

CASAS データセットを用いた LSTM モデルによる 時間内行動生起予測精度の評価

Evaluation of Accuracy in Forecasting Occurrence of Daily Living Activity within Specified Time by LSTM Model Using CASAS Dataset

松井 智一[†] 諏訪 博彦^{†‡} 安本 慶一[†]
Tomokazu Matsui Hirohiko Suwa Keiichi Yasumoto

1. はじめに

近年、住宅のスマート化を背景に、宅内における居住者の位置情報や家電の利用状況などから行動を認識・予測し、より利便性の高い宅内サービスを提供するシステムが研究されている。居住者の行動を認識することで、居住者の生活改善を促すことや居住者の状態に応じた家電の制御、エネルギーの無駄遣い防止が可能である。また、居住者のコンテキストを理解し、行動を予測することによって、エアコンの温度調整や浴槽の自動湯沸かし、就寝時の消灯などの家電の先回り制御が可能となり、行動認識技術による以上の QoL 向上が期待できる。そこで、スマートホームで収集した家電の利用状況データから、行動認識によって居住者の生活習慣の改善を提案するための研究 [1] や、高齢者向け見守りサービスを提供する研究 [2]、居住者の健康管理システムを提供する研究 [3] が提案されている。また、行動予測によって高齢者や障害者向けの健康管理の実現を目指す研究 [4] が提案されている。さらに、経済産業省の指針 [5] では、2019 年度以降には行動予測による買物や介護・育児、家庭リソースシェアリングなどの社会実装を目指しており、宅内における行動予測技術のさらなる発展が望まれている。

そこで、居住者の行動予測を行う上で、以下の 5 項目が課題として挙げられる。

1. 居住者の負担
2. プライバシーの侵害
3. 予測に要する時間の長さ
4. 予測精度の低さ
5. システムの導入・維持コストの高さ

項目 1 に関して、宅内に多くのセンサを設置することや、装着型センサ・スマートデバイスの利用は、居住者が侵襲感を感じる要因となり、負担になると考えられる。項目 2 に関して、画像データや音声データを取得することは、居住者に監視されているという心理的圧力を与え、プライバシーを侵害する恐れがある。項目 3 に関して、

行動予測自体に長時間を要する場合、リアルタイムでの家電の先回り制御が不可能である。そのため、予測に要する時間はできるだけ短時間であることが望ましい。項目 4 に関して、居住者のプライバシー保護のために限られたセンサによるデータから居住者の行動予測を行う必要がある。さらに、行動予測は、行動認識の発展であり、次に生起する行動の種類だけでなく生起までの時間も予測する必要があるため、予測精度の向上が課題である。一方で、項目 5 に関して、実用上はシステムの導入・維持コストは低く抑える必要があり、高価なセンサモジュールを利用することは望ましくない。したがって、これらの課題を解決するためのスマートホーム環境および行動予測モデルが必要である。そこで、著者らの所属する研究グループでは、次に生起する行動の種類と、現在から次行動生起までの時間を分類問題として扱う手法（以下、佐々木らの手法）を提案した [6]。具体的には、次行動生起までの時間を回帰により求めることで行動予測するのではなく、時間のある範囲で区切り、次行動がその時間範囲以内に生起するかしないかを判断する分類問題として行動予測を行う。この手法により、次行動生起までの平均絶対誤差が大きく実サービスへの応用が難しかった従来手法に対して、就寝 10 分前の消灯や入浴 30 分前の浴槽湯沸かし、就寝 1 時間前の寝室空調調整など、ユースケースに応じた家電制御が可能となり、実サービスへの応用が容易になる。この際、予測に利用する情報は人感センサデータや家電の消費電力量であり、システムの構築費用が比較的安価であることに加えて、居住者の負担やプライバシーに配慮したセンシングを行っている。これにより、上述した 5 項目の課題達成が期待できる。文献 [6] の実験では、奈良先端科学技術大学院大学内のスマートホーム（以下、NAIST スマートホームとする）において、5 人の被験者に対して 3 泊 4 日ずつ行った。得られた結果として、平均予測再現率 33% 以上を達成した行動は 30 分以内には 3 種類、60 分以内には 4 種類であった。なお、実験時に、不均衡データの生成を避けるため極端に少ない行動が発生しないように被験者に対して指示をしていたため、被験者が普段の生活習慣と異なる生活をしていただけた可能性があること、また、各被験者

