

競技かるたにおける動作の時系列状況認識手法の検討

A Preliminary Study on Sequential Activity Recognition in Competitive Karuta

武市 蓮麻[†] 松田 裕貴[†]
Remma Takeichi Yuki Matsuda

1 はじめに

競技かるたは、札の記憶、読手の読み上げに対する迅速な反応、構えや払いなどが高度に複合した競技であり、習得において技術的・身体的ハードルが高い。現在、指導やプレーの振り返りは指導者や熟練者の観察・経験則に大きく依存している [1]。そのため、「どのタイミングで構えが崩れたか」「払いの初動が遅れたか」「無駄な振りが発生しているか」といった身体動作の変化を定量的に分析・評価することは重要と考えられる。

身体動作の定量的把握に向け、近年ではウェアラブルな慣性センサを用いたスポーツ動作解析や行動認識が注目されている [2, 3]。しかし、競技かるた特有の一連の動作は、静止状態からの微小な初動変化や類似した腕の振り動作が短時間に連続して発生するため、時系列データからの正確な状況認識は容易ではない。

そこで本研究では、慣性センサを用いて競技かるたの試合データを収集・構築し、試合中の「構え」「反応」「素振り」などの状態・動作を時系列で認識する手法を検討する。特に、動作の類似性やクラス不均衡が識別精度に与える影響を評価し、階層的な分類アプローチの有効性を明らかにする。本取り組みは、競技かるたにおける初心者支援やプレイスタイル分析を実現するための基礎技術となることを目指す。

2 競技かるたの基礎知識

本研究で対象とする競技かるたの試合における動作特徴を明確にするため、全日本かるた協会が定める競技規程細則 [4] に基づき、試合の進行と競技者の基本動作について述べる。

競技かるたは小倉百人一首を用い、相対する 2 人の競技者間で行われる。取札 100 枚の中から 50 枚を競技に使用し、競技者は無作為に選んだ 25 枚を各々自分の陣に 25 枚ずつ並べ、読手が読み上げる札を取り合うことで、先に自陣を 0 枚にした者を勝者とする。読手は読札 100 枚の中から無作為に選んだ札を 1 枚ずつ、直前に読んだ札の下に続けて次の札の上の札を読み上げ、1 枚目の前には序歌が読まれる。

競技者の動作に関しては、以下のルールおよび動作様式が定められている。




図 1: 競技かるたにおける一般的な状態遷移

- **構え:** 競技者は左右いずれか一方の手を札を取る手（有効手）と定め、競技中の左右変更は認められない。上の句が読み始められるまでは、畳に接した状態で自陣の下段手前に有効手を配置して待機する。
- **取りの成立:** 読手の読み上げる札（以降、出札とする）が競技線内にあるうちに、相手より早く有効手で直接触れるときに取りが成立する（札直接の取り）。共に札直接の取りではなかった場合でも、出札を完全に有効手で競技線外に押し出したときは、取りが成立する（札押しの取り）。なお、出札のない陣にある札に触れた場合は「お手つき」となる。
- **送り札:** 相手陣の札を取った場合、または相手がお手つきをした場合、自陣の持札を 1 枚相手に送ることができる。
- **札の整理:** 乱れた陣を整える際など、読手に読みを待たせる場合は、挙手をするといった明瞭な合図を行う必要がある。

競技かるたの試合中においては、一般的に図 1 に示すような状態遷移を繰り返しながら試合が進行する。

3 関連研究

3.1 競技かるたに関する研究

競技かるたは、数十～数百ミリ秒単位の短い時間枠の中で聴覚情報の処理、意思決定、および高速な運動制御を行う人間行動の典型例であり、近年の情報処理、センサ工学、ヒューマンコンピュータインタラクションなどの学術分野において多角的な研究対象とされている。

