

ベイイズ学習に基づく隠れマルコフモデルを用いた スポーツ映像解析におけるイベント検出

本井滋[†] 三須俊彦^{††} 中田洋平[†] 松本隆^{†††} 八木伸行^{††}

[†] 早稲田大学大学院 理工学研究科 東京都新宿区大久保 3-4-1

^{††} 日本放送協会 放送技術研究所 東京都世田谷区砧 1-10-11

^{†††} 早稲田大学 理工学術院 東京都新宿区大久保 3-4-1

E-mail: [†]{motoi05,yohei}@matsumoto.elec.waseda.ac.jp, ^{††}{misu.t-ey,yagi.n-iy}@nhk.or.jp,
^{†††}takashi@mse.waseda.ac.jp

あらまし 2007年度中に開始予定のサーバー型放送では、メタデータを利用したサービス提供が検討されている。このような中、映像解析によるイベント検出技術、及び検出されたイベントをメタデータとして映像データに付与する、メタデータ自動付与システムの研究・開発が進められている。本稿は、サッカー映像から抽出した選手位置情報などの特徴量を用い、コーナーキック等の生起を検出するイベント検出法を提案する。これまで、手作業により作成されたルールによるイベント検出法などが提案されてきた。本研究では、イベント検出技術の高度化を目的とし、ベイイズ学習に基づく隠れマルコフモデルを適用する。また本稿では、Jリーグ・サッカー試合の映像を用いて、提案アルゴリズムによるイベント検出の可能性を検証する。
キーワード イベント検出, スポーツ映像, 隠れマルコフモデル, ベイズ学習, マルコフ連鎖モンテカルロ法

Bayesian Hidden Markov Model Approach for Events Detection in Sports Movie

Shigeru MOTOI[†], Toshihiko MISU^{††}, Yohei NAKADA[†], Takashi MATSUMOTO^{†††}, and
Nobuyuki YAGI^{††}

[†] Graduate School of Science and Engineering, Waseda University
3-4-1 Okubo, Shinjuku-ku, Tokyo, Japan

^{††} NHK Science & Technical Research Laboratories
1-10-11 Kinuta, Setagaya-ku, Tokyo, Japan

^{†††} Science and Engineering, Waseda University
3-4-1 Okubo, Shinjuku-ku, Tokyo, Japan

E-mail: [†]{motoi05,yohei}@matsumoto.elec.waseda.ac.jp, ^{††}{misu.t-ey,yagi.n-iy}@nhk.or.jp,
^{†††}takashi@mse.waseda.ac.jp

Abstract Home-server-based broadcasting is scheduled to launch by April 2008 in Japan. In the broadcasting, several services with metadata are also planned. Therefore, some researches have been focused on event detection methods and systems to add detected events as metadata to movie data. This paper proposes a novel event detection method with players' positions extracted from movie data of soccer games. In the proposed method, a hidden Markov model with a Bayesian framework is used for automatic event detection, while a conventional method used rules made by hand. The proposed method is tested against movie data set of J-league soccer games.

Key words event detection, sports movie, hidden Markov model, Bayesian learning, Markov chain Monte Carlo

1. はじめに

1.1 動機

メタデータとは、データの内容を記述したデータを言う。映像データの場合、例えばドラマ番組映像に対してはセリフ文字列や出演者名などがメタデータであり、スポーツ映像であれば得点シーンなどの情報がメタデータとなる [1]。

2007 年度中に開始が予定されているサーバー型放送では、このようなメタデータを利用した様々なサービス提供が検討されている。さらにメタデータは、映像データの検索の効率化や番組制作の半自動化などに繋がると期待されている [1][2]。

このような中、シナリオがなくメタデータの手動付与が困難なスポーツ中継番組映像に対し、メタデータの自動付与システムが提案されてきた [2]。このメタデータ自動付与システムはイベント検出に基づくものであり、予め設定されたルールにより特定のイベントを検出し、検出されたイベントを用いて映像データにメタデータを付与するものである。

