

Zero-shot 宅内行動認識に向けた 行動区間推定手法の検討

A Study on Activity Window Estimation Methods for Zero-Shot
Human Activity Recognition in Smart Homes

飛田祐聖[†]

Yusei Hida

松井智一[†]

Tomokazu Matsui

諏訪博彦[†]

Hirohiko Suwa

安本慶一[†]

Keiichi Yasumoto

1. はじめに

宅内行動認識は、住人の日常行動を把握し、高齢者の見守り、生活支援、健康状態の継続的な確認へつなげる技術である [1, 2, 3]. 人感、ドア、温度等の環境センサは、カメラ映像を常時取得せずに生活行動を観測でき、実生活下での継続的な認識に適している [3, 5].

一方、住宅ごとに間取り、センサ配置、センサ ID、イベント密度、行動分布は異なる。新規住宅ごとに教師あり認識器を構築するには、長期間の生活ログへ行動ラベルを付与する必要がある、住人と研究者の負担が大きい [4]. この負担を抑えるため、既存住宅で学習した認識器を、転移先住宅のラベル付きデータを使わずに適用する住宅間転移・Zero-shot 認識が求められる。このような住宅間の表現差を吸収する手法として TDOST が提案されている。TDOST は、センサ反応を場所・種類・状態を含む自然言語へ変換し、住宅固有 ID への依存を弱める [6].

しかし、多くの宅内行動認識は、入力があらかじめ行動単位へ分割されていることを前提とする。実環境で得られるのは正解境界を持たない連続センサログであり、認識器へ入力する区間を別途推定しなければならない。区間推定に失敗すると、複数行動の混在、識別的イベントの欠落、過度に短い入力が生じ、後段の認識性能が低下し得る。すなわち、連続ログを Zero-shot 認識へ接続するには、認識器だけでなく前段の区間推定を独立した設計対象として評価する必要がある。

そこで本稿では、転移先住宅の連続ログから区間を推定し、固定した Zero-shot 認識器へ入力する実験系を構築する。TDOST, SentenceTransformer, BiLSTM からなる認識器を固定し、転移先住宅の行動ラベルを区間推定および認識器の学習に用いない。固定分割、逐次ルール、隠れマルコフモデル (Hidden Markov Model: HMM)、学習元住宅の正解境界を教師とする手法、複合手法の 30 条件を比較する。Milan と Aruba は CASAS プロジェクトで公開されている異なる実住宅のセンサデータセットである。Milan を学習元住宅、Aruba を転移先住宅とする方向と、Aruba を学習元住宅、Milan を転移先住宅とする方向の 2 方向を、10 個の乱数シードで評価する。RQ1 では区間推定条件の違いが後段の Zero-shot 分類性能に与える影響を検証し、RQ2 では推定境界と正解境界の一致度が分類性能とどのように関係するかを調べる。

結果として、Milan から Aruba では学習元住宅の正解境界を教師とする条件が 100 イベント固定を Macro-F1 で平均 0.0085 上回り、Aruba から Milan ではドア+無反応時間が 50 イベント固定を 0.0448 上回った。本稿の貢献は、(1)

転移先住宅の行動ラベルを区間推定および認識器の学習に用いない比較手順、(2) 利用情報の異なる区間推定条件の比較、(3) 直接境界 F1 と分類性能の乖離の定量化、(4) 同一住宅内評価による住宅間差の切り分け、の 4 点である。

2. 関連研究

本章では、環境センサを用いた宅内行動認識、住宅間転移、連続ログの区間推定を整理し、本研究の位置づけを示す。

2.1 環境センサを用いた宅内行動認識

スマートホームは、住人の自立生活支援や健康状態の継続的な確認への利用が検討されている [1, 2]. CASAS は、人感・ドア・温度センサ等を備えた実住宅データと認識基盤を提供した [5]. 環境センサによる宅内行動認識には、映像を常時記録せずに日常行動を扱える利点がある一方、行動の多様性、クラス不均衡、時系列構造、住宅ごとの差が課題として整理されている [3].

2.2 住宅間転移と Zero-shot 認識

住宅間転移では、異なる間取りやセンサ配置に起因する表現差を吸収する必要がある。TDOST は、あらかじめ行動区間が与えられたセンサイベント列を自然言語記述へ変換し、SentenceTransformer と系列分類器を用いて住宅間認識を行う [6]. 従来の TDOST による認識では、学習時には行動区間と行動ラベルが与えられ、評価時にも入力区間の境界が既知である。区間内のイベントを文章化して行動ラベルと対応付け、認識モデルを学習する。TDOST 自体は区間推定手法ではない。本研究では、転移先住宅の連続ログから区間を推定した後、各生成区間を TDOST へ入力する。さらに、空間意味情報 [11]、住人軌跡の画像表現 [12]、環境情報の表現と推論方法 [13] を利用する方法が報告されている。これらは住宅間で認識可能な表現や推論を扱うが、連続ログから認識入力を作る区間推定は別の課題として残る。

2.3 連続ログの区間推定

固定時間または固定イベント数による分割は再現しやすいが、行動継続時間や不規則なイベント密度を直接扱わない。Najeh らは境界の手掛かりとなるセンサと時空間関係を用いた動的分割を提案し [7]、Aminikhanghahi らは変化点検出を行動分割へ適用した [8]。Srivatsa らは連続センサ流の分割と分類を一体として扱う必要性を論じている [9]。系列評価には、予測区間と正解行動区間を一対一対応させる Segmental F1 が利用される [10].

2.4 本研究の位置づけ

本研究では、2.3 節で述べた複数の区間推定方法を用いて転移先住宅の連続センサログを区間へ分割し、各生成区間

[†]奈良先端科学技術大学院大学
Nara Institute of Science and Technology




図1 本研究の全体構成

を共通の行動認識器へ入力する。TDOSTを含む後段認識器を固定し、転移先住宅の行動ラベルを区間推定に用いない条件で分類性能への影響を比較する。さらに、分類性能と境界一致度を別々に測り、連続ログを住宅間 Zero-shot 認識へ接続する際の設計上の差を明らかにする。

3. 実験設定

本実験の目的は、認識器を固定した条件で行動区間推定方法のみを変更し、区間推定条件の違いが住宅間 Zero-shot 行動認識性能に与える影響と、推定境界の一致度と認識性能の関係を明らかにすることである。本章では、そのための評価の流れ、使用データ、ラベル対応、評価指標を示す。

3.1 評価の流れ

図1に全体構成を示す。学習元住宅の正解行動区間で学習した同一の認識器を、転移先住宅の全区間推定条件で共有する。転移先住宅の行動ラベルと正解境界は区間推定には用いず、生成後の多数決ラベル付与と評価にのみ用いる。

3.2 認識器

学習元住宅では正解行動区間、転移先住宅では推定した生成区間を用いる。各区間内のセンサイベントを、設置場所、センサ種別、状態を含む TDOST Basic 文へ変換する。TDOSTは与えられた区間を文章化する処理であり、行動区間推定手法ではない。生成した文章を SentenceTransformer (all-distilroberta-v1) で 768 次元の埋込み系列へ変換し、1 層双方向 LSTM (hidden 64) で行動を分類する。

1 区間当たり最大 100 イベント、batch size 32, 75 epochs とした。100 イベントを超える生成区間では末尾イベントが認識器へ入力されない。実装と保存済みモデル間のラベル対応は一致している。

3.3 比較設定

認識器を固定し、区間推定条件だけを比較する。CASAS の異なる実住宅データである Milan と Aruba を用い、Milan を学習元住宅、Aruba を転移先住宅とする方向と、Aruba を

学習元住宅、Milan を転移先住宅とする方向について、1 方向当たり 30 条件を評価する。各住宅データの詳細は 3.4 節で述べる。学習元住宅のデータ分割シードは 42, 学習初期値と学習順序の乱数シードは 43~52 とした。同じ学習元住宅・同じ学習シードの認識モデルを全区間推定条件で共有する。10 シードは同一データ分割で学習時の乱数変動を確認するものであり、交差検証ではない。区間単位の Macro-F1 を主指標とし、Accuracy, Weighted-F1, 直接境界 F1 等を併記する。

