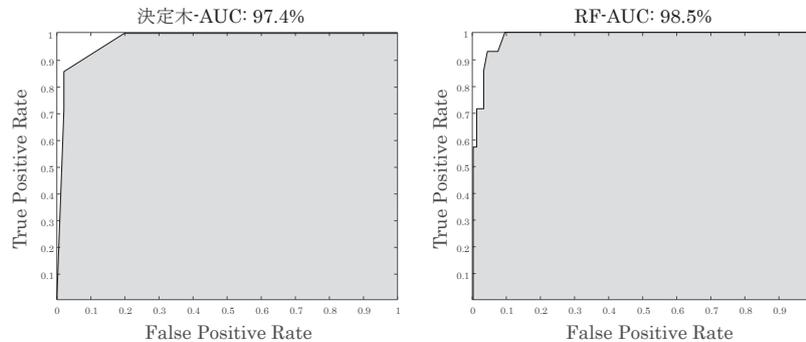


図5 4年生男子のROC曲線とAUC

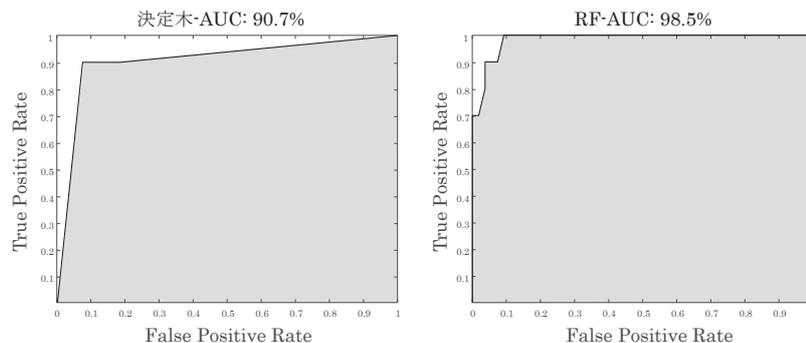


図6 4年生女子のROC曲線とAUC

精度に関する指標を示した。また、AUCはROC曲線の下部面積から算出しており、図5に4年生男子の決定木とRFから作成したROC曲線とAUCを、図6に4年生女子の決定木とRFから作成したROC曲線とAUCをそれぞれ示している。4年生男子の決定木-AccuracyとRF-Accuracyはいずれも95.5%、決定木-AUCは97.4%、RF-AUCは98.5%であった。4年生女子の決定木-Accuracyは92.2%、RF-Accuracyは90.6%、決定木-AUCは90.7%、RF-AUCは98.5%であった。

## 2. 特徴量の重要度

RFの手法を用いて構築した合否予測モデルから特徴量の重要度を算出し、図7に男女別の特徴量重要度を降順に示した。4年生男子は、補正総合Tスコアが最も重要度が高く、次いで総合Tスコア、補正立3段跳の順に重要度が高くなっている。4年生女子は、総合Tスコアが最も重要度が高く、次いで補正総合Tスコア、補正30m走の順に重要度が高くなっている。

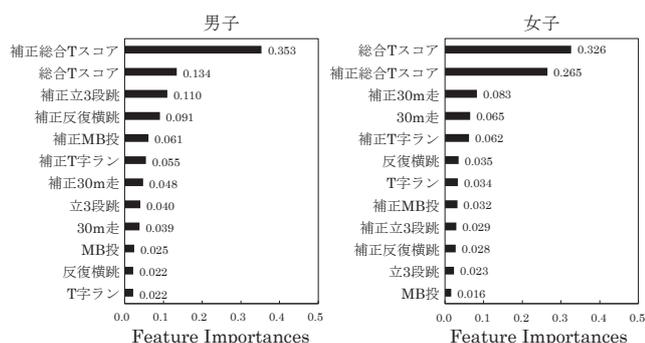


図7 特徴量重要度

## IV. 考察

本研究の目的は、2014年から2019年に兵庫県のTID事業であるHJSAの選考会に参加した児童のデータを利用し、機械学習の手法を用いて選考会の合否予測モデルを構築すること、並びに特徴量重要度から測定項目の選考会の合否に影響する重要度を示すことであった。RFによる合否予測モデルは男女ともに高い精度で合否予測が可能モデルを構築することができ、構築した合否予測モデルを利用することで、選考会参加児童の合格確率を0%から100%で示すことができた。また、特徴量重要度から、男子は月齢による補正総合Tスコアが合否予測にとっては重要であり、女子は月齢による補正を行わない総合Tスコアが重要であることが分かった。以下に詳細な考察を示す。