しかし、文献 [2] ではイベント検出に手作業により作成されたルールを用いているため、イベントの生起要因やその時間的依存関係を適切に考慮できていない可能性があった。また、ルールの設定は手作業で行うため、検出性能が設定者に依存し、スポーツ種類ごとに手作業が発生するものであった。

本研究では、上述の問題を解決すべく、(i) 隠れマルコフモデル、(ii) ベイズ学習を導入したスポーツ映像イベント検出法を提案する。提案手法では、隠れマルコフモデルを用いることで、イベント発生の要因やその時間的依存関係を適切に考慮することが可能となる。また、ベイズ学習を用いることで、少ない学習用データであっても客観的なモデル学習が実現できる。本稿では、Jリーグ・サッカー試合の映像データを用いて、上述の提案手法によるイベント検出可能性を検証する。

1.2 先行研究

イベント検出は、特定の事象（イベント）の生起を検出する技術であり、様々な応用分野で用いられている。映像分野に限れば、ニュース番組を対象とするもの [3]、ホームビデオや長編映画に対するもの [4]、スポーツ映像に対する手法 [5] などが提案されている。ただし、本研究のようにベイズ学習を用いた隠れマルコフモデルによるアプローチは見当たらない。

2. メタデータ自動付与システムの概要

提案手法について述べる前に、文献 [2] で提案されているスポーツ映像メタデータ自動付与システムの概要につい

て述べる。

本研究に関連するメタデータ自動付与システム [2] は、図 1 に示す構成となっている。図示するシステムでは、センサカメラにより獲得したスポーツ映像データについて、(i) 選手位置追跡処理、(ii) 特徴量抽出処理、(iii) 特徴量加工処理、(iv) イベント検出処理、(v) メタデータ記述処理を順に行い、最終的にメタデータを映像データベースに付与する。以降、これらの処理について簡単に説明する。

(i) 選手位置追跡処理

各選手の位置を推定する。本稿では、文献 [2][6] と同様に背景差分法と拡張カルマンフィルタを用いて、実座標系における選手位置の推定を行っている。

(ii) 特徴量抽出処理

選手位置追跡処理により得られた各選手位置を用いて、各選手の速度、色分類、シルエット面積などを算出する。

(iii) 特徴量加工処理

上記 2 つの処理により得られた情報を元に、全選手位置の平均値など統計量を算出する。

(iv) イベント検出処理

得られた統計量などに基づき、モデルやルールなどを用いて特定のイベントを検出する処理である。サッカー映像の場合はキックオフやコーナーキックなどを検出する。

(v) メタデータ記述処理

検出されたイベントをメタデータとして記述する処理である。記述の形式としては、例えば XML である。

本研究は、上述の (iv) イベント検出処理の高度化を目的とするものである。

3. ベイズ隠れマルコフモデル

本節では、イベント検出処理で用いるベイズ隠れマルコフモデル [7][8] について述べる。

3.1 隠れマルコフモデルの構造

隠れマルコフモデルの構造は、状態数 N とその形状により定めることができる。よく用いられる形状として、任意の状態から任意の状態へ遷移可能であるエルゴード型と、一方向にしか遷移ができない left-to-right 型が存在する。本稿の実験ではエルゴード型の構造を用いている。

図 2 は隠れマルコフモデルの形状の例を示している。ただし、双方の例とも状態数 $N = 3$ としている。図中の円は状態を表し、矢印は状態間遷移を表す。

3.2 観測列と状態列

隠れマルコフモデルを用いた枠組では、観測列

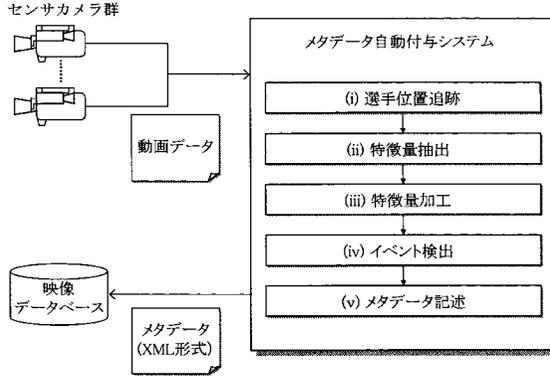


図 1: メタデータ自動付与システム [2] の概要図

Fig. 1 Abstract of automatic metadata generation system [2].