表1に条件群の利用情報を、図2に連続するイベント列を区間へ分割する問題を示す。

- **固定分割 (3 条件)**: 固定 10 分, 100 イベント固定, 100 イベント固定・初期ずらし 25 イベントである。時間またはイベント数だけで機械的に分割し、区間境界を学習しない基準条件とする。初期ずらし条件では先頭 25 イベントを除外した後、100 イベントごとに非重複で分割し、末尾の不完全区間を保持する。
- **逐次ルール (4 条件)**: 無反応 10 分と、ドア+無反応 10 / 15 / 30 分 (pad 0) である。ドアイベントまたは規定時間以上の無反応を境界候補とし、判定時点までに観測済みのイベントだけを用いる。無反応時間の経過は待つが候補より後のイベントを直接参照せず、pad 0 は候補後の追加イベントを参照しないことを表す。
- **一括・教師なし (18 条件)**: ドア+無反応 10 / 15 / 30 分 (pad 10 / 25) の 6 条件, HMM 状態数 6 / 8 / 10 / 12 / 16 / 20 の 6 条件, ドア+ HMM の 3 条件, 前後 5 分参照 (閾値 0.15 / 0.25 / 0.35) の 3 条件である。ドア + HMM は HMM 状態数 12 で、無反応 15 分・pad 10, 無反応 15 分・pad 25, 無反応 30 分・pad 10 の 3 設定とする。HMM は未ラベル系列から潜在状態を推定し、状態変化を境界候補とする。前後 5 分参照は各イベント時刻の前後 300 秒における部屋分布差を用いる。将来イベントまたは転移先住宅の未ラベル系列全体を参照するが、行動ラベルは用いない。

表 1 区間推定条件の利用情報

条件群	主な条件	境界手掛かり	未来情報	境界教師
固定分割	固定 10 分, 100 イベント, 初期ずらし 25 イベント	時間／イベント数, 非重複	なし	なし
逐次ルール	無反応 10 分, ドア+無反応時間 (pad 0)	無反応時間, ドアイベント	なし	なし
一括・教師なし	pad>0, HMM, 前後 5 分参照, ドア+HMM	将来イベントまたは全系列	あり	なし
学習元境界学習	学習元境界 LR / RF (閾値 0.6 / 0.8)	時刻・センサ・部屋分布	あり	学習元のみ
正解区間入力	転移先住宅の正解行動区間	—	—	転移先




図 2 連続センサログからの区間推定例

- ・ **学習元境界学習 (4 条件)**: 学習元境界 LR と学習元境界 RF について, それぞれ判定閾値 0.6 / 0.8 を用いる計 4 条件である. 両モデルは学習元住宅の正解境界を教師として候補時刻が行動境界かを判定する区間推定用モデルであり, 転移先住宅の正解境界は用いない. 後方 5 分の部屋分布とイベント数を特徴量に含むため, 本実装では一括処理として扱う.
- ・ **正解区間入力 (1 条件)**: 転移先住宅の正解行動区間をそのまま認識器へ入力する. 自動区間推定条件ではなく, 区間推定誤差を除いた場合の参考性能として用いる.

3.4 データセット

CASAS は, 実住宅内に設置したセンサの反応を長期間にわたり時系列で記録したデータセットである. 本研究で主に扱うのは人感センサとドアセンサであり, 各イベントには時刻, センサ ID, 反応値または状態, 行動注釈が記録される. 例えば, 2010-11-04 05:40:51, M003, ON, Sleeping end は, 時刻, センサ ID, 反応値に続き, Sleeping の行動区間が終了したことを表す注釈を持つ記録である. 開始・終了注釈の間に生じた複数のイベントから, 正解行動区間を構成できる.

TDOST の概念例として, 08:00 から 08:10 の Meal Preparation 区間に, キッチンの人感センサ ON と冷蔵庫ドア OPEN が記録されている場合を考える. これらのイベント列が一つの正解行動区間を構成し, TDOST は区間内のイベントを設置場所, センサ種別, 状態を含む文章表現へ変換して行動ラベルと対応付ける. これは処理の流れを示す概念説明であり, 実際の TDOST 出力文を再現したものではない.

CASAS Aruba (2010-11-04 00:03:50~2011-06-11 23:58:10, 220 観測日) と Milan (2009-10-16~2010-01-06) を用いる. 本研究で用いる Aruba と Milan のイベント数, 全区間数, 評価対象区間数を表 2 に示す.

正規化後イベント数は Aruba 1,713,133 件, Milan 428,890 件である. 日内重複ブロックを統合し, Aruba 6,425 件, Milan 4,775 件を除外した. Aruba の元ラベル区間は 6,440 であり,

表 2 データセット統計

住宅	イベント	全区間	評価対象区間
Aruba	1,713,133	12,759	12,332
Milan	428,890	4,297	3,601

注釈間から復元した Other 6,319 区間を加えたため, 全区間は 12,759 となる. Milan の全区間は 4,297 で, 共通 8 クラス評価対象は Aruba 12,332, Milan 3,601 である. 参考文献 [13] の Aruba 6,477 区間とは, 本実験が重複統合後の元ラベル区間と復元 Other 区間を区別して集計する点で定義が異なる.