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

[‡] 理化学研究所, RIKEN

の生活期間が4日間と短く、被験者間の生活パターンが類似していないことなどから、予測精度が低下したことが考えられる。

そこで、本稿では、佐々木らの手法の有効性を確認するために、学内で収集したセンサデータではなく、同じ被験者による長期間の生活データが含まれるオープンデータセットであるCASASデータセット[7]を利用して分類による行動予測精度を評価し、文献[6]の結果と比較する。

比較した結果、行動の種類によっては文献[6]の予測精度を上回るものの、逆に下回る行動があった。本稿では、予測精度が向上、減少した要因に関する考察を行い、その結果を報告する。

2. 関連研究

Nazerfardら[8]は、スマートホームにおける居住者の行動予測を行うために、ある時点から次の時点における行動の種類を予測するための特徴量であるCRAFFTを導入している。行動予測の精度は73.7%を達成しており、高精度であるといえる。しかしながら、予測時点までの行動を終了したことを認識しなければ次行動の予測を行うことができない課題がある。したがって、実サービスへの応用を考慮した場合、連続した行動に対する家電の制御などは不可能である。

Minorら[9]は、オープンデータセットであるCASASデータセットを利用して、宅内行動予測を行っている。データセットには、人感センサや磁気ドアセンサなどの離散データ、温度センサや照度センサなどの連続データが含まれており、それらのセンサデータから特徴量を抽出し、回帰木によるモデルで行動予測を行っている。しかしながら、次行動生起までの予測時間の平均絶対誤差が8402secであることから、家電の先回り制御などの実サービスにおける利用は難しい。

Mohammadら[10]は、家電の利用情報から居住者の行動の流れであるエピソードを認識し、認識したエピソードから次行動の予測を行っている。しかしながら、居住者ごとに行動の周期性は異なるため、エピソードを利用して学習した予測モデルは汎用的に利用できない。

Niekら[11]は、MITデータセット、CASASデータセット、Kasterenデータセットを利用して、LSTMやGRUなどのアルゴリズムを用いた行動予測や精度の比較を行っている。結果として、次行動種類の予測精度が26.9~52.9%であり、次行動生起までの予測時間の平均絶対誤差が1210.32~3757.70secであることから、行動予測システムとしての完成度は高いといえる。しかしながら、次に生起する行動の種類と時間を個別に学習していることから、特定の行動が一定時間後に生起する確率

表 1: hh104 データセットの概要

Number of Activities	33
Number of Sensors	133
Number of Sensor Types	8
Number of Residents	1
Measurement Period	2 months

しか判定できないため、実サービスへの適用が難しい。

これら既存研究は、行動予測の精度は高いものの前章で述べた5つの課題の解決には至っていない。したがって、佐々木らの提案する実サービスへの応用を念頭においた文献[6]の手法により、それらの課題を解決する。

3. CASAS データセット

本研究で利用するオープンデータセットに関して以下に述べる。CASAS (Center for Advanced Studies in Adaptive Systems) は、スマートホームにおける様々なデータを提供するためのプロジェクト[7]である。提供されているデータセットには、居住者の人数や性別、計測場所、計測期間などが異なる60以上のシチュエーションが存在し、各データセットに格納されているセンサデータには、温度センサなどの連続センサデータ、人感センサやドア開閉センサなどの離散センサデータが含まれている。本稿では、行動予測に利用するデータセットとして、表1に示すhh104データセットを選択する。

なお、本稿では、佐々木らの手法をオープンデータセットに適用した場合の比較を行うため、予測する行動ラベルや利用するセンサデータを可能な限り佐々木らの手法と揃える必要がある。したがって、hh104データセットでラベリングされている行動ラベルと利用するセンサを、それぞれ表2、3に示す変換表を元に変換する。これにより、hh104データセットでは33種類であった行動ラベルを14種類とし、8種類であったセンサを5種類とした。この際、佐々木らの手法における実験環境では、トイレを利用できなかったためToilet行動が存在しなかった。しかしながら、トイレを利用することは実環境において一般的な行動であることから、行動ラベルとして取り入れている。また、hh104データセットではCook行動、CookDinner行動、CookLunch行動など、Cookという行動にも多数のラベルが存在する。そのため、これらの類似行動ラベルは主となる行動ラベルに統一した。

