

## 映像編集のための事例学習に基づく素材映像からのショット列生成

姜 国臻<sup>†</sup> 新田 直子<sup>†</sup> 馬場口 登<sup>†</sup>

<sup>†</sup> 大阪大学大学院工学研究科 〒 565-0871 大阪府吹田市山田丘 2-1  
E-mail: †{kyo,naoko,babaguchi}@nanase.comm.eng.osaka-u.ac.jp

**あらまし** 映像編集は一般に、素材映像から選択されたショットの並び替えにより実現される。本研究では事例映像である専門家により制作された編集映像とその素材映像から学習した編集技術に基づいた自動映像編集を目指す。まず、編集映像を構成するショットを、ショット長、動き、輝度といった画像特徴量の量子化に基づきシンボル化し、その時系列パターンを隠れマルコフモデル (HMM) により学習する。また、編集映像において連続するショットの素材映像における相対位置分布を求める。次に、学習した HMM によりシンボル列を生成し、ユーザから与えられた素材映像を構成するすべてのショットに対して算出した各シンボルへの適合度、及び相対位置分布に基づき、各シンボルに最適なショットを選択することにより、編集映像のショット列を生成する。本稿では事例映像としてアクション映画の予告映像と本編映像を用い、一本の本編映像に対する映像編集により提案手法を評価した。

**キーワード** 映像編集, ショット時系列パターン, ショット列生成, 隠れマルコフモデル

## Shot Sequence Generation from Raw Footage for Video Editing Based on Learning by Example

Guozhen JIANG<sup>†</sup>, Naoko NITTA<sup>†</sup>, and Noboru BABAGUCHI<sup>†</sup>

<sup>†</sup> Graduate School of Engineering Osaka University, Yamadaoka 2-1, Suita, 565-0871 Japan  
E-mail: †{kyo,naoko,babaguchi}@nanase.comm.eng.osaka-u.ac.jp

**Abstract** Video editing is generally realized by arranging video segments selected from raw footage. Considering professionally edited videos and their original footage as example videos, our aim is to automatically edit a raw footage based on the editing techniques learned from example videos. The proposed method firstly represents each shot constituting the edited videos by a symbol based on the image features such as shot length, motion, and brightness, and learns the shot temporal sequence pattern by Hidden Markov Model (HMM). For each set of consecutive shots in edited videos, the distribution of their relative positions in the original footage is also obtained. Then, a symbol sequence, which constructs an edited video, is generated by the learned HMM, and according to symbol compatibilities of all shots in raw footages and the position distribution, we select the most appropriate shot for each symbol. In this paper, we used action movies as the example videos and evaluated our approach by editing an original movie.

**Key words** Video Editing, Shot Temporal Sequence Patterns, Shot Sequence Generation, Hidden Markov Model

### 1. はじめに

映像編集とは、素材映像から選択した適切な部分映像をつなぎ合わせ、新たな映像を制作する作業である。素材映像を構成する部分映像にはさまざまな種類が存在し、編集映像におけるその時系列上での組み合わせは無限に存在するため、編集映像の質は編集者の持つ技術に依存する。そこで、効率的かつ効果的な映像編集を実現するための自動映像編集に関連した研究が多くなされてきた。そのほとんどは、動画の構成

に着目したもので、例えば Sundaram ら [2] は、視覚的複雑度 (visual complexity)、及びショット構成に関する映像文法 (film syntax) という二つの観点に基づき、素材映像から編集映像に用いるべき部分映像を決定している。また、天野ら [3] はショットサイズが大きく異なるショット同士は接続できない、といった映像文法に基づいた自動映像編集を試みた。このような映像文法に始まり、選択するショットとその時系列上での組み合わせに関する編集パターンは無数にあるが、主観的に設定されたものも含め、定式化されておらず、すべての編集パターンを考

