

(19) 日本国特許庁(JP)

(12) 特許公報(B2)

(11) 特許番号

特許第4953478号  
(P4953478)

(45) 発行日 平成24年6月13日(2012.6.13)

(24) 登録日 平成24年3月23日(2012.3.23)

(51) Int.Cl. F I  
**G 0 6 F 17/30 (2006.01)** G O 6 F 17/30 3 4 O A  
**G 1 0 L 19/00 (2006.01)** G O 6 F 17/30 1 7 O E  
 G 1 0 L 19/00 3 1 2 Z

請求項の数 13 (全 35 頁)

|   |  |
|---|--|
| <p>(21) 出願番号 特願2009-525449 (P2009-525449)</p> <p>(86) (22) 出願日 平成20年7月31日 (2008.7.31)</p> <p>(86) 国際出願番号 PCT/JP2008/063771</p> <p>(87) 国際公開番号 W02009/017195</p> <p>(87) 国際公開日 平成21年2月5日 (2009.2.5)</p> <p>審査請求日 平成21年12月18日 (2009.12.18)</p> <p>(31) 優先権主張番号 特願2007-199936 (P2007-199936)</p> <p>(32) 優先日 平成19年7月31日 (2007.7.31)</p> <p>(33) 優先権主張国 日本国(JP)</p> <p>(出願人による申告) 平成19年度独立行政法人科学技術振興機構「音楽デザイン転写・音響信号理解に基づく音インタフェース」委託研究、産業技術力強化法第19条の適用を受ける特許出願</p> | <p>(73) 特許権者 301021533<br/>独立行政法人産業技術総合研究所<br/>東京都千代田区霞が関1-3-1</p> <p>(74) 代理人 100091443<br/>弁理士 西浦 ▲嗣▼晴</p> <p>(72) 発明者 後藤 真孝<br/>茨城県つくば市東1-1-1 独立行政法人産業技術総合研究所つくばセンター内</p> <p>(72) 発明者 吉井 和佳<br/>茨城県つくば市東1-1-1 独立行政法人産業技術総合研究所つくばセンター内</p> <p>(72) 発明者 奥乃 博<br/>京都府京都市左京区吉田本町 国立大学法人京都大学大学院 情報学研究科内</p> <p style="text-align: right;">最終頁に続く</p> |
|---|--|

(54) 【発明の名称】 楽曲推薦システム、楽曲推薦方法及び楽曲推薦用コンピュータプログラム

(57) 【特許請求の範囲】

【請求項1】

複数のユーザのそれぞれが複数の楽曲の少なくとも一つについて評価した複数の評価スコアが記憶された評価スコア記憶部と、

前記複数の楽曲の音響信号からそれぞれ抽出した音響的特徴を記憶する音響的特徴記憶部と、

複数の変数と複数のパラメータとを備えて構成された確率モデルを含んで、ある前記ユーザからの楽曲推薦要求に対して前記複数の楽曲の嗜好ランキングを出力する楽曲推薦部と、

前記複数の評価スコアと前記複数の音響的特徴とを入力として、前記複数のパラメータの尤度を最大化するように前記確率モデルの前記複数のパラメータを推定する基本学習部とを備え、

前記楽曲推薦部の前記確率モデルは、前記複数の楽曲に関する変数が記憶されている楽曲変数ノードと、前記複数のユーザに関する変数が記憶されているユーザ変数ノードと、前記複数の音響的特徴に関する変数が記憶されている特徴変数ノードと、複数の概念的なジャンルが隠れ変数として記憶されている隠れ変数ノードとを備え、

前記ユーザ変数ノードと前記隠れ変数ノードとの間には、ある前記ユーザが選ばれたときに該ユーザが前記複数のジャンルのそれぞれを選択する複数のジャンル選択確率が存在しており、

前記隠れ変数ノードと前記楽曲変数ノードとの間には、ある前記ジャンルが選ばれたと

10

20

きに前記複数の楽曲のそれぞれが選択される複数の楽曲選択確率が存在しており、

前記隠れ変数ノードと前記特徴変数ノードとの間には、ある前記ジャンルが選択されたときに選択された前記ジャンルに対して前記複数の音響的特徴に関する変数がそれぞれ発生する複数の特徴発生確率が存在しており、

前記ジャンル選択確率、前記楽曲選択確率及び前記特徴発生確率が、それぞれ互いに独立するように構成された三方向アスペクトモデルが定式化された確率モデルであり、

しかも定式化された前記三方向アスペクトモデルが、ある前記ユーザがある前記楽曲中のある前記音響的特徴を聴く事象の生起確率を求める式の中に、前記ジャンル選択確率、前記楽曲選択確率及び前記特徴発生確率を前記複数のパラメータとして含んでいるものであり、

10

前記楽曲推薦部は、ある前記ユーザからの楽曲推薦要求があったときに、該ユーザについての前記ジャンル選択確率、前記楽曲選択確率及び前記特徴発生確率を用いて該ユーザに対する前記複数の楽曲の嗜好ランキングを出力するように構成されており、

前記評価スコア記憶部を監視して、前記評価スコアの変更及び新たなユーザの追加があるたびに、前記評価スコアを変更した前記ユーザ及び前記新たなユーザについての前記ジャンル選択確率を、前記基本学習部によって定められた前記尤度が最大化された状態を維持するように更新または追加する第1のインクリメンタル学習部と、

前記音響的特徴記憶部を監視して、前記楽曲の追加による前記音響的特徴の追加があるたびに、追加された前記楽曲に関する前記楽曲選択確率を、前記基本学習部によって定められた前記尤度が最大化された状態を維持するように追加する第2のインクリメンタル学習部とを

20

さらに備えていることを特徴とする楽曲推薦システム。

#### 【請求項2】

前記基本学習部は、

前記複数の評価スコアから複数の評価ベクトルを算出する評価ベクトル算出部と、

前記複数の音響的特徴から複数の内容ベクトルを算出する内容ベクトル算出部と、

前記複数の評価ベクトルと前記複数の内容ベクトルに対する前記パラメータの尤度を算出する尤度算出部と、

前記尤度を最大化する方向に前記複数のジャンル選択確率、前記複数の楽曲選択確率及び前記複数の特徴発生確率を更新する更新部と、

30

前記尤度の増加が収束したことを判定すると前記尤度算出部と前記更新部の動作を終了する収束判定部と

を備えている請求項1に記載の楽曲推薦システム。

#### 【請求項3】

前記基本学習部を確立する基本学習部確立システムを更に備え、

前記基本学習部確立システムは、

前記複数のユーザを前記複数の評価スコアに基づいて算出した複数の評価ベクトルに基づいてクラスタリングを行い複数の代表ユーザを決定して、該複数の代表ユーザについての複数の評価ベクトルを算出する代表ユーザ決定部と、

前記複数の楽曲を前記複数の楽曲の前記音響的特徴を示す複数の内容ベクトルに基づいてクラスタリングを行い複数の代表楽曲を決定し、該複数の代表楽曲についての複数の内容ベクトルを算出する代表楽曲決定部と、

40

前記三方向アスペクトモデルが定式化された推定用の確率モデルをコアモデルとして有して、前記複数の代表ユーザについての前記複数の評価ベクトルと前記複数の代表楽曲についての前記複数の内容ベクトルとに基づいて、前記コアモデルの前記ジャンル選択確率、前記楽曲選択確率及び前記特徴発生確率の尤度を最大化するようにこれらの確率を推定するコアモデル学習部と、

前記評価スコア記憶部に記憶されている前記複数のユーザのそれぞれについての前記複数の評価スコアを入力として用い、前記複数のユーザを前記コアモデルに追加するため、前記複数のユーザについてのそれぞれの前記ジャンル選択確率を、前記コアモデル学習部

50

によって定められた尤度が最大化された状態を維持するように順次追加する第1の基本学習部確立用インクリメンタル学習部と、

前記音響的特徴記憶部に記憶されている前記複数の楽曲それぞれの前記複数の音響的特徴を入力として、前記複数の楽曲を前記コアモデルに追加するため、前記複数の楽曲についてのそれぞれの前記楽曲選択確率を、前記コアモデル学習部によって定められた尤度が最大化された状態を維持するように追加する第2の基本学習部確立用インクリメンタル学習部とを備え、

前記第1及び第2の基本学習部確立用インクリメンタル学習部によって追加された複数のユーザについての複数の前記ジャンル選択確率及び前記複数の楽曲についての複数の前記楽曲選択確率を前記コアモデル学習部の前記コアモデルに追加したモデルを前記基本学習部として確立することを特徴とする請求項1に記載の楽曲推薦システム。

【請求項4】

前記第2の基本学習部確立用インクリメンタル学習部による前記コアモデルへの追加を、前記第1の基本学習部確立用インクリメンタル学習部による前記コアモデルへの追加に優先して実行する請求項3に記載の楽曲推薦システム。

【請求項5】

前記楽曲推薦部による推薦精度の低下が予め定めた許容値より大きくなったか否かを判定する推薦精度判定部をさらに備え、

前記推薦精度判定部が前記推薦精度の低下が予め定めた許容値より大きくなったことを判定すると、

前記基本学習部確立システムを再度動作させて、前記基本学習部を更新することを特徴とする請求項3に記載の楽曲推薦システム。

【請求項6】

複数のユーザのそれぞれが複数の楽曲の少なくとも一つについて評価した複数の評価スコアを評価スコア記憶部に記憶する評価スコア記憶ステップと、

前記複数の楽曲の音響信号から音響的特徴を抽出し、前記複数の楽曲のそれぞれについて抽出した複数の前記音響的特徴を音響的特徴記憶部に記憶する音響的特徴記憶ステップと、

前記複数の楽曲に関する変数が記憶されている楽曲変数ノードと、前記複数のユーザに関する変数が記憶されているユーザ変数ノードと、前記複数の音響的特徴に関する変数が記憶されている特徴変数ノードと、複数の概念的なジャンルが隠れ変数として記憶されている隠れ変数ノードとを備え、前記ユーザ変数ノードと前記隠れ変数ノードとの間には、ある前記ユーザが選ばれたときに該ユーザが前記複数のジャンルのそれぞれを選択する複数のジャンル選択確率が存在しており、前記隠れ変数ノードと前記楽曲変数ノードとの間には、ある前記ジャンルが選ばれたときに前記複数の楽曲のそれぞれが選択される複数の楽曲選択確率が存在しており、前記隠れ変数ノードと前記特徴変数ノードとの間には、ある前記ジャンルが選択されたときに選択された前記ジャンルに対して前記複数の音響的特徴に関する変数がそれぞれ発生する複数の特徴発生確率が存在しており、前記ジャンル選択確率、前記楽曲選択確率及び前記特徴発生確率が、それぞれ互いに独立するように構成された三方向アスペクトモデルが定式化されており、しかも定式化された前記三方向アスペクトモデルが、ある前記ユーザがある前記楽曲中のある前記音響的特徴を聴く事象の生起確率を求める式の中に、前記ジャンル選択確率、前記楽曲選択確率及び前記特徴発生確率を複数のパラメータとして含んでおり、ある前記ユーザからの楽曲推薦要求があったときに、該ユーザについての前記ジャンル選択確率、前記楽曲選択確率及び前記特徴発生確率を用いて該ユーザに対する前記複数の楽曲の嗜好ランキングを出力するように構成された確率モデルを用いて、前記ユーザからの楽曲推薦要求に対して前記複数の楽曲の嗜好ランキングを出力する楽曲推薦ステップと、

前記楽曲推薦ステップを実行する前に、前記複数の評価スコアと前記複数の音響的特徴とを入力として、前記複数のパラメータの尤度を最大化するように前記確率モデルの前記

10

20

30

40

50

複数のパラメータを推定する基本学習ステップと、

前記基本学習ステップを実行した後、前記評価スコア記憶部を監視して、前記評価スコアの変更及び新たなユーザの追加があるたびに、前記評価スコアを変更した前記ユーザ及び前記新たなユーザについての前記ジャンル選択確率を、前記基本学習ステップによって定められた前記尤度が最大化された状態を維持するように更新または追加する第1のインクリメンタル学習ステップと、

前記基本学習ステップを実行した後、前記音響的特徴記憶部を監視して、前記楽曲の追加があるたびに、追加された前記楽曲に関する前記楽曲選択確率を、前記基本学習ステップによって定められた前記尤度が最大化された状態を維持するように追加する第2のインクリメンタル学習ステップとをコンピュータで実行する楽曲推薦方法。

10

【請求項7】

前記基本学習ステップは、

前記複数の評価スコアから複数の評価ベクトルを算出する評価ベクトル算出ステップと、

前記複数の音響的特徴から複数の内容ベクトルを算出する内容ベクトル算出ステップと、

前記複数の評価ベクトルと前記複数の内容ベクトルに対する前記パラメータの尤度を算出する尤度算出ステップと、

前記尤度を最大化する方向に前記複数のジャンル選択確率、前記複数の楽曲選択確率及び前記複数の特徴発生確率を更新する更新ステップと、

20

前記尤度の増加が収束したことを判定すると前記尤度算出ステップと前記更新ステップとを終了する収束判定ステップとを備えている請求項6に記載の楽曲推薦方法。

【請求項8】

請求項1に記載の前記基本学習部をコンピュータを用いて確立する基本学習部確立方法であって、

前記複数のユーザを前記複数の評価スコアに基づいて算出した複数の評価ベクトルに基づいてクラスタリングを行い複数の代表ユーザを決定して、該複数の代表ユーザについての複数の評価ベクトルを算出する代表ユーザ決定ステップと、

前記複数の楽曲を前記複数の楽曲の前記音響的特徴を示す複数の内容ベクトルに基づいてクラスタリングを行い複数の代表楽曲を決定し、該複数の代表楽曲についての複数の内容ベクトルを算出する代表楽曲決定ステップと、

30

前記三方向アスペクトモデルが定式化された推定用の確率モデルをコアモデルとして含み、前記複数の代表ユーザについての前記複数の評価ベクトルと前記複数の代表楽曲についての前記複数の内容ベクトルとに基づいて、前記コアモデルの前記ジャンル選択確率、前記楽曲選択確率及び前記特徴発生確率の尤度が最大化するようにこれらの確率を推定するコアモデル学習部を用意するステップと、

