

見守りシステムの現状と課題

—IoTとしての位置付け—

沼尾 雅之

IoTを活用した医療介護改革と新しいサービスの創出が、Society5.0として提案されている。本解説では、見守りシステムをこの医療・介護IoTの中心システムとして捉え、その現状と課題について説明する。IoTでは、センサネットワークによるデータ収集、ビッグデータ解析、データ活用サービスのサイクルが回ることが重要である。そこで、まずIoTの観点から見守りシステムを位置付けし、そのうえで、データ収集については、生体情報取得のための多様なセンサ類を、データ解析としては行動認識のためのAI技術を、そして、データ利活用としては、介護度や孤独度の測定などの応用例について解説する。

キーワード：IoT, AI, ビッグデータ, 高齢者見守り, Society5.0, 日常生活行動

1. はじめに

超高齢化社会を迎え、IoTやAIを活用した医療・介護支援の普及が必要不可欠となっている。特に、自立した生活を送れるための健康寿命を延ばすための見守りシステムが注目されている。

総務省の人口推計によると、2010年に総人口1億2800万人のうち65歳以上の高齢者の割合は12%であったのが2025年には、総人口1億2066万人となり高齢者の割合は30%、2060年には総人口8674万人となり高齢者の割合は40%となる。高齢者の比率の増加は、少子高齢化、つまり出生率の低下と平均寿命の増加によるものであるが、われわれにとって重要なのは、平均寿命と健康寿命の差である。健康寿命は「医療や介護に依存しないで、自分の心身で生命維持し、自立した生活ができる生存期間の平均」と定義されており、2013年の健康寿命は、男性71.19歳、女性74.21歳、平均寿命は、男性80.21歳、女性86.61歳となっている。「健康ではない期間」とされる平均寿命と健康寿命の差は、男性9.02年、女性12.40年となっている。そして、「健康ではない期間」を生活するためには介護や支援が必要である。2013年の65歳以上人口は3202万人であり、そのうちの17.8%が要介護または要支援の認定を受けている。要介護者は、その程度に応じて、軽いほうから要支援1, 2, 要介護1~5に区分され、程度に応じた介護サービスを受けることができる。介護サービスは、居宅サービス、地域密着型サービス、施設サー

ビスの三つに分類される。施設サービスは、重度の要介護者向けであり、特別養護老人ホーム（特養）や介護老人保健施設（老健）などがあるが、いずれも入居希望者に対して絶対数が不足しており、たとえば平成25年での特養入居待ちの要介護者数は52万人と言われていて、深刻な問題となっている。また、建物はできているのに、介護職員の不足で空床のままになっている施設もあることが報告されていて、介護職人材の不足もまた大きな問題となっている。こうした医療介護の問題を解決するために、内閣府、厚生労働省、経済産業省がさまざまな施策を講じているが、その中でも、IoTを活用した医療介護改革と新しいサービスの創出が、Society5.0として提案されている。

Society5.0は、平成7年に制定された「科学技術基本法」の5期目にあたるもので、IoTを活用した未来の産業創造と社会変革を目指す大胆な政策である。医療・介護分野においても、個々の問題を個別に解決するのではなく、各個人の生理データと、医療、介護現場のデータを統合、解析することによって、リアルタイムの生活支援、健康促進、最適治療、負担軽減を実現するような新しいサービスを創出するものである。なかでも見守りシステムは、センサ、知能・制御系、駆動系の三つの技術要素を統合したもので、介護ロボットとしても重要であるばかりではなく、医療・介護IoTにおける現実世界との接点デバイスとしても重要な位置付けを占めている。

本稿では、見守りシステムをこの医療・介護IoTの中心システムとして捉え、その現状と課題について説明する。IoTではデータ収集、データ解析、データ利活用のサイクルが回ることが重要である。以下では、

ぬまお まさゆき
電気通信大学情報理工学研究所
numao@cs.ucc.ac.jp

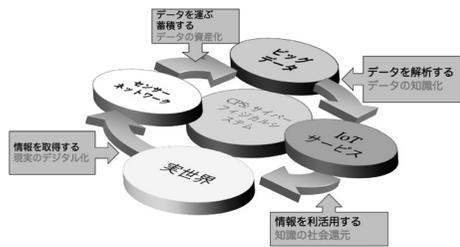


図1 IoTによる実世界とサイバーワールドの連携

データ収集のための多様なセンサ類，データ解析のためのAI技術，そして，データ利活用として，見守りの応用例について説明する。

2. IoTと見守りシステム

2.1 IoTの医療・介護応用

IoTは，現実世界とサイバー空間を結び付けた新しいビジネスを創出するものとして期待されている．図1のように四つのステップから構成される．

- (1) 実世界情報の取得：さまざまな種類のセンサによって，現実の情報をデジタル化して情報通信可能なデータとする．
- (2) データの集約：すべてのセンサがネットワークに接続されることによって，世界中のデータがビッグデータとしてどこでも利用可能になる．
- (3) データの解析：ディープラーニングなどのAI技術を駆使して，ビッグデータから知識を抽出する．
- (4) 知識の利活用：得られた知識を単に分析するだけでなく，積極的に活用して新しいサービスを提案し，社会にフィードバックする．