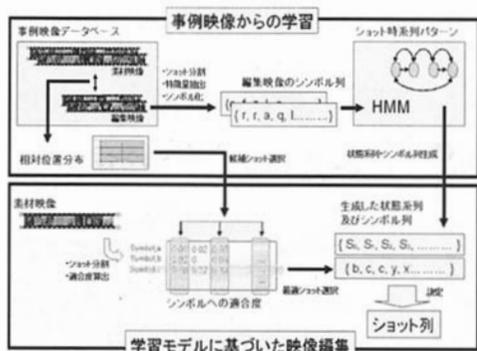


図 1 提案手法の概要

慮したシステム構築は容易ではない。

そこで本研究は、実際に専門家により制作された編集映像とその素材映像から学習した妥当性の高い編集パターンに基づいた映像編集を目的とする。ここで、映像編集の目的として、ニュース番組中で放映されるスポーツのダイジェスト映像に代表される短時間での情報獲得を可能にする映像制作と、映画予告映像に代表される短時間で素材映像の魅力を伝えるエンタテイメント性の高い映像制作の2つが挙げられる。前者に対しては、映像解析により意味内容に基づいた重要場面を自動抽出する手法が多々提案されているが、後者に対しては、映像の意味内容以外に、映像中の動きやカメラの切り替わりの頻度などの変化が生み出すリズムといった感覚的な側面について考慮する必要がある。

以上を踏まえ、本研究では、編集映像におけるショットの時系列パターン、及び編集映像を構成するショットの素材映像における相対位置分布に従った、素材映像からのショット列生成による映像編集手法を提案する。映像リズムに関連すると考えられる画像特徴量に基づいたショット時系列パターンにより、感覚的側面、また、相対位置分布により、素材映像から選択されるショット間の意味的関連性を考慮した上で、統計的に学習されるショットの選択及び整列パターンに基づいた映像編集を実現する。本稿では、目的とする編集映像の理想形の一つとして専門家により制作された映画予告映像とその素材映像である本編映像を事例映像とし学習に用いるとともに、映画本編を素材映像としたショット列生成により制作された編集映像と実際の予告映像の比較により提案手法の有効性について考察する。

## 2. 提案手法の概要

提案手法の全体像を図1に示す。提案手法は1) 事例映像からの学習、2) 学習モデルに基づいた映像編集、の2つのプロセスにより構成される。学習プロセスは、専門家により制作された編集映像とその素材映像の対を複数、事例映像として持つ。まず、編集映像におけるショットの時系列上の組み合わせに着目し、編集映像を構成する各ショットから、映像のリズムに関連すると考えられる信号的特徴として、ショット長、輝度、動き

といった画像特徴量を抽出し、類似した特徴量を持つショットを同一のシンボルで表現する。この結果得られた、編集映像を構成するすべてのショット列を表すシンボル列を観測系列とし、隠れマルコフモデル (HMM: Hidden Markov Model) [4] により編集映像に共通するショット時系列パターンを学習する。さらに、素材映像から選択されるショットの位置に着目し、編集映像において連続するショットの素材映像における位置関係を表す相対位置分布を求める。

編集プロセスでは、ユーザから与えられた素材映像からショット列を生成することにより映像編集を実現する。まず、学習したHMMを用い、状態遷移系列、及びシンボル列を生成する。次に、与えられた素材映像を構成するショットをシンボル化する必要があるが、素材映像から選択されたショットは映像編集時に長さの調節が可能であるため、その特徴量を一意に決定することができない。そこで、各ショットに対して長さを調節しながら、各シンボルへの適合度を求める。最後に、求めた適合度、及び学習プロセスにおいて求められた相対位置分布に応じて、生成されたシンボル列の各シンボルに最適なショットを素材映像から選択することで、編集映像を構成するショット列を生成する。

3, 4章に、各プロセスの詳細を述べる。

## 3. 事例映像からの学習

本章では、学習プロセスにおける事例映像からの学習方法について述べる。本研究では、編集映像におけるショットの時系列上の構成、及び編集映像に選択されたショットの素材映像における位置、の2点を考慮する。前者に対しては、編集映像の感覚的側面に着目し、映像のリズムに関連すると考えられる画像特徴量に基づいたショット時系列パターンを学習する。後者に対しては、素材映像におけるショットの意味的なつながりを考慮するため、編集映像において連続したショットに対する素材映像における相対的な位置関係を相対位置分布として求める。

### 3.1 編集映像におけるショット時系列パターン

映像の感覚的側面であるリズムは、映像中の動きやカメラの切り替わりの頻度など、動画中的変化により生成されると考えられる[7]。そこでまず、ショットからショット長、輝度、動き強度、動き変動性、及び動き範囲の5つの特徴量を抽出する[1]。動き特徴量はブロックマッチングにより求めるが、ブロックマッチングは動きの速いフレームやカメラワークのあるフレームにおいて非常に弱く、実際の動きと一致しない動きベクトルが多く現れる。このような動きベクトルに共通する特徴として、周りの動きベクトルと異なる角度と大きさを持つ孤立ベクトルとして検出されることが挙げられる。ここでは、孤立ベクトルを考慮した動き特徴量を3つ抽出している。ただし、同じ角度と大きさの動きベクトルが他に存在しない動きベクトルを孤立ベクトルとする。ここでは、ショット $m$ に含まれるフレーム $j$ の特徴量ベクトル $F_{m,j} = (f_0, \dots, f_4)$ の平均をショット $m$ の特徴量ベクトル $V_m = (v_0, \dots, v_4)$ とする。以下に各特徴量について説明する

- a) ショット長  $f_0$ : ショットに含まれる全フレーム数.
- b) 輝度  $f_1$ : 平均輝度.
- c) 動き強度  $f_2$ : 孤立ベクトルを除いた動きベクトルの大きさの総和. 実際の動きの大きさをより忠実に表す.
- d) 動き変動性  $f_3$ : 孤立ベクトルの大きさの和の全ての動きベクトルの和に対する割合. 動きの速いフレーム間ではブロックマッチングによる誤検出が多く観測され, 孤立ベクトルが多く現れるため, ショット中の動きの速さと関連する.
- e) 動き範囲  $f_4$ : 1画素以上の大きさを持つ動きベクトルの全ての動きベクトルに対する割合. フレームにおける静止点の割合を表し, 背景の動きあるいはカメラワークの有無と関連する.

さらに, 特徴量  $v_i$  に対し, 累積ヒストグラムに基づき, 各区間において  $100/N_i\%$  のショットを含むよう決定した分割点により,  $N_i$  区間に分け, 特徴量空間を  $\prod_{i=0}^4 N_i$  個のセルに分割する. 分割した各セルに属するすべてのショットに対し, 一つのシンボルを割り当てる. この結果, 編集映像を構成するショット列はシンボル列で表される.

本研究では, 編集映像におけるショット時系列パターンを学習した上で, 学習モデルに即した新たな編集映像の生成を目的とする. そこで, 時系列データからのモデル表現への抽象化, 及びモデルからの時系列データの生成を一つの数学モデルで記述できる特徴を持った HMM を用いてショット列パターンを学習する. そこで, 得られたシンボル列を観測系列とし, HMM のパラメータを Baum-Welch アルゴリズム [4] により学習する.

### 3.2 相対位置分布

上記の通り学習されたショット列パターンは, さまざまな画像特徴量を持ったショットが編集映像の各位置において選択される確率を示す. しかし, 同様の画像特徴量を持ったショットは素材映像の中に複数存在するため, 各位置に対して最適なショットを選択することは困難である.