4. データ分析手法

本稿の目的は、佐々木らの手法をCASASデータセットに適用した場合の結果を示し、佐々木らの結果と比較することであるため、実験条件を佐々木らの手法に準拠して決定する。そのため、予測モデルの構築のために、

表 2: 行動ラベルの変換表

Proposed Method	hh104	Sasaki's Method
Bathe	Bathe	Bathing
Cook	Cook	Cooking
	CookDinner	
	CookLunch	
Eat	Eat	Eating
	EatBreakfast	
	EatDinner	
	EatLunch	
Groom	Groom	MakeUp
LeaveHome	LeaveHome	LongGoOut
		ShortGoOut
NotAssign	NaN	NotSpecified
Others	BedToiletTransition	-
	Dress	
	EntertainGuests	
	EnterHome	
	EveningMeds	
	Relax	
	MorningMeds	
	TakeMedicine	
PersonalHygiene	PersonalHygiene	TeethCleaning FaceWashing
Phone	Phone	UsingSmartphone
Read	Read	Reading
Sleep	Sleep	Sleeping
	SleepOutOfBed	
Toilet	Toilet	-
WashDishes	WashBreakfastDishes	WashingDishes
	WashDinnerDishes	
	WashDishes	
	WashLunchDishes	
WatchTV	WatchTV	WatchingTV
Work	Work	WorkingOnPC
	WorkAtTable	
	WorkOnComputer	
-	-	CleaningBathroom
-	-	CleaningRoom
-	-	Laundry
-	-	PlayingGame

佐々木らと同様に LSTM (Long Short Term Memory) モデルを利用する。さらに, CASAS データセットから提供されている hh104 データセットには 2ヶ月分のデータが格納されているが, 佐々木らの手法に準拠し, 利用するデータセットの期間は 2 週間とする。また, データセットには, センサが反応した時点におけるタイムスタンプと, その時点でのセンサ値が格納されている。したがって, 学習に利用するためにはデータセットのサンプリング間隔を決定し, 値を丸める必要がある。本比較では, 佐々木らの手法に準拠し, 磁気ドアセンサ, 照明スイッチ, 赤外線モーションセンサ, 広域赤外線モーションセンサに関しては 10 秒間において 1 度でも反応した

表 3: センサ種類の変換表

Proposed Method	hh104	Sasaki's Method
InfraredMotion Sensor	InfraredMotion Sensor	MotionSensor
LightSensor	LightSensor	-
LightingSwitch	LightingSwitch	-
MagneticDoorSensor	MagneticDoorSensor	-
WideAreaInfrared MotionSensor	WideAreaInfrared MotionSensor	-
-	BatteryLevel	-
-	TemperatureSensor	-
-	-	BluetoothWatt Checker
-	-	CTSensor
-	-	ECHONETLite
-	-	UltrasonicPosition Sensor

かを判定し, 照明センサに関しては 10 秒間での中央値を利用してデータセットのリサンプリングを行っている。

本比較で行動予測に利用する LSTM モデルは, Input 層, Dropout 層, LSTM 層, Dense 層, Output 層から構成している。また, 入力とするデータはデータ数, 特徴量数, 追憶データ数の 3 種類であり, 10 秒おきの特徴量データを追憶データ数だけ重ねたデータを生成する。さらに, ハイパーパラメータの設定は佐々木らの手法に準拠し, 追憶データ数を 100, エポック数を 10, 入力バッチサイズを 512 として学習を行う。同様に, 各層のパラメータは Dropout 層の Dropout 率を 0.2, LSTM 層の隠れユニットは 512, Dense 層の Activation 関数として softmax 関数を利用する。なお, 学習したモデルの検証は, 2-Fold 交差検証によって行う。