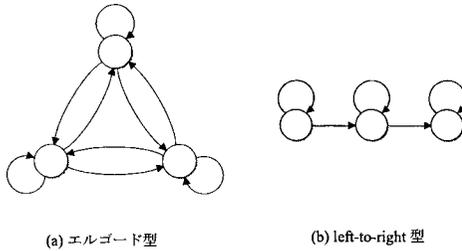


図 2: 隠れマルコフモデルの形状の例

Fig. 2 Examples of HMM topology.

$y := (o_1, \dots, o_T)$ とそれと同長の (隠れ) 状態列 $z := (q_1, \dots, q_T)$ を考える必要がある。以降に本研究における観測列と状態列について説明する。なお、本研究では 1 映像データが 1 つの観測列 y と状態列 z に対応する。

観測列は $y := (y_f, y_e)$ のように、特徴量ベクトルの系列 $y_f := (f_1, \dots, f_T)$ と生起イベントの系列 $y_e := (e_1, \dots, e_T)$ とで構成される。ただし、時刻 t における特徴量ベクトル f_t は $f_t := (f_{t,1}, \dots, f_{t,L})$ と L 個の特徴量で構成されるものとする。また、 $f_{t,l} \in \{1, \dots, K_l\}$ は時刻 t における l 番目の特徴量、 $e_t \in \{1, \dots, M\}$ は時刻 t における生起イベントである。ただし、 $l = 1, \dots, L$ であり、特徴量シンボル数 K_l 、イベントシンボル数 M は正の整数である。

状態 $q_t \in \{1, \dots, N\}$ は時刻 t における観測値 y_t の隠れた生起要因を表すものである。ただし、状態数 N は正の整数である。

3.3 尤度関数

隠れマルコフモデルの全てのパラメタのセット θ が与えられたとき、観測列 y に対する確率分布 (尤度関数) は

以下のように表される。

$$P(y|\theta) = \sum_z P(y|z, \theta)P(z|\theta) \quad (1)$$

ただし、

$$P(y|z, \theta) = \prod_{t=1}^T \prod_{l=1}^L P(f_{l,t}|q_t, \theta)P(e_t|q_t, \theta), \quad (2)$$

$$P(z|\theta) = P(q_1|\theta) \prod_{t=2}^T P(q_t|q_{t-1}, \theta) \quad (3)$$

である。以降に式 (2)~(3) に表される各確率について述べる。

(i) 特徴量出力確率

l 番目の特徴量 $f_{l,t}$ に対する出力確率 $P(f_{l,t}|q_t, \theta)$ を以下のように定める。

$$P(f_{l,t} = k|q_t = i, \theta) := b_{l,ik}$$

ここで、 $b_{l,ik}$ は $b_{l,ik} > 0$ 、及び、 $\sum_{k'=1}^{K_l} b_{l,ik'} = 1$ を満たす。ただし、 $l = 1, \dots, L$ 、 $k = 1, \dots, K_l$ 、 $i = 1, \dots, N$ である。

(ii) イベント出力確率

生起イベント e_t に対する出力確率 $P(e_t|q_t, \theta)$ を以下のように定める。

$$P(e_t = k|q_t = i, \theta) := c_{ik}$$

ここで、 c_{ik} は $c_{ik} > 0$ 、及び、 $\sum_{k'=1}^M c_{ik'} = 1$ を満たす。ただし、 $k = 1, \dots, M$ 、 $i = 1, \dots, N$ である。

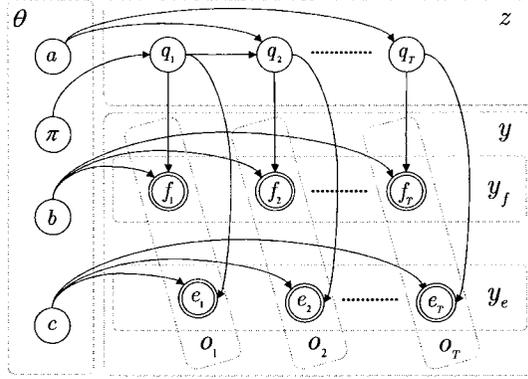


図3: モデル構造のグラフィカル表現.

Fig. 3 Graphical representation of model structure.

(iii) 初期状態確率

初期状態確率 $P(q_1|\theta)$ を次式で定める.

$$P(q_1 = i|\theta) := \pi_i$$

ここで, π_i は $\pi_i > 0$, 及び, $\sum_{i'=1}^N \pi_{i'} = 1$ を満たす. ただし, $i = 1, \dots, N$ である.

(iv) 状態遷移確率

1 時刻前の状態 q_{t-1} から現在の状態 q_t への状態遷移確率 $P(q_t|q_{t-1}, \theta)$ を以下のように定める.

$$P(q_t = j|q_{t-1} = i, \theta) := a_{ij} \quad (4)$$

ここで, a_{ij} は $a_{ij} > 0$, 及び, $\sum_{j'=1}^N a_{ij'} = 1$ を満たす. ただし, $i = 1, \dots, N, j = 1, \dots, N$ である.

3.4 事前分布

ベイズ学習においては, 前節で定めた状態遷移確率などのほかにパラメータセット θ に対する事前分布の設計が必要になる. 本稿では, それぞれのパラメータに対する独立性を仮定し, 以下に示すような事前分布とする.

$$P(\theta) := \prod_{i=1}^N \prod_{l=1}^L P(b_{l,i}) \cdot \prod_{i=1}^N P(c_i) \cdot P(\pi) \cdot \prod_{i=1}^N P(a_i) \quad (5)$$

ただし,

$$b_{l,i} := (b_{l,i1}, \dots, b_{l,iK_l}), \quad c_i := (c_{i1}, \dots, c_{iM}),$$

$$\pi := (\pi_1, \dots, \pi_N), \quad a_i := (a_{i1}, \dots, a_{iN}),$$

$$\theta := (\{b_{l,i}\}, \{c_i\}, \pi, \{a_i\})$$

である.

なお, 実装の簡略化のため, 提案モデルでは各事前分布には自然共役性 [9] を持つディリクレ分布を用いる. 以降にそれぞれの事前分布の詳細を示す.

(i) 特徴量出力確率パラメタ $b_{l,i}$ の事前分布

l 番目の特徴量 $f_{l,t}$ の出力確率パラメタ $b_{l,i}$ に対する事前分布を, デリクレ分布を用いて以下のように定める.

$$P(b_{l,i}) := \mathcal{D}(b_{l,i}; \beta_{l,i}) \quad (6)$$

ここで, $\mathcal{D}(\cdot)$ はディリクレ分布を表す. $\beta_{l,i} := (\beta_{l,i1}, \dots, \beta_{l,iK_l})$ は分布の形状をあらわすハイパパラメタである. ただし, $\beta_{l,ik} > 0$ ($k = 1, \dots, K_l$) である.

(ii) イベント出力確率パラメタ c_i の事前分布

生起イベント e_t の出力確率パラメタ c_i に対する事前分布を次式のように定める.

$$P(c_i) := \mathcal{D}(c_i; \gamma_i) \quad (7)$$

ただし, $\gamma_i := (\gamma_{i1}, \dots, \gamma_{iM})$ はハイパパラメタであり, $\gamma_{ik} > 0$ ($k = 1, \dots, M$) を満たす.

(iii) 初期状態確率パラメタ π の事前分布

初期状態確率パラメタ π の事前分布を次式で定める.

$$P(\pi) := \mathcal{D}(\pi; \rho) \quad (8)$$

ただし, $\rho := (\rho_1, \dots, \rho_N)$ はハイパパラメタであり, $\rho_i > 0$ ($i = 1, \dots, N$) を満たす.