前記評価スコア記憶部に記憶されている前記複数のユーザのそれぞれについての前記複数の評価スコアを入力として用い、前記複数のユーザを前記コアモデルに追加するため、前記複数のユーザについてのそれぞれの前記ジャンル選択確率を、前記コアモデル学習部によって定められた尤度が最大化された状態を維持するように順次追加する第1の基本学習部確立用インクリメンタル学習ステップと、

40

前記音響的特徴記憶部に記憶されている前記複数の楽曲それぞれの前記複数の音響的特徴を入力として、前記複数の楽曲を前記コアモデルに追加するため、前記複数の楽曲についてのそれぞれの前記楽曲選択確率を、前記コアモデルによって定められた尤度が最大化された状態を維持するように追加する第2の基本学習部確立用インクリメンタル学習ステップと、

前記第1及び第2の基本学習部確立用インクリメンタル学習ステップによって追加された複数のユーザについての複数の前記ジャンル選択確率及び前記複数の楽曲についての複数の前記楽曲選択確率を前記コアモデル学習部の前記コアモデルに追加したモデルを前記基本学習部として確立することを特徴とする基本学習部確立方法。

50

## 【請求項 9】

前記第 2 の基本学習部確立用インクリメンタル学習ステップを、前記第 1 の基本学習部確立用インクリメンタル学習ステップに優先して実行する請求項 8 に記載の基本学習部確立方法。

## 【請求項 10】

複数の楽曲に関する変数が記憶されている楽曲変数ノードと、複数のユーザに関する変数が記憶されているユーザ変数ノードと、前記複数の楽曲のそれぞれから抽出された複数の音響的特徴に関する変数が記憶されている特徴変数ノードと、複数の概念的なジャンルが隠れ変数として記憶されている隠れ変数ノードとを備え、前記ユーザ変数ノードと前記隠れ変数ノードとの間には、ある前記ユーザが選ばれたときに該ユーザが前記複数のジャンル10のそれぞれを選択する複数のジャンル選択確率が存在しており、前記隠れ変数ノードと前記楽曲変数ノードとの間には、ある前記ジャンルが選ばれたときに前記複数の楽曲のそれぞれが選択される複数の楽曲選択確率が存在しており、前記隠れ変数ノードと前記特徴変数ノードとの間には、ある前記ジャンルが選択されたときに選択された前記ジャンルに対して前記複数の音響的特徴に関する変数がそれぞれ発生する複数の特徴発生確率が存在しており、前記ジャンル選択確率、前記楽曲選択確率及び前記特徴発生確率が、それぞれ互いに独立するように構成された三方向アスペクトモデルが定式化されており、しかも定式化された前記三方向アスペクトモデルが、ある前記ユーザがある前記楽曲中のある前記音響的特徴を聴く事象の生起確率を求める式の中に、前記ジャンル選択確率、前記楽曲20選択確率及び前記特徴発生確率を複数のパラメータとして含んでおり、ある前記ユーザからの楽曲推薦要求があったときに、該ユーザについての前記ジャンル選択確率、前記楽曲選択確率及び前記特徴発生確率を用いて該ユーザに対する前記複数の楽曲の嗜好ランキングを出力するように構成された確率モデルを用いて、ある前記ユーザからの楽曲推薦要求に対して前記複数の楽曲の嗜好ランキングを出力する楽曲推薦機能と、

評価スコア記憶部に記憶された前記複数のユーザのそれぞれが前記複数の楽曲の少なくとも一つについて評価した複数の評価スコアと音響的特徴記憶部に記憶された前記複数の音響的特徴とを入力として、前記複数のパラメータの尤度を最大化するように前記確率モデルの前記複数のパラメータを推定する基本学習機能と、

前記評価スコア記憶部を監視して、前記評価スコアの変更及び新たなユーザの追加があるたびに、前記評価スコアを変更した前記ユーザ及び前記新たなユーザについての前記ジャンル30選択確率を、前記基本学習機能によって定められた前記尤度が最大化された状態を維持するように更新または追加する第 1 のインクリメンタル学習機能と、

前記音響的特徴記憶部を監視して、前記楽曲の追加により前記音響的特徴の追加があるたびに、追加された前記楽曲に関する前記楽曲選択確率を、前記基本学習機能によって定められた前記尤度が最大化された状態を維持するように追加する第 2 のインクリメンタル学習機能とをコンピュータに実現させるための楽曲推薦用コンピュータプログラム。

## 【請求項 11】

前記基本学習機能は、

前記複数の評価スコアから複数の評価ベクトルを算出する評価ベクトル算出機能と、

前記複数の音響的特徴から複数の内容ベクトルを算出する内容ベクトル算出機能と、

前記複数の評価ベクトルと前記複数の音響的特徴を示す複数の内容ベクトルに対する前記パラメータの尤度を算出する尤度算出機能と、

前記尤度を最大化する方向に前記複数のジャンル選択確率、前記複数の楽曲選択確率及び前記複数の特徴発生確率を更新する更新機能と、

前記尤度の増加が収束したことを判定すると前記尤度算出ステップと前記更新機能とを終了する収束判定機能と

を備えている請求項 10 に記載の楽曲推薦用コンピュータプログラム。

## 【請求項 12】

請求項 1 または請求項 8 に記載の前記基本学習部をコンピュータに実現させるための基本学習部確立用コンピュータプログラムであって、

10

20

30

40

50

前記複数のユーザを前記複数の評価スコアに基づいて算出した複数の評価ベクトルに基づいてクラスタリングを行い複数の代表ユーザを決定して、該複数の代表ユーザについての複数の評価ベクトルを算出する代表ユーザ決定機能と、

前記複数の楽曲を前記複数の楽曲の前記音響的特徴を示す複数の内容ベクトルに基づいてクラスタリングを行い複数の代表楽曲を決定し、該複数の代表楽曲についての複数の内容ベクトルを算出する代表楽曲決定機能と、

前記三方向アスペクトモデルが定式化された推定用の確率モデルをコアモデルとして含み、前記複数の代表ユーザについての前記複数の評価ベクトルと前記複数の代表楽曲についての前記複数の内容ベクトルとに基づいて、前記コアモデルの前記ジャンル選択確率、前記楽曲選択確率及び前記特徴発生確率の尤度が最大化するようにこれらの確率を推定するコアモデル学習部を用意する機能と、

10

前記評価スコア記憶部に記憶されている前記複数のユーザのそれぞれについての前記複数の評価スコアを入力として用い、前記複数のユーザを前記コアモデルに追加するため、前記複数のユーザについてのそれぞれの前記ジャンル選択確率を、前記コアモデル学習部によって定められた尤度が最大化された状態を維持するように順次追加する第1の基本学習部確立用インクリメンタル学習機能と、

前記音響的特徴記憶部に記憶されている前記複数の楽曲のそれぞれの前記複数の音響的特徴を入力として、前記複数の楽曲を前記コアモデルに追加するため、前記複数の楽曲についてのそれぞれの前記楽曲選択確率を、前記コアモデル学習部によって定められた尤度が最大化された状態を維持するように追加する第2の基本学習部確立用インクリメンタル学習機能とを前記コンピュータに実現させ、

20

前記第1及び第2の基本学習部確立用インクリメンタル学習機能によって追加された複数のユーザについての複数の前記ジャンル選択確率及び前記複数の楽曲についての複数の前記楽曲選択確率を前記コアモデル学習部の前記コアモデルに追加したモデルを前記基本学習部として確立することを前記コンピュータに実現させることを特徴とする基本学習部確立用コンピュータプログラム。

#### 【請求項13】

請求項10、11または12に記載のプログラムを記録したコンピュータ読み取り可能な記録媒体。

#### 【発明の詳細な説明】

30

#### 【技術分野】

#### 【0001】

本発明は、楽曲推薦システム、楽曲推薦方法及び楽曲推薦用コンピュータプログラムに関するものであり、特に、音楽配信サービスにおいて使用される楽曲推薦技術の効率性とスケーラビリティの改善に関する発明である。

#### 【背景技術】

#### 【0002】

情報処理学会が2006年8月7日に開催した研究発表SIGMUS66（研究会発表2006/8/7）で発行した論文集に掲載された「ユーザの評価と音響的特徴との確率的統合に基づくハイブリッド型音楽推薦システム」と題する論文（非特許文献1）には、3方向アスペクトモデルと呼ばれるベイジアンネットワークを利用したハイブリッド型音楽推薦技術が開示されている。この公知の推薦技術では、「協調フィルタリング」と「内容に基づくフィルタリング」の両方を利用する。「協調フィルタリング」技術では、あるユーザに楽曲を推薦する際に他のユーザの楽曲評価を参考にする。例えば、楽曲A、Bを好むユーザに推薦を行う場合、楽曲A、B、Cを好むユーザが他に多数いれば、楽曲Cを推薦する。しかし、この技術では、以下の2つの問題があった。

40

#### 【0003】

(1) 未評価楽曲（新譜やマイナーな楽曲）は推薦できなかった。

(2) 既知のヒット曲が多く推薦され、バリエーションが乏しかった。

#### 【0004】

50

また「内容に基づくフィルタリング」では、ジャンル、楽器構成、音響的特徴などの音楽要素を音響信号から自動的に抽出し、ユーザが好む楽曲と類似した楽曲を推薦する。しかし、この技術では、以下の2つの問題があった。

【0005】

(1) 音楽要素の自動抽出技術が研究段階で、推薦精度に問題があった。

(2) 音響信号から得られないが、推薦には役立つ情報(人気や文化的背景)を考慮していなかった。

【0006】

これら二つの技術の問題点を考慮して開発されたのが、ハイブリッド型音楽推薦技術である。この技術では、評価情報と内容に基づく情報とを同時に考慮して推薦を行うことで、従来の推薦技術の問題を解決し、推薦精度も改善する。

10

【0007】

具体的には、「ユーザが付与した5段階評価スコア」と「音響信号から自動抽出した音響的特徴」をベイジアンネットワークモデル(3方向アスペクトモデル)を用いて確率的に統合する方式を採用する。このベイジアンネットワークモデル(3方向アスペクトモデル)は、A. Popescul, L. Ungar, D. Pennock及びS. Lawrenceが、UAI, 2001, pp. 437~444 に発表した“Probabilistic Models for Unified Collaborative and Content-based Recommendation in Sparse-data Environments,”と題する論文(非特許文献2)に記載されている。このモデルでは、直接観測できない「概念的なジャンル」を「隠れ変数」として表現することで、ユーザの音楽的嗜好を直接モデル化する。そのため、観測データ(楽曲評価と音響的特徴)の生成過程を自然に表現できる。なお、このモデルの4つのノード間をつなぐ各枝の確率値はEMアルゴリズムによる最尤推定法で求める。この統合方式は理論的で、信頼性が高いことが分かっている。

20

【非特許文献1】2006年8月7日に開催した研究発表SIGMUS66(研究会発表2006/8/7)で発行した論文集に掲載された「ユーザの評価と音響的特徴との確率的統合に基づくハイブリッド型音楽推薦システム」と題する論文

【非特許文献2】A. Popescul, L. Ungar, D. Pennock及びS. Lawrenceが、UAI, 2001, pp. 437~444 に発表した“Probabilistic Models for Unified Collaborative and Content-based Recommendation in Sparse-data Environments,”と題する論文

【発明の開示】

30

【発明が解決しようとする課題】

【0008】

しかしながら、従来のハイブリッド型音楽推薦技術では、学習時間は楽曲数とユーザ数に比例し、わずかなデータ変化でモデルの再学習が必要であった。すなわち、従来の技術では、あるユーザが評価を変えた場合、それに即座に適應することができないだけでなく、新規ユーザや新規楽曲を逐次的に追加登録していくこともできなかった。なぜなら、データが変化するたびに確率モデル全体を再学習する必要があり、その学習時間はユーザ数と楽曲数に比例するからである。そのため、従来の技術では、効率性が悪かった。また、従来の技術では、楽曲数とユーザ数を多くすることに限界があり、数百万曲、数十万人規模のデータを扱うことは現実にはできなかった。

40

【0009】

本発明の目的は、基本学習部で再学習することなしに、新規ユーザ(評価を追加・変更した既存ユーザも新規ユーザと見なす)、新規楽曲を即座に登録できる楽曲推薦システム、楽曲推薦方法及び楽曲推薦用コンピュータプログラムを提供することにある。

【0010】

本発明の他の目的は、数百万曲、数十万人規模のデータを扱うことができる基本学習部を簡単に確立することができる楽曲推薦システム及び楽曲推薦方法を提供することにある。

【0011】

本発明のさらに他の目的は、数百万曲、数十万人規模のデータを扱うことができる基本

50

学習モデルを簡単に確立するのに利用可能なプログラムを提供することにある。

【課題を解決するための手段】

【0012】

本発明は、効率性を改善するため、確率モデル中でデータの変化に関係するパラメータ（確率値）のみを更新する。そこで本発明の楽曲推薦システムでは、評価スコア記憶部と、音響的特徴記憶部と、楽曲推薦部と、基本学習部と、第1のインクリメンタル学習部と、第2のインクリメンタル学習部とを備えている。

【0013】

評価スコア記憶部は、複数のユーザのそれぞれが複数の楽曲の少なくとも一つについて評価した複数の評価スコアを記憶する。また、音響的特徴記憶部は、複数の楽曲の音響信号からそれぞれ抽出した音響的特徴を記憶する。そして、楽曲推薦部は、複数の変数と複数のパラメータとを備えて構成された確率モデルを含んで、あるユーザからの楽曲推薦要求に対して複数の楽曲の嗜好ランキングを出力する。さらに、基本学習部は、複数の評価スコアと複数の音響的特徴とを入力として、複数のパラメータの尤度を最大化するように確率モデルの複数のパラメータを推定する。

