

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



دانشکده مهندسی کامپیوتر و فناوری اطلاعات  
رشته مهندسی کامپیوتر- گرایش هوش مصنوعی

رساله دکتری

## یک معماری برای شناسایی اعمال انسان تحت شرایط پیچیده در خانه‌های هوشمند

نگارنده: وحید قاسمی

استاد راهنما

دکتر علی اکبر پویان

اساتید مشاور

دکتر علیرضا احمدی فرد- دکتر محسن شریفی

شهریور ۱۳۹۶

شماره: ۷۴۴ رف. ا

تاریخ: ۹۶/۶/۱۴

ویرایش:

باسمه تعالی



مدیریت تحصیلات تکمیلی

فرم شماره ۱۲: صورت جلسه نهایی دفاع از رساله دکتری (Ph.D)  
(ویژه دانشجویان ورودی های ۹۴ و ما قبل)

بدینوسیله گواهی می شود آقای وحید قاسمی دانشجوی دکتری رشته مهندسی کامپیوتر به شماره دانشجویی ۹۰۲۴۷۵ ورودی بهمن ماه سال ۱۳۹۰ در تاریخ ۹۶/۰۶/۰۸ از رساله نظری / عملی خود با عنوان: یک معماری برای شناسایی اعمال انسان تحت شرایط پیچیده در خانه های هوشمند در خانه های هوشمند ۱۸/۱۷ به درجه: دکتری نائل گردید.

|  |  |
|--|--|
| <input checked="" type="checkbox"/> الف) درجه عالی: نمره ۱۹-۲۰ | <input type="checkbox"/> ب) درجه بسیار خوب: نمره ۱۸/۹۹-۱۷          |
| <input type="checkbox"/> ج) درجه خوب: نمره ۱۶/۹۹-۱۵            | <input type="checkbox"/> د) غیر قابل قبول و نیاز به دفاع مجدد دارد |
| <input type="checkbox"/> ه) رساله نیاز به اصلاحات دارد         |  |

| ردیف | هیئت داوران                               | نام و نام خانوادگی             | مرتبه علمی        | امضاء |
|------|---|--------------------------------|-------------------|-------|
| ۱    | دکتر علی اکبر پویان                       | استاد راهنما                   | استادیار          |       |
| ۲    | دکتر علیرضا احمدی فرد-<br>دکتر محسن شریفی | مشاورین                        | دانشیار-<br>استاد |       |
| ۳    | دکتر اسداله شاه بهرامی                    | استاد خارجی                    | دانشیار           |       |
| ۴    | دکتر امیدرضا معروضی                       | استاد مدعو داخلی               | استادیار          |       |
| ۵    | دکتر محسن رضوانی                          | استاد مدعو داخلی               | استادیار          |       |
| ۶    | دکتر هدی مشایخی                           | نماینده تحصیلات تکمیلی دانشکده | استادیار          |       |

مدیر محترم تحصیلات تکمیلی دانشگاه:

ضمن تأیید مراتب فوق مقرر فرمائید اقدامات لازم در خصوص انجام مراحل دانش آموختگی آقای وحید قاسمی بعمل آید.

نام و نام خانوادگی رئیس دانشکده:

تاریخ و امضاء و مهر دانشکده:

شماره: ۷۴۴ رف

تاریخ: ۹۶/۱۲/۱۲

ویرایش:

باسمه تعالی



مدیریت تحصیلات تکمیلی

پیوست شماره ۲

دانشکده: مهندسی کامپیوتر و فناوری اطلاعات

گروه: مهندسی کامپیوتر

رساله دکتری آقای وحید قاسمی

تحت عنوان: یک معماری برای شناسایی اعمال انسان تحت شرایط پیچیده در خانه های هوشمند  
در تاریخ ۹۶/۰۶/۰۸ توسط کمیته تخصصی زیر جهت اخذ مدرک کارشناسی ارشد/ رساله دکتری ارزیابی گردید و با درجه  
بسیار خوب مورد پذیرش قرار گرفت.

| امضاء | اساتید مشاور                                 | امضاء | اساتید راهنما                              |
|-------|--|-------|--|
|       | نام و نام خانوادگی:<br>دکتر علیرضا احمدی فرد |       | نام و نام خانوادگی:<br>دکتر علی اکبر پویان |
|       | نام و نام خانوادگی:<br>دکتر محسن شریفی       |       | نام و نام خانوادگی:                        |

| امضاء | نماینده تحصیلات تکمیلی                 | امضاء | اساتید داور                                     |
|-------|--|-------|---|
|       | نام و نام خانوادگی:<br>دکتر هدی مشایخی |       | نام و نام خانوادگی:<br>دکتر اسداله شاه بهرامی ✓ |
|       |  |       | نام و نام خانوادگی:<br>دکتر امیدرضا معروضی      |
|       |  |       | نام و نام خانوادگی:<br>دکتر محسن رضوانی         |

تقدیم بہ پدرم بہ استواری کوه، مادرم بہ مہربانی چشمہ، و ہمسرم بہ پائی باران۔

## هو العلميم

بي شك اگر امروز با آسايش كام در راه كسب علم مي گذاريم، مديون مرداني بي ادعايم كه عاشقانه جان خود را خاك پاكان  
كرده اند. باشد كه حق اين عشق به درستي به جاي آوريم.

بر خود لازم ميدانم كه مراتب تشكر و قدرداني خود را از استاد شايسته ام، جناب آقاي دكتور علي اكبر پويان، كه در كمال سعه صدر، با  
سن خلق و فروتنی، از بهيچ گلي دينغ نمودند و زحمت راهنمائي اين رساله را بر عهده گرفتند، به جاي آورم. همچنين، از پدر و مادر عزيزم،  
كه همواره بر كوتاهي و درستي من قلم عفو كشيده اند و همسر بزرگوارم كه همواره باعث دلگرمي من بوده است نيز كمال قدرداني و  
پاس را دارم.

## تعهد نامه

این جانب وحید قاسمی دانشجوی دوره دکتری رشته مهندسی کامپیوتر/هوش مصنوعی دانشکده مهندسی کامپیوتر و فناوری اطلاعات دانشگاه صنعتی شاهرود نویسنده پایان نامه یک معماری برای شناسایی اعمال انسان تحت شرایط پیچیده در خانه های هوشمند، تحت راهنمایی دکتر علی اکبر پویان متعهد می شوم :

- تحقیقات در این پایان نامه توسط این جانب انجام شده است و از صحت و اصالت برخوردار است.
- در استفاده از نتایج پژوهش های محققان دیگر به مرجع مورد استفاده استناد شده است.
- مطالب مندرج در پایان نامه تاکنون توسط خود یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ جا ارائه نشده است.
- کلیه حقوق معنوی این اثر متعلق به دانشگاه صنعتی شاهرود می باشد و مقالات مستخرج با نام « دانشگاه صنعتی شاهرود » و یا « Shahrood University of Technology » به چاپ خواهد رسید.
- حقوق معنوی تمام افرادی که در به دست آمدن نتایج اصلی پایان نامه تأثیرگذار بوده اند در مقالات مستخرج از پایان نامه رعایت می گردد.
- در کلیه مراحل انجام این پایان نامه ، در مواردی که از موجود زنده ( یا بافتهای آن ها ) استفاده شده است ضوابط و اصول اخلاقی رعایت شده است.
- در کلیه مراحل انجام این پایان نامه، در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته یا استفاده شده است اصل رازداری ، ضوابط و اصول اخلاق انسانی رعایت شده است .

تاریخ:

امضای دانشجو :

### مالکیت نتایج و حق نشر

- کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج، کتاب، برنامه های رایانه ای، نرم افزار ها و تجهیزات ساخته شده است ) متعلق به دانشگاه صنعتی شاهرود می باشد. این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر شود.
- استفاده از اطلاعات و نتایج موجود در پایان نامه بدون ذکر مرجع مجاز نمی باشد.

## چکیده

امروزه توسعه خانه‌های هوشمند با هدف کمک به زندگی راحت‌تر انسان‌ها، مورد توجه بسیاری از محققین قرار گرفته است. کمک به افراد سالخورده و ناتوان، ایجاد امنیت بیشتر، مدیریت مصرف انرژی، مراقبت‌های پزشکی، از جمله انگیزه‌های توسعه چنین محیط‌هایی می‌باشند. در چنین محیط‌هایی، تصمیم‌گیری در خصوص ارائه خدمات، بر اساس اعمال انجام شده کاربران صورت می‌گیرد. لذا شناسایی اعمال از اهمیت ویژه‌ای برخوردار است. در اینگونه محیط‌ها از انواع مختلفی از حسگرها برای جمع‌آوری داده‌های مربوط به کاربران و فعالیت‌های آنان استفاده می‌شود. سپس، با استفاده از این داده‌ها، و با به کارگیری روش‌های یادگیری ماشین و داده‌کاوی، سعی می‌شود اعمال آنان بازشناسی گردد.

در عمده کارهایی که تا کنون برای شناسایی اعمال ارائه شده‌اند، پیش‌فرض‌هایی برای ساده‌سازی شناسایی اعمال در نظر گرفته شده و کمتر به موقعیت‌های پیچیده‌تر در دنیای واقعی پرداخته شده است. در بسیاری از سناریوهای دنیای واقعی چنین پیش‌فرض‌هایی محدود کننده هستند و در عمل وجود نخواهند داشت. از جمله این پیش‌فرض‌ها، انجام ترتیبی اعمال، وجود محیط تک کاربره، و لحاظ نکردن عدم قطعیت در داده‌های حسگرها و استنتاج می‌باشند. ضرورت دارد تا حد امکان از تاثیر این پیش‌فرض‌ها در شناسایی اعمال کاسته شده، و فرآیندهای شناسایی اعمال برای سناریوهای پیچیده‌تر در دنیای واقعی تطبیق یابند. لذا در این رساله، به دنبال شناسایی اعمال در چنین شرایطی خواهیم بود.

با در نظر گرفتن شرایط فوق، در این رساله یک معماری سه لایه برای شناسایی اعمال ارائه گردیده است. لایه‌های این معماری به ترتیب، مربوط به اخذ داده‌ها، بازشناسی اعمال در محیط‌های تک کاربره، و بازشناسی اعمال در محیط‌های چند کاربره می‌باشند. در نخستین لایه این معماری، داده‌های کاربران با استفاده از حسگرهای محیطی جمع‌آوری شده، و به صورت جریانی از داده‌ها (رویدادهای حسگرها) در اختیار لایه‌های بعدی قرار می‌گیرند. لایه دوم به بازشناسی اعمال در محیط‌های تک کاربره، با تاکید بر کاهش عدم قطعیت در استنتاج می‌پردازد. در لایه سوم، ابتدا دنباله داده‌های کاربران در محیط‌های چند کاربره مدل‌سازی، و از هم تفکیک می‌شوند. سپس، اعمال کاربران بر روی دنباله داده‌های جدا شده، با به کارگیری رویکردهای ارائه شده برای محیط‌های تک کاربره در لایه دوم، بازشناسی می‌گردند. نتایج نشان می‌دهند که معماری پیشنهادی در مقایسه با رویکردهای مرسوم، که عمدتاً مبتنی بر مدل‌های گرافیکی هستند، کارایی بهتری را از خود نشان می‌دهد.

**کلمات کلیدی:** خانه‌های هوشمند، شناسایی اعمال، عدم قطعیت، محیط چند کاربره، سنجش متراکم، شبکه‌های حسگر بیسیم.



## مقالات استخراج شده از رساله

### مقالات پذیرفته شده در مجلات

- 1- V. Ghasemi, A. A. Pouyan, "Modeling **Users' Data Traces in Multi-Resident Ambient Assisted Living Environments**", International Journal of Computational Intelligence Systems (IJCIS), special issue on Computational Intelligence for Smart Environments, 2017, **(Accepted)**.
- 2- V. Ghasemi, A. A. Pouyan, and M. Sharifi, "**Human Activity Recognition in Smart Homes Based on a Difference of Convex Programming Problem**", KSII Transactions on Internet and Information Systems, 2017, 11, (1), pp. 321-344.
- 3- V. Ghasemi, A. Pouyan, and M. Sharifi, "**A Sensor-Based Scheme for Activity Recognition in Smart Homes using Dempster-Shafer Theory of Evidence**", Journal of AI and Data Mining, vol. 5, pp. 245-258, 2017.

### مقالات پذیرفته شده در کنفرانس‌ها

- 1- Ghasemi, Vahid, and Ali Akbar Pouyan. "**Activity recognition in smart homes using absolute temporal information in dynamic graphical models**", *Control Conference (ASCC), 2015 10th Asian*. IEEE, 2015.
- 2- Ghasemi, Vahid, and Ali Akbar Pouyan. "**Human activity recognition in ambient assisted living environments using a convex optimization problem**", *Signal Processing and Intelligent Systems (ICSPIS), International Conference of*. IEEE, 2016.

## فهرست مطالب

- فصل ۱ . معرفی ..... ۱
- ۱-۱ مقدمه ..... ۲
- ۲-۱ اعمال ترتیبی، متداخل، و همروند ..... ۳
- ۳-۱ حسگرهای مورد استفاده ..... ۵
- ۴-۱ بیان مساله ..... ۷
- ۵-۱ چالش‌ها ..... ۸
- 1-6 اهداف مورد نظر ..... ۱۰
- ۷-۱ مفروضات مورد نظر برای مساله شناسایی اعمال ..... ۱۱
- ۸-۱ مجموعه‌های داده ..... ۱۲
- ۹-۱ معماری پیشنهادی ..... ۱۴
- ۱۰-۱ نوآوری‌ها ..... ۱۸
- ۱۱-۱ ساختار رساله ..... ۱۹
- ۱۲-۱ جمع‌بندی ..... ۲۰
- فصل ۲ . مروری بر کارهای پیشین ..... ۲۱
- ۱-۲ مقدمه ..... ۲۲
- ۲-۲ رویکردهای مبتنی بر تصویر ..... ۲۴
- ۳-۲ رویکردهای مبتنی بر حسگرها ..... ۲۶
- ۱-۳-۲ تشخیص اعمال، با استفاده از حسگرهای پوشیدنی ..... ۲۷
- ۲-۳-۲ رویکردهای مبتنی بر سنجش متراکم ..... ۳۰

|    |  |
|----|--|
| ۳۰ | ..... روش‌های مبتنی بر داده ۱-۲-۳-۲  |
| ۴۹ | ..... روش‌های مبتنی بر دانش ۲-۲-۳-۲  |
| ۵۸ | ..... روش‌های هیبریدی ۳-۲-۳-۲  |
| ۵۹ | ..... جمع بندی ۴-۲   |
| ۶۳ | ..... فصل ۳ . راهکار پیشنهادی اول برای شناسایی اعمال، مبتنی بر نظریه دمپستر-شافر |
| ۶۴ | ..... ۱-۳ مقدمه  |
| ۶۵ | ..... ۲-۳ قالب کلی رویکرد پیشنهادی برای شناسایی اعمال                            |
| ۶۶ | ..... ۳-۳ پیاده سازی رویکرد پیشنهادی با استفاده از DST                           |
| ۷۰ | ..... ۱-۳-۳ نظریه DS و محاسبه BPA  |
| ۷۲ | ..... ۲-۳-۳ به دست آوردن شاهدها برای یک عمل                                      |
| ۷۳ | ..... ۳-۳-۳ فضای عقاید و تشخیص شاهدهای مربوط به یک عمل                           |
| ۷۴ | ..... ۴-۳-۳ ترکیب عقاید شاهدها و استنتاج   |
| ۷۵ | ..... ۵-۳-۳ پیاده سازی و ارزیابی   |
| ۷۷ | ..... ۱-۵-۳-۳ آزمایش اول   |
| ۸۰ | ..... ۲-۵-۳-۳ آزمایش دوم   |
| ۸۲ | ..... ۴-۳ جمع بندی   |
| ۸۵ | ..... فصل ۴ . راهکار پیشنهادی دوم برای شناسایی اعمال، مبتنی بر بهینه سازی        |
| ۸۶ | ..... ۱-۴ مقدمه  |
| ۸۸ | ..... ۲-۴ جریان داده حسگرها و نمادگذاری های مربوطه                               |
| ۹۰ | ..... ۳-۴ روش پیشنهادی   |

- ۹۳..... محاسبه بردارهای باور اولیه (PBV).....
- ۹۵..... شناسایی اعمال با استفاده از یک مساله برنامه ریزی تفاضل محدب (DCP).....
- ۹۶..... شناسایی اعمال با استفاده از بردارهای باور ثانویه.....
- ۱۰۱..... پیاده سازی و ارزیابی.....
- ۱۰۲..... ۱-۴-۴ آزمایش اول.....
- ۱۰۵..... ۲-۴-۴ آزمایش دوم.....
- ۱۰۵..... ۵-۴ جمع بندی.....
- ۱۰۷..... فصل ۵. بازشناسی اعمال در محیط‌های با چند کاربر.....
- ۱۰۸..... ۱-۵ مقدمه.....
- ۱۱۰..... ۲-۵ مدل سازی دنباله داده های کاربران.....
- ۱۱۰..... ۱-۲-۵ ساختار شبکه حسگر، و وضعیت‌های محیط.....
- ۱۱۲..... ۲-۲-۵ دنباله داده‌های کاربران و بیان مساله مدل‌سازی آنها.....
- ۱۱۴..... ۳-۲-۵ تخمین کمترین مربعات شرطی (CLS).....
- ۱۱۶..... ۴-۲-۵ روش پیشنهادی برای تخمین پارامترهای زنجیره مارکوف.....
- ۱۱۶..... ۱-۴-۲-۵ گراف دسترسی.....
- ۱۱۸..... ۲-۴-۲-۵ تنظیم تخمین های CLS.....
- ۱۱۹..... ۳-۵ استخراج دنباله داده های کاربران.....
- ۱۲۱..... ۱-۳-۵ الگوریتم فیلتر ذرات برای تفکیک دنباله داده‌های کاربران.....
- ۱۲۲..... ۲-۳-۵ بسط ذرات.....
- ۱۲۵..... ۳-۳-۵ امتیاز دهی به ذرات.....
- ۱۲۸..... ۴-۵ شناسایی اعمال روی دنباله داده‌های استخراج شده.....

|     |                                     |
|-----|-------------------------------------|
| ۱۳۰ | ..... ۵-۵ ارزیابی و پیاده سازی      |
| ۱۳۱ | ..... ۱-۵-۵ آزمایش اول              |
| ۱۳۳ | ..... ۲-۵-۵ آزمایش دوم              |
| ۱۳۵ | ..... ۳-۵-۵ آزمایش سوم              |
| ۱۳۹ | ..... ۶-۵ جمع بندی                  |
| ۱۴۱ | ..... فصل ۶ . جمع بندی و کارهای آتی |
| ۱۴۲ | ..... ۱-۶ جمع بندی                  |
| ۱۴۴ | ..... ۲-۶ کارهای آتی                |

## فهرست شکل‌ها

- شکل ۱-۱. الف- اعمال ترتیبی. ب- اعمال متداخل. ج- اعمال هم‌روند. ۴.....
- شکل ۲-۱. معماری سه لایه پیشنهادی برای شناسایی اعمال. ۱۶.....
- شکل ۱-۲. دسته بندی روش‌های بازشناسی اعمال انسان در محیط‌های هوشمند. ۲۴.....
- شکل ۲-۲. الف- گراف قالب یک مدل گرافیکی، ب- گراف باز شده یک شبکه بیزین. ۳۶.....
- شکل ۳-۲. الف) ساختار یک NBC، ب) ساختار یک HMM، ج) ساختار یک HHMM برای تشخیص اعمال [۱۰]. ۳۸.....
- شکل ۴-۲. الف- میدان تصادفی شرطی خطی، ب- میدان تصادفی شرطی با زنجیره پرش (SCCRF)، ج-میدان تصادفی شزطی نهان دینامیکی (LDCRF). ۴۰.....
- شکل ۵-۲. الف- ساختار PHMM، ب- CHMM و ج- FCRF، برای شناسایی اعمال در محیط چند کاربره. ۴۴.....
- شکل ۶-۲. هستان شناسی عمل "استفاده از سرویس بهداشتی" در BDS [104]. ۵۶.....
- شکل ۷-۲. هستان شناسی عمل "استفاده از سرویس بهداشتی" در 3LDS [۱۰۵]. ۵۷.....
- شکل ۱-۳. قالب کلی اولین رویکرد پیشنهادی برای شناسایی اعمال. ۶۷.....
- شکل ۲-۳. پیاده‌سازی رویکرد پیشنهادی با به کار گیری نظریه DS. ۶۹.....
- شکل ۳-۳. فضای عقاید. ۷۳.....
- شکل ۴-۳. نحوه ترکیب عقاید شاهدها. ۷۵.....
- شکل ۵-۳. الف- داده‌های خام حسگرها، ب- ویژگی‌های CP، ج- ویژگی‌های LC [۶۰]. ۸۱.....
- شکل ۱-۴. مثالی از جریان داده حسگرها. ۸۹.....
- شکل ۲-۴. نحوه انجام اعمال به صورت ترتیبی، متداخل و هم‌روند. ۹۰.....
- شکل ۳-۴. فازها و مراحل روش پیشنهادی (DCPAR). ۹۱.....

- شکل ۴-۴. شبه کد مرحله آموزش. ۹۲.....
- شکل ۵-۴. شبه کد مرحله آزمون. ۹۲.....
- شکل ۶-۴. تابع  $u(x)$ ، و اکستریم‌های آن. ۹۶.....
- شکل ۷-۴. نتایج جستجو برای پارامترهای  $\lambda$  و  $\gamma$  در اولین دور از LOOCV. ۱۰۲.....
- شکل ۸-۴. مقایسه صحت روشهای مختلف. ۱۰۴.....
- شکل ۱-۵. لایه سوم معماری پیشنهادی. ۱۱۰.....
- شکل ۲-۵. مثالی از نحوه فعال شدن حسگرها در محیطی با دو کاربر و سه حسگر. ۱۱۱.....
- شکل ۳-۵. نحوه ایجاد داده‌های مجتمع توسط دنباله داده‌های کاربران. ۱۱۲.....
- شکل ۴-۵. گراف دسترسی برای بخشی از خانه هوشمند پیاده سازی شده در [۶۱]. ۱۱۷.....
- شکل ۵-۵. ساختار یک ذره در محیطی با سه کاربر. ۱۲۲.....
- شکل ۶-۵. الگوریتم فیلتر ذرات برای استخراج دنباله داده‌های کاربران. ۱۲۲.....
- شکل ۷-۵. شبه کد مربوط به بسط ذرات (تابع  $(.)$  extend). ۱۲۵.....
- شکل ۸-۵. پروسه بسط ذرات در دور  $t$  ام از الگوریتم شکل ۷-۵. ۱۲۶.....
- شکل ۹-۵. به دست آوردن جریان رویدادهای حسگرها از روی دنباله داده‌های استخراج شده. ۱۲۹.....
- شکل ۱۰-۵. فاصله Kullback-Leibler بین سطرهای ماتریس‌های انتقال تخمین زده شده و ماتریس انتقال واقعی (برای حسگرهای غیر حرکتی). ۱۳۲.....
- شکل ۱۱-۵. فاصله Kullback-Leibler بین سطرهای ماتریس‌های انتقال تخمین زده شده و ماتریس انتقال واقعی (برای حسگرهای حرکتی). ۱۳۳.....
- شکل ۱۲-۵. خلوص دنباله‌های استخراج شده از قطعات با طول از ۲۰ تا ۲۵۰ برش زمانی. ۱۳۴.....
- شکل ۱۳-۵. خلوص دنباله‌های استخراج شده از قطعات با طول از ۲۶۰ تا ۵۰۰ واحد زمانی. ۱۳۵.....
- شکل ۱۴-۵. الف) ساختار CHMM مورد استفاده، و ب) ساختار FCRF مورد استفاده. ۱۳۶.....

شکل ۵-۱۵. صحت روش‌های شناسایی اعمال..... ۱۳۸



## فهرست جدول‌ها

- جدول ۱-۱. برخی از مجموعه داده‌های مرکز تحقیقاتی CASAS [۱۳]..... ۱۳
- جدول ۱-۲. ویژگی‌های معمول در رویکردهای موجود..... ۶۰
- جدول ۱-۳. نتایج روش پیشنهادی برای شناسایی اعمال..... ۷۹
- جدول ۲-۳. نتایج روش‌های BDS، 2LDS، 3LDS، و روش پیشنهادی..... ۷۹
- جدول ۳-۳. مقایسه روش پیشنهادی با 2LDS و 3LDS با استفاده از آزمون فرض  $t$ ..... ۸۰
- جدول ۴-۳. نتایج به دست آمده از روش پیشنهادی، NBC، HMM، و HSMM..... ۸۲
- جدول ۱-۴. مثالی از شناسه، نوع، دامنه، و رویدادهای ممکن برای حسگرها..... ۸۹
- جدول ۲-۴. محدودیت‌های لازم برای محاسبه بردارهای باور ثانویه ( $M_i, i = 1, \dots, T$ )..... ۹۷
- جدول ۳-۴. اعمال انجام شده توسط کاربران در مجموعه داده مرجع {Singla, ۲۰۰۹#۶۲}..... ۱۰۱
- جدول ۴-۴. مقایسه DCPAR با HMM..... ۱۰۳
- جدول ۵-۴. نتایج ارزیابی برای روش‌های DCPAR، SMAA، SMSA، و SCCRF..... ۱۰۴
- جدول ۶-۴. نتایج ارزیابی برای مقایسه DCPAR و CPAR..... ۱۰۵
- جدول ۱-۵. اعمالی که در مجموعه داده وجود دارند..... ۱۳۱
- جدول ۲-۵. مقایسه رویکردهای DCPAR+PF، CHMM، و FCRF..... ۱۳۷
- جدول ۳-۵. مقایسه DCPAR+PF و CPAR+PF..... ۱۳۹

## فهرست اختصارات

|              |   |              |   |
|--------------|---|--------------|---|
| <b>2LDS</b>  | 2-layered Dempster-Shafer                                   | <b>HOG</b>   | Histogram of Oriented Gradient          |
| <b>3LDS</b>  | 3-layered Dempster-Shafer                                   | <b>HSMM</b>  | Hidden Semi-Markov Model                |
| <b>ANN</b>   | Artificial Neural Networks                                  | <b>IoT</b>   | Internet of Things                      |
| <b>BPA</b>   | Basic Probability Assignment                                | <b>KNN</b>   | K-Nearest Neighbor                      |
| <b>BS</b>    | Body Sensors  | <b>LBP</b>   | Loopy Belief Propagation                |
| <b>CASAS</b> | Center for Advanced Studies in Adaptive Systems             | <b>LDCRF</b> | Latent Dynamic Conditional Random Field |
| <b>CCP</b>   | Convex-Concave Procedure                                    | <b>LF</b>    | Last Fired                              |
| <b>CHMM</b>  | Coupled Hidden Markov Model                                 | <b>LOOCV</b> | Leave One Out Cross Validation          |
| <b>CLS</b>   | Conditional Least Squares                                   | <b>LZW</b>   | Lempel-Ziv-Welch                        |
| <b>CP</b>    | Change Point  | <b>MAP</b>   | Maximum a Posteriori                    |
| <b>CPAR</b>  | Convex Programming-Based Activity Recognition               | <b>MERL</b>  | Mitsubishi Electric Research Labs       |
| <b>CRF</b>   | Conditional Random Field                                    | <b>MLE</b>   | Maximum Likelihood Estimation           |
| <b>DBN</b>   | Dynamic Bayesian Network                                    | <b>MLP</b>   | Multi-Layer Perceptron                  |
| <b>DCP</b>   | Difference of Convex Programming                            | <b>NBC</b>   | Naïve Bayes Classifier                  |
| <b>DCPAR</b> | Difference of Convex Programming-Based Activity Recognition | <b>PBV</b>   | Primary Belief Vector                   |
| <b>DST</b>   | Dempster-Shafer Theory                                      | <b>PHMM</b>  | Parallel HMM                            |
| <b>ECG</b>   | Electrocardiography   | <b>RFID</b>  | Radio-Frequency Identification          |
| <b>EP</b>    | Emerging Pattern  | <b>SBV</b>   | Secondary Belief Vectors                |
| <b>FCRF</b>  | Factorial Conditional Random Field                          | <b>SCCRF</b> | Skip-Chain Conditional random fields    |
| <b>HAR</b>   | Human Activity Recognition                                  | <b>SIFT</b>  | Scale-Invariant Feature Transform       |
| <b>HCI</b>   | Human-Computer Interaction                                  | <b>SMSA</b>  | Single Model Single Activity            |
| <b>HMM</b>   | Hidden Markov Model   | <b>SOM</b>   | Self Organizing Map                     |
| <b>HHMM</b>  | Hierarchical Hidden Markov Model                            | <b>SVM</b>   | Support Vector Machine                  |
| <b>HOF</b>   | Histogram of Optical Flow                                   |              |   |

## فصل ۱. معرفی

## ۱-۱ مقدمه

بررسی‌ها نشان می‌دهند که تعداد افراد سالخورده در جوامع مختلف رشد زیادی داشته و یا رو به افزایش است. به عنوان مثال، در اروپا گزارش شده که تعداد افراد سالخورده از ۱۰٪ در سال ۱۹۵۰ به بیش از ۲۵٪ در سال ۲۰۵۰ خواهد رسید. همچنین در ایران، در حال حاضر جمعیت افراد با سن بیشتر از ۶۵ سال بیش از ۷٪ گزارش شده و پیش بینی می‌شود که در سال ۲۰۵۰ به ۲۱٪ افزایش یابد [۱]. افزایش سن در افراد می‌تواند منجر به ناتوانی فیزیکی آنها گردد. حتی زمانی که افراد از سلامت فیزیکی برخوردارند، افزایش سن می‌تواند با کاهش حواس طبیعی، کاهش توانایی واکنش به محیط، و یا مشکلات حافظه همراه باشد. در چنین حالتی، نمی‌توان با قرار دادن تعداد زیادی مراقب برای این افراد، سلامتی آنها را تضمین کرد؛ زیرا اولاً این کار دشوار و هزینه‌بر است و ثانياً تعداد بسیاری از این افراد ترجیح می‌دهند تا جایی که ممکن است در خانه‌های خود و به طور مستقل زندگی کنند. این مساله موجب شده تا سیستم‌های نظارتی<sup>۱</sup> مانند خانه‌های هوشمند<sup>۲</sup> با هدف حمایت از افراد سالخورده‌ای که عموماً تنها زندگی می‌کنند، پدید آیند. چنین محیط‌هایی باید دارای توانایی یادگیری باشند تا بتوانند با استفاده از داده‌هایی که حسگرهای نصب شده در محیط فراهم می‌آورند، رفتارهای غیرطبیعی را تشخیص دهند.

علاوه بر مراقبت‌های پزشکی، برای بسیاری از افراد کسب آسایش بیشتر می‌تواند انگیزه مناسبی برای استفاده از خانه‌های هوشمند باشد [۲]. مثلاً اینکه در محیط منزل به طور سیستماتیک اطمینان داده شود زمانی که باران می‌بارد، همه پنجره‌ها بسته هستند و یا اینکه همواره کنترل شود که درب ورودی منزل قفل است. در واقع، یک خانه هوشمند با آگاهی از وضعیت فعلی محیط می‌تواند تصمیمی

---

<sup>۱</sup>Monitoring Systems

<sup>۲</sup>Smart House

به صورت خودمختار، و یا با مشارکت ساکنین آن، برای کنترل عوامل موجود در محیط اتخاذ نماید و حتی با استفاده از عملگرهای<sup>۱</sup> نصب شده، کاری را انجام دهد.

خانه‌های هوشمند می‌توانند در بهینه سازی میزان مصرف انرژی نیز موثر واقع شوند. مثلاً سیستم گرمایشی خانه می‌تواند بر اساس وضعیت جاری ساکنین و پیش بینی اینکه در چه زمانی آنها به خانه باز خواهند گشت به صورت خودکار فعال و غیر فعال گردد و دمای خانه را تنظیم نماید [۳]. در [۳] نشان داده شده که با به کار گیری این روش ۲۸٪ صرفه جویی در مصرف انرژی صورت خواهد گرفت.

در خانه‌های هوشمند اعمالی که توسط کاربران انجام می‌گیرند منشاء بسیاری از تصمیمات می‌باشند. به عنوان مثال، در سیستم‌های نظارت پزشکی با بررسی سطح فعالیت فرد در محیط و آنالیز اعمال انجام شده توسط او، پزشکان می‌توانند میزان سلامت جسمانی شخص را تعیین کنند. و یا اینکه بر حسب عمل انجام شده یا در حال انجام توسط کاربران، خدمات مقتضی به آنها ارائه می‌گردد. لذا بازشناسی اعمال کاربران در چنین محیط‌هایی از اهمیت ویژه‌ای برخوردار است. بدین منظور، داده‌های کاربران با استفاده از انواع مختلفی از حسگرها جمع‌آوری و پردازش می‌گردند. دنباله‌ای از این داده‌ها می‌تواند به عنوان یک عمل تفسیر گردد. این کار با به کارگیری تکنیک‌های مختلف یادگیری ماشین و داده‌کاوی انجام می‌گیرد. هرچند، با توجه به شرایط محیطی و نحوه انجام اعمال، چالش‌های جدی در بازشناسی اعمال وجود دارند که در ادامه به آنها خواهیم پرداخت.

## ۱-۲ اعمال ترتیبی، متداخل، و هم‌روند

---


<sup>۱</sup>Actuators

اعمالی که کاربران در محیط انجام می‌دهند، می‌توانند به صورت ترتیبی<sup>۱</sup>، متداخل<sup>۲</sup>، و یا هم‌روند<sup>۳</sup> باشند. در ذیل، تعاریف مربوط به اینگونه اعمال آورده شده و شکل (۱-۱) نمودار زمانی مربوط به آنها را نشان می‌دهد.

**اعمال ترتیبی:** اعمالی که مراحل آنها پشت سرهم و به صورت پیوسته در طول زمان انجام می‌گیرند. در این حالت، در هر زمان فقط یک عمل می‌تواند انجام شود. مثلاً کاربر پس از خوردن ناهار میز را جمع کرده و سپس به تماشای تلویزیون می‌پردازد.

**اعمال متداخل:** دو یا چند عمل که مراحل آنها می‌توانند توأم با هم، و به صورت ناپیوسته، طوری انجام گیرند که در هر زمان فقط یک عمل انجام شود. مانند متوقف کردن عمل آشپزی، پاسخ دادن به تلفن، و مجدداً بازگشت به عمل آشپزی.

**اعمال هم‌روند:** اعمالی که مراحل آنها به صورت هم‌روند با هم صورت می‌گیرند. در این حالت، در هر زمان بیش از یک عمل می‌تواند صورت گیرد. مانند پاسخ دادن به تلفن در حین آشپزی کردن و یا وضعیتی در محیط‌های چند کاربره، که کاربران به طور هم‌روند اعمال متفاوتی را انجام می‌دهند.



شکل ۱-۱. الف - اعمال ترتیبی. ب - اعمال متداخل. ج - اعمال هم‌روند.

لازم به ذکر است که در محیط‌های با بیش از یک کاربر عموماً اعمال به صورت هم‌روند رخ

<sup>۱</sup> Sequential  
<sup>۲</sup> Interleaved  
<sup>۳</sup> Concurrent

می‌دهند.

## ۳-۱ حسگرهای مورد استفاده

در محیط‌های هوشمند، مشاهدات مربوط به اعمال کاربران با استفاده از حسگرهای مختلفی جمع‌آوری می‌شوند. از جمله این حسگرها می‌توان به حسگرهای ویدئویی، حسگرهایی که روی بدن نصب می‌شوند، حسگرهای لمسی و حرکتی، حسگرهای دوحالته، حسگرهای دما و رطوبت، اشاره کرد. بسته به نوع حسگرهای مورد استفاده، روش‌های بازشناسی اعمال به دو دسته مبتنی بر حسگرهای پوشیدنی<sup>۱</sup> و مبتنی بر حسگرهای محیطی (یا سنجش متراکم<sup>۲</sup>) تقسیم بندی می‌شوند.

باید توجه داشت که حسگرهای نصب شده در محیط به صورت مشترک در اعمال مختلف فعال می‌گردند. مثلاً حسگر نصب شده در اجاق گاز می‌تواند به طور مشترک در اعمال "آماده کردن ناهار"، "درست کردن قهوه"، و "گرم کردن غذای مختصر"، فعال شود. و یا یک حسگر حرکتی نصب شده بر سقف هال می‌تواند در اعمال "خروج از منزل"، "وارد شدن به یکی از اتاق‌ها" و "مرتب کردن منزل"، فعال گردد. توجه داریم که این اعمال می‌توانند به طور ترتیبی، هم‌روند، و یا متداخل، توسط ساکنین انجام گیرند.

دوربین‌ها می‌توانند اطلاعات مفیدی در مورد ساکنین و محیط فراهم آورند، اما از آنجا که با به کارگیری آنها حریم شخصی<sup>۳</sup> افراد نقض خواهد شد، ایجاد تراکم<sup>۴</sup> خواهند کرد. به طور مشابه، حسگرهایی که روی بدن نصب می‌شوند (BS)<sup>۵</sup> (مانند شتاب‌سنج‌ها<sup>۶</sup>) برای جمع‌آوری اطلاعات حرکتی

---

<sup>۱</sup> Wearable sensors

<sup>۲</sup> Dense sensing

<sup>۳</sup> Privacy

<sup>۴</sup> Obtrusiveness

<sup>۵</sup> Body Sensors

<sup>۶</sup> Accelerometers

و وضعیت بدن) نیز، ایجاد تزاخم خواهند کرد زیرا برای شناسایی حرکات، باید در تمام مدتی که فرد در منزل است این حسگرها را روی بدن خود داشته باشد.

با توجه به مشکلات فوق، در این رساله قصد داریم از حسگرهایی استفاده کنیم که ایجاد تزاخم نمی‌کنند. این حسگرها به اشیاء و لوازم خانگی مانند اجاق، قفسه‌ها، شیرهای آب و غیره متصل شده و اطلاعات مربوط به تعاملات کاربر با اشیاء مختلف را جمع‌آوری می‌کنند. زمانی که کاربران کارهای روزمره خود را انجام می‌دهند، در تعامل آنان با اشیاء، این حسگرها فعال یا غیر فعال خواهند شد. این روش را سنجش متراکم<sup>۱</sup> می‌گویند. مثلاً باز کردن یا بستن درب اجاق مایکروویو می‌تواند حسگری را که به آن متصل شده فعال کند. این کار موجب خواهد شد تا دنباله‌ای از مشاهدات حسگرها، که هر کدام مربوط به یک رویداد در انجام یک عمل خاص است، ایجاد شود. دنباله‌ای از رویدادهای حسگرها می‌تواند به عنوان یک عمل تفسیر گردد. مثلاً دنباله‌ای از مشاهدات حسگرها که مربوط به رویدادهای "بستن درب حمام"، "روشن کردن چراغ"، و "باز کردن شیر آب" است، می‌تواند مربوط به عمل "دوش گرفتن" باشد.

مشاهدات حسگرها می‌توانند به صورت مقادیر گسسته و یا پیوسته باشد. مثلاً مشاهدات حسگرهای دو حالت<sup>۲</sup> نشان دهنده دو وضعیت خاموش و یا روشن هستند در حالی که مشاهدات یک حسگر دما یا رطوبت به صورت مقادیر پیوسته خواهد بود. هرچند، می‌توان داده‌های پیوسته حسگرها را به داده‌های گسسته تبدیل نمود.

لازم به ذکر است که شناسایی اعمال در محیط‌هایی با سنجش متراکم، نسبت به محیط‌هایی که از حسگرهای نصب شده روی بدن استفاده می‌کنند دارای پیچیدگی‌های بیشتری است. زیرا در

---

<sup>۱</sup>Dense Sensing

<sup>۲</sup>Switch Sensors



سنجش متراکم هویت کاربران نامشخص است در حالی که با استفاده از حسگرهای نصب شده روی بدن می‌توان به سادگی متوجه شد که حسگر مربوط به کدام کاربر داده‌ای را ارسال کرده است. در نتیجه، در سنجش متراکم دنباله داده‌های کاربران مختلف در هم تنیده خواهند شد در حالی که در استفاده از حسگرهای پوشیدنی، دنباله داده‌های یک کاربر از دیگران متمایز خواهد بود. اما مزیت سنجش متراکم، استفاده راحت‌تر کاربران می‌باشد؛ چون آنان مجبور نخواهند بود حسگرهایی را در تمام مدت روی بدن خود حمل نمایند.

با توجه به اینکه در شناسایی اعمال، حسگرهای ویدیویی و حسگرهای نصب شده روی بدن ایجاد تزاخم می‌نمایند، قصد داریم مشخصاً به شناسایی اعمال با سنجش متراکم و استفاده از حسگرهای بدون تزاخم نصب شده در محیط پردازیم. لذا در کلیه بخش‌های این رساله هر جا که بحث شناسایی اعمال در محیط مطرح می‌شود، منظور شناسایی اعمال با سنجش متراکم و با استفاده از حسگرهای بدون تزاخم خواهد بود، مگر آنکه به صراحت نوع روش بازشناسی مربوطه ذکر گردد.

## ۴-۱ بیان مساله

در یک خانه هوشمند کلیه تصمیم‌گیری‌ها بر مبنای اعمال شناسایی شده کاربر و تغییر وضعیت محیط توسط او انجام می‌گیرد. لذا شناسایی این اعمال از اهمیت ویژه‌ای برخوردار است. مشاهدات حسگرهای نصب شده در محیط به نوعی اعمال کاربران را بازنمایی می‌کنند. لذا مساله باز شناسی اعمال ساکنین را می‌توان به صورت یافتن نگاشتی از دنباله داده‌های حسگرها به اعمال انجام شده توسط کاربر بیان کرد.

**تعریف ۱-۱.** (تعبیر کلی مساله شناسایی اعمال): اگر  $S$  دنباله‌ای از داده‌های حسگرها، و

$A$  مجموعه‌ای از اعمال قابل انجام در محیط باشد، آنگاه شناسایی اعمال کاربران عبارت است از محاسبه

نگاشت  $m$  با رابطه (۱-۱). در این رابطه،  $2^S$  مجموعه زیر دنباله‌های  $S$  می‌باشد.

$$m: 2^S \rightarrow A \quad (1-1)$$

تا کنون، روش‌های زیادی برای به دست آوردن نگاشت تعریف ۱-۱ ارائه شده‌اند. این روش‌ها را می‌توان به سه دسته کلی مبتنی بر دانش، مبتنی بر داده، و هیبریدی تقسیم‌بندی کرد، که در فصل آتی به تفصیل به هریک از آنها خواهیم پرداخت. در شناسایی اعمال، چالش‌هایی جدی وجود دارند و هر دسته از رویکردهای مطرح شده سعی در مرتفع ساختن برخی از این چالش‌ها دارند. در اغلب این کارها ساده‌سازی‌هایی به عنوان پیش‌فرض در نظر گرفته شده‌اند که آنها را برای استفاده در سناریوهای پیچیده‌تر در دنیای واقعی محدود می‌سازد. به عنوان مثال، روش‌های مبتنی بر دانش سعی دارند که از دانش قبلی<sup>۱</sup> در خصوص نحوه انجام اعمال، برای شناسایی آنها استفاده نمایند. اما این دانش قبلی از محیطی به محیط دیگر متفاوت است و در برخورد با ویژگی‌های شخصی افراد تضمینی برای صحت عملکرد آنها وجود ندارد. در ادامه به چالش‌های مورد نظر در زمینه شناسایی اعمال می‌پردازیم.

## ۱-۵ چالش‌ها

در انجام اعمال در خانه‌های هوشمند، هر زمان که ساکنین کاری را انجام می‌دهند حسگرها فعال یا غیر فعال می‌گردند. اما فاصله زمانی بین اعمال و نیز طول مدت زمان لازم برای انجام آنها از قبل مشخص نیست. بنابر این، زمان شروع و پایان اعمال مشخص نخواهد بود. این مساله موجب خواهد شد که استخراج قطعات داده‌ای مربوط به یک عمل به منظور استنتاج عمل مربوط بسیار چالش برانگیز باشد. یک روش برای مدیریت این چالش، که معمولاً برای اعمال ترتیبی در محیط‌های تک کاربره

---

<sup>۱</sup>Prior Knowledge

استفاده می‌شود، استفاده از رویکردهای بدون نظارت<sup>۱</sup> است، که قبل از رده‌بندی داده‌های حسگرها انجام می‌گیرد. در این روش‌ها سعی می‌شود الگوهای تکراری داده‌ها از جریان داده حسگرها استخراج شوند. سپس، نمونه‌های این الگوها، از جریان ورودی، استخراج شده و برای هر کدام، یک عمل تشخیص داده می‌شود [۴، ۵]. برخی رهیافت‌ها نیز به مساله بخش بندی، با در نظر گرفتن قاب‌های زمانی و یا قاب‌های رویدادهای حسگرها با طول ثابت پرداخته‌اند [۶]. در این روش‌ها، برای دنباله داده‌های هر پنجره، یک عمل تشخیص داده شده، و سپس پنجره به جلو لغزنده می‌شود. هرچند، ممکن است که همه داده‌های یک پنجره مربوط به یک عمل نباشند و این موجب خواهد شد تا دیگر اعمالی که داده‌های آنها در پنجره وجود دارند به درستی تشخیص داده نشوند. همچنین، ممکن است یک پنجره برای دربرگرفتن داده‌های یک عمل به اندازه کافی بزرگ نباشد که این نیز می‌تواند منجر به عدم تشخیص صحیح عمل مربوطه گردد. میزان این خطا در محیط‌های چندکاربره که اعمال به صورت هم‌روند و یا متداخل انجام می‌گیرند، بسیار بیشتر می‌باشد؛ زیرا در این شرایط دنباله داده‌های اعمال مختلف در هم تنیده خواهند شد. در کنار روش‌های مبتنی بر قطعه‌بندی غیرضمنی، روش‌هایی نیز وجود دارند که هر دو کار قطعه‌بندی و تشخیص اعمال را توأم با هم انجام می‌دهند. مدل‌های احتمالاتی گرافیکی از این نوع روش‌ها می‌باشند [۷-۱۰]. هرچند، استفاده از این رویکردها در شناسایی اعمال متداخل و هم‌روند و مخصوصاً برای محیط‌های چندکاربره منجر به ایجاد مدل‌های پیچیده‌ای خواهند شد که پیچیدگی محاسباتی بسیار بالایی دارند. با توجه به موارد فوق، در بازشناسی اعمال در محیط‌های چند کاربره با چالشی جدی مواجه خواهیم بود.

مساله رده‌بندی تک کلاسه<sup>۲</sup> برای الگوهای هم‌روند در سال ۲۰۱۲ در [۱۱] برای شناسایی

---

<sup>۱</sup>Unsupervised

<sup>۲</sup> One-class classification

رویدادهای مرحله‌ای تصادفی<sup>۱</sup> معرفی گردید. به طور مشابه، در مساله شناسایی اعمال در محیط‌های چند کاربره، با توجه به هم‌روندی و درهم‌تنیدگی داده‌های مربوط به اعمال مختلف، با رده‌بندی چند کلاس‌ه‌الگوهای هم‌روند روبرو خواهیم بود. در چنین شرایطی، با داشتن دنباله‌ای از داده‌های درهم‌تنیده حسگرها، شناسایی اعمال بسیار چالش برانگیز خواهد بود. لازم به ذکر است که تا کنون، در تعداد معدودی از کارهای انجام شده به بحث شناسایی اعمال در محیط‌های چند کاربره، مبتنی بر سنجش متراکم پرداخته شده است [۱۲].

در بسیاری از موقعیت‌ها، به هنگام انجام یک عمل، داده‌های حسگرها توأم با عدم قطعیت<sup>۲</sup> هستند. عدم قطعیت به معنی عدم آگاهی در خصوص رخداد یا عدم رخداد یک عمل می‌باشد. عدم قطعیت می‌تواند در اثر خطای سخت افزاری در حسگرها، خطای کاربر در فعال‌سازی حسگرها، خطای طراح در نصب حسگرها در مکانی صحیح، و یا خطای کاربر به هنگام انجام یک عمل به وجود آید. لذا در شناسایی اعمال، عدم قطعیت داده‌های حسگرها نیز یکی دیگر از چالش‌هایی است که با آن روبرو خواهیم بود. علیرغم اهمیت مساله عدم قطعیت، در بسیاری از کارهای انجام شده، این موضوع نیز در نظر گرفته نشده است.

## ۱-۶ اهداف مورد نظر

با توجه به چالش‌های فوق، در این رساله به شناسایی اعمال در شرایط پیچیده خواهیم پرداخت. در حالت کلی منظور از شرایط پیچیده، موقعیت‌هایی است که در آنها بیش از یک کاربر به فعالیت‌های روزمره خود می‌پردازند. این شرایط را به صورت زیر تعریف می‌کنیم:

---

<sup>۱</sup>Stochastic episodic events

<sup>۲</sup>Uncertainty

**تعریف ۱-۲. (شرایط پیچیده).** شرایطی محیطی که در آن داده‌های حسگرها توام با عدم قطعیت بوده و نیز امکان رخداد تصادفی اعمال توسط یک یا چند کاربر وجود دارد.

طراحی یک معماری برای شناسایی اعمال در چنین شرایطی، آن را برای استفاده در سناریوهای دنیای واقعی بسیار مناسب‌تر خواهد ساخت.

## ۱-۷ مفروضات مورد نظر برای مساله شناسایی اعمال

همانطور که در فصل آتی نیز بیان خواهد شد، عمده روش‌های مبتنی بر داده مطرح شده تا کنون، مبتنی بر پیش فرض‌هایی هستند که شناسایی اعمال در شرایط پیچیده را محدود می‌سازند. حضور یک کاربر در محیط، انجام یک کار در هر زمان، و پیش فرض‌های مورد استفاده در مدل سازی‌های گرافیکی، از جمله پیش فرض‌هایی هستند که می‌توان به آنها اشاره کرد. لذا عمده این کارها برای استفاده در شرایط پیچیده (مطابق تعریف ۱-۲) در سناریوهای دنیای واقعی مناسب نخواهند بود. همچنین، در حالت کلی، از آنجا که روش‌های مبتنی بر دانش بر اساس ساختارهای از پیش تعریف شده‌ای برای بازنمایی دانش هستند، در برخورد با خصوصیات فردی کاربران در انجام اعمال با مشکل مواجه خواهند شد. لذا در این رساله، برای حل مساله شناسایی اعمال، مفروضات زیر را در نظر می‌گیریم:

- بیش از یک کاربر در محیط حضور خواهند داشت.
- با توجه به پیچیدگی مساله، تاکید بر حل مساله در محیط‌های دو کاربره خواهد بود.
- در محیط چند کاربره اعمال در حال انجام را از هم مستقل فرض می‌کنیم.
- به دنبال مدل‌سازی تعاملات بین کاربران نیستیم.
- به شناسایی اعمال کاربر در شرایط پیچیده مطابق با تعریف ۱-۲ خواهیم پرداخت.
- شناسایی فعالیت‌های روزمره ساده و مشخص که در مجموعه داده‌های موجود، مرسوم هستند

مد نظر خواهد بود.

- قصد داریم تعیین کنیم که به ازای هر رویداد حسگر و یا هر واحد زمانی چه اعمالی رخ داده اند.

- برای جمع آوری داده‌ها از حسگرهای بدون تزاحم<sup>۱</sup> استفاده خواهد شد.

- منظور از حسگرهای بدون تزاحم آنهایی هستند که حریم خصوصی کاربران را نقض نکرده، و موجب نارضایتی آنان نمی‌شوند. حسگرهای ویدئویی و حسگرهایی که روی بدن نصب می‌شوند مد نظر نخواهند بود.

- حسگرها در محیط و روی اشیاء مختلف نصب شده اند (سنجش متراکم<sup>۲</sup>).

- از حسگرهای با مقادیر گسسته استفاده می‌کنیم.

- عمدتاً حسگرهای مورد استفاده دودویی هستند. زمانی که حسگرهای با مقادیر پیوسته داریم، آنها را گسسته سازی خواهیم کرد.

- روشی مبتنی بر داده و با ناظر برای شناسایی اعمال کاربران در محیط ارائه خواهیم داد.

- در حالت کلی روش‌های مبتنی بر دانش بر مبنای مدل‌های از پیش تعریف شده‌ای هستند و در مواجهه با خصوصیات فردی کاربران مختلف انعطاف پذیری و توسعه پذیری لازم را نخواهند داشت.

## ۸-۱ مجموعه‌های داده

مرکز مطالعات پیشرفته سیستم‌های تطبیق پذیر (CASAS<sup>۳</sup>) با هدف توسعه محیط‌های

هوشمند در سال ۲۰۰۷ در دانشگاه ایالتی واشنگتون تشکیل شده و در حال حاضر مشغول به کار

---

<sup>۱</sup> Unobtrusive

<sup>۲</sup> Dense sensing

<sup>۳</sup> Center for advanced studies in adaptive systems

می‌باشد. این مرکز مجموعه داده‌ها و ابزارهای مختلفی را به منظور توسعه مکانیزم‌های تشخیص اعمال در اختیار محققین قرار داده است. مجموعه داده‌های این مرکز از طریق آدرس اینترنتی <http://ailab.wsu.edu/> قابل دسترسی می‌باشد. در جدول ۱-۱، تعدادی از این مجموعه‌های داده، و ویژگی‌های آنها آورده شده است:

جدول ۱-۱. برخی از مجموعه داده‌های مرکز تحقیقاتی CASAS [۱۳].

| مجموعه داده | Testbed | #Residents / #Participants | Description  | Annotated |
|-------------|---------|----------------------------|--|-----------|
| 1           | Kyoto   | 1                          | Daily life, 2007   | Yes       |
| 2           | Kyoto   | 2                          | Daily life, 2008   | Yes       |
| 3           | Kyoto   | 2                          | Daily life, Spring 2009  | Yes       |
| 4           | Kyoto   | 2                          | Daily life, Summer 2009  | Yes       |
| 5           | Tulum   | 2                          | Daily life, 2009   | Yes       |
| 6           | Tulum   | 2                          | Daily life, 2009-2010  | Yes       |
| 7           | Kyoto   | 2                          | Daily life, 2010   | Yes       |
| 8           | Kyoto   | 1                          | ADL Activities with Actigraph  | Yes       |
| 9           | Kyoto   | 20                         | ADL Activities with Errors   | Yes       |
| 10          | Kyoto   | 20                         | Interweaved ADL Activities   | Yes       |
| 11          | Kyoto   | 30                         | ADL Activities with Environment, Wearable, Object, Phone sensors, 2011 | Yes       |
| 12          | Kyoto   | 20                         | ADL Activities   | Yes       |

در این مجموعه‌های داده انواع مختلفی از حسگرها (مانند حسگرهای حرکتی، دما، فشار، حسگرهای دو حالت) بر روی اشیاء و قسمت‌های مختلف خانه هوشمند نصب شده‌اند. کلیه این حسگرها بدون تزاخم می‌باشند و اطلاعات مربوط به اعمال روزمره و معمول افراد، مانند "بیرون رفتن از منزل"، "خوابیدن"، "خوردن صبحانه" و غیره را با سنجش متراکم جمع آوری می‌کنند.

علاوه بر مجموعه داده‌های فوق، مجموعه داده‌های دیگری نیز برای مساله شناسایی اعمال در محیط‌های هوشمند وجود دارند. به عنوان نمونه، مجموعه داده‌های ارائه شده توسط VanKasteren<sup>۱</sup>.

<sup>۱</sup> <https://sites.google.com/site/tim0306/datasets>

داده‌های آزمایشگاه<sup>۱</sup> Placelab در دانشگاه ماساچوست، و مجموعه داده‌های حسگرهای حرکتی نصب شده در آزمایشگاه‌های تحقیقات الکتریکی شرکت میتسوبیشی (MERL)<sup>۲</sup> از جمله مجموعه داده‌هایی هستند که می‌توانند مورد استفاده قرار گیرند.

کلیه این مجموعه‌های داده در دسترسی آزاد قرار داشته و می‌توان به آنها از طریق آدرس اینترنتی مرکز تحقیقات CASAS نیز دسترسی داشت.

## ۹-۱ معماری پیشنهادی

در بازشناسی اعمال در محیط‌های هوشمند، عموماً از مدل‌هایی استفاده می‌شود (مانند مدل‌های احتمالاتی گرافیکی [۱۴-۱۶]) که در آنها با افزوده شدن تعداد کاربران، مدل مربوطه بسیار پیچیده خواهد شد. چنین مدل‌هایی در مواجهه با افزایش تعداد کاربران مقیاس پذیر نیستند. مثلاً در خصوص مدل‌های احتمالاتی گرافیکی، که بسیار مرسوم هستند، با افزایش تعداد کاربران، تعداد متغیرهای تصادفی مربوط به اعمال آنان افزایش یافته، و در نتیجه تعداد پارامترهای مدل مربوطه نیز به صورت نمایی افزایش خواهد یافت [۱۷]. برای آموزش این مدل‌ها، از یک سو به مجموعه داده بسیار وسیع، و از سوی دیگر به توان محاسباتی بالایی نیاز خواهد بود. با توجه به محدودیت منابع، در تخمین پارامترهای چنین مدل‌هایی معمولاً به بهینه‌های محلی اکتفا شده، که به نوبه خود منجر به کاهش کارایی فرآیند بازشناسی خواهد شد. بنابراین، باید به دنبال راهکاری بود که بتواند تاثیر تعدد کاربران در محیط را با پیچیدگی محاسباتی مناسب، مدیریت نماید. بدین منظور، در بازشناسی اعمال در محیط‌های چند کاربره، پس از دریافت جریان داده‌های حسگرها، ابتدا دنباله داده‌های کاربران را از آن استخراج می‌کنیم. سپس، بر

---

<sup>۱</sup> [http://architecture.mit.edu/house\\_n/data/PlaceLab/PlaceLab.htm](http://architecture.mit.edu/house_n/data/PlaceLab/PlaceLab.htm)

<sup>۲</sup> Mitsubishi Electric Research Labs

<sup>۳</sup> <https://sites.google.com/a/drwren.com/wmd/home>



روی این دنباله‌ها با به‌کارگیری رویکردهای بازشناسی اعمال در محیط‌های تک‌کاربره، اعمال مربوطه را شناسایی می‌کنیم. با این رویکرد، یک مساله بازشناسی چند کاربره به چند مساله بازشناسی تک کاربره تبدیل خواهد شد. باید توجه داشت که در این رهیافت، پیچیدگی محاسباتی استخراج دنباله داده‌های کاربران از اهمیت ویژه‌ای برخوردار می‌باشد. این ساز و کار منجر به ارائه یک معماری سه لایه خواهد شد.

معماری پیشنهادی، مربوط به بازشناسی اعمال تحت شرایط پیچیده، در شکل ۱-۲ نمایش داده شده است. این معماری دارای سه لایه بوده که عبارتند از: ۱- لایه جمع‌آوری داده<sup>۱</sup>، ۲- لایه تشخیص اعمال تک کاربره<sup>۲</sup>، و ۳- لایه تشخیص اعمال چند کاربره<sup>۳</sup>. در ادامه به توضیح خدمات هر لایه و ساز و کار آنها خواهیم پرداخت.

**لایه جمع‌آوری داده:** این لایه، حسگرهای دودویی که در خانه هوشمند نصب شده‌اند را در خود جای داده است. این لایه، داده‌های حسگرها را به صورت جریانی از رویدادها در اختیار لایه‌های بالایی قرار می‌دهد.

**لایه تشخیص اعمال تک کاربره:** این لایه برای بازشناسی اعمال در محیطی تک کاربره مورد استفاده قرار می‌گیرد. در صورتی که جریان داده ورودی مربوط به محیطی چند کاربره باشد، ابتدا با استفاده از روال‌های لایه سوم دنباله داده‌های کاربران تفکیک، و سپس بر روی هر دنباله اعمال تشخیص داده می‌شوند. فرض بر این است که تک کاربره یا چند کاربره محیط از قبل مشخص می‌باشد. در کلی‌ترین حالت، در این لایه یک رده‌بند آموزش داده شده و برای بازشناسی نمونه‌های جدید مورد

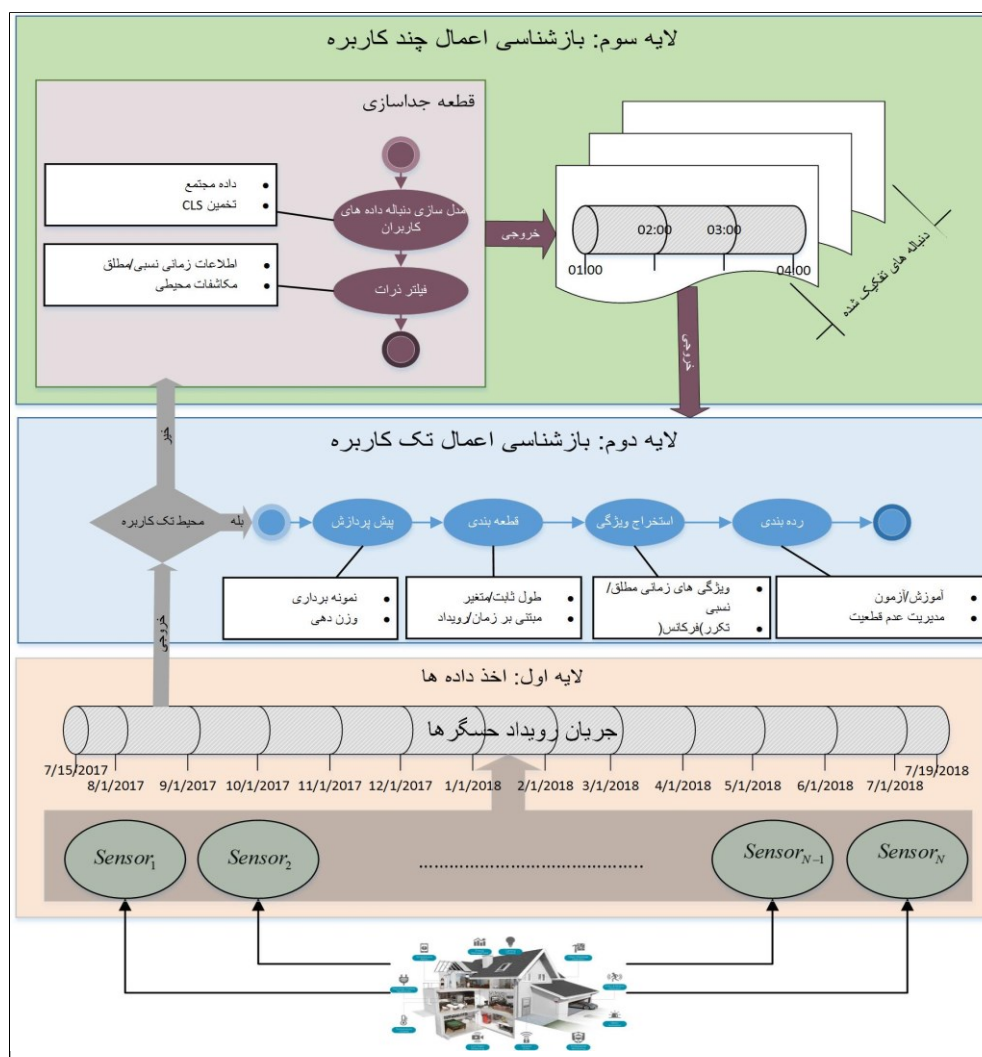
---

<sup>۱</sup> Data acquisition

<sup>۲</sup> Single-subject human activity recognition (HAR)

<sup>۳</sup> Multi-subject human activity recognition (HAR)

استفاده قرار می‌گیرد. برای آموزش، مجموعه داده آموزشی به صورت مجموعه‌ای از جریان‌های رویدادها در محیط تک کاربره مورد استفاده قرار می‌گیرد. در نخستین گام، در صورت نامتعادل<sup>۱</sup> بودن داده‌ها، با وزن دهی به آنها و یا با نمونه‌برداری تاثیر عدم تعادل را تخفیف می‌دهیم. سپس، در صورت لزوم، و بسته به نوع رده‌بند، جریان رویدادها را قطعه بندی می‌کنیم. این قطعات می‌توانند پنجره‌های زمانی و یا پنجره‌های مبتنی بر رویداد با طول ثابت یا متغیر باشند. به ازای هر پنجره یک بردار ویژگی استخراج خواهد شد.



شکل ۱-۲. معماری سه لایه پیشنهادی برای شناسایی اعمال.

<sup>۱</sup> Imbalanced

این بردار ویژگی می‌تواند شامل داده‌هایی مانند اطلاعات زمانی مطلق یا نسبی رویدادها، تکرر وقوع رخداد حسگرها، و یا هر ویژگی دیگر مربوط به داده‌ها باشد. در نهایت، یک رده‌بند با استفاده از ویژگی‌های استخراج شده برای بازشناسی اعمال آموزش داده می‌شود. در رده‌بندی ساز و کاری برای مدیریت عدم قطعیت در نظر می‌گیریم.

برای پیاده‌سازی لایه دوم، دو رویکرد پیشنهاد گردیدند. در رویکرد اول از نظریه دمپستر-شافر برای تجمیع عقاید تعدادی شاهد در خصوص اعمال، و در نتیجه کاهش عدم قطعیت استفاده کردیم. شاهدان را چندتایی‌هایی از حسگرهای فعال شده در نظر گرفتیم. عقاید این شاهدان را به صورت سه‌تایی‌هایی شامل: باور، عدم باور، و عدم قطعیت، و با استفاده از تابع توزیع بتا محاسبه نمودیم. برای قطعه‌بندی رویدادهای حسگرها، آنها را بر حسب زمان رخدادشان خوشه‌بندی کردیم. در رویکرد دوم، از رهیافت‌هایی مبتنی بر بهینه‌سازی استفاده نمودیم. ابتدا به ازای هر رویداد حسگر، مقادیر باور القا شده در خصوص هر یک از اعمال را به صورت یک بردار محاسبه کردیم و آن را بردار باور اولیه نامیدیم. در تطبیق با اجزای لایه دوم معماری پیشنهادی، بردارهای باور اولیه را می‌توان همان بردار ویژگی مربوط به حسگرهای فعال شده در نظر گرفت. سپس، با استفاده از مفروضاتی که در خانه‌های هوشمند عمومیت دارند، توابع هدفی را برای هموار سازی بردارهای باور اولیه تعریف کردیم. در تعریف این توابع، عدم قطعیت استنتاج را معادل با مفهوم آنتروپی در نظر گرفتیم. با کمینه سازی این توابع هدف، بردارهای باور اولیه هموار شده، و به ازای هر رویداد حسگر، یک بردار باور ثانویه محاسبه گردید. در نهایت، استنتاج بر مبنای بردارهای باور ثانویه صورت گرفت. این رویکردها نیازی به قطعه بندی غیر ضمنی جریان داده ورودی ندارند.

### **لایه تشخیص اعمال چند کاربره: وظیفه اصلی این لایه جداسازی دنباله داده‌های کاربران**

می‌باشد. روال‌های این لایه توسط لایه دوم، مورد دسترسی قرار می‌گیرند. در حالت کلی، در این لایه

پس از دریافت داده‌های مجتمع (درهم تنیده) با استفاده از قطعه جداسازی<sup>۱</sup> دنباله داده‌های کاربران از هم تفکیک می‌شوند. بدین منظور، با فرض اینکه همه کاربران طبق مدلی یکسان در محیط فعالیت می‌کنند، مدلی برای دنباله داده‌های آنان محاسبه می‌گردد. سپس، با استفاده از یک الگوریتم مبتنی بر فیلتر ذرات، دنباله داده‌های کاربران از هم تفکیک می‌شوند. در الگوریتم فیلتر ذرات پیشنهادی، از مدل تخمین زده شده، اطلاعات زمانی مطلق و نسبی داده‌های حسگرها، و نیز دیگر مکاشفه‌های محیطی، به منظور امتیازدهی به ذرات می‌توان بهره گرفت. دنباله داده‌های تفکیک شده به منظور بازشناسی اعمال در اختیار لایه دوم قرار خواهند گرفت.

در پیاده‌سازی لایه سوم، به منظور مدل‌سازی دنباله داده‌های کاربران از یک زنجیره مارکوف استفاده کرده‌ایم. فرض را بر این قرار دادیم که کاربران منطبق با یک زنجیره مارکوف واحد موجب رویداد حسگرها خواهند شد. پارامترهای این زنجیره (یعنی ماتریس انتقال مربوطه) را مستقیماً با استفاده از داده‌های درهم تنیده کاربران، و با به کارگیری ایده تخمین کمترین مربعات شرطی (CLS<sup>۲</sup>) محاسبه نمودیم. سپس، از ماتریس انتقال محاسبه شده، و زمان رویداد حسگرها به منظور امتیازدهی به ذرات در الگوریتم فیلتر ذرات پیشنهادی استفاده کردیم. پس از جداسازی دنباله داده‌های کاربران، از الگوریتم مبتنی بر بهینه‌سازی، که در لایه دوم ارائه گردید، برای بازشناسی اعمال روی هر دنباله داده تفکیک شده استفاده نمودیم؛ زیرا این الگوریتم برای آموزش نیازی به دنباله داده‌های از قبل تفکیک شده کاربران ندارد.

## ۱-۱۰ نوآوری‌ها

---

<sup>۱</sup> Deinterleaving module

<sup>۲</sup> Conditional least squares

نوآوری‌ها در این رساله به شرح ذیل می‌باشند:

- ارائه یک معماری سه لایه جدید برای بازشناسی اعمال کاربران در محیط‌های تک کاربره و چند کاربره.
- ارائه یک راهکار جدید برای بازشناسی اعمال در محیط‌های تک کاربره، با به کارگیری نظریه دمپستر-شافر، به منظور کاهش عدم قطعیت استنتاج.
- ارائه یک راهکار جدید برای بازشناسی اعمال در محیط‌های تک کاربره، بر اساس یک مساله بهینه‌سازی، و با تاکید بر کاهش عدم قطعیت.
- ارائه روشی جدید برای بهبود تخمین پارامترهای یک زنجیره مارکوف به منظور مدل‌سازی دنباله داده‌های کاربران در محیط‌های چند کاربره.
- ارائه یک روش جدید مبتنی بر فیلتر ذرات برای تفکیک دنباله داده‌های کاربران.

## ۱-۱ ساختار رساله

رساله‌ی پیش رو در شش فصل تنظیم شده است. ساختار این رساله در فصل‌های آتی بدین ترتیب می‌باشد:

در فصل دوم به مرور منابع مرتبط با بازشناسی اعمال پرداخته‌ایم. در این فصل، یک دسته‌بندی از رویکردهای بازشناسی اعمال ارائه، و سپس به بیان کارهای مرتبط با هر دسته، و مزایا و معایب هر یک پرداخته‌ایم. در فصل سوم، اولین راهکار پیشنهادی، مبتنی بر نظریه دمپستر-شافر، برای بازشناسی اعمال در محیط تک کاربره ارائه شده است. در فصل چهارم، راهکاری پیشنهادی دوم برای بازشناسی اعمال در محیط‌های تک کاربره ارائه گردیده که مبتنی بر کمینه سازی یک تابع هدف تفاضل محدب می‌باشد. رویکردهای فصل سوم و چهارم به منظور پیاده سازی لایه دوم معماری پیشنهادی، با تاکید بر

کاهش عدم قطعیت می‌باشند. در فصل پنجم، به بازشناسی اعمال در محیط‌های چند کاربره مطابق با لایه سوم معماری پیشنهادی پرداخته‌ایم. بدین منظور، ابتدا مدل‌سازی دنباله داده‌های کاربران را مورد بررسی و پیاده‌سازی قرار دادیم. سپس، الگوریتمی برای تفکیک دنباله داده‌های کاربران پیشنهاد گردیده که مبتنی بر فیلتر ذرات می‌باشد. از مدل محاسبه شده برای دنباله داده‌های کاربران، به منظور امتیاز دهی به ذرات در الگوریتم فیلتر ذرات پیشنهادی استفاده شده است. در ادامه، اعمال مربوط به هر یک از دنباله‌های تفکیک شده را با به کارگیری یک الگوریتم بازشناسی اعمال تک کاربره محاسبه نموده و مورد ارزیابی قرار داده‌ایم. در نهایت، در فصل ششم به جمع‌بندی و بیان کارهای آتی پرداخته شده است.

## ۱-۱۲ جمع‌بندی

در این فصل، ضرورت شناسایی اعمال در محیط‌های هوشمند مطرح گردید. سپس، حسگرهای مورد استفاده و نحوه جمع‌آوری اطلاعات توسط آنها بیان شد. آنگاه، مساله شناسایی اعمال را به صورت یافتن نگاشتی از دنباله داده‌های حسگرها به اعمال، عنوان نمودیم. در ادامه به چالش‌های مورد نظر پرداختیم. اهداف تحقیق، پیش فرض‌های در نظر گرفته شده، و مجموعه داده‌های مورد استفاده، نیز در ادامه مطرح گردیدند. در نهایت، معماری سه لایه پیشنهادی معرفی گردید و به بیان نوآوری‌ها و ساختار رساله پرداختیم.

## فصل ۲. مروری بر کارهای پیشین

## ۱-۲ مقدمه

اصطلاح "محاسبات همیشه حاضر"<sup>۱</sup> اولین بار توسط مارک ویزر<sup>۲</sup> مطرح شد. طبق این دیدگاه، پیش بینی شده بود که کامپیوترها در آینده به گونه‌ای در اختیار مردم خواهند بود که آنها از حضور بدون تزاخم چنین کامپیوترهایی در اشیائی مانند لباس‌ها، اتومبیل‌ها، و دیگر وسایل هیچ اطلاعی نخواهند داشت [۱۸]. برای خلق چنین محیط‌هایی نیاز به استفاده از ابزارهای مختلفی از حوزه‌های هوش مصنوعی، بینایی ماشین، یادگیری ماشین، تکنولوژی‌های بیسیم، و تعامل کامپیوتر و انسان می‌باشد، تا محیط بتواند به صورت خودکار یادگیری داشته باشد و با نیازهای کاربران تطبیق یافته و به آنها پاسخ دهد.

برای اینکه محیط بتواند به طور هوشمندانه به نیازهای کاربران پاسخ دهد، ابتدا باید بتواند رفتارهای آنان را بر مبنای داده‌های دریافت شده از محیط فیزیکی شناسایی نماید. این داده‌ها می‌توانند از حسگرها، میکروفن‌ها، دوربین‌های ویدئویی و غیره دریافت شوند. لذا مساله تشخیص اعمال به موضوعی جالب در حوزه یادگیری ماشین تبدیل شده است.

یکی از کاربردهای تشخیص اعمال که به ساکنین در زندگی روزمره خود کمک می‌کند، خانه‌های هوشمند است، که در دهه گذشته به موضوعی جالب برای محققین تبدیل شده است. یک خانه هوشمند محیطی خودکار است که از انواع مختلفی از حسگرها برای تشخیص اعمال ساکنین خود استفاده می‌کند. عموماً این خانه‌ها می‌توانند برای نظارت و حمایت از افراد سالخورده یا افرادی با عارضه‌های جسمی یا روانی مورد استفاده قرار بگیرند. مثلاً می‌توانند اعمال با ریسک بالا و یا اعمال غیر

---

<sup>۱</sup> Ubiquitous Computing

<sup>۲</sup> Mark Weiser



طبیعی را شناسایی کنند. یا به ساکنین خود، کارهایی که می‌بایست انجام دهند را یادآوری نمایند. از جمله دیگر کاربردها می‌توان به مراقبت‌های پزشکی، کاربردهای امنیتی و امداد و نجات (مثلا شناسایی حرکات مشکوک در فرودگاه‌ها و معابر [۱۹])، استفاده‌های صنعتی (مثلا نظارت بر کارهای انجام شده توسط کارگران در خطوط تولید [۲۰])، و اتوماسیون (مثلا اتوماسیون کنترل دما، تهویه هوا و تهویه مطبوع [۲۱]) اشاره نمود.

تا کنون روش‌های متعددی برای شناسایی اعمال در محیط‌های هوشمند مطرح شده است. بر حسب نوع حسگرهای استفاده شده برای دریافت داده‌های کاربران، این روش‌ها را می‌توان به دو دسته: ۱- مبتنی بر حسگر<sup>۱</sup> و ۲- مبتنی بر تصویر<sup>۲</sup> تقسیم‌بندی کرد. بر حسب نحوه پیاده سازی شبکه حسگر، رویکردهای مبتنی بر حسگرها خود به دو دسته: ۱- مبتنی بر سنجش متراکم<sup>۳</sup> و ۲- مبتنی بر حسگرهای پوشیدنی<sup>۴</sup>، تقسیم‌بندی می‌شوند. همچنین، بر حسب روش‌هایی که برای مدل سازی اعمال انسان استفاده می‌شود، هریک از رویکردهای بازشناسی اعمال را می‌توان به سه زیر گروه: ۱- مبتنی بر داده<sup>۵</sup>، ۲- مبتنی بر دانش<sup>۶</sup>، و ۳- هیبریدی<sup>۷</sup> دسته بندی کرد. رویکردهای مبتنی بر داده خود می‌توانند با ناظر<sup>۸</sup>، بدون ناظر<sup>۹</sup>، و یا نیمه نظارتی<sup>۱۰</sup> بوده، و رویکردهای مبتنی بر دانش می‌توانند مبتنی بر داده کاوی، منطقی، و یا هستان شناسی باشند. این دسته بندی را به طور کامل برای رویکردهای مبتنی بر حسگرها با سنجش متراکم نشان می‌دهد. لازم به ذکر است که دسته بندی ذکر شده برای رویکردهای مبتنی بر

---

<sup>۱</sup> Sensor-based

<sup>۲</sup> Vision-based

<sup>۳</sup> Dense sensing-based

<sup>۴</sup> Wearable sensor-based

<sup>۵</sup> Data-driven

<sup>۶</sup> Knowledge-driven


<sup>۷</sup> Hybrid

<sup>۸</sup> Supervised

<sup>۹</sup> Unsupervised

<sup>۱۰</sup> Semi-supervised

تصویر و حسگرهای پوشیدنی نیز می‌تواند وجود داشته باشد؛ اما از آنجا که تمرکز اصلی این رساله بر رویکردهای مبتنی بر حسگرها با سنجش متراکم است، از جزئیات مربوط به این روش‌ها صرف نظر کرده ایم. در ادامه به مرور روش‌های بازشناسی اعمال مطابق با این نمودار خواهیم پرداخت.



شکل ۱-۲. دسته بندی روش‌های بازشناسی اعمال انسان در محیط‌های هوشمند.

## ۲-۲ رویکردهای مبتنی بر تصویر

روش‌های مبتنی بر تصویر [۲۲-۲۴] برای شناسایی اعمال از دیرباز مورد توجه خاصی قرار داشته‌اند. در این رویکردها، از دوربین‌های ویدئویی، برای تشخیص عمل، موقعیت بدن کاربر و تغییرات محیط استفاده می‌شود. این حوزه از تحقیقات بخش مهمی از پژوهش‌های مربوط به بینایی ماشین بوده و کاربردهای وسیعی در سیستم‌های نظارتی و امنیتی، سیستم‌های مراقبت پزشکی، و سیستم‌های تعاملی انسان-کامپیوتر (HCI)<sup>۱</sup> را دارا می‌باشد [۲۵-۲۸].

به طور کلی، تشخیص اعمال با استفاده از دنباله‌های ویدئویی شامل مراحل حائز اهمیت از جمله: پیش پردازش تصاویر، استخراج ویژگی با در نظر گرفتن اعمال، و مدل سازی اعمال بر مبنای ویژگی‌های

<sup>۱</sup> Human-computer interaction

استخراج شده می‌باشد. در پیش پردازش سعی می‌شود تا کارایی سیستم، با حذف نویز و ویژگی‌های کم اهمیت از ورودی ویدیویی، بهبود داده شده [۲۹]، و خروجی مناسبی (مثلا قطعه بندی تصویر کاربر با مشخص کردن اجزای بدن [۳۰, ۳۱]) برای دیگر اجزای سیستم فراهم گردد. سپس از داده‌های پیش پردازش شده ویژگی‌های مناسب به منظور مدل سازی استخراج می‌گردند. هدف اصلی در استخراج ویژگی یافتن مجموعه‌ای از خصیصه‌ها مانند شکل، سیلوت، رنگ‌ها، وضعیت‌ها و حرکات بدن است که اعمال کاربر را به خوبی توصیف کرده و آنها را با مجموعه‌ای از ویژگی‌های توصیفی<sup>۱</sup> بازنمایی نماید. به عنوان مثال، این ویژگی‌های توصیفی می‌توانند SIFT<sup>۲</sup> [۳۲]، HOG<sup>۳</sup> [۳۳]، HOF<sup>۴</sup> [۳۴, ۳۵] و غیره باشند. بر مبنای ویژگی‌های استخراج شده، مدلی برای تشخیص یا کشف عمل کاربر آموزش، و سپس به منظور استنتاج استفاده می‌شود. این مدل‌ها می‌توانند تولیدی<sup>۵</sup> (مانند مدل های مخفی مارکوف<sup>۶</sup> (HMM) و شبکه‌های بیزین دینامیک<sup>۷</sup> (DBN))، و یا تمایزی<sup>۸</sup> (مانند ماشین‌های بردار پشتیبان<sup>۹</sup> (SVM) و شبکه‌های عصبی مصنوعی<sup>۱۰</sup> (ANN)) باشند.

از جمله کارهایی که اخیرا در این حوزه انجام شده می‌توان به رویکردهای [۳۶]، [۳۷]، و [۳۸] اشاره کرد. در [۳۶] از وضعیت‌های بدن که با استفاده از داده‌های دوربین‌های عمقی تخمین زده می‌شوند برای شناسایی اعمال پیچیده انسان استفاده شده است. در این کار یک معماری سلسله مراتبی سه سطحی، که مبتنی بر بازنمایی تنک اعمال ساده انسان است، معرفی گردیده. در [۳۷] یک الگوریتم

<sup>۱</sup> Descriptive features

<sup>۲</sup> Scale-invariant feature transform

<sup>۳</sup> Histogram of oriented gradient

<sup>۴</sup> Histogram of optical flow

<sup>۵</sup> Generative

<sup>۶</sup> Hidden Markov model

<sup>۷</sup> Dynamic Bayesian network DBN

<sup>۸</sup> Discriminative

<sup>۹</sup> Support vector machine

<sup>۱۰</sup> Artificial neural networks

تشخیص اعمال، مبتنی بر استخراج مفصل‌های اسکلت کاربر، با استفاده از دوربین‌های عمقی ارائه شده است. در این سیستم یک عمل با استفاده از مجموعه کوچکی از وضعیت‌های پایه‌ای بدن که با استفاده از خوشه بندی به دست می‌آیند، توصیف می‌گردد. در این کار از یک SVM چند کلاسه برای رده‌بندی استفاده شده است. در [۳۸] رویکردی برای شناسایی اعمال انسان با استفاده از یادگیری عمیق<sup>۱</sup> ارائه شده است. سیستم ارائه شده، اعمال فیزیکی انسان را با استفاده از داده‌های مربوط به اسکلت بدن که از دوربین‌های عمقی به دست می‌آیند، تشخیص می‌دهد.

با وجود آنکه رویکردهای مبتنی بر تصویر مزایایی از جمله وجود داده‌های مطلوب و مناسب برای مدل‌سازی و افزایش کارایی الگوریتم‌های تشخیص اعمال (مثلاً افزایش صحت<sup>۲</sup> رده بندی) دارند، از چند منظر با محدودیت‌های جدی روبرو هستند. اول آنکه استخراج ویژگی‌های توصیفی از تصاویر ویدیویی ضبط شده پیچیدگی محاسباتی بالایی داشته و بنابراین به منابع محاسباتی پر قدرت (و البته گران قیمت) نیازمند خواهیم بود [۳۹]. ثانیاً حریم خصوصی کاربران مساله بسیار مهمی است که مقبولیت استفاده از روش‌های مبتنی بر تصویر را، مخصوصاً در محیط‌های خصوصی مثل محیط منزل، به شدت کاهش می‌دهد [۳۹، ۴۰]. زیرا هیچ کس مایل نیست که در محیط زندگی خود تمام مدت توسط دوربین‌هایی مورد پیگرد قرار بگیرد. این محدودیت‌ها موجب شده تا بسیاری از محققین استفاده از حسگرهای ساده را برای استفاده در محیط‌های هوشمند ترجیح دهند.

## ۲-۳ رویکردهای مبتنی بر حسگرها

در حال حاضر، گستره وسیعی از حسگرها از جمله حسگرهای تماسی<sup>۳</sup>، RFID<sup>۴</sup>، شتاب سنج‌ها،

---

<sup>۱</sup> Deep learning

<sup>۲</sup> Accuracy

<sup>۳</sup> Contact sensors

<sup>۴</sup> Radio-frequency identification

آشکار سازه‌های حرکتی، و غیره به منظور شناسایی اعمال استفاده می‌شوند. مطابق با تقسیم‌بندی که در [۴۱] ارائه شده این حسگرها را می‌توان به چهار دسته: حسگرهای محیطی<sup>۱</sup>، حسگرهای خانگی<sup>۲</sup>، حسگرهای موقعیت یابی، و حسگرهای پزشکی برای دریافت اطلاعات حیاتی بدن تقسیم‌بندی کرد. در کلی‌ترین حالت، این حسگرها یا پوشیدنی و یا محیطی هستند [۴۰]. در ادامه به رویکردهای شناسایی اعمال مبتنی بر حسگرهای پوشیدنی و حسگرهای محیطی می‌پردازیم.

## ۲-۳-۱ تشخیص اعمال، با استفاده از حسگرهای پوشیدنی

حسگرهای پوشیدنی به آنهایی اطلاق می‌شود که به صورت مستقیم یا غیر مستقیم روی بدن انسان کار گذاشته می‌شوند. این حسگرها به هنگام انجام اعمال توسط شخص، سیگنال‌هایی را تولید می‌کنند. این حسگرها، بسته به نوع، می‌توانند داده‌هایی مربوط به وضعیت فیزیکی شخص، حرکت بدن، نبض، دمای بدن و غیره را دریافت نمایند. این حسگرها معمولاً در لباس، عینک، ساعت مچی، گوشی موبایل، و یا مستقیماً روی بدن کار گذاشته می‌شوند. از جمله این حسگرها می‌توان به شتاب سنج‌ها، ژيروسکوپ<sup>۳</sup>، حسگر دمای بدن، حسگر<sup>۴</sup> ECG، و حسگر ضربان قلب اشاره کرد [۴۲].

شتاب سنج‌ها از جمله حسگرهای رایجی هستند که برای شناسایی اعمال اشخاص استفاده می‌شوند. این حسگرها عموماً در شناسایی اعمالی که در آنها حرکات تکراری اجزای بدن رخ می‌دهد مانند راه رفتن، دویدن، ایستادن و بالا رفتن از پله‌ها، موثر می‌باشند. در [۴۳]، از پنج حسگر شتاب‌سنج دو محوری برای شناسایی بیست عمل متفاوت کاربر شامل: راه رفتن، نشستن، ایستادن، دویدن، مسواک زدن و غیره استفاده شده است. این حسگرها بر روی بازو، زانو، مچ پا، مفصل ران، و مچ دست اشخاص

---

<sup>۱</sup> Environmental

<sup>۲</sup> Home usage

<sup>۳</sup> Gyroscope

<sup>۴</sup> Electrocardiography

تعبیه شدند. در [۴۴] رویکردی برای تشخیص اعمال انسان مبتنی بر به کارگیری تنها یک شتابسنج پوشیدنی با سه محور<sup>۱</sup> ارائه شده است. شتابسنج بر دو نقطه‌ی بدن (سینه و مچ پا) مورد آزمون قرار گرفته و از داده‌های آن برای تشخیص اعمال مختلف کاربر شامل نشستن، دراز کشیدن، ایستادن، دویدن، پریدن و غیره استفاده گردیده است. به طور مشابه، در [۴۵] از یک شتاب سنج سه محوری گوشی موبایل هوشمند برای تشخیص اعمال کاربر استفاده شده است. در [۴۶]، از حسگرهای ژيروسکوپ و شتاب سنج، که بر مچ دست و نیز حسگرهای گوشی موبایلی که در جیب شخص قرار گرفته برای شناسایی اعمال مختلف او (مانند ورزش کردن، بالا و پایین رفتن از پله ها و غیره) استفاده شده است. در این کار نشان داده شده که به کارگیری حسگرها در این دو نقطه کارایی فرآیند تشخیص اعمال را نسبت به زمانی که فقط از یکی از این نقاط استفاده می شود افزایش می دهد.

از دیگر فناوری‌های حسگرهای پوشیدنی، حسگرهای بیولوژیکی هستند که با اندازه‌گیری فعالیت‌های حیاتی بدن، برای شناسایی وضعیت‌های جسمانی و یا عمل کاربر استفاده می گردند. تا کنون، انواع مختلفی از حسگرهای بیولوژیکی برای اندازه گیری سیگنال‌های حیاتی بدن مانند فشار خون، ECG، EEG<sup>۲</sup>، و اطلاعات تنفسی، استفاده شده‌اند. در [۴۷]، دمای بدن سربازان به منظور تشخیص هیپوترمی<sup>۳</sup> استفاده شده است. در [۴۸] روشی موسوم به سنتینلا<sup>۴</sup> برای تشخیص پنج عمل راه رفتن، دویدن، نشستن، بالا رفتن، و پایین آمدن ارائه شده. در این کار از ترکیب داده‌های شتابسنج‌های نصب شده بر روی بدن و سیگنال‌های حیاتی بدن برای افزایش صحت تشخیص عمل کاربر استفاده شده است. در این کار، از یک شتابسنج سه محوری و حسگرهای بیولوژیکی برای دریافت سیگنال‌های ECG، دمای بدن،

---

<sup>۱</sup> Triaxial accelerometer

<sup>۲</sup> Electroencephalography

<sup>۳</sup> hypothermia

<sup>۴</sup> Centinela

ضربان قلب، نرخ تنفس، و غیره استفاده شده است.

حسگرهای سیستم مکان یابی جهانی (GPS<sup>۱</sup>) نیز از جمله حسگرهای پوشیدنی پر استفاده تلقی می‌شوند. حسگرهای GPS که امروزه در همه گوشی‌های موبایل وجود دارند، برای استفاده در کاربردهای آگاه به متن<sup>۲</sup> بسیار مناسب می‌باشند. با دانستن موقعیت مکانی فرد، تشخیص عمل او با صحت بیشتری امکان پذیر خواهد بود [۴۹]. در [۵۰] تشخیص رفتارهای سطح بالای انسان، مانند سوار شدن بر اتوبوس در ایستگاه، مسافرت کردن، و پیاده شدن از وسیله نقلیه، با استفاده از جریانی از داده‌های GPS مورد مطالعه گرفته است. در [۵۱] از GPS برای یادگیری مکان‌های مهم، و پیش‌بینی حرکت کاربران استفاده شده است. در [۵۲]، یادگیری نحوه تغییر مکان و پیش‌بینی هدف کاربر و نیز رفتارهای غیر نرمال او با استفاده از لاگ‌های<sup>۳</sup> داده GPS مورد بررسی قرار گرفته است. لازم به ذکر است از آنجا که استفاده از GPS در محیط‌های بسته بسیار محدود می‌گردد، لذا معمولاً این حسگرها توأم با حسگرهای شتاب‌سنج استفاده می‌شوند [۴۹].

تشخیص اعمال با استفاده از حسگرهای پوشیدنی با محدودیت‌هایی همراه می‌باشد. این حسگرها باید به صورت پیوسته و بدون مداخله کاربر کار کنند. همچنین، کاربر باید مدام آنها را با خود حمل کند. این موارد مشکلاتی را در عمل ایجاد می‌کنند. یکی از مشکلات عمده، پذیرش و تمایل کاربر، و نیز توانایی او در استفاده از چنین حسگرهایی می‌باشد. در محیط‌های هموشمندی که تردد کاربر (یا کاربران) به آنها زیاد است و یا کاربر تمایلی به پوشیدن حسگرها ندارد استفاده از این راهکار غیر عملی خواهد بود. از نظر فنی نیز باید توجه داشت که این حسگرها از نظر عمر باتری با محدودیت مواجه هستند. همچنین، ابعاد ماجول‌های مربوط به این حسگرها باید طوری باشد که به سادگی قابل حمل باشند، در

---

<sup>۱</sup> Global Positioning System

<sup>۲</sup> Context-aware

<sup>۳</sup> Logs

غیر این صورت حمل آنها در دراز مدت بسیار دشوار خواهد بود. با توجه به این موارد می توان گفت که استفاده از حسگرهای پوشیدنی توام با ایجاد تزامم<sup>۱</sup> برای کاربر خواهد بود.

## ۲-۳-۲ رویکردهای مبتنی بر سنجش متراکم

رویکردهای مبتنی بر سنجش متراکم [۴۰] که در برخی منابع مانند [۵۳] با عنوان شناسایی محیطی/اعمال<sup>۲</sup> نیز از آن نام برده می شود، به روش هایی اطلاق می شود که در آنها حسگرها در محیط، و بر روی اشیاء مختلف نصب شده اند. این حسگرها داده های مربوط به تعامل کاربر و اشیاء مختلف را دریافت می کنند. در این روش ها، اعمال کاربر با استفاده از تعاملات او با اشیاء مختلف شناسایی می شود. دانستن اینکه چه اشیائی در حال استفاده شدن هستند، سر نخ های مهمی برای تشخیص عمل کاربر به دست می دهد. بنابراین، در این روش ها فرض بر این است که اعمال با استفاده از داده های حسگرها، که هر کدام به کارگیری یک شیء و یا یک رویداد خاص محیطی (مثل حضور شخص در یک مکان) را نشان می دهد، قابل شناسایی هستند. در سنجش متراکم، حسگرهایی با توان مصرفی پایین، کم هزینه، و اندازه کوچک بر روی اشیاء و در مکان های مختلف محیط کار گذاشته می شوند. در ادامه این روش ها را در قالب روش های مبتنی بر داده، مبتنی بر دانش، و هیبریدی با جزئیات بیشتری مورد مطالعه قرار می دهیم. غالباً سنجش متراکم برای توسعه محیط های هوشمند مانند خانه های هوشمند مورد استفاده وسیعی قرار می گیرد.

## ۱-۲-۳-۲ روش های مبتنی بر داده

روش های مبتنی بر داده از تکنیک های یادگیری ماشین و داده کاوی برای مدل سازی اعمال کاربر با استفاده از مجموعه داده هایی که در محیط جمع آوری شده، بهره می گیرند. یکی از مزایای این

---

<sup>۱</sup> Obtrusiveness

<sup>۲</sup> Ambient activity recognition



رویکردها این است که نیاز به تعریف قوانین و ساختارهای صریح برای استخراج اعمال کاربر را کاهش می‌دهند. در این روش‌ها پس از آنکه الگوریتم یادگیری ماشین مربوطه بر روی داده‌های جمع‌آوری شده در محیط آموزش داده شد، رده‌بندی بدون نیاز به دخالت انسان می‌تواند انجام شود. هرچند، برای الگوریتم یادگیری ماشین، به داده‌های آموزشی نیاز خواهد بود و نیز وارد کردن دانش قبلی مربوط به یک حوزه خاص در این الگوریتم‌ها دشوار می‌باشد.

در این رویکردها هدف اصلی یادگیری ماشین، آموزش دادن یک رده‌بند با استفاده از داده‌های آموزشی، و سپس استفاده از آن برای رده‌بندی یا پیش‌بینی نمونه‌های جدید است. الگوریتم‌های آموزش خود می‌توانند با ناظر، بدون ناظر و یا به صورت نیمه-نظارتی باشند. تفاوت اصلی بین این رهیافت‌ها در میزان برچسب‌گذاری داده‌های آموزشی در آنهاست. در ادامه به هر یک از این رویکردها خواهیم پرداخت.

## روش‌های با ناظر

در یادگیری با ناظر، یک رده‌بند بر روی داده‌های حسگرها و یا ویژگی‌های استخراج شده از آنها آموزش داده می‌شود. داده‌های حسگرها در مجموعه آموزشی به طور کامل برچسب‌گذاری شده و رده‌بند طوری آموزش داده می‌شود که کمترین خطای رده‌بندی (یا به عبارتی بیشترین صحت) حاصل گردد. روش‌های با ناظر نخستین رویکردهایی هستند که برای شناسایی اعمال استفاده می‌شوند. رده‌بندهای نزدیکترین همسایه (KNN)<sup>۱</sup>، [۵۴]، [۵۵]، درخت‌های تصمیم [۵۶]، [۵۷]، [۵۸]، ماشین‌های بردار پشتیبان (SVM)، [۶]، و مدل‌های گرافیکی احتمالاتی مانند رده‌بند ساده بیز<sup>۲</sup> [۵۹]، [۶۰]، مدل مخفی

---

<sup>۱</sup> K nearest neighbor

<sup>۲</sup> Naïve Bayes Classifier

مارکوف و انواع مختلف آن [۷]، [۶۱]، [۱۰]، [۶۰]، [۹]، [۶۲]، [۱۴]، [۱۶]، میدان‌های تصادفی شرطی<sup>۱</sup> (CRF) و انواع مختلف آن [۶۰]، [۸]، [۶۳]، [۶۴]، [۱۶]، [۶۵]، و شبکه‌های بیزین پویا (DBN<sup>۲</sup>) [۶۶]، [۶۷]، روش‌های مرسوم هستند که در شناسایی اعمال از آنها استفاده می‌شود. عموماً غیر از روش‌های مبتنی بر مدل‌های یادگیرنده گرافیکی، در سایر روش‌ها قبل از رده بندی، جریان داده حسگرها با توجه به معیارهایی قطعه بندی<sup>۳</sup> می‌گردد. این قطعات ممکن است بر حسب عمل کاربر (با طول زمانی یا تعداد رویدادهای متغیر) [۶۸]، [۵۸]، پنجره‌های زمانی با طول ثابت، پنجره‌هایی با طول زمانی متغیر اما با تعداد ثابت رویداد حسگرها، و یا پنجره‌هایی وزن دار محاسبه شوند [۶].

یکی از ساده ترین رده بندهای تمایزی مبتنی بر داده KNN می‌باشد. از KNN معمولاً زمانی که دنباله داده‌های حسگرها بر حسب عمل مربوط به آنها از پیش قطعه بندی شده‌اند استفاده می‌شود. در چنین رویکردهایی برای یک دنباله داده جدید، بردار ویژگی مربوطه استخراج، و فاصله آن با بردار ویژگی نمونه‌های آموزشی محاسبه می‌شود. نمونه جدید مشاهده شده مربوط به عملی (کلاسی) است که بیشترین تعداد نمونه از بین  $k$  نزدیکترین همسایه، با آن عمل برچسب خورده‌است. در [۵۴] برای هر دنباله داده مربوط به عمل کاربر، یک بردار ویژگی شامل تعداد تکرارهای رخداد حسگرها محاسبه، و نیز فاصله اقلیدسی برای رده بند KNN در نظر گرفته شده است. در [۵۵] مشابه با کار قبلی، عملکرد KNN مورد مطالعه قرار گرفته است. در این کار علاوه بر KNN کلاسیک، نسخه‌ای از KNN که مبتنی بر نظریه شهود دمپستر-شفر<sup>۴</sup> است، تحت عنوان ET-KNN<sup>۵</sup>، نیز بررسی گردیده. در ET-KNN هر یک از  $k$  نزدیکترین همسایه یک نمونه جدید، به عنوان شهودی<sup>۶</sup> در نظر گرفته می‌شود که به میزان خاصی به

<sup>۱</sup> Conditional random field

<sup>۲</sup> Dynamic Bayesian networks

<sup>۳</sup> Segment

<sup>۴</sup> Dempster-Shafer theory of evidence

<sup>۵</sup> Evidence theory based KNN

<sup>۶</sup> Evidence

تعلق نمونه جدید به هریک از کلاس‌ها (یعنی اعمال) باور<sup>۱</sup> دارد. توده باور  $k$  نزدیک‌ترین همسایه با عملگر ترکیب دمپستر تجمیع شده و عملی که بیشترین باور در مورد آن به دست می‌آید به عنوان برچسب نمونه جدید در نظر گرفته می‌شود. در [۵۵] نشان داده شده که عملکرد ET-KNN تا حدودی بهتر از KNN کلاسیک می‌باشد.

درختان تصمیم یکی دیگر از الگوریتم‌های رده‌بندی تمایزی مناسب برای بازشناسی اعمال هستند. در درختان تصمیم، داده‌های آموزشی بر حسب برچسب اعمال مربوط به آنها، به زیرمجموعه‌هایی تقسیم می‌شوند و مجموعه‌ای از قوانین مبتنی بر مقادیر ویژگی‌های داده‌های آموزشی برای این تقسیم‌بندی به دست می‌آیند. هر زیر مجموعه پایانی با یک عمل برچسب می‌خورد. از قوانین به دست آمده برای شناسایی زیرمجموعه‌ای که مربوط به دنباله جدید مشاهده شده است استفاده می‌شود. در [۵۶] از درخت تصمیم C4.5 برای تشخیص اعمالی همچون استفاده از کامپیوتر، خوابیدن، مطالعه کردن، و غیره استفاده شده. در این کار از پنجره گذاری زمانی با طول ثابت (۳۰ ثانیه) و برچسب گذاری آنها برای آموزش و آزمون استفاده شده است. در [۵۷] از درختان تصمیم برای استخراج ویژگی استفاده شده است. در این کار با بهره‌گیری از درخت تصمیم J48 مبتنی بر بهره اطلاعاتی<sup>۲</sup>، زیر مجموعه‌ای از ویژگی‌ها (حسگرها) که بیشترین تاثیر در رده بندی اعمال را دارند انتخاب شده اند. برای این کار جریان داده حسگرها بر حسب اعمال به صورت دستی قطعه بندی شده اند. در [۵۸] جریان داده حسگرها بر حسب میزان همبستگی رخداد متوالی حسگرها و نیز رابطه زمانی بین آنها قطعه بندی، و سپس با استفاده از درختان تصمیم برای هر قطعه یک عمل استنتاج می‌گردد. با وجود اینکه درختان تصمیم برای شناسایی رفتارهای انسان کارایی مناسبی دارند، اما برای شناسایی تغییرات در رفتارها مناسب نیستند. به عنوان مثال، آشپزی کردن همیشه مجموعه حسگرهای یکسانی را فعال نمی‌کند. در

---

<sup>۱</sup> Belief

<sup>۲</sup> Information gain

واقع هرچند یک درخت تصمیم ممکن است نداشت بین زیر مجموعه ای از داده‌های حسگرها به اعمال را یادبگیرد، اما در عین حال ممکن است داده‌های دیگر حسگرهایی که مربوط به آن عمل هستند را از دست بدهد.

از دیگر روش‌های تمایزی پرکاربرد مورد استفاده در تشخیص اعمال، می‌توان به ماشین بردار پشتیبان (SVM) اشاره کرد. در [۶] (و به طور مشابه در [۶۹]) جریان داده حسگرها با روش‌های مختلف قطعه بندی (یعنی پنجره گذاری زمانی، پنجره گذاری مبتنی بر رویداد، و وزن دهی به داده‌های یک پنجره)، بخش بندی شده، سپس برای هر قطعه یک بردار ویژگی شامل تعداد رخداد حسگرها، زمان شروع و اتمام قطعه، و نیز احتمال تعلق قطعه قبلی به هر یک از کلاس‌ها (اعمال)، محاسبه می‌گردد. در نهایت یک رده بند SVM چند کلاسه آموزش داده شده، و برای تشخیص عمل مربوط به داده‌های جدید از آن استفاده می‌شود. در [۷۰]، جریان داده حسگرهای دودویی به بازه‌های زمانی کوچک (۶۰ ثانیه) قطعه بندی شده، و در هر برش زمانی احتمال پسین رخداد هر یک از اعمال با استفاده از ماشین بردار پشتیبان محاسبه می‌گردد. از این توزیع پسین به عنوان ماتریس نشر<sup>۱</sup> در یک HMM برای تشخیص نهایی اعمال متوالی در برش‌های زمانی استفاده شده است. در [۷۱] از SVM با توابع هسته<sup>۲</sup> مختلف (خطی، چند جمله‌ای، گاوسی<sup>۳</sup>، و پرسپترون چند لایه (MLP<sup>۴</sup>)) برای رده بندی دنباله‌های از پیش قطعه بندی شده استفاده شده است. در این کار ترکیب خروجی رده بندهای SVM مبتنی بر هسته‌های متفاوت نیز مورد بررسی قرار گرفته و نشان داده شده که کارایی رده بندی با این کار افزایش می‌یابد. در [۷۲] از C-SVM با تابع هسته گاوسی برای رده بندی مشاهدات حسگرها، به منظور مدیریت داده‌های نامتعادل<sup>۵</sup> استفاده شده است. برای این کار، به هر یک از کلاس‌ها وزنی اختصاص داده شده تا هزینه

---

<sup>۱</sup> Emission matrix

<sup>۲</sup> Kernel function

<sup>۳</sup> Gaussian

<sup>۴</sup> Multi-Layer perceptron

<sup>۵</sup> Imbalanced data

رده‌بندی نمونه‌های کلاس کم جمعیت افزایش، و در نهایت صحت رده‌بند افزایش یابد. یکی از مشکلات استفاده از SVM پیچیدگی محاسباتی بالای آن مخصوصاً در مسائل چند کلاسه با نمونه‌های آموزشی زیاد می‌باشد.

از آنجا که همواره تغییراتی در نحوه انجام اعمال وجود دارند و نیز رفتارها مستقیماً قابل مشاهده نیستند (یعنی فقط از طریق حسگرها میتوان رفتار کاربر را مشاهده کرد)، مدل‌های احتمالاتی گرافیکی<sup>۱</sup> مانند: رده‌بند ساده بیز، مدل‌های مخفی مارکوف و غیره، برای شناسایی اعمال مورد توجه خاصی قرار گرفته‌اند. این راهکارها ابزار مناسبی برای مدل کردن دنباله‌ها فراهم می‌آورند [۱۷]. در این مدل‌ها، یک گراف قالب<sup>۲</sup> وجود دارد که در آن وابستگی بین متغیرهای تصادفی (رئوس گراف) برحسب دانش پیشین و با استفاده از یالهایی بین آنها نمایش داده می‌شود (شکل ۲-۲ قسمت الف). این گراف می‌تواند یک شبکه بیزین و یا یک شبکه مارکوف باشد. با داشتن دنباله‌ای از مشاهدات، گراف قالب باز<sup>۳</sup> شده و یک شبکه بیزین یا مارکوف برای کل دنباله به دست می‌آید (شکل ۲-۲ قسمت ب). در شبکه باز شده احتمال متغیرهای مجهول به شرط متغیرهای مشاهده شده محاسبه، و از این تابع توزیع پسین برای استنتاج محتمل‌ترین توالی از مقادیر متغیرهای مخفی استفاده می‌شود. در ادامه به روش‌های مبتنی بر این مدل‌ها می‌پردازیم.

ساده‌ترین مدل گرافیکی مورد استفاده، رده‌بند ساده بیز (NBC<sup>۴</sup>) می‌باشد. در این رده‌بند، ابتدا توزیع احتمال توام اعمال و دنباله داده‌های حسگرها به دست می‌آید. سپس، با مشاهده مجموعه‌ای از داده‌های حسگرها، مجموعه‌ای از اعمال که احتمال آنها به شرط مشاهده آن حسگرها ماکزیمم باشد،


---

<sup>۱</sup> Probabilistic graphical models

<sup>۲</sup> Template graph

<sup>۳</sup> Unroll

<sup>۴</sup> Naïve Bayes classifier



شکل ۲-۲. الف- گراف قالب یک مدل گرافیکی، ب- گراف باز شده یک شبکه بیزین.

استنتاج خواهد شد [۵۹]. شکل ۲-۳ قسمت الف ساختار یک NBC نوعی برای تشخیص اعمال را نشان می‌دهد. این مدل‌سازی بر این فرض استوار است که مشاهدات حسگرها در یک زمان، صرفاً به عمل انجام شده در همان زمان وابسته هستند؛ و ارتباط بین داده‌های متوالی حسگرها و نیز اعمال متوالی ممکن، در نظر گرفته نمی‌شود. بنابراین، یک مشکل در روش ساده بیز این است که اطلاعات زمانی مثل ترتیب فعال شدن حسگرها و یا مدت زمان فعال ماندن آنها در نظر گرفته نمی‌شود. امروزه از NBC به عنوان یک روش معیار در بسیاری از کارها استفاده می‌شود [۶۰].

مدل‌های مخفی مارکوف (HMM)<sup>۱</sup> و انواع مختلف آن، از جمله رده‌بندهای تولیدی هستند که می‌توانند اطلاعات زمانی<sup>۲</sup> را نیز در مدل‌سازی وارد کنند. در HMM پایه [۷۳]، یک لایه از وضعیت‌های مخفی و یک لایه از وضعیت‌های قابل مشاهده وجود دارد. وضعیت‌های لایه مخفی با یک توپولوژی خاص و به صورت یک زنجیره مارکوف به یکدیگر و نیز به وضعیت‌های مربوط به مشاهدات متصل هستند. با در نظر گرفتن وضعیت‌های لایه مخفی به عنوان اعمال (متغیرهای مجهول)، و وضعیت‌های لایه مشاهدات به عنوان داده‌های حسگرها، توزیع احتمال توأم اعمال و مشاهدات، یعنی  $p(y_1, \dots, y_T, x_1, \dots, x_T)$  با

<sup>۱</sup>Hidden Markov Model

<sup>۲</sup> Temporal information


در نظر گرفتن وابستگی‌های بین متغیرها در شبکه بیزین باز شده<sup>۱</sup> HMM محاسبه می‌گردد. این ساختار در شکل ۲-۳ قسمت ب نشان داده شده است. محاسبه این توزیع توام مبتنی بر مفروضات مارکوف (یعنی وابستگی یک وضعیت مخفی به تعداد محدودی از وضعیت‌های مخفی قبلی، و نیز استقلال شرطی مشاهدات از هم) می‌باشد [۷۳]. با داشتن دنباله مشاهدات حسگرها، احتمال پسین اعمال به شرط مشاهدات، با استفاده از توزیع احتمال توام محاسبه شده و دنباله اعمال با بیشترین احتمال با استفاده از الگوریتم ویتربی<sup>۲</sup> بدست می‌آید [۷]، [۶۱]. این الگوریتم، هر داده در دنباله مشاهدات حسگرها را با یک عمل برچسب می‌زند. اگر هر عمل خود از زیر عمل‌هایی ساده‌تر تشکیل شده باشد، آنگاه می‌توان از مدل مخفی مارکوف سلسله مراتبی (HHMM)<sup>۳</sup> استفاده کرد [۱۰]. در [۱۰] یک مدل مخفی مارکوف با سه لایه مخفی و یک لایه مشاهدات مطابق با شکل ۲-۳ برای شناسایی اعمال ارائه شده است. در این ساختار،  $x_i$  ها بردارهای مشاهدات، اولین لایه مخفی ( $y_i$  ها) مربوط به اعمالی خواهد بود که قصد شناسایی آنها را داریم، لایه مخفی میانی ( $f_i$  ها) مربوط به متغیرهای کمکی است که مقدار آنها پایان دنباله اعمال ساده مربوط به یک عمل پیچیده تر را نشان می‌دهند، و لایه مخفی پایینی ( $Z_i$  ها) مربوط به اعمال ساده کاربر می‌باشد. همانطور که می‌بینیم در این ساختار نیز در لایه‌های مخفی وضعیت‌ها مانند یک زنجیره مارکوف به هم متصل هستند و نیز، وابستگی بین وضعیت‌های لایه‌های مخفی مختلف با توپولوژی از پیش تعریف شده‌ای تعیین می‌گردد. در عمل، در مدل‌های چند لایه، با توجه به تعداد زیاد پارامترهای مجهول، به داده‌های آموزشی بیشتر برای افزایش کارایی رده‌بند، نیاز خواهد بود.

---

<sup>۱</sup> Unrolled

<sup>۲</sup> Viterbi

<sup>۳</sup> Hierarchical hidden Markov model



شکل ۲-۳. الف) ساختار یک NBC، ب) ساختار یک HMM، ج) ساختار یک HHMM برای تشخیص اعمال [۱۰].

در HMM مدت زمان توقف در یک وضعیت لایه مخفی می‌تواند مدت زمان یک عمل را نشان دهد. این زمان در HMM پایه به طور ضمنی و با یک انتقال از وضعیت به خودش<sup>۱</sup> مدل می‌شود. اما در بسیاری از کاربردها مدت زمان توقف در یک وضعیت بهتر است به درستی تعیین گردد. برای انجام این کار می‌توان از مدل نیمه-مارکوف مخفی (HSMM)<sup>۲</sup> استفاده نمود [۶۲]، [۹]، [۶۰]. در HSMM مدت زمان توقف در یک وضعیت به طور غیر ضمنی و با یک متغیر تصادفی نشان داده می‌شود. به هنگام تغییر به وضعیت جدید مقدار این متغیر به صورت تصادفی با یک توزیع احتمال خاص، تعیین می‌گردد. در هر گام یک واحد از مقدار این متغیر کاسته می‌شود و هر زمان که به صفر رسید، تغییر وضعیت می‌تواند صورت گیرد. در [۶۰] و [۹] از یک لایه مخفی، و در [۶۲] از دو لایه مخفی در ساختار HSMM استفاده شده است. از جمله دیگر انواع HMM، می‌توان به مدل مخفی مارکوف کوپل (CHMM)<sup>۳</sup> برای مدل کردن تعاملات بین کاربران در محیط‌های با چند کاربر نام برد [۱۴]، [۱۶].

لازم به ذکر است که در برخی از کارها، مانند [۷۴] و [۷۵]، برای تشخیص عمل مربوط به یک

<sup>۱</sup>Self-transition

<sup>۲</sup>Hidden Semi-Markov Model

<sup>۳</sup> Coupled hidden Markov model



دنباله از داده‌های حسگرها، اعمال به صورت مجزا مدل می‌شوند. در [۷۴]، برای هر عمل یک HMM با تعداد دلخواه وضعیت مخفی ایجاد شده که فقط نشان دهنده مدل مربوط به همان عمل است. سپس با داشتن دنباله ای از داده‌های حسگرها، مساله ارزیابی<sup>۱</sup> برای HMM مربوط به هر عمل حل می‌شود. عملی را که مدل آن بیشترین احتمال تولید دنباله مشاهده شده را دارد به عنوان عمل انجام شده در نظر گرفته می‌شود. در [۷۵]، برای هر عمل یک مدل مارکوف (زنجیره مارکوف) تعریف شده است. در مدل مربوط به هر عمل، حسگرها وضعیت‌های مدل مارکوف را تشکیل می‌دهند. در هر وضعیت، مدت زمان استفاده از حسگر به صورت یک متغیر تصادفی مدل شده است. با داشتن دنباله داده‌های حسگرها، احتمال رخداد هر عمل به شرط داشتن مدل مربوط به آن محاسبه می‌شود. عملی که بیشترین احتمال رخداد را دارد به عنوان عمل انجام شده، استنتاج می‌شود.


میدان‌های تصادفی شرطی ( $CRF^2$ ) [۷۶] از جمله رده‌بندهای تمایزی هستند که می‌توان از آنها آنها برای رده‌بندی دنباله‌های مربوط به اعمال کاربر استفاده کرد [۶۰]، [۸]، [۶۳]. برخلاف HMM ها، در CRF ها احتمال پسین اعمال به شرط مشاهدات حسگرها به طور مستقیم، و بدون محاسبه توزیع توام آنها محاسبه می‌شود. بر خلاف HMM در CRF ها شرط استقلال مشاهدات از هم، پیش‌فرض نیست. یک CRF باز شده، شبکه مارکوفی است که در آن مشاهدات (ویژگی‌های محاسبه شده)، و برچسب کلاس‌های مورد نظر به عنوان متغیرهای تصادفی مجهول وابسته به هم در نظر گرفته می‌شوند. وضعیت‌های مخفی با یک توپولوژی خاص، مثلاً زنجیره خطی، به هم وابسته هستند (شکل ۲-۴. الف). در [۶۰]، [۸]، و [۶۳] از CRF ها با توپولوژی زنجیره خطی برای شناسایی اعمال استفاده شده است. در این کارها وضعیت‌های مخفی را مربوط به اعمال، و داده‌های حسگرها را به عنوان مشاهدات در نظر

---

<sup>۱</sup>Evaluation

<sup>۲</sup> Conditional random fields

گرفته‌اند. در [۶۴] از CRF نهان دینامیکی (LDCRF<sup>۱</sup>) برای تشخیص اعمال استفاده شده است. در ساختار LDCRF یک لایه اضافی از متغیرهای تصادفی نهان وجود دارد که خصوصیات ساختاری مربوط به اعمال را نشان می‌دهند (شکل ۴-۲ ج). مقادیر این متغیرها در مجموعه آموزشی دیده نشده، لذا آنها را نهان<sup>۲</sup> می‌نامند (متغیرهای  $h_i$ ). از جمله دیگر انواع CRF ها، می‌توان به CRF های فاکتوری (FCRF<sup>۳</sup>) اشاره نمود. مشابه CHMM ها از FCRF ها برای مدل سازی تعاملات بین کاربران استفاده شده است [۱۶].



شکل ۴-۲. الف- میدان تصادفی شرطی خطی، ب- میدان تصادفی شرطی با زنجیره پرش (SCCRF)، ج- میدان تصادفی شرطی نهان دینامیکی (LDCRF).

یکی از محدودیت‌های CRF این است که معمولاً وابستگی بین وضعیت‌ها با یک ساختار ساده، مثلاً زنجیره خطی، ایجاد می‌شود. در صورت پیچیده شدن این ساختار، پیچیدگی محاسباتی افزایش خواهد یافت. همچنین لازم به ذکر است که برای تعیین نحوه وابستگی وضعیت‌ها (اعمال) به هم، به دانش قبلی نیاز خواهد بود که این نیز محدود کننده است. مثلاً در [۶۵] از CRF با زنجیره‌های پرش<sup>۴</sup>

<sup>۱</sup> Latent dynamic conditional random field

<sup>۲</sup> Latent

<sup>۳</sup> Factorial Conditional Random Fields

<sup>۴</sup> Skip-chain conditional random fields

(SCCRF) برای تشخیص اعمال متداخل استفاده شده است (شکل ۲-۴. ب). این زنجیره‌ها با دانش قبلی در ساختار CRF وارد می‌شوند و در صورت نادقیق بودن، کارآیی رده‌بند را کاهش می‌دهند.

از جمله دیگر مدل‌های گرافیکی برای شناسایی اعمال، شبکه‌های بیزین دینامیکی (DBN) هستند. DBN ها نوع عمومی‌تر HMM ها می‌باشند. در ساختار DBN در هر برش زمانی یک بخش<sup>۱</sup> وجود دارد که شامل وضعیت جدید و وضعیت قبلی است [۱۷]. هر وضعیت در DBN، یک کپی از قالب شبکه بیزین اولیه ای است که وابستگی بین متغیرها را نشان می‌دهد. آموزش و استنتاج در DBN، به سادگی شامل انتشار شبکه بیزین اولیه در برش‌های زمانی متوالی مطابق با یک مدل احتمالاتی، و محاسبه توزیع توام متغیرهای وضعیت جدید، به شرط متغیرهای وضعیت قبلی خواهد بود. در DBN طبق شرط مارکوف، فرض می‌شود که هر وضعیت در طول زمان فقط به وضعیت قبلی خود وابسته است. همچنین فرض می‌شود که احتمال وضعیت جدید به شرط وضعیت قبلی، مستقل از زمان<sup>۲</sup> است. در [۶۶] از DBN برای دنبال کردن و مدل‌سازی اعمال اشخاص استفاده شده است. در [۶۷]، یک وسیله رباتیک لمسی به منظور امداد در فوریت‌های پزشکی با استفاده از DBN ها برای مدل‌سازی رفتار فعلی کاربر و توانایی‌های او مانند نرخ یادگیری و غیره استفاده شده است.

علاوه بر روش‌های فوق، برخی از روش‌های با نظارت سعی دارند از داده‌های برای استخراج مدل اعمال کاربر از داده‌های آموزشی، استفاده نمایند. در [۴۱] روشی با نظارت برای طراحی یک سیستم دستیار هوشمند ارائه گردیده که در آن نیازی به برچسب گذاری دستی داده‌ها نیست. در محیط، علاوه بر حسگرها، عملگرهایی<sup>۳</sup> نیز نصب گردیده و وقتی کاربر عملی را انجام می‌دهد، علاوه بر حسگرها، عملگرها نیز فعال شدن خود را ثبت می‌کنند. در این کار، داده‌های آموزشی به هنگام انجام اعمال توسط

---

<sup>۱</sup>Fragment

<sup>۲</sup>Time Invariant

<sup>۳</sup> Actuators

کاربر، جمع‌آوری شده و به طور خودکار توسط عملگرهایی برچسب گذاری می‌شوند. پس از مدتی محیط خواهد آموخت که با فعال شدن چه حسگرهایی کدام عملگرها فعال می‌شوند. لذا سیستم آگاه به متن<sup>۱</sup> خواهد بود. حال اگر کاربر با انجام عملی مجموعه‌ای از حسگرها را فعال کند، متن عمل مربوطه تشخیص داده خواهد شد و عملگرهای مرتبط با آن می‌توانند به طور خودکار فعال شوند و در جهت کمک به کاربر عملی را انجام دهند. این روش برای محیط‌های تک کاربره ارائه گردیده است.

در حال حاضر، عمده کارهای مربوط به شناسایی اعمال مبتنی بر سنجش متراکم، از جمله کارهایی که تا اینجا به آنها پرداختیم، مربوط به محیط‌های تک کاربره هستند. اگر تعداد کاربران در محیط افزایش یابد، اعمال کاربران و نیز داده‌های مربوط به آنها به صورت متداخل یا هم‌روند در خواهند آمد، و تشخیص آنها پیچیدگی محاسباتی بیشتری خواهد داشت. در ادامه به معدود کارهایی که مربوط به محیط‌های چند کاربره مبتنی بر سنجش متراکم هستند می‌پردازیم.

در [۷۷] چارچوبی به نام EPSICAR<sup>۲</sup> برای شناسایی اعمال ترتیبی، متداخل و هم‌روند، بر مبنای یافتن الگوی داده‌ای هر عمل ارائه شده است که می‌تواند در محیط‌های با چند کاربر نیز مورد استفاده قرار گیرد. در این رهیافت، ابتدا برای هر عمل مجزا، الگوهایی از داده‌های حسگرها که رخداد یک عمل در جریانی از حسگرها را نشان می‌دهند، موسوم به الگوهای در حال ظهور (EP<sup>۳</sup>)، شناسایی می‌شوند. این کار با استفاده از داده‌های آموزشی صورت می‌گیرد. سپس برای تشخیص اعمال ترتیبی در جریانی از داده‌ها، در یک نقطه زمانی برای هر عمل، به اندازه میانگین مدت زمان آن عمل، داده‌ها جمع‌آوری شده و اگر EP مربوط به آن عمل ظاهر شده باشد، امکان رخداد آن عمل در آن بازه زمانی با یک مقدار عددی بازنمایی می‌شود. پس از اینکه این امکان برای همه اعمال محاسبه شد، محتمل‌ترین عمل

---

<sup>۱</sup>Context Aware

<sup>۲</sup> Emerging pattern-based sequential, interleaved, and concurrent activity recognition

<sup>۳</sup> Emerging Pattern

انتخاب شده و آن قاب زمانی با عمل انتخاب شده برچسب زده می‌شود. سپس، قاب زمانی قبلی اصلاح میشود و این مراحل مجدداً از انتهای آن قاب زمانی تکرار می‌شوند. برای شناسایی اعمال متداخل و یا هم‌روند، EP مربوط به آنها، با ترکیب EP های اعمال مجزا به شکل‌های مختلف، به دست می‌آید. آنگاه، با استفاده از EP اعمال متداخل و هم‌روند به دست آمده، از همان رویه قبلی که برای شناسایی اعمال ترتیبی بیان شد، برای شناسایی اعمال متداخل یا هم‌روند استفاده می‌شود. مشکلی که در این روش وجود دارد، این است که اولاً در پیاده‌سازی‌های انجام شده از تعداد زیادی حدود آستانه برای تشخیص الگوهای تکراری استفاده می‌شود. ثانیاً طراح سیستم باید از قبل تعیین کرده باشد که امکان انجام کدام اعمال به صورت متداخل یا هم‌روند وجود دارد و تمامی این حالات را برای تشخیص درست در نظر بگیرد که بسیار محدود کننده است.

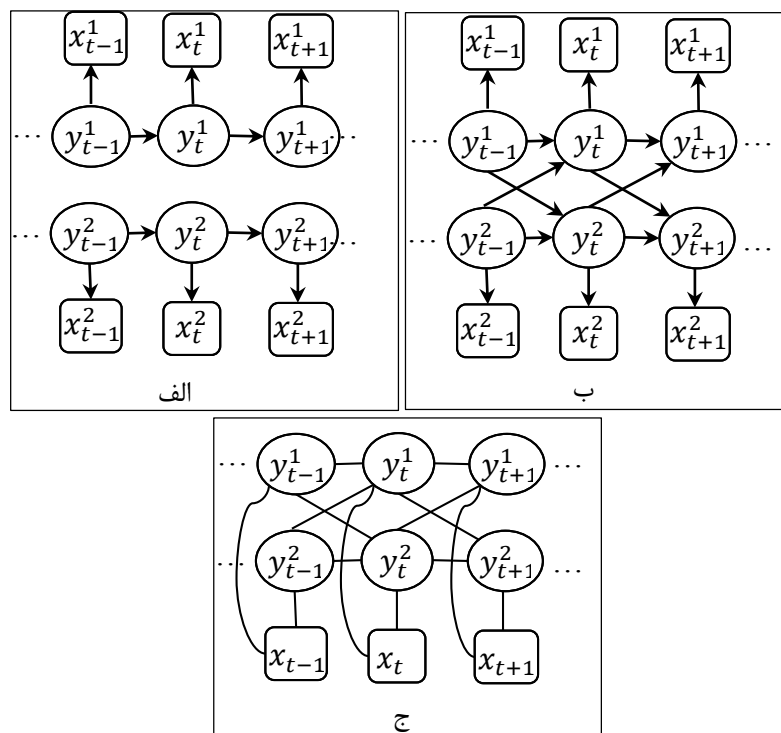
اکثر مدل‌های پیشنهادی برای شناسایی اعمال کاربر در محیط‌های با چند کاربر مبتنی بر مدل‌های گرافیکی احتمالاتی هستند [۱۲]. در [۷۸] و به طور مشابه [۷۹]، از زنجیره مارکوف و رده بند ساده بیز برای تخصیص داده‌های حسگرها به افراد در یک محیط با چند کاربر استفاده شده است. در این کارها عنوان شده که با استخراج داده‌های کاربران مجزا، می‌توان به سوالات بعدی مثل اینکه چند نفر در محیط قرار دارند، پاسخ داد [۷۸]. در [۶۱] به دو شکل از مدل مخفی مارکوف برای شناسایی اعمال کاربران استفاده شده است. در رویکرد اول یک HMM واحد برای مدل کردن اعمال کلیه کاربران و مشاهدات حسگرها به صورت توأم استفاده شده است. در رویکرد دوم، با فرض مشخص بودن اینکه کدام رویداد حسگر مربوط به چه کاربری بوده، به ازای هر کاربر یک مدل مخفی مارکوف آموزش داده شده است. نتایج نشان می‌دهد که رویکرد دوم کارایی بیشتری نسبت به رویکرد اول خواهد داشت.

در [۸۰] از مدل مخفی مارکوف موازی (PHMM)<sup>۱</sup> برای شناسایی اعمال کاربر استفاده شده

---

<sup>۱</sup> Parallel HMM

است. در ساختار PHMM به ازای هر کاربر یک HMM مجزا وجود دارد و نیز فرض بر آن است که داده‌های حسگرهای مربوط به هر کاربر پیشاپیش از هم متمایز شده اند. در شکل ۵-۲. قسمت (الف)، ساختار PHMM مربوطه نشان داده شده است. در [۸۰] و [۱۵] از CHMM ها برای شناسایی اعمال کاربران با در نظر گرفتن تعامل بین آنها استفاده شده است. در ساختار CHMM به ازای هر کاربر یک زنجیره در نظر گرفته شده است. شکل ۵-۲. قسمت (ب) ساختار CHMM مورد استفاده را نشان می‌دهد. در این کار، جریان داده‌های کاربران از قبل مجزا در نظر گرفته شده است. به طور مشابه، در [۱۶] از FCRF برای تشخیص اعمال کاربران با در نظر گرفتن تعاملات بین آنها در مدل مربوطه بهره گرفته شده است. شکل ۵-۲. قسمت (ج) ساختار FCRF مربوطه را نشان می‌دهد. هرچند در این کار از حسگرهای پوشیدنی استفاده شده است، اما مشابه CHMM ها می‌توان از آن در محیط‌های هوشمند با سنجش متراکم نیز استفاده کرد.



شکل ۵-۲. الف- ساختار PHMM، ب- CHMM و ج- FCRF، برای شناسایی اعمال در محیط چند کاربره.

باید توجه داشت که آموزش یک مدل با در نظر گرفتن وابستگی‌های بین اعمال کاربران، و مشاهدات حسگرها پیچیدگی محاسباتی بالایی خواهد داشت.

## روش‌های بدون ناظر

در یادگیری بدون نظارت، آموزش با دسته‌بندی داده‌هایی که دارای ویژگی‌های مشابه هستند، در خوشه‌های<sup>۱</sup> یکسان انجام می‌گیرد. از آنجا که این روش آموزش نیازی به برچسب‌گذاری داده‌ها نداشته و نیز نیازی به دانش قبلی در خصوص نحوه انجام فعالیت‌ها ندارد، جالب توجه می‌باشد.

در بحث شناسایی اعمال، آموزش بدون نظارت برای شناسایی دنباله داده‌های حسگرهایی که مربوط به یک عمل کاربر هستند، استفاده می‌شود. سپس با استفاده از یک روش بانظارت می‌توان برای هر یک از این مجموعه داده‌ها یک عمل خاص تعیین نمود. یک روش برای خوشه‌بندی، استفاده از اطلاعات موجودی است که از قبل بر روی شبکه اینترنت قرار دارند. به این ترتیب که با استفاده از اینترنت و وب‌کاوی<sup>۲</sup>، اشیایی که بر روی آنها حسگرها نصب شده اند مورد بررسی قرار گرفته و اعمالی که امکان انجام آنها با این اشیاء وجود دارند استخراج می‌شوند [۸۱]، [۸۲]، [۸۳]. لازم به ذکر است که این رهیافت‌ها می‌توانند تحت عنوان روش‌های مبتنی بر دانش نیز دسته‌بندی گردند. همانطور که در بخش بعدی گفته خواهد شد، محدودیت این رویکردها اثبات عمومیت آنها و ضعف آنها در برخورد با ویژگی‌های شخصی افراد است.

علاوه بر رویکردهای مبتنی بر وب‌کاوی، در برخی کارها تمرکز بر استفاده از روش‌های خوشه بندی برای یافتن الگوهای تکراری در دنباله داده‌های ورودی است. در این روش‌ها فرض می‌شود در انجام یک عمل، هر بار دنباله‌های مشابهی از داده‌های حسگرها ایجاد می‌شوند. لذا اگر بتوان زیر

---

<sup>۱</sup>Cluster

<sup>۲</sup>Web Mining

دنباله‌های جریان داده حسگرها را خوشه‌بندی نمود، آنگاه دنباله‌های هر خوشه می‌تواند مربوط به یک عمل باشد. در برخی از این روش‌ها از الگوریتم‌های خوشه‌بندی استاندارد مانند نگاشت‌های خودسازمان‌ده (SOM)<sup>۱</sup> [۸۳]، و یا خوشه‌بندی k-means [84] استفاده شده است. از این روش‌ها می‌توان برای استنباط اینکه تا چه اندازه دنباله داده حسگرها مشابه هم هستند استفاده نمود. اغلب یک گام دیگر در این روش‌ها استفاده از یک الگوریتم با نظارت برای نگاشت خروجی دسته‌بندی بدون نظارت به اعمال و شناسایی آنهاست.

در [۸۵] روشی بر مبنای فشردگی اطلاعات با توسعه روش فشردگی سازی LZW<sup>۲</sup> مطرح شده است. در این کار داده‌های حسگرها به صورت نشانه‌ها<sup>۳</sup> در نظر گرفته می‌شوند. فرض شده که هر عمل منجر به تولید الگوهای تکراری از دنباله نشانه‌ها خواهد شد. بنابراین با توسعه روش LZW، برای الگوهای تکراری نشانه‌ها یک کلمه رمزی<sup>۴</sup> تولید می‌شود. سپس، یک یا چند کلمه رمزی به یک عمل تخصیص پیدا کرده و مدل آن عمل به صورت یک HMM به دست می‌آید. آنگاه وضعیت‌های هر HMM برچسب زده می‌شود واز آنها برای استنتاج اعمال در یک روش با نظارت استفاده می‌گردد.

در [۴]، روشی بدون ناظر به نام DVSM<sup>۵</sup> برای استخراج الگوهای تکراری از دنباله داده‌های حسگرها بیان شده. در این روش ابتدا الگوهای عمومی و شکل‌های مختلف آنها از داده‌های متداخل اعمال کاربران، بر حسب میزان پیوستگی الگوها، و میزان فشردگی داده‌ها با جایگزینی الگوهای تکراری، استخراج می‌شوند. سپس الگوهای استخراج شده بر حسب مجموع فاصله ویرایش آنها، و نیز تعداد جا به جایی‌ها و تغییرات لازم برای یکسان سازی، خوشه‌بندی می‌گردند. هر خوشه مربوط به

---

<sup>۱</sup> Self Organizing Map

<sup>۲</sup> Lempel-Ziv-Welch

<sup>۳</sup> Tokens

<sup>۴</sup> Code Word

<sup>۵</sup> Varied-Order Sequence Miner

<sup>۶</sup> Edit Distance



یک عمل در نظر گرفته می‌شود. سپس با استفاده از داده‌های این خوشه‌ها  $n$  مدل مخفی مارکوف ایجاد می‌گردد طوری که در آنها حالات مخفی، اعمال، و مشاهدات، داده‌های حسگرها هستند. با داشتن دنباله داده‌های ورودی جدید، ابتدا این دنباله بخش بندی شده، و بعد بین HMM ها رای گیری می‌گردد و عمل مربوطه به اکثریت آراء انتخاب می‌گردد. در [۵]، روشی به نام COM معرفی شده، که عملکرد DVSM را با تغییر روش خوشه بندی توسعه داده است. در COM، الگوهای استخراج شده بر حسب مکان فیزیکی، مدت زمان آنها، زمان شروع، و ساختار داده‌های حسگرها خوشه بندی می‌شوند. در این روش از حد آستانه‌های مختلفی برای تصمیم‌گیری در خصوص تکراری بودن یک الگو، بسته به نوع حسگرها، استفاده شده است. در [۸۶] رویکرد COM برای استخراج زیردنباله‌های مربوط به اعمال به صورت بدون نظارت مورد استفاده قرار گرفته و سپس برچسب عمل مربوط به زیر دنباله با یک رده بند با نظارت (SVM) تعیین می‌گردد.

روش‌های بدون ناظر مبتنی بر این پیش‌فرض هستند که به هنگام انجام یک عمل، الگوهای تکراری از داده‌های حسگرها ایجاد خواهد شد. فرض دیگری که در کارهای مطرح شده وجود دارد این است که در هر زمان یک عمل (هر چند متداخل) اتفاق می‌افتد. اما در محیط‌های چند کاربره به هنگام انجام اعمال متداخل و یا هم‌روند الگوهای متنوعی از داده‌ها ایجاد خواهند شد و نیز در هر زمان چند عمل می‌تواند صورت گیرد. لذا استخراج الگوهای تکراری به روش‌های مذکور، با انفجار محاسباتی مواجه خواهد بود. اساساً در بهترین حالت، این روش‌ها برای استخراج الگوهای تکراری از دنباله داده‌های اعمال متداخل با فرض اینکه در هر زمان یک عمل اتفاق می‌افتد، طراحی شده‌اند. لذا محدودیت این روش‌ها عدم قابلیت آنها در محیط‌های چند کاربره و تشخیص الگوهای هم‌روند است.