ここで, 編集映像において会話シーンなどでは, 会話内容などが重要であるため連続するショット間の意味的なつながりが強く, 一方, アクションシーンなどではショット長や動きなどのショットの信号的特徴が重要な役割を果たし, 連続するショット間の意味的なつながりは弱いと考えられる. また, 素材映像で近接したショットは同一シーンに属し, 意味的な関連性が高いなど, ショット対の意味的なつながりは素材映像における位置関係に関連すると想定される.

一方, 映像において会話シーンは話者のアップがセリフ全体に渡って移るなど, 動きが少なく長いショット, アクションシーンは動きが多く短いショットが多い, など同一シーンを構成するショットの特徴は類似する傾向があると考えられる. HMM においては, 類似特徴を持つシンボル列が同一状態で観測されるよう学習を行うため, 本研究では, HMM の各状態は上記のような類似ショットにより構成されるシーンに対応すると仮定

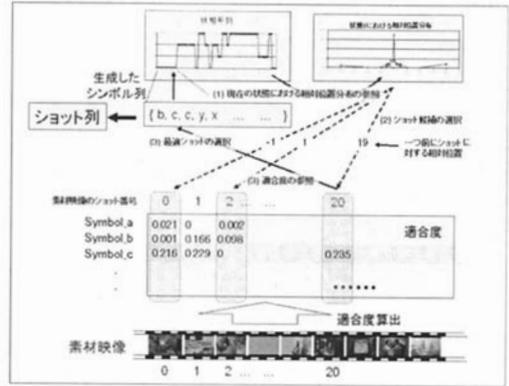


図2 編集プロセスの概要

する.

上記の二点より, 編集映像の各位置において選択されるべきショットをショット間の意味的なつながりを考慮しながら決定するため, 事例映像となる各編集映像に対し得られた学習後の HMM における最適状態系列に基づき, 各状態において連続するショットの素材映像における位置関係を相対位置分布として求める. 編集映像でのショット  $m$  に対応する状態  $S_t$  が  $S_t = q$  の時, 素材映像における位置を  $O_t$  とすると, 相対位置分布  $f_i(x)$  は以下のように定義される.

$$f_i(x) = \frac{N_i(x)}{T} \quad (1)$$

ただし  $N_i(x)$  は  $O_t - O_{t-1} = x$  を満たす  $m$  の個数,  $T$  は編集映像を構成するすべてのショット数を表す.

## 4. 学習モデルに基づいた映像編集

本章では, 提案手法の編集プロセスにおいて, ユーザが与えた素材映像に対する学習モデルに基づいたショット列生成により, 映像編集を実現する方法について述べる. 本プロセスの概要を図2に示す. ここでは, 学習した HMM に基づき生成した状態系列, 及びシンボル列に従って, ショット列を生成することを考える. まず, ユーザから与えられた素材映像を構成する各ショットをシンボルに変換する必要がある. しかし, 素材映像から選択されたショットは映像編集時に長さを調節し得るため, その特徴量を一意に決定することができない. そこで, 各ショットに対して長さを調節しながら, 各シンボルへの適合度を求める. 次に, 生成されたシンボル列に対し, 先頭シンボルから順に最適なショットを選択する. 具体的には, 該当シンボルが生成された状態における相対位置分布に従い, 編集映像の各位置に使用するショット候補を素材映像から選択する. ショット候補のうち, 該当位置のシンボルへの適合度が最も高いものを最適ショットと決定する.

以下にシンボル列生成, 適合度算出, ショット列生成の方法について述べる.