【0014】

楽曲推薦部で用いる確率モデルは、複数の楽曲に関する変数が記憶されている楽曲変数ノードと、複数のユーザに関する変数が記憶されているユーザ変数ノードと、複数の音響的特徴に関する変数が記憶されている特徴変数ノードと、複数の概念的なジャンルが隠れ変数として記憶されている隠れ変数ノードとを備えている。そして、この確率モデルでは、ユーザ変数ノードと隠れ変数ノードとの間に、あるユーザが選ばれたときに該ユーザが複数のジャンルのそれぞれを選択する複数のジャンル選択確率が存在している。また、隠れ変数ノードと楽曲変数ノードとの間に、あるジャンルが選ばれたときに複数の楽曲のそれぞれが選択される複数の楽曲選択確率が存在している。さらに隠れ変数ノードと特徴変数ノードとの間に、あるジャンルが選択されたときに選択されたジャンルに対して複数の音響的特徴に関する変数がそれぞれ発生する複数の特徴発生確率が存在している。そして、確率モデルは、ジャンル選択確率、前記楽曲選択確率及び前記特徴発生確率が、それぞれ互いに独立するように構成された三方向アスペクトモデルが定式化された確率モデルである。しかも、定式化された三方向アスペクトモデルは、あるユーザがある楽曲中のある音響的特徴を聴く事象の生起確率を求める式の中に、ジャンル選択確率、楽曲選択確率及び特徴発生確率を複数のパラメータとして含んでいる。また楽曲推薦部は、あるユーザからの楽曲推薦要求があったときに、このユーザについてのジャンル選択確率、楽曲選択確率及び特徴発生確率を用いてこのユーザに対する複数の楽曲の嗜好ランキングを出力するように構成されている。

【0015】

本発明で用いる第1のインクリメンタル学習部は、評価スコア記憶部を監視して、評価スコアの変更及び新たなユーザの追加があるたびに、評価スコアを変更したユーザ及び新たなユーザについてのジャンル選択確率を、基本学習部によって定められた尤度が最大化された状態を維持するように更新または追加する。

【0016】

また、第2のインクリメンタル学習部は、音響的特徴記憶部を監視して、楽曲の追加による音響的特徴の追加があるたびに、追加された楽曲に関する楽曲選択確率を、基本学習部によって定められた尤度が最大化された状態を維持するように追加する。

【0017】

すなわち、本発明によれば、新規ユーザの評価スコアと評価した楽曲の音響的特徴のみを参照して、新規ユーザのジャンル選択確率すなわち音楽的嗜好のみを推定（学習）する。また、新規楽曲の音響的特徴のみを参照して、新規楽曲の楽曲選択確率のみを推定（学習）する。すなわち、本発明では、新規ユーザの評価データの追加、既存ユーザの評価データの追加または変更があったときでも、従来のように、基本学習部における再学習をせずに、新規ユーザのジャンル選択確率及び新規楽曲の楽曲選択確率のみを推定（学習）し

10

20

30

40

50



て、その結果を確率モデルに追加することにより、楽曲の推薦を行うことを可能にする。したがって、本発明によれば、新規ユーザの評価データの追加、既存ユーザの評価データの追加または変更、さらに楽曲の追加を、基本学習部における再学習をすることなく、簡単に行うことができる。本発明のシステムを用いると、データ変化を逐次的にモデルに反映させることができる。

【0018】

なお、基本学習部は、複数の評価スコアから複数の評価ベクトルを算出する評価ベクトル算出部と、複数の評価ベクトルと前記複数の音響的特徴を示す複数の内容ベクトルに対する前記パラメータの尤度を算出する尤度算出部と、複数の音響的特徴から複数の内容ベクトルを算出する内容ベクトル算出部と、尤度を最大化する方向に複数のジャンル選択確率、複数の楽曲選択確率及び複数の特徴発生確率を更新する更新部と、尤度の増加が収束したことを判定すると尤度算出部と更新部の動作を終了する収束判定部とを備えた構成とされるのが好ましい。この構成の基本学習部は、既存の技術によって構築することができる。しかしながら、この基本学習部で、数百万曲、数十万人規模のデータを扱おうとすると、学習に相当の時間を要する。そのため、現実的には、この基本学習部で、数百万曲、数十万人規模のデータを扱うこと（スケーラビリティを上げること）は、無理がある。

10

【0019】

そこで、本発明では、基本学習部を確立する基本学習部確立システムを更に備える構成とすることが好ましい。基本学習部確立システムは、代表ユーザ決定部と、代表楽曲決定部と、コアモデル学習部と、第1の基本学習部確立用インクリメンタル学習部と、第2の基本学習部確立用インクリメンタル学習部とから構成することができる。

20

【0020】

代表ユーザ決定部は、複数のユーザを複数の評価スコアに基づいて算出した複数の評価ベクトルに基づいてクラスタリングを行い、複数の代表ユーザを決定し、複数の代表ユーザについての複数の評価ベクトルを算出する。また、代表楽曲決定部は、複数の楽曲を複数の楽曲の音響的特徴を示す複数の内容ベクトルに基づいてクラスタリングを行い、複数の代表楽曲を決定し、該複数の代表楽曲についての複数の内容ベクトルを算出する。

【0021】

コアモデル学習部は、三方向アスペクトモデルが定式化された推定用の確率モデルをコアモデルとして有している。そして、コアモデル学習部は、複数の代表ユーザについての複数の評価ベクトルと複数の代表楽曲についての複数の内容ベクトルとに基づいて、コアモデルのジャンル選択確率、楽曲選択確率及び特徴発生確率の尤度を最大化するように、これらの確率を推定する。

30

【0022】

第1の基本学習部確立用インクリメンタル学習部は、評価スコア記憶部に記憶されている複数のユーザのそれぞれについての複数の評価スコアを入力として用い、複数のユーザをコアモデルに追加するため、複数のユーザについてのそれぞれのジャンル選択確率を、コアモデル学習部によって定められた尤度が最大化された状態を維持するように順次追加する。また、第2の基本学習部確立用インクリメンタル学習部は、音響的特徴記憶部に記憶されている複数の楽曲のそれぞれの複数の音響的特徴を入力として、複数の楽曲をコアモデルに追加するため、複数の楽曲についてそれぞれの楽曲選択確率を、コアモデル学習部によって定められた尤度が最大化された状態を維持するように追加する。そして、最終的に、第1及び第2の基本学習部確立用インクリメンタル学習部によって追加された複数のユーザについての複数のジャンル選択確率及び複数の楽曲についての複数の楽曲選択確率を、コアモデル学習部のコアモデルに追加したモデルを基本学習部として確立する。このようにすると、基本学習部を確立する場合においても、複数のユーザについてのジャンル選択確率の推定（学習）及び複数の楽曲についての楽曲選択確率の推定（学習）演算のみを行うだけでよいので、数百万曲、数十万人規模のデータになっても、演算処理は簡単に行うことができる。したがって、この基本学習部確立システムを用いて、基本学習部を確立すれば、スケーラビリティを任意に拡大することが可能になる。なお、このシステムで

40

50

は、スケーラビリティを改善するために、大量のユーザと楽曲から一定数の代表的なユーザと楽曲を仮想的に生成し、それらに対してコンパクトな「コアモデル」を構築する。そして、コアモデルを、データの元になるユーザと楽曲を逐次的に登録しながら更新することになる。

**【0023】**

基本学習部確立システムを用いて、基本学習部を確立した後は、楽曲推薦システムにおいて、この確立した基本学習部を用い、前述の第1及び第2のインクリメンタル学習部を用いて、さらに、ユーザの追加及び楽曲の追加を行う。なお、ユーザの追加数及び楽曲の追加数が多くなり過ぎると、推薦精度が低下することがある。その場合には、推薦部による推薦精度の低下が予め定めた許容値より大きくなったか否かを判定する推薦精度判定部をさらに備えておけばよい。そして、推薦精度判定部が、推薦精度の低下が予め定めた許容値より大きくなったことを判定したときには、基本学習部確立システムを再度動作させて、基本学習部を更新する。このようにすることにより、基本学習部が、それまでに集まったすべてのユーザの評価データ及びすべての楽曲のデータを元に、コアモデルのパラメータを再推定（更新）することになり、低下した推薦精度を回復することができる。

10

**【0024】**

なお、第2の基本学習部確立用インクリメンタル学習部による追加を先に実行し、第1の基本学習部確立用インクリメンタル学習部による追加を後にしたほうが、推薦精度が高くなる。このことは実験により確認されている。

**【0025】**

本発明は、コンピュータを利用して実施する楽曲推薦方法としても捉えることができる。本発明の楽曲推薦方法では、まず、複数のユーザのそれぞれが、複数の楽曲の少なくとも一つについて評価した複数の評価スコアを評価スコア記憶部に記憶する（評価スコア記憶ステップ）。また、複数の楽曲の音響信号から音響的特徴を抽出し、複数の楽曲のそれぞれについて抽出した複数の音響的特徴を音響的特徴記憶部に記憶する（音響的特徴記憶ステップ）。これらの2つのステップは、どちらを先に実行してもよい。

20

**【0026】**

楽曲推薦ステップでは、確率モデルを用いて、ユーザからの楽曲推薦要求に対して前記複数の楽曲の嗜好ランキングを出力する。使用する確率モデルは、前述の楽曲推薦システムで使用するものと同じである。

30

**【0027】**

楽曲推薦ステップを実行する前には、複数の評価スコアと複数の音響的特徴とを入力として、複数のパラメータの尤度を最大化するように、確率モデルの複数のパラメータを推定する基本学習ステップを実行する。そして、基本学習ステップが終了した後は、常時、第1のインクリメンタル学習ステップと、第2のインクリメンタル学習ステップが実行可能な状態になる。第1のインクリメンタル学習ステップでは、評価スコア記憶部を監視して、評価スコアの変更及び新たなユーザの追加があるたびに、評価スコアを変更したユーザ及び新たなユーザについてのジャンル選択確率を、基本学習ステップによって定められた尤度が最大化された状態を維持するように、更新または追加する。第2のインクリメンタル学習ステップでは、音響的特徴記憶部を監視して、楽曲の追加があるたびに、追加された楽曲に関する楽曲選択確率を、基本学習ステップによって定められた尤度が最大化された状態を維持するように更新または追加する。第1及び第2のインクリメンタル学習ステップは、必要に応じて実行され、これらのステップに優先順位はない。

40

**【0028】**

基本学習ステップでは、次の複数のステップが実行される。まず、複数の評価スコアから複数の評価ベクトルを算出する（評価ベクトル算出ステップ）。また、複数の音響的特徴から複数の内容ベクトルを算出する（内容ベクトル算出ステップ）。そして、複数の評価ベクトルと複数の音響的特徴を示す複数の内容ベクトルに対するパラメータの尤度を算出する（尤度算出ステップ）。これら二つのステップに優先順位はない。次に、尤度を最大化する方向に複数のジャンル選択確率、複数の楽曲選択確率及び複数の特徴発生確率を

50

推定（更新）する（更新ステップ）。そして、尤度の増加が収束したことを判定すると尤度算出ステップと更新ステップとを終了する（収束判定ステップ）。

【 0 0 2 9 】

前述の基本学習部確立する技術は、コンピュータで実施する基本学習部確立方法としても捉えることができる。この基本学習部確立方法では、以下の複数のステップにより、コンピュータを用いて基本学習部を確立する。まず、複数のユーザを複数の評価スコアに基づいて算出した複数の評価ベクトルに基づいて、クラスタリングを行い複数の代表ユーザを決定して、該複数の代表ユーザについての複数の評価ベクトルを算出する（代表ユーザ決定ステップ）。また、複数の楽曲を複数の楽曲の音響的特徴を示す複数の内容ベクトルに基づいてクラスタリングを行い複数の代表楽曲を決定し、該複数の代表楽曲についての複数の内容ベクトルを算出する（代表楽曲決定ステップ）。これら2つのステップに優先順位はない。そして、三方向アスペクトモデルが定式化された推定用の確率モデルをコアモデルとして含み、複数の代表ユーザについての複数の評価ベクトルと複数の代表楽曲についての複数の内容ベクトルとに基づき、コアモデルのジャンル選択確率、楽曲選択確率及び特徴発生確率の尤度が最大化するように、これらの確率を推定するコアモデル学習部を用意する（コアモデル学習部準備ステップ）。

10

【 0 0 3 0 】

次に、評価スコア記憶部に記憶されている複数のユーザのそれぞれについての複数の評価スコアを入力として用い、複数のユーザをコアモデルに追加するため、複数のユーザについてのそれぞれのジャンル選択確率を、コアモデル学習部によって定められた尤度が最大化された状態を維持するように順次追加する（第1の基本学習部確立用インクリメンタル学習ステップ）。また、音響的特徴記憶部に記憶されている複数の楽曲のそれぞれの複数の音響的特徴を入力として、複数の楽曲をコアモデルに追加するため、複数の楽曲についてのそれぞれの楽曲選択確率を、コアモデル学習部によって定められた尤度が最大化された状態を維持するように追加する（第2の基本学習部確立用インクリメンタル学習ステップ）。そして、第1及び第2の基本学習部確立用インクリメンタル学習ステップによって追加された複数のユーザについての複数のジャンル選択確率及び複数の楽曲についての複数の楽曲選択確率をコアモデル学習部のコアモデルに追加したモデルを、基本学習部として確立する。

20

【 0 0 3 1 】

なお、本発明は、コンピュータに楽曲推薦方法を実行させる楽曲推薦用コンピュータプログラムとしても捉えることができる。本発明の楽曲推薦用コンピュータプログラムは、以下の機能をコンピュータに実現させるように構成されている。すなわち、楽曲推薦システムで採用した確率モデルと同じ確率モデルを用いて、あるユーザからの楽曲推薦要求に対して複数の楽曲の嗜好ランキングを出力する楽曲推薦機能と、基本学習機能と、第1及び第2のインクリメンタル学習機能である。基本学習機能は、評価スコア記憶部に記憶された複数のユーザのそれぞれが複数の楽曲の少なくとも一つについて評価した複数の評価スコアと音響的特徴記憶部に記憶された複数の音響的特徴とを入力として、確率モデルの複数のパラメータの尤度を最大化するように確率モデルの複数のパラメータを推定する機能である。そして、第1のインクリメンタル学習機能は、評価スコア記憶部を監視して、評価スコアの変更及び新たなユーザの追加があるたびに、評価スコアを変更したユーザ及び新たなユーザについてのジャンル選択確率を、基本学習機能によって定められた尤度が最大化された状態を維持するように更新または追加する機能である。また、第2のインクリメンタル学習機能は、音響的特徴記憶部を監視して、楽曲の追加により音響的特徴の追加があるたびに、追加された楽曲に関する楽曲選択確率を、基本学習部によって定められた尤度が最大化された状態を維持するように更新または追加する機能である。

30

40

【 0 0 3 2 】

基本学習機能は、複数の評価スコアから複数の評価ベクトルを算出する評価ベクトル算出機能と、複数の音響的特徴から複数の内容ベクトルを算出する内容ベクトル算出機能と、複数の評価ベクトルと複数の音響的特徴を示す複数の内容ベクトルに対するパラメータ

50

の尤度を算出する尤度算出機能と、尤度を最大化する方向に複数のジャンル選択確率、複数の楽曲選択確率及び複数の特徴発生確率を更新する更新機能と、尤度の増加が収束したことを判定すると、尤度算出ステップと更新手機能とを終了する収束判定機能とを備えている。

【0033】

また、基本学習部をコンピュータに実現させるための基本学習部確立用プログラムは、以下の代表ユーザ決定機能と、代表楽曲決定機能と、コアモデル学習部準備機能と、第1及び2の基本学習部確立用インクリメンタル学習機能をコンピュータに実現させるように構成されている。代表ユーザ決定機能は、複数のユーザを複数の評価スコアに基づいて算出した複数の評価ベクトルに基づいてクラスタリングを行い、複数の代表ユーザを決定して、該複数の代表ユーザについての複数の評価ベクトルを算出する機能である。また、代表楽曲決定機能は、複数の楽曲を複数の楽曲の音響的特徴を示す複数の内容ベクトルに基づいてクラスタリングを行い、複数の代表楽曲を決定し、該複数の代表楽曲についての複数の内容ベクトルを算出する機能である。さらに、コアモデル学習部準備機能は、三方向アスペクトモデルが定式化された推定用の確率モデルをコアモデルとして含み、複数の代表ユーザについての複数の評価ベクトルと前記複数の代表楽曲についての複数の内容ベクトルとに基づいて、コアモデルのジャンル選択確率、楽曲選択確率及び前記特徴発生確率の尤度が最大化するように、これらの確率を推定するコアモデル学習部を用意する機能である。そして、第1の基本学習部確立用インクリメンタル学習機能は、評価スコア記憶部に記憶されている複数のユーザのそれぞれについての複数の評価スコアを入力として用い、複数のユーザをコアモデルに追加するため、複数のユーザについてのそれぞれのジャンル選択確率を、コアモデル学習部によって定められた尤度が最大化された状態を維持するように順次追加する機能である。さらに第2の基本学習部確立用インクリメンタル学習機能は、音響的特徴記憶部に記憶されている複数の楽曲のそれぞれの複数の音響的特徴を入力として、複数の楽曲をコアモデルに追加するため、複数の楽曲についてのそれぞれの楽曲選択確率を、コアモデル学習部によって定められた尤度が最大化された状態を維持するように追加する機能である。なお、このプログラムでは、第1及び第2の基本学習部確立用インクリメンタル学習機能によって追加された複数のユーザについての複数のジャンル選択確率及び複数の楽曲についての複数の楽曲選択確率をコアモデル学習部のコアモデルに追加したモデルを基本学習部として確立する。

【0034】

なお、これらのコンピュータプログラムはコンピュータ読み取り可能な記録媒体に記録されていてもよい。

【発明の効果】

【0035】

本発明によれば、新規ユーザの評価データの追加、既存のユーザの評価データの追加または変更、さらに楽曲の追加を、基本学習部における再学習をすることなく、簡単に行うことができる。本発明のシステムを用いると、データ変化を逐次的にモデルに反映させることができる。

【0036】

また、基本学習部確立システムを用いていれば、基本学習部を確立する場合においても、複数のユーザについてのジャンル選択確率の推定（学習）及び複数の楽曲についての楽曲選択確率の推定（学習）演算のみを行うだけでよいので、数百万曲、数十万人規模のデータになっても、演算処理は簡単に行うことができ、スケーラビリティを任意に拡大することが可能になる。

【図面の簡単な説明】

【0037】

【図1】本実施の形態の楽曲推薦システムの構成の一例を示すブロックである。

【図2】本実施の形態で使用する三方向アスペクトモデルを示す模式図である。

【図3】EMアルゴリズムを利用して構成する基本学習部の構成の一例を示すブロックで

10

20

30

40

50

ある。

【図4】基本学習部をプログラムで実現する場合に用いるプログラムのアルゴリズムを示すフローチャートである。

【図5】ステップST42の詳細を示すフローチャートである。

【図6】ステップST44の詳細を示すフローチャートである。

【図7】ステップST45の詳細を示すフローチャートである。

【図8】図1の実施の形態をコンピュータを用いて実現する場合に用いるプログラムのアルゴリズムを示すフローチャートである。

【図9】ステップST4の詳細を示すフローチャートである。

【図10】ステップST6の詳細を示すフローチャートである。

10

【図11】基本学習部確立システムの一例の構成を示すブロック図である。

【図12】基本学習部確立システムのオペレーションの状態を模擬的に示す図である。

【図13】評価行列Rの計算例を示す図である。

【図14】本学習部確立システムをプログラムでコンピュータにより実現する場合のプログラムのアルゴリズムの一例を示すフローチャートである。

【図15】基本学習部確立システムと、推薦精度判定部と、楽曲推薦システムとをプログラムによりコンピュータで実現する場合に用いるプログラムのアルゴリズムを示すフローチャートである。

【図16】クロスバリデーションのためのデータの準備を示す図である。

【図17】推薦精度の計算例を示す図である。

20

【図18】インクリメンタル学習に利用する評価スコアの増加に伴う推薦精度の低下を実験した結果を示す図である。

【図19】既存ユーザと新規ユーザに対する推薦精度の比較を示す図である。

【図20】既存楽曲と新規楽曲の推薦精度の比較を示す図である。

【図21】スケーラビリティを改善した場合の推薦精度の変化を示す図である。

【符号の説明】

【0038】

1 楽曲推薦システム

3 評価スコア記憶部

5 音響的特徴記憶部

7 楽曲データ記憶部

9 記憶装置

11 音響的特徴抽出部

13 確率モデル

15 楽曲推薦部

17 基本学習部

19 第1のインクリメンタル学習部

21 第2のインクリメンタル学習部

23 基本学習部確立システム

25 推薦精度判定部

30

40

【発明を実施するための最良の形態】

【0039】

以下、図面を参照して、本発明の楽曲推薦方法を実施する本発明の楽曲推薦システムの実施の形態の一例を詳細に説明する。図1は、本実施の形態の楽曲推薦システム1の構成の一例を示すブロック図である。この楽曲推薦システム1では、評価スコア記憶部3と、音響的特徴記憶部5と、楽曲データ記憶部7とを備えた記憶装置9と、音響的特徴抽出部11と、確率モデル13を備えた楽曲推薦部15と、基本学習部17と、第1のインクリメンタル学習部19と、第2のインクリメンタル学習部21とを備えている。なお、図1には、基本学習部17を確立するために本発明の別の実施の形態で用いる基本学習確立システム23と推薦精度判定部25についても併せて示してある。

50

## 【0040】

評価スコア記憶部3は、複数のユーザのそれぞれが複数の楽曲の少なくとも一つについて評価した複数の評価スコアを記憶する。ここで、ユーザ群を  $U = \{u_1, \dots, u_{|U|}\}$  とし、楽曲群を  $M = \{m_1, \dots, m_{|M|}\}$  とする。ここで、 $|U|$  と  $|M|$  は、ユーザ数と楽曲数を表し、 $U$  および  $M$  はあらかじめデータベースに登録されているものとする。本発明の楽曲推薦システムは確率モデルに基づいており、 $u \in U$  と  $m \in M$  を確率変数として扱う。その他の付加的な情報（タイトルやアーティスト名、ジャンルなど）などは楽曲推薦に利用しない。ユーザの楽曲についての評価スコアは評価スコア記憶部3に登録されている。この評価スコアは、ユーザの再評価により、変化したり増加したりすることがある。本実施の形態では、楽曲の評価スコアは0（最低スコア：大嫌い）から4（最高スコア：大好き）の5段階とし、 $r_{u,m}$  ( $0 \leq r_{u,m} \leq 4$ ) をユーザ  $u$  が楽曲  $m$  に対して与えたスコアと定義する。ただし、ユーザ  $u$  が楽曲  $m$  に評価を与えていない場合、 $r_{u,m}$  には「空スコア」として便宜上  $0$  を代入しておく。全ユーザの評価スコアを集めることで、評価行列  $R$  が得られる。

$$R = \{r_{u,m} \mid u \in U, m \in M\} \dots\dots (1)$$

ここで、ユーザは  $M$  中のごく一部の楽曲にしか評価スコアを付与しないため、評価行列  $R$  中のほとんどの要素が  $0$  であることに注意する必要がある。

## 【0041】

また、音響的特徴記憶部5は、楽曲データ記憶部7に記憶された複数の楽曲の音響信号から音曲的特徴抽出部11がそれぞれ自動抽出した複数の音響的特徴を記憶する。この音響的特徴も特徴行列  $C$  として表すことができる。この特徴行列  $C$  は、楽曲  $m$  における例えば特徴  $t$  の重み  $c_{m,t}$  を並べた  $M \times T$  行列のデータである。例えば、特徴数  $T$  が64次元であり、1曲の音響的特徴は、1つの特徴量ベクトル（内容ベクトル）で表現できるものと仮定している。具体的には、特徴量ベクトルは各次元が意味的に等価であり、和は1に正規化されているものとする。例えば、楽曲全体の平均的な周波数帯域ごとのパワー比、あるいは小さな時間フレームから抽出した音響的特徴群を混合ガウス分布でフィッティングした時の重みなどが考えられる。本実施の形態では、楽曲群  $M$  に対応する音響信号が利用可能であると仮定している。いま、 $T = \{t_1, \dots, t_{|T|}\}$  を特徴量とする。ここで  $|T|$  は特徴量の種類数（特徴量ベクトルの次元）を表す。 $c_{m,t}$  を楽曲  $m$  から抽出した特徴  $t$  の重みとする。ここで  $\sum_t c_{m,t} = 1$  である。全楽曲の特徴量ベクトルを集めることで、内容行列  $C$  が得られる。

$$C = \{c_{m,t} \mid m \in M, t \in T\} \dots\dots (2)$$

なお本実施の形態では、この内容行列  $C$  として、発明者等が先に前述の非特許文献1で提案した Bag - Of - Timbres 法を用いて、多重音色分布行列  $C$  を生成した。

## 【0042】

そして、楽曲推薦部15は、複数の変数と複数のパラメータとを備えた構成とされた確率モデル13を含んでおり、あるユーザからの楽曲推薦要求に対して複数の楽曲の嗜好ランキングを出力するように構成されている。本実施の形態では、楽曲評価スコアと音楽的内容即ち音響的特徴とを統合するため、前述の非特許文献2に示された Popescu らによって提案された三方向アスペクトモデルと呼ばれるベイジアンネットワークを確率モデル13として利用する。図2は、本実施の形態で使用する三方向アスペクトモデルを示す模式図である。この確率モデルは、複数の楽曲  $M$  に関する変数が記憶されている楽曲変数ノード  $N1$  と、複数のユーザ  $U$  に関する変数が記憶されているユーザ変数ノード  $N2$  と、複数の音響的特徴に関する変数が記憶されている特徴変数ノード  $N3$  と、複数の概念的なジャンルが隠れ変数として記憶されている隠れ変数ノード  $N4$  とを備えている。そして、この確率モデルでは、ユーザ変数ノード  $N2$  と隠れ変数ノード  $N4$  との間に、あるユ

10

20

30

40

50

ユーザ  $u$  が選ばれたときに該ユーザ  $u$  が複数のジャンル  $Z$  のそれぞれを選択する複数のジャンル選択確率  $p(z | u)$  が存在している。ここで、ジャンル選択確率  $p(z | u)$  は、ユーザ  $u$  がジャンル  $Z$  を選択する確率であり、ユーザの音楽的嗜好を示すものである。また、隠れ変数ノード  $N_4$  と楽曲変数ノード  $N_1$  との間に、あるジャンルが選ばれたときに複数の楽曲のそれぞれが選択される複数の楽曲選択確率  $p(m | z)$  が存在している。さらに隠れ変数ノード  $N_4$  と特徴変数ノード  $N_3$  との間に、あるジャンルが選択されたときに選択されたジャンルに対して複数の音響的特徴に関する変数がそれぞれ発生する複数の特徴発生確率  $p(t | z)$  が存在している。この確率モデル 13 は、ジャンル選択確率  $p(z | u)$ 、楽曲選択確率  $p(m | z)$  及び特徴発生確率  $p(t | z)$  が、それぞれ互いに独立するように構成された三方向アスペクトモデルが定式化された確率モデルである。しかも、定式化された三方向アスペクトモデルは、あるユーザ  $u$  がある楽曲  $m$  中のある音響的特徴を聴く事象の生起確率を求める後述する式の中に、ジャンル選択確率  $p(z | u)$ 、楽曲選択確率  $p(m | z)$  及び特徴発生確率  $p(t | z)$  を複数のパラメータとして含んでいる。楽曲推薦部 15 は、あるユーザからの楽曲推薦要求があったときに、このユーザについてのジャンル選択確率、楽曲選択確率及び特徴発生確率を用いて、このユーザに対する楽曲選択確率  $p(m | u)$  が大きい複数の楽曲の嗜好ランキングを出力する。すなわち、楽曲推薦部 15 は、楽曲選択確率  $p(m | u)$  が大きい複数の楽曲  $m$  を推薦する。

10

【0043】

より一般的に説明すると、図 2 の確率モデルには隠れ変数（擬似ジャンル）が導入されており、この確率モデルは二つのノードの情報が発生する過程を確率的に表現できる。評価スコアや楽曲内容（音響的特徴）などの観測データは、隠れ変数  $Z = \{z | z_1, \dots, z_{|Z|}\}$  と関連付けられる。ここで、 $|Z|$  は隠れ変数の数である。隠れ変数はジャンルに対応していると考えると理解しやすいが、あくまで便宜的かつ概念的な考え方であり、一般的な意味でのジャンルではないことに注意する。図 2 の確率モデルでは、観測データには直接現れないユーザの音楽的嗜好を  $U$  と  $Z$  の確率的関係として表現する。すなわち、あるユーザ  $u$  の嗜好は、各ジャンル  $z$  の出現確率  $p(z | u)$  によって定まる。このモデルでは、ユーザ  $u$  は自分の嗜好  $p(z | u)$  に従ってジャンル  $z$  を選択し、そのジャンル  $z$  が確率的に楽曲  $m$  と音響的特徴  $t$  を生起させる過程が自然に表現できる。なおこの三方向アスペクトモデルでは、ユーザ  $U$ 、楽曲  $M$ 、音響的特徴  $T$  が、隠れ変数  $Z$  を介して条件付き独立であることを仮定している。また、1人のユーザが複数のジャンルへの嗜好を持つことが許されている。これは、多くのクラスタリング手法が、各ユーザをいずれかのジャンルクラスに割り当ててしまうのと異なる点である。