5. 検証結果

本章では, 佐々木らの手法の結果と, 佐々木らの手法を hh104 データセットに適用した結果を比較した。比較した結果, 特定の行動・特定の時間間隔においては予測精度が向上したものの, 逆に予測精度が低下したケースがあった。また, 利用するデータセットから, 学習するデータ区間を 2 週間分取り出す際に, 取り出した区間に関連して予測精度の高低が見られた。そこで, 佐々木らの手法との比較に加えて, 取り出す区間による予測精度の相違, 異なるオープンデータセット間での予測精度の相違を検証する。ここで, 比較するオープンデータセットとして, CASAS で提供されているデータセットである hh101, hh102, hh103 データセットを利用する。これらのデータセットに格納されている行動ラベルやセンサデータは, hh104 データセットと同様である。ただし, センシング対象となる居住者や宅内のセンサ配置はデータセット毎に異なる。

表 4: hh104 データセットで学習した予測再現率

	Bathe	Cook	Eat	Groom	LeaveHome	NotAssign	Others
10 min	0.000	0.174	0.136	0.129	0.021	0.597	0.059
30 min	0.000	0.191	0.343	0.000	0.087	0.786	0.278
60 min	0.004	0.219	0.251	0.000	0.368	0.912	0.564
	PersonalHygiene	Phone	Sleep	Toilet	WashDishes	WatchTV	Work
10 min	0.069	0.000	0.107	0.021	0.092	0.067	0.142
30 min	0.090	0.000	0.175	0.115	0.253	0.053	0.233
60 min	0.161	0.000	0.482	0.228	0.225	0.176	0.354

表 5: 文献 [6] の結果 (NAIST スマートホームでのデータによる予測再現率)

	Bathe	CleaningBath	CleaningRoom	Cook	Eat	Game	Groom	Laundry	LeaveLong	LeaveShort
10 min	0.002	0.129	0.000	0.155	0.474	0.000	0.040	0.138	0.190	0.015
30 min	0.031	0.222	0.256	0.157	0.538	0.204	0.270	0.284	0.144	0.092
60 min	0.052	0.271	0.327	0.260	0.564	0.259	0.113	0.238	0.325	0.270
	Others	Phone	Read	Sleep	ToothBrushing	WashDishes	WashFace	WatchTV	Work	
10 min	0.435	0.064	0.150	0.078	0.103	0.301	0.133	0.118	0.004	
30 min	0.658	0.268	0.082	0.032	0.238	0.370	0.399	0.164	0.001	
60 min	0.717	0.399	0.226	0.307	0.266	0.370	0.450	0.246	0.053	




図 1: hh104 データセットで学習した予測再現率

また、以上の検証結果から、同じデータセット内で学習する期間を伸ばすことで予測精度の向上が期待できると考えた。そこで、段階的に学習するデータ数を増加させ、予測精度が向上するか検証する。

5.1 佐々木らの手法との比較

表 4, 5 にそれぞれ hh104 データセットの各時間内行動生起の予測再現率の値、文献 [6] の各時間内行動生起の予測再現率の値を示す。また、図 1, 2 に、それぞれの予測再現率のグラフを示す。なお、本比較では、hh104

データセットにおいて Read 行動は生起していないため、行動ラベルとして存在しない。

結果より、hh104 データセットでは、1 時間以内の時間範囲では Sleep 行動や Work 行動、LeaveHome 行動などの予測再現率は高いものの、Bathe 行動や Phone 行動などは全く予測できていない。その他の時間範囲においても同様に、文献 [6] の結果と比較して予測再現率の改善は見られない。結果の要因として、センサデータの取捨選択やデータ数の不均衡、行動ラベルの丸め方が考




図 2: 文献 [6] の結果 (NAIST スマートホームでのデータによる予測再現率)

