

状況を考慮した情報推薦システムの提案

鈴木篤[†] 小島直己[†] 東佑美[†] 三浦直子[†] 高木友博[†]

[†] 明治大学 理工学部 情報科学科

〒214-8571 神奈川県川崎市多摩区東三田 1-1-1

E-mail: {s-atsushi, n-kojima, yumi-hgs, n_miura, takagi}@cs.meiji.ac.jp

概要 従来の推薦システムの手法では、現在地、時間、天気などのユーザーを取り巻く状況の考慮はされずに推薦が行われているため、状況次第では適切でない推薦が行われている可能性がある。本稿では、その問題を解決するためにユーザーの購買時の状況を考慮した推薦システムを提案する。提案手法では、購買アイテムに付加された日付や天気などの情報を用いることにより、状況に依存したユーザーの嗜好情報を獲得し、現在の状況に最適なアイテムを推薦する。スーパーマーケットにおける購買履歴を用いた比較実験の結果、従来手法に比べ、提案手法の方がより直近の購買に対する精度が高いことを確認した。

キーワード 推薦システム, 協調フィルタリング, Context

1 はじめに

近年、パーソナルコンピュータやスマートフォンの急速な普及にともない人々の周りには様々な情報があふれている。その膨大な情報の中から、ユーザーが適切な情報を取捨選択することは大変困難であるため、各ユーザーに適した形で情報を提供する方法の一つとして「情報推薦システム」が注目されている。

我々が何か情報を必要とした際、周りには必ず人々を取り巻く状況(以下 Context)がある。本稿においては Context とは季節/時間/同伴者/天気などの情報を取り扱う。その Context によって人々の嗜好はリアルタイムに変化する。例えば、平日の朝食の時間帯に居酒屋が推薦されることや、真冬の寒い時期にかき氷が推薦されることは一般的には、よい推薦とは言えない。

そこで、本研究では協調フィルタリングの構造を利用し、ユーザーの過去の購買アイテムに付加された様々な Context を考慮することにより、ターゲットユーザーが現在置かれている状況に対して適した推薦を行う手法を提案する。

本稿では、まず 2 章で情報推薦とユーザーの Context を利用した関連研究について述べる。3 章では提案手法の構造と計算方法の説明、4 章では評価実験の方法と結果、5 章では実験結果に基づく考察を行い、6 章でまとめを行う。

2 関連研究

2.1 情報推薦手法

情報推薦の手法として、大きく以下の 2 種類がある。

- a) 内容ベースフィルタリング
(Content-Based Filtering)
- b) 協調フィルタリング
(Collaborative Filtering)

a)の手法は、コンテンツに含まれている情報とユーザープロフィールにある嗜好情報を比較し情報を選択する手法である。

この手法は、ユーザープロフィールが更新されるごとに推薦されるアイテムが各ユーザーの嗜好に収束していくため、セレンディピティを考慮した推薦ができないという問題がある。

一方、b)の手法は、ユーザー同士の嗜好の類似度をもとにターゲットに対して類似ユーザーが高評価した情報を推薦する手法である。

こちらの手法は、前者とは反対に cold-start 問題が発生しやすいという弱点があるが、代わりにユーザー間の類似度を用いて推薦しているためターゲットユーザーのプロフィールとは異なるアイテムを推薦することが可能であるので、セレンディピティのある推薦がされやすいという特徴がある。協調フィルタリングを用いた代表例としては、Amazon [1], MovieLens[2]などがある。

協調フィルタリングは、一般的に内容ベースフィルタリングに比べ、他者の評価を考慮した上で推薦

を行っているため、推薦精度が高いとされている。

2.2 ユーザーコンテキストを用いた推薦

奥ら [3]は、協調フィルタリングの考えに基づき Context 付きコンテンツの満足度に対するユーザーの嗜好を学習する方法として Support Vector Machine(SVM)を用いた C-SVM-CF を提案している。

SVM を用いることで、Context の特徴を含んだ多次元空間内の正例/負例を超平面で分離し学習することができ、ユーザーごとにモデル化することを可能にしている。

一方で、関ら[4]はユーザーごとにアイテム利用時の Context を蓄積/学習し、最適なアイテムを推薦するのではなく、アイテムごとに最適な Context を学習し、ユーザーの Context 取得時に k 近傍法を用いてその Context に最適なアイテムの推薦を行う手法を提案している。

従来のシステムでは、新規ユーザーは購買履歴を持っていないため cold-start 問題が発生していたが、この手法ではアイテム側でユーザー利用時の Context が考慮されているため、新規ユーザーの Context を取得する方法でこの問題を解決している。

篠田ら[5]は、ユーザーの行動の位置情報を事前登録なしに GPS などの位置探知システムから取得し、ユーザーの「滞在スポット」や場所ごとの「滞在時間」を考慮に入れることで行動ナビゲーションをする方法を提案している。その際、推薦方法に協調フィルタリングを採用し、他のユーザーとの行動パターンを比較して類似ユーザーの発見を行っている。

3 提案手法

本章では、提案手法であるユーザーの状況を考慮した情報推薦システムについて説明する。

本システムでは、基盤となる協調フィルタリングなどでは考慮されていなかった、ユーザーの購買時の状況を考慮する。これによりユーザーが現在置かれている状況に適した推薦を行う。全体のシステム構成を図 1 に示す。

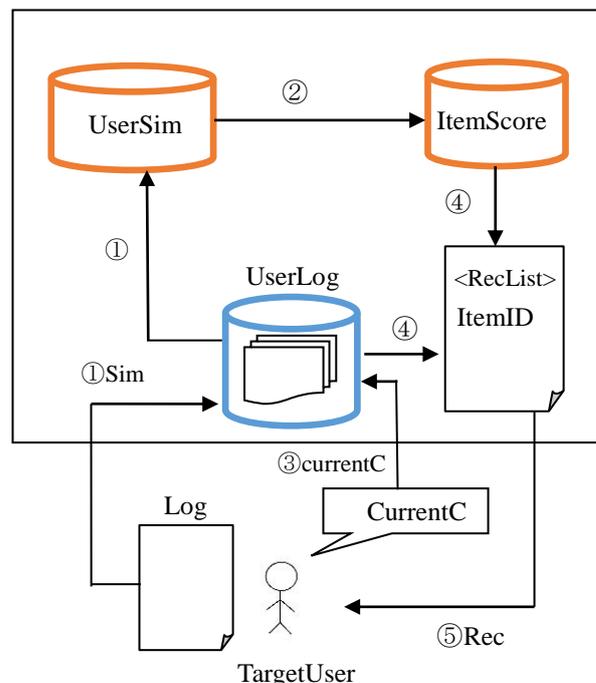


図 1：システムの概要図

以降本章では、図 1 に沿って提案手法について説明を行う。

提案手法は、大きく「購買情報の入力」と「推薦」の二つの処理に分かれている。

3.1 購買情報の入力

本稿では、ユーザー集合を $U=\{u_1, \dots, u_N\}$ 、アイテム集合を $I=\{i_1, \dots, i_M\}$ とする。また、各ユーザーの各購買アイテムに付属している Context を $C_{u,i}=\{c^1_{u,i}, \dots, c^L_{u,i}\}$ とする。

i) ユーザー間の購買類似度を計算する。図 1 においては①の処理にあたる。購買類似度は、「同じアイテムをどれだけ似た状況で買っているのか」を表す。ターゲットユーザーを u_T とした時、図 2 のように他のユーザー $u_n (n \neq T)$ との購買類似度を $purSim$ とする。購買類似度は、式(1)のように定義され以下の 2 式によって計算される。

$$purSim(u_T, u_n) \equiv \sum_{m \in M} Sim(C_{u_T, i_m}, C_{u_n, i_m}) \quad \dots(1)$$

$$Sim(C_{u_T, i_m}, C_{u_n, i_m}) \equiv \sum_{l \in L} \cos(c^l_{u_T, i_m}, c^l_{u_n, i_m}) \quad \dots(2)$$

ii) 図 1 の②では、各ユーザーにおけるアイテムの重要度の計算を行う。重要度は ItemScore とし、類似した他のユーザーとの購買類似度をもとにターゲットユーザーにとって各アイテム

がどれだけ価値のあるものかを求める。重要度は式(3),(4)によって算出されるが、まず式(4)は、あるアイテム i_m を、ターゲットユーザーの類似ユーザー u_n が購入しているかを判断している。もし、購入されている場合はターゲットユーザーと u_n の購買類似度を $score(i_m)$ とし、されていない場合は 0 としている。次に、式(3)の処理は式(4)で算出された $score(i_m)$ の総和である。

図3の「×」印は、式(4)において、類似ユーザーがターゲットと同じアイテムを購入したことがあるかを判断する部分に当たる。

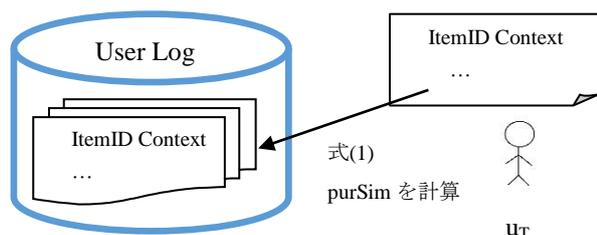


図2：ユーザー間購買類似度の計算

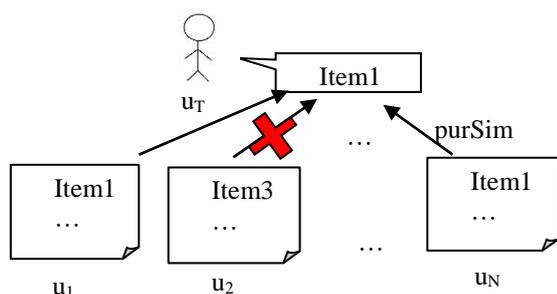


図3：ItemScore の計算

$$ItemScore(u_T, i_m) \equiv \sum_{m \in M} score(i_m) \quad \dots(3)$$

$$score(i_m) = \begin{cases} purSim(u_T, u_n) & \text{if } (u_n \text{ buy } i_m) \\ 0 & \text{else} \end{cases} \quad \dots(4)$$

3.2 現在の状況を考慮した推薦

ここでは、事前処理で求めた(1),(2)とターゲットユーザーの現在の Context を用いて推薦アイテムの決定を行う。上記の図1においては、③以降の処理が本章にあたる。

i) ターゲットユーザー u_T にとって類似度が高いユーザーの過去の購買履歴から順番に購買アイテムを獲得し、各購買アイテムに付加されている Context(以下 $C_{u,i}$)とターゲットユーザーの現在の Context(以下 $currentC_{u,i}$)の類似度である $currentSim$ を計算する。その際、事前処理ではアイテムが一致し

た上で付加された Context 同士の類似度を測っていたが、ここではアイテムの一致は考慮しない。つまり、これは u_T に似た u_n があるアイテムをどのような状況で買っていて、それが u_T の現在置かれている状況にどれだけ似ているかの計算である。同じアイテムを複数回購入している場合は、より類似度の高い方を採用している。

式の定義は(2)を変形したもので次のようになる。

$$currentSim(currentC_{u_T}, C_{u_n, i_m}) \equiv \sum_{l \in L} \cos(currentC_{u_T}^l, C_{u_n, i_m}^l) \dots(5)$$

ii) 図1の④では、事前処理で求めた u_T に対する $ItemScore$ を取り出し、 $currentSim$ に対応する i_m の $ItemScore$ を取得する。以上の二つの値から最終的な推薦候補アイテムのスコアである $recItemScore(u_T, i_m)$ を求める。 $recItemScore$ を求める際、それぞれの値をシグモイド関数を用いて正規化し[0,1]とする。シグモイド関数は以下の式である。

$$sigmoid(x) = \frac{1}{1 + e^{-a(x-b)}} \quad \dots(6)$$

(6)のゲイン a や軸 b の設定に関しては4章にて考察を行う。

以上より、推薦候補アイテムのスコアは以下の式で定義される。

$$recItemScore(u_T, i_m) \equiv sigmoid(currentSim(currentC_{u_T}, C_{u_n, i_m})) \times sigmoid(ItemScore(u_T, i_m)) \quad \dots(7)$$

(7)を全類似ユーザーに対して計算し更新していくことで u_T に対する最終的なアイテムごとのスコアを求める。このスコアを降順でソートしターゲットユーザー u_T に対する推薦アイテムリストとする。図1では⑤にあたる。

図で示すと次のようになる。

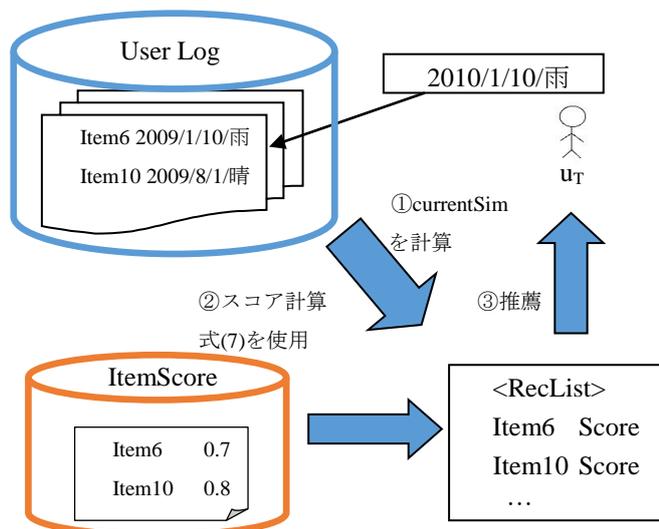


図 4：現在の Context を用いた推薦部

4 実験

本章では、提案手法の評価実験の方法と実験結果について述べる。

今回、以下の 2 種類の方法で評価を行った。

1. 適合率(Precision)と再現率(Recall)による評価
2. T 検定による有意差の検証

いずれも、比較手法として通常の協調フィルタリング(以下 CF)を用いた。

4.1 実験用データ

データセットは GroceryShoppingDatasets[6]を用いた。本データセットは、ベルギーにある匿名のスーパーマーケットの 2000/11/01~2001/02/28 までの 4 ヶ月間の購買履歴を記録したものである。

本稿の提案手法の目的であるユーザーの状況を考慮した場合としない場合との比較実験が行えるよう、データセットに以下のような事前処理を行った。

- a) もともとのデータセットに付加されているアイテムを購入したときの年月日情報に、年月日情報から算出した曜日情報、さらにベルギーの 2000/11/01~2001/02/28 までの天気情報(10 種類)を各国の過去の天気情報が検索できる wunderground.com[7]の WEB ページよりクロールし、付加した。
- b) 本データセットはスーパーマーケットで収集されたデータであるため、日常的に購買されているアイテムが存在する。このようなアイテムは Context における影響を受けにくく、ユーザーの状況を考慮した推薦システムを考えるうえで不適切なアイテムであると考えられる。また、本稿の提案手法では従来の CF

等と比べ、Context を考慮しているためにデータのスパース性による cold-start 問題における影響を受けやすい。以上の理由から、購買回数が 4000 回以上のアイテムと 100 回以下のアイテムの購買データを削除した。

- c) 2001/01/16 以前の購買データを学習データとし、それ以降の直近 5 個の購買データを正解データとした。
- d) 学習データに購買データが 1 個以下しか存在しないユーザーは推薦結果に影響を与えないため、これらのユーザーを削除した。

表 1：GroceryShoppingDatasets の概要

DataSet	事前処理前	事前処理後
Users	32,266	23,041
Items	23,812	972
Ratings	817,741	218,220
Rating Scale	binary	binary

事前処理前後の各データ数を表 1 に示す。

評価実験では、学習データに購買データが 15 個以上あり、正解データに購買データが 5 個以上あるユーザーをターゲットユーザー候補とした。実験ではこのターゲットユーザー候補の中からランダムで選んだ 200 人をターゲットとしたものを 1 セットとし、計 12 セットで交差検定による評価実験を行った。

4.2 シグモイド関数のパラメータ設定

今回の評価実験における精度は、4.1 で述べられているようにターゲットユーザー候補の中から 200 人 × 12 パターンに対する精度の平均としている。

CF との比較を行う前に、3 章で定義した(7)で用いる ItemScore と currentSim のそれぞれに対するシグモイド関数のゲイン a と軸 b の値の設定について考察を行った。

表 2 のように 5 つの組み合わせを用意し、その中から最良の組み合わせを見つける実験を行った。本システムは、ユーザーの現在の状況を重視する性質上、より直近に購買するアイテムを予測できることが望ましいため推薦候補リストで 1 位のアイテムに対する Precision, Recall そして F 値において比較した。

表 2: ゲイン a と軸 b の組み合わせ

	ItemScore		currentSim	
	a	b	a	b
Pattern1	0.400	262	1.0	0.0
Pattern2	1.000	262	0.4	0.0
Pattern3	0.005	30000	1.4	0.0
Pattern4	0.003	※	1.5	0.0
Pattern5	0.003	※	2.0	1.0

※12 パターンそれぞれの *ItemScore* の値域からパターンごとに設定.