20

30

【0044】

次に、三方向アスペクトモデルの定式化について説明する。本実施の形態では、三方向アスペクトモデルの定式化を行っている。いま、3つ組  $(u, m, t)$  でユーザ  $u$ 、楽曲  $m$ 、多重音色（音響的特徴） $t$  の共起を表す。これは、「ユーザ  $u$  が楽曲  $m$  中の多重音色  $t$  を聴く」という観測可能な事象に対応する。さらに、 $n(u, m, t)$  を上記事象の生起回数とし、以下の通り 2 つの観測データの積に分解できると仮定する。

40

$$n(u, m, t) = r_{u, m} \times c_{m, t} \dots \dots (3)$$

ここで、 $r_{u, m}$  と  $c_{m, t}$  は以下の通り定義されている。

- ・  $r_{u, m}$  はユーザ  $u$  の楽曲  $m$  に対する評価スコアである。未評価の場合はデフォルトスコアとして 2.5（または ）が代入される。

- ・  $c_{m, t}$  は楽曲  $m$  中の多重音色（音響的特徴） $t$  の重みである。事象  $(u, m, t)$  は、ユーザ  $u$  が楽曲  $m$  を好む度合いが大きいほど、あるいは楽曲  $m$  中の多重音色（音響的特徴） $t$  の重みが大きいほど生起しやすいと考えられる。

【0045】

同様に、4つ組  $(u, m, t, z)$  でユーザ  $u$ 、楽曲  $m$ 、多重音色（音響的特徴） $t$ 、

50

ジャンル  $z$  の共起を表す。これは、「ユーザ  $u$  が多重音色  $z$  を選択し、 $z$  が楽曲  $m$  と多重音色（音響的特徴）  $t$  を生起している」事象に対応するが、観測は不可能である。上記事象の生起確率  $p(u, m, t, z)$  は以下の式で与えられる。

$$p(u, m, t, z) = p(u) p(z|u) p(m|z) p(t|z) \dots\dots (4)$$

ここで、 $p(u)$  はユーザ  $u$  の事前確率、 $p(z|u)$  はユーザ  $u$  が与えられた場合にジャンル  $z$  が生起する確率、 $p(m|z)$  および  $p(t|z)$  はジャンル  $z$  が与えられた場合に楽曲  $m$  および多重音色（音響的特徴）  $t$  が生起する確率である。上記式を  $z$  で周辺化することで、事象  $(u, m, t)$  の生起確率  $p(u, m, t)$  は以下の通り求まる。

【数 1】

$$p(u, m, t) = \sum_z p(u) p(z|u) p(m|z) p(t|z) \quad (5)$$

【0046】

本モデルにおける未知パラメータは、 $\{p(z|u) | z \in Z, u \in U\}$ 、 $\{p(m|z) | m \in M, z \in Z\}$  および  $\{p(t|z) | t \in T, z \in Z\}$  である。これらは、観測データである評価行列  $R$  と内容行列  $C$  を用いて基本学習部 17 で推定する。推薦を行う際には、各ユーザ  $u$  に対して、 $p(m|u) = \sum_t p(u, m, t)$  に従ってユーザ  $u$  の未評価楽曲に対してランク付けを行うことになる。

【0047】

すなわち、基本学習部 17 は、複数の評価行列（評価スコア）  $R$  と複数の音響的特徴即ち内容行列  $C$  とを入力として、複数のパラメータの尤度を最大化するように確率モデルの複数のパラメータ（確率値）を推定する。この未知のパラメータの推定方法について説明する。まず、事象  $(u, m, t)$  が独立に生起すると仮定すると、学習用データ（評価行列  $R$  と内容行列  $C$ ）に対するパラメータの尤度  $L$  は以下で与えられる。

【数 2】

$$L = \prod_{u,m,t} p(u, m, t)^{n(u,m,t)} \quad (6)$$

$$= \prod_{u,m,t} \left( \sum_z p(u) p(z|u) p(m|z) p(t|z) \right)^{n(u,m,t)} \quad (7)$$

【0048】

求めるべきパラメータは尤度  $L$  を最大化するものである。このように隠れ変数を含む尤度  $L$  を最大化する問題を解くため、本実施の形態では EM アルゴリズムを利用している。なお、EM アルゴリズムに代えて DAE M アルゴリズムを利用してもよい。DAE M アルゴリズムは、N. Ueda 及び R. Nakano が書いた “Deterministic Annealing EM Algorithm,” と題する論文 (Neural Net., Vol. 11, No. 2, pp. 271, 282, 1998) に詳しく記載されている。この DAE M アルゴリズムは、通常の EM アルゴリズムに比べて局所解に陥りにくいという利点を持つ。

【0049】

10

20

30

40

50



図3は、EMアルゴリズムを利用して構成する基本学習部17の構成の一例を示すブロックであり、図4は、基本学習部17をコンピュータで実現する場合に用いるコンピュータプログラムのアルゴリズムを示すフローチャートである。図4から分かるように、ステップST41で、複数の既存ユーザの評価スコアを準備し、ステップST42で、複数の評価スコアを用いて複数の評価ベクトルを算出する。ステップST42の詳細は、図5に示すとおりである。すなわち、ステップST42Aで、あるユーザが与えられたとき、該ユーザの未評価楽曲に対してはデフォルトスコアを代入する。そして、ステップST42Bで、全楽曲に対する評価スコアを集めて該ユーザに対応する評価ベクトルを生成する。また、ステップST43においては、複数の既存楽曲の音響信号から抽出した複数の音響的特徴を準備する。そして、ステップST44で、複数の音響的特徴を集めて複数の内容ベクトルを算出する。ステップST44の詳細は、図6に示すとおりである。すなわち、ステップST44Aでは、ある音響信号が与えられたとき、該音響信号からメルケプストラム係数群を算出する。そして、ステップST44Bで、メルケプストラム係数群に対して平均と分散を固定した混合ガウス分布をフィッティング(重みのみを推定)する。最後に、ステップST44Cで、推定した重みを集めて該音響信号に対する内容ベクトルを生成する。ここで、ガウス分布の混合数は内容ベクトルの次元数に等しい。そして、最後にステップST45において、EMアルゴリズムによる三方向アスペクトモデルの学習を行う。ステップST45の詳細は、図7に示すとおりである。すなわち、ステップST45Aで、アスペクトモデルの複数のパラメータを初期化する。次に、ステップST45Bで、評価ベクトルと内容ベクトルに対する複数のパラメータの尤度Lを算出する。そして、尤度Lを最大化する方向に複数のパラメータ(確率値)を更新する。そして、ステップST45Dにおいて、尤度の増加が収束したか(閾値以下になったか)が判定される。ステップST45Eで、収束が判定されるまで、ステップST45BからステップST45Dが繰り返される。収束が判定されると、ステップST45B~ステップST45Dは終了する。

#### 【0050】

図3に示した基本学習部17の構成は、図4及び図7のアルゴリズムによって実現される。評価ベクトル算出部17Aは、複数の評価スコアから複数の評価ベクトルを算出する。内容ベクトル算出部17Bは、複数の音響的特徴から複数の内容ベクトルを算出する。尤度算出部17Cは、複数の評価ベクトルと複数の内容ベクトルに対する複数のパラメータの尤度を算出する。そして更新部17Dは、尤度を最大化する方向に複数のパラメータ(複数のジャンル選択確率、複数の楽曲選択確率及び複数の特徴発生確率)を更新する。そして収束判定部17Eは、尤度の増加が収束したことを判定すると尤度算出部17Cと更新部17Dの動作を終了する。

#### 【0051】

本実施の形態の楽曲推薦システムで用いるアルゴリズムは、モデルベースのアルゴリズムである。モデルベースのアルゴリズムでは、前述のように、推薦を行う際に常に観測データ全体(評価行列Rと内容行列C)を参照する。またモデルベースのアルゴリズムでは、観測データを用いてユーザの音楽的嗜好を推定するための確率モデルを構築したのち、確率モデルに基づいて推薦を行う。モデルベースのアルゴリズムを用いる場合には、推薦自体は迅速に行えるものの、事前のモデル学習(基本学習部17における演算)に時間がかかる。そこでモデルベースのアルゴリズムを用いる場合には、モデル学習コストを抑えることが課題である。

#### 【0052】

前述のDAEMアルゴリズムによるアスペクトモデルの学習コストは、 $|T|$ と $|Z|$ は一定である(具体的に本実施の形態の場合であれば、 $|T|$ と $|Z|$ はそれぞれ64と10とする)ので、 $O(|U||M|)$ である。これは二つの深刻な問題を引き起こす。一つの問題は、効率性に関する問題である。観測データが変化する度に、コストの大きなモデル学習をやり直す必要がある。二つめの問題は、スケーラビリティに関する問題である。

10

20

30

40

50

## 【 0 0 5 3 】

時間的且つ空間的なコスト（学習時間と必要メモリ）は、 $O(|U| |M|)$  のオーダーで急激に増加する。効率性とスケーラビリティは実用上極めて重要な要素である。しかしながら従来は、この点に関してほとんど考慮されてこなかった。

## 【 0 0 5 4 】

そこで、本実施の形態では、効率性を改善するため、三方向アスペクトルモデルからなる確率モデル 13 に対して、インクリメンタル学習法を適用するための第 1 及び第 2 のインクリメンタル学習部 19 及び 21 を設ける。なお、協調フィルタリングのための基本的なアスペクトモデルに対するインクリメンタル学習法については、L. Zhang, C. Li, Y. Xu, 及び B. Shi が発表した “An Efficient Solution to Factor Drifting Problem in the pLSA Model,” と題する論文 (CIT, 2005, pp. 175 ~ 181) に開示されている。本実施の形態では、この公知のインクリメンタル学習法を、内容情報を考慮できるように拡張した。

10

## 【 0 0 5 5 】

本実施の形態で第 1 のインクリメンタル学習部 19 は、評価スコア記憶部 3 を監視して、評価スコアの変更及び新たなユーザの追加があるたびに、評価スコアを変更したユーザ及び新たなユーザ  $u$  についてのジャンル選択確率  $p(z|u)$  を、基本学習部 17 によって定められた尤度  $L$  が最大化された状態を維持するように確率モデル 13 に更新または追加する。また第 2 のインクリメンタル学習部 21 は、音響的特徴記憶部 5 を監視して、楽曲の追加による音響的特徴の追加があるたびに、追加された楽曲  $m$  に関する楽曲選択確率  $p(m|z)$  を、基本学習部 17 によって定められた尤度  $L$  が最大化された状態を維持するように確率モデル 13 に追加する。

20

## 【 0 0 5 6 】

次に本実施の形態において、第 1 及び第 2 のインクリメンタル学習部 19 及び 21 によって、三方向アスペクトモデルからなる確率モデル 13 のパラメータ（更新または追加されたジャンル選択確率及び追加された楽曲選択確率）を逐次的に更新する手法について述べる。以下の説明では、基本学習部 17 における学習で DAE M アルゴリズムを用いて得られた確率モデルを基本モデル、インクリメンタル学習法を用いて更新された確率モデルを、更新モデルと呼ぶ。更新モデルを生成する際には、以下の三つのケースを別々に扱う。

30

## 【 0 0 5 7 】

(1) 新たに評価スコアを与えた既存ユーザ  $u$  にモデルを適応する場合（既存ユーザのプロファイル更新）。

(2) いくつかの評価スコアを持つ新規ユーザ  $u$  をモデルに追加登録する場合（新規ユーザのプロファイル更新）。

(3) 評価スコアを持たない新規楽曲  $m$  をモデルに追加登録する場合（新規楽曲の追加登録）。

## 【 0 0 5 8 】

最初のケース (1) では確率モデルのサイズは増加しないが、残りの二つのケース (2) 及び (3) では新規ユーザ  $u$  や新規楽曲  $m$  の追加により、確率モデルのサイズが増加する。

40

## 【 0 0 5 9 】

まず、第 1 のインクリメンタル学習部 19 が実行する、上記 (1) の既存ユーザのプロファイル更新について説明する。あるユーザ  $u$  の音楽的嗜好を表す条件付き確率分布  $\{p(z|u) | z \in Z\}$ 、すなわちジャンル選択確率をユーザプロファイルと呼ぶ。本実施の形態では、確率モデル 13 は、全てのユーザのユーザプロファイルが独立であると仮定している。したがって、あるユーザが評価スコアを変化させた場合、基本学習部 17 によって定められた尤度  $L$  が最大化された状態が維持されるように該当ユーザのユーザプロファイル（ジャンル選択確率）のみを更新すればよい。

## 【 0 0 6 0 】

50

いま、尤度  $L$  が最大化されているところに、既存ユーザ  $u$  が評価スコアを変化させたために、ユーザプロファイル  $\{p(z|u) | z \in Z\}$  を更新する問題を考える。ユーザ  $u$  を含まないパラメータは一定であると仮定すると、評価スコア変更後の尤度  $L$  の最大化は、尤度  $L$  中でユーザ  $u$  を含む項の和の最大化と等価になる。 $L_u$  をユーザ  $u$  に関する尤度とすると、 $L_u$  は以下で求まる。

【数 3】

$$L_{u'} = \sum_{m,t} n(u', m, t) \log p(m, t|u') \quad (8)$$

10

$$= \sum_{\langle m,t|u' \rangle} \log p(m, t|u') \quad (9)$$

【0061】

上記式では、ある変数  $X$  に対して  $\sum_{m,t} n(u', m, t) X$  のように作用するオペレータ  $\langle m, t | u' \rangle$  を便宜的に導入した。