えられる。本比較では、佐々木らの手法と条件を合わせるために、説明変数として利用するセンサの種類を制限している。一方で、佐々木らの手法では、hh104 データセットには存在しない Echonet 家電の利用状況などを説明変数として利用している。また、行動ラベルの丸め方に関して、本比較では朝食、昼食、夕食、それ以外の食事を全て同様の Eat 行動としてラベリングしている。周期的な行動としての食事は予測しやすいことが考えられるが、間食や夜食など居住者が自由なタイミングでとる食事は予測が困難である。したがって、行動予測を実サービスへ応用する際には、制御する家電などに応じて、これらの行動ラベルの丸め方を考慮し、予測する行動の種類を決定する必要がある。

5.2 取り出す時間区間の比較

図 3 に、hh104 データセット内から 7 月 1 日～7 月 13 日、7 月 14 日～7 月 27 日、8 月 1 日～8 月 13 日区間をそれぞれ抜き出して学習を行った結果の各時間内行動生起の予測再現率を示す。なお、7 月 1 日からのデータでは、Bathe 行動と LeaveHome 行動が生起しておらず、全ての時間区間で Read 行動が生起していないため、行動ラベルとして存在しない。

結果より、7 月 14 日からのデータと 8 月 1 日からのデータを比較した際に、大きな予測再現率の差異は見られない。しかしながら、7 月 1 日からのデータはその他の時間区間のデータと比較して、Sleep 行動や WatchTV 行動の予測再現率が高いことが読み取れる。結果の要因

として、分類する行動ラベル数が、7 月 1 日からのデータのみ少なかったことが考えられる。また、時間区間によって居住者の行動様式が変化することで、行動の周期性が変化していたことが考えられる。たとえば、外気温の上昇による外出頻度の低下や休暇に伴う仕事頻度の低下などの非定常的なノイズによって、居住者の行動様式が変化することが考えられる。以上のことから、行動予測を行う際には、取り出す時間区間や季節、外的要因による行動数の増減や行動様式の変化を考慮する必要があることが示唆されている。

5.3 CASAS データセット間の比較

図 4 に、hh101, hh102, hh103, hh104 データセットを、同時期 (hh101 データセットは 2012 年 8 月 1 日～13 日、その他のデータセットは 2011 年 8 月 1 日～13 日) において学習した結果の各時間内行動生起の予測再現率を示す。なお、本比較において、hh101, hh102, hh103, hh104 データセットでは、それぞれ Groom 行動と Work 行動、LeaveHome 行動と Phone 行動、Groom 行動、Read 行動が生起していないため、行動ラベルとして存在しない。

結果より、Groom 行動や Phone 行動はどのデータセットにおいても共通して予測再現率が低く、Cook 行動や Sleep 行動は共通して予測再現率が高いことが読み取れる。しかしながら、hh103 データセットにおける Bathe 行動や、hh101 データセットにおける Read 行動など、データセット間で予測再現率に大きく差異がある行動が