競技かるたにおける選手の運動特性の定量化や判定の自動化・客観化を目指した研究において、まず物理センサを用いた直接計測によるアプローチが試みられてきた。

[†] 岡山大学, Okayama University

山田ら [5] は、競技者の手首に装着した 3 軸加速度・3 軸角速度センサから得られる慣性データに基づき、払い動作中の札取得タイミングを推定する手法を提案した。事前に採取した正解データとの比較において、特徴量に基づく手法と動的時間伸縮法 (Dynamic Time Warping: DTW) を用いた波形マッチング手法を検証し、波形マッチング手法を用いることで被験者が異なる場合でも平均誤差 40 ミリ秒以下という精度で札取得タイミングの判定が可能であることを実証した。また、腕や手首の運動にとどまらず下半身の力学的役割に着目した研究として、尾山ら [6] は床面に配置した圧力センサマットを用いて試合中の札取得動作を分析している。試合中における競技者の足圧分布や重心移動の時系列変化を連続的に計測することで、構えから踏み込み、払い動作に至る一連の過程における下半身の力学的作用と姿勢制御の特性を定量的に明らかにした。

一方、競技者へ物理的なセンサや機器を装着させることによる動作への不自然さや阻害を避けるため、カメラ映像を用いた非接触型の解析手法も展開されている。北川ら [1] は、Google の姿勢推定ライブラリ「MediaPipe」を活用し、二次元動画から抽出した三次元骨格情報に基づく可視化システムを構築した。競技かるたの正座姿勢による下半身の遮蔽に対応するため分析対象を主に上半身に特化させ、複数選手の三次元ボーン表示の重ね合わせや右手首位置の時系列グラフ化を実現した。初心者と A 級四段の上級者を比較した実験を通じて、上級者は相手陣遠方の札を払う際に全身の重心移動を活用して手を加速させていることなど、フォームの安定性や熟練度に伴う動作軌道の特徴を定量的に示している。

加えて、競技かるたの身体的タスク構造を応用・拡張するインタフェース研究も展開されている。丸山ら [7] は、VR 空間における百人一首かるた (VR かるた) を構築し、札取り動作を Fitts の法則に基づくポインティングタスクとしてモデル化した。プレイヤーが「不自然さを感じない」認知許容範囲内でターゲットサイズや手の衝突判定の拡大率を調整することにより、対戦者間の実力差を意識させることなくゲームスキルを均衡化させる非知覚型調整手法の可能性を示した。

3.2 本稿の立ち位置

競技かるたを対象とした研究は、手首や床面センサによる物理計測から非接触の三次元骨格解析、さらには VR・インクルーシブ技術に至るまで幅広く体系化されつつある。しかしながら、本研究は試合全体で発生する競技かるた特有の一連の動作シーケンスに着目し、慣性センサから得られる時系列データを用いて連続的な試合展開における動作境界の検知精度向上を目指す点に独自性がある。




図 2: 提案手法の処理フロー

4 提案手法

本研究では、競技かるたにおける初心者への支援やプレイスタイルの分析をしてアドバイスをする「競技かるた支援システム」の実現を目指している。この実現に向けて、慣性センサを用いた選手の動作センシングに基づき、試合中の一連の動作における現在の状況 (シーン) の推定手法を提案する。

提案手法の処理フローを図 2 に示す。まず、体の複数部位に装着した慣性センサから競技中の動作データを計測するとともに、リアルタイムアノテーション手法によるアノテーションをして、両者の時刻を同期させた試合の時系列データを作成する。次に、試合の時系列データを一定時間ごとのウィンドウとして切り出し、多次元の時系列特徴量を抽出する。最終的に、抽出した特徴量を入力としたモデルを構築し、現在の動作状況を認識する精度を検証する。動作状況が認識できれば、札が読まれた時の競技者の動きを推定し、競技者の札へのアプローチのタイプ分類をして、初心者支援やそのタイプに応じた札の払い方の改善や戦略的アドバイスを送るためのシステムの実現につながる。

以下、センサの装着方法、データ収集、アノテーション、特徴量抽出、および認識モデルの各構成要素について説明する。

4.1 使用センサと装着方法

本研究では、小型慣性センサである MetaMotionS^{*1} を用いて有効手側の腕、手首、手の甲、太ももにおける動作を計測した。各部位の装着方法について説明する。図 3a や図 3c では、腕や太ももに対して MetaMotionS を 3D プリンタで作成したカバーで覆い、伸縮バンドを用いて固定している。図 3b では、手首に対して MetaMotionS を 3D プリンタで作成したカバーで覆い、マジックテープを用いて固定している。手の甲に対しては、グローブを作成し、手の甲にポケットを取り付けて MetaMotionS をその中に入れてマジックテープを用いて固定している。

