

# コード進行によるヒット曲予測システムの構築

吉田 隼輔<sup>1</sup> 木村 優介<sup>1</sup> 深山 覚<sup>2</sup> 林 宏樹<sup>1</sup>

**概要:**本研究では、楽曲のコード進行からヒット曲の分析を行い、そこから楽曲がヒットするかを算出する予測モデルを構築する。具体的には Billboard Japan Year End Hot 100 の 2010 年から 2019 年の上位 20 曲のサビ部分のコード進行を用い、3 つの分析を行って予測をした。一つ目の分析では、ダイアトニックコード、繰り返し、コードの種類に着目し、コード進行の複雑性を分析した。二つ目の分析では、tf-idf を用いてコード進行のパターンを分析した。三つ目の分析では、潜在ディリクレ配分法を用いて特徴的なコード進行を分析した。これらの分析結果を数値化したものを入力として、重回帰分析とニューラルネットワークによって楽曲のランキングを予測するシステムを構築した。その後 2020 年の楽曲のコード進行を入力してランキングを予測し、実際のランキングと比較することで予測の性能を確認した。

## 1. はじめに

ある楽曲がヒットするかの予測ができれば、音楽を創る上で参考にできて有用である。また音楽産業にとって、どのような楽曲を売り出すかの戦略を決める上で有益である。このような背景のもと、本研究は日本国内で毎年 3000 曲以上<sup>\*1</sup>リリースされるシングル CD の楽曲中で、楽曲ランキング上位となる楽曲の法則を発見し、そのランクインを予測することを目的とする。

ヒット曲の法則を探る課題は Hit Song Science [1] と呼ばれ多くの研究がされている。楽曲の音響的特徴と歌詞 [2]、音響的特徴と楽曲についてのアノテーション [1,3,4] などからヒットを予測する研究がある。音楽の重要な要素であるコード進行に着目した既存研究では、コード進行の特徴に基づいたクラスタ分析と対数線形モデルを用いた分析が行われている [5,6]。しかしその分析に従ってヒット曲を予測するには至っていなかった。

そこで本研究では、コード進行によってどの程度ヒット曲が予測できるかを調査する。ヒット曲のコード進行データベースを構築し、コード進行の特徴を 3 種類の観点から分析して数値化し、それら数値と楽曲のランクを重回帰分析およびニューラルネットワークによる回帰を行った。その結果を用いて、コード進行から未来のヒット曲を予測するシステムを構築した。

なお本稿では、情報処理学会第 3 回中高生情報学研究コンテストにて発表したコード進行の分析方法 [7] の詳細と、実際にヒット曲を予測するシステムを構築した上での考察を述べる。

## 2. ヒット曲のコード進行データベース

ヒット曲を収集する際には、Billboard Japan が発表する日本におけるシングル楽曲の音楽チャート Japan's Billboard Year-End Hot 100 上位 20 曲を 2010 年から 2020 年までの 11 年分収集した。これらヒット曲のコード進行を調べるために、ギターコード/ウクレレ/ピアノ/バンドスコアが閲覧できるウェブサイト U-FRET<sup>\*2</sup>に掲載されたコード進行を用いた。さらにコードの機能と和声的な役割を分析できるようにするため、すべてのコード進行をハ長調もしくはイ短調へと移調して用いた。

## 3. ヒット曲のコード進行の分析

ヒット曲のコード進行の特徴を、2010 年から 2019 年までのヒット曲 200 曲を使って、以下の 3 種類の観点から分析し数値化した。

- A. コード進行の複雑性
- B. コード進行のパターン
- C. 特徴的なコード進行

分析 A と分析 B ではクラスタリングを行い、得られた複数のクラスタ中心からの距離によって特徴の数値化を行う。分析 C ではトピック分析によって求めたトピック分布の類似度によって数値化を行う。

<sup>1</sup> 兵庫県立姫路西高等学校  
Hyogo Prefecture Himeji Nishi Senior High School

<sup>2</sup> 国立研究開発法人産業技術総合研究所  
National Institute of Advanced Industrial Science and Technology (AIST)

<sup>\*1</sup> 一般社団法人日本レコード協会調べ

<sup>\*2</sup> <https://www.ufret.jp/> (2020 年 2 月閲覧)




図1 コード進行の複雑性の分析による第1 第2 主成分による平面上でのクラスタリング結果. 赤い点が各クラスタのクラスタ中心, 同じ色の点が同一のクラスタに属する楽曲を表す.