今までの狭義のIoTが(1)(2)だけで，データ分析を主な目的としていたのに対して，広義のIoTでは，より(3)(4)に重点を置いて，AIを活用した新しいサービスを提案し，ビジネスを創出することによって，社会を変革することを目的としている．

医療・介護に当てはめると，実世界データとしては，医療・介護現場のデータ，環境情報，医療情報を共有データとして，センサネットによって得られる個人ごとのリアルタイム生理計測データを収集する．これを医療・介護ビッグデータとして解析することによって，以下のようなサービスを実現することを提唱している¹．

生活支援：「ロボットによる生活支援．話し相手などにより一人でも快適な生活を送ること」

健康促進：「リアルタイムの自動健康診断などでの健

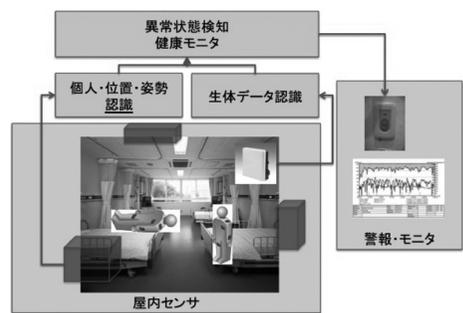


図2 見守りシステム

- 健康促進や病気を早期発見すること」
- 最適医療：「生理・医療データの共有によりどこでも最適な治療を受けること」
- 負担軽減：「医療・介護現場でのロボットによる支援で負担を軽減すること」

2.2 見守りシステムの位置付け

図2に見守りシステムのプロットを示す．IoTフレームワークから見守りシステムを捉えると，まず，屋内環境に設けられたセンサやウェアラブルセンサなどから，個人ごとのバイタルサインなどの生体データを計測するセンサ端末としての機能，そして，収集したデータを解析することによって行動認識や健康状態を認識する知識処理機能，さらに得られた認識結果を基に，健康状態の表示や転倒の警報を鳴らすようなフィードバック機能を兼ね備えていることがわかる．さらに，転倒や梗塞などの緊急事態を検知して対応することを考えるとリアルタイム性も必要となる．つまり見守りシステムは，自動運転システムなど同様のリアルタイムシステムとして設計する必要がある．

そこで，図3に示すようなUMLのユースケースを使って見守りシステムをより詳細に定義する．ユースケース図を用いるメリットは，システムが制御できない外部システムと開発すべきシステムの境界を明示することで，外部システムとの相互作用が明確化されることである．

見守りシステムの外側に位置付けられる外部アクタとして，以下の五つが定義される．

- (1) 利用者 (左上)：見守りシステムの利用者であり，介護関係者，医療関係者，家族などである．
- (2) エンジニア (左下)：見守りシステムをカスタマイズしたり，認識モデルやセンサの構成などを定義する人である．
- (3) 居住者 (右上)：見守りシステムの観察対象者であり，この人の行動や健康状態をモニタすることが

¹ https://www8.cao.go.jp/cstp/society5_0/index.html

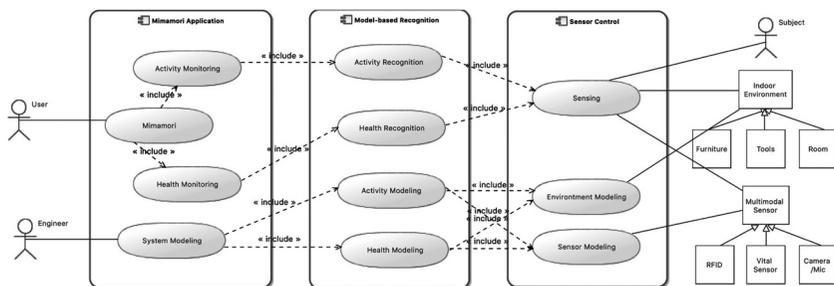


図 3 見守りシステムのユースケース図

目的である。

- (4) 居住環境 (右中) : 居住者の環境としての, 家具, 部屋, 道具などである. 多くの行動は, 居住者と居住環境との相互関係で定義されるため, 居住環境も観測対象となる. たとえば「座る」という動作は椅子と人との相互関係で決められるものである.
- (5) センサ (右下) : センサを外部アクタとしておくことによって, 複数のセンサを環境や機能に応じて自由に設置できることを想定している.

次に, 見守りシステム自体は, 三つのコンポーネントから構成されている. 左が見守りアプリ部, 中が行動認識部, 右がセンサ制御部となっている. データの流れとしては, 右側から左側に流れる中で, データ収集, データ解析, データ利用という IoT のサイクルに対応している. また, それぞれのコンポーネントにおいて, 上半分のユースケースはデータ処理, 下半分はシステムの設定あるいは事前準備となっている. 上半分では, 「誰がいつどこで何をしている」という見守りに必要な行動認識をすることが基本である. 一方, 下半分では, システムを運用する前に, エンジニアが見守りシステムをカスタマイズしたり, 行動や健康状態を定義したり, センサや屋内の状況を定義することによって, データの収集や解釈が可能になって, 期待どおりの運用ができるようになる.

