

(19) 日本国特許庁(JP)

(12) 特 許 公 報(B2)

(11) 特許番号

特許第5789204号  
(P5789204)

(45) 発行日 平成27年10月7日(2015.10.7)

(24) 登録日 平成27年8月7日(2015.8.7)

(51) Int.Cl.

F I

G 0 6 F 17/30 (2006.01)

G 0 6 F 17/30 2 2 0 B

G 0 6 F 17/30 4 1 9 B

請求項の数 4 (全 22 頁)

(21) 出願番号 特願2012-31561 (P2012-31561)  
 (22) 出願日 平成24年2月16日 (2012.2.16)  
 (65) 公開番号 特開2012-185812 (P2012-185812A)  
 (43) 公開日 平成24年9月27日 (2012.9.27)  
 審査請求日 平成27年2月10日 (2015.2.10)  
 (31) 優先権主張番号 13/040,005  
 (32) 優先日 平成23年3月3日 (2011.3.3)  
 (33) 優先権主張国 米国 (US)

早期審査対象出願

(73) 特許権者 596170170  
 ゼロックス コーポレイション  
 XEROX CORPORATION  
 アメリカ合衆国、コネチカット州 068  
 56、ノーウォーク、ビーオーボックス  
 4505、グローバー・アヴェニュー 4  
 5  
 (74) 代理人 100079049  
 弁理士 中島 淳  
 (74) 代理人 100084995  
 弁理士 加藤 和詳  
 (72) 発明者 ボリス・チドロフスキー  
 フランス国 メラン 38240 アヴェ  
 ニュー・プレヌヌ・フルーリー 21

最終頁に続く

(54) 【発明の名称】 マルチリレーショナル環境において項目を推薦するためのシステム及び方法

(57) 【特許請求の範囲】

【請求項 1】

コンピュータによって推薦タスクを実行するための方法において、  
 メモリが、ソーシャルメディアネットワークのソーシャルメディアデータモデルを表す  
 リレーショナルグラフと、インスタンス生成されたソーシャルメディアデータとを記憶す  
 ることと、  
 リレーショナルグラフ展開モジュールが、リレーショナルグラフに少なくとも一部基  
 いて、インスタンス生成されたソーシャルメディアデータを同時生起行列に展開すること  
 によって展開されたリレーショナルグラフを決定することと、  
 一般的なランダムウォーク生成器が、推薦タスク及び展開されたリレーショナルグラフ  
 に少なくとも一部基づいてランダムウォークモデルを生成することと、  
 重み付けランダムウォーク生成器が、ランダムウォークモデル及び重み付け値に基づい  
 て重み付けランダムウォークモデルを生成することと、  
 学習モジュールが、ランダムウォークモデルについての定常分布を近似することと、訓  
 練事例と連動して損失関数の最小化を使用することによって定常分布を最適化すること  
 によって重み付け値を決定し、メモリ制限プロイデン・フレッチャー・ゴールドファープ  
 ・シャノン B F G S ( L - B F G S ) 法を使用して重み付け値を決定することと、  
 ソーシャルメディア選択モジュールが、重み付けランダムウォークモデルにおいてラン  
 ダムウォークを実行し、ランダムウォークに少なくとも一部基づいて推薦を出力すること  
 とを備える、方法。

10

20

## 【請求項 2】

ランダムウォークモデルを生成することが、リレーショナルグラフを、定常分布及び状態遷移確率の組を備えるマルコフ連鎖に変換することを備える、請求項 1 記載の方法。

## 【請求項 3】

ソーシャルメディアネットワークが、エンティティ間で定義されたりレションを有するエンティティを備える相互に接続された電子ネットワーク構造である、請求項 1 記載の方法。

## 【請求項 4】

推薦タスクを実行するためのシステムにおいて、

ソーシャルメディアネットワークのソーシャルメディアデータモデルを表すリレーショナルグラフと、インスタンス生成されたソーシャルメディアデータとを記憶するメモリと、

リレーショナルグラフに少なくとも一部基づいて、インスタンス生成されたソーシャルメディアデータを同時生起行列に展開することによって展開されたりレショナルグラフを決定するように構成されたりレショナルグラフ展開モジュールと、

推薦タスク及び展開されたりレショナルグラフに少なくとも一部基づいてランダムウォークモデルを生成するように構成された一般的なランダムウォーク生成器と、

ランダムウォークモデル及び重み付け値に基づいて重み付けランダムウォークモデルを生成するように構成された重み付けランダムウォーク生成器と、

ランダムウォークモデルについての定常分布を近似することと、訓練事例と連動して損失関数の最小化を使用することによって定常分布を最適化することとによって重み付け値を決定するように構成された学習モジュールであって、メモリ制限プロイデン・フレッチャー・ゴールドファープ・シャンノ B F G S ( L - B F G S ) 法を使用して重み付け値を決定する重み学習モジュールと、

重み付けランダムウォークモデルにおいてランダムウォークを実行し、ランダムウォークに少なくとも一部基づいて推薦を出力するように構成されたソーシャルメディア選択モジュールとを備える、システム。

## 【発明の詳細な説明】

## 【技術分野】

## 【0001】

以下は、ソーシャルネットワーク等のマルチリレーショナル環境において項目を推薦するためのシステム及び方法に関する。ソーシャルネットワークは、ソーシャルネットワークに属するエンティティが 1 つ以上のリレーションによってリンクされたりレショナルグラフとして論理的に表される。

## 【背景技術】

## 【0002】

メディア共有サイト F l i c k r 及び Y o u T u b e 等の大きなソーシャルメディアネットワークは、多くのユーザ（例えば数百万人）によってアップロードされて注釈が付けられた多くの画像及びビデオ（例えば数十億）を含む。ソーシャルネットワーク内のメディアオブジェクト（画像及びビデオ等）のタグ付けする能力は、メディア共有及び検索機能を改善する強力なメカニズムである。そのようなソーシャルネットワークにおいて、タグは、関連するメディアオブジェクトについてのメタデータの役割を担う。しかしながら、これらのタグは、多くの場合、オブジェクトにおける同定及びタグ付けのために均一で一貫性のある手順よりはむしろメディアオブジェクトの個々のユーザのユニークな知覚を反映した自由形式で提供される。タグ付けにおける均一性の欠乏は、検索者及びタグ付与者が異なる専門用語を使用することがあるため、タグに基づく検索の有効性を低減する可能性がある。この自由な個々の選択にもかかわらず、人々が所定のメディアオブジェクト又は一群のオブジェクトの意味記述について同意するとき、いくつかの共通使用トピックが現れる。

## 【0003】

Flicker及びYouTube等のメディア共有サイトの場合、サイトにおいて注釈が付けられてタグが付けられた大量のオブジェクトは、新規及び既存のメディアオブジェクトについてのタグを提案するための基礎を形成する。推薦システムは、特に、ブートストラップ及びクエリーモードにおいて有益である。ブートストラップモードにおいて、推薦システムは、新たにアップロードされたオブジェクトについて最も関連のあるタグを提案する。クエリーモードにおいて、画像に注釈を付けているユーザは、既存の画像タグを強化することができる推薦されたタグが提示される。双方のモードは、ユーザのための注釈付けタスクを容易とすることができ、画像に注釈を付けているタグの範囲を拡大するのに役立つことができる。

#### 【0004】

より広い意味において、ソーシャルネットワークサイトにおける活動は、多くの場合、様々なエンティティ型（例えば「エンティティ」）及びそれらの間の関係（リレーション）を含む多次元に沿って及ぶ。それゆえに、タグ推薦は、他のソーシャルネットワークオブジェクトのメタデータに基づいてソーシャルネットワーキングサイトのユーザに対してデータを推薦する多くの可能なシナリオのうちの単に1つにすぎない。例えば、他の推薦シナリオは、ユーザについてのコンタクト又はグループの推薦、グループについての画像を推薦等と関係してもよい。これらの推薦は、ソーシャルネットワークにおけるエンティティ間の複数の関係に基づいて提供されてもよい。したがって、所定の推薦タスクのために、エンティティのどのリレーションが推薦タスクと関連しているか、及び、どのようにしてリレーションが最適な方法で項目を推薦するのに使用されるかについて知ることが望ましい。

#### 【発明の概要】

#### 【0005】

典型的な実施形態の1つの態様によれば、既存のタグをソーシャルメディアエンティティインスタンスと関連付けるためにソーシャルネットワークのユーザに対する推薦を行うための方法が提供される。本方法は、ソーシャルネットワークの少なくとも一部についてのソーシャルメディアエンティティインスタンスを含むランダムウォークモデルを生成することと、ランダムウォークモデルについての重み付け値を決定することと、ランダムウォークモデル及び重み付け値に基づいて重み付けランダムウォークモデルを生成することと、ソーシャルメディアエンティティインスタンスから始めて重み付けランダムウォークモデルにおいてランダムウォークを実行することと、ランダムウォークに基づいてユーザに対して既存のタグを推薦することとを含む。