【0062】

式(9)は、Jensenの不等式を用いて以下のように変形できる。

20

【数 4】

$$L_{u'} = \sum_{\langle m,t|u' \rangle} \log \sum_z p(m|z)p(t|z)p(z|u') \quad (10)$$

30

$$= \sum_{\langle m,t|u' \rangle} \log \sum_z \frac{p(m|z)p(t|z)}{\delta_{m,t}} p(z|u') \delta_{m,t} \quad (11)$$

$$\geq \sum_{\langle m,t|u' \rangle} \sum_z \frac{p(m|z)p(t|z)}{\delta_{m,t}} \log p(z|u')$$

40

$$+ \sum_{\langle m,t|u' \rangle} \log \delta_{m,t} \quad (12)$$

【0063】

ここで、以下の補助関数  $\delta_{m,t}$  を導入した。

【数5】

$$\delta_{m,t} = \sum_z p(m|z)p(t|z) \quad (13)$$

【0064】

上記式で楽曲選択確率  $p(m|z)$  および特徴発生確率  $p(t|z)$  が一定であることを考慮すると、尤度  $L_u$  の最大化は、式(12)の第一項の最大化と等価である。すなわち、以下の制約付き最大化問題を得る。 10

【数6】

$$\text{Maximize } \tilde{L}_{u'} = \sum_{\langle m,t|u' \rangle} \sum_z \frac{p(m|z)p(t|z)}{\delta_{m,t}} \log p(z|u') \quad (14)$$

$$s.t. \sum_z p(z|u') = 1 \quad (15)$$

【0065】

この問題はラグランジュの未定乗数法を用いて解くことができる。いま、ラグランジュの未定乗数を  $\lambda$  として、新たな関数  $L_{u'}^*$  を以下で定義する。

【数7】

$$L_{u'}^* = L_{u'} - \lambda \left( \sum_z p(z|u') - 1 \right) \quad (16)$$

【0066】

関数  $L_{u'}^*$  を  $p(z|u')$  に関して偏微分すると以下が得られる。

【数8】

$$\frac{\partial L_{u'}^*}{\partial p(z|u')} = \frac{\sum_{\langle m,t|u' \rangle} \frac{p(m|z)p(t|z)}{\delta_{m,t}}}{p(z|u')} - \lambda \quad (17)$$

【0067】

目的関数  $L_{u'}^*$  が最大となるには、式(17)がゼロに等しい必要がある。したがって、以下の等式を得る。

【数 9】

$$\lambda p(z|u') = \sum_{\langle m,t|u' \rangle} \frac{p(m|z)p(t|z)}{\delta_{m,t}} \quad (18)$$

【0068】

次に、式(18)を式(15)に代入することで を求める。

10

【数 10】

$$\sum_z p(z|u') = 1 \Leftrightarrow \lambda = \sum_z \sum_{\langle m,t|u' \rangle} \frac{p(m|z)p(t|z)}{\delta_{m,t}} \quad (19)$$

$$\Leftrightarrow \lambda = \sum_{\langle m,t|u' \rangle} \frac{\sum_z p(m|z)p(t|z)}{\delta_{m,t}} \quad (20)$$

20

$$\Leftrightarrow \lambda = \sum_{m,t} n(u', m, t) \quad (21)$$

【0069】

最終的に、以下のユーザプロフィール更新式を得る。

30

【数 11】

$$p(z|u') = \frac{\sum_{m,t} n(u', m, t) \frac{p(m|z)p(t|z)}{\sum_{z'} p(m|z')p(t|z')}}{\sum_{m,t} n(u', m, t)} \quad (22)$$

40

【0070】

次に、第1のインクリメンタル学習部19が実行する、上記(2)の新規ユーザプロフィール(ジャンル選択確率)の更新について説明する。新規ユーザ  $u \in U$  のユーザプロフィール  $\{p(z|u) | z \in Z\}$  を新たに生成する問題を考える。新規ユーザ  $u$  は既存楽曲に対して評価スコア  $\{r_{u,m} | m \in M\}$  を付与している。そのため、この場合でも上記式(22)を適用することが可能である。このとき、楽曲選択確率  $p(m|z)$  および特徴発生確率  $p(t|z)$  は既存ユーザの評価スコアを用いて基本学習部17で学習されたものを用いる。

【0071】

50

ここで、 $|M|$  を新規ユーザ  $u$  が付与した評価スコアの数 ( $u$  が既存ユーザの場合は追加・変更した評価スコアの数) だとすれば、更新にかかる計算コストは  $O(|M|)$  である。よって上記式 (22) 中で、それらの楽曲に関する項のみ再計算すればよい。

【0072】

次に、第2のインクリメンタル学習部21が実行する上記(3)の新規楽曲の追加登録について説明する。新規楽曲  $m$  が与えられたとき、条件付き確率  $\{p(m|z) | z \in Z\}$ 、すなわち、楽曲選択確率を推定する問題を考える。このケースにも上記と同様の考え方が適用でき、条件付き確率分布  $\{p(z|m) | z \in Z\}$  を求めたあと  $p(m|z) = p(z|m) / p(z)$  とすればよい。このとき、新規楽曲  $m$  は評価スコアを持っておらず、内容ベクトル  $\{c_{m,t} | t \in T\}$ 、すなわち、音響的特徴しか利用できないことに注意する。したがって、新規楽曲追加(新曲  $m$  の楽曲選択確率  $p(m|z)$  の追加)のための更新式は以下で与えられる。

$$p(z|m') = \frac{\sum_t c_{m',t} \frac{p(t|z)}{\sum_{z'} p(t|z')}}{\sum_t c_{m',t}} \quad (23)$$

この更新にかかる計算コストは定数オーダーである。

【0073】

以上の説明から分かるように、上記(1)乃至(3)の確率の計算コストは、従来のように基本学習部17における再学習に要する計算コストと比べて、僅かである。したがって本実施の形態によれば、従来の楽曲推薦システムまたは方法と比べて効率性を大幅に高めることができる。

【0074】

図8は、図1の実施の形態をコンピュータを用いて実現する場合に用いるプログラムのアルゴリズムを示すフローチャートである。ステップST1で基本学習部17を確立し、ステップST2で確立モデル13の全パラメータを更新する。そしてステップST3でユーザの評価スコアの追加(既存のユーザの評価スコアの更新を含む)を判定する。このステップは、評価スコア記憶部3への評価データの追加または変更を監視することにより実行される。そして新規ユーザ  $u$  の評価スコアの追加(既存のユーザの評価スコアの更新)があるときに限り、ステップST4でジャンル選択確率  $p(z|u)$  を推定して、三方向アスペクトモデルからなる確立モデル13への追加登録を行う。既存のユーザの評価スコアの変更の場合には、その既存のユーザの更新されたジャンル選択確率だけを推定して更新する。図9は、ステップST4の詳細を示している。ステップST4Aでは、更新または新規のユーザの評価スコアを取得する。そしてステップST4Bで、評価スコアから評価ベクトルを算出する。さらにステップST4Cで、評価ベクトルを用いて新規ユーザのジャンル選択確率を推定し三方向アスペクトモデルからなる確率モデル13へ追加登録する。

【0075】

ステップST5では、新規楽曲の追加の有無を判定する。この判定は、新規楽曲の楽曲データが楽曲データ記憶部7に記憶され、音響的特徴抽出部11がその楽曲データ(音響信号)から新たな音響的特徴を抽出して、その音響的特徴が音響的特徴記憶部7へ新規に記憶されるか否かを監視することにより判定される。新規楽曲の追加を判定した場合には、ステップST6へと進んで、ステップST6では、その新規の楽曲  $m$  についての楽曲

選択確率  $p(m | z)$  の推定を実行して、三方向アスペクトモデルからなる確率モデル 13 へ追加登録する。図 10 は、ステップ S T 6 の詳細を示している。ステップ S T 6 A では、新規楽曲の音響的特徴を取得し、ステップ S T 6 B で、音響的特徴から内容ベクトルを算出する。そしてステップ S T 6 C で、内容ベクトルを用いて楽曲選択確率を推定し三方向アスペクトモデルへ追加登録する。

【 0 0 7 6 】

ステップ S T 7 であるユーザから楽曲推薦要求があるか否かの判定が行われる。そして楽曲推薦要求があった場合には、ステップ S T 8 で楽曲推薦部 15 がそのユーザに適応した全楽曲のランキングまたは推薦確率  $p(m | u)$  が大きいものから順に楽曲のランキング付けを行い、ランキングを出力する。楽曲推薦要求が無い場合にはステップ S T 9 へと進む。ステップ S T 9 で終了指令の入力の有無を判定して、終了指令が入力されると終了する。終了指令の入力がなければ、ステップ S T 3 へと戻る。

10

【 0 0 7 7 】

上記実施の形態では、基本学習部 17 を従来と同様の学習方法を用いて確立している。しかしながら既存の学習方法で確立した基本学習部で、数百万曲、数十万人規模のデータを扱おうとすると、学習に相当の時間を要する。そのため、現実的には、この基本学習部 17 で、数百万曲、数十万人規模のデータを扱うこと（スケーラビリティを上げること）は、無理がある。そこで本発明の別の実施の形態では、基本学習部を確立する基本学習部確立システム 23 を用いてスケーラビリティを改善する。図 11 は、基本学習部確立システム 23 の一例の構成を示すブロック図である。また図 12 は、基本学習部確立システム 23 のオペレーションを模擬的に示している。

20

【 0 0 7 8 】

この基本学習部確立システム 23 は、代表ユーザ決定部 23 A と、代表楽曲決定部 23 B と、コアモデル学習部 23 C と、第 1 の基本学習部確立用インクリメンタル学習部 23 D と、第 2 の基本学習部確立用インクリメンタル学習部 23 E とから構成されている。代表ユーザ決定部 23 A は、評価スコア記憶部 3 から取得した複数のユーザ（ユーザ群 U）の複数の評価スコアに基づいて算出した複数の評価ベクトルに基づいて、複数のユーザのクラスタリングを行い、複数の代表ユーザを決定する。そして決定した複数の代表ユーザについての複数の評価ベクトルを算出する。また、代表楽曲決定部 23 B は、音響的特徴記憶部 5 から取得した複数の楽曲（楽曲群 M）の音響的特徴を示す複数の内容ベクトルに基づいて、複数の楽曲についてクラスタリングを行い複数の代表楽曲を決定する。そして複数の代表楽曲についての複数の内容ベクトルを算出する。

30

【 0 0 7 9 】

コアモデル学習部 23 C は、三方向アスペクトモデルが定式化された推定用の確率モデルをコアモデル 23 F として有している。そしてコアモデル学習部 23 C は、複数の代表ユーザについての複数の評価ベクトルと複数の代表楽曲についての複数の内容ベクトルとに基づいて、コアモデル 23 F のジャンル選択確率、楽曲選択確率及び特徴発生確率の尤度を最大化するようにこれらの確率を推定する。

【 0 0 8 0 】

第 1 の基本学習部確立用インクリメンタル学習部 23 E は、評価スコア記憶部 3 に記憶されている複数のユーザのそれぞれについての複数の評価スコアを入力として用いる。第 1 の基本学習部確立用インクリメンタル学習部 23 E は、複数のユーザをコアモデル 23 F に追加するため、複数のユーザについてのそれぞれのジャンル選択確率を、先に代表ユーザ及び代表楽曲に基づいてコアモデル学習部 23 C によって定められた尤度が最大化された状態を維持するようにコアモデル 23 F に順次追加する。また、第 2 の基本学習部確立用インクリメンタル学習部 23 E は、音響的特徴記憶部 5 に記憶されている複数の楽曲のそれぞれの複数の音響的特徴を入力とする。第 2 の基本学習部確立用インクリメンタル学習部 23 E は、複数の楽曲をコアモデル 23 F に追加するため、複数の楽曲についてのそれぞれの楽曲選択確率を、先に代表ユーザ及び代表楽曲に基づいてコアモデル学習部 23 C によって定められた尤度が最大化された状態を維持するように追加する。そして、最

40

50

最終的に、第1及び第2の基本学習部確立用インクリメンタル学習部23D及び23Eによって追加された複数のユーザについての複数のジャンル選択確率及び複数の楽曲についての複数の楽曲選択確率を、コアモデル学習部23Cのコアモデル23Fに追加したモデルを基本学習部17として確立する。このようにすると、基本学習部17を確立する場合においても、複数のユーザについてのジャンル選択確率の推定(学習)及び複数の楽曲についての楽曲選択確率の推定(学習)演算のみを行うだけでよいので、数百万曲、数十万人規模のデータになっても、演算処理は簡単に行うことができる。このシステムでは、スケーラビリティを改善するために、大量のユーザと楽曲から一定数の代表的なユーザと代表楽曲を仮想的に生成し、それらに対してコンパクトなコアモデル23Fを構築している。そしてコアモデル23Fを、ユーザ群Uの各ユーザの評価スコアと楽曲群Mの各楽曲の音響的特徴とを逐次的に登録しながら部分的に更新している。

10

## 【0081】

すなわち、実際のユーザ群Uと楽曲群Mを新規ユーザおよび新規楽曲とみなし、インクリメンタル学習法を用いてコアモデル23Fに追加登録していく。追加登録の順序には二通りあるが、楽曲群Mの楽曲を先に追加登録する方式(図12中で下のパスに対応)の方が推薦精度が高くなる。なおこの点は、後に説明する実験で確かめられている。

## 【0082】

代表ユーザと代表楽曲を生成するには、K-means法のようなクラスタリング手法を利用することができる。クラスタリングでは、まずユーザ群Uをユーザの評価スコアの評価ベクトルの類似性によってグループ化する。距離尺度として、協調フィルタリングでよく利用されるピアソン相関係数を用いた。一方、楽曲群Mは特徴量ベクトル間のユークリッド距離に従ってグループ化する。代表ユーザと代表楽曲は、各グループの平均的なものとなる。ここで問題は、コアモデル学習に用いる評価行列Rと内容行列Cの生成である。

20

## 【0083】

図13に評価行列Rの計算例を示す。ある代表ユーザがある代表楽曲に付与したスコアは、対応するグループ内のユーザが対応するグループ内の楽曲に付与した実際のスコアの平均値である。新しい内容行列Cは、グループ内の楽曲の特徴量ベクトルを平均することで得られる。通常、クラスタリングのような近似的な操作を行うと推薦精度は低下する。すなわち精度と効率のトレードオフ(精度と効率が両立しない関係)が発生する。しかし、本例の場合には、精度と効率の間にはトレードオフは発生しない。