表 3: 組み合わせごとの精度比較

	Precision	Recall	F 値
Pattern1	0.0150	0.0030	0.0050
Pattern2	0.0146	0.0029	0.0049
Pattern3	0.0883	0.0177	0.0294
Pattern4	0.0883	0.0177	0.0294
Pattern5	0.0900	0.0180	0.0300

表 3 から, Pattern5 の組み合わせにおける精度が他の組み合わせに比べ高い値を示しているため, 今回の実験では Pattern5 のパラメータを採用し実験を行った.

精度が向上した要因として, 1) *ItemScore* を正規化した際に値ができるだけ [0,1] の値域の中でばらつきが起こるようにしたこと, 2) ユーザーの現在の状況の反映度をより大きくしたことにより, 現在の状況を考慮していない *ItemScore* に依存した推薦を避けることができたことが考えられる.

4.3 Precision/Recall における比較実験

CF と提案手法の比較を行った. 4.1 にある通り, 各ユーザーにおける正解アイテムは, 1/16 以降に購買したものとし, 今回はその中から直近 5 つのみを用いて, 検証を行った. 次に実験結果を示す.

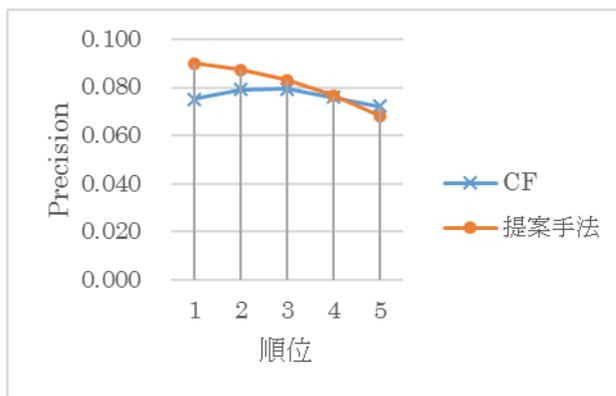


図 5: 順位ごとの Precision の推移

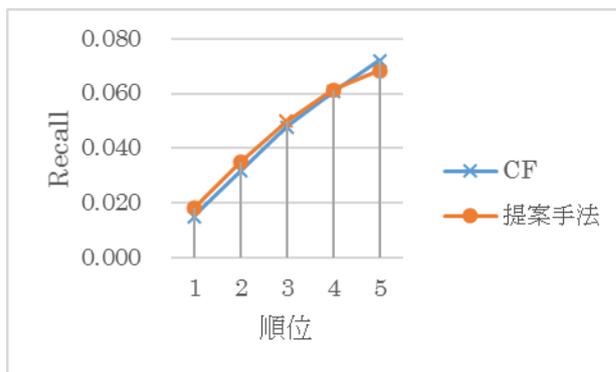


図 6: 順位ごとの Recall の推移

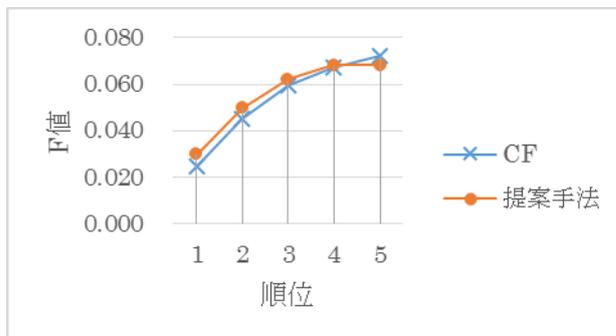


図 7: 順位ごとの F 値の推移

図 5 に注目すると, 推薦順位が 3 位までの Precision の値は提案手法の方が CF よりも高い値となっている. そして, 4 位では CF と同じ程度の値となり 5 位以降は CF が上回っている. 同様に図 6,7 についても図 5 と同様な結果となっている. しかし, 今回の提案手法は, 現在から見て一番直近の購買を予測することを重要視しているため, 時系列的に見て現在から先の未来に対する推薦精度は現在から離れる程落ちてしまうと考えられる. そのため, 今回の実験結果は提案手法において, 直近の推薦に関しては比較手法よりも優れた推薦が行えていると考えられる.

