

リコメンテーションアルゴリズムの研究

研究対象

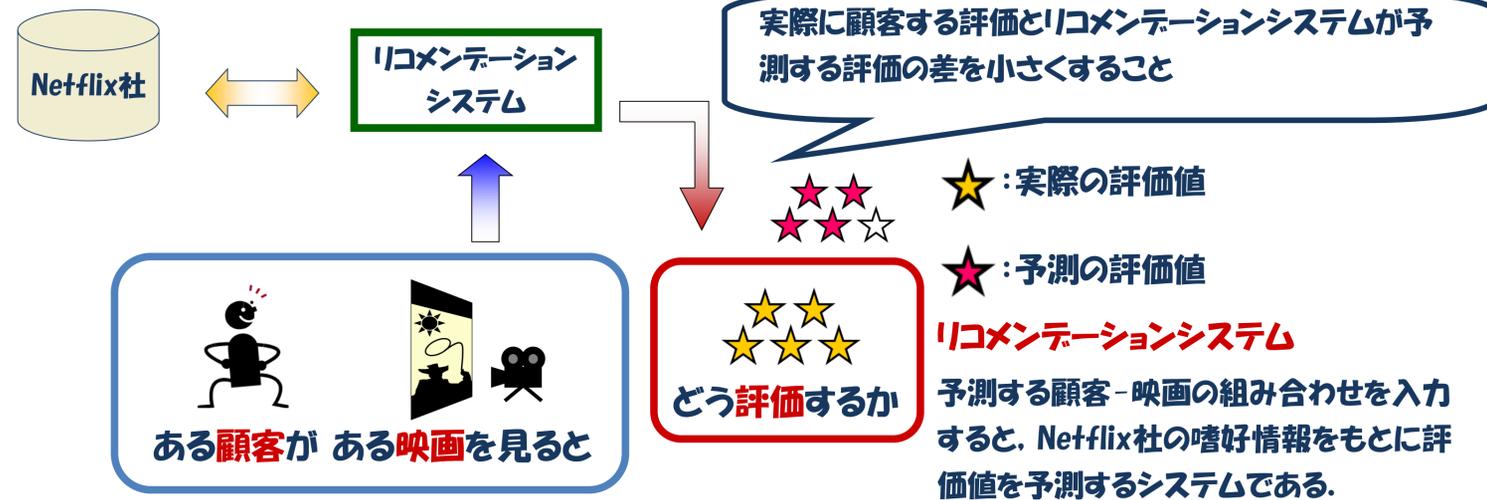
オンラインDVDレンタルサービス会社のNetflix社は、膨大な情報の中からユーザの嗜好に合った情報を見つけ出し、その情報をユーザに能動的に提供する推薦技術の研究を行っている。また、自社の推薦システムの予測精度を高めるために、自社の顧客の嗜好データを公開し、多くの研究者と協調しながら研究を進めている。提供されたデータを研究対象とする。



© 1997-2006 Netflix, Inc. All rights reserved. <http://www.netflixprize.com/>

研究目的

Netflix社に蓄積された顧客の嗜好情報をもとに、ある顧客がある映画を見るとどう評価するのかを予測する。この予測の精度を高めることが研究目的である。



予測手法

データ

Netflixデータは478,615人の顧客の17,770本の映画に対する5段階評価データである。評価されている項目は約1億件である。このデータを分析し、特徴を作成する。

マトリックス分解を用いた推薦アルゴリズム

映画-顧客の評価を説明する潜在的な特徴を各の映画と各の顧客に置くことで予測を可能とする。潜在的な特徴は映画のジャンルかもしれませんが、特徴がジャンルとするなら、映画に置いた特徴はその映画のジャンルを表すことになる。そして、顧客に置いた特徴はその顧客のジャンルへの好みを表すことになる。このような潜在的な特徴を設定することはマトリックス分解技術を使うことで可能となる。マトリックス分解技術の1つである特異値分解を用いて特徴を抽出する。

$$\begin{bmatrix} \text{Original}_{I \times J} \end{bmatrix} \approx \begin{bmatrix} \text{Customer}_{I \times K} \end{bmatrix} \begin{bmatrix} \text{Movie}_{K \times J} \end{bmatrix} = \begin{bmatrix} \text{Predict}_{I \times J} \end{bmatrix}$$

K : Number Of Latent Factor

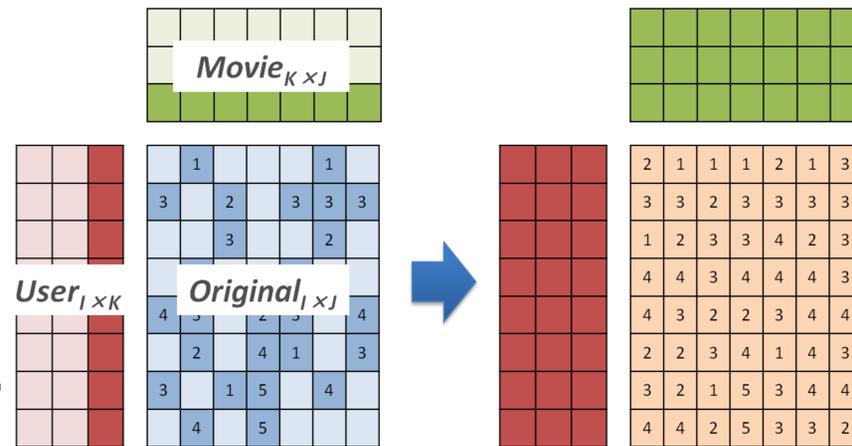
潜在的な特徴の推定方法は、全ての既知評価に対して右に示す1~3の手順を行います。そして、全ての既知評価値について行えた場合に、操作手順4により二乗誤差が最小になっているかを判断する。最小になっていなければ同様の処理を行う。なっていれば次の特徴量に対しても同様の処理を行う。

①予測 $\hat{x}_{ij} = \sum_{k=1}^K c_{ik} m_{kj}$

②既知と予測の誤差 $e_{ij} = x_{ij} - \hat{x}_{ij}$

③ c_{ik} と m_{kj} を更新 $c_{ik} \leftarrow c_{ik} + \eta(e_{ij} m_{kj})$
 $m_{kj} \leftarrow m_{kj} + \eta(e_{ij} c_{ik})$

④条件の判定 $\arg \min \sum_{i,j} (x_{ij} - \sum_k c_{ik} m_{kj})^2$



推薦アルゴリズムの予測精度の評価

推薦アルゴリズムの予測精度の評価は予測の精度をあらわす指標RMSEを用いて行う。

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (X_n - \hat{X}_n)^2}$$

X : 既知評価
 \hat{X} : 予測評価
 N : サンプル数

特異値分解にリッジ回帰を適用

目的関数に正則化項を加えることで、予測精度をさらに向上できる。

$$E = \frac{1}{2} \sum_{i,j} (x_{ij} - \sum_k c_{ik} m_{kj})^2 + \frac{1}{2} \lambda (\sum_k c_{ik}^2 + \sum_k m_{kj}^2)$$

正則化項

SVDとリッジ回帰を適用させた場合の特徴量数とRMSEの関係図:

