

# オンライン学習法を用いた日常生活行動モデル生成手法の提案

須藤広平<sup>†</sup> 片野圭二<sup>‡</sup> 小川裕二<sup>‡</sup> 金天海<sup>†</sup>

岩手大学<sup>†</sup> 株式会社アイカムス・ラボ<sup>‡</sup>

## 1 はじめに

介護・医療現場の人手不足や少子高齢化の影響から、1人暮らしの高齢者や障害者（被介護者）の数が近年急速に増えている。ここでは、親族や医療スタッフ（介護者の）目が届かない日常生活中での認知機能の低下や情緒の不安定化が問題となっている。従来の在宅見守りシステムでは、被介護者の日常生活行動 (Activities of Daily Living, ADL) を認識し、ADL と乖離した行動が観測された際に介護者へ発報するシステムが研究されている。しかしながら、従来システムでは被介護者の認知機能低下や情緒不安定のシグナル（以下、シグナルとする）を自動的にとらえて発報するには至っていない。

これらのシグナルは、日常生活における本人の唐突な行動変化「ADLの唐突な変化」に現れることが多い。これらの変化を検出するためには、本人固有のADLを認識し、ADLから乖離した行動を発見する必要がある。また、「介護者の負担を減らす」という在宅見守りシステムの本来の目的からすれば変化の検出や発報を自動的に行えることが望ましい。

そこで本研究では、ADLの変化から認知機能低下や情緒不安定のシグナルを自動的に検出・発報するために在宅中の被介護者の行動ログを住宅に設置したセンサにより取得し、取得した行動モデルを人工知能に学習させ、ADLモデルを自動で生成することを目指す。

## 2 提案手法

### 2.1 ADLの観測方法

ADLの変化の観測方法として、センサのON/OFF情報（二値情報）もとにした行動ログの生成を試みる。従来の行動ログ生成手法において、変化の検出や発報

の自動化が困難であった理由の1つとして、センサ情報の解釈が困難であったことがあげられる。従来の行動ログ生成手法では、温度、湿度、もしくは画像や距離センサといったアナログ情報をもとに人の行動を分類しているが、その分類精度は必ずしも高くはない。また、ディープラーニングなどの手法により分類精度を向上させようとした際にも、高い分類精度を得るためには手作業によるチューニングが欠かせず自動化が難しい。そこで、本研究ではアナログ情報の分類結果を行動ログとするのではなく、センサのON/OFFをもとに生成した情報を人の行動ログとして利用することを試みる。センサのON/OFF情報は個々の現象との対応が明確な情報であり、アナログ情報と比べ環境からのノイズにも強い。そのため、ON/OFF情報の処理は複雑な調整を必要とせず、自動化が比較的容易である。そこで本研究ではセンサのON/OFF情報を中心としてADLモデルの自動生成を試みる。

### 2.2 ADLモデル

本研究では図1のようなADLモデル（状態遷移ネットワーク）を自動生成する人工知能を提案する。このADLモデルは、被介護者が過去に操作した対象物の情報を平均操作時間  $\bar{T}$ 、操作時間の分散  $\sigma$ 、状態遷移回数  $N$ 、状態遷移確率  $p$  などとして記憶しており、人工知能により随時更新される。住宅に取り付けられるセンサ数の増減や種類の違いによらずADLモデルを自動生成できることがこの人工知能の特徴である。

ADL model generate using online learning

<sup>†</sup>Iwate University

<sup>‡</sup>Icomes Lab. co., ltd.

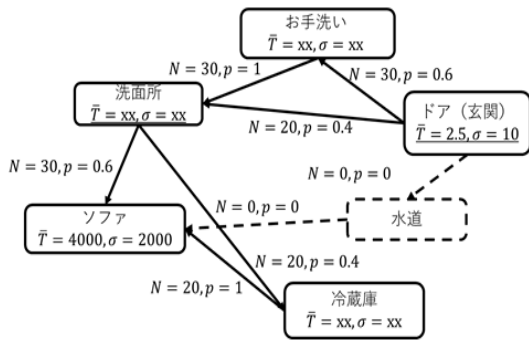


図 1: 提案 ADL モデル

から認知機能低下や情緒不安定のシグナルを自動的に検出・発報するために役立てることができると考えられる。

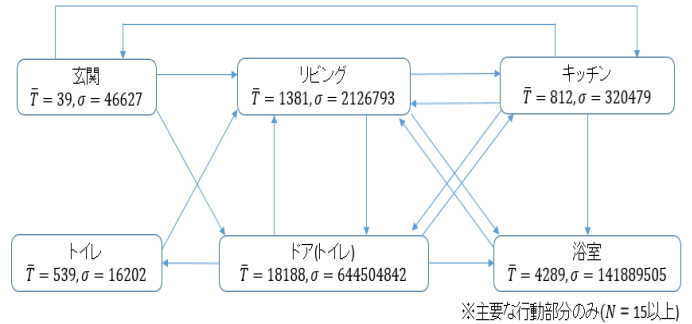


図 2: 実験で生成された ADL モデル (単位:秒)

### 3 実験

#### 3.1 実験内容

提案法の実現性や有用性を検証するため、実際に被験者のご自宅をお借りし、リアルタイムに ADL モデルの生成を行った。実験終了後、本実験により生成された ADL モデルがどのようなものだったかを解析した。被験者宅には人感センサを 3 つとドア開閉センサを 3 つ、データ取得用のノートパソコンを 1 台設置し、10 日間ほど実験を行った。

#### 3.2 実験結果

本実験より、図 2 のような ADL モデルの自動生成に成功した。この結果より、リアルタイムに変化する ADL に対して、鮮度の良い ADL モデルを生成できたと言える。また、ADL モデルから被験者の行動経路を把握することができ、各エリアの使用時間の平均・分散から被験者の日常生活の様子をうかがうこともできると考えられる。

また、表 1 は被験者の実験期間中のノード間の遷移確率(小数第 5 位以下は切り捨て)である。今回の実験期間中の遷移回数の合計に対するノード間の遷移確率を求めた。すると、今回の実験では被験者の動きとして最も確率の低い動きは玄関からトイレに向かうという動きであり、最も確率の高い動きはリビングからドア(トイレ)に向かうという動きであるということが分かった。このように、被験者が比較的取りやすい行動や取りにくい行動についても分析することができる。これらの結果から被介護者の動きをセンサでリアルタイムに観測し、ADL モデルを生成・更新することで、ADL モデルの鮮度を保ち、被介護者の ADL の唐突な変化

表 1: 被験者のノード間の遷移確率

Current\Next	Entrance	Bathroom	Door(Toilet)	Toilet	Living	Kitchen
Entrance	-	0.0030	0.0061	0.0010	0.0111	0.0203
Bathroom	0.0030	-	0.0111	-	0.0579	0.0132
ToiletDoor	0.0081	0.0152	-	0.0162	0.1688	0.0152
Toilet	-	0.0020	0.0091	-	0.0162	0.0040
Living	0.0061	0.0478	0.1719	0.0020	-	0.1688
Kitchen	0.0244	0.0172	0.0254	0.0122	0.1414	-

### 4 結論及び今後の展望

オンライン学習を用いた ADL モデル生成手法を用いることで、鮮度の良い ADL モデルを生成することができることが分かった。また、本手法により生成・更新された ADL モデルは被介護者の ADL の唐突な変化から認知機能低下や情緒不安定のシグナルを自動的に検出・発報するために役立てることができると考えられる。今後の展望としては本手法を用いて ADL モデルを生成し、モデルの更新を行いながらも、ADL モデルと乖離した行動から発報の可否を判断する人工知能の開発に取り組みたい。