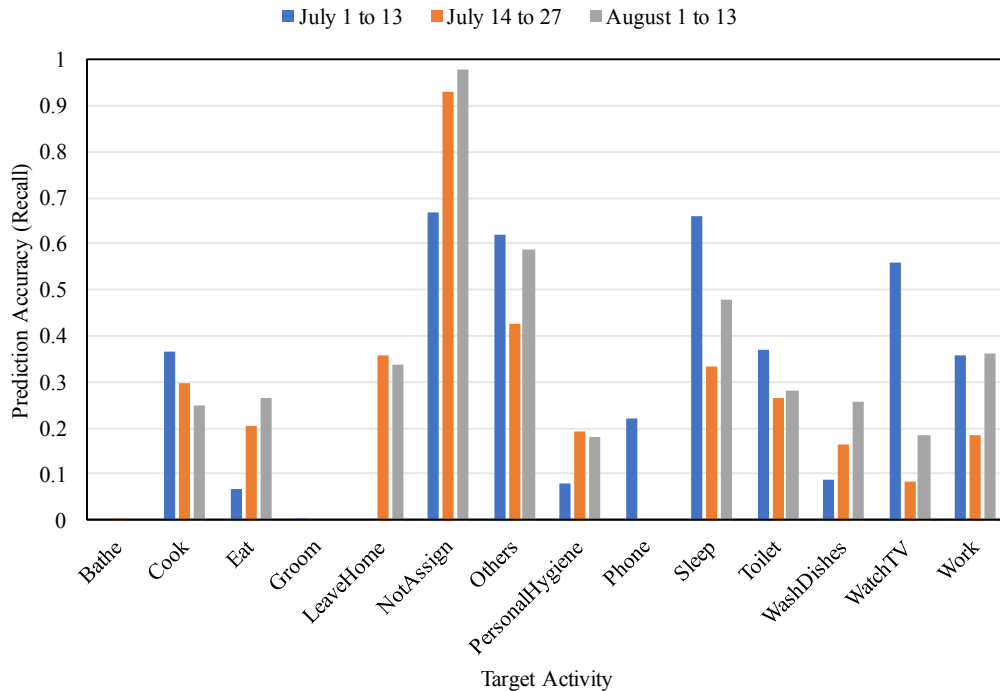


図 3: 訓練データの時間区間の違いによる予測再現率の比較

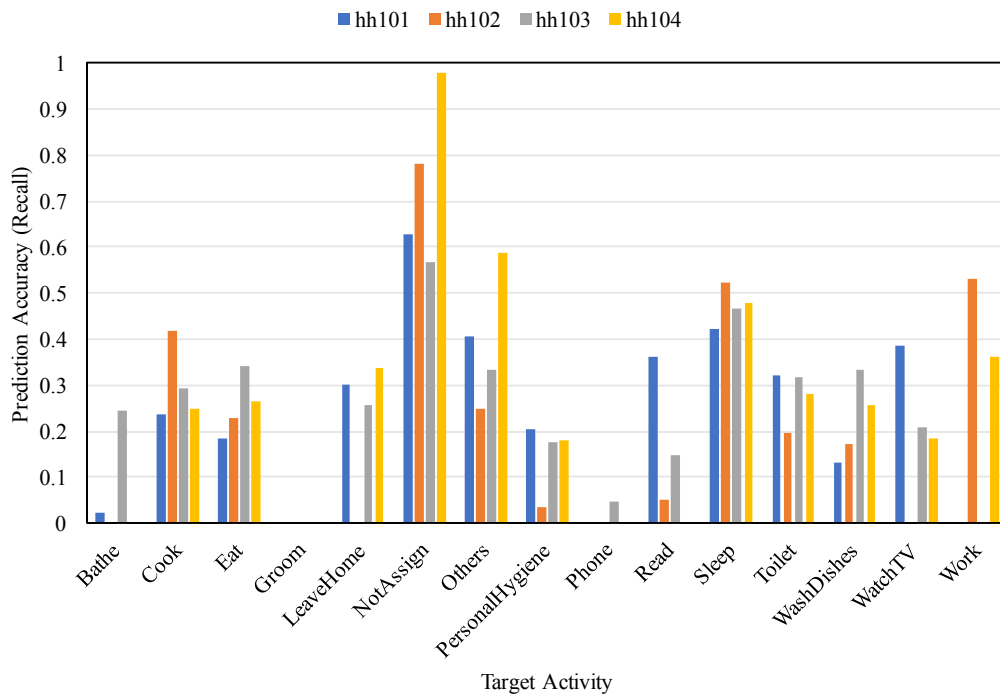


図 4: 対象家庭の違いによる予測再現率の比較

存在する。以上のことから、データセットによって予測しやすい行動が異なることが考えられる。今回利用したデータセットでは、取り出した時間区間は等しいものの、各データセットごとに居住者の特徴やセンサの設置位置・個数が異なっている。したがって、センシング対象となる居住者特有の行動様式や、宅内に設置するセンサの位

置によって行動予測の精度が変化することが考えられる。

5.4 学習期間ごとの比較

図 5 に、hh104 データセットをそれぞれ 2 週間、4 週間、6 週間、8 週間学習した結果の各時間内行動生起の予測再現率を示す。学習データ期間の取り出し方はそれぞれ 2 週間：8 月 1 日～8 月 14 日、4 週間：7 月 14 日～