2.3 見守りシステムの課題

見守りシステムは, IoT のサイクルの中での居住者データ収集, データ解析, データ応用の三つが揃うことによって初めて, 運用する人にも利用する人にとってもメリットのあるシステムとなることを考えると, 現状では以下の課題がある.

- (1) 単一機能・単一センサ : 製品レベルの見守りシステムでは, 機能を起床検出や動き検知などに限定し, フットスイッチや赤外線センサなど単一のセンサだけに頼ったシステムが多く, 発展性に欠け, コスト高になっている.

- (2) 低機能 : (1) にも関連するが, 見守りの目的が転倒予防や在室チェックなどに限定されており, 見守り本来の目的である Quality of Life の向上に活かされていない. これは, データ解析部が貧弱で, 十分な行動認識ができないことによる.
- (3) 低データ利用 : せっかく収集した居住者データが単一目的である転倒検知や在室チェックだけに使われている. ビッグデータとして共有化して解析すれば, 高齢者行動パターンのような有益な知識となる可能性がある. もちろん, データ共有化に際しては, 非特定・非識別化などによって, プライバシー保護をする必要がある.
- (4) 個別開発 : 施設設置型の見守りシステムでは, 施設ごとに一から設計・開発が必要となり, コスト高になっている. また, 施設ごとに居住者記録などのデータを管理する必要があり, 共有化やセキュリティの問題もある.

3. 見守りシステムのセンサ

見守りシステムの生データ入力手段であるセンサの選択と組み合わせは非常に重要である. センサを技術的に大別すると, 画像カメラ系, 音声マイク系, 非画像センサ系, 通信デバイス系に分けられるが, センサごとに得意分野が異なるため, 見守りの用途に合わせて, 最適なセンサの組み合わせでシステムを設計することが重要となる. 図 4 は複数のセンサをマイコン (Raspberry Pi) 上に接続したシステムの実装を示している.

3.1 画像系センサ

画像系センサは, CCD イメージセンサを用いたビデオカメラが代表である. カメラ画像からの 2 次元画像処理によって, 見守りに必要な個人認識, 行動認識, 位置認識などが可能であり, 一つのカメラを設置することによって, 複数種類のセンサと同等の能力が得られる. 一方, 夜間や睡眠中については, 補完するための

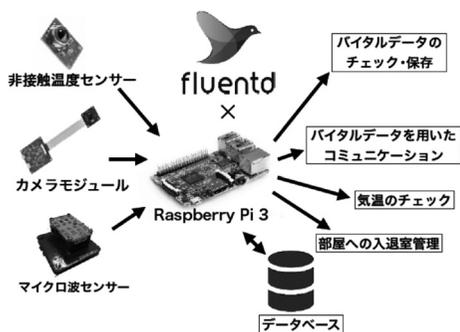


図 4 見守りシステムの実装

別のセンサが必要である。一方、見守り目的以外の情報まで取れてしまうために、プライバシーの観点から、ほかの専用センサに比べると、使用には注意が必要である。あえてシルエット画像などに変換するなどして、プライバシーに配慮した機器も提案されている。見守りでは、人認識および顔認識が重要であるが、openCVなどの画像処理ライブラリが充実しており、簡単なプログラミングで実装することができる。カメラ基盤に個人認識と表情認識をパッケージした製品もでてい

また、Kinect など、赤外線レーザーを用いて、深さ情報を加えた3次元画像が取得できるものや、サーモグラフィーなど2次元温度分布が取得できるものもあり、画像処理技術と組み合わせることによって、高性能の見守りが実現できる可能性がある。

3.2 音声系センサ

音声については、咳やいびきなどの非話音声は、健康状態を判定するために重要である。環境音や生活音などから、行動認識する研究もされている。一方、画像と同様に、通常の会話音声もとれてしまうために、プライバシーに配慮した使用が必要である。

3.3 ウェアラブルセンサ

ウェアラブルセンサの代表的なものとして加速度センサがある。腕時計型やスマホに搭載された3軸加速度センサのデータを用いて、それを保持している人の行動認識をするものである。光学式心拍計によって腕から心拍を計測できるものもあり、体動と心拍を組み合わせることによって、睡眠段階の推定もできるようになっている。

3.4 マットセンサ

ベッドに敷くマットレス型センサは、無負荷・無侵襲で睡眠状態を認識するのに最適である。感圧センサ自体は、半導体圧力センサや光ファイバーの回折現象を用いるものなどがあるが、たとえばピエゾ型の半導体圧力センサでは、数 mg レベルの感度をもって、

その上に横たわった被験者の圧力変化の波形データから心拍数、呼吸数、体動などの生体情報を取得することができる [1]。

3.5 超音波センサ

マイクロ波ドップラーセンサは、2.4~24 GHz のマイクロ波を対象物に照射し、その反射波が対象物の動きに応じて揺らぐドップラー効果を測定することによって、対象物の動きを認識する。従来型のセンサと違い、観測対象者は何ももつ必要がなく、リモートに対象者の状態をモニタすることができるため、完全に無負荷・無侵襲のセンサとして注目されている。

原理的には、FFT によって体動波形データを周波数解析することによって、振幅が微小のために埋もれている呼吸、心拍周波数成分を抽出する。呼吸、心拍の帯域は、それぞれ 0.2~0.8 Hz, 0.8~1.5 Hz であることから、これらの周波数帯だけ通すバンドパスフィルターを構成することにより、呼吸数、心拍数などの生体情報を取り出すことができる。

3.6 RFID

RFID タグが軽量、低コスト、そしてバッテリーが不要な受動的センサであることであることを利用して、居住者のパジャマやスリッパなどに装着することで、無負荷センサとして使用することができる。布片にパッケージされたリネン型タグもあり、アイロンなどで簡単に着物に装着でき、洗濯しても大丈夫である。

RFID という名前のおりユニークな ID を識別できるという利点もあり、これは、特に複数の人が出入りするような病院などの施設での対象者の識別に適している。また、受信電波強度 (Received Signal Strength Indicator, RSSI) を利用することで、位置・姿勢認識に用いる研究もされている [2]。また安価軽量というタグの特性を活かして、屋内のあらゆるものにタグを装着して、その位置や動きをモニターする Dense Sensing を用いたスマートハウスも提案されている [3]。

3.7 Wi-Fi

最近では誰もがもっているスマートフォンに常備されている Wi-Fi 機能を利用した位置測定や行動認識も研究されており、介護スタッフ用のセンサとして利用することが考えられる。位置測定は、アクセスポイントと端末間の通信における RSSI を測定することで行われる。たとえばアクセスポイント 3 か所との間の RSSI が測定できると三点測定の原理で端末の位置が特定される。最近では位相情報も用いることによって 10 cm レベルの精度で測位ができるという報告もされている [4]。

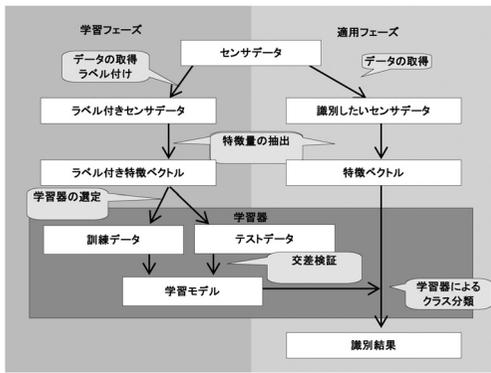


図5 機械学習フレームワーク

4. AI による行動認識

多種多様なセンサから得られた生データから、見守りが必要となる「誰がいつどこで何をした」という形に変換するのがデータ解析部である。より具体的には、日常生活行動 (Activities of Daily Living, ADL) 認識と言われ、起床から、整容、着替え、食事、排泄、入浴などの行動を認識することである。見守りシステムの頭脳とも言えるものであり、AI を活用した、いくつかのアプローチについて紹介する。

4.1 機械学習型行動認識

センサデータからの行動認識の研究は数多くあるが、機械学習を用いた認識方法が最も活発に研究されており、それらは図5に示すような機械学習の一般的なフレームワーク [5] に従っている。これは、以下に示すように、加速度センサに限らず、波形データを含む時系列データを生成するようなセンサすべてに適用可能なものである。

- (1) センサデータを収集しながら、分類すべき行動を含むさまざまな行動を実際に行って、センサデータに行動ラベルを付与する。これが教師データとなる。
- (2) センサデータから特徴ベクトルを算出する。具体的には波形データを、窓幅と言われる時間間隔で区切り、そこから複数の特徴量を計算して特徴ベクトルとする。
- (3) 正解のラベル付きの特徴ベクトルを、訓練データとテストデータに分割する。交叉検証では、分割の組み合わせを複数生成する。
- (4) 学習器に訓練データを入れて学習させ、学習モデルを得る。そして、テストデータによって学習モデルを評価する。混合行列 (Confusion Matrix) などを用いて、正解ラベルに対する適合率や再現率

表1 機械学習の精度 (平均適合率) 比較 [6]

	Setting 1	Setting 2	Setting 3	Setting 4
Bayes	98.86	96.69	89.96	64.00
SVM	98.15	98.16	68.78	63.00
kNN	98.15	99.26	72.93	49.67
DT	97.29	98.53	77.95	57.00

の評価を行う。

- (5) 評価が不満足の場合には、特徴量の選び方を変えたり、学習器を別のアルゴリズムに変えたりして、再学習と評価を繰り返す。
- (6) 評価が満足の場合には、得られた学習モデルを適用フェーズに用いて、未知のセンサデータに対して分類を行う。

Ravi らは、このフレームワークに基づいて、「歩く」「立ち上がる」「歯を磨く」など日常的な8種類の行動を認識する実験を行っており、評価法も含めてこの分野の研究の標準的な方法となっている [6]。センサデータとしては、ウェアラブルセンサとして3軸の加速度データを使っている。特徴ベクトルとしては、窓幅を5.12秒間として、波形の平均、標準偏差、パワー、軸相関係数を用いている。学習アルゴリズムは、Bayes, SVM, k 近傍法 (k NN), 決定木 (DT) の4種類を用いて比較している。さらに、訓練データとテストデータの選び方を以下の4種類で評価している。

- Setting 1: 被験者1人の複数日にわたる行動で訓練データとテストデータを作る。
- Setting 2: 複数被験者の複数日にわたる行動で訓練データとテストデータを作る。
- Setting 3: 被験者1人の1日の行動で訓練データを作り、同一人物の別の日の行動でテストデータを作る。
- Setting 4: 被験者1人の1日の行動で訓練データを作り、ほかの被験者の別の日の行動でテストデータを作る。

この結果を表1に示す。Setting 1, 2では高い認識精度がでているが、Setting 3, 4で低下している。特にSetting 4では悪い。これは、同じ行動でも、人によって動きに差があることを示している。しかし、見守りシステムの運用を考えると、居住者ごとに訓練データを集めるわけにはいかないので、Setting 4の状況に耐えられるような頑健な認識システムが必要である。

ここに機械学習型行動認識の課題が見えている。機械学習の認識率は、訓練データの質に大きく依存する。多くの人の行動をカバーするような訓練データが用意

表 2 オンライン学習の混合行列 (上は未知概念学習, 下は既知概念拡張)

Activity	Classified As											Accuracy Rate
	Sitting	Standing	Walking	Vacuuming	Blow-drying	Washing Hands	Brushing Teeth	Gargling	Speaking	Stairs Up/Down		
Sitting	37	0	0	0	0	0	0	0	0	0	0	1.0
Standing	0	21	6	0	0	0	0	0	0	12	0	0.53
Walking	0	0	55	0	0	0	0	0	0	2	0	0.96
Vacuuming	0	0	0	38	0	0	0	0	0	0	0	1.0
Blow-drying	0	0	0	0	40	0	0	0	0	0	0	1.0
Washing Hands	0	0	0	0	0	39	0	0	0	0	0	1.0
Brushing Teeth	0	0	0	0	0	0	39	0	0	0	0	1.0
Gargling	0	1	0	0	0	0	0	23	0	0	0	0.96
Speaking	0	0	0	0	0	0	0	0	40	0	0	1.0
Stairs Up/Down	0	3	0	9	0	0	0	0	0	116	0	0.91

Activity	Classified As											Accuracy Rate
	Sitting	Standing	Walking	Vacuuming	Blow-drying	Washing Hands	Brushing Teeth	Gargling	Speaking	Stairs Up/Down		
Sitting	42 (47)	0(0)	0(1)	0(0)	0(0)	0(0)	0(0)	0(0)	0(0)	0(0)	0(0)	1.0 (0.98)
Standing	0(0)	26 (34)	0(7)	0(0)	0(0)	0(0)	0(0)	0(0)	0(0)	0(0)	0(0)	1.0 (0.83)
Walking	0(0)	0(0)	45 (45)	0(0)	0(0)	0(0)	0(0)	0(0)	0(0)	0(0)	0(0)	1.0 (1.0)
Vacuuming	0(0)	0(0)	0(0)	47 (42)	0(0)	0(0)	0(0)	0(0)	0(0)	0(0)	0(0)	1.0 (1.0)
Blow-drying	0(0)	0(0)	0(0)	0(0)	39 (38)	0(0)	0(0)	0(0)	0(0)	0(0)	0(0)	1.0 (1.0)
Washing Hands	0(0)	0(0)	0(0)	0(0)	0(0)	39(39)	0(0)	0(0)	0(0)	0(0)	0(0)	1.0 (1.0)
Brushing Teeth	0(0)	0(0)	0(0)	0(0)	0(0)	0(0)	38 (35)	0(0)	0(0)	0(0)	0(0)	1.0 (1.0)
Gargling	0(0)	0(1)	0(0)	0(0)	0(0)	0(0)	0(0)	3 (13)	37 (0)	0(0)	0(0)	0.08 (1.0)
Speaking	19 (10)	0(0)	0(0)	0(0)	0(0)	0(0)	0(0)	0(0)	28 (24)	0(0)	0(0)	0.60 (0.71)
Stairs Up/Down	0(0)	1 (1)	35 (5)	0(0)	0(0)	0(0)	0(0)	0(0)	0(0)	17 (94)	0(0)	0.32 (0.94)

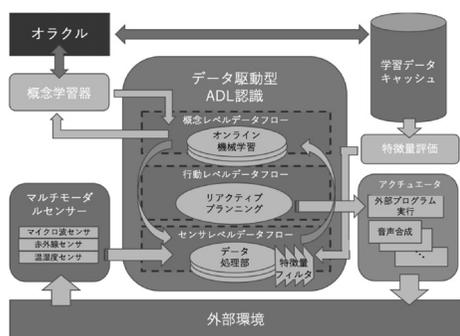


図 6 アクティブ・オンライン学習フレームワーク

できればよいが、それには莫大なコストがかかる。

4.2 オンライン学習型行動認識

通常の機械学習では、いったん学習モデルが決まり、適用フェーズに入ってしまうと、再学習のためにはシステムのバージョンアップなどが必要とされる。また、学習モデルは、学習時と同じ特徴ベクトルを用いないと、認識率が大きく低下してしまう。これは、見守りシステムの運用上、大きな障害となる。たとえば、センサの種類や台数が施設によって異なると、特徴ベクトルが異なってしまう、準備した学習モデルは使い物にならなくなる。また、特徴ベクトルが同じとしても、たとえば設置型センサで、その位置や向きが変わっただけでも認識率が低下してしまう。このようにセンサの設置環境の違いに頑健なシステムが必要である。

その解決法の一つが、オンライン学習である。オンライン学習では、従来のバッチ型学習とは違い、訓練データが流れてくるごとに学習モデルをアップデートする。大石らは、図 6 に示すようなアクティブ・オンライン学習フレームワークを提案している [7]。図の左側にセンサ、右側にアクチュエータが配置され、中央がデータ処理部になる。左側からきたセンサデータは、

中央下側に流れ込み、ここで時系列データから特徴ベクトルの抽出が行われる。そして中央上部の機械学習器によって行動認識され、その結果によって中央真ん中でプランニングされた結果のアクションが右側のアクチュエータで出力される。

複数のセンサが搭載され、カメラによる顔認識、表情認識、サーモメータによる体温測定、マイクロ波センサによる心拍・呼吸測定ができる。またアクチュエータとしては、音声合成による発声とデータベースに対する記録などができるようになっているが、従来の見守りと異なるのは、複数のセンサによる条件を統合したシナリオが記述できることである。たとえば、朝、山田さんが笑いながら起きてきたら、「おはよう、山田さん、ごきげんよう」と呼びかけて、同時に山田さんの起床時間、および心拍、呼吸、体温のバイタルデータを記録し、集計サーバに送るようなことをシナリオとして記述できる。

ここで、居住者が何をしているかという ADL 認識の過程において、既存のクラスに分類できないデータが流れてきた場合に、図左上の新概念学習器がオラクルにクエリを送信し、対応する行動ラベルをオラクルから受け取る。ここでオンライン学習手法を適応してリアルタイムで学習モデルを更新し、新しい概念の獲得あるいは既知概念の拡張を行う。このように、適用フェーズで未知データを訓練データに転用して再学習させるところが通常のオンライン学習と異なる点である。

オラクルから受け取ったラベルが既存クラスに存在しないものだった場合、候補クラスに受け取ったラベルが追加される。すでに既存クラスに存在するものだった場合は、対応するクラス概念が拡張される。ここで、オラクルとは、正解を与えるプロセスのことを指し、たとえば、見守りシステムの運用中に、クラス判

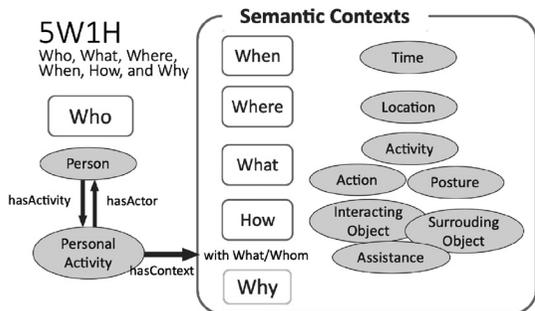


図7 行動オントロジー

定のできないデータがきたときには、システム管理者に通知が行って、管理者から正解を得るような方法が考えられる。表2の上は初期5クラス standing, sitting, walking, cleaning, blow-drying を分類するモデルを作成し、次に新5クラスとして、stairs up/down, washing hands, brushing teeth, gargling, speaking の動作に対して新たに概念獲得できるかを検証したものであり、下は合計10クラスの動作を、訓練データ時とは異なる人に対して、行動認識をしたときのオンライン学習結果を示す。カッコ内がオンライン学習後の結果である。これは、4.1節のSetting4に対応するものであり、居住者が変わった場合でも素早く再学習ができることを示している。

4.3 モデルベース行動認識

機械学習は、行動ラベル付きの訓練データが必要であり、これを認識すべきクラスごとに用意しなければならない。また、得られた学習モデルは、訓練データ作成時の環境や人に依存していて、ほかの環境や人に対しては十分な性能が得られない場合が多い。これに対して、認識用の知識を予めオントロジーなどの知識表現法を使って記述し、論理推論によって行動認識をするモデルベース型行動認識が提案されている [8]。見守りシステムが認識対象とする ADL は、人の動きだけではなく、人を取り巻く環境との関係で定義されるものが多い。たとえば、「歯磨き」は洗面所で、歯ブラシとコップを持って、立ちながら、手を動かす行動である。これを人の動作だけで学習させるのは無理であり、場所、道具、姿勢と動きの関係で記述し、認識すべきであるという立場である。機械学習型行動認識が、与えられたセンサデータから何とか行動認識させようというボトムアップ型に対して、モデルベース型は、まずは行動の定義をトップダウン型で行う方法である。

大石らは、センサデータからは場所、道具の利用、姿勢、低レベルの動作の認識だけにとどめ、上位のADL認

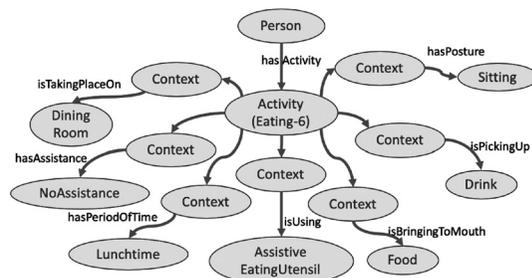


図8 食事オントロジーのクラス関係

識はモデルベースで行う方法を提案している [9]。ADL記述は W3C で定められたオントロジー言語 OWL で定義している。図7に行動オントロジーを記述するための基本クラスを示す。ADLを「誰がいつどこで何をどのようにした」という5W1Hで記述する。まず、人(Person)と行動(Personal Activity)の間の関係が規定され、さらに行動を特化するものとして、いつ(Time)どこで(Location)何が(Activity)どのように(Posture, Interacting Object, Surrounding Object, Assistance)行われたかを規定する。これらの行動を特化するための状況をコンテキストクラス(Semantic Context)として、この情報はセンサデータなどから得られるとしている。たとえば、「食事をする」のオントロジーを図8に示す。ここで、コンテキストと実際の場所や時間や道具や姿勢との関係を「～の場所で(isTakingPlaceOn)」、「～の時間帯で(hasPeriodOfTime)」、「～の道具を使って(isUsing)」、「～の姿勢で(hasPosture)」といったオブジェクト属性を用いて定義している。

5. 見守りシステムの応用

ここでは、見守りの基本機能としてのADL認識ができたうえでのより高度な応用についての事例を紹介する。

5.1 機能的自立度の自動測定

機能的自立度(Functional Independence Measure, FIM)は、居住者が日常生活を過ごす中で、介助なしでできる度合いを示す客観的な指標である。図9に示すように、運動13項目と認知5項目の計18項目で採点される。各項目7点満点で、完全自立が7点、完全介護が1点となる。自立度と介護度は正負の関係でもあるので、自立度を測定することによって介護度の認定にも用いることができる。FIMと同様に自立度を計測する尺度としてバーテル指標(Barthel Index, BI)というものもあるが、BIが、インタビュー形式で本人の

運動項目				認知項目	
セルフケア	排泄	移乗	移動	コミュニケーション	社会認識
食事 整音 清拭 更衣(上半身) 更衣(下半身) トイレ動作 排泄コントロール 排泄コントロール ベッド・椅子・車椅 トイレ 浴槽・シャワー 歩行・車椅子 階段				理解・聴覚・視覚 歩山(歩行・歩行器)	問題解決 社会的交流 記憶
計42~6点	計14~2点	計21~3点	計14~2点	計14~2点	計21~3点
運動項目 計91~13点				認知項目 計35~5点	
合計 126~18点					

図9 機能的自立度 [10]

自己申告に基づくものに対して、FIMは実際の行動を観察することで判定される。したがって、FIMは見守りシステムによるADL認識からの計測に適した指標である。

大石らはADL認識を応用して、FIMの自動計測システムを提案している[9]。FIM項目の中の排泄を除く運動項目と、社会認識を除く認知項目を自動採点する。FIMの採点法自体もオントロジーとして知識化している。たとえば、食事4点は「細かい食物をつかもうとするとときに補助を必要とする」であり、食事2点は「介助者が常に手を取って食事をつかんで口元に運ぶ必要がある」であるが、オントロジーでは介助者や介助道具の介在と、介助の度合いが「食事」クラスのオブジェクト属性として記述される。また、実際のセンサーデータからは、食事の際に、居住者と介助者が一緒にいた時間の割合や、介助道具の存在などがわかり、そこから「食事X点」というクラスが推論される。

5.2 社会的孤独度の判定

身体的衰退、配偶者との離別、社会的地位の喪失などの生活環境変化によって引き起こされる、高齢者の社会的孤立が問題になっている[5]。社会的孤立は廃用症候群、精神的抑うつ、自殺などの深刻な結果を招く危険があるために、早めに気づきケアすることが必要である。

