

アクセスオブジェクトの順序対に着目したふるまい検知

Detection of Human Behavior Using Ordered Pairs in Access Object Sequence

山原 裕之† 藤原 聰子† 野口 豊司†† 島川 博光†††
Hiroyuki Yamahara Satoko Fujiwara Toyoshi Noguchi Hiromitsu Shimakawa

1. はじめに

ユビキタス環境において人間のふるまいを正確に認識することができれば、行動を適切に支援できる[1,2,3,4]。本論文では、特定状況における人間の行動パターンを生成する手法および行動パターンを実際の人間の行動と照合することでふるまいを検知する手法について提案を行う。提案手法は、人間が触れたオブジェクトの種類と、複数のオブジェクトにどのような順序で触れたかという情報を行動ログとして記録し、特徴的なパターンを抽出する。本手法は、連続して触れたオブジェクトだけではなく、連続で触れていないが順序関係を持つオブジェクトにも着目し、順序照合と確率モデルを分離することで、

- 規則性と不規則性が混在する人間の複雑な行動を表現できる
- 確率的に稀な行動を含んでいる場合でも正しくふるまいを検知することができる

という特長を持つ。提案手法を用いた実験を行った結果、90%以上の割合で正しくふるまいを検知することができた。

2. 知的空間における人間の行動認識

2.1 Tagged World

本研究では、人間の行動を認識する知的空間として Tagged World を構築した。Tagged World は、財布、携帯電話、ドアノブなど、人間の生活空間におけるさまざまなオブジェクトに RFID タグが貼り付けられた知的空間である。RFID タグには、タグを識別するために一意のタグ ID が記録されており、タグ ID を用いてオブジェクトを識別することができる。Tagged World において、人間は指に装着可能な近距離型の RFID リーダーを内蔵した小型の携帯型計算機を所持する。この小型の携帯型計算機が Tagged World における人間のアシスタントとして機能することから、本研究ではこれをポケットアシスタントと呼ぶ。

人間は日常生活において、さまざまなオブジェクトに近付き、利用する。このとき、人間が装着した RFID リーダーがオブジェクトに貼り付けられた RFID タグのタグ ID を読み取る。その結果、タグ ID とそのタグへのアクセス時刻を示す時刻印の組を、時系列で取得することができる。この時系列は人間の動作の対象を表しており、どのようなオブジェクトを利用したかを示す詳細な行動ログである。Tagged World では、人間の行動を認識するために行動ログをポケットアシスタントに蓄積する。

2.2 習慣的行動を含むふるまいの検知

人間は日常生活の特定の状況において、習慣的な行動をとる。これは、特定の状況において習慣的に同じオブジェクトに触れるなどを意味する。たとえば、外出する状況に

おける人間のふるまいには“財布を持つ”“腕時計を着ける”“トイレに行く”“携帯電話を持つ”というさまざまなかつてが含まれる。腕時計を着けない人やトイレに行かない人もいるため、外出のふるまいにどの行動が含まれるかは個人の習慣に依存する。また、これらの行動の順序も個人の習慣によってさまざまである。

Tagged World ではこの考えに基づいて、人間が触れたオブジェクトの種類を行動ログとして取得し、特定の状況における人間のふるまいを検知する。既存の研究では、知的空間における人間のジェスチャや移動経路など、動作そのものを計測対象としている。ジェスチャや移動経路は、あいまい性を多く含む連続量として計測される。そのため、似た動作をした異なる意味の行動を区別するために負荷の大きな処理が必要となる。これに対して、Tagged World では動作の対象であるオブジェクトへのアクセスに着目することで、人間の行動が離散値として計測される。よって、認識処理の負荷は軽い。

ポケットアシスタントの性能を考慮して、ふるまいの検知は以下の 2 点に着目して段階的に進行する。

- 触れたオブジェクトの種類
- オブジェクトに触れた順序

第 1 段階ではオブジェクトの種類のみに着目する。たとえば、外出のふるまいを検知することを考える。外出時に触れるオブジェクトと食事や料理をしているときに触れるオブジェクトは全く異なる。ゆえに、触れたオブジェクトの種類に着目するだけで、その人間の状況が外出の可能性が高いと判断できる。しかし、外出時と帰宅時には触れるオブジェクトの種類が似ていることから、第 1 段階だけで外出のふるまいであると確定することはできない。その後、第 2 段階ではオブジェクトに触れた順序に着目し、第 1 段階よりも詳細に行動ログを検証する。常に詳細な順序の検証を行うのではなく、第 1 段階で粗く判別することにより、ポケットアシスタントの負荷を軽減することができる。本論文では、第 2 段階における人間が触れたオブジェクトの順序関係からふるまいを検知する手法について提案する。