#### 【0006】

他の態様において、推薦タスクを実行するためのシステムが提供される。システムは、ソーシャルメディアネットワークのソーシャルメディアデータモデルとインスタンス生成されたソーシャルメディアデータとを表すリレーショナルグラフを記憶するためのメモリを含む。システムはまた、リレーショナルグラフに少なくとも一部基づいてインスタンス生成されたソーシャルメディアデータを同時生起行列に展開することによって展開されたリレーショナルグラフを決定するように構成されたリレーショナルグラフ展開モジュールと、推薦タスク及び展開されたリレーショナルグラフに少なくとも一部基づいてランダムウォークモデルを生成するように構成された一般的なランダムウォーク生成器と、ランダムウォークモデル及び重み付け値に基づいて重み付けランダムウォークモデルを生成する重み付けランダムウォーク生成器と、重み付けランダムウォークモデルにおいてランダムウォークを実行し、ランダムウォークに少なくとも一部基づいて推薦を出力するように構成されたソーシャルメディア選択モジュールとを含む。

#### 【0007】

さらに他の態様において、 $S$ にわたる初期分布 $P_0$ によって規定される状態 $S$ の組にわたるマルコフ連鎖及び状態遷移確率

10

20

30

40

【数 1】

$$P(S_t|S_{t-1})$$

の組を決定することにより、推薦タスクに少なくとも一部基づいてソーシャルメディアデータモデルについてのランダムウォークモデルを生成し、ランダムウォークモデルについての重み付け値を学習し、ランダムウォークモデル及び学習された重み付け値に基づいて重み付けランダムウォークモデルを生成し、1つ以上の推薦を生成するように重み付けランダムウォークモデルにおいてランダムウォークを実行するように構成されたプロセッサを含む、推薦タスクを実行するための装置が提供される。マルコフ連鎖状態遷移確率は、初期状態分布  $P_0$  にしたがって確率  $> 0$  によってリセットされ、定常分布  $\pi$  は、以下として定義される。

10

【数 2】

$$\pi = \alpha \sum_{t=0}^{\infty} (1 - \alpha)^t P_0 P^t$$

【図面の簡単な説明】

【0008】

【図 1】図 1 は、ソーシャルメディアデータモデルを表すリレーショナルグラフの概略図である。

20

【図 2】図 2 は、マルチリレーショナル環境において項目を推薦するためのシステムを図示している。

【図 3】図 3 は、タグが付けられることになる画像に関する簡略化した重み付けランダムウォークモデルを図示している。

【図 4】図 4 は、図 2 のシステムにおいて実行されてもよいマルチリレーショナル環境において項目を推薦するための方法を図示しているフローチャートである。

【図 5】図 5 は、典型的な方法及びシステムの評価からの結果を、グラフを用いて図示している。

【図 6】図 6 は、典型的な方法及びシステムの評価からの結果を、グラフを用いて図示している。

30

【図 7】図 7 は、典型的な方法及びシステムの評価からの結果を、グラフを用いて図示している。

【図 8】図 8 は、典型的な方法及びシステムの評価からの結果を、グラフを用いて図示している。

【図 9】図 9 は、典型的な方法及びシステムの評価からの結果を、グラフを用いて図示している。

【発明を実施するための形態】

【0009】

ソーシャルネットワーク等のマルチリレーショナル環境において項目を推薦するためのシステム及び方法が本願明細書において開示される。このために、典型的な実施形態は、多くの異なるエンティティ及びそれらの間のリレーションを統合し、異なる推薦タスクについてのデータモデルを構築するためにリレーションを使用し、所定の推薦タスクに対する各リレーションの最適な寄与を見出すことができるマルチリレーショナルフレームワークに関する。ソーシャルネットワークは、本願明細書では、ノードの特性に基づいてノード間で関係（リレーション）を有するノード（エンティティ）から構成された相互に接続された電子ネットワーク構造をいう。例えば、ソーシャルネットワークは、人々、グループ、機関、動物、コンピュータ、メディアオブジェクト（視聴覚作品又は画像等）、メタデータ要素（コメント又はタグ等）等の電子的表現物間における関係を表してもよい。

40

【0010】

ソーシャルネットワーク等のマルチリレーショナル設定において、同じ又は異なる型の

50

エンティティは、複数のリレーションを形成するように接続される。ネットワークにおける各リレーションは、単一型エッジ（ユーザ - ユーザ間のように、同じ型のエンティティについて）又は双部分エッジ（ユーザ - 画像のように、異なる型のエンティティについて）によって表されてもよい。典型的なシステム及び方法において、ソーシャルネットワークを形成するエンティティ及びリレーションは、1つの特定のソーシャルネットワークに限定されず、複数のソーシャルネットワークからエンティティを統合してもよい。1つの実施形態において、別個のソーシャルネットワークからの個人プロフィール及びデータは、共通のエンティティ（共通の個人認証情報等）を介して接続される。例えば、いくつかのソーシャルネットワーキングサイト（Facebook（登録商標）、My Space（登録商標）、Google Friend Connect（登録商標）等）は、ソーシャルネットワークコネクタを介してプラットフォームにわたって共通のユーザを決定するのを許容するアプリケーションプログラミングインタフェース（API）を提供する。いくつかの実施形態において、公然とアクセス可能なデータ（Deliciousソーシャルネットワークにおけるページ推薦及びTwitterにおける関連ツイート等）は、統合されたソーシャルネットワークを構築するのに使用される。説明のために、ソーシャルメディアサイトFlickrがソーシャルメディア共有システムの例として使用される。Flickrは、同じ又は他のユーザによってアップロードされた画像にユーザがタグ付け及びコメントするのを許容するソーシャルメディアサイトである。ユーザ自身は、他のユーザに対して論理的に接続されてもよく、又は、グループのメンバーであってもよい。

【0011】

本願明細書では、推薦タスクは、ネットワークにおける第2のエンティティのインスタンスについてのソーシャルネットワークにおける1つのエンティティの1つ以上のインスタンスの推薦と関係する。第1及び第2のエンティティは、同じ型からなってもよく、異なる型からなってもよい。例えば、推薦タスクは、画像についてタグを推薦すること、ユーザについてコンタクト若しくはグループを推薦すること、又は、ユーザについてユーザを推薦することを含んでもよい。さらに、本願明細書では、「エンティティ」は、データがそれについて記憶されることができる単一のオブジェクトの表現であり、エンティティのインスタンスは、エンティティの単一の発生である。例えば、ソーシャルネットワークは、「ユーザ」エンティティを有してもよい。ここで、ユーザエンティティのインスタンスは、「ボブ・ジョーンズ」である。この目的を達成するために、「インスタンス生成された」ソーシャルメディアデータは、1つ以上のソーシャルメディアデータインスタンスの集合をいう。

【0012】

高いレベルにおいて、所定の推薦タスクのために、典型的な実施形態は、ソーシャルネットワークモデルを表すリレーショナルグラフを取得する。ソーシャルネットワークモデルは、単一のソーシャルネットワークのモデルであってもよく、又は、複数のソーシャルネットワークモデルの統合であってもよい。ソーシャルネットワークモデルを表すリレーショナルグラフは、ソーシャルネットワークモデルにおける2つのエンティティ間の各リレーションの強さが2つのエンティティの間におけるランダムウォークに依存するマルコフ連鎖に変換される。この変換を実行するために、リレーショナルグラフに関するソーシャルネットワークデータのインスタンス化とともに、リレーショナルグラフは、予め注釈が付けられた訓練事例に最適化された重み付け平均とその後に組み合わされる同時生起行列（エンティティ間の各リレーションについての1つ）に展開される。そして、ランダムウォークは、推薦の組を取得するために重み付けされて展開された行列に実行される。

【0013】

図1を参照すると、（Flickrネットワークのような）ソーシャルメディアデータモデルを表す図示されたリレーショナルグラフ2が示されている。リレーショナルグラフ2は、リレーション6、10、14、18、20、22、26によって接続されたエンティティ4、8、12、16、24を含む。各リレーションは、2つのエンティティがどのように関連があることができるかについて定義する。例えば、ユーザは画像を所有し、し

