

感性キーワードと映像特徴を用いた BGM 自動生成

藤江 哲也 , 相川 清明

東京工科大学バイオ情報メディア研究科
〒192-0982 東京都八王子市片倉町 1404-1
Email g31070252a@gsst.eu.ac.jp

あらまし 近年インターネットによる動画配信、地上デジタル放送による番組に対応する技術にはめまぐるしいものがあり、又その中で番組制作へのスピードも求められてきている。こうした背景において今回 MA 作業という音付け作業に注目し、これを自動化できないかと考えた。今回映像の BGM が流れる部分の特徴を洗い出しそれをもとにソフトウェアを開発した。また、映像と音のメディア変換といった視点からみても新たな視点からソフトウェアを開発した。本方法はバラエティー、ニュース番組等の自動効果音付加システムへの応用やデジタルコンテンツ等のコンテンツの自動生成に応用が考えられる。

Automatic BGM Generation using Emotional Keywords and Movie Features

Tetsuya Fujie Kiyoshi Aikawa

†Tokyo University of Technology

1404-1 katakuracho, Hachioji-shi, Tokyo, 192-0982, Japan

Abstract Recently, it is requested to boost speed for the works on TV program, content production. This report describes a method for automatic BGM generation for Multi Audio works. This method uses both emotional keywords and signal features obtained from the picture sequence. This method can contribute to automation to producing variety and news programs for TV or Internet

1. はじめに

現在のメディア変換を用いた映像コンテンツ、音楽コンテンツへのアプローチは主にシンセサイザーの発する音からきらびやかな映像を自動生成する、映像の特徴量から音を生成するといったリアルタイム性のあるものがほとんどであり、使用法のほとんどが楽器自身として使われているのが現状である。こういったものの多くがユーザーにとって可能性を追求するものにとどまり[1]、ヘビーユーザーしか使用していないような現状をみると、こうしたメディア変換技術がまだ発展途上にあり、誰にでも使いやすくもっと簡潔な方法でツールを使用できるようになつたり、不必要的パラメータ値をコンテンツ自身から取り込めるようになるのではと考えている。従来の研究について映像から音を出すという研究に関して述べていくと映像の周波数から音を出すと言うことはもはや実現されている[1]。しかし、問題としてそれらは意図的に音を出すものではなく、ただ連続的に音を出すものがほとんどである（映像を意図的なものにすれば別だが）。本研究ではこういった音、ミュージックをある意図された時間のみで再生することができないだろうかと考えた。そのため本研究で注目した点は映像が音、ミュージックなどを再生すべきタイムライン上でどのような特徴を持っているか、又それ特徴をどうやって抽出するのかといったところに注目し、効果音自動的にその映像に合った効果音付ができるツールを提案する。またこうした選曲付けの自動化を進めることにより、現状のメディア変換をより効率的なものへと変え、よりインテリジェントな映像制作ツールを構築し、制作の生産効率を上げることに直結し、コンテンツ量を増やしながらも質を落とさないような番組作りが増えると考えた。また、今回映像から人間の服の色を抽出していくこ

とにより、その服が季節感に合った服であるかどうかということを春らしい、夏らしい、秋らしい、冬らしいといった感性語（季節感）にパラメータを変更できるようにした。

2. ソフトウェアに関して

今回開発した自動効果音付加ツールはコンボボックスから音をつけたい感性語（楽しい、さわやかなど）のキーワードを選び書き出しボタン[2]を押すことによくバラエティーの番組にあるような説明部分に的確にBGMを書き出すことができるツールである。




図1 自動効果音付加ツール

ここでは、ニュース番組やバラエティなどの毎週使われるような映像を扱うことを想定している[2]。

3. 自動効果音付加ツール処理の流れ

UI のほとんどは[2]から流用したものだが、今回の研究は効果音書き出しの自動化ということで作った部分は主に書き出し部分、映像読み込み部分である。映像を分析するに当たって、今回は映像の速度場を求め、それが限りなく0に近いときに映像が止まっている（番組の説明部分である）と考えた。本研究ではオプティカルフロー（ブロックマッチング法）を参考に速度場が0に近いフレームを求め速度がある際のペクトルを作ることは省略し、画像全体を動きテンプレートを巡回させることで1フレー

ム前の画像の差分を求めて速度場を求めていった[3][4]。

今回映像の速度場をNTSCの規格を参考に映像信号を 720×480 ドット, 色信号RGBをr,g,bとし、速度場を求めるために巡回させるテンプレートを動きテンプレートとする。