3. 離散順序関係に着目したふるまい検知

3.1 離散順序対集合で表現した行動パターン

本論文では、特定の状況における習慣的行動を含むふるまいが示す特徴的なパターンを行動パターンと呼ぶ。行動パターンは個人ごとに異なる。提案手法では、人間が触れたオブジェクトの順序関係からふるまいを検知するために、あらかじめ特定の状況における行動パターンを生成しておく。行動パターンは、オブジェクトの順序対で表現される。外出の行動パターンを例に挙げて、行動パターン生成の流れを図 1 に示す。行動パターンは、

- (1) 行動ログを収集する
- (2) 順序対を列挙する

† 立命館大学大学院 理工学研究科

†† 株式会社 内田洋行

††† 立命館大学 情報理工学部

- (3) 各順序対の出現回数をカウントする
(4) 出現回数が閾値以上の順序対を抽出する
という流れで生成される。

まず標本ケースとして、外出時の個人の行動ログを w ケース収集する。本論文では、行動パターンの生成に用いる標本ケース数 w をウィンドウサイズと呼ぶ。ポケットアンスターに蓄積された行動ログの中から外出時の一定期間の行動ログを切り出すことで、外出の行動ログを収集するものとする。複数ケースの行動ログを収集した場合、各ケースの行動ログに含まれるオブジェクトは異なる。行動ログ中で m 個のオブジェクト $o_i (i=1, 2, \dots, m)$ に順に触れていた場合、行動ログ l は接続 $\{o_1, o_2, \dots, o_m\}$ で表現される。ただし、 $o_{i-1} \neq o_i (1 < i \leq m)$ である。

次に、収集した行動ログから 2 つのオブジェクト間の順序対を列挙する。あるオブジェクト o_i に触れてからオブジェクト o_j に触れていた場合、順序対 p を $\{o_i \rightarrow o_j\}$ と表記する。このとき、 $o_i = o_j$ の場合も除外しない。また、行動ログ内で連続して触れたオブジェクトの対だけでなく、隣りあつてないオブジェクトの組も順序対として列挙する。たとえば、行動ログ $\{o_1, o_2, o_3\}$ から列挙される順序対は、 $p_1: \{o_1 \rightarrow o_2\}$, $p_2: \{o_1 \rightarrow o_3\}$, $p_3: \{o_2 \rightarrow o_3\}$ となる。

すべての標本ケースにおける順序対を列挙した後に、各順序対の出現回数をカウントする。1 つの標本ケースにおいて同一の順序対が何回出現しているかには注目せず、各順序対が w 個の標本ケースのうち何ケースに出現しているかをカウントする。

最後に、列挙された順序対集合の中から、出現ケース数が閾値 e よりも多い順序対のみを抽出する。抽出された n 個の順序対の集合で表現される行動パターン π は以下のように定義できる。

$$\pi = \{p_1, p_2, \dots, p_n\}, \text{ occur}(p_i) > e$$

ここで、関数 $\text{occur}(p_i)$ は順序対 p_i の w 個の標本ケース中の何ケースに出現したかを返す。

既存の研究において時間軸に沿った人間の行動パターン生成に用いられている Hidden Markov Model では、時間的に連続である 2 状態間の遷移確率を考慮して行動パターンが生成される[1,3]。実際の人間の行動を局所的に見れば、同じ行動をとっても毎回順序が細かく入れ替わっていることが多いが、大局的に見れば行動順序の規則性が存在することは明らかである。このような、行動順序に規則性のある部分とない部分が混在する複雑な人間の行動を、時間的に連続な 2 状態に注目した行動パターンでは表現することは難しい。これに対して提案手法は、行動ログの中で隣りあ

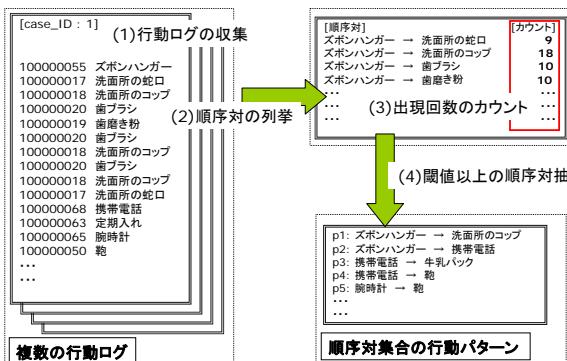


図 1 行動パターンの生成

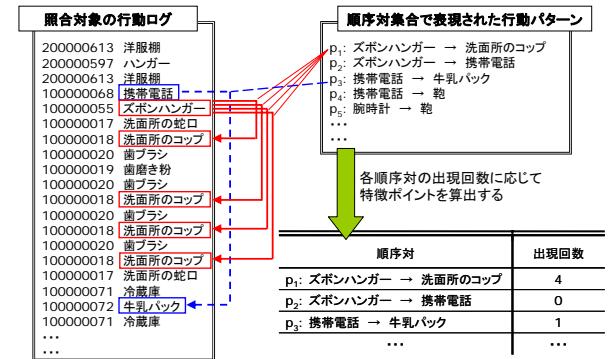


図 2 行動パターンの照合

った 2 つのオブジェクトの順序対だけでなく、隣りあってないオブジェクトの順序対も考慮して行動パターンを生成することで、複雑な人間の行動を柔軟に、かつ簡潔に表現できるという利点を持つ。

3.2 ふるまいの検知

提案手法では、人間の行動から特定のふるまいを検知するために、あらかじめ生成した順序対集合の行動パターンと、実際の人間の行動から得られる行動ログを照合する。本論文では、照合対象の行動ログが行動パターンに適応している度合いを示す値を特徴ポイントと呼ぶ。

照合手法を図 2 を用いて説明する。図の右上には、あらかじめ生成した行動パターンが示されている。これに対して図の左側に示されているのは、現在行動している人間から得られた行動ログである。まず最初に、行動パターンに含まれる各順序対が照合対象の行動ログに含まれている回数をカウントする。図 2 では、順序対 $p_1: \{\text{ズボンハンガー} \rightarrow \text{洗面所のコップ}\}$ は照合対象の行動ログ中に 4 回出現する。同様に、順序対 $p_2: \{\text{ズボンハンガー} \rightarrow \text{携帯電話}\}$ は 0 回、順序対 $p_3: \{\text{携帯電話} \rightarrow \text{牛乳パック}\}$ は 1 回、というようにカウントする。次に、順序対の出現回数から特徴ポイントを求める。行動パターン $\pi: \{p_1, p_2, \dots, p_n\}$ に対して、特徴ポイント CP は以下の計算式で求める。

$$CP = \sum_{i=1}^n \text{calcAddedPoint}((\text{occur}(p_i)))$$

ここで、

$$\text{calcAddedPoint}(k) = \sum_{i=1}^k \text{point}(i)$$

とする。本手法では、同じ順序対が複数回出現した場合、出現するたびに異なるポイントが加算される。 $\text{point}(k)$ は同じ順序対が k 回目に出現したときに加算されるポイントを示す。たとえば、ある順序対が行動ログ中に 3 回出現した場合、その順序対によって加算される特徴ポイントの値は、 $\text{calcAddedPoint}(3) = \text{point}(1) + \text{point}(2) + \text{point}(3)$ である。加算されるポイントは、順序対の種類には依存しない。行動パターンと行動ログを照合した結果、得られた特徴ポイントがあらかじめ設定した検知閾値以上であれば、ふるまいを検知する。

既存研究で用いられている Hidden Markov Model は、2 状態間の遷移確率と各状態における記号出力確率の積を計算することで、観測した記号列が output される確率を求める[1,3]。そのため、出力確率が稀な記号が観測記号列の一部に存在した場合、観測記号列が output される確率が低くなる。

実際の人間の行動を例に考えると，“外出時に玄関ドアを開けるさい、ドアノブに手をかけてからチェーンがかかっていることに気付き、チェーンをはずした”というような、普段はあまり現れない動作の順序が一部に存在しただけで、Hidden Markov Model は外出のふるまいを上手く検知できない可能性がある。これに対して提案手法は、順序対の出現回数に応じて特徴ポイントを加算することで、特徴的な行動順序が存在することのみを基準にふるまいを検知する。出現確率の低い順序対は、行動パターンを生成する時点で排除されている。提案手法は、行動パターンの照合において、あえて確率モデルを排除することで、確率的には稀な行動が出現した場合でも、柔軟にふるまいを検知することができる。

4. 実験

4.1 実験概要

提案手法の有効性を検証するために、被験者 15 人に対してふるまいを検知する実験を行った。本論文では、検知すべきふるまいの行動ログを正の事例、検知すべきでないふるまいの行動ログを負の事例と呼ぶ。実験では、住宅を模した実験空間に Tagged World を構築し、正の事例と負の事例の両方を収集した。正の事例として外出のふるまいを、負の事例としては、外出のふるまいと触れるオブジェクトが似ているために、誤って検知してしまう可能性がある帰宅のふるまいを収集した。またその他に、外出時に行われる可能性がある行動や外出時と移動経路が似ていると考えられる行動も、負の事例として収集した。被験者 1 人あたりに収集した行動ログは、正の事例 20 ケース、負の事例 10 ケースである。合計で、正の事例 300 ケース、負の事例 150 ケースを収集した。

本論文では、2 つの実験を行った。第 1 実験では、行動パターン照合時の特徴ポイント加算方式および行動パターン生成時の検知閾値の設定方法に関する評価実験を行った。第 2 実験では、提案手法が正の事例を正しく検知し、負の事例を誤って検知しないことを実証するために、行動パターンの生成と照合を繰り返してふるまいの認識率を評価した。実験結果はすべて被験者 15 人の結果の平均値である。以下、それぞれの実験について順に述べる。

4.2 特徴ポイント加算方式と検知閾値の設定

第 1 実験では、行動パターン照合時の特徴ポイント加算方式として、12 個のアルゴリズムを比較評価した。表 1 は、algorithm-0 から algorithm-11 までの 12 個のアルゴリズムに関して、照合対象の行動ログ中に同じ順序対が 1 回目から 4 回目に出現したときに特徴ポイントに加算されるポイントを示している。point(k)は順序対が k 回目に出現したとき

表 1 特徴ポイント計算閾値の値

	point(1)	point(2)	point(3)	point(4)
algorithm-0	16	16	16	16
algorithm-1	16	16	16	0
algorithm-2	16	16	0	0
algorithm-3	16	0	0	0
algorithm-4	16	0	16	0
algorithm-5	16	0	0	16
algorithm-6	16	8	8	8
algorithm-7	16	4	4	4
algorithm-8	16	14	12	10
algorithm-9	16	11	6	1
algorithm-10	16	14	10	2
algorithm-11	16	8	4	2

の加算ポイントである。各アルゴリズムは、行動パターン照合時に同じ順序対が複数回出現した場合、それを行動の特徴として考慮する度合いの違いを表現するために、2 回目以降の出現で加算されるポイントの値が異なる。たとえば algorithm-3 は、同じ順序対が複数回出現しても、それを特徴とみなさない。どのアルゴリズムも 5 回目以降の出現に対してはポイントを加算しない。

検知閾値は過去の特徴ポイントの値から計算する。第 1 実験では、検知閾値の設定に関して、以下のように複数の計算方法を比較評価した。

[最大値タイプ] 過去の特徴ポイントの中から最大値 Max を選び、その値の 90%から 10% の値を検知閾値に設定する。(Max*90%～Max*10%)

[平均値タイプ] 過去の特徴ポイントの平均値 Avg を計算し、その値の 90%から 10% の値を検知閾値に設定する。(Avg*90%～Avg*10%)

[標準偏差タイプ] 過去の特徴ポイントの平均値 Avg および標準偏差 σ を計算し、平均値から $-\sigma$, -2σ の値を検知閾値に設定する。(Avg $-\sigma$, Avg -2σ)

以上 3 つのタイプの閾値設定では、正の事例から得られる特徴ポイントのみから検知閾値を設定する。正の事例と負の事例の両方から得られる特徴ポイントを組み合わせると、より望ましい検知閾値が計算できる可能性も考えられる。実験では、両方の事例から得られる特徴ポイントを組み合わせた場合の検知閾値設定も比較した。

[最小最大中間値タイプ] 過去の正の事例の特徴ポイントの最小値と負の事例の特徴ポイントの最大値の平均値を検知閾値に設定する。(Mid Of MinMax)

[平均中間値タイプ] 過去の正の事例の特徴ポイントの平均値と負の事例の特徴ポイントの平均値の中間値を検知閾値に設定する。(Mid of Avg)

[標準偏差中間値タイプ] 過去の正の事例の特徴ポイントの平均値を M として、 $M-\sigma$, $M-2\sigma$ の値を求める。同じく、過去の負の事例の特徴ポイントの平均値を m として、 $m+\sigma$, $m+2\sigma$ の値を求める。 $M-\sigma$ と $m+\sigma$ の中間値、 $M-2\sigma$ と $m+2\sigma$ の中間値を検知閾値として設定する。(Mid of Avg $-\sigma$, Mid of Avg -2σ)

4.3 検知手法の評価

第 1 実験では、行動パターン生成時のウィンドウサイズを 5 に設定した。以下に、実験の流れを示す。

- (1) 正の事例 20 ケースから任意に 10 ケースを選ぶ。
- (2) 選び出した 10 ケースの中から任意に 5 ケースを選び、行動パターンを生成する。

(3) 生成した行動パターンを、残りの正の事例 5 ケースと負の事例 10 ケースと照合し、特徴ポイントを求める。

(4) (2)(3)を 5 回繰り返し、正の事例 25 ケースの特徴ポイントと負の事例 50 ケースの特徴ポイントを用いて、検知閾値を設定する。

(5) 設定した検知閾値を、正負の事例を合わせて 75 ケースから計算した特徴ポイントと比較し、認識率を求める。

以上の操作を、特徴ポイント加算アルゴリズムと検知閾値設定のすべての組み合わせに対して行った。

図 3 は、特徴ポイント加算アルゴリズムと検知閾値設定のすべての組み合わせに関して、実験結果として得られた認識率の値を示したグラフである。横軸は検知閾値の設定、縦軸は認識率を示す。図は、12 個のうち認識率の高い上位

3つのアルゴリズムの、認識率90%以上の部分のみを示している。検知閾値の設定に関しては、Avg*50%，Mid of Avg，Mid of Avg- σ の場合に最も高い認識率を示している。正負の事例から得られる特徴ポイントを組み合わせると、正の事例の特徴ポイントのみを用いた場合よりも望ましい検知閾値が計算できる可能性があることを考慮したが、実験の結果、正の事例の特徴ポイントのみから検知閾値を計算した場合と同程度の認識率であった。むしろ、負の事例はケースごとの特徴ポイントのばらつきが大きく、負の事例から得られる特徴ポイントが最適でない場合、正の事例の特徴ポイントのみから検知閾値を計算した場合よりも認識率は低い。よって、最適な検知閾値の設定はAvg*50%であると考えられる。

また図3から、最も認識率の高いalgorithm-3が性能の良いアルゴリズムであると言える。algorithm-3は同じ順序対が複数回出現した場合でも、2回目以降の出現に関しては特徴ポイントを加算しない。2回目以降の出現に関しても特徴ポイントを加算する他のアルゴリズムでは、正の事例の特徴ポイントがより高くなり、結果として正の事例の中でもケースごとに特徴ポイントのばらつきが発生した。そのため、検知閾値の値が不安定になり、認識率を下げていた。

4.4 ふるまいの認識率

第2実験では、提案手法が正の事例を正しく検知し、負の事例を誤って検知しないことを実証するために、行動パターンの生成と照合を繰り返してふるまいの認識率を評価した。また、ウィンドウサイズの変化に伴う認識率の変化も考察した。未知の行動ログに対する性能を評価するために、第1実験では用いなかった10ケースを照合対象の行動ログとして用いた。以下に実験の流れを示す。

- (1) 第1実験で生成した5つの行動パターンから1つを選ぶ。第1実験の結果から初期検知閾値を設定する。
 - (2) 第1実験では用いなかった正の事例10ケースの中からまだ照合対象に選ばれていない1ケースを選んで照合する。同時に、負の事例10ケースとも照合を行う。
 - (3) 照合した1ケースの行動ログをウィンドウに加えて、行動パターンを学習する。
 - (4) (2)(3)を10回繰り返して正の事例、負の事例それぞれの認識率を求める。
 - (5) (1)～(4)を5回繰り返して、平均認識率を求める。
- 以上の操作を、ウィンドウサイズを3～10に設定して、それぞれ行った。

4.5 考察

第2実験の結果として得られたウィンドウサイズごとの認識率を図4に示す。正の事例は98%以上、負の事例は95%以上の高い認識率を示した。提案手法は既存の手法と異なり、人間の動作の対象であるオブジェクトの順序関係に注目することで、少ないパラメータで高い認識率を示したことから、その有効性が実証された。実験の結果、ウィンドウサイズを変化させても認識率にはほとんど差は出ず、ウィンドウサイズ3の場合でも高い認識率を示した。一般に、記号列パターンの生成と照合に良く用いられているHMMなどの既存手法は、パターンを生成するためにはあらかじめ多数の学習用サンプルが必要とされている。これに対して、提案手法は少ないサンプルからパターンを生成することができる点において有効だと言える。

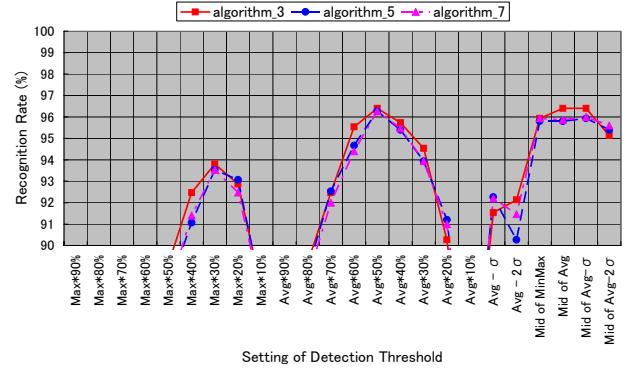


図3 特徴ポイント加算方式と検知閾値設定の比較

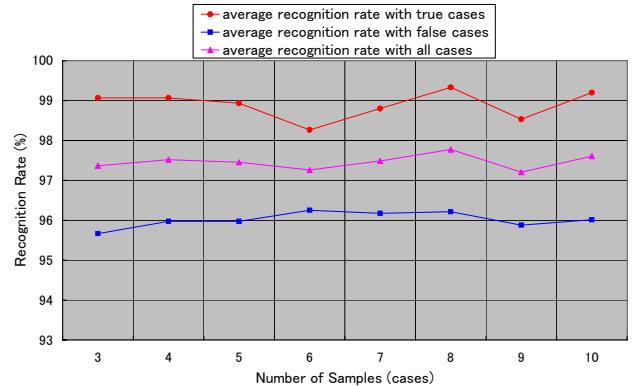


図4 ウィンドウサイズと認識率の相関関係

外出以外のふるまいを検知する例として、帰宅のふるまいに関して同様の実験を行った。ウィンドウサイズは4に設定した。実験の結果、正の事例は93.20%，負の事例は92.28%の認識率を示した。帰宅のふるまいは外出のふるまいに比べて、触れるオブジェクトの数が少ないとから、正の事例の特徴ポイントと負の事例の特徴ポイントの値の差が小さくなり、やや認識率が下がったと考えられる。また同様の理由から、最適な検知閾値の設定が外出と異なる結果になったと言える。

5. おわりに

本論文では、Tagged Worldにおいて人間のふるまいを検知するための行動パターン生成手法および行動パターン照合手法を提案した。今後は、生活空間のさまざまな情報を取得し、個人のふるまいと組み合わせて、より詳細な状況判断をもとにサービスを提供する予定である。

参考文献

- [1] 青木 茂樹, 大西 正輝, 小島 篤博, 福永 邦雄, “独居高齢者の行動パターンに注目した非日常状態の検出,”電学論(E), vol.125-E, no.6, pp.259-265, 2005.
- [2] T. Mori, H. Noguchi, A. Takada, and T. Sato, “Sensing room: Distributed sensor environment for measurement of human daily behavior,” Proc. INSS2004, pp.40-43, 2004.
- [3] T. Fukuda, Y. Nakachi, K. Noguchi, and T. Matsubara, “Time series action support by mobile robot in intelligent environment,” Proc. ICRA2005, pp.2908-2913, 2005.
- [4] M. Perkowitz, M. Philipose, D.J. Patterson, and K. Fishkin, “Mining Models of Human activities from the web,” Proc. WWW2004, pp.573-582, 2004.