たがって、ユーザエンティティ 16 は、リレーション「オーナ」22 によって画像エンティティ 4 とリンクされる。同様に、画像はタグによってタグ付けされてもよく、したがって、画像エンティティ 4 は、「tagged\_with」リレーション 6 によってタグエンティティ 8 とリンクされる。さらに他の例として、例えばコンタクトとして、2 人のユーザがリンクされることができ、これは、「コンタクト」単一型エッジリレーション 18 を含むことによって図 1 のリレーショナルグラフ 2 において示される。

【0014】

論理レベルにおいて、リレーショナルグラフ 2 は、一律にソーシャルネットワークの全てのエンティティ及びリレーションの統合を許容する。数学用語において、リレーショナルグラフ 2 は、 $G = (E, R)$  として書かれてもよい。ここで、エンティティ型  $e_k$

10

【数 3】

$e \in E$

は、ノードとして表され、エンティティ型  $e_k$  及び  $e_l$  間のリレーション  $r_{kl}$

【数 4】

$e \in R$

は、(型付き)リンクとして表される。ここで留意すべきは、「コンタクト」リレーション 18 等の単一型リレーションについては  $k = l$  であるということである。しかしながら、インスタンス生成されたとき、 $e_k$  及び  $e_l$  は、2 つの異なるユーザエンティティインスタンスのインスタンスとしてインスタンス生成される。図 1 において、図示したリレーショナルグラフ 2 は、任意の 2 つのエンティティ型  $e_k$  及び  $e_l$  間の 1 つのリレーションしか有しない。しかしながら、リレーショナルグラフは、任意の 2 つのエンティティ  $e_k$  及び  $e_l$  間の複数のリレーションを有してもよい。さらに、いくつかのエンティティは、許容可能なリレーションを有しなくてもよく、例えば、図 1 のリレーショナルグラフ 2 におけるタグエンティティ型 8 とコメントエンティティ型 12 との間にリレーションがない。

20

【0015】

リレーショナルグラフにおける各リレーションは、リレーションにおける同値が推薦タスクについて同じ重要性を有する傾向があるという意味で内部的に同種である。任意の所定の推薦タスクについて、異なるリレーションは、所定の推薦タスクと関連して重要性において異なっているもよい。例えば、画像エンティティ 4 とタグエンティティ 8 との間の tagged\_with リレーション 6 は、ユーザエンティティ 16 とグループエンティティ 24 との間のメンバーリレーション 20 よりもタグ推薦タスクに対してより重要であると思われる。

30

【0016】

図 2 は、ソーシャルネットワーク等のマルチリレーショナル環境において所定のエンティティインスタンスと関連することになるエンティティインスタンスを推薦するための典型的なシステム 100 を図示している。システム 100 は、エンティティインスタンス 104 (特定の画像等)、ソーシャルネットワークモデル 106、インスタンス生成されたソーシャルメディアデータ 108 (ソーシャルネットワークについての特定のユーザデータ等)、及び、任意にランダムウォークモデルについての予め設定された重み 123 を表すデータを受けるための入力装置 102 を含む非一時的装置である。代わりに、入力 104、106、108、123 は、システム 100 自身によって生成されてもよい及び/又はシステム 100 に記憶されてもよい。入力する前に、入力 104、106、108、123 は、ディスク、ROM 若しくは RAM 等の任意の適切な有形記憶媒体に記憶されてもよく、又は、例えばインターネットを介して搬送波の形態でシステム 100 に入力されてもよい。入力装置 102 は、モデムリンク、有線若しくは無線通信、USB ポート、フロッピー若しくはハードディスク受信機、携帯電話の送受信機部分等を含んでもよく、システム 100 の他の構成要素と分離され若しくは組み合わされてもよい。

40

50

## 【 0 0 1 7 】

システム 1 0 0 は、処理の間、ソーシャルメディアデータ 1 0 4、ソーシャルメディアデータモデル 1 0 6、インスタンス生成されたソーシャルメディアデータ 1 0 8、及び、任意の予め設定された重み 1 2 3 の単一のインスタンスを記憶するためのデータメモリ 1 1 2 を含む。システム 1 0 0 のメインメモリ 1 1 4 は、リレーショナルグラフ展開モジュール 1 1 8、一般的なランダムウォーク生成器 1 2 0、任意の重み学習モジュール 1 2 2、重み付けランダムウォーク生成器、及び、ソーシャルメディア選択モジュール 1 2 6 を含む典型的な方法を実行するための命令 1 1 6 を記憶する。当然のことながら、2 つのメモリ 1 1 2、1 1 4 は、単一の記憶装置として具体化されてもよく、又は、メモリ 1 1 2、1 1 4 の一方又は双方は、2 つ以上の記憶装置構成要素を備えてもよい。命令 1 1 6 は、図示されたコンピュータプロセッサ 1 3 6 等のデジタルプロセッサ上で適切に実行される。コンピュータプロセッサは、シングルコアプロセッサ、デュアルコアプロセッサ（又は、さらに一般的に言えば複数コアプロセッサ）、デジタルプロセッサ及び協働する数値演算コプロセッサ、デジタルコントローラによる等、様々に具体化されることができる。モジュール 1 1 8、1 2 0、1 2 2、1 2 4、1 2 6 からの出力は、メモリ 1 1 2、1 1 4 に記憶されてもよく、及び/又は、出力装置 1 2 8 を介して、任意にはインターネット等のネットワーク 1 3 2 を介して、クライアント端末機 1 3 0 に対して出力されてもよい。1 つの図示された例において、ユーザは、携帯機器を使用してソーシャルネットワークにアクセスするが、システム 1 0 0 は、ソーシャルネットワークによって提供されるサービスである。この場合、システム 1 0 0 は、ソーシャルネットワークをサポートするサーバ（サーバは、分散型又は「クラウド」コンピューティングネットワークであってもよい）に位置し、入力 1 0 2 及び出力 1 2 8 は、適切には、サーバのインターネットポータルであり、プロセッサ 1 3 6 及びメモリ 1 1 2、1 1 4 は、サーバのデジタルプロセッサ（例えば、マイクロプロセッサ又はマイクロプロセッサのパラレルアレイ）及びメモリ構成要素によって適切に具体化され、ネットワーク 1 3 2 は、適切には、任意のダウンストリームネットワーク（例えば、携帯電話ネットワーク又は W i F i ネットワーク）とともにインターネットであり、クライアント端末機 1 3 0 は、適切には、出力を表示するためのその表示画面を含む携帯機器である。

## 【 0 0 1 8 】

リレーショナルグラフ展開モジュール 1 1 8 は、入力装置 1 0 2 を介して、ソーシャルメディアデータモデル 1 0 6 及びインスタンス生成されたソーシャルメディアデータ 1 0 8 を入力として受信する。上述したように、ソーシャルメディアデータモデル 1 0 6 は、図 1 によって図示されたリレーショナルグラフ 2 のようなリレーショナルグラフであるか、又は、リレーショナルグラフに変換されてもよい。モジュール 1 1 8 は、インスタンス生成されたソーシャルメディアデータ 1 0 8 を、ソーシャルメディアリレーショナルグラフによって定義されるエンティティ関係を反映する同時生起行列に（すなわち、展開されたリレーショナルグラフ 1 1 9）に展開する。この展開プロセスは、図 4 の工程 S 1 4 0 に関してより詳細に記載される。

## 【 0 0 1 9 】

一般的なランダムウォーク生成器 1 2 0 は、リレーショナルグラフ展開モジュール 1 1 8 によって生成された展開されたリレーショナルグラフ 1 1 9 を入力として受信し、ランダムウォークモデル 1 2 1 を構築する。ランダムウォークモデル 1 2 1 は、展開されたリレーショナルグラフ 1 1 9 からマルコフ連鎖を構築することによって生成される。当業者によって理解されるように、マルコフ連鎖（又はマルコフモデル）は、任意の所定の状態についての次の状態が所定の状態のみに依存する状態を有するモデルである。典型的な実施形態において、マルコフ連鎖自身は、ランダムウォークモデル 1 2 1 として指定される。展開されたリレーショナルグラフ 1 1 9 からランダムウォークモデル 1 2 1 を生成するプロセスは、図 4 の工程 S 1 5 0 に関してより詳細に記載される。

## 【 0 0 2 0 】

任意の重み学習モジュール 1 2 2 は、所定の推薦タスクについてのリレーショナルグラ

10

20

30

40

50

フ（例えば、図１、リレーショナルグラフ２）における各リレーションの重み付け寄与を表す重み付け値の組１２３を決定する。例えば、図１のリレーショナルグラフ２に関して、タグ８の推薦が所定の画像４に関して行われることになっている場合、オーナリレーション２２が、所定の画像４について推薦するのにタグ８がより良好な指示であることが決定される場合、オーナリレーション２２は、appears\_inリレーション２６よりも重く重み付けされてもよい。重み付け値の組１２３を決定するこのプロセスは、図４の工程Ｓ１６０に関して以下により詳細に記載される。

#### 【００２１】

重み付けランダムウォーク生成器１２４は、重み学習モジュール１２２からの重み付け値の組１２３と、一般的なランダムウォーク生成器１２０からのランダムウォークモデル１２１とを入力として受信する。他の実施形態において、重み付け値１２３は、システム１００のオペレータによって直接入力された値等、重み学習モジュール１２２以外のソースから提供される。そして、重み付けランダムウォーク生成器１２４は、重み付けランダムウォークモデル１２５を作成するためにランダムウォークモデル１２１に対して重み付け値の組１２３を適用する。典型的な実施形態において、重み付けランダムウォークモデル１２５は、重み付け値の組１２３にしたがって調整された定常分布を有するランダムウォークモデル１２１である。そして、生成器１２４は、ソーシャルメディア選択モジュール１２６に対して重み付けランダムウォークモデル１２５を提供する。重み付けランダムウォークモデル１２５を生成するプロセスは、図４の工程Ｓ１７０に関して以下により詳細に記載される。

#### 【００２２】

ソーシャルメディア選択モジュール１２６は、重み付けランダムウォーク生成器１２４からの重み付けランダムウォークモデル１２５を入力として受信し、ソーシャルメディアデータ１０４の入力インスタンスに関して、所定の推薦タスクについての１つ以上のエンティティインスタンスを選択するために重み付けランダムウォークモデル１２５においてランダムウォークを実行する。そして、選択されたエンティティインスタンスは、所定の入力エンティティ１０４についての推薦１３４として出力される。例えば、簡略化した重み付けランダムウォークモデル１２５は、（状態 $S_0$ によって示された）タグが付けられることになる画像に関して図３において提供される。この例において、 $S_1$ についての２０％の機会及び $S_3$ についての３０％の機会とは対照的に $S_2$ が次の段階である５０％の機会をランダムウォークが提供することから、モデル１２５において実行されるランダムウォークは、選択されることになる状態 $S_2$ によって表されるタグをもたらすようである。ランダムウォークは、複数のエンティティインスタンスを選択するために複数回実行されてもよい。重み付けランダムウォークモデル１２５からエンティティインスタンスを選択するこのプロセスは、図４の工程Ｓ１８０に関して以下により詳細に記載される。

#### 【００２３】

典型的な実施形態において、構成要素１１４、１１６、１１８、１２０、１２２、１２４、１２６は、コンピュータプロセッサ１３６によって実行されるメインメモリ１１２に記憶されたソフトウェア命令を備える。コンピュータのＣＰＵ等のプロセッサ１３６は、メモリ１１２に記憶された処理命令の実行によってコンピューターシステム１００の全体動作を制御してもよい。構成要素１０２、１１２、１１４、１１６、１１８、１２０、１２２、１２４、１２６、１２８、１３６は、データ制御バス１３８によって接続されてもよい。

#### 【００２４】

明らかなように、システム１００は、さらに同じ機能性を有しながら、より少し又はより多くの構成要素を含んでもよい。例えば、構成要素１１６、１１８、１２０、１２２、１２４、１２６は、より少しの構成要素を形成するように組み合わせられてもよく、又は、より多くの個々の構成要素を形成するように機能的に分離されてもよい。

#### 【００２５】

システム１００は、パーソナルコンピュータ、ＰＤＡ、ラップトップコンピュータ、サ

10

20

30

40

50

ーバコンピュータ、又は、それらの組み合わせ等、1つ以上の計算装置を備えてもよい。メモリ112、114は、一体であってもよく、又は、分離されていてもよく、ランダムアクセスメモリ(RAM)、読み出し専用メモリ(ROM)、磁気ディスク若しくはテープ、光ディスク、フラッシュメモリ、又は、ホログラフィックメモリ等、任意の種類のコンピュータ読み取り可能な媒体を表してもよい。1つの実施形態において、メモリ112、114は、ランダムアクセスメモリ及び読み出し専用メモリの組み合わせからなる。いくつかの実施形態において、プロセッサ136及びメモリ112及び/又は114は、単一チップに結合されてもよい。

#### 【0026】

システム100は、クライアント端末機130やサーバ等の出力装置に対して推薦134を出力してもよい。出力装置128は、システム100と直接接続されてもよく、又は、例えば、ローカルエリアネットワーク、ワイドエリアネットワーク、又は、インターネット等の有線・無線リンク132を介して、それに対してリンクされてもよい。システム100又はクライアント端末機130は、ユーザに対する表示のためのグラフィカルユーザインターフェース(GUI)を生成してもよい。典型的なGUI(図示しない)は、カーソル制御装置、キーボード、キーパッド、ジョイスティック等のユーザ入力装置を用いてクライアント端末機130の表示画面を介してユーザがシステム100と対話するのを可能とする。典型的な実施形態において、クライアント端末機130は、ユーザがシステム100と対話するのを許容するウェブブラウザを含んでもよく、それはサーバコンピュータによって実装されてもよい。

#### 【0027】

本願明細書では、用語「ソフトウェア」は、ソフトウェアの目的であるタスクを実行するようにコンピュータ又は他のデジタルシステムを構成するために、コンピュータ又は他のデジタルシステムによって実行可能な命令の任意の集合又はセットを含むことを目的としている。本願明細書では、用語「ソフトウェア」は、RAM、ハードディスク、光ディスク等の記憶媒体に記憶されるそのような命令を含むことを目的としており、ROM等に記憶されるソフトウェアであるいわゆる「ファームウェア」を含むことも目的としている。そのようなソフトウェアは、様々な方法で編成されてもよく、ライブラリ、リモートサーバ等に記憶されたインターネットベースのプログラム、ソースコード、解釈コード、オブジェクトコード、直接実行可能コード等として編成されたソフトウェアコンポーネントを含んでもよい。ソフトウェアが所定の機能を実行するためにサーバ又は他の位置にある他のソフトウェアに対してシステムレベルコード又はコールを呼び出してもよいと考えられる。

#### 【0028】

図4は、マルチリレーショナル環境において項目を推薦するための典型的な方法を図示している。本方法は、図2において詳述された典型的なシステムにおいて実行されてもよい。本方法は、S100から始まる。

#### 【0029】

S110において、ソーシャルメディア推薦システム100は、推薦タスクが実行されることになるソーシャルメディアデータ104(画像等)の単一のインスタンスをメモリ112及び/又は114に受信する。説明的な目的のために、推薦タスクが入力画像についての1つ以上のタグを推薦することになっていると仮定される。しかしながら、推薦タスクは、一般に、ネットワークにおける第2のエンティティのインスタンスについてのソーシャルネットワークにおける1つのエンティティのうちの1つ以上のインスタンスの推薦をカバーする。

#### 【0030】

S120において、ソーシャルメディア推薦システム100は、ソーシャルメディアデータモデルを表すリレーショナルグラフ106をメモリ112及び/又は114に受信する。例えば、図1のリレーショナルグラフ2は、Flickrソーシャルメディアデータモデルの表現であり、システム100への入力であってもよい。

## 【 0 0 3 1 】

S 1 3 0において、ソーシャルメディア推薦システム 1 0 0は、インスタンス生成されたソーシャルメディアデータ 1 0 8をメモリ 1 1 2及び/又は 1 1 4に受信する。インスタンス生成されたソーシャルメディアデータは、入力ソーシャルメディアデータモデル 1 0 6にしたがう1つ以上のソーシャルメディアエンティティインスタンス（画像、タグ、ユーザ等）を含む。

## 【 0 0 3 2 】

S 1 4 0において、リレーショナルグラフ展開モジュール 1 2 0は、ソーシャルメディアデータモデル 1 0 6及びインスタンス生成されたソーシャルメディアデータ 1 0 8に基づいて同時生起行列を作成することによって展開されたリレーショナルグラフ 1 1 9を生成する。上述したように、ソーシャルメディアデータモデル 1 0 6は、 $G = (E, R)$ によって与えられるグラフである。ここで、エンティティ型 $e_k$

10

## 【 数 5 】

$$\in E$$

は、ノードとして表され、型 $e_k$ 及び $e_l$ のエンティティ間のリレーション $r_{kl}$

## 【 数 6 】

$$\in R$$

は、（型付き）リンクとして表される。展開されたリレーショナルグラフ 1 1 9を作成するために、各リレーション $r_{kl}$ は、以下の行列の形態で（インスタンス生成されて）展開される。

20

## 【 数 7 】

$$A_{kl} = \{a_{kl}^{ij}\}, i = 1, \dots, |e_k|, j = 1, \dots, |e_l|$$

ここで、以下

## 【 数 8 】

$$a_{kl}^{ij}$$

30

は、以下

## 【 数 9 】

$$i \in e_k$$

及び

## 【 数 1 0 】

$$j \in e_l$$

40

のエンティティ間のリレーションを示す（例えば、図1のtagged\_withリレーション6において、画像 $i$ がタグ $j$ によってタグ付けされた場合には、リレーション $r_{kl}$ において $a_{kl}^{ij} = 1$ であり、そうでない場合は0である）。

一般的な場合において、 $a_{kl}^{ij}$ は、範囲 $[0, 1]$ からの実数値である。リレーショナルグラフが型 $e_1, \dots, e_b$ の $b$ 個のエンティティ $P$ を含むと仮定する。エンティティの総数は、以下である。

【数 1 1】

$$N = \sum_{k=1}^b |e_k|$$

展開されたリレーショナルグラフ 119 は、各  $(e_k, e_l)$  対について 1 つのブロックとしたとき、 $b^2$  個のブロックから構成される。利用可能なリレーションは、いくつかのブロックを満たし、他のブロックは、空のままにされることができ、又は、リレーション他動性  $A_{k,l} = A_{k,m} A_{m,l}$  を使用して構成されたリレーションによって満たされることができる。ここで、 $A_{k,l}$  は、基本的又は構成されたリレーションである。リレーション構成は、所定の推薦タスクに依存してもよい。

【0033】

10

図 1 の F l i c k r リレーショナルモデル 2 に関して、P における対応するブロックを満たし且つ他のリレーションを構成することができる 7 つの基本リレーション 6、10、14、18、20、22、26 がある。タグ同時生起関係は、構成されたリレーションの例である。行列  $A_{I,T}$  がリレーション  $t a g g e d\_w i t h$  (画像, タグ) を記載する場合、タグ同時生起行列は、 $A_{T,T} = A'_{I,T} A_{I,T}$  によって取得されることができる。 $A_{T,T}$  におけるより高い値は、より多くの画像が所定のタグ対によってタグ付けされることを示す。

【0034】

S 150 において、一般的なランダムウォーク生成器 120 は、展開されたリレーショナルグラフ 119 からマルコフ連鎖を構築することによってランダムウォークモデル 121 を生成する。一般的なランダムウォーク生成器 120 によって構築されたマルコフ連鎖は、特定の予測タスクについて良好に作用する定常分布を有する。状態 S の組にわたるマルコフ連鎖は、S にわたる初期分布  $P_0$  及び状態遷移確率

20

【数 1 2】

$$P(S_t | S_{t-1})$$

の組によって規定される。マルコフ連鎖は、初期状態  $S_0$  が  $P_0$  にしたがって最初にサンプリングされ、その後、遷移確率にしたがって順に状態  $S_t$  ( $t = 1, 2, \dots$ ) がサンプリングされる生成プロセスを介して、状態の配列にわたって分布を定義する。マルコフ連鎖の定常分布は、制限が存在する場合、以下によって与えられる。

30

【数 1 3】

$$\pi(s) = \lim_{\infty} P(S_t = s)$$

【0035】

マルコフ連鎖が独特な定常分布を有するのを確実にするために、モジュール 120 は、初期状態分布  $P_0$  にしたがって確率  $\alpha > 0$  によってプロセスをリセットする。確率  $\alpha$  は、本方法についての調整パラメータであり、実際には、適切な確率  $\alpha$  は、連鎖が小ループから抜け出せなくなるのを防止する。典型的な実施形態において、約 0.05 から 0.40 に及ぶ値の  $\alpha$  は、良好な結果を生成するが、 $\alpha$  についての他の値が考えられる。 $S_0$  にしたがって分布された初期状態  $S_0$ 、P によって与えられる状態遷移及びリセット確率によるマルコフ連鎖  $S_0, S_1, \dots$  を有する場合、以下のように定常分布を表現することは容易である。

40

【数 1 4】

$$(1) \quad \alpha \sum_{t=0}^{\infty} (1 - \alpha)^t P_0 P^t$$

【0036】

式 (1) は、効率的に  $\pi(s)$  を計算するのに使用されることができる。大きい  $t$  に対応する期間が非常に僅かな重みを有することから、 $\pi(s)$  を計算するとき、このシーケンスは、重大な誤差を被ることなく最初の数期間 (

50

【数 1 5】

 $(\frac{1}{\alpha} \text{のオーダー})$ 

のオーダー)の後に打ち切られてもよい。

【数 1 6】

 $(1 - \alpha)^t$ 

一般的なランダムウォーク生成器 1 2 0 の出力は、ランダムウォークモデル 1 2 1 である。典型的な実施形態において、ランダムウォークモデル 1 2 1 は、マルコフ連鎖と同様である。

10

【0 0 3 7】

S 1 6 0 において、重み学習モジュール 1 2 2 は、所定の推薦タスクについてのリレーショナルグラフ 1 0 6 における各リレーションの重み付け寄与を表す重み付け値の組 1 2 3 を決定する。重み付け値 1 2 3 は、重み付け値 1 2 3 及び前に作成されたランダムウォークモデル 1 2 1 を組み合わせた重み付けランダムウォークモデル 1 2 5 を作成するために重み付けランダムウォーク生成器 1 2 4 によって使用される。他の実施形態において、重み付け値 1 2 3 は、計算される必要がないシステム 1 0 0 への入力であってもよい。

【0 0 3 8】

説明の便宜上、所定のランダムウォークモデルを考える。重み  $w_{k \ 1}$  は、エンティティ  $e_k$  及び  $e_1$  の間のランダムウォークモデルにおける所定のリレーション  $r_{k \ 1}$  の相対的な寄与を表現する。以下によって表現されるリレーションの重み付け和及び  $(s)_j$  は、エンティティ型  $j$  における定常分布 の射影である。

20

【数 1 7】

$$A = \sum_{kl} w_{kl} A_{kl}$$

【0 0 3 9】

ランダムウォークモデルにおいてランダムウォークを開始するために、初期分布  $P_0$  は、クエリーに利用可能な全ての要素を有する  $b$  個のベクトル  $i$ 、 $i = 1, \dots, b$  から構成される。したがって、 $P_0$  は、 $[ \quad_1, \quad_2, \dots, \quad_b ]$  の正規化として定義されてもよい。それゆえに、重み  $w_{i \ j}$  が専門家によって公知であるか又は推薦された場合、式 (1) は、定常分布 及びその射影  $j$  を推定するのに使用されてもよい。重みが事前に不明である場合、重み学習モジュール 1 2 2 は、所定の損失関数を最小化する重み  $w_{k \ 1}$  についての値を見出す。

30

【0 0 4 0】

リレーショナルランダムウォークの重みを学習するために、定常分布 は、省略されたバージョンで近似され、最適化問題は、予測が訓練事例に対して適用されるときに、損失関数の最小化として重み  $w_{k \ 1}$  において表現される。それゆえに、重み付けランダムウォークは、確率分布をもたらず重み付けマルコフ連鎖クエリーによって定義される。より高い重みを有するより多くのリンク (例えば、エンティティ間のリレーション) を有するノードは、より少ないリンクを有し且つより低い重みのノードよりも多くの確率を集積する。さらに、リンク上の重みは、訓練事例から推定されることができ。ここで、モデルは、訓練事例  $T$  における予測誤差を最小化するマルコフモデル重みのインスタンス化である。重み学習を支援するために、型  $e_k$  のエンティティに対して  $[0, 1]$  の値を割り当てるスコアリング関数  $H$  が使用される。重み学習モジュール 1 2 2 は、ソーシャルメディアデータモデル 1 0 6 及び / 又は展開されたリレーショナルグラフ 1 1 9 から生じるもの等、エンティティ間における公知のリレーションの組から関数  $H$  を学習する。関数  $H$  は、所定のオブジェクト  $i$  についての確率  $p$  を推定する。  $y$  を  $i$  の真の確率を意味するものとし、  $p$  を  $H$  によるその推定値とする。  $y$  の場所における予測  $p$  のときに取られる損失は、損失関数  $l(y, p)$  として定義される。  $y$  及び  $p$  の間の二乗損失は、以下として表現され