4.4 T 検定による有意差の検証

次に、T 検定を用いて提案手法と従来手法の CF の精度には有意に差があったかどうかについて、検証結果を示す。検定は両側検定/対応のあるデータとし、有意水準を 5% とした。

検証には、推薦時に 12 パターンに分けたターゲットユーザーの集合それぞれに対する P@1 の値(表 4 参照)を用いた。

結果、 $p=0.003151<0.05$ となり、提案手法と従来手法との精度の間に有意差が認められた。

表 4: 2 手法のパターンごとの P@1

Pattern	CF	提案手法
1	0.065	0.105
2	0.085	0.085
3	0.095	0.120
4	0.055	0.065
5	0.070	0.080
6	0.080	0.080
7	0.065	0.100
8	0.065	0.090
9	0.090	0.100
10	0.075	0.075
11	0.095	0.100
12	0.060	0.080

5 考察

図 5-7 で示した通り、推薦リストの上位に関しては従来手法に比べて優れた精度を示すことができた。第 5 位以降に関しては Precision/Recall が共に精度が落ちてしまっているが、提案手法はユーザーの現在の状況を考慮した上での推薦のため、現在の状況をより反映していると考えられる直近の未来の購買を予測するという特徴があるため、予測する日にちが離れるほど、現在の Context の影響度が弱まり推薦リストの順位が下がるとともに、CF との精度の差が縮まり第 5 位に達した時点で入れ替わったのだと考えられる。

また、提案手法と通常の CF との比較実験において、2 手法間の精度の差が小さかったことの原因として、今回実験に用いたデータでの購買履歴の性質が関係していると考えられる。スーパーマーケットにおける購買履歴の特性上、生活必需品などのユーザーの現在の状況に依存されない購買が多く含まれていると想定できる。そのため、個々のユーザーにおける Context に依存した特徴的な購買が反映されにくかったのではないかと考えられる。また、このデータは 4 か月分という限られた期間におけるデー

タであったため、季節などが限定されてしまっている。その結果、「1 年前に同じ状況で購買されているアイテム」などのデータが存在しなかったため、1 年間分以上のデータを用いて実験する場合に比べユーザーの現在の Context を生かしきれなかった可能性があると考えられる。

6 おわりに

本稿では、ユーザーの購買アイテムに付加された購買時の状況を用いて、ターゲットユーザーが現在置かれている状況において最適なアイテムを選択する手法を提案した。

評価実験では、正規化に用いたシグモイド関数のゲインと軸の設定によってアイテムの重要度とユーザーの現在の状況に対する重みを変えることができ、それにより、推薦結果に大きく影響することが確認された。また、Context のリアルタイム性を重視した推薦のため、直近の購買に対する予測ほど従来手法に比べ高い精度を出すことが可能であった。

今後の課題として、実用的な手法を考えた場合、使用する Context の次元数は今回使用したものよりも増加し、それによってデータのスパース性/計算コストの増加が考えられる。そのため、多次元空間に対してテンソル分解などを適用することにより次元縮退をし、処理速度と精度の 2 面において向上を図る必要があると考えられる。

参考文献

- [1] Amazon.com : <http://www.amazon.co.jp/>
- [2] MovieLens : <http://movielens.org/>
- [3] 奥 健太, 中島 伸介, 宮崎 純, 植村 俊亮: Context-Aware SVM に基づく状況依存型情報推薦方式の提案, 第 17 回データ工学ワークショップ(DEWS), 2006
- [4] 関 匠吾, 中島 伸介, 張 建偉: アイテム利用時のユーザーコンテキストを考慮した情報推薦システムの提案, 第 3 回データ工学と情報マネジメントに関するフォーラム(DEIM), 2011
- [5] 篠田 裕之, 竹内 享, 寺西 裕一, 春本 要, 下條 真司: 行動履歴に基づく協調フィルタリングによる行動ナビゲーション手法, 情報処理学会研究報告. GN, [グループウェアとネットワークサービス], 2007
- [6] Grocery Shopping Datasets : http://recsyswiki.com/wiki/Grocery_shopping_datasets , ACM Recsys wiki
- [7] Wunderground.com : <http://www.wunderground.com/>