図2 動きテンプレートの説明

動きテンプレートの最小の単位は 4×4 pixelとし、(1, 1)の部分を毎回(a, b)とし、一つの画素Iの中のRGB成分を(r, g, b)と表現し、これを巡回させていった。また、映像から読み込んだ各フレームはframe, 1つ前のフレームをframe-1とし、映像の1フレーム中のr, g, bのそれぞれの動きを T_r, T_g, T_b とした。

$$S(x, y) = \sum_{x=0}^3 \left[\sum_{y=0}^3 I_{a+x, b+y}(r, g, b) \right] \quad (1)$$

$$T(r, g, b) = \sum_{x=4}^{740} \sum_{y=4}^{480} \text{frame} \times S_{xy} - \sum_{x=4}^{740} \sum_{y=4}^{480} (\text{frame}-1) S_{x-1, y-1} \quad (2)$$

$T_r + T_g + T_b$ が限りなく0に近い場合これを動きのないフレームとみなし、10フレーム動きがない場合音を生成するようにした。実際に

softwareを使う場合は音を何度も上書きするようになど動作する。また今回文字キーワードだけでは表現者の意図したBGMを選択できないという観点から映像のパラメータから『季節感』というキーワードを抽出していくようにした。




図3 動きテンプレートを巡回させる際の映像の速度場を求めるフローチャート




図4 色味テンプレートを巡回させるための方法

技術的に言及していくと、まず図4にあるように1フレーム中の人間の顔の色味をキャプチャする[5]。これに関しては顔の大きさがある程度の大きさ（映像の1/4~1/32）であることを想定し、 8×8 pixelの色味テンプレートを毎フレーム中全て巡回させこれがマッチングし

たときにそれを顔と捕えるようにした[3][6]。次にその顔と認識した 8×8 pixel の色味テンプレートと大きさが同じ大きさで顔の下の部分の画像をキャプチャし、それを RGB から HSV に変換することで人間味のある色の識別を可能にした。




図5 色味テンプレートを巡回させた際における、映像から感性キーワードを抽出するためのフローチャート

次に『季節感』というキーワードと結びつけるためにあらかじめ用意した色味を参照することでこの感性語のパラメータを変化させた。ボップアップにあるキーワードと映像から抽出したキーワード（パラメータ）を両方同時に使用することによりマルチモーダルな選曲を可能にしている。この機能は全ての映像中の1フレームで起きればその服に合ったキーワードを取得してくるようにしている。

また、映像フレームにカット検出の技術を用い従来使われているカットを検出したらカットポイントを生成するような使い方でなく、映像が、違うショットに切り替わってもこれをBGMを書き込むポイントだと認識させないようにした[7]。

次に音のBGMを生成することについて技術的に言及していくと、映像の速度場が0に限り

なく近い映像が続くときに音源をキーワードから選ばれた音源を参照し、それまでの映像に動きがある部分には空白トラックを作成した[5][6]。これをつなぎ合わせて書き出すことでDAWや映像制作ツールに書き出したトラックをインポートしたときに何も手を付け加えなくても音源が的確な位置かつ、その映像に適した音を配置することができる。

3. 実験

次は実際に日本語教材用に作られた映像を使いこのツールがどれくらい正確にBGMを生成できるのかということを最小二乗法を用いた単回帰分析行うことで検証した。

映像のサンプルは30種類用意し、それぞれの映像が音を生成し始める時間（startと表記）、生成し終わる時間（endと表記）し、ここで書き込むべきと想定した時間を推定時間、実際に音を生成し始めた時間、し終わる時間を実測時間とし、横軸ラベルを推定時間、縦軸ラベルを実測時間とし、最小二乗法を用いた単回帰分析を用いて行った。ラベルの単位は秒であるとする。なお本論文の全てのグラフは最小二乗法を用いた単回帰分析を用いているものとする。




図6 BGMを生成し始めるタイミングにおける推定時間と実測時間との時間的誤差

表1 図6におけるあてはめの要約

| | |
|--------------------|----------|
| R2乗 | 0.142847 |
| 自由度調整R2乗 | 0.10988 |
| 誤差の標準偏差(RMSE) | 5.229676 |
| Yの平均 | 10.07107 |
| オブザベーション(または重みの合計) | 28 |