40

50

る。

【数 1 8】

$$(2) \quad l_{sq}(y, p) = y(1 - p)^2 + (1 - y)p^2$$

【0 0 4 1】

ここで留意すべきは、 $p$  における一次及び二次の偏導関数は、それぞれ、以下であるということである。

【数 1 9】

$$\frac{\partial}{\partial p} l_{sq}(y, p) = 2(p - y)$$

10

【数 2 0】

$$\frac{\partial^2}{\partial^2 p} l_{sq}(y, p) = 2$$

【0 0 4 2】

一般性の損失なしに、タグ推薦タスクは、二乗損失関数を示すように表される。タグエンティティセットが  $L$  個のタグインスタンスを有すると仮定する。所定の画像について、画像がタグ  $i$ 、 $i = 1, \dots, L$  によってタグ付けされる場合、 $Y_B$  を二値ベクトル  $Y_B = \{y_1, \dots, y_L\}$  を意味するものとする。ここで、 $y_i$  は 1 である。タグ設定タグにわたる確率分布は、 $Y = (y_1, \dots, y_n)$  である。ここで、 $y_i$  は以下である。

20

【数 2 1】

$$0 \text{ or } \frac{1}{|Y_E|}, i = 1, \dots, L$$

【0 0 4 3】

$P$  を推定されたタグ確率分布  $P = (p_1, \dots, p_L)$  を意味するものとする。ここで、以下である。

30

【数 2 2】

$$\sum_{i=1}^L p_i = 1$$

$Y$  の場所において分布  $P$  を使用した二乗損失は、以下として定義される。

【数 2 3】

$$(3) \quad L_{sq}(Y, P) = \frac{1}{L} \sum_{i=1}^L l_{sq}(y_i, p_i)$$

【0 0 4 4】

40

分布の二乗損失  $L_{sq}$  について、導関数は、以下の形式を有する。

【数 2 4】

$$\frac{\partial}{\partial P} L_{sq}(Y, P) = \frac{1}{L} \sum_{i=1}^L \frac{\partial}{\partial p_i} l_{sq}(y_i, p_i) = \frac{2}{L} \sum_{i=1}^L (y_i - p_i)$$

そして、同様に以下である。

【数 2 5】

$$\frac{\partial^2}{\partial^2 P} L_{sq}(Y, P) = \frac{1}{L} \sum_{i=1}^L \frac{\partial^2}{\partial^2 p_i} l_{sq}(y_i, p_i) = 2$$

【0 0 4 5】

画像の訓練事例  $T$  がタグ確率分布  $Y$  を有する場合、重み学習モジュール 1 2 2 は、以下として定義される  $T$  にわたる経験的損失を最小化するスコアリング関数  $H$  を見出す。

【数 2 6】

10

$$Loss(H) = \frac{1}{|T|} \sum_{j \in T} L_{sq}(Y_j, P_j),$$

ここで、 $Y_j$  は、画像  $j$  についての真の確率ベクトルであり、 $P_j$  は、予測確率分布である。

【0 0 4 6】

$b$  個の異なるエンティティ型から構成される重み付け和は、以下である。

【数 2 7】

20

$$A = \sum_{kl}^b w_{kl} A_{kl}$$

$w_{kl}$  のより大きな値は、型  $i$  及び  $j$  の間のリレーションのより多くの重要度を示す。リレーション  $r_{kl}$  についての全ての行列  $A_{kl}$  は、各状態遷移分布によって正規化される。行列混合  $A$  は、以下の同じ条件及び制約を満たさなければならない。

【数 2 8】

$$\sum_l w_{kl} = 1, w_{kl} \geq 0$$

30

しかしながら、混合行列  $A$  は、対称形であるのを必要とされなく、一般的な場合において

【数 2 9】

$$W_{kl} \neq W_{lk}$$

$i$  である。それゆえに、以下の最適化問題が以下に表される。

【数 3 0】

$$(5) \min_{w_{kl}} Loss(iI) \text{ s. t. } 0 \leq w_{kl} \leq 1$$

【数 3 1】

40

$$\sum_l w_{kl} = 1, k = 1, \dots, b$$

【0 0 4 7】

制約つき最適化問題 (5) は、変数  $v_{kl}$ 、 $k, l = 1, \dots, b$  を導入して以下を表すことによって制約がないものに変換されることができる。

【数 3 2】

$$w_{kl} = e^{v_{kl}} / \sum_m \exp(v_{km})$$

$w_{kl}$  に制約される問題は、 $v_{kl}$  に制約されなくなる。

【0048】

問題(5)を解決するために、重み学習モジュール122は、メモリ制限プロイデン・フレッチャー・ゴールドファーブ・シャノ(L-BFGS)法を使用する。L-BFGSアルゴリズムは、準ニュートン最適化法の広い群の要素である。これらの方法は、周知のニュートン法を近似し、(2回連続して微分可能な)関数の停留点を求める山登り最適化技術の類である。そのような問題のために、最適化についての要件は、勾配がゼロであるということである。関数が最適条件の近くで二次テイラー展開を有しない限り、ニュートン法及びBFGS法は、収束する必要はない。一般的に言えば、これらの方法は、一次及び二次の導関数を使用する。

10

【0049】

準ニュートン法において、二次導関数のヘッセ行列は、直接推定される必要はない。代わりに、ヘッセ行列は、勾配推定値(又は近似の勾配推定値)によって指定される階数1のアップデートを使用して近似される。プロイデン・フレッチャー・ゴールドファーブ・シャノ(BFGS)法は、この類の最もよく知られた要素の1つである。

【0050】

L-BFGSは、逆ヘッセ行列を近似するためにBFGSのメモリ制限バリエーションを使用する。高密度の $n \times n$ の近似値を記憶するオリジナルのBFGS法と異なり、L-BFGSは、暗に近似値を表す少数のベクトルのみを記憶する。L-BFGSルーチンによる最適化パッケージは、Matlab及びPython/Scipy環境において使用される。

20

【0051】

上述した反復スキームは、ヘッセ行列 $HL(W)$ の勾配

【数 3 3】

$$\nabla L(W)$$

及び逆行列を含む全ての $w_{kl}$ 次元に一般化されてもよい。ここで、 $W = (w_{kl})$ 、 $k, l = 1, \dots, b$ である。これは、近似された解決策 $W_0, W_1, \dots$ の以下の反復シーケンスを与える。

30

【数 3 4】

$$(6) \quad W_{n+1} = W_n - [HL(W)]^{-1} \nabla F(W_n), n \geq 0$$

【0052】

重み付けランダムウォークのために準ニュートン法を展開するために、変数 $w_{kl}$ に関する損失関数の導関数は、以下で取得される。

【数 3 5】

$$(7) \quad \frac{\partial \text{Loss}(H)}{\partial w_{kl}} = \frac{1}{|T|} \sum_{j \in T} \frac{\partial}{\partial P_j} L_{sq}(Y_j, P_j) \frac{\partial P_j}{\partial w_{kl}},$$

40

ここで、以下及び

【数 3 6】

$$P_0^t$$

は、画像 $j$ についての初期確率分布である。

【数 3 7】

$$P_j = \alpha \sum_{t=1}^k (1 - \alpha)^t P_0^j A^t$$

【0053】

べき級数  $A^t$ 、 $t = 1, 2, \dots$  は、 $w_{kl}$  に依存する  $P_j$  における唯一の項であり、それらの一次導関数は、以下によって提供される。

【数 3 8】

$$(8) \quad \frac{\partial A^t}{\partial w_{kl}} = \frac{\partial}{\partial w_{kl}} (A^{t-1} A) = \frac{\partial A^{t-1}}{\partial w_{kl}} A + A^{t-1} A_{kl}, \quad 10$$

そして、二次導関数は、以下によって提供される。

【数 3 9】

$$(9) \quad \frac{\partial^2 A^t}{\partial^2 w_{kl}} = \frac{\partial^2 A^{t-1}}{\partial^2 w_{kl}} A + 2 \frac{\partial A^{t-1}}{\partial w_{kl}} A_{kl} +$$

【0054】

S 170 において、重み付けランダムウォーク生成器 124 は、一般的なランダムウォーク生成器 120 からのランダムウォークモデル 121 に対して重み学習モジュール 122 からの重み付け値の組 123 を適用することによって重み付けランダムウォークモデル 125 を生成する。典型的な実施形態において、重み付け値の組 123 は、ランダムウォークモデル 121 における各リレーション  $r_{kl}$  についての重み  $w_{kl}$  を備える。それゆえに、ランダムウォークモデル 121 におけるリレーション  $r_{kl}$  を有するエンティティ間の各リンク遷移確率は、重み付けランダムウォークモデル 125 を作成するために値  $w_{kl}$  を乗じる。 20

