

Residual CNNを用いた楽曲コード進行推定法 Music chord progression estimation method using Residual CNN

中山翔太†
Shota Nakayama

荒井秀一†
Shuichi Arai

1. まえがき

音楽情報検索の課題の一つにコード進行推定があり、近年盛んに研究されている。特に最近ではディープラーニングを用いたモデルが数多く提案されている。しかし提案されているどのモデルもネットワークの層が浅く、ディープラーニング本来の性能を引き出していないと考える。そこで本稿では、Residual Network(ResNet)に着目し、深いネットワークの学習を可能にする。ResNetは隠れ層を深くするほど精度が上がると言われている手法であり、ResNetとConvolutional Neural Network(CNN)を組み合わせたコード進行推定モデルを提案することで、更なる精度向上を目指す。

2. 先行研究

コード進行は、楽曲における雰囲気を決定づける重要な要素である。楽曲信号からコード進行を正確に推定できれば、楽曲の雰囲気や類似性に基づいた楽曲検索や楽曲推薦、またカバー曲の検索等への応用が可能になる。従来はHMM(Hidden Markov Model)を用いた推定法が主流であったが、近年は画像処理などの分野で用いられている深層学習をコード進行推定に応用した手法が盛んに提案されている。深層学習を用いたコード進行推定法として、F. Koreniowskiら [1]はコード認識の自動化を目的に、DNN(Deep Neural Network)とHMMによるコード進行推定法を提案しているが、この手法はHMMのパラメタ推定の際に大量の学習データを必要とするという問題点がある。また、X. Zhouら [2]は、高度なコード進行推定を目指し、ポトルネットワーク構造のDNNによるコード進行推定を行った。そして先行研究として挙げられる全ての手法は、深層学習を用いているものの隠れ層が多いもので3層ほどであり、ディープラーニング本来の性能を引き出していないと考える。またS.Nakayamaら [3]はDNNをResnet化し、コード進行推定に用いていたが、CNNをResnet化したネットワークモデルは提案されていない。そこで本稿では、Residual Network[4]に着目し、深いネットワークの学習を可能にさせ、更なる認識精度の向上を図れるのではないかと考えた。

3. Residual Network

ResNetのアイデアはとてもシンプルで、隠れ層への入力と隠れ層からの出力を足し合わせることで、勾配法による最適化が容易になるというものである。例えば、図1左のようなネットワークを考える。ここで“Weight Layer”は通常の隠れ層であり、この例では、入力 x を2層の隠れ層に通した出力 $H(x)$ を勾配法で最適化するというのが一般的な手法である。これに対し、ResNetでは

図1右のように最適化したい $H(x)$ と入力 x との残差関数 $F(x) := H(x) - x$ をネットワークの出力として学習させる。すなわち、本来の出力 $H(x)$ は $H(x) = F(x) + x$ と書けるので、図のようにShortcut Connectionをネットワークに追加すればよい。このShortcut Connectionで挟まれた区間を残差ブロックと呼び、この残差ブロックを多段に積み上げて、深いネットワークを構成する。




図1: 一般的な隠れ層から残差ブロックへの変更

これにより、仮に深い層での最適な関数が恒等写像のような関数であった場合、 $H(x) := F(x) + x \approx x$ となるよう、零写像に近い $F(x)$ を学習で見つけ出すことになる。これは、小さな勾配を基に重みを更新し、恒等関数のような $H(x)$ を見つけ出すより非常に簡単であり、勾配消失の影響が少ないため、深いネットワークにおける学習が可能になる。

4. コード進行推定モデル

本稿ではResNetを組み込んだCNNとCRF(Conditional Random Fields)を用いたコード進行推定モデルを提案する。モデル構造を図2に示す。ここで、図2の“conv”は畳み込み層を表し、 (3×3) はフィルタサイズ、Padはパディング数を表す。各畳み込み層に繋がる入力と出力の矢印に添えられた数字は、それぞれ入力、出力の特徴マップの数を表す。“Batch Normalization”はバッチ正規化層を表す。Max PoolingはMaxプーリングの層を表し、Average PoolingはAverageプーリングの層を表し、各プーリング層内に記載された括弧内の値は、プーリングの際のフィルタサイズを表す。“Block”は残差ブロックを n 個重ねていることを表す。この推定モデルは、CNNで特徴を抽出し、“Full Connection(全結合層)”で25個のラベルに分類し、その結果をCRFで音楽的文脈も加味して最終的なラベル系列として出力する。