3.5 元ラベルと共通 8 クラス

元ラベルを事前定義した共通 8 クラスへ統合した. 主要多対一の対応を表 3 に示す. Dining_Rm_Activity は Eat へ対応する. ラベルなし期間は隣接する注釈間から Other として復元した. 実装と保存済みモデル間のラベル対応は一致している.

3.6 評価指標

分類性能は区間単位 Accuracy, Macro-F1, Weighted-F1, クラス別 F1 / クラス件数とする. 住宅間評価ではクラス件数の偏りが大きく, Accuracy や Weighted-F1 は件数の多いクラスの影響を強く受ける. このため, 本稿では各クラスを等しく扱う Macro-F1 を主指標とする. 一方, 評価指標によって条件の順位が変わり得るため, Accuracy と Weighted-F1 も併記する. 各指標は 10 個の乱数シードごとに算出し, 平均とシード間標準偏差 (SD) を示す.

直接境界 F1 (Direct Boundary-F1) は, 生成区間の内部境界と転移先の正解行動境界を分類器を通さず比較する. 先頭と末尾を除き, 同一時刻を統合し, 許容 $1 \cdot 5 \cdot 10$ 分で 1 対 1 の最近傍対応を行う. 本文では 5 分を主に示す.

4. 実験結果

本章では, 固定区間条件, 動的区間推定条件, 境界一致度, クラス別性能, 同一住宅内評価の順に結果を示す.

表3 元ラベルと共通クラスの対応

共通クラス	Aruba 元ラベル	Milan 元ラベル
Bed_to_Toilet	Bed_to_Toilet	Bed_to_Toilet
Cook	Meal_Preparation	Kitchen_Activity
Eat	Eating	Dining_Rm_Activity
Leave_Home	Leave_Home	Leave_Home
Other	Respirate, ラベルなし期間	Master_Bedroom_Activity, Meditate, ラベルなし期間
Relax	Relax	Read, Watch_TV
Sleep	Sleeping	Sleep
Work	Housekeeping, Wash_Dishes, Work	Chores, Desk_Activity




図3 固定区間幅の比較

4.1 固定区間条件の比較

主比較の30条件に含まれる固定10分と100イベント固定に加え、パラメータ依存性を調べる別分析として、固定時間5/10/15/30分と固定イベント50/100/150/200件の8設定を、移動幅を区間長と同じにした非重複条件で10個の乱数シードについて評価した。固定10分と100イベント固定は両分析で共通である。図3より、MilanからArubaの最良固定条件は100イベント(Macro-F1 0.2402)、ArubaからMilanは50イベント(0.1788)であった。固定10分はそれぞれ0.1728, 0.1651であった。

4.2 動的区間推定条件の評価

表4に、各転移方向の最良固定条件と主な動的条件の分類結果を示す。MilanからArubaでは、学習元境界RFのMacro-F1が0.2487であり、100イベント固定の0.2402より0.0085高かった。この差は10個の乱数シードのうち9個で同じ方向に現れた。

ArubaからMilanでは、ドア+無反応時間30分(pad 0)のMacro-F1が0.2236であり、50イベント固定の0.1788より0.0448高かった。この差は10個の乱数シードすべてで同じ方向に現れた。Accuracyは0.4957から0.4709, Weighted-F1は0.4296から0.4159へ低下した。

下線は各方向の最良固定条件、太字は最良自動条件を示す。正解区間入力値は参考値であり、自動条件の順位には含まない。

4.3 境界一致度

図4に29自動条件の分布を示す。いずれの転移方向でも、直接境界F1が最大となる条件とMacro-F1が最大となる条件は一致しなかった。また、直接境界F1の大小とMacro-F1の順位には明確な対応関係が見られなかった。

4.4 クラス別性能

図5では、各転移方向について、最良固定条件とMacro-F1が最大となった自動条件のクラス別F1を比較する。転移方向によって比較する条件は異なる。MilanからArubaの学習元境界RFは、100イベント固定よりOtherとEatのF1が高く、Leave_HomeとRelaxは両条件とも0付近であった。ArubaからMilanのドア+無反応時間は、50イベント固定に対してLeave_Homeを0.00から0.43へ高め、CookとSleepでは低下した。