図2 エルボー法によるクラスタ数毎の歪み. クラスタ数を増やしても歪みが大きく減少しない箇所をクラスタ数4と見極め, コード進行の複雑性の分析でのクラスタ数を4に決定した.

### 3.1 分析 A：コード進行の複雑性の分析

コードの複雑性を分析するために, 各ヒット曲のコード進行の非ダイアトニックコード率, 非繰り返し率, コード種類数を算出した. 非ダイアトニックコードとは, コード進行に含まれるダイアトニックコードではないコードの数のコード進行の系列長に対する比率である. また非繰り返し率とは, 長さ5以上19以下の長さによるコードの繰り返し単位を検出した上で, それら繰り返し単位に含まれないコードの数のコード進行の系列長に対する比率である. 最後に, コード種類数とはコードネームがコード進行中に何種類出現するかを数えたものである.

非ダイアトニックコード率, 非繰り返し率, コード種類数の3次元からなるデータに対して主成分分析を行い2次元へと次元圧縮をした. このとき寄与率は第1主成分と第2主成分がそれぞれ0.5447と0.286であった. さらに第1主成分と第2主成分を用いてk-meansクラスタリングを行った. このときクラスタ数はエルボー法によって4と決定した. クラスタリングの結果を図1に示す. またクラスタ数を決めるにあたってのエルボー法による歪みの計算結

果を図2に示す.

得られたクラスタは, それぞれ異なった特徴を持つヒットしやすい楽曲の集合を表していると考えられる. また所属する楽曲数が多いクラスタは, よりヒットする傾向が高いコード進行の特徴を持った楽曲のクラスタと考えられる. そこで, ある楽曲のコード進行  $X$  の複雑性の分析結果 (第1主成分と第2主成分) を  $\mathbf{x}_A$ , クラスタそれぞれのクラスタ中心を  $\mathbf{c}_A^i, (i = 1, \dots, 4)$ , クラスタに含まれる楽曲数を  $N_A^i, i = 1, \dots, 4$  とし, コード進行  $X$  の複雑性にもとづいた「ヒットしやすさ度合い」  $f_A(X)$  を以下のように計算した.

$$f_A(X) = \frac{N_A^{i^*}}{|\mathbf{x}_A - \mathbf{c}_A^{i^*}|} \quad (1)$$

ここで  $i^*$  は  $|\mathbf{x}_A - \mathbf{c}_A^i|$  が最小となる  $i$  であり,  $|\mathbf{a}|$  はベクトル  $\mathbf{a}$  のユークリッド距離である.

### 3.2 分析 B：コード進行のパターンの分析

ヒット曲に含まれるコード進行の典型的なパターンを分析するために N-gram ( $N = 3$ ) による分析を行った. 各楽曲ごとに, 連続する3つのコード (トライグラム) の出現回数を調べたのち, それぞれの楽曲に特有なトライグラムを見つけるため, 文書中の単語の重要度を評価する指標の一つである tf-idf (Term Frequency - Inverse Document Frequency) を求めた. 具体的には, トライグラムを単語とし各楽曲を文章とみなして単語文書行列を作成し tf-idf を算出した.

次に tf-idf の値にもとづいてクラスタリングを行った. 各楽曲の tf-idf の平均と標準偏差を求め, 楽曲ごとの2次元の値を用いて k-means クラスタリング (クラスタ数3) を行った. クラスタリング結果を用いて, コード進行  $X$  のパターンにもとづいた「ヒットしやすさ度合い」  $f_B(X)$  を,  $f_A(X)$  と同様に計算した.

$$f_B(X) = \frac{N_B^{i^*}}{|\mathbf{x}_B - \mathbf{c}_B^{i^*}|} \quad (2)$$

ここで  $\mathbf{x}_B$  は楽曲ごとの tf-idf の平均と分散からなる2次元ベクトルであり,  $\mathbf{c}_B^i, (i = 1, \dots, 3)$  はクラスタそれぞれのクラスタ中心,  $N_B^i, i = 1, \dots, 3$  はクラスタに含まれる楽曲数,  $i^*$  は  $|\mathbf{x}_B - \mathbf{c}_B^i|$  が最小となる  $i$  である.

