

# Deep Learning を用いた アプリストアランキングの予測に関する研究

菊池 祥太郎<sup>†1</sup> 小池 優希<sup>†1</sup> 浦田 真由<sup>†2</sup> 遠藤 守<sup>†1</sup>  
安田 孝美<sup>†1</sup> 水野 政司<sup>†3</sup>

ソーシャルメディアの特徴に、リツイートやシェアなどの情報を評価し広範囲なネットワークに情報を拡散する機能がある。近年は、ソーシャルメディア上の「ロコミ」の拡散効果や活用の重要性について注目が集まっている。また、Deep Learning(深層学習)は機械学習アルゴリズムの1つであり、画像認識や音声認識の分野で大きな活躍を見せている。本研究では、ソーシャルメディアの「Twitter」におけるロコミの情報伝播効果が、モバイルアプリストアの「iTunes App Store ランキング」に与える影響の相関性・関連性について着目をした。さらに Deep Learning を用いて、Twitter におけるつぶやき数の変動や影響を与えやすい時間帯といった原因系データから、App Store ランキングの順位変動の予測可能性について分析・検証を行った。

## Study on Ranking Prediction in an Application Store Using the Deep Learning

SHOTARO KIKUCHI<sup>†1</sup> YUUKI KOIKE<sup>†1</sup> MAYU URATA<sup>†2</sup>  
MAMORU ENDO<sup>†1</sup> TAKAMI YASUDA<sup>†1</sup> MASASHI MIZUNO<sup>†3</sup>

Feature of social media has a function to spread the information to the wide range of networks by Retweet and share. Recently, a word of mouth in social media is the spreading effect and importance of utilization. In addition, Deep Learning is used mainly in the field of speech and image recognition. In this study, we focused on the relation and correlation between the number of tweets on Twitter and ranking of application store on iTunes App Store. We was analysis and verification of the possibility of predicting fluctuation the App Store from time zone and fluctuation number of tweets by using the Deep Learning.

### 1. はじめに

近年のインターネットにおける情報受発信ツールとして、ソーシャルメディアが果たす役割は非常に大きい。従来のインターネットにおける情報交換は、特定の話題に沿ったやりとりとなっていた。しかし、ソーシャルメディアの登場によって、人と人の繋がりを中心とした情報のやりとりを行う形態へと変化をしている。また、テレビを始めとしたマスメディアも、番組の情報発信や視聴者との双方向的な繋がりのために、ソーシャルメディアを積極的に利用し始めている。ソーシャルメディアは、手軽な情報発信や容易な情報共有性があり、情報が瞬時に広範囲に伝播する特徴がある。こうした特性に関して、マーケティングにおけるソーシャルメディアの活用に注目が集まっている。電通の調査[1]によると、ソーシャルメディアにおけるロコミが約半数の人にとって、商品の購入やサービスの利用意欲に影響を与えている。

また、ソーシャルメディア上のロコミなどはビッグデータとして扱われ、その活用方法の議論が活発になっている。

近年では、データ処理能力の向上やデータ解析技術の向上によって、今まで難しいとされた分野や新たな価値の創出に繋がっている。特に、機械学習における「ニューラルネットワーク」の分野では、Deep Learning と呼ばれる革新的な手法が登場した。現在は画像認識や音声認識などが中心に研究が報告されているが、今後ビッグデータ全般の解析に応用されていくと期待されている。

本研究では、ソーシャルメディアの「Twitter」におけるロコミの情報伝播効果が、モバイルアプリストアの「iTunes App Store」におけるランキングに与える影響について注目をした。本文では、この関連性をベースに、Twitter のツイート数やランキング推移といった原因系データから Deep Learning を用いて、次の時間帯におけるランキング予測の可能性について検討する。

### 2. 関連研究

最近ではソーシャルメディアの中でも Twitter に注目した、マーケティングへの活用に関する研究が多く行われている。小川ら[2]はツイートに含まれるユーザの行動に着目し、広報効果における Twitter 活用の可能性について分析を行っている。その中で、商品の購入に影響したとみられるツイートの多くに URL 情報が含まれていたとしている。また奥田ら[3]は、ツイート数の推移と商品の売れ行きとの間

<sup>†1</sup> 名古屋大学大学院 情報科学研究科  
Graduate School of Information Science, Nagoya University

<sup>†2</sup> 名古屋大学大学院 国際開発研究科  
Graduate School of International Development, Nagoya University

<sup>†3</sup> クエリーアイ株式会社  
QueryEye Inc.

の相関性に関する研究を行っている。そこでは、ツイート数ランキングの上昇が iTunes App Store ランキングに影響を与えていることを初めて明らかにした。また、ツイートの影響受けアプリストアランキングが急上昇する割合が約50%に上ることを示した。

Twitter のツイート内容や特徴を利用した予測に関する研究も多く行われており、実際のビジネス分野における応用も始まっている。Bollen ら[4]は、ツイートの内容が株式市場に与える影響がネガティブかポジティブかを判断する感情分析を利用し、日ごとの NY ダウ平均株価の上下変動が 87.6%の精度で予測可能であることを示した。NTT データ[5]は、ツイートの内容から株式市場のムードを捉える指標を開発した。さらにこの指標を用いて、ネット証券会社がリアルタイム株価予測の提供を始めた。那須野ら[6]は、国政選挙候補者の Twitter における情報拡散に着目し、当選者予測を行った。選挙期間中の候補者のアカウント状態(ツイート数やフォロワー数)といった指標よりも、リツイートなどの情報拡散そのものが選挙当落に影響を与えていることを示した。

一方、Deep Learning 技術の活用先として、マーケティングやビジネスインテリジェンスの分野が注目されている。Cooper ら[7]は、ソーシャルメディアにおけるビッグデータの未来について、Deep Learning がマーケティングにおける予測のあり方を変えるであろうと主張している。

### 3. Deep Learning

Deep Learning は従来の機械学習より深い階層構造をもつ機械学習手法の1つである。画像認識、音声認識、自然言語などの研究分野で大きな活躍を見せている。Google は YouTube 上の動画から猫の概念をコンピュータに学習させることに成功した[8]。また、ビジネス分野でも注目を浴びており、Apple 社の Siri[9]や Google の画像認識技術[10]に Deep Learning が適用されている。

本研究では、Deep Learning の手法の1つである Stacked Denoising Auto-Encoders (SdA) を用いた。以下で SdA と基礎構造の Denoising Auto-Encoders (dA) [11]について述べる。

#### 3.1 従来の機械学習と Deep Learning の違い

従来の機械学習、特にニューラルネットワークでは、生データから人間の手によって特徴抽出を行い、学習器に入力していた。そのため、入力する特徴やその抽出手法によって、その後の学習結果や精度が大きく変わっていた。また、生データからどのような特徴を抽出し、入力データとして扱うかはアルゴリズム設計者の勘と経験に依存していた。

これに対し Deep Learning は、人間が行っていた特徴抽出を学習プロセスの1つとして行う手法である。特徴抽出の

プロセスは教師あり学習プロセスの入力データとして扱うため、ユーザは生データを用いて機械学習を行うことが出来る。しかし、隠れ層の深さや反復回数といったパラメータの最適化が必要であり、最適化方法が確立されていないため今後の課題となっている。

#### 3.2 Denoising Auto-Encoders

dA は、SdA における特徴抽出の手法であり、教師なし学習を行う。図 1 の入力の一部に対して、ランダムにノイズを加え、元の入力に戻すように再構築を行うことで特徴抽出を行う。

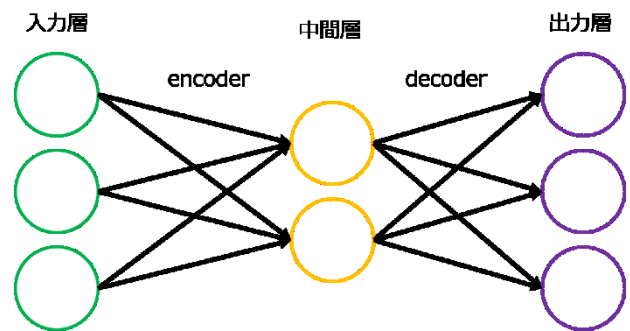


図 1 Denoising Auto-Encoders の概念図

図 1 における中間層への値と出力層への値は (1) 及び (2) よって計算される。s(·)はシグモイド関数である。また、 $w_x$  と  $b$  は入力層から中間層への重みとバイアスで、 $w_x^T$  と  $b^T$  は中間層から出力層への重みとバイアスである。

$$y = s(w_x + b) \quad (1)$$

$$y = s(w_x^T + b^T) \quad (2)$$

dA の最適化には確率的勾配降下法が用いられ、誤差関数は、交差エントロピー誤差関数 (3) で与えられる。 $\theta = (W, b, b^T)$  に対し、 $L_H$  の勾配を求める。

$$L_H(x, z) = -\sum_{k=1}^d x_k \log z_k + (1 - x_k) \log(1 - z_k) \quad (3)$$

#### 3.3 Stacked Denoising Auto-Encoders

SdA は、dA を多層に積み重ねた学習器である (図 2)。多層の Auto-Encoder に比べてより抽象的な表現を持つ特徴抽出が可能であると考えられている。学習プロセスは Pre-training と呼ばれる教師なし学習と Fine-tuning と呼ばれる教師あり学習に分けて行われる。入力層に近い層から Pre-training を行い、出力された重みを次の層の入力として

さらに学習を行っていく。上層までネットワークを構築した後、Fine-tuning に移る。Fine-tuning では Multilayer Perceptron によってネットワーク全体の重みの微調整を教師あり学習で行う。

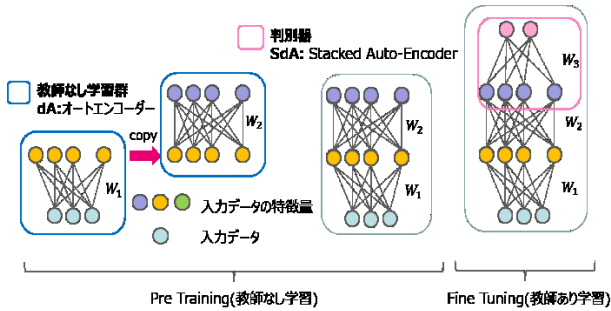


図 2 Stacked Denoising Auto-Encoders の概念図[a]

#### 4. データセット

本研究では、Twitter と iTunes App Store からそれぞれ公式の API を使用し、2 種類のデータセットを作成した。また、これらのデータセットから Deep Learning に用いる入力データセットを作成した

##### 4.1 Twitter のデータセット

Twitter のデータセットに関する情報を表 1 に示す。使用した API は全量データの 1% 程度のツイート情報である。収集するデータは、上記のツイート情報の中から特定の URL を含む、以下の条件のいずれかを満たすものである。

- ツイート本文に、固有のアプリケーション ID を含む iTunes App Store へのリンクが存在する
- ツイート本文に、固有のアプリケーション ID を含む iTunes App Store へのリンクを含むブログやネット記事の URL が存在する

表 1 Twitter のデータセット

収集方法	Twitter Stream API[12]
対象国	日本
期間	2011/1/1 00:00~2013/12/31 23:00 (1 時間毎)
集計対象	特定の URL を含むツイート

##### 4.2 iTunes App Store のデータセット

iTunes App Store のデータセットに関する情報を表 2 に示す。ランキングカテゴリはジャンル別に 23 種類と総合ランキングの計 24 種類である。またジャンルごとに料金体系別に 3 種類、iPhone や iPad のデバイス別に 2 種類がある。したがって、iTunes App Store には、計 144 種類のランキングカテゴリが存在することになる。

本研究では、iPhone と iPad の両機種のアプリケーションを対象とし、さらに有料総合・無料総合・トップセールスの 3 つのカテゴリを調査対象とした。

表 2 iTunes App Store のデータセット

収集方法	iTunes Search API[13]
期間	2011/1/1 00:00~2013/12/31 23:00 (1 時間毎)
集計対象	各ランキングカテゴリにおける 1 位~300 位のアプリケーション
調査対象	有料総合・無料総合・トップセールスの 3 種類のカテゴリ

#### 5. 相関関係と定義

収集したデータに対して処理を行うために、必要な各定義について述べる。

##### 5.1 Twitter のツイート数と iTunes App Store ランキングとの相関関係

あるアプリケーション ID を含む URL が含まれたツイートの数が上昇すると、その URL が参照される確率が増加する。さらに URL が参照される確率が高まると、アプリケーションを参照する機会が増え、同時にそのアプリケーションがダウンロードされる機会も増加する。結果として、iTunes App Store ランキングが上昇する。

##### 5.2 欠損値

収集したデータセットには、iTunes App Store のシステムダウンなどにより欠損値が生じている。時系列的に不連続になっている欠損値は、直前の時間帯の正常な値を検出しその値を欠損地点の値として補間を行った。(最近傍補間)。この処理をすべてのアプリケーション ID に対して行った。

##### 5.3 ランキング変動点

各ランキングカテゴリにおけるランキング変動点の区分を表 3 に示す。各区分は、ランキング変動点から-6 時間以内にツイート数が 10 個以上観測されたもののみを扱っている。

表 3 ランキング変動点の分類

変動点の区分	順位 (1 時間前と比較)
変動なし	0 位もしくは 1 位以上の下降
上昇	1 位以上 10 位未満の上昇
急上昇	10 位以上の上昇
急上昇①	10 位以上 30 位未満の上昇
急上昇②	30 位以上 100 位未満の上昇
急上昇③	100 位以上の上昇

a )[http://www.vision.is.tohoku.ac.jp/files/9313/6601/7876/CVIM\\_tutorial\\_deep\\_learning.pdf](http://www.vision.is.tohoku.ac.jp/files/9313/6601/7876/CVIM_tutorial_deep_learning.pdf)

### 5.4 ツイート数のランキング化

ツイート数は、1 時間毎の積算値であるため変動が大き  
 く、ツイート数のデータをそのまま入力要素として扱うこ  
 とは難しい。そこで、iTunes App Store におけるアプリケー  
 ションの販売実績に基づくランキングアルゴリズム[14]が  
 から、ツイートがランキングへ影響を与えやすい時間差を  
 考慮した (4) を定義した。この式は、ランキングへ影響を  
 与えるツイート数の時間差が小さいほどスコアを大きくす  
 ることができる。本研究では、(4) を用いてランキング変  
 動点を基準としたツイートのスコア付けを行い、ツイート  
 数の 1 時間毎のランキング化を行った。

$$\begin{aligned}
 Tw_i = & \sum_{j=0}^5 n_{i-j} \times 8 + \sum_{j=6}^{11} n_{i-j} \times 5 \\
 & + \sum_{j=12}^{17} n_{i-j} \times 5 + \sum_{j=18}^{23} n_{i-j} \times 2
 \end{aligned}
 \tag{4}$$

## 6. 予測実験

本章では、各データセットから得られた統計データの結  
 果と、それらを用いたアプリストアランキングの予測実験  
 について述べる。入力データセットは、トップセールス、  
 無料総合、有料総合とそれぞれのカテゴリを合わせた区別  
 無しの 4 種類について実験を行った。実験 1 から実験 3 で  
 は、ランキング予測の可能性や課題について探るため、ま  
 た実験 4 では、急上昇区分内における予測の可能性や課題  
 を探るために行った。さらに実験 5 では、実験 1 から実験  
 3 で明らかになった課題を解決し、予測精度の向上につい  
 て検証を行った。

また、5 章で定義した変動点における急上昇点は以下の  
 通りである。

- 有料総合・・・10,182
- 無料総合・・・13,022
- トップセールス・・・8,784

### 6.1 実験環境

Deep Learning は、入力する要素数やパラメータによるが、  
 一般に計算時間が膨大になってしまう。そこで通常の CPU  
 演算に加え、CUDA を利用した GPGPU を用いて予測実験  
 を行った。使用した CPU は Intel Core i5-4690, GPU は  
 NVIDIA GTX750, メモリは DDR3-2400 16GB, OS は  
 Windows 7 である。

### 6.2 入力データセット

入力データセットは表 4 及び表 5 の 2 種類を作成した。  
 ランキング推移は T 時間前での 1 位から 301 位までのラン  
 キングであり、ランキング差は T 時間前から T-1 時間前の  
 ランキング推移の差分である。ランキング推移とランキン  
 グ差の入力値は、実際の数値を  $0 \leq x \leq 1$  の間で表現した値

である。また、入力データセット B 中の変動点における時  
 間帯は、ツイートがランキングに反映された時間である。  
 時間帯は 1 時間毎の差があまり無いことから、24 時間を 6  
 つの時間帯に分類した。なお、基準となる時間はいずれも  
 ランキング変動点である。

実験に使用したデータの期間は、Pre-training が 2011/1/1  
 から 2012/12/31 までの 2 年間、Fine-tuning が 2013/1/1 から  
 2013/6/30 までの半年間、Test が 2013/7/1 から 2013/12/31 ま  
 での半年間である。

表 4 入力データセット A

iTunes App Store	Twitter
1 時間前～12 時間前までの ランキング推移 (12 時間分)	12 時間前までのランキ ング推移 (13 時間分)

表 5 入力データセット B

iTunes App Store	Twitter
1 時間前～12 時間前までの ランキング推移 (12 時間分)	12 時間前までのランキ ング推移 (13 時間分)
1 時間前～12 時間前までの ランキング差 (12 時間分)	変動点における時間帯 (6 種類)

### 6.3 実験 1 (ランキング上昇の検出)

入力データセット A を用いて、変動なしと上昇+急上昇  
 の場合、つまりランキングが上昇するかしないかの 2 択の  
 場合について実験を行った。




図 3 実験 1 の結果

図 3 から、それぞれのカテゴリに大きな差は見られなかつ  
 た。また、予測精度が約 50%であった。入力データセット  
 A からでは、ランキングが上昇するかしないかの予測は難  
 しい結果となった。

### 6.4 実験 2 (上昇を除いた急上昇の検知)

実験 1 の結果から上昇の区分の判別が精度低下につながっていると考え、実験 2 において上昇を除いた急上昇の検知 (変動なしと急上昇の 2 つの場合) について検証を行った。実験 1 と同様に入力データセット A を用いている。




図 4 上昇を除いた急上昇検知の結果

実験 1 と比べて大幅な精度の向上が見られ、概ね 70%程度の予測精度が得られた。この結果から、上昇以上の検知において上昇の区分が予測精度の低下を招いていることが明らかになった。

### 6.5 実験 3 (入力データセット A を用いた急上昇検出)

入力データセット A を用いて、変動なし+上昇と急上昇の場合、つまり急上昇の検知について実験を行った。




図 5 入力データセット A における急上昇検知

実験 1 と同様に、予測精度が約 50%となり、カテゴリ別の差は見られなかった。実験 2 及び実験 3 から、上昇区分について急上昇の検知においても精度低下につながっていることが明らかになった。したがって、入力データセット A が持つツイート数とランキング推移といったデータからでは、ランキングの急上昇検知が難しいことがわかった。