30

## 【0084】

上記のように基本学習部確立システム23を用いて基本学習部17を確立すれば、数百万曲、数十万人規模のデータになっても、スケーラビリティを任意に拡大することが可能になる。この基本学習部確立システム23を用いて基本学習部17を確立した後は、楽曲推薦システム1において、この確立した基本学習部17を用いる。そして前述の第1及び第2のインクリメンタル学習部19及び21を用いて、確立モデル13にさらにユーザの追加及び楽曲の追加を行う。

## 【0085】

図14は、基本学習部確立システム23をコンピュータプログラムによりコンピュータで実現する場合のプログラムのアルゴリズムの一例を示している。このアルゴリズムでは、ステップST101で既存ユーザの評価スコアを準備する。そして、ステップST102で各評価スコアに基づいて評価ベクトルを算出する。そして、ステップST103でクラスタリングを行って、複数の代表ユーザを決定する。ステップST104では、複数の代表ユーザの評価ベクトルを算出する。また、ステップST105で既存の楽曲の音楽的特徴を準備する。そして、ステップST106で各音楽的特徴に基づいて各楽曲の内容ベクトルを算出する。そして、ステップST107でクラスタリングを行って、複数の代表楽曲を決定する。ステップST108では、複数の代表楽曲の内容ベクトルを算出する。ステップST109においては、ステップST104で算出した複数の代表ユーザの複数の評価ベクトルと、ステップST108で算出した複数の代表楽曲の複数の内容ベクトル

40

50



とに基づいて、EMアルゴリズムによる別の確率モデルとしてのアスペクトモデルの学習を行い、アスペクトモデルの複数のパラメータを決定して、コアモデルを確立する。次にステップST110とステップST111を用いて、既存楽曲の情報をコアモデルにすべて登録するために、既存楽曲の楽曲選択確率を推定して、これをコアモデルに全部登録する。その後ステップST112及びST113を用いて、既存ユーザの情報をコアモデルに登録するために、既存ユーザのジャンル選択確率を推定して、これをコアモデルに全部登録する。すべての登録が完了したら終了する。このようにして情報が追加されたコアモデルが、楽曲推薦システム1で使用する基本学習部となる。

#### 【0086】

なお、ユーザの追加数及び楽曲の追加数が多くなり過ぎると、推薦精度が低下することがある。その場合には、楽曲推薦部15による推薦精度の低下が予め定めた許容値より大きくなったか否かを判定する推薦精度判定部25(図1)をさらに備えておけばよい。推薦精度判定部25が、推薦精度の低下が予め定めた許容値より大きくなったことを判定したときには、基本学習部確立システム23を再度動作させて、基本学習部17を更新する。このようにすると、基本学習部17が、それまでに集まったすべてのユーザの評価データ及びすべての楽曲のデータを元に、別の確率モデルとしてのコアモデル23Fのパラメータを再推定(更新)することになり、低下した推薦精度を回復することができる。

#### 【0087】

図15は、基本学習部確立システム23と、推薦精度判定部25と、楽曲推薦システム1とをプログラムによりコンピュータで実現する場合に用いるプログラムのアルゴリズムを示している。ステップST201で基本学習部23を確立した後は、ステップST202及びST203とステップST204及びST205へと進んで、楽曲推薦システム1が実現される。ステップST204及びST205で新規ユーザ(新規ユーザの評価スコア)の追加登録が実施され、ステップST202及びST203で新規楽曲(新規楽曲の音響的特徴)の追加登録が実施される。ステップST206で、推薦精度を判定し、推薦精度が予め定めた許容値を超えない(許容値より大きくなる)間は、楽曲推薦システム1の動作が継続する。推薦精度が予め定めた許容値を超えた(許容値より大きくなった)ことをステップST206で判定すると、ステップST201へと戻って、再度基本学習部の再確立が実施される。

#### 【0088】

次に、本実施の形態の評価実験について説明する。上記実施の形態では、インクリメンタル学習法を利用することで、楽曲推薦システムの効率性とスケーラビリティが大幅に向上する。しかし推薦精度への影響は実験的に検証する必要がある。そこで以下の実験条件で実験を行った。

#### 【0089】

##### [実験条件]

信頼性の高い実験を行うには、各ユーザがある程度の数の楽曲に評価を与えている楽曲評価データを用いることが望ましい。この問題に対処するため、評価スコアをWEBサイトから収集することにした。楽曲評価データは、K.Yoshii, M.Goto, K.Komatani, T.Ogata, 及び H.G.Okunoが発表した“Hybrid Collaborative and Content-based Music Recommendation Using Probabilistic Model with Latent User Preferences,” ISMIR,2006,pp.296-301.の研究報告で利用したものと同一である。使用した楽曲は、2000年4月から2005年12月までに、日本のシングルCD売り上げランキングで上位20位にランクインしたものである。それらに与えられた評価スコアはAmazon.co.jpから収集した。評価スコアにはユーザIDが付与されているため、あるユーザが複数の楽曲に評価を行っていても、それらの評価は同一ユーザのものであると判定できる。その後、評価数が4に満たないユーザと楽曲を削減することを繰り返し、評価数が4以上のユーザと楽曲のみを抽出した。最終的に、ユーザ数 $|U| = 316$ 、楽曲数 $|M| = 358$ となった。評価行列Rにおける全評価スコア数中の4から0の各スコアの割合は、それぞれ57.9%, 19.1%, 8.6%, 4.9%, 9.5%であり、半分以上がスコア4の「大好

10

20

30

40

50

き」という評価で占められていた。

【0090】

[評価方法]

実験は10クロスバリデーションで行う。まず、図16に示すように、評価行列R中の評価要素の10%をランダムにマスクし、学習用行列 $R_t$ と検証用行列 $R_e$ を生成する。推薦精度は、各ユーザごとに $x$  ( $x = 1, 3, 10$ )曲を推薦する場合、全ユーザで合計 $x \times NU$ 曲に着目して評価する。図16において、斜線によりハッチングしたボックスはマスクされたスコア(評価要素)である。このとき、推薦精度が高いことは、推薦楽曲には「実際には」高い評価スコア(3や4)が与えられていた楽曲の割合が高く、低い評価スコア(0や1)の楽曲がほとんどない状態をさす。しかし、検証用行列 $R_e$ 内にはわずかな評価要素しかない(評価行列R内の評価要素数の10%であるため、検証用行列 $R_e$ の密度は0.219%)、推薦される $x \times NU$ 曲全てについて、実際に与えられていた評価スコアを参照することはできない。そこで、 $x \times NU$ 曲の中から実際に評価スコアが与えられていた楽曲のみを抽出し、そのうち高い評価スコアが与えられている楽曲の割合を算出することにした。ここで、抽出された楽曲数を $N$  ( $N < x \times NU$ )と定義しておく。

10

【0091】

以下に、具体的な算出方法について述べる。いま、 $N_r$ を検証用行列 $R_e$ 中で実際はスコア $r$ が与えられていたが、学習用行列 $R_t$ 中でマスクされた要素数とする。ここで、 $N = \sum_r N_r$ とし、 $N$ に対する $N_r$ の割合を「 $A_r = N_r / N$ 」で定義する。 $x = 3$ とした場合の算出例を、図17に示す。図17において着色されたボックスはマスクされたスコアであり、とみなしてモデル学習を行っている。また、図17の下側に示したトップ3提示の各ボックスの中の数字は楽曲番号を示している。括弧内の数字は実際のスコアである。ここで注意すべきは、ランダムに楽曲を推薦した場合でも、 $A_r = N_r / N$ により求めた $A_4, \dots, A_0$ は20%にはならないことである。 $A_4, \dots, A_0$ のチャンスレートは、評価行列R中の評価要素数に対する評価スコアごとの割合に等しく、それぞれ、57.9%, 19.1%, 8.6%, 4.9%, 9.5%である。以降に、スコア4の楽曲が推薦される割合 $A_4$ に着目して議論を進める。 $A_4$ の値が大きいくほど、精度の高い推薦ができたことを示す。

20

【0092】

[インクリメンタル学習法の評価]

インクリメンタル学習法を評価するため、先に述べた三つの(1)乃至(3)のケースに分けて実験を行った。

30

【0093】

[既存ユーザに対する推薦]

実験では、基本の確率モデルを構築するのに利用する評価スコアの割合が低下するに伴い、推薦精度がどのように低下するかを調査した。また、基本の確率モデルと更新された確率モデルとの推薦精度の差を調査した。まず、実験手順を説明する。学習用行列 $R_t$ を用いて、1個の基本モデルと10個の更新モデルを構築した。基本モデルは学習用行列 $R_t$ をそのまま学習用データとし、DAEMアルゴリズムによる通常の学習法を適用することで得られた。更新された確率モデルは以下の手順で得られた。

40

【0094】

(1) 学習用行列 $R_t$ 中の評価スコアのうち $K\%$  ( $K = 0, 10, 20, \dots, 90$ )をランダムにマスクすることで、一時的な学習用行列 $R_t$ を生成する。なお、評価スコアについては、特に注釈がない限り、端に「評価スコア」と記載した場合には、以外の実際にユーザが付与した(0から4)のことを指すものとする。

(2)  $R_t$ を学習用データとしDAEMアルゴリズムによる通常の学習法を適用することで、一時的な基本モデルを得る。

(3) マスクされた $K\%$ の評価スコアをインクリメンタルに追加し、すなわち、学習用行列 $R_t$ を用いて、更新モデルを得る。

50

## 【0095】

このようにして、計11個の異なるモデルが得られるが、モデル構築に利用した評価スコアの数は最終的に等しくなる。ただし、基本モデル学習分とインクリメンタル学習分の割合が異なる。各モデルの推薦精度を評価するには、検証用行列  $R_e$  を利用した。そして上述した実験手順を10回繰り返した。これは先に述べた10クロスバリデーションにおいて、学習用行列  $R_t$  は10通りできるからである。

## 【0096】

図18に実験結果を示す。図18において、縦軸は推薦精度 (Recommendation accuracy) であり、横軸はインクリメンタル学習の評価スコアの比率 (Ratio of rating cores for incremental training) である。そして Top-1 rankings (baseline) は基本学習部を学習用行列  $R_t$  に適用して得られる確率モデルを使用して各ユーザに対して1曲を推薦する場合の推薦精度93.5%を表し、Top-3 rankings (baseline) は該確率モデルを使用して各ユーザに対して3曲を推薦する場合の推薦精度86.4%を表し、Top-10 rankings (baseline) は該確率モデルを使用して各ユーザに対して10曲を推薦する場合の推薦精度80.7%を表している。

## 【0097】

また、Top-1 rankings (incremental) は更新されたある確率モデルを使用して各ユーザに対して1曲を推薦する場合の推薦精度であり、Top-3 rankings (incremental) は更新されたある確率モデルを使用して各ユーザに対して3曲を推薦する場合の推薦精度であり、Top-10 rankings (incremental) は更新されたある確率モデルを使用して各ユーザに対して10曲を推薦する場合の推薦精度である。これらの結果をみると、インクリメンタル学習法を用いて更新された確率モデルを用いた場合で、さほど推薦精度が低下しないことが分かる。

## 【0098】

また、インクリメンタル学習法により、評価スコアが追加されてもユーザの好みに合うように適切に推薦結果を適応させることができた。基本モデルに逐次的に追加される評価スコアを、基本モデル学習するために利用する評価スコアと同数まで増やしても (Kを50まで増加)、推薦精度はほとんど低下しないことが分かった。各ユーザにランク一位の楽曲のみを推薦する場合 ( $x=1$ ) を見ると、基本の確率モデルと更新された確率モデルとの推薦精度の差は5%であり、十分に高い推薦精度を保つことができた。

## 【0099】

## [新規ユーザに対する推薦]

本実験では、既存ユーザに対する推薦精度と新規ユーザに対する推薦精度を比較した。この差が小さいほど、優れた推薦ができたことを示す。

## 【0100】

まず、以下に実験手順を説明する。まず、以下に実験手順を説明する。

(1) ユーザ群  $U$  から10%の数のユーザをランダムに抽出して  $U_{new}$  とし、新規ユーザとみなす。一方、残り残りのユーザを  $U_{reg}$  とし、既存ユーザとみなす。

(2) 学習用行列  $R_t$  から  $U_{new}$  に対応する行を削除することにより、縮退した評価行列  $R_t$  を生成する。すなわち、 $R_t$  のサイズは  $R_t$  の90%である。

(3)  $R_t$  を学習データとして一時的な基本モデルを構築する。この基本モデルには  $U_{new}$  のユーザプロファイルは含まれていない。

(4) まず、既存ユーザ  $U_{reg}$  に対する推薦精度を以下の手順で求める。

(a)  $R_t$  を式(22)に入力して ( $R_t$  を再度利用することになる)  $U_{reg}$  のユーザプロファイルを更新し、更新モデルを得る。

(b) 更新モデルによる推薦精度を検証用行列  $R_e$  中の  $U_{reg}$  に対応する行を用いて算出する。

## 【0101】

次に、新規ユーザ  $U_{new}$  に対する推薦精度を以下の手順で求める。

(a) 手順(2)で削除された評価データを式(22)に入力して  $U_{new}$  のユーザプロファイルを生成し、更新モデルを得る。

(b) 更新モデルによる推薦精度を検証用行列  $R_e$  中の  $U_{new}$  に対応する行を用いて算出する。

## 【0102】

10クロスバリデーションでは、学習用行列  $R_t$  は10通り生成されるので、上記した(1)から(4)の手順を、 $R_t$  を切り替えながら10回行った。推薦精度の平均と分散を求めるために、このような10クロスバリデーションを10回行った。

10

## 【0103】

図19に実験結果を示す。図19において、Registered usersは既存のユーザの場合であり、Non-registered usersは新規のユーザの場合である。インクリメンタル学習法により、既存ユーザと同様に新規ユーザに対しても精度よく推薦ができた。有意水準5%でF検定を行った結果、両者の分散には違いがあることが分かった。しかし、Welchのt検定を行ったところ、両者の推薦精度の平均には差がないことが分かった。

## 【0104】

[ 新規楽曲の推薦 ]