### 4.1 シンボル列生成

まず, 一様分布を用いて  $0 \sim 1$  の乱数を発生させ, HMM の

初期状態確率と状態遷移確率に基づき状態系列を生成する。ここで、ユーザの指定したショット数の状態系列を生成することで、編集映像の長さを調節できる。次に生成した状態系列とシンボル観測確率を用い、同様にシンボル列を生成する。

#### 4.2 シンボル適合度の算出

学習プロセスでショットをシンボルに変換する際、5次元特徴量空間上で  $\prod_{i=0}^4 N_i$  個のセルに分割する。ここで、素材映像のショットは、映像編集時に長さを調節し得るが、ショット長が決定されなければ特徴量を決定できないという問題がある。そこで、特徴量空間におけるショット長に対する  $N_0$  個の区間の各中心点  $l_k$  をショット長の候補とし、各ショット長を長さとする窓を用い、時間軸上に走査しながら抽出した部分映像の特徴量の平均をショットの特徴量として求める。つまり、ショット長を  $l_k$  とした時のショット  $m$  の特徴量ベクトル  $\mathbf{V}_{m,k}$  は以下のように求められる。

$$\mathbf{V}_{m,k} = \frac{\sum_{r=0}^{L_m-l_k} \mathbf{V}_{m,k}(r)}{L_m - l_k + 1} \quad (0 \leq k \leq N_0 - 1) \quad (2)$$

$$\mathbf{V}_{m,k}(r) = \frac{\sum_{j=r}^{r+l_k-1} \mathbf{F}_{m,j}}{l_k} \quad (3)$$

ここで、 $\mathbf{V}_{m,k}(r)$  はショット  $m$  において、フレーム  $r$  を開始フレームとする長さ  $l_k$  の部分映像の特徴量ベクトル、 $\mathbf{F}_{m,j}$  はショット  $m$  中のフレーム  $j$  の特徴量ベクトル、 $L_m$  はショット  $m$  のフレーム数、 $l_k$  は窓のフレーム数を表す。

素材映像中のショット  $m$  に対し、セル  $n$  の中心点ベクトル  $\mathbf{U}_n = (u_{n0}, \dots, u_{n4})$  との距離の逆数をシンボル  $n$  への適合度  $S(\mathbf{V}_{m,k}, \mathbf{U}_n)$  とする。

$$S(\mathbf{V}_{m,k}, \mathbf{U}_n) = \frac{1}{|\mathbf{V}_{m,k} - \mathbf{U}_n|} \quad (0 \leq n \leq \prod_{i=0}^4 N_i - 1) \quad (4)$$

ただし、上式は  $l_k = u_{n0}$  の時のみ計算される。ここで、素材映像中のすべてのショットが常に  $L_m > l_k$  を満たすとは限らない。よって  $l_k > L_m$  の場合、ショット  $m$  をショット長  $l_k$  で用いることは不可能であるとし、適合度  $S(\mathbf{V}_{m,k}, \mathbf{U}_n) = 0$  とする。

#### 4.3 ショット列の生成

まず、4.1 節で生成された状態系列と学習した相対位置分布に基づき、先頭の状態から順に、割り当てる最適ショットを素材映像から選択する。一つ前の状態から遷移した現在の状態に基づき、以下の二つの場合に分類される。

- I) 異なる状態に遷移した場合： シーンの変化が起こったと考えられるため、一つ前のショットとの関連を考慮せずにショットを選択する。具体的には、編集映像を構成するショットは素材映像においてほぼ全体に一樣に分布している [6] ため、ショットをランダムに選択する。
- II) 同じ状態に遷移した場合： 一つ前のショットと同じシーンに属すると考えられるため、一つ前のシンボルに対し選択されたショットの素材映像における位置を基に、該当状態の相対位置分布に従った位置からショットを選択する。

ただし、このように選択されたショットは、各状態で生成されたシンボルへの適合度が低い場合があるため、適合度が 0 でない  $M$  個の候補ショットを選択し、適合度が最も高いものを最適ショットとして決定する。

## 5. 実験と評価

実験では、事例映像として 20 本のアクション映画の予告映像と本編映像を用意し、別のアクション映画を素材映像としてショット列を生成した。アクションのジャンルに属する映画は [5] を参照し選択した。