【0055】

S 180 において、ソーシャルメディア選択モデル 126 は、インスタンス生成されたソーシャルメディアデータ 108 の範囲内で、1つ以上のソーシャルメディアインスタンスを確認するために、重み付けランダムウォークモデル 125 において1つ以上のランダムウォークを実行する。初期クエリー  $P^0$  は、ランダムウォークを開始するのに使用される。ランダムウォークは、推薦タスクが実行されることになるソーシャルメディアデータ 104 の単一のインスタンスを表す状態から始まる。典型的な実施形態において、ランダムウォークは、その後、要求される型のエンティティ（画像についてのタグ等）が見出されるまで、次の状態（すなわち、エンティティインスタンス）に進む。このプロセスは、推薦についての複数のエンティティインスタンスを選択するために複数回反復されてもよい。 30

【0056】

S 190 において、ソーシャルメディア選択モジュール 126 は、出力装置 128 を介して推薦として選択されたエンティティインスタンスを出力する。典型的な実施形態において、エンティティインスタンスのリストが出力であるが、他の実施形態において、エンティティインスタンス自身が出力であってもよい。 40

【0057】

図 4 に図示される方法は、コンピュータ上で実行されてもよいコンピュータプログラムにおいて実装されてもよい。コンピュータプログラムは、ディスクやハードディスク等の制御プログラムが記録される非一時的コンピュータ読み取り可能な記録媒体を備えてもよい。非一時的コンピュータ読み取り可能な媒体の一般的な形態は、例えば、フロッピーディスク、フレキシブルディスク、ハードディスク、磁気テープ、若しくは、任意の他の磁気記憶媒体、CD-ROM、DVD、若しくは、任意の他の光媒体、RAM、PROM、E 50

【 0 0 5 8 】

【 0 0 5 9 】

10

【 0 0 6 0 】

20

【 0 0 6 1 】

【 0 0 6 2 】

【数 4 0】

30

【数 4 1】

【数 4 2】

40

【数 4 3】

【数 4 4】

50

## 【 0 0 6 3 】

テストされた推薦タスクのうちの2つは、画像についてのタグ推薦及びユーザについてのコンタクト推薦である。前者は、ブートストラップ又はクエリーモードのいずれでも実行する。ブートストラップモードにおいて、タスクは、新たにアップロードされた画像についてのタグを予測することである。クエリーモードにおいて、画像は、いくつかのタグを有してもよく、予測タスクは、新規のタグを推薦することによってタグの組を拡大することである。双方のモードにおいて、タグの数  $|size|$  が画像によって変動するところのトップ5及び  $|size|$  タグを予測する性能は、前もって公知である（そして、テストタグ事例と等しい）。コンタクト推薦は、クエリーモードのみにおいてテストされた。

10

## 【 0 0 6 4 】

複数のラベル付きモードにおいて定義される精度、再現率及びF1評価尺度が使用された。 $Y_i$  及び  $P_i$  を、それぞれ、画像  $i$  についての真の及び予測タグベクトルを意味するものとする。そして、精度及び再現率は、それぞれ、以下として定義される。

## 【 数 4 5 】

$$P_r = \sum_i \frac{|Y_i \cap P_i|}{|P_i|}$$

## 【 数 4 6 】

$$Re = \sum_i \frac{|Y_i \cap P_i|}{|Y_i|}$$

20

そして、F1スコアは、以下として定義される。

## 【 数 4 7 】

$$2 \frac{Pr \cdot Re}{Pr + Re}$$

## 【 0 0 6 5 】

ランダムウォークの重みが学習され、重み付けなしスキーマによって与えられる基準性能結果と比較される。重み付けなしスキーマは、等しい重みを有するコア及び構成されたリレーションによって構成される。初期分布は、クエリー型の関数において変動する。平均値は、5つの独立した実行にわたって報告される。

30

## 【 0 0 6 6 】

図5は、1,000から25,000まで変動する画像セットの大きさによるブートストラップタグ推薦についての再現率及び精度値を報告している。テストは、leave-one-outスキーマにおいて実行され、予測されたタグのトップ5は、真のタグ事例と比較される。

## 【 0 0 6 7 】

図6は、クエリータグ推薦についての再現率及び精度値を報告している。ここで、画像セットの大きさは、1,000から25,000まで変動する。この評価において、50%のタグが所定の画像についてのクエリーを形成するようにランダムに選択され、残りの50%のタグがテストを行うために使用される。そして、予測されたタグのトップ5は、真のタグ事例と比較される。重み付けなし全体の精度及び再現率利得は、それぞれ、約5%及び3%である。さらに、図7は、同じ設定についてのF1スコア値を報告している。ここで、予測されたタグの数は5ではないが、テストタグ事例と等しい。

40

## 【 0 0 6 8 】

さらに、クエリーベースのシナリオは、ユーザのコンタクト推薦タスクにおいてテストされた。前のテストと同様に、ユーザのコンタクトの50%がクエリーを形成するように

50

ランダムに選択され、残りの50%のコンタクトがテストを行うために使用される。図8は、推薦されたコンタクトのトップ5についての精度及び再現率値を報告している。ここで、ユーザ数は、100から1900まで変動する。再現率におけるよりも精度において非常に高い利得を観察することができる。

【0069】

図9は、1、2、3、4、5又は10回反復後にシーケンスが打ち切られたとき、1,000枚及び20,000枚の画像の2つの場合についての精度及び再現率値について報告された性能上の式(1)における異なる打ち切りの影響を図示している。図9が示唆するように、双方の測定結果は、2又は3等の非常に小さい値についてそれらの最良値を達成している。

10

【図1】

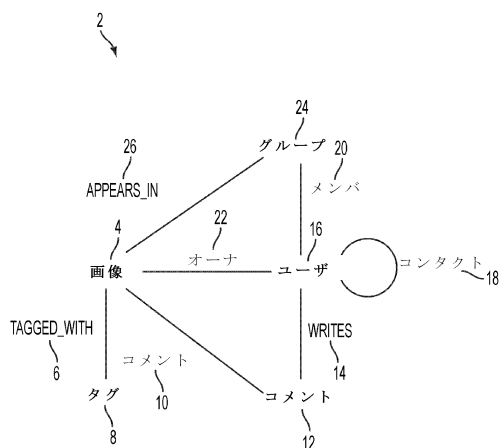


図 1

【図2】

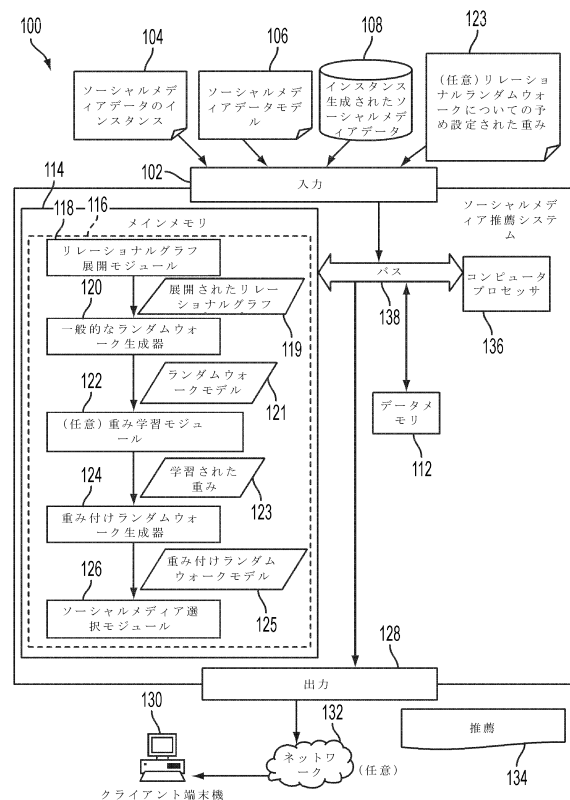


図 2

【図 3】

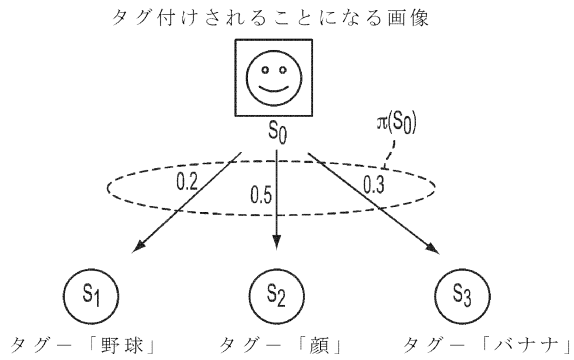


図 3

【図 4】

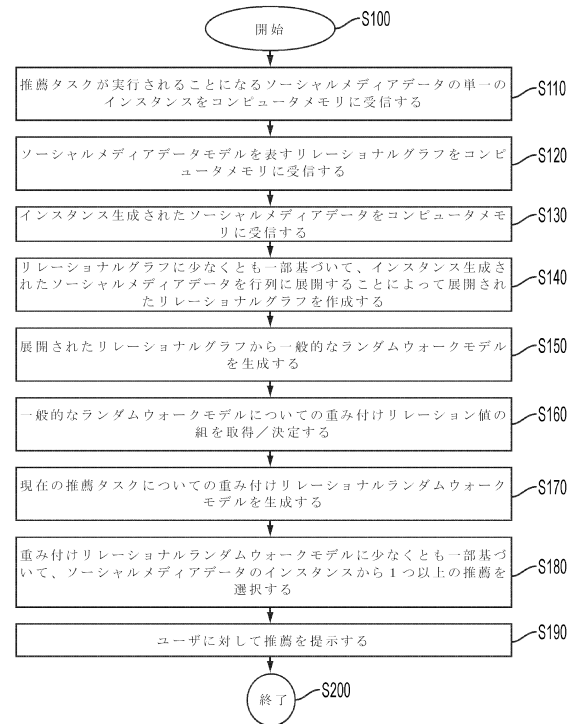


図 4

【図 5】

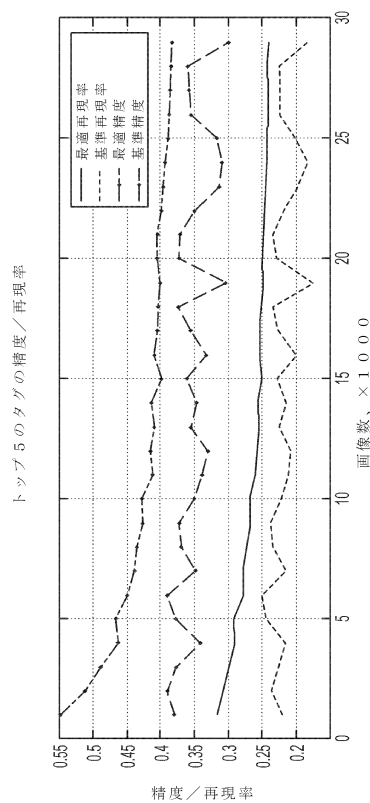


図 5

【図 6】

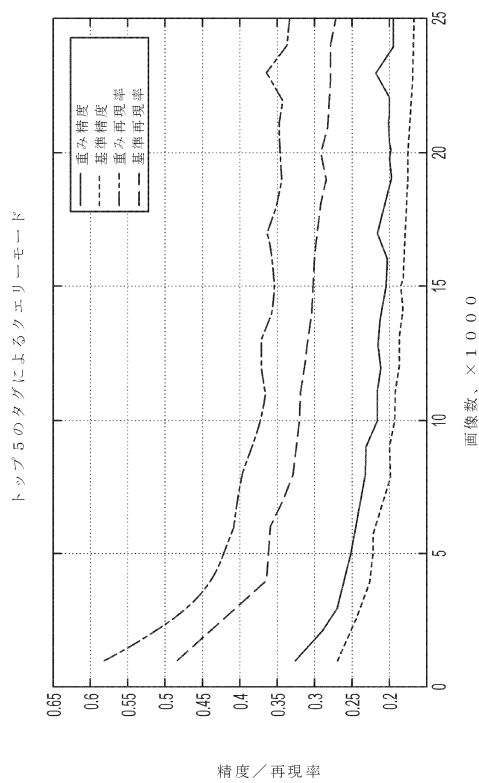
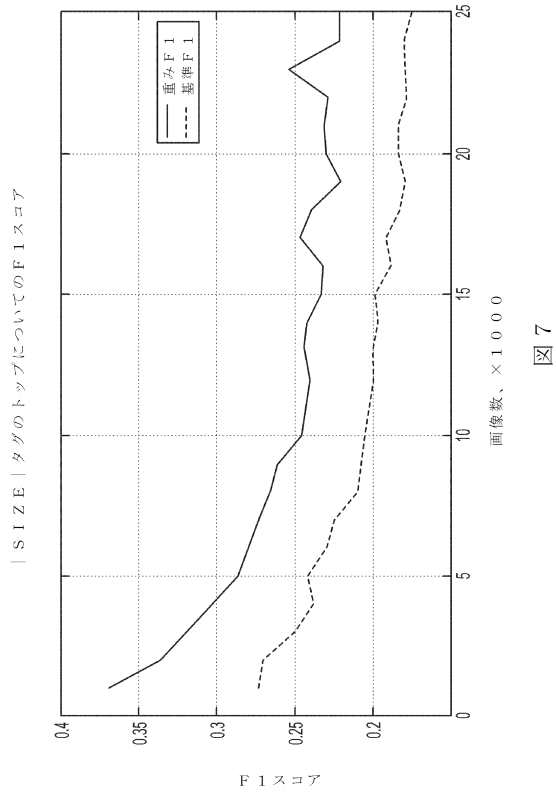
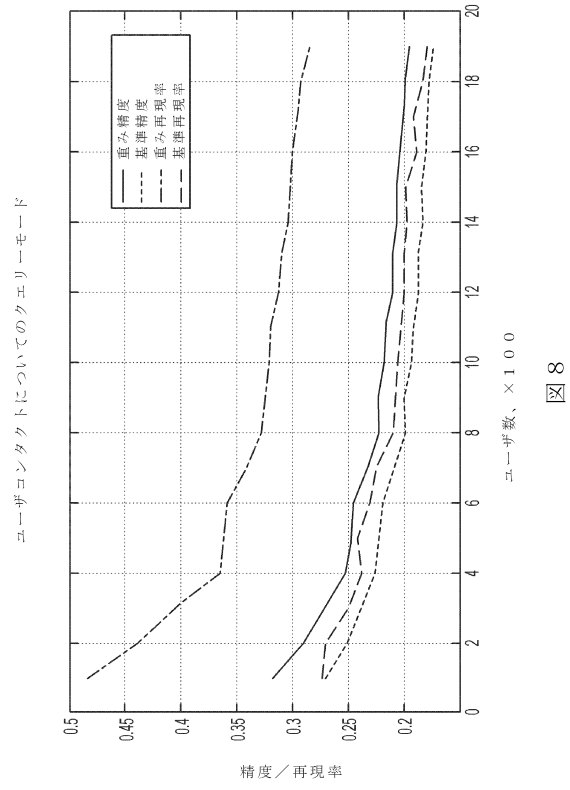


図 6

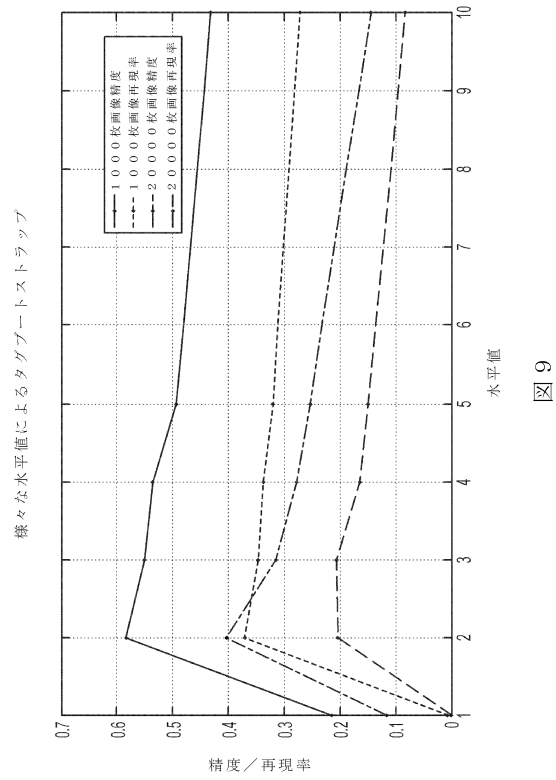
【図 7】



【図 8】



【図 9】



---

フロントページの続き

審査官 野崎 大進

(56)参考文献 上條 哲也 他, C G M画像に対する関連キーワード抽出手法に関する一検討, 電子情報通信学会  
技術研究報告, 日本, 社団法人電子情報通信学会, 2010年 7月28日, Vol.110, No.162(D  
E2010-15), pp.7-12.

Alekh Agarwal et al, Learning random walks to rank nodes in graphs, Proceedings of the  
24th international conference on Machine learning(ICML '07), 米国, ACM, Inc., 200  
7年 6月24日, pp.9-16., URL, [http://www.machinelearning.org/proceedings/icml200  
7/papers/562.pdf](http://www.machinelearning.org/proceedings/icml2007/papers/562.pdf)

(58)調査した分野(Int.Cl., DB名)

G 0 6 F 1 7 / 3 0

J S T P l u s ( J D r e a m I I I )