(iv) 状態遷移確率パラメタ a_i の事前分布

状態遷移確率パラメタ a_i の事前分布を次式で定める.

$$P(a_i) := \mathcal{D}(a_i; \alpha_i) \quad (9)$$

ただし, $\alpha_i := (\alpha_{i1}, \dots, \alpha_{iN})$ はハイパパラメタであり, $\alpha_{ij} > 0$ ($j = 1, \dots, N$) を満たす.

なお, 後述の実験では, 全てのハイパパラメタの値を 1 で固定した. このハイパパラメタの設定は, デリクレ分

布を事前分布と用いる際に用いる代表的な選択肢のひとつであり、この設定ではパラメタがその存在範囲に一様分布している形状をとる。

図 3.3 に以上までに説明したモデルの構造を示す。ただし、図中のパラメタは $a := \{a_i\}$, $b := \{b_{ii}\}$, $c := \{c_i\}$ を表す。また、二重円は観測される変数を、円は非観測変数を表す。なお、図が煩雑になるのを避けるため、ハイパパラメタやそれらに対する依存性は省略する。

4. イベント予測アルゴリズムの実装

本節ではイベント予測アルゴリズムの実装について述べる。

4.1 問題設定

イベント予測アルゴリズムの詳細を述べる前に、まず本稿で対象とする問題について述べる。対象とする問題は、以下のように纏められる。

問題： $C(\geq 1)$ 個の観測列から構成される観測列群 $Y := (y_1, \dots, y_C)$ が与えられているとする。この状況下で、新たな観測列 $y_f^{new} := (y_f^{new}, y_c^{new})$ の内、特徴量ベクトル系列 $y_f^{new} := (f_1^{new}, \dots, f_T^{new})$ のみが与えられたとき、それに対応する生起イベント系列 $y_e^{new} := (e_1^{new}, \dots, e_T^{new})$ を予測する。

4.2 イベント e_t^{new} の予測確率

上記の問題に対する 1 つの解決策として、前節までに述べたモデルを用いて導かれる予測確率により、生起イベントを評価することが考えられる。ここで、各時刻の生起イベント e_t^{new} の予測確率は以下の式で表される。

$$P(e_t^{new} | y_f^{new}, Y) = \int P(e_t^{new} | y_f^{new}, \theta) P(\theta | Y) d\theta \quad (10)$$

ただし、パラメタセット θ の事後分布 $P(\theta | Y)$ は、尤度関数 (1) 及び、事前分布 (5) を用いて以下のように示されるものである。

$$P(\theta | Y) = \frac{P(Y | \theta) P(\theta)}{\int P(Y | \theta) P(\theta) d\theta}, \quad (11)$$

$$P(Y | \theta) = \prod_{c=1}^C P(y_c | \theta) \quad (12)$$

4.3 イベント予測確率の算出

予測確率 (10) の周辺化を解析的に行うは困難であるため、なんらかの近似解法が必要となる。そのため、ここではモンテカルロ法を用いることとする。具体的には、文献 [8] に示されるマルコフ連鎖モンテカルロ法を用いることで、事後分布 (12) からパラメタセットのサンプル群 $\{\theta^{(s)}\}_{s=1}^S$ を得る。その後、得られたサンプル群 $\{\theta^{(s)}\}_{s=1}^S$ を用いて、イベント予測確率 (10) を次式のように近似する。

表 1: 対象イベント一覧

Table 1 List of target events.

番号 k	名称	観測列群 Y 内 生起回数	観測列 y^{new} 内 生起回数
1	キックオフ	10	2
2	コーナーキック	15	4
3	フリーキック	35	22
4	スローイン	46	25
5	ゴールキック	53	11

$$P(e_t^{new} | y_f^{new}, Y) \approx \frac{1}{S} \sum_{s=1}^S P(e_t^{new} | y_f^{new}, \theta^{(s)}) \quad (13)$$

なお、パラメタセットのサンプル $\theta^{(s)}$ が得られれば、 $P(e_t^{new} | y_f^{new}, \theta^{(s)})$ の算出は、以下の式により確率伝播法を用いて解析的に実施することができる。

$$P(e_t^{new} | y_f^{new}, \theta^{(s)}) = \sum_{q_t^{new}} P(e_t^{new} | q_t^{new}, \theta^{(s)}) P(q_t^{new} | y_f^{new}, \theta^{(s)}) \quad (14)$$

ただし、状態 q_t^{new} は生起イベント e_t^{new} と特徴量ベクトル f_t^{new} に対応する状態である。

図 4 に、本稿のイベント予測アルゴリズムの手順を纏める。ただし、図 4 に登場する状態列群 Z は学習用の観測列群 $Y := (y_1, \dots, y_C)$ に対応する状態列の集合を表し、 $Z := (z_1, \dots, z_C)$ と表せる。なお、状態列 z_c は観測列 y_c に対応する状態列である。

5. サッカー映像イベント予測実験

本節では、実際のサッカー映像データから抽出した特徴量を用いて実施した検証実験について述べる。

5.1 実験条件

本実験で対象としたイベントの名称、学習用観測列群 $Y(C=4)$ と評価用観測列 y^{new} での生起回数を表 1 に示す^(注1)。ただし、表 1 に示すイベント以外にも何も生起していないことを表す“イベントなし”というダミーイベントも用いている。

表 2 には本実験で用いた 28 個の特徴量を示す。表 2 に示す連続値型の特徴量はそのまま用いるのではなく、10 値に離散化して用いている。本実験で用いたその他の条件は表 3 に示す。

5.2 評価指標

提案アルゴリズムの評価指標として、次式に示すイベント予測確率比を用いる。

(注1)：なお、これらのイベントについては、審判の動作を元目視による検出を行い、その検出時刻 t を中心に $t \pm 4$ をその生起範囲としている。なお、本実験での時刻 t の単位は 30 フレーム (約 1 秒) である。

(I) 学習フェーズ

(a) 初期化ステップ:

初期のパラメタセット $\theta^{(0)}$ を事前分布 $P(\theta)$ からサンプリングする。

(b) MCMC ステップ:

以下のステップを $g = 1 \sim G$ まで繰り返す。

(i) $\theta^{(g-1)}$ を用いて、状態列群の g 番目のサンプル $Z^{(g)}$ をフォワード・バックワードサンプリング法を用いて得る [8]。

(ii) 状態列群のサンプル $Z^{(g)}$ を用いて、パラメタセットの g 番目のサンプル $\theta^{(g)}$ をギブスサンプリング法を用いて得る [8][9]。

(c) 選択ステップ:

モンテカルロ近似 (13) で用いるパラメタセットのサンプル群 $\{\theta^{(s)}\}_{s=1}^S$ を、MCMC ステップで得られたサンプル群 $\{\theta^{(g)}\}_{g=1}^G$ から選ぶ。なお、後述の実験では最後に得たサンプル ($g = G$) から逆順に S 個選出している。

(II) 予測フェーズ

(d) 確率伝播法ステップ:

各サンプル $\theta^{(s)}$ について、確率伝播法 (14) を用いて確率値 $P(e_t^{new} | y_f^{new}, \theta^{(s)})$ を計算する。

(e) モンテカルロ近似ステップ:

モンテカルロ近似 (13) により、イベント予測確率 (10) を求める。

図 4: イベント予測アルゴリズムの手順
Fig.4 Procedure for events prediction

$$S(k) := \frac{\sum_{t=1}^T P(e_t^{new} = k | y_f^{new}, Y) I(e_t^{new*} = k)}{\sum_{t=1}^T I(e_t^{new*} = k)} \times \frac{\sum_{t=1}^T I(e_t^{new*} \neq k)}{\sum_{t=1}^T P(e_t^{new} = k | y_f^{new}, Y) I(e_t^{new*} \neq k)} \quad (15)$$

ただし、 e_t^{new*} は実際に時刻 t に起こった生起イベントを表し、 $I(\cdot)$ は以下に示すようなインジケータ関数である。

$$I(X) = \begin{cases} 1, & X \text{ が真の場合,} \\ 0, & \text{それ以外の場合.} \end{cases} \quad (16)$$

イベント予測確率比 $S(k)$ が大きければ大きいほどイベント非発生時の予測確率の平均値と比較して発生時の予測確率の平均値が大きく、検出可能性が高いことを示す。また、仮にイベント予測確率比 $S(k)$ が 1 の場合、無作為に実施した予測 (ランダムゲス) と差がないことを示す。

5.3 結果と考察

表 4 に本実験で得られた各イベントに対するイベント予

表 2: 特徴量一覧

Table 2 List of feature values.