5. 入力処理

HCQT(Harmonic Constant Q Transform)の窓関数はハニング窓を使用し、各パラメータはサンプリングレートが22050 Hz、フレーム周期が1024 sample、最低周波数は32.700 Hz、最高周波数は2093.005 Hzで

†東京都市大学大学院 工学研究科




図 2: 提案モデルの構造

あり、これら 2 つの周波数の差は 6 オクターブ分ある。さらに、1 オクターブあたり対数周波数 bin の数を 24 個とし、6 オクターブの間で対数周波数 bin の数が 144 個になるよう設定する。

6. 実験条件

6.1. 使用データセット

使用したデータセットは isophonics[‡] が公開しているコード進行のアノテーションである。使用したデータセットの内訳を表 1 に示す。

表 1: 使用データセット内訳

アーティスト	楽曲数
Beatles	180
Queen	20
Zweieck	18
Total	218

6.2. 推定ラベルの種類

本稿では、12 個のピッチクラスと 2 種類 (major, minor) のコードの種類からなる 24 種類のコードと、無音、単音またはパーカッションのみの区間を表す "No Chord" の計 25 種類のラベルの推定を目的とする。

6.3. 評価基準

評価基準として WCSR (Weighted Chord Symbol Recall) を使用した先行研究が数多くあるため、本稿では評価基準として WCSR を用いる。また本稿では、交差検証を用いて評価を行う。その際の分割数は 6 である。

$$WCSR = \frac{\text{推定ラベルが正解した時間の総和}}{\text{楽曲の長さの総和}} \quad (1)$$

7. 実験結果

本提案手法の推定精度を他のアルゴリズムの推定精度と比較した。比較に用いるモデルは、(1) unit 数 256、

隠れ層 3 層の DNN でコードを推定した後、HMM により音楽的文脈を考慮した推定をおこなう DNN-HMM [1] と、(2) 8 層の CNN でコードを推定し、その後段に CRF を置くことで音楽的文脈を考慮した推定をおこなう ConvNet [5]、の 2 つである。この 2 つの手法と提案手法を WCSR を用いて評価した結果を表 2 に示す。

表 2: 他のアルゴリズムとの精度比較

Algorithm	WCSR [%]
DNN-HMM	76.0
ConvNet	77.6
Proposed	77.8

7.1. 検討及び結論

DNN-HMM と比較すると、本提案手法の推定精度は 1.8% 高い。この結果から、DNN-HMM よりも深い隠れ層によって構成される本提案手法を用いることで、より複雑な特徴を学習できたと考える。

ConvNet と比較すると、本提案手法の推定精度との差は 0.2% であり、大きな差はなかった。この理由としては、出力特徴マップの数の違いが考えられる。CNN は各畳み込み層で抽出した特徴を出力特徴マップとして出力する。ConvNet の特徴マップの要素の総数は本提案手法の約 2 倍の数であり、その分だけ多くの特徴を抽出していることが要因だと考える。しかしこれは、ResNet で層を深くすることで、出力特徴マップの要素を半分に削減しても、同等の精度で推定できることを意味し、ResNet の有用性を示す結果であると言える。

これらの結果から、コード進行推定において ResNet が有効であることが分かった。

参考文献

- [1] Filip Korzeniewski and Gerhard Widmer. On the futility of learning complex frame-level language models for chord recognition. Vol. abs/1702.00178, , 2017.
- [2] Zhou X. and Lerch A. Chord detection using deep learning. In *Proceedings of the 16th ISMIR Conference*, pp. 52–58, 2015.
- [3] Shota Nakayama and Arai Shuichi. Residual dnn-crf model for audio chord recognition. *International Conference on Intelligent System and Image Processing (ICISIP)*, pp. 92–98, 2017.
- [4] He Kaiming et al. Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition.*, pp. 770–778, 2016.
- [5] Filip Korzeniewski and Gerhard Widmer. A fully convolutional deep auditory model for musical chord recognition. *Machine Learning for Signal Processing (MLSP)*, pp. 1–6, 2016.

[‡]<http://isophonics.net/datasets>