4 つの部位で計測を行ったのは、それぞれの部位が競技かるたの動作特徴を相補的に保持しているためである。腕は札を払う動作の特徴が顕著に現れる部位であり、手首および手の甲は札を取得する際の手の角度変化を捉え

^{*1} <https://mbientlab.com/metamotions/>



(a) 腕



(b) 手首・手の甲



(c) 太もも

図 3: 有効手側の各部位の装着プロトコル




図 4: 試合映像

る部位である。また、太ももは札を払う際の体重移動など、下半身の動作特徴を反映する部位である。

4.2 試合データ収集

動作データの取得においては、MetaMotionS を用いて加速度データとジャイロデータを取得する（サンプリング周波数：200Hz）。加えて、試合と並行して同時にアノテーションを行う。そのために Python を用い図 5 に示す独自のリアルタイムアノテーションアプリを開発した。このリアルタイムアノテーションアプリは、キーボード入力により即時に時系列ラベルを付与し、JSON 形式で出力する機能を有する。具体的なラベル付け方法については 4.3 節で詳述する。なお、アノテーションの修正に用いる目的で、側方カメラで図 4 に示すような試合中の映像を撮影した。

なお、各 MetaMotionS はデバイス内蔵の時刻情報を持つため、4 台のセンサデータは Unix 時間に基づいてプ




図 5: リアルタイムアノテーションアプリ

表 1: 状態・動作カテゴリのラベル一覧

ラベル名	ラベルの説明
待ち	読手の読みを待つ状態
素振り	待ち状態で空振りする動作
構え	札が読まれる直前の状態
反応	札が読まれてからの一連の動作
札を取りに行く	飛ばした札を取りに行く動作
送り札	自陣から相手陣に札を送る動作
札の整理	札を並べて陣を整える動作
その他	上記以外の状態・動作

ログラム上で同期した。さらに、センサ群とリアルタイムアノテーション間の時刻同期には、計測開始時に被験者へ挙手動作を行わせ、そのタイミングを同期マーカーとしてデータの波形オフセットを計算・補正した。

4.3 時系列ラベルの付与

ラベル付与に関して、ラベルカテゴリを「状態・動作」、「取り方」、「読み」、「判定」、「位置」、「接触」とし、状態・動作カテゴリを主ラベル、それ以外のカテゴリは属性ラベルとすることを提案する。要件としては、状態・動作カテゴリのラベルは時系列試合データに必ず一つ存在すること、その他のカテゴリは状態・動作カテゴリの「反応」ラベルのみに付加する形でラベル付けすることとする。本研究では第一段階として、状態・動作カテゴリのラベル推定のみを試行対象とする。状態・動作カテゴリのラベルの一覧を表 1 に示す。

リアルタイムアノテーションによるラベル付けのあとは Label Studio^{*2} を利用して、試合映像を見ながらラベルの誤りの修正や位置ズレの補正といった精緻化を行う（図 6）。

^{*2}<https://labelstud.io/>




図 6: Label Studio でのアノテーションの修正・補正の様子

4.4 ウィンドウ化・特徴量抽出

MetaMotionS による慣性データとアノテーションを同期させたあと、試合ごとにウィンドウを切り出し、スライディングウィンドウ法を適用して特徴量変換を行う。ウィンドウ化に関してはウィンドウサイズを 2 秒とし、ウィンドウストライドを 1 秒としている。ウィンドウごとの特徴量の抽出には、Python で時系列データから特徴量を自動抽出するためのオープンソースライブラリである tsfresh^{*3}を用いて特徴量変換を行う。なお、ラベルに関してはウィンドウごとに多数決により定める。

4.5 モデル構築

特徴量を抽出したデータを入力とし、LightGBM を用いて状況認識モデルを構築する。本稿では、異なる状況に注目した以下の 3 つのモデルを構築する。なお、競技かるたの分析において重要となる「反応」と、動作特性が類似し識別上の課題となりやすい「素振り」の 2 動作を「目的動作」と位置づけて検証を行う。

8 クラス分類 表 1 に示す 8 種類のラベルを対象とした 8 クラス分類モデルを構築する。少数サンプルのクラスが存在するため、ダウンサンプリングについてはデータ数が 1500 件を超えるクラスのみ 1500 件にランダム抽出して、それ以下のクラスは全件保持するようにした。