番号 l	特徴量名	形式
1	全選手位置 x 方向平均値	連続値型
2	全選手位置 y 方向平均値	連続値型
3	全選手位置 x 方向分散	連続値型
4	全選手位置 xy 共分散	連続値型
5	全選手位置 y 方向分散	連続値型
6	左チーム選手位置 x 方向平均値	連続値型
7	左チーム選手位置 y 方向平均値	連続値型
8	左チーム選手位置 x 方向分散	連続値型
9	左チーム選手位置 xy 共分散	連続値型
10	左チーム選手位置 y 方向分散	連続値型
11	右チーム選手位置 x 方向平均値	連続値型
12	右チーム選手位置 y 方向平均値	連続値型
13	右チーム選手位置 x 方向分散	連続値型
14	右チーム選手位置 xy 共分散	連続値型
15	右チーム選手位置 y 方向分散	連続値型
16	全選手速度 x 方向平均値	連続値型
17	全選手速度 y 方向平均値	連続値型
18	全選手速度絶対値平均値	連続値型
19	右奥コーナー攻撃選手有無	フラグ型
20	右手前コーナー攻撃選手有無	フラグ型
21	左奥コーナー攻撃選手有無	フラグ型
22	左手前コーナー攻撃選手有無	フラグ型
23	タッチライン奥左チーム選手有無	フラグ型
24	タッチライン手前左チーム選手有無	フラグ型
25	タッチライン奥右チーム選手有無	フラグ型
26	タッチライン手前右チーム選手有無	フラグ型
27	センターライン手前左チーム選手有無	フラグ型
28	センターライン手前右チーム選手有無	フラグ型

表 3: 実験条件

Table 3 Conditions of experiment.

変数名/属性名	値
特徴量数 (次元数) L	28
学習用の観測列数 C	4
観測列長 T	約 2400 (観測列により異なる)
特徴量シンボル数 K_l	連続値型: 10 フラグ型: 2
イベントシンボル数 M	6
状態数 N	40
MCMC ステップ回数 G	500
利用サンプル数 S	200

測確率比 $S(k)$ を示す。図 5 にイベント予測確率の例を示す。表 4 に示すようにキックオフ、コーナーキック、ゴールキックについては、イベント予測確率比 $S(k)$ が大きい値となり、高いイベント検出可能性が示されている。特にキックオフとコーナーキックは、図 5 にも示すように予測確率の推移と実際のイベント生起区間との対応からも高い検出可能性が確認できる。

ただし、スローインとフリーキックについては、イベン

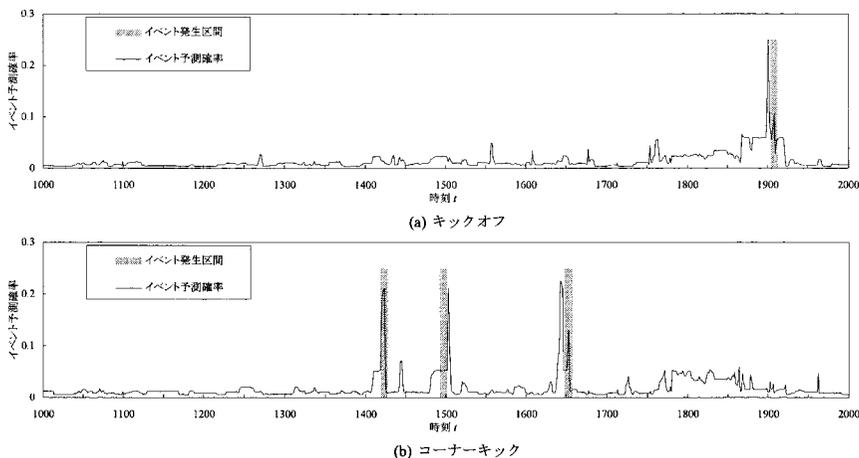


図 5: イベント予測確率の例

Fig. 5 Examples of prediction

表 4: イベント予測確率比

Table 4 Ratios of predictive probabilities for events.