### 3.3 分析 C：特徴的なコード進行の分析

サビにおいてどのような特徴的なコードが現れるかを分析するために, 楽曲を文章, コードを単語とみなして潜在ディリクレ配分法 (Latent Dirichlet Allocation; LDA) [8] によるトピック分析をした. なお分析に用いたコード進行はハ長調もしくはイ短調へ移調して用いており, 各コードは調の中での機能を表していると考えられるため, コードの系列ではなくコードを単語とみなした分析を行うことは妥




図3 トピック数ごとのパープレキシティとコヒーレンスを計算しトピックの数を設定した。パープレキシティが小さくコヒーレンスが大きいトピック数を探しトピック数を7に設定した。

当である。

はじめに各楽曲のコード進行の特徴をより表すコードに限って分析を行うために、7割以上の楽曲に出現するコードと、200曲中で10回以下しか出現しないコードを除外した。

次にLDAのトピック数を決めるため、学習したLDAモデルのパープレキシティとコヒーレンスをPythonモジュールgensimを用いて計算した。パープレキシティは確率モデルによる予測能力の指標であり、値が小さいほど予測候補を少ない数に絞れることを意味する。コヒーレンスは学習された各トピックに含まれる単語間類似度であり、値が高いほど適切なトピックが推定されていることがわかる。トピック数ごとのパープレキシティとコヒーレンスの計算結果を図3に示す。パープレキシティが小さくコヒーレンスが大きいトピック数(7トピック)に決定した。

トピック分析によって得られた各トピックに含まれる単語を可視化(出現確率に比例したフォントサイズで表示)したものを図4に示す。これらトピックの偏りはヒット曲の特徴を反映しており、ある楽曲のコード進行に同様なトピックの偏りがある場合は特徴が似ておりヒットがしやすいと考えられる。

過去のヒット曲のトピック分布と新しい楽曲のトピック分布の類似度を計算することで、ヒットしやすさ度合いを数値化する。まず過去のヒット曲のトピックの相対的な偏り $\alpha_k$ を求めるため、分析データ中の全ての楽曲(200曲)のトピック分布 $p_n(\theta)$ ,  $n=1, \dots, 200$ の総和を以下のように計算した。

$$\alpha_k = \sum_{n=1}^{200} p_n(\theta_k) \quad (3)$$

ここで $n$ は楽曲のインデックス、 $\theta_k$ は $k$ 番目のトピックである。続いて、求めたトピックの相対的な偏りと、あるコード進行 $X$ のトピック分布 $p(\theta)$ の重み付け和を求め、コード進行 $X$ のサビにおけるコード進行の特徴にもとづいた「ヒットしやすさ度合い」 $f_C(X)$ を

$$f_C(X) = \sum_{k=1}^7 \alpha_k p(\theta_k) \quad (4)$$

のように求めた。過去のトピック分布の相加重平均を $q(\theta)$ とすると式(4)は

$$f_C(X) = 200 \sum_{k=1}^7 q(\theta_k) p(\theta_k) \quad (5)$$

と変形できる。このことから、過去のヒット曲のトピック分布とトピック分布 $p(\theta)$ の類似度を内積によって求めていることがわかる。

## 4. ヒット曲予測システムの構築

コード進行の特徴分析によってヒット曲を予測するシステムを構築する。ある楽曲のコード進行 $X$ の特徴量 $f_A(X), f_B(X), f_C(X)$ から、楽曲が音楽チャートにランクインする順位 $r$ を推定する。本研究では、重回帰分析とニューラルネットワークの2種類の方法を用いてヒット曲予測システムの構築を行った。また実際に2020年度のヒット曲の予測を行い、予測された順位を実際の順位と比較した。

### 4.1 重回帰分析による予測

重回帰分析による予測システムを構築した。ある楽曲のコード進行 $X$ の特徴量 $f_A(X), f_B(X), f_C(X)$ を説明変数、楽曲が音楽チャートにランクインする順位 $r$ を目的変数とする回帰式

$$r = \beta_A f_A(X) + \beta_B f_B(X) + \beta_C f_C(X) + \varepsilon \quad (6)$$

を用いて、係数 $\beta_A, \beta_B, \beta_C$ および切片 $\varepsilon$ を最小二乗法によって求めた。得られた回帰式の係数および切片を表1に示す。

求めた回帰式を使い、回帰式を作るに当たって用いなかった年(2020年)の楽曲ランキングを正解データとして、ヒット曲予測の性能を調査した。回帰式を用いて予測した順位を表2に示す。