3 クラス分類 表 1 に示す 8 種類のラベルの中でも、特に競技に関係する「反応」ラベルに着目し、「反応」ラベルと類似する「素振り」ラベルとそれ以外のラベルを「その他」とした 3 クラス分類モデルを構築する。ダウンサンプリングについては、一番少ないラベルの数を上限とした。

2 段階 2 クラス分類 上述の 3 クラス分類における「素振り」「反応」ラベルを統合した「素振り・反応」クラス

とそれ以外のラベルを「その他」クラスとした 2 クラス分類モデルを構築する（以降、Stage1）。さらに Stage1 で「素振り・反応」クラスに分類されたサンプルを入力とし、「素振り」クラスと「反応」クラスに分類する 2 クラス分類モデルを構築する（以降、Stage2）。各学習ともダウンサンプリングについては、一番少ないラベルの数を上限とした。

5 時系列状況認識についての実験

5.1 実験設定

本稿において交差検証に用いるデータとして、被験者に関しては B 級参段の競技かるた経験者 3 名の協力を得て、計 4 試合分の試合データを収集した。試合時間は、各試合約 29 分 0 秒、33 分 27 秒、31 分 56 秒、46 分 11 秒となり、総時間は約 140 分 34 秒である。各試合で被験者は 1 名とし、対戦相手のデータは収集しない設定とした。さらに、被験者 1 名に関しては異なる日に 2 試合分の試合データを収集した。試合に関しては、本稿では競技開始を競技の最初に読まれる序歌の始めとして、競技終了を勝敗が決まり、対戦相手と礼をするまでと定義し、読手として読み上げ機の「ありあけ^{*4}」を使用する。さらに、被験者の条件として右利き限定として、分析条件を統一し、対象外の動作による影響を抑えるために、本稿の実験の被験者に対して競技に支障をきたさない程度の制約を課し、それらを以下に示す。

- 読手に対して手を挙げるときは有効手ではない方を挙げること
- 被験者が競技している以外の試合に関して、飛んできた札を拾うといった関与をしないこと

5.2 評価方法

本稿では、未知の試合に対する性能を評価するため、試合データの中で 1 試合をテストデータとして、残りの試合を学習データとする Leave-One-Game-Out 交差検証（以降 LOGO-CV とする）を利用する。さらに、LOGO-CV における分類器に関して、ラベルの数に偏りがあるためダウンサンプリングにより、シード値を変えて 5 回繰り返す。シード値ごとに 4 試合分の平均を出してから、異なるシード値 5 回分の平均を出し検証をする。ダウンサンプリングは各試合の学習データのみ適用し、テストデータは元のクラス分布を維持した。なお、標準偏差については、ダウンサンプリングの乱数差を表している。分類モデルの評価指標として、混同行列、適合率（Precision）、再現率（Recall）、F1 値（F1-score）を利用する。

^{*3} <https://tsfresh.readthedocs.io/en/latest/>

^{*4} <https://www.moubic.co.jp/ariakemiyabi/ariake/>

表 2: 8 クラス分類における識別性能の評価結果

クラス	Precision	Recall	F1-score
待ち	0.5799	0.3835	0.4613
素振り	0.0632	0.0924	0.0746
構え	0.4894	0.4051	0.4428
反応	0.2302	0.1754	0.1990
札を取りに行く	0.3067	0.5699	0.3987
送り札	0.1104	0.1681	0.1331
札の整理	0.2927	0.5011	0.3690
その他	0.0028	0.0046	0.0034
Macro Avg	0.2594	0.2875	0.2602




図 7: 8 クラス分類における混同行列

5.3 検証結果

本実験では、全試合から抽出した全 25,148 件のデータセット（待ち：10,820 件、構え：5,782 件、札の整理：3,095 件、送り札：1,830 件、札を取りに行く：1,481 件、反応：1,204 件、素振り：805 件、その他：131 件）を用いて各識別モデルの評価を行った。以下に各実験の検証結果を示す。

5.3.1 8 クラス分類における検証結果

8 クラス分類に関して検証した結果として評価結果を表 2、混同行列を図 7 に示す。評価結果および混同行列から、8 クラスを一括で識別するアプローチには、物理的運動の類似性および動的变化の検出限界に起因する課題が存在することが判明した。本研究の目的動作に着目すると、「素振り」の F1-score は 0.0746、「反応」の F1-score は 0.1990 と、いずれも低い値に留まった。「素振り」では、判定されるべきサンプルの 29% が「札の整理」、26% が「送り札」へ誤判定されていた。これは、腕を伸ばす・振