### 1. 男女の合否予測モデルの検証

決定木は、機械学習に使用した訓練データについては高い識別性能を有するものの、訓練データに含まれない

未知のデータに対しては識別性能が低くなるという過学習 (over fitting) を起こしやすいモデルとされており (飯山, 2015)、訓練データに含まれていないデータ、つまり別のデータに対する性能が重要であるとされている (秋庭ら, 2019)。過学習を防ぐための代表的な方法として、訓練データとテストデータに分割する手法 (秋庭ら, 2019) やRFを用いる手法 (飯山, 2015) が挙げられる。本研究は、2014年から2018年の選考会に参加した4年生男女児童のデータを訓練データとして合否予測モデルを構築し、2019年のデータをテストデータとして検証を行った。選考会に参加した児童は完全に異なっており、訓練データとテストデータで重複しているデータは含まれておらず、かつRFの手法を用いてAUCを算出しているため、過学習を起こしている可能性は低いと考えられる。以上の事を踏まえて、選考会に参加した男女児童の合否予測モデルの精度を考察していく。

4年生男子は、表3に示した通り、男子の決定木-AUCは97.4%、RF-AUCは98.5%であり、非常に高い精度で合否予測が可能となる機械学習モデルが構築できたと考えられる。また、決定木よりもRFの手法の用いた方がAUCが向上しており、選考会の合否予測モデルを構築する際には、RFの手法を用いた機械学習を行うことが有効であることが示唆された。

4年生女子は、表3に示した通り決定木-AUCは90.7%、RF-AUCは98.5%であり、非常に高い精度で合否予測が可能となる機械学習モデルを構築することができたと考えられる。また、男子と同様に決定木よりもRFの手法を用いた方がAUCが向上しており、選考会の合否予測モデルを構築する際には、RFの手法を用いた機械学習を行うことが有効であることが示唆された。

以上の事から、過去の選考会のデータを利用して機械学習を行うことによって、選考会の合否予測モデルを構築することができ、RFの手法を用いた合否予測モデルを利用することで、男女ともに98.5%の精度で合否予測が可能となることが示唆された。

### 2. 特徴量重要度からみた男女の特徴

図7に示した通り、4年生男子の特徴量重要度では、補正総合Tスコアが最も重要度が高く、次いで総合Tスコア、月齢によって補正した補正立3段跳の順に重要度が高くなっていた。特徴量重要度はあくまで機械学習を行う際の特徴量がどのくらいの割合で予測に寄与しているかを示す数値であるため、特徴量重要度が低い種目が選考において不要であるという事ではない。森下 (2021) は、特徴量重要度はモデルを解釈していくファーストステップとして、モデルのふるまいの外観をつかむ用途には適しているとしているが、一方で特徴量重要度からは、各特徴量と

モデルの予測値の関係を知らることができないと述べている。つまり、今回構築した4年生男子の合否予測モデルでは、補正総合Tスコア、総合Tスコア、補正立3段跳の順番で予測結果に影響を及ぼし、重要度の値が低いT字ラン、反復横跳、MB投はあまり予測結果に影響を及ぼさないという事実を示しているに過ぎない。今回構築した合否予測モデルは、30m走、立3段跳、MB投、反復横跳、T字ランの5種目において構築した機械学習モデルのため、種目が少なくなったり多くなったりすることで予測の精度は変化すると考えられる。そのため、HJSAが実施している選考会で行っている5種目が適切かどうかまでは判定することは難しいが、補正総合Tスコアの特徴量重要度(0.353)が総合Tスコアの特徴量重要度(0.134)よりも2倍以上の値を示していたことから、月齢によって補正した総合Tスコアを選考の指標として用いることは妥当であると考えられる。これは月齢による補正を行うことによって、生まれ月の影響を低くすることができるという鶴木ら(2017)の報告と一致し、4年生男子においては、月齢による補正を行って算出した補正総合Tスコアが選考に及ぼす影響は大きいと推察される。

一方で、4年生女子の特徴量重要度では、総合Tスコアが最も重要度が高く、次いで補正総合Tスコア、補正30m走の順に重要度が高くなっていった。男子とは反対に、総合Tスコアの特徴量重要度(0.326)が補正総合Tスコアの特徴量重要度(0.265)よりも大きくなっていったことから、女子は男子よりも補正值が合否予測に与える影響は低いと推察される。ただし、補正総合Tスコアは2番目に重要な特徴量であること、補正30m走と補正T字ランの重要度は補正を行わない30mとT字ランの重要度よりも高いことから、RAEの影響を少なくするために効果的な補正を今後も検討していく必要があると考えられる。

## V. 今後の課題と展望

HJSAの選考会は4年生男子、4年生女子、5年生男子、5年生女子、6年生男子、6年生女子の6つのカテゴリに分けて選考を行っている。本研究では選考会に参加する児童のうち、最も参加者が多いカテゴリである4年生男子児童と2番目に参加者が多いカテゴリである4年生女子児童を対象とした。選考された児童は、基本的には小学校卒業まで継続的に事業に参加できるため、5・6年生の合格者は退会者を補充する程度で数名となっており、5・6年生の合格者は少なくなっている。さらに、既にHJSAに参加している児童も現時点での能力を測定する目的で選考会に参加しており、初めて選考会に参加する5・6年生の男

女児童の数は4年生男女児童の数よりも極端に少なくなったため、本研究の対象からは除外した。今後は、引き続き選考会のデータを収集しながら、5・6年生の選考会参加児童においても合否予測モデルの構築が可能かどうかを検討していく必要がある。

