

# 生活環境でのデジタルツインを用いた最適センサ位置推定の提案

## Proposal for optimal sensor location estimation using digital twin in living environment

池野 敦哉<sup>†</sup> 松井 智一<sup>†‡</sup> 諏訪 博彦<sup>†‡</sup> 安本 慶一<sup>†‡</sup>  
Ikeno Atsuya Matsui Tomokazu Suwa Hirohiko Yasumoto Keiichi

### 1. はじめに

近年, IoT デバイスの普及により, 生活のあらゆる場所にコンピュータが存在するユビキタス情報技術が進展している. その中で, 次世代の住宅として, あらゆる家電をネットワークに接続し, 集中的に自動化・制御ができるスマートホームが注目されている. より利便性の高い住居を実現するために宅内の住人の行動分析やそれに関する研究が盛んに行われており, 省エネ家電制御 [1] や高齢見守りシステム [2][3] など生活を支援するサービスへの応用が期待されている. これらのサービスを提供するためには多種多様な人間の生活行動を正確かつ安価に認識することが重要である. 人間の行動認識には様々なセンサを用いた研究があるが, センサの位置について検討しているものは少ない. そのため, 設置者によって認識精度が左右される可能性がある. 行動認識の知見がない人でも効率的なセンサ配置を見つけられるようにシミュレーションできるツールを開発することには大きな意義がある.

本研究では屋内生活行動を高精度かつ低コストで認識できる最適なセンサ配置を検証できるデジタルツイン環境を構築する. その後, LLM (Large Language Model) を利用して自律的に行動するエージェントをデジタルツイン内に配置することでコンピュータ上で行動認識のためのセンサの配置をシミュレーションできるツールについて検討する. LLM とは大規模言語モデルのことであり, 近年著しく発展を遂げている分野の一つである.

宅内行動認識分野では, カメラやマイクを用いたものや人感センサや接触センサを用いたものが提案されている. カメラやマイクを用いたシステムは, 取得できる情報量が多いため, 人物の行動を高精度に検出できる. しかし, 宅内の住人に対しては常に監視されている感覚を与え, プライバシー保護の面でも望ましくない [4]. 一方, 人感センサや接触センサを用いたシステムは取得できる情報量が少ないため, 宅内の住人のプライバシー保護には適しているが, 多くのセンサを設置する必要がある, 設置や維持コストが高くなる.

本提案では, 宅内の環境をサイバー空間上に高精度で

再現するデジタルツインを用いることで設置コストを最小限に抑える手法を検討する. デジタルツインとは現実世界から収集したデータをコンピュータ上で再現する技術のことを指す. 実際のスマートホームで行動認識を行う前に, コンピュータ上で再現された宅内環境を利用して, センサが目的の動作を認識できる配置になっているかをシミュレーションすることで, センサが目的の行動を認識できる配置を効率よく推定できる. また, 実際に住居内にセンサを配置した際にセンサの反応をコンピュータ上で可視化することにより, 行動認識の効率化を図る.

実空間での行動認識の実験だけでなく, デジタルツイン上で行動認識を行うことで, 設置コストや実験コストを大幅に削減できる. デジタルツイン上で行動認識を行うためには, 自律的に行動するエージェントを作成する必要がある. 自律的に行動するエージェントを作成する手法については LLM を用いたものが提案されている. [5]. 本提案では自律的に行動する機能として, 生成 AI を用いて行動予定を生成し, その予定に沿って行動できるエージェントのシステムを構築する.

本稿の構成は以下のとおりである. 2 章では, 宅内行動認識システムや LLM を用いたエージェント生成についての既存研究を概説し, 関連研究の課題を述べるとともに本提案の位置づけを述べる. 3 章では提案する生活環境でのデジタルツインの構築手法について説明し, 4 章では提案したデジタルツイン環境による行動認識の評価と実験計画についてを説明する. 最後に, 5 章では本稿の結論と今後の展望について述べる.

### 2. 関連研究

本章では, 宅内行動認識システムに関する既存研究で使用されているセンサについて取り上げる. また, LLM を用いたエージェント作成の既存研究を概説し, 本提案の位置づけを明確にする.