表 3: 3 クラス分類における識別性能の評価結果

クラス	Precision	Recall	F1-score
素振り	0.0721	0.5014	0.1260
反応	0.1836	0.4271	0.2564
その他	0.9614	0.6941	0.8059
Macro Avg	0.4057	0.5408	0.3961

るという上肢の三次元的な動きのベクトルが類似していることに加え、かるた競技特有の一連の動作シーケンス内でこれらの動作領域が時間的に近接して発生するためと考えられる。さらに、「素振り」と判断されるものに腕の振りが強い素振りと弱い素振りが存在しており、広範な動作が含まれていることも要因だと考えられる。「反応」では、判定されるべきサンプルの 33% が「構え」へ誤判定されていた。読手によって札が読み上げられた直後の「反応」は、静止状態である「構え」からの微小な初動変化を捉える必要がある。8 クラス分類モデルでは、静止状態と微小変化の境界閾値を適切に獲得できず、「構え」の延長として埋没してしまったことが示唆される。

5.3.2 3 クラス分類における検証結果

3 クラス分類に関して検証した結果として評価結果を表 3、混同行列を図 8 に示す。評価結果から、対象クラスを 3 つに絞り込んだものの、目的動作である「素振り」の Precision は 0.0721、「反応」の Precision も 0.1836 と低い値に留まった。この要因は、目的動作である「素振り」(805 件) および「反応」(1,204 件) に対し、それら以外の 6 動作をまとめて統合した「その他」クラスが、全データ中 23,139 件（全体の約 92%）を占めるという圧倒的なデータ不均衡に帰着される。混同行列によれば、「その他」クラスの 21% が「素振り」、9% が「反応」と誤判定されている。「その他」の全データ母数が非常に大きいため、わずかなパーセントの誤判定であっても絶対数としての誤検出が膨れ上がり、目的動作の Precision を強力に低下させる現象が浮き彫りとなった。

5.3.3 2 段階 2 クラス分類における検証結果

2 段階 2 クラス分類に関して検証した結果として評価結果を表 4、Stage1 の混同行列を図 9、Stage2 の混同行列を図 10 に示す。Stage1 においては、膨大な「その他」データのうち 82% を正確に非対象動作として棄却することに成功した。これにより、Stage2 へ流出する誤判定を大幅に低減させるフィルター機能を果たしており、目的動作間の細かな局所特徴に集中することが可能となった。結果として、「素振り」の Recall は 0.7675（3 クラス分類における 0.5014 から大幅に向上）、「反応」の Precision は 0.7911 となり、Stage2 単体で Macro F1-score 0.6479




図 8: 3 クラス分類における混同行列




図 9: 2 段階 2 クラス分類 (Stage1) における混同行列

という分類性能であることを確認した。一方で, Stage1 における「素振り・反応」の Recall は 0.5577 にとどまり, 目的動作の約 44% が「その他」として誤って棄却された。これは非対象動作の削減とのトレードオフであり, Stage1 における検出漏れの抑制がシステム全体の最終精度を向上させる上での課題であることも浮き彫りとなった。大規模な非対象動作が存在する時系列動作識別において, 一括で多クラス分類を行うよりも, 判定ステップを階層化させるアプローチが有効であることを支持するものである。

5.4 考察

本実験で得られた 3 つのモデルを比較すると, 膨大な非対象動作が存在する環境下における各アプローチの特性が示された。8 クラス分類や 3 クラス分類では, 動作の類似性や圧倒的なデータ不均衡に起因して目的動作の




図 10: 2 段階 2 クラス分類 (Stage2) における混同行列

表 4: 2 段階 2 クラス分類 (Stage1 および Stage2) における識別性能の評価結果

クラス	Precision	Recall	F1-score
Stage 1 : 素振り・反応 / その他			
素振り・反応	0.2149	0.5577	0.3098
その他	0.9554	0.8221	0.8836
Macro Avg	0.5852	0.6899	0.5967
Stage 2 : 素振り / 反応 (正例のみ)			
素振り	0.5454	0.7675	0.6357
反応	0.7911	0.5709	0.6600
Macro Avg	0.6682	0.6692	0.6479