### 6.6 実験 4 (急上昇内の予測)

入力データセット A を用いて、急上昇内における予測が可能か実験を行った。




図 6 急上昇内の予測

カテゴリ別にばらつきがあるものの、約 55%から約 72%の予測精度が見られた。トップセールスと無料総合カテゴリは下位でもランキングの変動が多く、有料総合カテゴリは上位でのランキング変動が多いため、このような結果になったと考えられる。

### 6.7 実験 5 (入力データセット B を用いた急上昇検出)

実験 1 から実験 3 で課題となった上昇区分と他の区分の判別可能にするため、入力データセット A に対して、ランキング差や時間帯を含めた入力データセット B を用いて、実験 3 と同様に急上昇検知の実験を行った。




図 7 入力データセット B における急上昇検知

実験の結果、カテゴリ別に精度の開きがあるものの、約 60%以上の予測精度が確認できた。特に無料総合カテゴリでは、約 77%の高い予測精度を得ることが出来た。カテゴリ別に差があったのは、それぞれのカテゴリが持つ特徴によるものと考えられる。無料総合カテゴリは、ランキングの変動が起きる 1 時間前の分布のバランスがよく、下位だけでなく中位や上位でも急上昇が起こる。一方、トップセールスと有料総合カテゴリは、ランキング下位での急上昇が起こりやすいという特徴がある。また、時間帯の特徴を予測の新たな要素として追加した結果、課題であった上昇区分の判別が可能となり、大幅に予測精度が向上した。つまり、カテゴリの特徴やランキングに反映される時間帯の特徴について、実験 5 の結果から先行研究[3]の結果を裏付けることになった。

## 7. 考察と今後の課題

実験1から実験3までの結果から、単純なツイート数の推移とランキングの推移といったデータからでは、ランキングの予測が難しいことが明らかになった。実験5では入力データセットAの要素が少ないと考え、ランキングの差やツイートの影響がランキングに反映された時間帯といった要素の追加（入力データセットBの作成）を行い、カテゴリ別に約60%から約77%まで精度が向上し、カテゴリの区別が無い場合は、約68%の予測精度となった。また、奥田らの研究で示されていた統計的事実の裏付けも得ることができた。さらに、実験4から急上昇内における予測も概ね60%程度の予測精度が得られた。

今回行った5つの実験から、ツイート数の推移やランキングに反映された時間帯といった原因系データを用いることで、約68%の精度で1時間後のiTunes App Storeランキングの予測が可能であることが明らかになった。また、単純なランキング急上昇の検知にとどまらずに、急上昇の度合いについても予測の可能性が見えてくる結果となった。

今後の課題として、3点が挙げられる。1点目は、Deep Learningにおけるパラメータの調整が十分に最適化されていない点である。本研究では、いくつかのパターンのパラメータを用意して予測実験を行い、最適と思われるパラメータを使用した。要素の種類や数によって、最適なパラメータが変化するため、今回使用したパラメータが最適とは限らない。2点目は、特徴抽出手法である。今回はSdAを使用した。Deep Learningの特徴抽出にはDeep Belief Network (DBN)と呼ばれる代表的な手法がある。SdAとDBNの予測精度の差について、今後検討する必要がある。3点目は新たな要素の追加である。細江らの研究[15]では、ランキングに影響を与えるツイートを発信するユーザが特定されている。また本研究では、ツイートの内容やアプリストアのレビュー情報に一切触れず、ツイート数などの数値データのみから予測を試みた。ゲームや仕事効率化など、更に細かいジャンル別に予測を行う際は、ユーザ情報の追加や急上昇の誘因となるキーワードの追加が鍵となると考えられる。今回の実験では、1時間後のランキングが急上昇するかしないかの予測に試みてきたが、上述した課題の解決によって、将来1日後や1週間後といったある意味天気予報に近い予測が可能になると考える。