図6は音を生成し始めた推定時間と実測時間の分析である。図6の場合はずれ値が極端に直線から離れていてこれによりグラフ上ではあまり正確に音を生成しているように見えないが、推定時間が13秒、実測時間15秒周辺に大きな固まりがある。この部分は正確にBGMを生成できている部分である。またこれだけ書き込む時間がずれる理由として、今回の映像では映像の速度場が0に限りなく近くなるフレームが多くあり、この部分と間違えて音を生成してしまうケースが図6で多々見られた。この部分の精度の悪さに関しては図7で別の視点から考察している。




図7 BGMを生成し終わるタイミングにおける時間と実測時間との時間的誤差

表2 図7におけるあてはめの要約

| | |
|--------------------|----------|
| R2乗 | 0.640851 |
| 自由度調整R2乗 | 0.627038 |
| 誤差の標準偏差(RMSE) | 3.977483 |
| Yの平均 | 15.61179 |
| オブザベーション(または重みの合計) | 28 |

次に図7は音を生成し終わる時間関係を示したものである。図7は全体的にいえばまとまっているようなグラフだが、正確性に関して言えば、図6で示している音を生成し始める実測時間のほうが正確に生成できているものが前述の図6の説明で固まりの部分を示したように多かった。しかし図6、7のグラフは回帰直線の精度自体はそれほど良い精度ではなかった。この理由として映像の速度場が0に近い時間上に音を生成する仕様のため特に図6のような相関をもたないようなグラフになってしまったのだと分析した。




図8 実際にBGMを書き込んだpointと実際にBGMがあるべき場所におけるpointの誤差のグラフ

実際に図8ではプログラム上で音を生成するタイミングをすべて網羅し、その部分にpointと名付けた映像のセグメンテーション作業を施し[3][4]、これをグラフ化した。図6の推定

時間と実測時間の平均誤差は実測時間のほうが推定時間よりも 1.46 秒速く、図 8 で、正しいポイントに生成する BGM の平均は、0.27 秒遅い。

表3 図8におけるあてはめの要約

| | |
|--------------------|----------|
| R2乗 | 0.633629 |
| 自由度調整R2乗 | 0.619537 |
| 誤差の標準偏差(RMSE) | 0.89509 |
| Yの平均 | 2.571429 |
| オブザベーション(または重みの合計) | 28 |

今回の実験で、point といったセグメント化されたデータにおいては 48% という確率で BGM を正確な位置に生成できるようになった。

4.結論

この報告では人間の発するキーワードからだけでなく映像から感性を取得し、それを人間の発想するキーワードとミックスすることでマルチモーダルな効果音自動付加システムを提案した。また、効果音付の自動化を提案した。正確な音付けはまだ実現できていないが、これから精度向上を行いたい。

検討,” 情報処理学会研究報告, I P S J

(A V M) ,pp.145~150

[4]服部しのぶ、亀山渉、富長英義,”映像特徴空間に基づく同系映像の分類,” 情報処理学会研究報告,2003-A V M-43, pp.145~150 , 2003

[5]小渡悟、星野聖 ,”オプティカルフローと色情報に基づく掌の検出と追跡によるジェスチャ認識,” 情報処理学会研究報告, I P S J Vol4 No.SIG9 (C V I M 7) ,pp.47-54

[6]入谷勝、茂野聰登志、前原隆、金丸隆志、関根優年, “テンプレートマッチングにおける主要成分分布の解析,” 映像情報メディア学会技術報告

[7]池添剛、梶川嘉延、野村康雄 ,“音楽感性空間を用いた感性語によるデータベース検索システム,” 情報処理学会研究報告 Vol.42, No.12 ,pp.3201-3212

[8]中神央二、渡辺裕、富永英義 ,“差分画像を利用したアニメーション映像からのオブジェクト抽出,” 情報処理学会オーディオビジュアル複合情報処理,40-6, pp.31~35,2003

参考文献

- [1]池田徹志、室田健吾、石黒浩, “全方位映像から音楽情報へのメディア変換に基づく資格情報の伝達,” 情報処理学会研究報告, Vol.48.No1, pp274-282, 2007
- [2]相川清明、谷島加奈子, “ベクトル空間法を用いた相対的感性表現による音検索,” 情報処理学会研究報告,2006-S L P -65,pp.5-10,Februaly 2007
- [3]奥野洋平、朱青、富永英義,”同画像インデキシングを目的とした人物顔追跡に関する