また、AIの判断で全ての合否を判定できる訳ではなく、TID事業の選考に合格できるかどうかは、児童の将来のアスリートとしての可能性を決定づける要因ともなりうるため、最終的な選考は人為的な介入が不可欠であると考えられる。さらに、選考会の時点から児童が将来どこまで成長するかは未知数であり、完全な予測を行うことは非常に難しい。しかし、HJSAは事業開始から13年を超え、大学生や社会人として活躍している修了生も増えてきており、そのような修了生のデータを収集することによって、選考会の時点からアスリートとしてどのくらいの成長が見込めるかを予測することができるようにもなり、国際舞台で活躍するアスリートを発掘・育成するシステムとして大いに活用できると考えられる。そのためには、WPNや他の地域TID事業などと連携を取りながら、計画的にTID事業を行っていくことが必要であると考えられる。

## VI. まとめ

HJSAは2009年に発足後、兵庫県内の小学4年生から6年生を対象に毎年4月に選考会を行ってきた。選考会に参加した児童のデータから、将来世界で活躍する可能性の高いタレントを発掘する手法を検討する中で、本研究では、機械学習の教師あり学習の分析手法に着目し、HJSAにおける選考会の合否予測モデルを構築すること、並びに特徴量重要度から測定項目の選考会の合否に影響する重要度を示すことを目的とした。RFによって構築した4年生男子と4年生女子の合否予測モデルは、いずれも98.5%の精度で合否予測が可能となるモデルであり、非常に高い精度で合否予測が可能となるモデルを構築することができた。また、特徴量重要度から、男子は月齢による補正総合Tスコアが合否予測にとっては重要であり、女子は月齢による補正を行わない総合Tスコアが重要であることが明らかとなり、男女によって補正の効果に差が生じることが明らかとなった。RAEの影響を少なくするための補正を今後も検討していくと同時に、選考会のデータだけではなく、アカデミー修了生のデータも活用することによって、将来世界で活躍できる可能性の高いタレントを発掘していくことが必要であると考えられる。

## VI. 謝辞

稿を終えるにあたり、多大なご支援をいただいた(公財)兵庫県スポーツ協会およびびょうごジュニアスポーツアカデミー実行委員会に深謝する。

## 【参考文献】

- 秋庭伸也, 杉山阿聖, 寺田学, 加藤公一 (2019) 見て試してわかる機械学習アルゴリズムの仕組み 機械学習図鑑 (3) . 翔泳社, pp.80-85, pp.148-156.
- Breiman, L. (2001) Random Forests. *Machine Learning* 45 : 5-32.
- 福岡県タレント発掘実行委員会事務局 (2010) 福岡県タレント発掘事業の取り組み . *トレーニング科学*, 22 (3) : 169-180.
- 波部斉 (2016) ランダムフォレストの基礎と最近の動向 . *映像情報メディア学会誌*, 70 (9) : 788-791.
- 飯山将晃 (2015) 使える!統計検定・機械学習-IV : Random Forests を用いたパターン認識 . *システム/制御/情報*, 59 (2) : 71-76.
- 鷗木秀夫, 平川和文, 谷所慶, 矢野琢也, 賀屋光晴, 長野崇, 村田和隆, 高田義弘 (2017) 兵庫県スポーツタレント発掘・育成事業の選考方法について—相対年齢効果の視点から—. *陸上競技研究紀要*, 13 : 37-42.
- Karnuta, J. M., Luu, B. C., Haeberle, H. S., Saluan, P. M., Frangiamore, S. J., (2020) Machine Learning Outperforms Regression Analysis to Predict Next-Season Major League Baseball Player Injuries. *Orthop J Sports Med*, 8 (11) .
- 衣笠泰介, 藤原昌, 和久貴洋, Gulbin, J (2018) 我が国におけるタレント発掘・育成に関する取組の変遷 . *Sports Science in Elite Athlete Support*, 3 : 15-26.
- McKenzie G. (2015) Data analytics in sports : improving the accuracy of NFL draft selection using supervised learning. University of Missouri-Columbia. Graduate School. Theses and Dissertations.
- 文部科学省 (2000) 新体力テスト—有意義な活用のために—. *ぎょうせい*, pp.77-96.
- 森下光之助 (2021) 機械学習を解釈する技術 . 株式会社技術評論社, pp.2-5.
- 日本スポーツ振興センター (2021) ワールドクラス・パスウェイ・ネットワーク . <https://pathway.jpnsport.go.jp/wpn/index.html> (2022年2月14日参照) .
- 総務省 (2016) 総務省—平成28年版情報通信白書 . 第4章 ICTの進化と未来の仕事, 第2節 人工知能 (AI) の

現状と未来 : 232-241.

鈴木英之進 (2004) 正確な学習よりも得する学習—誤分類コストを考慮する分類学習— (2) 解決編 . *情報処理*, 45 (5) : 500-505.

矢野琢也, 鷗木秀夫 (2017) 兵庫県のタレント発掘・育成事業 . *子どもと発育発達*, 14 (4) : 315-322.

(2022年2月28日受付)  
(2022年5月23日受理)

