

機械学習を用いたヒット曲予測AIの構築

兵庫県立姫路西高等学校 木村優介 吉田隼輔

素朴な疑問

日本国内では毎年3000曲以上の楽曲がリリースされるけど、「ヒットする」楽曲には特徴がないのかな？

楽曲にはいろいろな特徴量がある
メロディ・ハーモニー
リズム・歌詞など

コード進行だけでヒットするかどうか予測できないか？！

過去のヒット曲の「コード進行」と「ランキング結果」のデータがある。

コード進行って「複雑」そうにみえて規則性がある？
コード進行にはある一定の「パターン」がありそう？
ヒットする楽曲のコードには「特徴的な要素」がありそう？

統計手法を用いて数値化

予測モデル構築
ニューラルネットワーク
重回帰分析

機械学習の仕組み

入力 ある曲のコード進行
F G Em7 Am7 F E7
Am7 Gm7 C7 F G
予測モデル
出力 ランキングにつながる予測値を算出

コード進行とランキングのデータ入手の自動化

予測モデルの自動更新

ヒット曲予測AI

1. 研究動機・目的

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の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「コード進行」だけで発見し、そのランクインを予測することを目的とする。

2. 楽曲データベース

【ヒット曲の収集】 Japan's Billboard Year-End Hot 100 2010~2020年 各年上位20曲
【コード進行の取得】 U-FRET サビ部分のみ 長調はハ長調、短調はイ短調に移調

3. 分析手法

2010年から2019年のヒット曲のコード進行を3つの観点で分析

【第一分析】

コード進行の複雑性を数値化

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

【第二分析】

コード進行のパターンを数値化

【第三分析】

特徴的なコード進行を数値化

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

使用した分析手法

主成分分析・クラスタ分析

N-gram解析・クラスタ分析

トピックモデル分析(LDA)

1 3つの特徴量を説明変数、順位を目的変数
ヒット曲(順位)を予測する回帰式の作成

重回帰分析法

2 ニューラルネットワークの設計
入力:3つの特徴量 出力:順位の逆数

ニューラルネットワーク

4. 分析

第一分析

コード進行の複雑性の分析

手順①

コード種類数
コード進行中に出現するコードの種類

非ダイアトニックコード率
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

非繰り返し率
長さ5以上のコードの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

主成分分析

2次元化

寄与率

第一主成分 0.5447
第二主成分 0.2860

手順② 主成分得点をk-meansクラスタリングを行う。

- ・エルボー法によりクラスタ数を4に決定
- ・クラスタごとに分類(図1) ⇒ $f_A(X)$ の値を算出

結果




図1 クラスタリング結果

第二分析

コード進行のパターンの分析

手順①

ヒット曲に含まれるコード進行の典型的なパターン分析

2010~2019年の各楽曲ごとに連続する3つのコード(トライグラム)の出現回数を調べる。

手順②

それぞれの楽曲に特有なトライグラムを見つける
トライグラムを単語、各楽曲を文章とみなしてtf-idf値を算出。

手順③

各楽曲のtf-idfの平均と標準偏差をk-meansクラスタリングを行う。

- ・エルボー法によりクラスタ数を3に決定
- ・クラスタごとに分類(図2) ⇒ $f_B(X)$ の値を算出

トライグラムとは(例)

A,B,C,D,B,A,B
↓
(A,B,C), (B,C,D),
(C,D,B), (D,B,A),
(B,A,B)とわかる

結果




図2 クラスタリング結果

それぞれ異なった特徴を持つヒットしやすい楽曲のクラスタを表す

楽曲数が多いクラスタ → よりヒットする傾向が高いコード進行を持った楽曲のクラスタ

ある楽曲について「ヒットしやすさ度合い」

$$f_A(X), f_B(X) = (\text{所属したクラスタの楽曲数}) \div (\text{中心との距離})$$

第三分析 特徴的なコード進行の分析

- 手順① 楽曲のコード進行から7割以上出現・10個以下しか出現しないコードを削除した。
- 手順② トピック数は評価指標であるPerplexityとCoherenceによって7トピック分けることを決定した。
- 手順③ 楽曲を文章、コードを単語とみなして、LDAを実行した。(図4)




図4 トピックの可視化

結果

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

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

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

過去のヒット曲のトピックの相対的な偏り

n : 楽曲のインデックス
 θ_k : k 番目のトピック

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

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

「ヒットしやすさ度合い」 $f_C(X)$

過去のトピック分布の相加重平均を $q(\theta)$ とする

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

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

トピックはヒット曲の特徴を反映している
・同様なトピックの偏りがある ⇒ ヒットしやすい
・特徴が似ている

5. 結果

コード進行の特徴分析によってヒット曲予測するシステムの構築

曲の特徴量 $f_A(X)$, $f_B(X)$, $f_C(X)$

楽曲が音楽チャートにランクインする順位
の推定につながる予測値を出力

算出した予測値の相対順位と
実際の順位と比較

重回帰分析

説明変数: $A \cdot B \cdot C$ の値 目的変数: 各曲の順位 r

として、回帰式

$$r = \beta_A \times f_A(X) + \beta_B \times f_B(X) + \beta_C \times f_C(X) + \epsilon$$

を用いて、係数及び切片を最小二乗法により求めた。

	係数	標準誤差	t	P-値	下限 95%	上限 95%	下限 95.0%	上限 95.0%
β_A	-0.631133775	0.404479353	-1.560360919	0.120287802	-1.42882418	0.16655663	-1.42882418	0.16655663
β_B	-0.05637123	0.404101941	-0.139497548	0.889200229	-0.853317326	0.740574866	-0.853317326	0.740574866
β_C	-0.988339587	0.404564946	-2.442968915	0.015452785	-1.786198794	-0.19048038	-1.786198794	-0.19048038
ϵ	10.5	0.402858086	26.06376876	1.31346E-65	9.705506962	11.29449304	9.705506962	11.29449304

求めた回帰式を使い、2020年のランキング上位20曲のサビの部分のコード進行を用いて、順位を予測する。

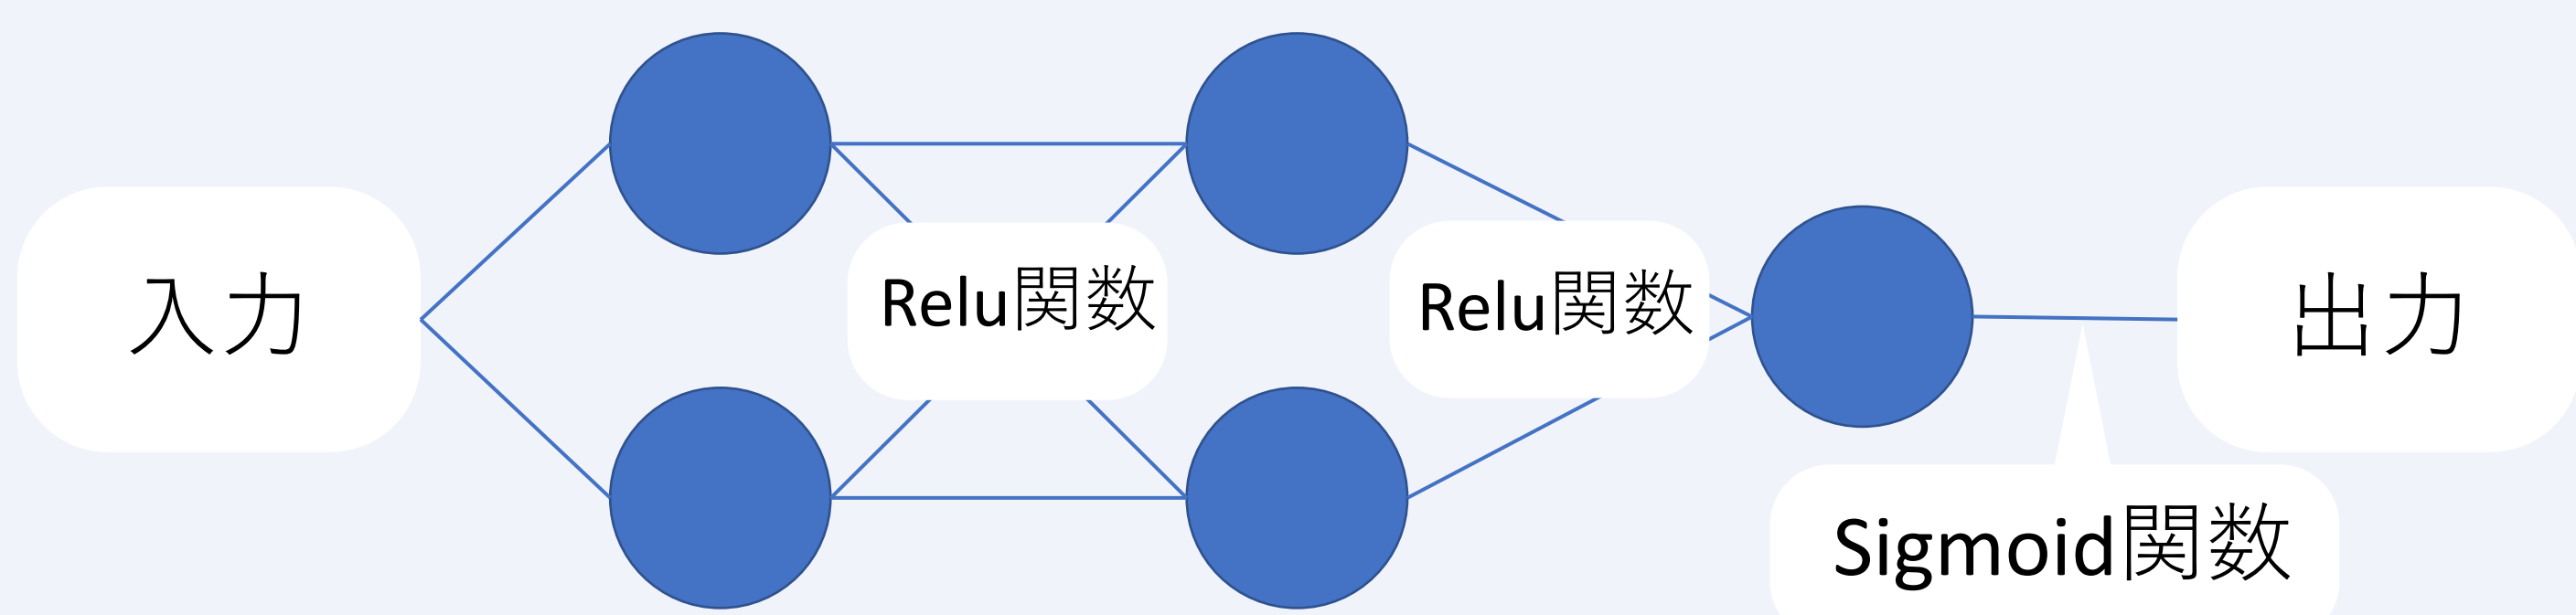
2020年ランキングの予測結果

順位
の推定に
つながる
予測値

楽曲	アーティスト名	正解	重回帰	NN	平均
楽曲A	アーティスト I	1	8.0	2.6	5.3
楽曲B	アーティスト II	2	6.9	5.5	6.2
楽曲C	アーティスト III	3	11.2	6.8	9.0
楽曲D	アーティスト IV	4	9.3	7.5	8.4
楽曲E	アーティスト V	5	10.8	6.9	8.9
楽曲F	アーティスト VI	6	11.0	5.9	8.5
楽曲G	アーティスト VII	7	9.3	3.7	6.5
楽曲H	アーティスト VIII	8	12.2	7.0	9.6
楽曲I	アーティスト IX	9	11.6	6.7	9.2
楽曲J	アーティスト X	10	11.5	6.3	8.9

ニューラルネットワーク

入力: 曲の特徴量 $f_A(X)$, $f_B(X)$, $f_C(X)$ 出力: 順位の逆数




補足

サポートベクトル回帰

各楽曲の特徴量の分布が非線形である

↓
SVRによる順位予測



楽曲の予想順位に明確な差が現れなかった。

6. 考察

コード進行の特徴にもとづいた3種類の分析結果を用いてヒット曲の予測を行い、ランキングの1位と2位のヒット曲の予測を行うことができた。

楽曲A	アーティスト I	1	8.0	2.6
楽曲B	アーティスト II	2	6.9	5.5

重回帰分析で最も上位と予測された楽曲
楽曲Bの予測値6.9 ⇒ 他楽曲と相対的に比較すると1位
ニューラルネットワークで最も上位と予測された楽曲
楽曲Aの予測値2.6 ⇒ 他楽曲と相対的に比較すると1位

⇒ 楽曲A~Jで2つの予測値の平均値の相対的な順位は、実際の1位、2位と一致した!

一方で

その他のランクの予測の精度は不十分

改善案

回帰を二段階で行い、各分析でランキングとの単回帰分析を行った結果を使って重回帰分析を行った

t検定のp値0.93であり有意差は見られなかった

分析精度の向上

分析に用いた楽曲を増やす

サビ以外のコード進行とメロディを用いる

ヒットしなかった楽曲を含めて分析する

今後

コード進行の移調に専門知識が必要 ← 自動化

分析用楽曲データの差し替え → ある条件に沿った予測が可能

7. 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計算し、特徴量とランキングの順位の間での予測を行い、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。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に研究を進展させたい。

【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 Soeren, 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).