永間らは、高齢者が日中とる行動と、社会的孤立には相関関係があることから、ADL認識を応用して孤独度を測定することを提案している[11]。まず、孤独度を物理的孤独度、精神的孤独度、社会的孤独度の3次元の量として定義する。そしてADLの行動項目について、それが、いつ、どこで、誰と行われたかによって3軸の点数づけを行う。たとえば、「食事」という行動に対しても、1人寝室で食事した場合、食堂に行った場合、さらに食堂で友人と話しながら食べた場合で異なる採点がされる。このように、ADL上では一つの行動ラベルに分類される場合でも、それが場所の移動を伴う場合には物理的孤独度に反映され、発話や表情

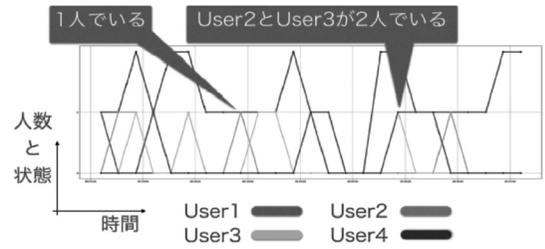


図10 談話室における同席状況

の変化を伴う場合には精神的孤独度、他人との同席や会話を伴う場合には社会的孤独度に反映されるように採点方法が定義される。

実験では、実際に老人ホームの食堂や談話室などに見守りロボットを設置して、共用スペースを訪れる高齢者の頻度と、そのときの表情やバイタルサインなどを記録した。図10は、談話室の利用状況を示すものである。誰がいつ誰と談話室で過ごしていたかがわかり、社会的孤独度測定的基础となる。

6. おわりに

超高齢化社会におけるさまざまな問題を解決するために、見守りシステムの開発と利用は必要不可欠である。本解説では、見守りシステムを単に介護業界における負担軽減のためだけでなく、IoTを活用したSociety5.0における医療・介護分野の社会改革のための中心システムとして位置付けて理解してもらえることを試みた。

IoTでは、インターネットレベルでのデータ収集、データ解析したうえでデータの活用を新しいサービスとして提案することが求められている。見守りデータについても、個人から収集したデータを、その個人の見守りに用いるだけでなく、施設や国レベルで共有することによって、生活支援、健康促進、最適治療、負担軽減のための知識を抽出して、新しいサービスに結び付けられるかが問われている。本稿がそのための一助となれば幸いである。

参考文献

- [1] K. Takadama, K. Hirose, H. Matsushima, K. Hattori and N. Nakajima, "Learning multiple band-pass filters for sleep stage estimation: Toward care support for aged persons," *IEICE Transaction on Communications*, **E93B**, pp. 811-818, 2010.
- [2] M. Numao and S. Masuda, "Non-restrictive continuous health monitoring by integration of RFID and microwave sensor," In *Proceedings of AAAI Spring Symposium*, pp. 396-402, 2016.
- [3] D. Fortin-Simard, J.-S. Bilodeau, K. Bouchard, S.

- Gaboury, B. Bouchard and A. Bouzouane, “Exploiting passive RFID technology for activity recognition in smart homes,” *IEEE Intelligent Systems*, **30**(4), pp. 7–15, 2015.
- [4] D. Vasisht, S. Kumar and D. Katabi, “Decimeter-level localization with a single WiFi access point,” In *Proceedings of the 13th USENIX Symposium on Networked Systems Design and Implementation*, pp. 165–178, 2016.
- [5] N. Biccocchi, M. Mamei and F. Zambonelli, “Detecting activities from body-worn accelerometers via instance-based algorithms,” *Pervasive and Mobile Computing*, **6**, pp. 482–495, 2010.
- [6] N. Ravi, N. Dandekar, P. Mysore and M. L. Littman, “Activity recognition from accelerometer data,” In *Proceedings of the National Conference on Artificial Intelligence*, **20**, p. 1541, 2005.
- [7] N. Oishi and M. Numao, “Active online learning architecture for multimodal sensor-based ADL recognition sense of community in nursing home,” In *Proceedings of AAAI Spring Symposia*, pp. 259–266, 2018.
- [8] S. Zhang, P. McCullagh, C. Nugent and H. Zheng, “An ontology-based context-aware approach for behaviour analysis,” *Activity Recognition in Pervasive Intelligent Environments*, pp. 127–148, 2011.
- [9] N. Oishi and M. Numao, “Measuring functional independence of an aged person with a combination of machine learning and logical reasoning,” In *Proceedings of the AAAI Spring Symposia*, 2019.
- [10] 厚生労働省, 「日常生活動作 (ADL) の指標 FIM の概要」, <https://www.mhlw.go.jp/file/05-Shingikai-12404000-Hokenkyoku-Iryouka/0000184198.pdf> (2019 年 4 月 1 日閲覧)
- [11] S. Nagama and M. Numao, “IoT-based emotion recognition robot to enhance sense of community in nursing home,” In *Proceedings of AAAI Spring Symposia*, 2018.