

コンテキストデータの動的影響分析方法の提案と評価

M2013SE004 伊藤 まどか

指導教員 青山 幹雄

1. はじめに

SMD (Smart Mobile Device) やセンサ機器の普及により、大量のコンテキストデータが存在する。ユーザを取り巻く大量のコンテキストデータの構造を分析し、適切なサービス提供への活用が期待される。そこでコンテキストデータ間の影響関係の構造をユーザ自身に属するコンテキストデータと時間経過により変化するコンテキストデータに着目し、コンテキスト間の影響を推定する分析方法を提案する。提案方法を自動車の走行中のデータに適用し、ユーザコンテキストから自動車コンテキストへの影響関係を推定し、提案方法の妥当性を評価する。

2. 研究課題

コンテキストデータの変化に応じた影響を推定するために、以下の2点を研究課題とする。

2.1. 非構造的なコンテキストの意味づけ

大量のコンテキストデータから分析に最適なコンテキストデータを抽出するため、様々な形式のデータを一様に扱う必要がある。そこで、非構造的なコンテキストデータへメタデータを付加することが課題としてあげられる。

2.2. コンテキスト間の構造の分析方法の確立

意味づけされた時間経過に伴うコンテキストデータにおいて、コンテキストデータ間の構造を分析する方法が確立されていないことが課題としてあげられる。

3. 関連研究

3.1. 意図に基づくコンテキストウェアサービス提供モデルの提案 [2]

コンテキストウェアサービスの実現に向けた研究として、コンテキストに基づくユーザの意図に着目し、ドライバビリティの UX (User eXperience) を向上させるサービス提供モデルが提案されている。この研究では、ドライバビリティの概念を拡張し、自動車または車載情報システムからのサービス提供によるドライバの意図の達成と定義している。ドライバに属するコンテキストと周囲の状況を決定づけるコンテキストから、ドライバの意図を推測し、推移する意図と整合性のとれたサービス提供を可能にしている。しかし、この研究では、コンテキストの関係をベクトル空間でモデル化しているが、ユーザのコンテキストと自動車に不随するコンテキストの影響の分析方法は提案されていない。

3.2. ドライバの振舞いモデル化の研究[3]

ドライバに影響を与えるコンテキストをモデル化した研究として、ドライバの振舞いを運転しやすさ (Drivability) の観点から定量的に評価する方法が提案されている。この研究では、ドライバの振舞いをコンテキストに関連して時間と共に動的に変化することと定義されている。ドライバの振舞いに影響を与える貢献者を特定し、貢献者から受ける影響度に基づき数式として表すことで、ドライバのドライバビリティを定量的に評価できる。

4. アプローチ

本稿のアプローチの全体図を以下に示す(図1)。




図1 アプローチ全体像

本稿では、コンテキスト間の影響をユーザ自身に属するコンテキストデータが周囲の状況を決定づけるコンテキストデータに対して作用することとする。ユーザにとって無意識の状態や心情がユーザ自身に属するコンテキストデータに関係し、それらが周囲の状況を決定づけるコンテキストデータに影響があり値が変動すると仮定する。また、コンテキストデータは時間変化によっても変動すると仮定する。

コンテキスト間の影響に着目して、時間経過により変化するコンテキストでデータを抽出するため、コンテキストデータにメタデータを付加し意味づけを行うモデルとコンテキストウェア概念[4]に基づきデータ分析の方法を提案し、コンテキスト間の影響を推定する。

5. コンテキスト意味モデル

5.1. モデルの定義

コンテキスト意味モデルとは、収集したデータにコンテキストのメタデータとしてコンテキストデータが持つ属性を付加することとする。

5.2. コンテキストデータ

Day らによりコンテキストは「エンティティの状態を既定で

きる何らかの情報」と定義されている[1]. 本稿では、自動車走行時に関わるアクタに着目し、コンテキストを以下のように定義する. エンティティは、ユーザ、自動車とし、それらの状態を既定できる何らかの情報をコンテキストとする. ユーザに付随するコンテキストをユーザコンテキスト、自動車に付随するコンテキストを自動車コンテキストとする. この定義に基づき、ユーザを取り巻くコンテキストを整理し、ドライバに属するコンテキストと周囲の状況を決定づけるコンテキストの構造をモデル化する. また、時間経過に伴い変化をするコンテキストを動的コンテキスト、時間経過に伴い変化しないコンテキストを静的コンテキストとする.