4.5 同一住宅内評価

正解区間入力時の住宅間性能を同一住宅内評価と比較した。各住宅で日を単位とした70/15/15%の学習/検証/テスト分割を固定し、10シードでホールアウト評価を行った。Milanで学習したモデルは、転移先Arubaで最良自動条件0.2487、正解区間入力0.4553、同一住宅Milanで0.8640であった。Arubaで学習したモデルは、転移先Milanで最良自動条件0.2236、正解区間入力0.3876、同一住宅Arubaで0.9465であった。

5. 考察

本章では、区間推定条件による分類性能の違い、境界一致度と分類性能の関係、住宅間差について考察する。

5.1 区間推定条件による分類性能の違い

動的な境界手掛かりを用いることで、両方向において各方向の最良固定条件より高いMacro-F1を示す動的条件の候補例が得られた。MilanからArubaでは学習元境界RF, ArubaからMilanではドア+無反応時間が最良であり、有効な条件は転移方向によって異なった。ただし、ArubaからMilanではAccuracyとWeighted-F1が低下し、クラス別性能にも改善と悪化が見られた。この結果は、Macro-F1の改善が全指標および全クラスの改善を意味するものではない。

表 4 代表条件の 10 シード評価結果

転移	条件	Macro-F1(SD)	Accuracy	Weighted-F1
M→A	100 イベント固定	0.2402 (0.0210)	0.5452	0.4667
	ドア+無反応 30 分, pad 0	0.2445 (0.0210)	0.5755	0.5011
	学習元境界 RF, 閾値 0.8	0.2487 (0.0189)	0.5896	0.5083
	正解区間入力	0.4553 (0.0581)	0.6595	0.5602
A→M	50 イベント固定	0.1788 (0.0152)	0.4957	0.4296
	ドア+無反応 30 分, pad 0	0.2236 (0.0146)	0.4709	0.4159
	前後 5 分参照, 閾値 0.35	0.1874 (0.0096)	0.4524	0.3692
	学習元境界 RF, 閾値 0.8	0.2048 (0.0118)	0.4780	0.4100
	正解区間入力	0.3876 (0.0275)	0.6871	0.6421




図 4 直接境界 F1 と Macro-F1 の関係




図 5 クラス別 F1

いことを示している。最良自動条件の Macro-F1 は Milan から Aruba で 0.2487, Aruba から Milan で 0.2236 であった。ここで、0.2487 および 0.2236 は生成区間に対する行動分類の Macro-F1 であり、推定境界の一致度を表す直接境界 F1 とは異なる。Macro-F1 は 8 クラスの F1 を等しく平均した分類指標であり、これらの値は全クラスを十分に認識できたことを意味しない。実際に、一部クラスの F1 は 0 付近であり、正解行動区間を用いた場合でも Macro-F1 はそれぞれ 0.4553, 0.3876 と、同一住宅内評価の 0.8640, 0.9465 を大きく下回った。したがって、本結果は動的な区間推定条件に

よる相対的な改善を示す一方、現時点で実用に十分な住宅間認識性能が得られたとはいえない。実用性を判断するには、利用場面ごとの要求精度を定めた追加評価が必要である。

5.2 境界一致度と分類性能

直接境界 F1 が最大となる条件と Macro-F1 が最大となる条件は、両方向で一致しなかった。境界が正解時刻に近い場合でも、生成区間に含まれるイベント列が行動認識に適しているとは限らない。区間推定の評価には、境界一致度

と分類性能の両面からの確認が必要である。

5.3 住宅間差

正解行動区間を与えた住宅間評価でも、同一住宅内評価より Macro-F1 が低く、区間推定以外の住宅間差が残った。本評価は Aruba と Milan を対象とした探索的評価である。今後は、異なる住宅データセットを追加して得られた傾向の一般性を検証するとともに、ルールベース手法とモデルベース手法の両面から行動区間推定方法を再検討する。

6. おわりに

TDOST, SentenceTransformer, BiLSTM を固定し、転移先住宅の行動ラベルを区間推定および認識器の学習に用いず、30 条件 × 2 方向を 10 シードで評価した。探索的評価の結果、各方向の最良固定条件より高い Macro-F1 を示す動的条件の候補例が得られた。Aruba と Milan の住宅ペアでは最良条件が転移方向によって異なり、直接境界 F1 最大条件と Macro-F1 最大条件も一致しなかった。正解区間入力でも同一住宅内評価との差が残った。今後は、Aruba と Milan 以外の住宅データセットを用いて評価範囲を拡張するとともに、ルールベースおよびモデルベースの両面から行動区間推定方法を再検討する。

参考文献

- [1] M. Chan, E. Campo, D. Estève, and J.-Y. Fourniols, “Smart Homes—Current Features and Future Perspectives,” *Maturitas*, Vol. 64, No. 2, pp. 90–97 (2009), DOI: 10.1016/j.maturitas.2009.07.014.
- [2] P. P. Morita, K. S. Sahu, and A. Oetomo, “Health Monitoring Using Smart Home Technologies: Scoping Review,” *JMIR mHealth and uHealth*, Vol. 11, e37347 (2023), DOI: 10.2196/37347.
- [3] D. Bouchabou, S. M. Nguyen, C. Lohr, B. LeDuc, and I. Kanellos, “A Survey of Human Activity Recognition in Smart Homes Based on IoT Sensors Algorithms: Taxonomies, Challenges, and Opportunities with Deep Learning,” *Sensors*, Vol. 21, No. 18, 6037 (2021), DOI: 10.3390/s21186037.
- [4] S. K. Hiremath, Y. Nishimura, S. Chernova, and T. Plötz, “Bootstrapping Human Activity Recognition Systems for Smart Homes from Scratch,” *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, Vol. 6, No. 3, Article 119, pp. 1–27 (2022), DOI: 10.1145/3550294.
- [5] D. J. Cook, A. S. Crandall, B. L. Thomas, and N. C. Krishnan, “CASAS: A Smart Home in a Box,” *Computer*, Vol. 46, No. 7, pp. 62–69 (2013).
- [6] M. Thukral, S. G. Dhekane, S. K. Hiremath, H. Haresamudram, and T. Plötz, “Layout-Agnostic Human Activity Recognition in Smart Homes through Textual Descriptions of Sensor Triggers (TDOST),” *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, Vol. 9, No. 1, Article 19, pp. 1–38 (2025), DOI: 10.1145/3712278.
- [7] H. Najeh, C. Lohr, and B. Leduc, “Dynamic Segmentation of Sensor Events for Real-Time Human Activity Recognition in a Smart Home Context,” *Sensors*, Vol. 22, No. 14, 5458 (2022), DOI: 10.3390/s22145458.
- [8] S. Aminikhanghahi and D. J. Cook, “Enhancing Activity Recognition Using CPD-Based Activity Segmentation,” *Pervasive and Mobile Computing*, Vol. 53, pp. 75–89 (2019), DOI: 10.1016/j.pmcj.2019.01.004.
- [9] Srivatsa P and T. Plötz, “Using Graphs to Perform Effective Sensor-Based Human Activity Recognition in Smart Homes,” *Sensors*, Vol. 24, No. 12, 3944 (2024), DOI: 10.3390/s24123944.
- [10] C. Lea, A. Reiter, R. Vidal, and G. D. Hager, “Segmental Spatiotemporal CNNs for Fine-Grained Action Segmentation,” in *ECCV 2016*, LNCS 9907, pp. 36–52 (2016), DOI: 10.1007/978-3-319-46487-9_3.
- [11] An Minhyoung, 菊池尊勝, 庭本眞太郎, 新明勇翔, 竹田圭汰, Yuexiao Liu, 松井智一, 安本慶一: 行動認識のための住宅間データ転移に向けた言語を用いた空間意味情報推定手法の提案, マルチメディア, 分散, 協調とモバイル (DICOMO 2026) シンポジウム論文集, pp. 1013–1018 (2026).
- [12] 庭本眞太郎, 新明勇翔, 菊池尊勝, An Minhyoung, 竹田圭汰, Yuexiao Liu, 松井智一, 安本慶一: マルチモーダル LLM によるゼロショット日常生活行動認識に向けた軌跡画像生成と入力手法, マルチメディア, 分散, 協調とモバイル (DICOMO 2026) シンポジウム論文集, pp. 1842–1852 (2026).
- [13] 新明勇翔, 菊池尊勝, 庭本眞太郎, An Minhyoung, Yuexiao Liu, 竹田圭汰, 松井智一, 安本慶一: スマートホームにおける Zero-shot 行動認識に向けた環境情報表現と推論手法の比較評価, マルチメディア, 分散, 協調とモバイル (DICOMO 2026) シンポジウム論文集, pp. 813–830 (2026).