誤検知や見落としが頻発した。これに対し, 提案する 2 段階分類は, 事前に非対象動作の大半を遮断することで目的動作の検出能力 (Recall) を大幅に向上させ, 非対象動作の棄却に対する有効性を実証した。

各モデルの長所・短所を踏まえると, 将来的なデータ規模や実用環境に応じた選定指針が導かれる。単一モデルによる一括分類は, 処理構造がシンプルな反面データ不均衡に弱い。しかし, 将来的にデータ数が大幅に増加し, 多様なノイズパターンと微小な動作境界をモデルが十分に学習可能となれば, 一括処理の有効性が再評価されることが考えられる。一方, 2 段階分類は, 処理の多段化や初期段階での誤棄却という短所を持つものの, 非対象動作が支配的な環境下においても目的動作の検出能力を確実に確保できる点において, 実用上有効なアプローチといえる。

今後は, 初期段階での見落としを抑える判定閾値の最適化に加え, 時間的な動作の流れを活用したモデルの導入が課題となる。

6 おわりに

本稿では、競技かるたにおける選手の動作状況を自動認識するため、慣性センサを用いた時系列データセットの構築と識別モデルの検証を行った。実験の結果、一括での多クラス分類や3クラス分類では、非対象動作の圧倒的な多さや動作の類似性により目的動作の識別性能が低下する課題が浮き彫りとなった。これに対し、非対象動作を段階的に除去する「2段階2クラス分類」アプローチを導入することで、「反応」や「素振り」といった重要動作の識別精度を大幅に向上させられることを示した。

今後の課題として、Stage1における目的動作の検出漏れ（Recallの低下）を防ぐための特徴量設計やモデル構造の検討が挙げられる。さらに今後は、被験者数および試合数を拡大してデータセットの規模と多様性を向上させるとともに、本稿で対象とした主ラベルである状態・動作カテゴリにとどまらず、競技に特に関係する「反応」ラベルに着目して、それに付随する属性ラベルである「取り方」「位置」「接触」などのカテゴリを組み合わせた詳細な時系列分析を進める予定である。これにより、選手の得意・苦手な取りのパターンや試合中の疲労による札への反応の変化などを定量化し、実用的な選手分析・指導支援システムへの展開を目指す。

謝辞 本研究の一部は、JSPS 科研費（26K21206）の助成を受けて行われたものです。また実験にあたっては、岡山大学競技かるた部の方々にご協力いただきました。ここに感謝の意を申し上げます。

参考文献

- [1] 北川リサ, 伊藤貴之. 競技かるたにおける払いの動作の三次元ボーン表示による可視化. 日本データベース学会和文論文誌, Vol. 23-J, No. 3, pp. 1–7, 2025.
- [2] Ruichen Liu, Zhelong Wang, Xin Shi, Hongyu Zhao, Sen Qiu, Jie Li, and Ning Yang. Table Tennis Stroke Recognition Based on Body Sensor Network. In *Internet and Distributed Computing Systems*, pp. 1–10, 2019.
- [3] Hamza Sonalcan, Enes Bilen, Bahar Ateş, and Ahmet Çağdaş Seçkin. Action Recognition in Basketball with Inertial Measurement Unit-Supported Vest. *Sensors*, Vol. 25, No. 2, pp. 1–23, 2025. Article No. 563.
- [4] 全日本かるた協会. 競技規程細則. https://www.karuta.or.jp/static/kitei/20200526-kyougi_saisoku.pdf, 2020. Accessed on 22/07/2026.
- [5] 山田浩史, 村尾和哉, 寺田努, 塚本昌彦. 競技かるたにおける手首動作に基づく札取得タイミング推定手法の提案. *インタラクション*, pp. 969–971, 2015.
- [6] 尾山幹大, 中村優吾, 荒川豊. 競技かるたにおける圧力センサマットを用いた試合中の札取得動作分析. 第86回全国大会講演論文集, 第2024巻, pp. 381–382, 2024.
- [7] 丸山礼華, 栗原一貴, 山中祥太. VR百人一首かるたにおける札取り動作の数理モデル解析とそのゲームスキル調整への応用. 第31回インタラクティブシステムとソフトウェアに関するワークショップ（WISS 2023）論文集, 2023.