#### 2.1 宅内行動認識システム

居住者に異常検知や生活支援を提供することを目的とした行動認識には様々な機器を用いた研究がある. Bianchi ら [6] は, 居住者が着用しているウェアラブルデバイスの慣性データから居住者の 9 つの行動パターンを 95% 以上の精度で認識している. データの収集は, ベルトにセンサを装着した被験者が, 一般的な宅内行動につ

<sup>†</sup> 奈良先端科学技術大学院大学, Nara Institute of Science and Technology

<sup>‡</sup> 理化学研究所 革新知能統合研究センター, RIKEN AIP

いて事前に設定された順序で行うことにより集められている。しかし、高精度な行動データは「歩く」、「座る」といったユーザの姿勢に強く関連した行動しか認識できず、スマートホーム内における「睡眠」、「食事」などの行動認識は難しい。また、ユーザが常にデバイスを持続する必要がある、ユーザの負担が大きいという課題も存在する。

Annalisa ら [7] は、部屋に設置したカメラから取得した画像データと骨格を組み合わせて、機械学習法を用いることで多クラス行動認識を行い、98.8%の精度を達成している。訓練データおよび評価データは公開データセットである CAD-60 および CAD-120 を用いており、より一般的な宅内環境への拡張は、さらなる分析が必要と示されている。

Chen ら [8] は、接触センサ、圧力センサ、モーションセンサ、環境センサなどが多数埋め込まれたスマートホームにおいて、お茶を入れる、パスタを作る、テレビを見る、入浴する、手を洗うといったマイクロ生活行動を90%以上の正確さで認識するシステムを構築した。これは、知識ベースのオントロジーにより生活行動を識別しているため、機械学習を用いた手法のように事前に大量の訓練データを必要としないという利点がある。しかし、多種・多数のセンサを使っており、導入コストが高いという問題がある。

Matsui ら [9] は一般家庭においても行動認識技術を利用すべくプライバシーを考慮したセンシングシステムを提案している。非侵襲的なエナジーハーベスティングで動作するセンサとアノテーションボタンから構成されたこのシステムを用いてデータ収集を行い、「食事」「調理」「入浴」「睡眠」「外出」の5種類の行動について LSTM モデルで行動認識を行った結果として再現率で 72.3%の精度で識別している。

上記に挙げた既存研究のように行動認識の分野では様々な機器やセンサを用いて宅内行動認識の精度の向上を目指している。しかし、多くの研究ではセンサや認識の手法を工夫をしているが、センサの位置について深く言及しているものは少ない。これは、行動認識モデルは特定のスマートホーム環境に依存しない汎用的な手法を提案することを目指しているため、センサの位置に関する十分な議論はされてこなかった。しかし、センサの位置は行動認識の精度に大きく影響を及ぼす要素の一つである。センサ位置が適切でないと、不要なセンサが多く設置されることになり、全体的なエネルギー消費が増加する。また、不要なデータが増えることで、データ処理のコストも増加する問題がある。

## 2.2 デジタルツイン

VanDerHorn ら [10] は、一般的なデジタルツインを物理システムの仮想表現であり、物理システムと仮想システムの間で情報交換を通じて更新されるものと定義した。物理的現実・仮想表現・情報交換の3つの主要要素が連携し、物理システムと仮想モデルをリアルタイムで更新して最適な意思決定を支援するデジタルツインの基盤となる。

Zhang ら [11] は、デジタルツイン技術が様々な産業分野での応用についていかに重要であるかを示した。スマートホームの分野では、家庭内のデバイスやシステムのリアルタイムモニタリングと制御が可能となる。例えば、Zhang らは、スマートホームにおけるエネルギー管理の最適化にデジタルツインを活用することで、家庭内のエネルギー消費パターンを詳細に分析し、エネルギー効率を向上させる方法を提案している。自己持続型センサが、家庭内の様々な環境データを収集し、デジタルツインモデルに反映させることで、より正確な制御と予測が可能となる。しかし、リアルタイムにより常時監視されることに対するユーザのプライバシー保護の問題があり、カメラやマイクなどのプライバシーを侵害するような問題を解決する必要がある。

## 2.3 LLM ベースのエージェント

Park ら [12] は、LLM を拡張してエージェントの経験の完全な記憶を自然言語で保存し、時間とともにこれらの記憶を高次の反映に合成し、動的にそれらを取得して行動を計画するアーキテクチャを構築した。このアーキテクチャによって生成されたエージェントは人工の社会経済環境下でそれぞれが自律的に行動し、互いに影響を及ぼし合いながら社会的行動を行う。

エージェントは、観察、計画、反映の各コンポーネントを通じて一貫性のある行動を生成する [13]。エージェントは、観察したデータをもとに行動を計画し、計画に従って行動しながら、新たに観察した情報を記憶に追加する。これにより、エージェントは継続的に学習し、環境に適応することができる。

## 2.4 本研究の位置づけ

関連研究では様々な機器やセンサを利用した行動認識や LLM ベースのエージェントについてを明示した。行動認識の分野ではユーザ側にセンサを装着する負担やセンサ設置のコストについて課題がある。また、センサの位置を最適化について述べている文献の少ない点が問題点として挙げられる。デジタルツインでの問題点としては、リアルタイム監視やカメラやマイクによるプライバシー侵害の問題が挙げられる。

そこで本提案では、宅内環境を再現した 3D モデルにセ




図 1: システムの概要

ンサを自由に配置できるデジタルツインを構築し、LLM によって自律的に生活行動を行うエージェントを作成することでコンピュータ上でセンサの反応を確認できるシミュレーションシステムを提案する。使用する機器はカメラやマイクを用いず、人感センサや環境センサといったプライバシー侵害の少ないセンサを用いる。本提案は実際の住居にセンサを配置する前段階に配置の調整を行う。

### 3. 提案手法

本章では、まず図 1 に示す提案システムの概要について述べ、要件定義を行う。続いて、LLM による自律エージェントの自律行動システムについても検討を行う。

#### 3.1 提案手法の概要

本提案では、宅内環境での行動認識のためのセンサ配置を検討するシステムとして、ゲームエンジンである Unity を用いてデジタルツインを構築し、センサ配置を調整しながら行動認識のシミュレーションを行えるシステムを提案する。このシステムでは、実際に宅内環境での行動認識実験を行う前に、デジタルツイン環境で LLM ベースのエージェントを相手に行動認識のシミュレーションを行うことで、センサ配置の有効性を検証することができる。また、宅内環境で行動認識実験を行う際にも、このシステムを用いることで、ユーザの行動を検知しているセンサを可視化し、実験効率を高めることが可能である。

提案する手法は大きく 2 つの要素に分かれる。1 つ目は宅内環境のデジタルツインの構築、2 つ目は LLM エージェントの自律システムである。

#### 3.2 宅内環境のデジタルツイン

宅内環境としては図 2 に示すスマートホーム（奈良先端大内に設置されている 1LDK の実験用住宅設備）を 3D モデル空間としてコンピュータ上で再現する。図 3 に、実際のスマートホームと 3D モデルによるスマートホームの比較画像を示す。図のような実際の宅内環境のモデルを作成した後にセンサを再現する。デジタルツイン上で再現する主なセンサとしては、人感センサや環境

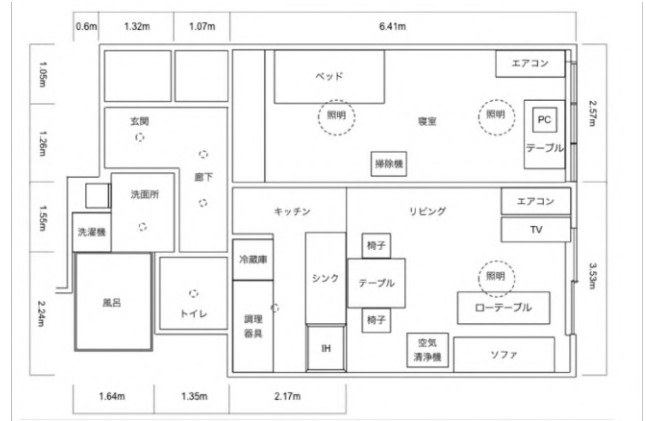


図 2: スマートホームの間取り



図 3: 宅内環境の比較（左：宅内環境 右：3D モデル）

センサ、振動センサなどのプライバシー侵害のリスクが低いセンサが挙げられる。

デジタルツイン上で動作するエージェントの動作によって、センサが反応するモデルについては今後の研究で構築する必要がある。このモデルは、人の位置や姿勢による人感センサの反応から仮想センサの反応モデルを作成する。

##### 3.2.1 人感センサ

人感センサとは、人を検知するセンサの総称であり、赤外線センサや超音波センサ、マイクロ波センサなどを指す。宅内で用いられるものとしては一般的に赤外線センサが用いられる。赤外線センサは周囲の温度と人間の温度差による赤外線の変化量を計測することで人を検知する。検知距離は約 5m ほどであるが、宅内環境の温度が高いと人体との温度差が小さくなるため検知距離が近くなる問題がある。

上記の理由から、設置位置の調整は非常に重要である。センサの設置場所を最適化することで、検知精度を最大化し、必要なセンサの数を最小限に抑えることが可能である。また、検知精度を上げるにはセンサが目的の生活行動時のみに検知するような配置を設定することも重要である。例えば、リビングでのテレビ鑑賞や、キッチンでの調理といった特定の部屋での特定の行動のみを検知するように配置することで、不要な検知を減らし、精度を高めることができる。

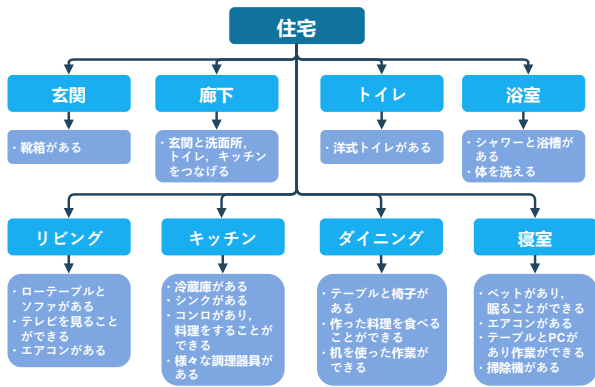


図 4: 自然言語による宅内環境のデータツリー構造

### 3.2.2 環境センサ

環境センサとは、周囲の温度、湿度、気圧など環境に関する情報を定量的に数値化するためのセンサである。これにより、宅内環境の状態を正確に把握し、行動認識の精度を向上させることが可能となる。環境センサのデータは、住人の行動や宅内環境の変化に応じたセンサ配置の最適化に役立つ。

### 3.3 振動センサ

振動センサとは、物体の振動を検知するセンサであり、加速度計やジャイロセンサを用いて物体の動きや振動を計測する。これにより、家具の使用状況や歩行時の振動を検知し、住人の行動を把握できる。振動センサは床や家具に設置されることが多く、「椅子に座る」「に横たわる」といった特定の動作を検知するのに有効である。

### 3.4 宅内環境データの反映

前述した人感センサや環境センサ、振動センサなど、周囲の環境によって検知距離や精度が変化するセンサには、実際の宅内環境のデータが必要である。このため、宅内環境のデータをデジタルツイン上に反映するシステムを構築する必要がある。これにより、仮想環境内でのセンサ配置のシミュレーションが現実の環境に近い形で行われ、検知精度やプライバシー保護の観点から最適なセンサ配置を決定することができる。

### 3.5 LLM エージェントの自律行動システム

LLM を用いた自律行動システムでは住宅設備のラベル付けと行動予定の生成に分けられる。

### 3.6 住宅設備のラベル付け

LLM エージェントが宅内で行動する際に、宅内環境を理解するためにはその環境をツリーデータ構造として表現し、自然言語で理解することが必要である [12]。図 4 に自然言語による宅内環境のデータツリー構造の例を示す。このデータツリーでは各部屋ごとに部屋の構成要素

### 初期計画を生成するためのプロンプト

**エージェント概要:**  
 名前: ジョン・スミス (年齢: 35)  
 特性: 整理整頓が好き、料理が得意、家族思い  
 ジョン・スミスは、妻と2人の子供と一緒に暮らしている。彼は家庭的で、家事や料理をこなすのが得意である。ジョンは、朝のルーティンや家事を効率的に行うことを重視している。

**前日の要約:**  
 昨日、ジョンは以下の行動を行った:  
 1. 午前6時に起床し、朝食を作った。  
 2. 午前7時に子供たちを学校に送り出した。  
 3. 午前9時から午前11時までリビングルームを掃除した。  
 4. 午後12時に昼食を作り、家族と一緒に食事をした。  
 5. 午後2時から午後5時まで庭の手入れをした。  
 6. 午後6時に夕食を作り、家族と一緒に食事をした。  
 7. 午後8時に子供たちを寝かしつけ、自分も午後10時に就寝した。

### 初期計画

**今日の計画:**  
 今日は2月13日です。ジョンの今日の大まかな計画は以下の通りです:  
 1. 午前6時に起床し、朝のルーティンを完了する(歯を磨き、顔を洗う、着替える)。  
 2. 午前7時に朝食を作り、家族と一緒に食べる。  
 3. 午前9時から午前11時までキッチンを掃除する。  
 4. 午前11時から午前12時まで書斎で読書をする。  
 5. 午後12時に昼食を作り、家族と一緒に食べる。  
 6. 午後3時から午後5時までリビングルームの模様替えをする。  
 7. 午後6時に夕食を作り、家族と一緒に食べる。  
 8. 午後8時に子供たちを寝かしつけ、自分も午後10時に就寝する。

### 詳細計画

**詳細な行動への分解:**  
 午前6時: 起床し、朝のルーティンを完了する。  
 ・午前6時: 歯を磨く  
 ・午前6時10分: 顔を洗う  
 ・午前6時20分: 着替える  
 午前7時: 朝食を作る。  
 ・午前7時: 冷蔵庫から食材を取り出す  
 ・午前7時10分: パンケーキを作る  
 ・午前7時30分: ジュースを準備する

図 5: 生成するプロンプト例

を自然言語で記述する。エージェントは、住宅のデータツリーと個別にある自分が現在観察している情報のデータツリーから自身の生活空間を認識する。

### 3.7 行動予定の生成

LLM エージェントは、自分の行動計画に基づいて宅内環境内を移動し、生活行動を行う。行動計画は大まかな日程から始まり、具体的な行動に分解される。エージェントは一日の概要を5~8のチャンクに分けて生成する。この初期計画は、エージェントの概要説明と前日の要約をもとに生成される。

大まかな日程が決まったら、それをさらに詳細な行動に分解する。例えば、「午前7時: 朝食を作る」という予定を、さらに細かい時間単位(1時間ごと)に分解する。その後、これらの1時間単位の行動を5~15分単位に分解する。生成するプロンプト例を図5に示す。エージェントは、生成した行動計画に従って行動するが、宅内環境やほかのエージェントとのインタラクションによって計画を動的に調整する。動的な計画の調整にはエージェントが観察した情報を最近性、重要性、関連性でスコアを付け、重要度が高い結果を取得した場合、再計画を行う。また、エージェントは、経験を基に高次の反映を行い、今後の行動計画に役立てる。これにより、過去の経



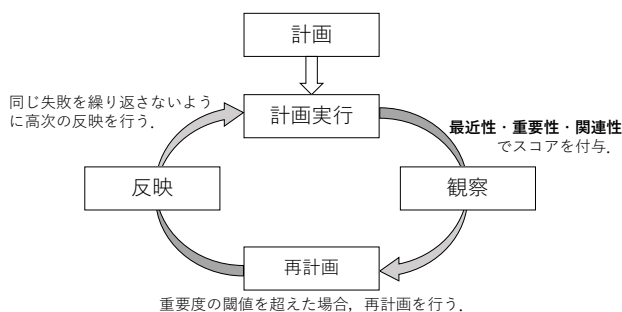


図 6: 動的な行動計画のシステム概要

験から学び、より適切な行動をとることができる [14]. 動的な行動計画のシステムを図 6 に示す。これらの手法により、エージェントは動的に行動計画を調整し、環境やほかのエージェントとの相互作用に柔軟に対応することができる。

以上により、エージェントの行動計画を生成することが可能になる。しかし、この手法では自然言語レベルの行動計画を生成するため、実際にエージェントを Unity 上で行動させるには自然言語からエージェントのアバターレベルでの動作を生成する機構が必要である。そのため、生成した自然言語ベースの行動計画によって、Unity 上のエージェントを行動させるシステムを今後検討していく。

## 4. 実験計画

本章では、提案システムの評価を行うための実験計画について述べる。実験は以下のステップで構成される。

### 4.1 実験目的

提案するデジタルツイン環境での最適センサ配置システムの有効性を評価し、センサ配置による行動認識の精度向上を確認することを目的とする。

### 4.2 実験環境

実験は奈良先端科学技術大学院大学内の実験用スマートホーム (ILDK) で行う。実験用機器として、赤外線センサ、環境センサ、振動センサなどの各種センサを使用する。また、Unity を用いたデジタルツインシミュレーション環境と LLM を用いた自律エージェントを活用する。

### 4.3 実験手法

実験手法として、Unity を用いて実際のスマートホームを 3D モデル化し、センサを仮想的に配置してデジタルツイン環境を構築する。このプロセスでは、実際の環境をデジタルツインに反映させるとともに、センサ配置の最適化を行う。具体的には、仮想環境内で異なるセン

サ配置パターンをシミュレーションし、それぞれの配置における行動認識の精度を評価することで、最も効果的かつ効率的なセンサ配置を決定する。

このシミュレーションでは、LLM エージェントが住宅内を自律的に行動し、センサデータを収集する。

#### 4.3.1 デジタルツインによる行動認識の評価

行動認識の評価では、各センサ配置における行動認識の精度を評価する。具体的には、朝食の準備、テレビ鑑賞、掃除、入浴といった日常的な行動を対象とする。認識精度の評価には正解率 (Accuracy)、適合率 (Precision)、再現率 (Recall)、F 値 (F-measure)、センサ配置のコスト効率 (Cost Efficiency)、ユーザのプライバシー保護 (Privacy Protection) を用いる。 [15].

行動認識モデルの全体の予測がどれだけ正確かを示す Accuracy の評価方法としては、実際のスマートホーム環境でセンサデータを収集する。その後、提案するシステムを用いて、収集したセンサデータから被験者の行動を認識する。そして、認識された行動と実際に行った行動を比較し、正確に認識された割合を計算する。手順としては、各行動の真陽性 (TP)、真陰性 (TN)、偽陽性 (FP)、偽陰性 (FN) をカウントし、式 1 を用いて精度を計算する。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

次に、予測された正のクラスのうち、実際に正しいクラスの割合を示す Precision を式 2 を用いて計算する。

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

また、実際に正のクラスのサンプルのうち、どれだけ正しく予測できたかを示す Recall を式 3 を用いて計算する。

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

これらの値から精度と再現率のバランスを評価する指標である F-measure を式を用いて計算する。

$$F\ measure = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

これらの指標を用いて、行動認識モデルの性能を多角的に評価する。

センサ配置のコスト効率は各センサの設置コストと維持コストを見積り、全体のセンサ配置にかかる総コストで認識精度を割ることでコスト効率を評価する。この評価では、行動認識の精度あたりのセンサ配置のコストを定量的に評価できる。

ユーザーのプライバシー保護の観点での評価については、使用するセンサの収集する情報のプライバシーリス

クによって評価を1~3に分けて、設置場所（リビング、寝室、バスルームなど）によるリスクも1~3の評価基準を設定し、それらの数値を掛け合わせることで、プライバシー侵害の可能性についての定量的な評価を行う。

#### 4.3.2 実環境での検証

シミュレーション結果をもとに、最適と判断されたセンサ配置を実際のスマートホームに適用し、行動認識実験を行う。この実験では複数の被験者に異なる日常行動を行ってもらい、センサデータを収集する。スマートホーム環境での実験では、取得したデータに正解値を付与するためにアノテーションボタンやアンケートによるラベル付けを行う。

#### 4.3.3 結果の比較と分析

シミュレーション結果と実環境での実験結果を比較し、提案システムの有効性を評価する。実環境での認識制度がシミュレーション結果と一致するかを確認し、相違がある場合はその原因を分析する。

#### 4.4 実験結果の評価基準

実験結果の評価基準は、デジタルツインと同様に行動認識の正解率 (Accuracy)、適合率 (Precision)、再現率 (Recall)、F 値 (F-measure)、センサ配置のコスト効率 (Cost Efficiency)、ユーザのプライバシー保護 (Privacy Protection) を用いる。また、行動認識モデルからセンサの情報量を取り出すことで、デジタルツインによるセンサ位置最適化のパラメータに利用する。最後に、被験者にアンケートを実施し、プライバシーに対する不安や安心感を定性的に評価する。

これらの評価基準を用いて、実際のスマートホーム環境での実験結果とデジタルツイン環境でのシミュレーション結果を比較検討することで、提案するシステムの有効性と利便性を総合的に評価する。

## 5. おわりに

本提案では、宅内行動認識におけるセンサの最適な位置推定を目的として、宅内環境のデジタルツインとLLMによる自律エージェントのシステムについて提案と検討を行った。今後は、デジタルツイン環境の構築、各種センサをデジタルツインへ反映させるシステム開発、LLMエージェント自立行動システムの作成を目指す。また、このデジタルツインによりシミュレーションした結果と実際の環境による行動認識との比較実験を行う予定である。

## 参考文献

[1] Simin Ahmadi-Karvigh, A. Ghahramani, B. Becerik-Gerber, and L. Soibelman. Real-time activity recognition for energy efficiency in

buildings. *Applied Energy*, Vol. 211, pp. 146–160, 2018.

- [2] Miguel Ángel Álvarez de la Concepción, L. M. Soria-Morillo, Juan Antonio Álvarez García, and L. G. Abril. Mobile activity recognition and fall detection system for elderly people using a meva algorithm. *Pervasive Mob. Comput.*, Vol. 34, pp. 3–13, 2017.
- [3] Jong-Tak Kim, Jae-Yong Soh, Sung-Ho Kim, and Kyung-Yong Chung. Emergency situation alarm system motion using tracking of people like elderly live alone. In *2013 International Conference on Information Science and Applications (ICISA)*, pp. 1–4, 2013.
- [4] 神尾崇. 画像認識を応用した高度映像セキュリティシステム. パナソニック技報= Panasonic technical journal, Vol. 54, No. 4, pp. 213–217, 2009.
- [5] Josh Achiam, Steven Adler, Sandhini Agarwal, Lama Ahmad, Ilge Akkaya, Florencia Leoni Aleman, Diogo Almeida, Janko Altenschmidt, Sam Altman, Shyamal Anadkat, et al. Gpt-4 technical report. *arXiv preprint arXiv:2303.08774*, 2023.
- [6] Valentina Bianchi, Marco Bassoli, Gianfranco Lombardo, Paolo Fornaciari, Monica Mordonini, and Ilaria De Munari. Iot wearable sensor and deep learning: An integrated approach for personalized human activity recognition in a smart home environment. *IEEE Internet of Things Journal*, Vol. 6, No. 5, pp. 8553–8562, 2019.
- [7] Annalisa Franco, Antonio Magnani, and Dario Maio. A multimodal approach for human activity recognition based on skeleton and rgb data. *Pattern Recognition Letters*, Vol. 131, pp. 293–299, 2020.
- [8] Liming Chen, Chris D Nugent, and Hui Wang. A knowledge-driven approach to activity recognition in smart homes. *IEEE Transactions on Knowledge and Data Engineering*, Vol. 24, No. 6, pp. 961–974, 2011.
- [9] Tomokazu Matsui, Kosei Onishi, Shinya Misaki, Manato Fujimoto, Hirohiko Suwa, and Keiichi Yasumoto. Salon: Simplified sensing system for activity of daily living in ordinary home. *Sensors*, Vol. 20, No. 17, 2020.

- [10] Eric VanDerHorn and Sankaran Mahadevan. Digital twin: Generalization, characterization and implementation. *Decision support systems*, Vol. 145, p. 113524, 2021.
- [11] Zixuan Zhang, Feng Wen, Zhongda Sun, Xinge Guo, Tianyiyi He, and Chengkuo Lee. Artificial intelligence-enabled sensing technologies in the 5g/internet of things era: from virtual reality/augmented reality to the digital twin. *Advanced Intelligent Systems*, Vol. 4, No. 7, p. 2100228, 2022.
- [12] Joon Sung Park, Joseph O'Brien, Carrie Jun Cai, Meredith Ringel Morris, Percy Liang, and Michael S Bernstein. Generative agents: Interactive simulacra of human behavior. In *Proceedings of the 36th annual acm symposium on user interface software and technology*, pp. 1–22, 2023.
- [13] Dongkyu Choi, Tolga Konik, Negin Nejati, Chunki Park, and Pat Langley. A believable agent for first-person shooter games. In *Proceedings of the Third AAAI Conference on Artificial Intelligence and Interactive Digital Entertainment, AIIDE'07*, p. 71–73. AAAI Press, 2007.
- [14] Liangming Pan, Michael Saxon, Wenda Xu, Deepak Nathani, Xinyi Wang, and William Yang Wang. Automatically correcting large language models: Surveying the landscape of diverse self-correction strategies. *arXiv preprint arXiv:2308.03188*, 2023.
- [15] Jamie A. Ward, Paul Lukowicz, and Hans W. Gellersen. Performance metrics for activity recognition. *ACM Trans. Intell. Syst. Technol.*, Vol. 2, No. 1, 2011.