番号 k	名称	予測確率比 $S(k)$
1	キックオフ	9.28
2	コーナーキック	7.04
3	フリーキック	1.11
4	スローイン	1.97
5	ゴールキック	4.33

ト予測確率比 $S(k)$ が比較的 1 に近い値を取っており、検出可能性が低いことが示されている。本稿で用いた特徴量にはこれらのイベントの予測に効果的なものがあり含まれていないことや、あまり予測に効果のない特徴量などが含まれておりそれらの特徴量が予測に悪影響をしていることが、原因として考えられる。現在、これらのイベントに対しても効果的な特徴量の作成や不要な特徴量の選別を進めている。

6. むすび

本稿では、イベント検出の高度化を目的とし、ベイズ学習に基づく隠れマルコフモデルを用いたイベント検出手法を提案した。さらに、Jリーグ・サッカー試合の映像を用いた実験により、提案手法のイベント検出適用可能性を検証した。その結果から、コーナーキックなど幾つかのイベントに対し検出可能性が確認された。今後はデータの拡充とともに、より効果的な特徴量の抽出・加工や特徴量選別手法の導入などを実施する。

謝辞 早稲田大学 松本隆 研究室の佐々木浩人氏には、本研究におけるモデルの理論的側面やアルゴリズムの実装に

関して有益なご助言・ご議論を頂きました。深謝致します。また、日本放送協会 放送技術研究所の松井淳氏、高橋正樹氏、サイモン・クリッピングデル氏には、映像データやメタデータなどについて多くのご助言を頂いたことを感謝致します。

文 献

- [1] 住吉英樹, 佐野雅規, 山田一郎, 松井淳, Simon Clippingdale, 望月貴裕, 三須俊彦, 佐藤庄衛, 小林彰夫, 今井亨, 松村欣司, 八木伸行: “メタデータ制作・活用システムの試作,” 映像情報メディア学会技術報告, Vol.29, no.70, BCT2005-159, ME2005-205, AIT2005-120, pp.13-18 (2005)
- [2] 三須俊彦, 高橋正樹, 蓼沼真, 八木伸行: “サッカー映像のフォーメーション解析に基づく実時間イベント検出,” 第4回科学技術フォーラム, LI-003, pp.141-144 (2005)
- [3] James Allan, Ron Papka, and Victor Lavrenko: “On-line New Event Detection and Tracking,” 1998 Annual International ACM SIGIR Conference, pp.37-45 (1998)
- [4] Yun Zhai and Mubarak Shah: “Video Scene Segmentation Using Markov Chain Monte Carlo,” IEEE Transactions on Multimedia, vol.8, pp.686-697 (2006)
- [5] Baoxin Li and M.Ibrahim Sezan: “Event Detection and Summarization in Sport Video,” IEEE Workshop on Content-based Access of Image and Video Libraries (CBAIVL'01), pp.132-138 (2001)
- [6] 三須俊彦, 高橋正樹, 合志清一, 蓼沼真, 藤田欣裕, 八木伸行: “実時間画像処理に基づくオフサイドライン可視化システム,” 電子情報通信学会論文誌, VOL.J88-D-II, NO.8, pp.1681-1692 (2005)
- [7] 船田篤志, 佐々木浩人, 中田洋平, 松本隆: “モンテカルロ隠れマルコフモデルを用いたオンライン文字認識,” 第15回日本神経回路学会全国大会, pp.137-138 (2005)
- [8] Steven L.Scott: “Bayesian Methods for Hidden Markov Models: Recursive Computing in the 21st Century,” Journal of the American Statistical Association, vol.97, pp.337-351 (2000)
- [9] W.R.Gilks, S.Richardson, and D.J.Spiegelhalter: Markov Chain Monte Carlo in Practice, Chapman & Hall, London (1996)