本実験では、既存楽曲の推薦精度と新規楽曲の推薦精度を比較した。この差が小さいほど、優れた推薦ができたことを示す。

20

## 【0105】

(1) 楽曲群  $M$  から10%の数の楽曲をランダムに抽出して  $M_{new}$  とし、新規楽曲とみなす。一方、残りの楽曲を  $M_{reg}$  とし、既存楽曲とみなす。

(2) 学習用行列  $R_t$  から  $M_{new}$  に対応する列を削除することにより、縮退した学習用行列  $R_t$  を生成する。すなわち、縮退した学習用行列  $R_t$  のサイズは学習用行列  $R_t$  の90%である。

(3) 縮退した学習用行列  $R_t$  を学習データとして一時的な基本モデルを構築する。この基本モデルには  $M_{new}$  と  $Z$  との確率的な関係は含まれていない。

(4) まず、既存楽曲  $M_{reg}$  の推薦精度を以下の手順での手順で求める。

30

## 【0106】

(a) 縮退した学習用行列  $R_t$  を式(23)に入力して ( $R_t$  を再度利用することになる)  $M_{reg}$  の確率的な関係を再計算し、更新モデルを得る。

(b) 更新モデルによる推薦精度を検証用行列  $R_e$  中の  $M_{reg}$  に対応する列を用いて算出する。

## 【0107】

次に、新規楽曲  $M_{new}$  に対する推薦精度を以下の手順で求める。

(a) 手順(2)で削除された評価データを式(23)に入力して  $M_{new}$  と  $Z$  の確率的な関係を推定し、更新モデルを得る。

(b) 更新モデルによる推薦精度を検証用行列  $R_e$  中の  $M_{new}$  に対応する列を用いて算出する。

40

## 【0108】

10クロスバリデーションでは、学習用行列  $R_t$  は10通り生成されるので、上記した(1)から(4)の手順を、学習用行列  $R_t$  を切り替えながら10回行った。推薦精度の平均と分散を求めるために、このような10クロスバリデーションを10回行った。

## 【0109】

図20に実験結果を示す。図20において、Registered piecesは既存の楽曲の場合であり、Non-registered piecesは新規楽曲の場合である。インクリメンタル学習法により、既存楽曲と同様に新規楽曲も精度よく推薦ができた。有意水準5%でF検定とt検定を行った結果、この実験においても両者の推薦精度

50

の平均に差は見られなかった。

#### 【0110】

##### [ スケーラビリティ改善法の評価 ]

この実験では、先に述べたインクリメンタル学習法を用いない従前の基本学習部を用いる本発明の実施の形態であるベースライン ( b a s e l i n e ) システムと二つのスケーラブルな基本学習部確立システムにより確立した基本学習部を用いた楽曲推薦システムの推薦精度を比較した。二つのスケーラブルな基本学習部確立システムは仮想的なユーザ群と楽曲群に対して同じコアモデルを構築するが、実際のユーザ群と楽曲群を追加登録するときの順序が異なる。ここで、最初に楽曲群Mを追加し、次にユーザ群Uを追加するのを p i e c e s - u s e r s システム ( 図 1 2 中 の 下 側 領 域 に 示 さ れ た パ ス )、逆の順序で追加するのを u s e r s - p i e c e s システム ( 図 1 2 中 の 上 側 領 域 に 示 さ れ た パ ス ) と呼ぶことにする。

10

#### 【0111】

図 2 1 に実験結果を示す。 p i e c e s - u s e r s システムが他の二つのシステムより高い推薦精度を示した。各ユーザにランク一位の楽曲のみを推薦する場合 ( x = 1 ) では、 p i e c e s - u s e r s システムはベースラインシステムと同等の推薦精度を示し、各ユーザにランク上位の 3 曲あるいは 1 0 曲を推薦する場合 ( x = 3、1 0 ) では、推薦精度が有意に高かった。これは、ユーザ群Uと楽曲群Mをクラスタリングすることで、評価行列のサイズおよびスパースネスが減少し ( 図 1 5 参照 )、 D A E M アルゴリズムにより推定されるモデルパラメータの品質が向上したからである。通常の E M アルゴリズムより局所解に陥りにくい D A E M アルゴリズムを利用しても、もとの評価行列 R は極めてスパースで局所解に陥りやすいため、スパースネスを減少させるスケーラビリティ改善法は効果的であった。

20

#### 【0112】

対照的に u s e r s - p i e c e s システムでは、ベースラインシステムより推薦精度は低下した。実際のユーザ群Uのユーザプロフィールを生成するための式 ( 2 2 ) は楽曲群Mに関するサメーションを含んでいるため、仮想的な楽曲群の内容行列ではなく、実際の楽曲群Mの内容行列を利用するほうが望ましい。一方、式 ( 2 3 ) はユーザ群Uに関するサメーションを含んでいない。そのため、実際のユーザを追加登録する前に、実際の楽曲を追加登録しておく必要がある。

30

#### 【0113】


本実施の形態によれば、ユーザや楽曲を効率的にシステムへ追加登録できるように、確率モデルのパラメータを部分的に更新することが可能になる。さらに、インクリメンタル学習法をクラスタリング手法と組み合わせることで、スケーラビリティを改善することができる。その結果、本実施の形態によれば、確率モデルの学習を劇的に高速化するだけでなく、推薦精度を改善することができる。すなわち、推薦精度と効率性・スケーラビリティとの間のトレードオフを解決することができた。

#### 【0114】


なお、本実施の形態で用いたプログラムはコンピュータ読み取り可能な記録媒体に記録できるのは勿論である。

40


【図1】



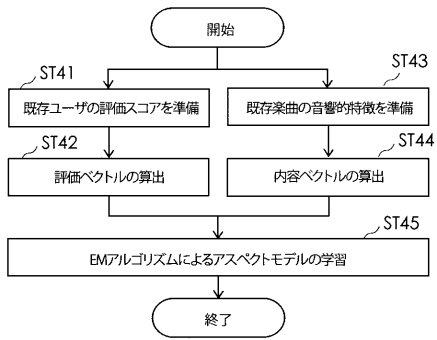
【図2】



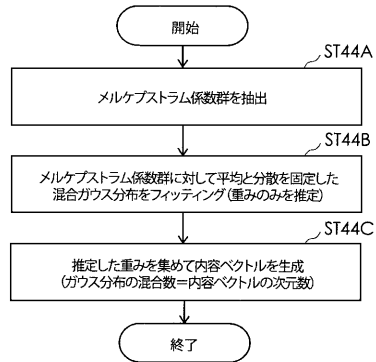
【図3】



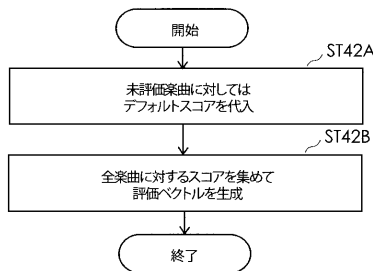
【図4】



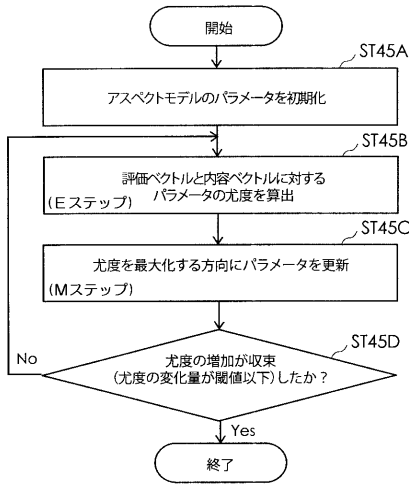
【図6】



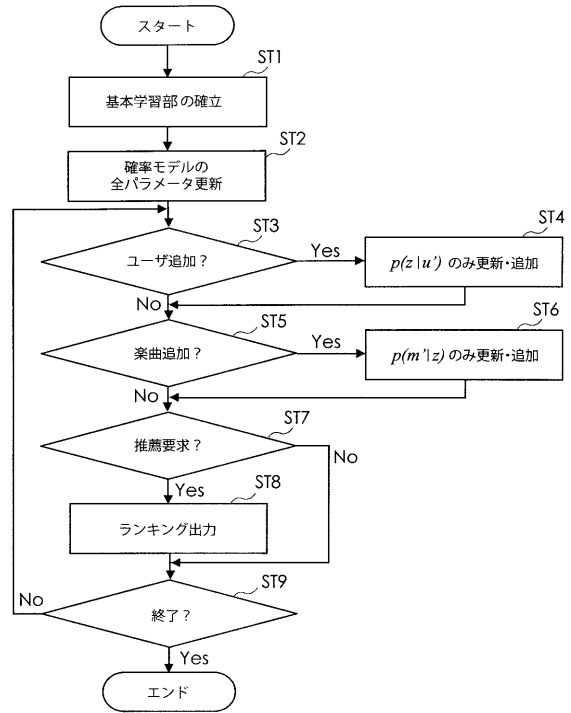
【図5】



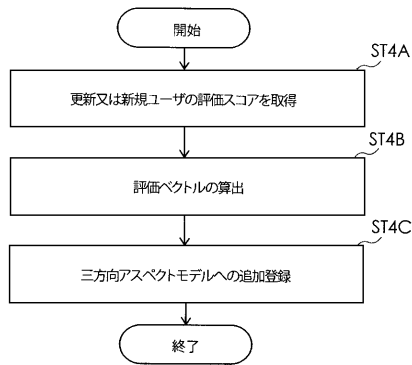
【図7】



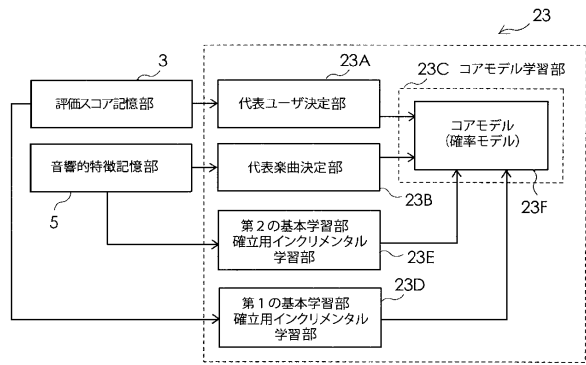
【図8】



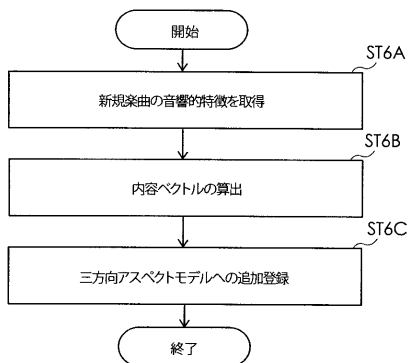
【図9】



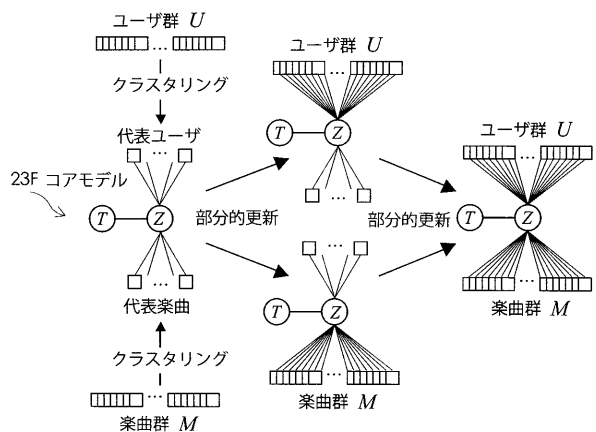
【図11】




【図10】



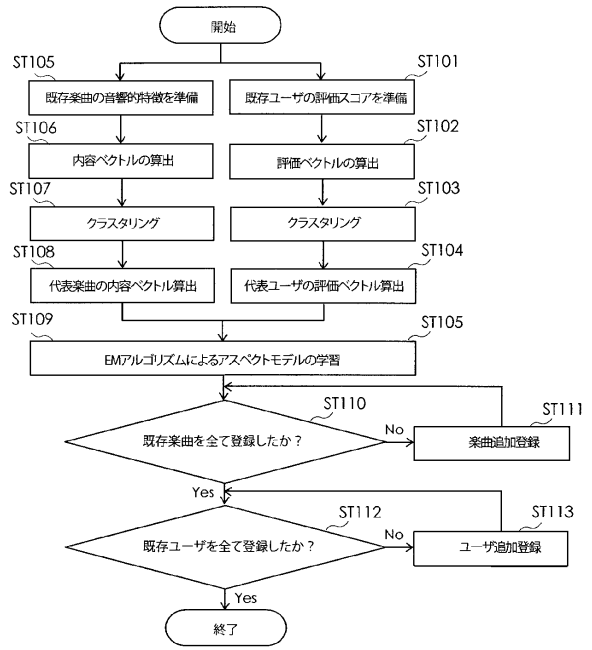
【図12】



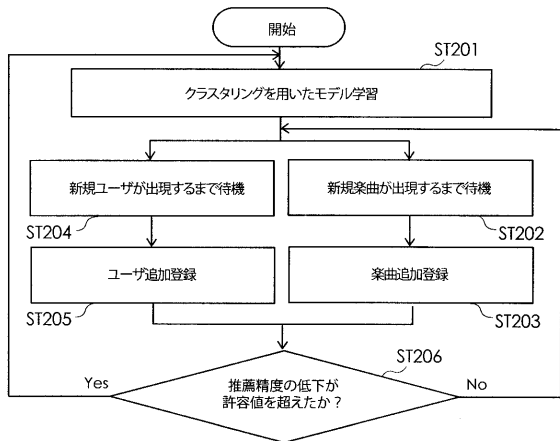
【図 13】




【図 14】




【図 15】




【図 17】



【図 16】




【図 18】







【 図 19 】



【 図 20 】



【 図 2 1 】



---

フロントページの続き

審査官 野崎 大進

(56)参考文献 吉井 和佳 他, ユーザの評価と音響的特徴との確率的統合に基づくハイブリッド型楽曲推薦システム, 情報処理学会研究報告, 日本, 社団法人情報処理学会, 2006年 8月 7日, Vol.2006, No.90(2006-MUS-66(8)), pp.45-52.

(58)調査した分野(Int.Cl., D B名)

G06F 17/30

G10L 19/00

JSTPlus(JDreamII)