5.3. モデルの構成

コンテキストデータ全体のモデルを定義し、ユーザコンテキスト、自動車コンテキストに分類し、さらに動的コンテキスト、静的コンテキストに分類する. 各コンテキストにコンテキストの情報を付加する.

(1) 全体のデータモデル

ユーザコンテキスト、自動車コンテキスト、動的コンテキスト、静的コンテキストの間の構造を以下に示す(図2).




図2 コンテキストの全体のモデル

(2) ユーザコンテキスト

ユーザコンテキストは運転を行うドライバから成り、ドライバ自身の特性を示す個人情報や運転の振舞いを示すドライバ特性[5]などを持つ(図3).




図3 ユーザコンテキストのモデル




図4 自動車コンテキストのモデル

(3) 自動車コンテキスト

自動車コンテキストはドライバが運転する自動車とカーナ

ナビから成る. カーナビは自動車に装備されていると考える. カーナビは現在位置などの場所に関するコンテキストと現在時刻などの時間に関するコンテキストを含む(図4).

6. 動的モデル

6.1. モデルの定義

動的モデルとは、コンテキスト意味モデルに基づき、時間経過によって変化するコンテキストデータを抽出し、ベクトル空間において単位時間あたりにおける類似度に基づいてユーザコンテキストから自動車コンテキストに対する影響を推定することとする.

6.2. 動的な影響推定

影響推定の中で、コンテキスト間の影響の定義に基づき、影響を「ある時点において、ユーザコンテキストが自動車コンテキストに与える作用」とする. ユーザコンテキストの値がユーザの状態や心情、または、ユーザ自身が意識していない事象も表すと仮定する.

(1) 動的コンテキストの抽出

図3, 4より、動的コンテキストに属するコンテキストを抽出する. ユーザコンテキストから身体情報、自動車コンテキストから車両状態、車内環境に属するコンテキストデータとカーナビの現在位置や時刻や経路や経過時間などコンテキストデータを抽出する.

(2) 要素をベクトルへ変換

コンテキスト意味モデルから抽出された動的コンテキストの要素をベクトル空間に変換する(式(1)). 時間 $n(n=0,1,2,\dots)$ におけるベクトルを T_n とする. C_{n1} から C_{ns} までをユーザコンテキストのドライバ特性に対する任意の値とし、 C_{ns+1} から C_{nm} までを自動車コンテキストの車における任意の値を持つ. ここで m はコンテキストの数とする. ベクトル空間でコンテキストデータを定量的に扱う.

$$T_n = \begin{bmatrix} C_{n1} \\ \vdots \\ C_{ns} \\ C_{ns+1} \\ \vdots \\ C_{nm} \end{bmatrix} \quad (1)$$

(3) クラスタリング

あるコンテキストデータの変化において、他のコンテキストが一定の割合で変化することで影響を推定する. ユーザコンテキストの要素の変化に基づき、時間経過に伴い、ユーザの状態ごとに分類する. 非階層クラスタリングの1つであるK平均法を用いてクラスタリングを行う.

7. 動的影響分析方法

7.1. 分析方法のプロセス

動的影響分析方法の構成を以下に示す(図5). 提案方法は、コンテキスト意味モデルから抽出したコンテキストデータの影響推定を行うことから成る.

本稿では、コンテキストは予め収集されていると仮定する.

(1) コンテキスト意味モデル

収集されたコンテキストデータをユーザコンテキストと自動車コンテキストに選別の関係をモデル化する。モデルに基づいて、メタデータとしてコンテキストデータに属する情報をコンテキストデータの値に付加する。

(2) 動的モデル

コンテキスト意味モデルから動的コンテキストを抽出する。抽出されたコンテキストデータの各要素をベクトルに変換する。ベクトル空間モデルを用いて、類似した最適な集合に分類する非階層クラスタリングを行う。時間経過とユーザ自身に属するコンテキストデータに基づきユーザの状態変化をクラスタリングし、コンテキスト間の影響を分析する。




図 5 動的影響分析方法のプロセス

7.2. 分析方法の振舞い

提案方法の振舞いを以下に示す(図6)。入力にはSMDやセンサなどから収集可能な情報とし、出力は影響を推定した関係とする。

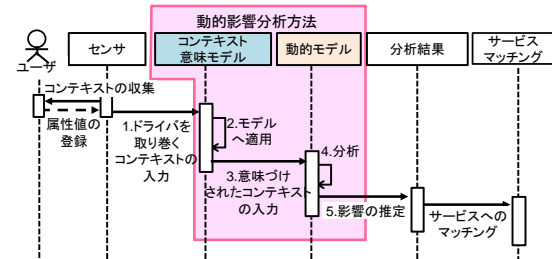


図 6 分析方法の振舞い

8. 適用と評価

8.1. 例題の概要

例題を用いて提案方法の妥当性を示す。経過時間、移動距離、速度、加速度、燃費、脈拍 6 個の動的コンテキストデータを 1 つの集合とする。複数の集合に対して提案モデルに適用した。

8.2. 例題の目的

眠気が無い場合と眠気がある場合に提案方法を適用する。眠気がない場合の例題では、平常の状態における影響を推定する。眠気がある場合の例題では、平常でない状態における影響を推定する。走行中における、脈拍の微分値と速度の微分値(以下加速度と記述する。)に関係があると仮定し、脈拍の微分値において、加速度がどのように変化するかを推定することを目的とする。

8.3. 例題 1: 眠気がない場合

走行中は、ドライバのみであり、渋滞などの外的要因によ

る脈拍の変化はないものとする。65 分間の走行中において、5 分後を $n=1$ 、10 分後を $n=2$ 、 \dots 、65 分後を $n=13$ とする。

(1) コンテキストデータへの意味づけ

動的コンテキストを抽出した値を示す(表 1)、それらをベクトル化し、 T_1 から T_{13} で表す。

(2) 影響の推定

T_1 から T_{13} までの 7 種類(90, 87, 81, 76, 75, 73, 74)の脈拍の値に基づいて 7 個で分類する。非階層クラスタリング k 平均法を 50 回繰り返し行った。非階層クラスタリングの結果と階層クラスタリングの結果を以下に示す(図 7)。

表 1 例題 1 のストリームデータ

	PULSE	TIME	DISTANS	VEL	ACC	FUEL
1	95.0	0.00486	0.00369	5.25	5.26	14.0
2	86.0	0.00933	2.71	2.00	2.08	16.5
...
11	80.0	0.0395	43.7	12.3	13.2	22.2
12	82.0	0.0423	45.9	2.25	2.34	21.8
13	84.0	0.0430	46.3	7.00	4.54	21.1

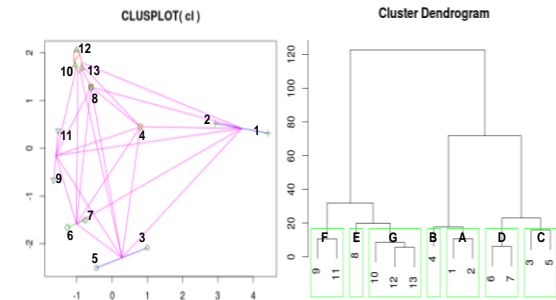


図 7 クラスタリング結果

各点にある数字は、 T_n の添え字 n の値と同様である。

(3) 適用結果




図 8 例題 1 の変化分

クラスタごとの状態変化を明確にするため、クラスタ順に並べ脈拍の微分値と加速度を比較する(図 8)。クラスタリングを行うことによって、13 の集合が類似した 7 のクラスタになる。クラスタ間の移動をユーザの状態変化を表し、クラスタ $A \rightarrow B$, $C \rightarrow D$, $E \rightarrow F$ に着目すると、脈拍の増加率が減少しているときに加速度の増加率も減少している。

8.4. 例題 2: 眠気がある場合

例題 1 と同様に、走行中は、ドライバのみであり、渋滞などの外的要因による脈拍の変化はないものとする。85 分間の走行中において、5 分後を $n=1$ 、10 分後を $n=2$ 、 \dots 、85

分後を $n=17$ とする。

(1) コンテキストデータへの意味づけ

動的コンテキストを抽出した値を示す(表 2)。それらをベクトル化する。T₁からT₁₇で表す。

(2) 影響の推定

T₁からT₁₇までの 10 種類(91, 88, 86, 85, 84, 83, 82, 81, 80, 79)の脈拍の値に基づいて 10 個に分類する。非階層クラスタリング k 平均法を繰り返し行った。非階層クラスタリングの結果と階層クラスタリングの結果を以下に示す(図 9)。各点にある数字は、T_nの添え字 n の値と同様である。

表 2 例題 2 のストリームデータ

	PULSE	TIME	DISTANS	VEL	ACC	FUEL
1	91.0	0.00308	0.121	7.25	7.22	21.2
2	88.0	0.00540	1.49	8.50	8.58	21.4
3	86.0	0.00772	2.66	1.75	0.146	21.4
4	85.0	0.01004	3.83	3.00	3.44	22.2
5	84.0	0.01236	5.00	5.25	11.2	22.1
6	83.0	0.01468	6.17	2.75	2.64	22.0
7	82.0	0.01700	7.34	7.25	7.22	21.2
8	81.0	0.01932	8.51	8.50	8.58	21.4
9	80.0	0.02164	9.68	1.75	0.146	21.4
10	79.0	0.02396	10.85	3.00	3.44	22.2




図 9 クラスタリングの結果

(3) 適用結果

図 9 より、どのように分類されているかを明確にするため、脈拍の微分値と加速度を比較する(図 10)。




図 10 例題 2 の変化分

クラスターごとの状態変化を明確にするため、クラスター順に並べ脈拍の微分値と加速度を比較する(図 10)。脈拍の種類である 10 つに分類したことにより、経過時間に近似した状態で分類された。クラスタリングを行うことによって、17 の集合が類似した 10 のクラスターになった。クラスター F, G, H, I の脈拍変化から眠気がある状態である。クラスター D→E への状態変化が、眠気の状態変化であることがわかる。眠気が発生するときに、加速度が急激に変化している。睡眠ある状態に変化することで加速度に影響があることがわかる。

9. 考察

9.1. 例題への適用により

コンテキスト意味モデルより、ユーザコンテキストは 23 項目から 1 項目に、自動車コンテキストは 22 項目から 5 項目に減少している。

9.2. コンテキストデータへの意味づけ

ユーザコンテキストと自動車コンテキストを時間経過の有無により動的コンテキストと静的コンテキストに分類することによって、動的コンテキストのみを抽出することが可能となる。大量コンテキストから必要コンテキストの抽出を行うことで、必要最低限のコンテキストが扱える。

9.3. コンテキストデータ間の関係

クラスタリングの分類を各項目におけるユーザコンテキストの変化に基づいてクラスタリングすることで、自動車コンテキストへの影響関係を分析することができた。しかし、本稿の提案では、手動で行っているため、即時にレスポンスできないので、リアルタイムに処理を行う必要がある。

10. 今後の課題

(1) ユーザを取り巻くコンテキストとの関係

外的要因により、脈拍の変化に異なる意味がある場合があり、外的要因との関係を検討する必要がある。

(2) 適用したデータ量

コンテキスト間の影響関係によって異なる場合があるため、状況を変えて妥当性を検討する必要がある。

11. まとめ

本稿では、コンテキスト間の影響を推定するために、時間経過に伴う変化に着目し、分析方法のモデルを提案した。提案方法では、時間経過に伴うコンテキストを抽出し、それらをドライバに属するコンテキストと周囲の状況を決めつけるコンテキストに分類し、ユーザ自身の持つコンテキストから影響を推定した。また、それぞれのコンテキストの数値の微分値に基づき評価した。これにより、ユーザ自身が持つコンテキストから周囲の状況を決めつけるコンテキストへの作用を分析することが可能になり、例題に適用することで、提案方法の妥当性を示した。

参考文献

- [1] A. K. Dey, et al., Toward a Better Understanding of Context-Awareness, CHI 2000 Workshop in the What, Who, Where, When, and How of Context-Awareness, 2000.
- [2] 牧 慶子ほか, 意図に応じたコンテキストウェアサービス提供モデルの提案と評価, 情報処理学会研究報告, Vol. 2013-SE-179, No. 28, pp. 1-8.
- [3] M. Panou, et al., Modelling Driver Behaviour in European Union and International Projects, Modelling Driver Behavior in Automotive Environment, Springer 2007, pp. 3-25.
- [4] S. Loke, Context-Aware Pervasive System, Auerbach, 2006.