## 8. まとめ

本研究では、Twitterにおけるツイート数などの原因系データから、次の時間帯におけるiTunes App Storeランキングの急上昇予測についてDeep Learningを用いて実験と考察を行った。その結果、ツイート数の推移やランキングに反映された時間帯などの入力要素を用いることで、iTunes App Storeランキングの予測が約68%の精度で可能である

ことが明らかになった。

今後は、パラメータの最適化やユーザ情報などの新たな要素の追加などを通して、予測精度の向上を目指して行きたい。

**謝辞** 本研究の一部は、JSPS 科研費(課題番号:2528031)の助成を受けたものです。

## 参考文献

- 1) 電通ソーシャルメディアラボ, “消費者行動を変化させるソーシャルメディアの影響”  
<http://www.nikkeibp.co.jp/article/column/20120405/304670/>
- 2) 小川晋一, 小川剛司, 吉野ヒロ子. “広報効果測定におけるTwitter活用の可能性について.”, 日本広報学会論文誌, Vol.17, pp.101-108, 2013.
- 3) 奥田輔, 安田孝美, 水野政司. “ソーシャルメディアにおける情報の伝播がもたらす商品の売れ行きに対する影響について.”, 電子情報通信学会技術研究報告, SS, Vol.111, No.268, pp.1-6, 2011.
- 4) Bollen, Johan, Huina Mao, and Xiaojun Zeng. “Finding trendsetters in information networks.”, Journal of Computational Science, Vol.2, No.1, pp.1-8, 2011.
- 5) Twitter データを用いた金融マーケット向け「Twitterセンチメント指標」を開発  
[http://www.nttdata.com/jp/ja/news/services\\_info/2014/2014030701.html](http://www.nttdata.com/jp/ja/news/services_info/2014/2014030701.html)
- 6) 那須野薫, 松尾豊. “Twitterにおける候補者の情報拡散に着目した国政選挙当選者予測.”, 人工知能学会全国大会論文誌, Vol.28, pp1-4, 2014.
- 7) Cooper Smith. “Reinventing Social Media: Deep Learning, Predictive Marketing, And Image Recognition Will Change Everything.”  
<http://www.businessinsider.com/social-medias-big-data-future--from-deep-learning-to-predictive-marketing-2014-2>
- 8) Using large-scale brain simulations for machine learning and A.I.  
<http://googleblog.blogspot.jp/2012/06/using-large-scale-brain-simulations-for.html>
- 9) From sci-fi to real life — the advances of artificial intelligence.  
<http://www.nyunews.com/2013/01/11/ciconet-3/>
- 10) Improving Photo Search: A Step Across the Semantic Gap.  
<http://googleresearch.blogspot.jp/2013/06/improving-photo-search-step-across.html>
- 11) Pascal Vincent, Hugo Larochelle, Yoshua Bengio, and pierre-Antoine Manzagol. “Extracting and Composing Robust Features with Denoising Autoencoders.” Proceedings of the 25<sup>th</sup> International Conference on Machine learning, pp.1096-1103, 2008.  
<https://dev.twitter.com/streaming/overview>
- 12) Twitter Streaming API Overview.  
<https://dev.twitter.com/streaming/overview>.
- 13) Apple iTunes Search API Overview.  
<https://www.apple.com/itunes/affiliates/resources/documentation/itunes-store-web-service-search-api.html>
- 14) How to market your app,  
<http://www.slideshare.net/misteroo/how-to-market-your-app>
- 15) 細江成洋, 菊池祥太郎, 安田孝美, 水野政司. “ソーシャルメディアにおける情報伝播ネットワークの可視化とアプリストアに与える影響についての統計的解析.”, 情報処理学会, 情報システムと社会環境研究報告, Vol.126, No.9, pp.1-6, 2013.