ショット分割については、本手法の有効性を確認するため、正確なショットが得られるよう手動で行った。ショットのシンボル化においては、 $N_0 = N_1 = 3, N_2 = N_3 = N_4 = 2$  とし、5次元特徴量空間を 72 個のセルに分割した。また、学習に用いた HMM の状態は 4 とした [1]。HMM の初期パラメータとして、初期状態分布及び状態遷移確率をランダムに、シンボル確率分布を全体の確率 1 をシンボル数で等分し 1/72 とした。

ショット列生成においては、実際に専門家により制作された編集映像との比較を行うため、事例映像に含まれない映画の本編を素材映像とし、その予告映像の HMM における最適状態系列に対し生成したシンボル列に対して、ショット列を生成した。学習プロセスにおけるシンボル化の結果、素材映像のショットに対し適合度を求める際に用いるショット長は、 $l_0 = 16, l_1 = 49, l_2 = 81$  となった。また、相対位置分布によるショット候補の数  $M$  を 3 とした。

以下に、学習結果と生成したショット列に関して考察する。

#### 5.1 事例映像からの学習結果に関する考察

学習後の HMM の各状態におけるシンボル観測確率を動き、ショット長、輝度の 3 種類の特徴量に基づき検証した。この際、動き特徴量については、得られた 72 種類のシンボルを、図 3 のように動き特徴量により“動”、“中”、“静”の 3 クラスに分類した。また、ショット長、輝度についてはシンボル化の際に分割した区間に基づき“長”、“中”、“短”、及び“明”、“中”、“暗”の 3 クラスに分類した。図 4, 5, 6 に HMM の各状態における動き、ショット長、輝度特徴に基づく 3 クラスのシンボルの観測確率を示す。このように、状態 1 では動きが少ない暗く長いショット、状態 2 では明るく短いショット、状態 4 では暗く短いショットが観測される確率が大いといった特徴が見られる。実際には、状態 1 は会話や自然風景のように穏やかなシーン、状態 2 はカメラの切り替わりが頻繁で画面変化の多いファイトシーンや爆発シーンに相当することが多く、HMM の各状態が同様の特徴を持ったショットで構成されるシーンと関連することが示された。

また、4 本の事例映像に対して求めた相対位置分布を図 7 に示す。このように、状態 1 と 3 に対しては素材映像において近接したショット、状態 2 と 4 に対しては比較的離れたショットが選択されることが多い。また、編集映像における各ショットに対応する状態と素材映像における位置を、映画“Broken Arrow”の予告映像を例として図 8 に示す。実際に、状態 1 と 3 では、素材映像における隣接ショット、状態 2 と 4 では、素材映像か

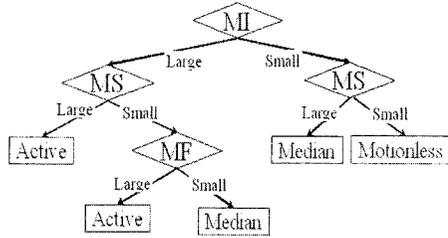


図3 シンボルの動き特徴量による分類

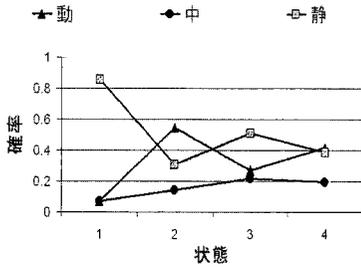


図4 各状態で観測される動き特徴

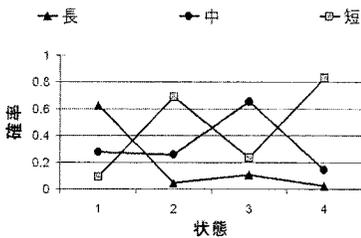


図5 各状態で観測されるショット長特徴

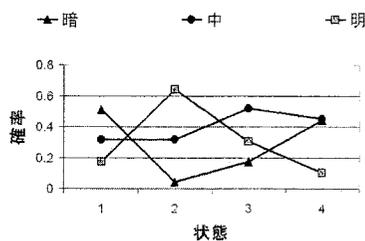


図6 各状態で観測される輝度特徴

らランダムにショットが選択される傾向があることが分かる。

## 5.2 生成されたショット列に関する考察

図10に生成したショット列の各ショットの素材映像における位置及び対応する状態を示す。3.2節で獲得した相対位置分布に従い、ショット列での隣接したショットは、状態1と3では素材映像において隣接した位置から、状態2と4ではランダムな位置から選択される傾向がある。

また、図11に、各状態において選択されたショットのショット長に基づくクラスを示す。同様に、状態1, 3が連続する部

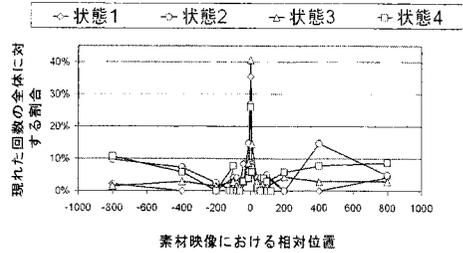


図7 相対位置分布

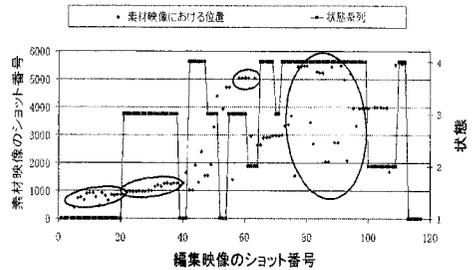


図8 編集映像の各ショットに対する状態と素材映像における位置

分においてそれぞれ“長”、“中”クラス、状態2と4が連続する映像後半においては“短”クラスに属するショットが多く選択されている。これを事例映像と比較するとほぼ一致している。さらに、図12に、各状態において選択されたショットの動き特徴に基づくクラスを示す。図から分かるように映像前半の状態1と3が連続する部分において選択されたショットはほぼ“静”クラスに属するものであるのに対し、状態2と4が連続する映像後半においては“動”クラスに属するショット、映像の最後に再度状態1が連続する部分において再び“静”クラスに属するショットが多く選択されている。実際の予告映像においては“動”クラスに属するショットがより多く選択されている。この理由については、実際の予告映像と他の事例映像の 패턴の差などが考えられるが、より多くの事例映像からの学習や、他の映像を素材映像としたショット列生成により実際に検証する必要がある。生成したショット列に動きの“中”クラスに属するショットが選択されなかったのは、図4から分かるようにこれらのショットが各状態において観測される確率が低いためであると考えられる。

最後に、図9にショット生成において各状態で選択されたショット例を示す。前半部分は会話ショット、状態遷移につれて後半部分ではファイトショットや爆発ショット、最後に再び会話ショットが選択された。

上記のように、提案手法により生成されたショット列の特徴が実際の予告映像のショット列の特徴とほぼ一致することから、事例映像としてアクション映画の予告と本編集映像から学習した、編集映像のショット時系列パターン、及び編集映像において連続したショットの素材映像における相対位置分布がアクション