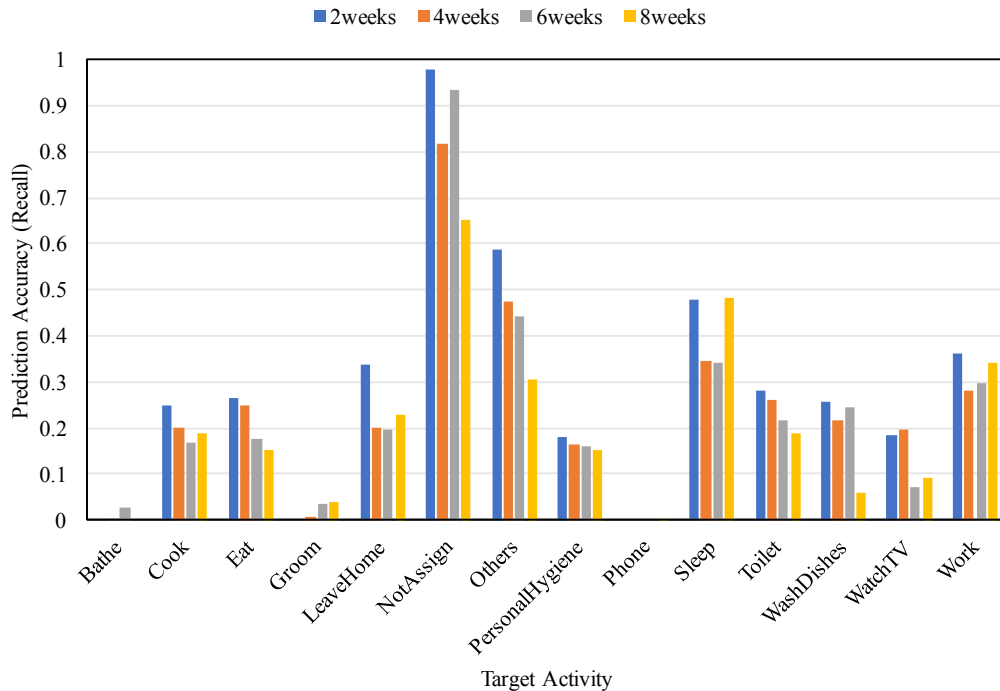


図 5: 学習データの期間の違いによる予測再現率の比較

8月14日, 6週間:7月1日~8月14日, 8週間:6月16日~8月14日とする. なお, 全ての学習期間において, Read 行動は生起していないため行動ラベルとして存在しない.

結果より, 2週間分のデータで学習した結果の予測再現率が平均的に最も高く, その他の期間で学習した結果の予測再現率は同程度であった. また, Sleep 行動や Work 行動などは8週間分のデータで学習することで予測再現率が増加していることが読み取れる. すなわち, 本比較において, 最も短い学習期間の結果が最も良い予測再現率を示している. その一方で, 学習期間を長期にすることで予測再現率の改善傾向が見られる. この結果の要因として, 学習データ数が増加することで, 学習に不要なデータも同様に増加し, データの不均衡度合いが増大することが考えられる. たとえば, 行動ラベルの割り振られていない期間が長期になるほど, 予測モデルは短期間しか行われていない行動を予測しなくなるため, 予測再現率が低下する. したがって, 取捨選択を行わず, 単純に多くのデータを利用して学習することは, 予測再現率を低下させる要因となりうることを示唆している. この問題に対して, 訓練データのオーギュメントやアップ・ダウンサンプリング, 学習時におけるクラスごとの重み付けが必要である.

6. おわりに

本稿では, 実サービスへの応用を前提とした宅内における居住者の行動予測の精度向上を目的として, 次行動生起までの時間を分類問題として扱う佐々木らの手法を hh104 データセットに適用し, その結果を佐々木らの結果と比較した. 比較結果から, 学習に利用するデータの取捨選択や行動ラベルの丸め方を工夫することにより予測精度の向上が可能であると結論づけた. また, 利用するデータセットの検証として, 取り出す時間区間での比較, 異なるデータセット間での比較, 学習期間長ごとの比較を行い, 行動予測に利用するデータセットに関する考察を行った.

取り出す時間区間での比較では, 居住者の行動様式が時期によって変化し, それにより行動予測の精度が変化することが示唆されている. また, 分類するクラス数によって予測再現率が変化することがわかった.

CASAS データセット間の比較では, 各データセットにおける居住者の行動様式, センサ設置位置情報, 間取り情報に応じて, 予測しやすい行動が異なることがわかった. したがって, 実サービスへの応用を考慮する場合, 可能な限りセンサの設置位置や種類を統一するように配慮する必要がある.

学習期間長ごとの比較では, 学習する期間によって予測再現率が変化することがわかった. また, データの取捨選択を行うことなく, 単純に学習期間を伸ばすことで, 予測精度の低下につながることを示唆されている.

今後の展望として、居住者の行動の流れや周期性を重視した、より実サービスに適用しやすい行動予測の問題設定やデータの取捨選択を行う。具体的に、行動ラベルの丸め方に関して、間食を示す Eat 行動と定期的な食事である EatBreakfast 行動, EatLunch 行動, EatDinner 行動などは、実サービスへの適用を考慮するならば、明示的に区別するべきである。また、得られたセンサデータから特徴量を生成し、説明変数として利用することや、主成分分析による寄与率の調査が必要である。さらに、スマートホームで得られる居住者の行動データは不均衡であることが殆どであるため、予測精度の向上のために、学習時の重み付けなどによるアルゴリズムレベルでの不均衡是正へのアプローチや、データオーギュメント、アップ・ダウンサンプリングなどのデータレベルでの不均衡是正へのアプローチを行う。

謝辞

本研究の一部は Society 5.0 実現化研究拠点支援事業の助成を受けて行った。

参考文献

- [1] Abdulsalam Yassine, Shailendra Singh, and Atif Alamri. Mining human activity patterns from smart home big data for health care applications. *IEEE Access*, Vol. 5, pp. 13131–13141, 2017.
- [2] Nagender Kumar Suryadevara, Subhas C Mukhopadhyay, Ruili Wang, and RK Rayudu. Forecasting the behavior of an elderly using wireless sensors data in a smart home. *Engineering Applications of Artificial Intelligence*, Vol. 26, No. 10, pp. 2641–2652, 2013.
- [3] Minh Pham, Yehenew Mengistu, Ha Do, and Weihua Sheng. Delivering home healthcare through a cloud-based smart home environment (coshe). *Future Generation Computer Systems*, Vol. 81, pp. 129–140, 2018.
- [4] Zaineb Liouane, Tayeb Lemlouma, Philippe Roose, Frédéric Weis, and Hassani Messaoud. An improved extreme learning machine model for the prediction of human scenarios in smart homes. *Applied Intelligence*, Vol. 48, No. 8, pp. 2017–2030, 2018.
- [5] 経済産業省 : スマートホームに関するデータ活用環境整備推進事業. available from <https://www.meti.go.jp/press/2017/05/20170523004/20170523004.html> (accessed 2019-07-25).
- [6] 佐々木渉, 藤原聖司, 藤本まなと, 諏訪博彦, 荒川豊, 安本慶一ほか. スマートホームデータの時系列分析に基づく宅内行動生起タイミングの予測. マルチメディア, 分散協調とモバイルシンポジウム 2018 論文集, Vol. 2018, pp. 1220–1226, 2018.
- [7] Washington State University : CASAS Datasets. available from <http://casas.wsu.edu/datasets/> (accessed 2019-07-25).
- [8] Ehsan Nazerfard and Diane J Cook. Using bayesian networks for daily activity prediction. In *Workshops at the Twenty-Seventh AAAI Conference on Artificial Intelligence*, 2013.
- [9] Bryan Minor and Diane J Cook. Forecasting occurrences of activities. *Pervasive and mobile computing*, Vol. 38, pp. 77–91, 2017.
- [10] Mohammad Marufuzzaman, Mamun Bin Ibne Reaz, Labonnah Farzana Rahman, and Araf Farayez. A location based sequence prediction algorithm for determining next activity in smart home. *Journal of Engineering Science & Technology Review*, Vol. 10, No. 2, 2017.
- [11] Niek Tax. Human activity prediction in smart home environments with lstm neural networks. In *2018 14th International Conference on Intelligent Environments (IE)*, pp. 40–47. IEEE, 2018.