### 4.2 ニューラルネットワークによる予測

ニューラルネットワークを用いて予測システムを構築した。ある楽曲のコード進行 $X$ の特徴量 $f_A(X), f_B(X), f_C(X)$ を入力すると、楽曲が音楽チャートにランクインする順位 $r$ の逆数が出力されるニューラルネットワークを設計した。

ニューラルネットワークは出力層を含む3層からなり、それぞれの素子数は2, 2, 1である。活性化関数は出力層ではsigmoid関数を用いて0以上1以下の数値を出力できるようにし、それ以外の層ではReLU(Rectified Linear Unit)を用いた。



表 2 2020 年ランキングの予測結果（重回帰：重回帰分析による予測，NN:ニューラルネットワークによる予測）

楽曲名	アーティスト名	正解	重回帰	NN
夜に駆ける	YOASOBI	1	8.0	2.6
Pretender	Official 髭男 disg	2	6.9	5.5
紅蓮華	LiSA	3	11.2	6.8
I LOVE...	Official 髭男 disg	4	9.3	7.5
白日	King Gnu	5	10.8	6.9
香水	瑛人	6	11.0	5.9
宿命	Official 髭男 disg	7	9.3	3.7
マリーゴールド	あいみょん	8	12.2	7.0
炎	LiSA	9	11.6	6.7
裸の心	あいみょん	10	11.5	6.3
イエスタデイ	Official 髭男 disg	11	9.3	2.9
Make you happy	NiziU	12	11.2	6.6
まちがいさがし	菅田将暉	13	10.9	4.3
感電	米津玄師	14	11.5	5.3
D.D.	Snow Man	15	10.7	7.2
115 万キロのフィルム	Official 髭男 disg	16	11.5	7.5
Lemon	米津玄師	17	12.2	6.5
Dynamite	BTS	18	10.4	6.7
Imitation Rain	sixTONES	19	10.8	9.2
ノーダウト	Official 髭男 disg	20	10.6	6.5

[7] 木村優介, 吉田隼輔: 統計, 機械学習 AI を用いた楽曲のヒット予測, 情報処理学会第 3 回中高生情報学研究コンテスト (2021).

[8] Blei, D. M., Ng, A. Y. and Jordan, M. I.: Latent Dirichlet Allocation, *Journal of Machine Learning Research*, Vol. 3, pp. 993–1022 (2003).

[9] Ioffe, S. and Szegedy, C.: Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, *Proceedings of the 32nd International Conference on Machine Learning*, No. 37, pp. 448–456 (2015).

[10] Kingma, D. P. and Ba, J. L.: Adam: A Method for Stochastic Optimization, *Proceedings of the 3rd International Conference on Learning Representations*, pp. 1–13 (2015).

## 6. おわりに

本研究ではコード進行によってどの程度ヒット曲が予測できるかを明らかにするために、ヒット曲のコード進行の特徴量を設計し、特徴量とランキングの順位の間を予測を行い、コード進行から未来のヒット曲を予測システムを構築した。今後、コード進行以外の要素も考慮したヒット曲予測システムを構築できるよう研究を進展させたい。

**謝辞** 本研究は文部科学省の「スーパーサイエンスハイスクール」の指定により国立研究開発法人科学技術振興機構の支援により行われた。

## 参考文献

[1] Pachet, F.: Hit Song Science *Music Data Mining (Chap. 10)*, Taylor & Francis (2011).

[2] Dhanaraj, R. and Logan, B.: Automatic Prediction of Hit Songs, *Proceedings of the International Conference on Music Information Retrieval*, pp. 488–491 (2005).

[3] Ni, Y., Santos-Rodríguez, R., McVicar, M. and Bie, T. D.: Hit Song Science Once Again a Science?, *Proceedings of the 4th International Workshop on Machine Learning and Music*, pp. 1–2 (2011).

[4] Herremans, D., Martens, D. and Sörensen, K.: Dance Hit Song Prediction, *Journal of New Music Research*, Vol. 43, No. 3, pp. 291–302 (2014).

[5] 川井豊大: ギターコードから見る J-POP の特徴の統計解析, 南山大学卒業論文要旨 (2005).

[6] 鶴田 崇: ギターコードから見るヒット曲の違いに関する統計的分析, 南山大学卒業論文要旨 (2009).