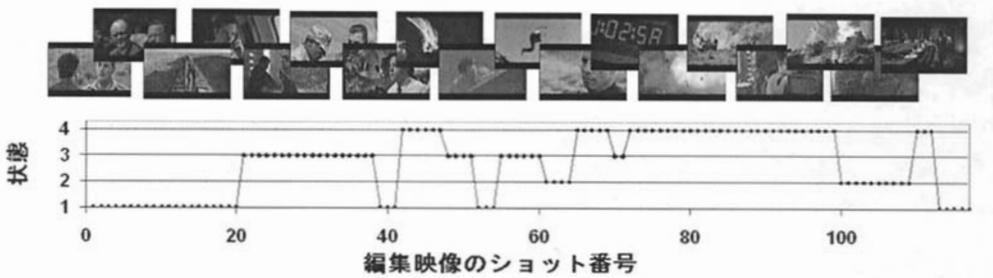


図9 生成したショット列の各状態での代表フレーム

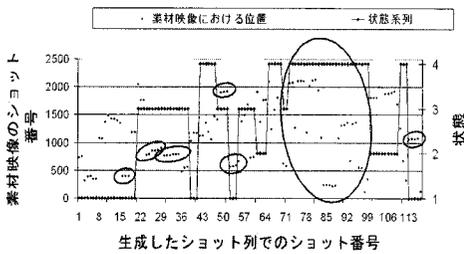


図10 状態系列と生成したショット列のショット分布

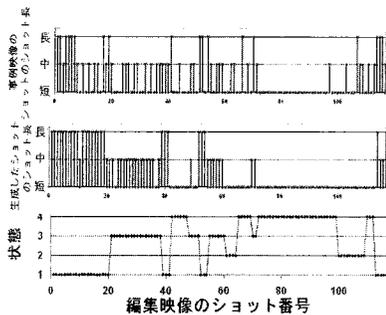


図11 生成したショット列のショット長の変化

の予告映像に共通するパターンであり、これらに基づいたショット生成により、実際のアクション映画の予告映像に類似した編集映像の作成が実現されたと言える。本稿ではアクションジャンルの映像のみ扱っているため、本手法の他ジャンルへの適用及び評価が今後の課題となる。

## 6. まとめ

本稿では、事例映像である編集映像と素材映像から学習した編集映像のショット時系列パターン、及び編集映像における連続ショットの素材映像における相対位置分布に基づいたショット列生成による自動映像編集手法を提案した。編集映像の理想形の例である映画予告映像とその素材映像である映画本編を事

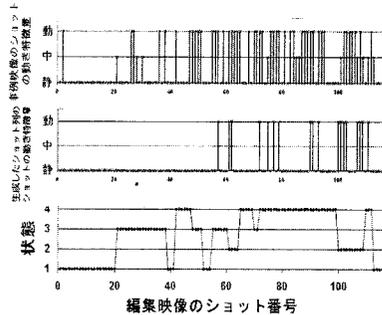


図12 生成したショット列の動き要素の変化

例映像とし、ジャンルをアクションとする事例映像からの学習後、アクション映画本編を素材映像としたショット列生成を行った。実際の予告映像と比較した結果、生成されたショット列の特徴がほぼ実際の予告映像の特徴と一致し、提案手法の有効性が確認された。今後、他ジャンルの映像での学習を行い、同じ素材映像に対するショット列生成により制作された編集映像のジャンルに対する主観評価により、学習効果について検証する必要がある。

## 文献

- [1] G. Jiang, N. Nitta, and N. Babaguchi, “映像編集支援を目標とした映画予告映像からのショット時系列パターンの学習,” 画像の認識・理解シンポジウム 2006(MIRU2006), July, 2006.
- [2] H. Sundaram and S-F. Chang, “Condensing Computable Scenes Using Visual Complexity and Film Syntax Analysis,” Proc. ICME, pp. 389-392, 2001.
- [3] M. Kumano, Y. Ariki, M. Amano, K. Uehara, K. Shunto, and K. Tsukada, “Video Editing Support System Based on Video Grammar and Content Analysis,” Proc. ICPR, vol. 2, p. 1031-1036, 2002.
- [4] L. R. Rabiner, “A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition,” Proc. IEEE, vol. 77, pp. 257-285, 1989.
- [5] <http://www.imdb.com/>
- [6] A. F. Smeaton, B. Lehane, N. E. O'Connor, C. Brady, and G. Craig, “Automatically Selecting Shots for Action Movie Trailers,” Proc. ACM Multimedia, pp. 231-238, 2006.
- [7] H. Zettl, “Sight Sound Motion: Applied Media Aesthetics,” Wadsworth Publishing Co., 1999