### روش‌های نیمه نظارتی

در رویکرد یادگیری به صورت نیمه نظارتی، الگوریتم یادگیری با استفاده از مجموعه محدودی از

نمونه‌های برچسب گذاری شده، همراه با بهره‌گیری از نمونه‌های بدون برچسب، آموزش داده می‌شود. این روش برای زمانی که تعداد محدودی داده برچسب گذاری شده در مجموعه آموزشی موجود هستند و نیز دانش پیشین مناسبی در خصوص نحوه توزیع نمونه‌های بدون برچسب وجود دارد، مناسب است. در بحث شناسایی اعمال در خانه‌های هوشمند، ممکن است برای کاربر دشوار و یا هزینه‌بر باشد که همه داده‌های حسگرها را برای آموزش سیستم برچسب گذاری نماید. در چنین شرایطی کاربر می‌تواند حجم کمتری از داده‌های آموزشی را برچسب گذاری نماید و سپس از آموزش به صورت نیمه نظارتی برای تعیین برچسب‌های دیگر نمونه‌های آموزشی استفاده کند. در [۸۷] با داشتن یک نمونه قطعه بندی شده جدید از دنباله داده‌های حسگرها، از یک رده بند ترکیبی<sup>۱</sup> برای برچسب گذاری نمونه جدید استفاده می‌شود، سپس نمونه جدید برچسب گذاری شده به مجموعه آموزشی اضافه شده و رده بند مجدداً آموزش داده می‌شود. در این کار از رده‌بندهای NBC، HMM، و CRF به عنوان رده‌بندهای پایه، و از یک درخت تصمیم برای ترکیب خروجی‌های این رده‌بندها استفاده شده است.

اغلب کارهایی که به آموزش نیمه نظارتی پرداخته‌اند مبتنی بر داده‌های حسگرهای پوشیدنی مانند شتاب‌سنج‌ها، هستند؛ هرچند، این رویکردها می‌توانند در محیط‌های مبتنی بر سنجش متراکم نیز مورد استفاده قرار بگیرند. در [۸۸] سه رده‌بند پایه KNN، NBC، و درخت تصمیم بر روی داده‌های برچسب زده شده آموزش داده شده‌اند. یک نمونه بدون برچسب توسط هر سه رده‌بند برچسب گذاری شده و در صورتی که خروجی رده‌بندها یکسان باشد، نمونه برچسب گذاری شده به مجموعه آموزشی اضافه شده و مجدداً رده‌بندها آموزش می‌بینند. این رویکرد بر روی داده‌های حسگرهای پوشیدنی مورد ارزیابی قرار گرفته اما قابل تعمیم به رویکردهای مبتنی بر سنجش متراکم نیز می‌باشد. در [۸۹] و [۹۰]، گرافی از داده‌های برچسب گذاری شده و بدون برچسب (به عنوان رئوس گراف) ایجاد شده و سپس یک

---

<sup>۱</sup> Ensemble

توزیع احتمال برای انتشار برچسب‌ها به نمونه‌های آموزشی بدون برچسب در گراف (گره‌های بدون برچسب)، محاسبه می‌گردد. یکی از مفروضات اصلی در این کارها فرض منیفلد<sup>۱</sup> است. به این معنی که فرض می‌شود برچسب داده‌هایی که در یک ناحیه از فضای ویژگی متراکم شده‌اند باید یکسان بوده باشند. به عبارت دیگر، فرض می‌شود که داده‌های ورودی بر روی یک منیفلد با ابعاد پایین (مثلاً یک رویه دو بعدی) در فضای ویژگی‌ها قرار دارند و ویژگی‌های نمونه‌ها بر روی این منیفلد به صورت ملایم تغییر می‌کنند. لذا می‌بایست این منیفلد تخمین زده شود.

در برخی دیگر از کارها، مانند [۹۱]، [۹۲]، و [۹۳]، از رویکرد انتقال یادگیری<sup>۲</sup> استفاده شده است. به این صورت که پس از آموزش سیستم شناسایی اعمال در یک محیط، سیستم آموزش داده شده به محیطی دیگر برای شناسایی اعمال منتقل می‌شود. اگر بتوان نداشت مناسبی بین حسگرها در دو محیط پیدا کرد، آنگاه این رویکرد می‌تواند امیدبخش باشد.

## ۲-۲-۳-۲ روش‌های مبتنی بر دانش

ایده اصلی در مدل سازی مبتنی بر دانش بر این فرض استوار است که لیست اشیاء دخیل در بسیاری از اعمال روزمره محدود و مشخص می‌باشد و حتی اگر یک عمل بتواند به روش‌های مختلفی نیز انجام گیرد، تعداد و نوع اشیاء دخیل در آن تفاوت‌های بسیار اندکی خواهد داشت. به عنوان مثال، در عملی مثل "مسواک زدن" می‌توان گفت که معمولاً همیشه اشیائی مثل مسواک، خمیر دندان و شیر آب دخالت دارند. هر چند، از سوی دیگر، از آنجا که سبک‌های زندگی، عادت‌ها، و یا توانایی‌های انسان‌ها با هم متفاوت است، ممکن است کارهایشان را به روش‌های مختلفی انجام دهند. مثلاً کسی ممکن است عادت داشته باشد که قهوه را با شیر استفاده کند و دیگری با شکر. با توجه به این موضوع، حتی برای

---

<sup>۱</sup>Manifold

<sup>۲</sup> Transfer learning

انجام یک عمل یکسان، افراد ممکن است از اشیاء مختلفی استفاده کنند. این مسائل ممکن است موجب شوند تا مدل‌های به دست آمده با استفاده از دانش قبلی در حالت کلی قابل تعمیم به همه اشخاص و محیط‌ها نباشند. اما با وجود این مسائل، به کار بستن دانش قبلی در مورد دامنه‌ای از اعمال خوش تعریف و به دست آوردن مدل اینگونه اعمال به صورت مستقل از اشخاص، موضوعی جالب توجه به نظر می‌رسد.

رویکرد مدل سازی و تشخیص اعمال مبتنی بر دانش قصد دارد از دانش قبلی مربوط به یک حوزه خاص استفاده کرده، مدل و الگوی اعمال انجام شده در آن حوزه را به دست آورده و نهایتاً با استفاده از یک فرآیند تصمیم‌گیری اعمال را تشخیص دهد. برای اینکار از متدولوژی‌ها و روش‌های مهندسی دانش برای به دست آوردن دانش استفاده می‌شود. دانش به دست آمده در یک ساختار نمایش داده می‌شود طوریکه این ساختار ارتباط بین اعمال، اشیاء، و زمان و مکان آنها را نشان دهد. نهایتاً از یک روش استنتاج برای مشخص کردن عمل انجام شده استفاده می‌شود. در مقایسه با روش‌های مبتنی بر داده، روش‌های مبتنی بر دانش نیازی به مشاهدات زیاد برای آموزش، و الگوریتم‌های یادگیری پیچیده ندارند. از جمله مزیت‌های این دسته از روش‌ها این است که نیازی به آموزش با داده‌های جمع‌آوری شده در محیط ندارند. اما از سوی دیگر، از ساختارهای ثابتی به عنوان مدل اعمال استفاده می‌کنند که با دانش پیشین به دست می‌آیند؛ لذا عمومیت مدل اعمال می‌تواند چالش برانگیز باشد.

بر حسب روش کسب دانش، نمایش آن، و نحوه استفاده از آن، رویکردهای مبتنی بر دانش برای به سه دسته کلی تقسیم می‌شوند که عبارتند از: رویکردهای مبتنی بر داده کاوی، مبتنی بر منطق، و مبتنی بر هستان‌شناسی<sup>۱</sup>.

---

<sup>۱</sup>Ontology-based

## رویکردهای مبتنی بر داده کاوی

ایده اصلی در این رویکردها ایجاد مدل‌های اعمال با داده کاوی روی اطلاعات مربوط به اعمال است که از منابع عمومی به دست می‌آیند. در واقع با داشتن مجموعه‌ای از اعمال، مجموعه متون مرتبط جستجو شده تا مجموعه اشیاء مورد استفاده و احتمال استفاده آنها در هر عمل به دست آیند. در این رویکردها، مدل اعمال به صورت احتمال حضور هر شیء در هر عمل به دست می‌آید. چنین دانشی می‌تواند با استفاده از منابع مختلفی مانند نحوه انجام کارها (قابل استخراج از سایت [ehow.com](http://ehow.com))، دستورالعمل‌ها (قابل استخراج از سایت [epicurious.com](http://epicurious.com))، کتابچه‌های آموزشی، قوانین تجربی نحوه انجام کارها، و دستورالعمل استفاده از وسایل به دست آیند.

در این رویکردها ابتدا اعمال مورد نظر و منابعی که آنها را توصیف می‌کنند شناسایی می‌شوند، سپس از روش‌های مختلفی از جمله روش‌های بازیابی و تحلیل اطلاعات برای بازیابی تعاریف اعمال و واکشی عباراتی که اشیاء دخیل در یک عمل را توصیف می‌کنند، استفاده می‌شود. آنگاه الگوریتم‌های تحلیل آماری برای تخمین احتمال استفاده از اشیاء به کار گرفته می‌شوند. نهایتاً از اشیاء به دست آمده و اطلاعات مربوط به میزان استفاده از آنها، برای ایجاد مدل اعمال، مثلاً یک HMM، استفاده می‌شود. از مدل به دست آمده می‌توان برای بازشناسی اعمال استفاده کرد.

این رویکردها در آغاز توسط محققان شرکت اینتل<sup>۱</sup> مورد بررسی قرار گرفتند [۸۳]. در [۸۳]، از برچسب گذاری POS<sup>۲</sup> کلمات یک جمله و یک تحلیلگر عبارات منظم برای واکشی اشیاء دخیل در یک عمل استفاده شده است. سپس احتمال استفاده از اشیاء در اعمال به دست آمده. در این کار، سایت‌های [ehow.com](http://ehow.com)، [ffts.com](http://ffts.com) و [epicurious.com](http://epicurious.com) برای به دست آوردن مدل مربوط به اعمال

---

<sup>۱</sup> Intel

<sup>۲</sup> Part of speech

متعددی مورد داده‌کاوی گرفته‌اند. از اشیاء و احتمالات آنها برای ایجاد مدل‌هایی بر مبنای شبکه‌های بیزین پویا (DBN)<sup>۱</sup> استفاده شده است. مشکل اصلی این روش این است که هیچ تضمینی برای درستی مدل‌های به دست آمده در بازنمایی مقادیر احتمالاتی و خصوصیات فردی اعمال وجود ندارد. این ضعف می‌تواند باعث شود تا میزان دقت مدل‌ها در پیاده‌سازی‌های دنیای واقعی کاهش یابد. در [۹۴]، رویکرد [۸۳] با هدف برطرف کردن مشکل خصوصیات فردی در انجام اعمال و افزایش میزان دقت مدل‌ها توسعه داده شده است. مشکلی که در [۹۴] و [۸۳] برای مرتبط کردن اشیاء به اعمال وجود دارد این است که مدل‌ها ممکن است به اشیاء هم معنی اما با اسم‌های متفاوت ارجاء داشته باشند. لذا ممکن است یک عمل دارای چند مدل با اسم یکسان اما اشیاء مختلفی باشد. برای حل این مساله در [۹۵] پیشنهاد شده که برای اشیاء با عملکرد مشابه، مجموعه کلمات هم معنی از WordNet استخراج گردند. WordNet یک مرجع لغوی آنلاین برای زبان انگلیسی است. مشکل دیگری که در رویکردهای اولیه [۹۴] و [۸۳] وجود دارد، قطعه بندی ترتیبی جریان داده حسگرها، بر حسب مدت زمان انجام اعمال است. از آنجا که مدت زمان انجام یک عمل از شخصی به شخص دیگر متفاوت است، موجب خواهد شد تا کاربردهای این روش‌ها محدود گردد. به علاوه در قطعه بندی ترتیبی بروز خطایی در یک بخش منجر به ایجاد خطا در بخش بندی دنباله‌های بعدی خواهد شد. در [۸۱] روشی متفاوت برای بخش‌بندی بر مبنای تعداد دفعات استفاده از اشیاء در اعمال مختلف پیشنهاد شده است.

در حالت کلی، هرچند رویکردهای مبتنی بر داده‌کاوی از منابع عمومی برای به دست آوردن مدل اعمال استفاده می‌کنند، اما در برخورد با خصوصیات فردی انسان‌ها در انجام اعمال ضعیف عمل می‌کنند.

## رویکردهای مبتنی بر منطق

---

<sup>۱</sup>Dynamic Bayesian Networks

در رویکرد مبتنی بر منطق، هر عمل به صورت یک مدل دانش در نظر گرفته می‌شود که با فرمالزیم‌های منطقی مختلفی تعیین می‌گردد. در این رویکردها اولین گام کسب دانش است که عبارت است از استخراج دانش از منابع مختلف مانند کتابچه‌های راهنما. گام دوم عبارت است از استفاده از تکنیک‌های مختلف مدل‌سازی دانش و نیز استفاده از ابزارهای لازم برای ایجاد ساختار مدل اعمال. در گام بعدی همه موجودیت‌ها، رویدادها، و وضعیت‌های زمانی و مکانی مربوط به اعمال، و نیز اصول<sup>۱</sup> و قوانین<sup>۲</sup> مربوطه به صورت رسمی<sup>۳</sup> تعیین می‌شوند. همچنین، یک موتور استنتاج منطقی برای استدلال درحوزه مورد نظر توسعه می‌یابد. با انجام این مراحل، شناسایی اعمال با ارسال فرم منطقی داده‌های حسگرها به موتور استنتاج انجام می‌گیرد.

روش‌های مختلفی برای مدل‌سازی و استنتاج منطقی وجود دارند. یکی از روش‌های موجود عبارت است از تبدیل مساله شناسایی اعمال به مساله برنامه‌ریزی<sup>۴</sup> در حوزه هوش مصنوعی [۹۶]. به بیان ساده این مساله بیان می‌کند که با داشتن دنباله‌ای از رویدادهای انجام شده (فعال سازی حسگرها) توسط کاربر، چگونه هدف مورد نظر کاربر را استنتاج کرده و دنباله اعمال را به صورت ساختار یک برنامه<sup>۵</sup> سازماندهی کنیم.

در شاخه دیگری از این دسته روش‌ها، از تئوری منطق توسعه یافته اعمال، مانند حساب رویدادها (EC)<sup>۶</sup> [۹۷] برای شناسایی اعمال استفاده شده است. EC، یک حوزه مورد نظر را در قالب جریان‌ها<sup>۷</sup>،

---

<sup>۱</sup>Axiom

<sup>۲</sup>Rule

<sup>۳</sup>Formal

<sup>۴</sup>Planning

<sup>۵</sup> Plan

<sup>۶</sup> Event Calculus

<sup>۷</sup>Fluents

رویدادها<sup>۱</sup>، و محمول‌ها<sup>۲</sup> پیگر بندی می‌کند. جریان‌ها، خصوصیات در حوزه مورد نظر هستند که می‌توانند در طول زمان تغییر کنند. رویدادها موجب تغییرات می‌شوند. تغییرات یک حوزه در نتیجه رویدادها ایجاد می‌شوند. محمول‌ها نیز ارتباط بین رویدادها و جریان‌ها را تعریف می‌کنند. در [۹۸] یک چارچوب کاری برای استنتاج منطقی اعمال بر مبنای EC ارائه گردیده که در آن فعالیت حسگرها به صورت رویدادها و وضعیت اشیاء به عنوان خصوصیات در نظر گرفته شده است.

یکی از نقایص رویکردهای مبتنی بر منطق ناتوانی آنها در نمایش عدم قطعیت<sup>۳</sup> است. هرچند، در کارهای اخیر سعی شده تا منطق فازی نیز به عنوان یک رویکرد استنتاج منطقی برای تشخیص اعمال به کار گرفته شود [۹۹، ۱۰۰]. یکی دیگر از نقاط ضعف این رویکردها عدم قابلیت انعطاف در تطبیق با عادات کاربران مختلف می‌باشد.

### رویکردهای مبتنی بر هستان شناسی

استفاده از هستان شناسی‌ها برای شناسایی اعمال به تازگی توجه بسیاری از محققین را به خود جلب کرده است. هستان‌شناسی‌ها مستقل از یک کاربرد یا الگوریتم خاص تعریف می‌شوند. برای شناسایی اعمال در محیط‌های مجهز به حسگرها، از هستان شناسی‌ها به منظور ایجاد مدل‌های قابل اطمینان از اعمال می‌توان استفاده کرد. چنین مدل‌هایی می‌توانند نام‌های مختلف یک شیء را با عبارتی در هستان‌شناسی که مرتبط با یک عمل خاص است، تطبیق دهند. این ویژگی می‌تواند برای حل مشکل ناکامل بودن مدل‌ها (در برداشتن همه عبارات یک دامنه) و عباراتی که دارای چند روش نمایش هستند، استفاده گردد. در [۹۵] هستان شناسی پیچیده‌ای برای اشیاء بر حسب تشابه عملکردی آنها در WordNet، ایجاد شده که می‌تواند مدل‌های به دست آمده از طریق داده کاوی Web را با اشیاء مشابه

---

<sup>۱</sup>Events

<sup>۲</sup> Predicates

<sup>۳</sup>Uncertainty



کامل نماید. در [۱۰۱]، از هستان شناسی‌ها برای نمایش اشیاء دخیل در اعمال استفاده شده است. با جستجوی ارتباط‌های معنایی بین اشیاء، این رهیافت می‌تواند حتی با وجود خصیصه‌های مختلف اشیاء (تغییر آنها و نیز نمایش‌های مختلف عبارات مربوط به آنها)، اعمال را به طور خودکار شناسایی کند. در اکثر کارهایی که تا کنون ارائه شده‌اند، از هستان‌شناسی‌های موجود به عنوان توصیف‌گرهایی برای تعریف اعمال استفاده شده و سپس، شناسایی اعمال بر مبنای استنتاج آماری و یا احتمالاتی صورت گرفته است [۱۰۱، ۹۵]. در [۱۰۱، ۹۵]، از هستان‌شناسی‌های موجود یا به عنوان نگاشتی برای تطبیق عبارات مختلف مربوط به یک شیء استفاده شده و یا از آنها برای گروه‌بندی عبارات و مفاهیم مشترک به کار گرفته شده است.

هستان‌شناسی‌هایی که به طور صریح مفاهیم اعمال را بیان می‌کنند، به تازگی ظهور یافته‌اند و برای شناسایی اعمال استفاده شده‌اند. در [۱۰۲] و [۱۰۳]، رویکردهایی برای شناسایی اعمال مبتنی بر هستان‌شناسی‌ها معرفی و توسعه داده شده‌اند. در این کارها، هستان‌شناسی‌هایی برای اطلاعات متنی<sup>۱</sup> و اعمال، به منظور مدل‌سازی در حوزه‌های مختلف ایجاد شده‌اند. در این کارها فعالیت حسگرها در یک بازه زمانی به اطلاعات متنی در هستان‌شناسی‌ها نگاشت شده و با هم ترکیب می‌شوند تا برای هر نقطه زمانی یک متن ایجاد نمایند. سپس از یک روش استنتاج برای رده‌بندی متن‌ها در هر نقطه زمانی، و تشخیص عمل در حال انجام استفاده شده است.


یکی از مسائلی که در شناسایی اعمال می‌بایست به آن توجه نمود بحث عدم قطعیت در شناسایی اعمال است. یک مشکل روش‌های مبتنی بر هستان‌شناسی، ضعف آنها در مدیریت عدم قطعیت می‌باشد [۱۰۲]. در بین روش‌هایی که از هستان‌شناسی‌ها برای تعریف مدل اعمال استفاده می‌کنند کارهای [۱۰۴]، [۱۰۵]، [۱۰۶]، و [۱۰۷] نمونه‌هایی هستند که سعی در مدیریت عدم قطعیت دارند.

---

<sup>۱</sup>Contextual

در این کارها از نظریه دمپستر-شافر<sup>۱</sup> (DST) برای مدیریت عدم قطعیت استفاده شده است.

در [۱۰۴] و [۱۰۵] فرض شده که عدم قطعیت به علت خطاهای سخت افزاری در حسگرها و تغییرات الگوی رفتاری افراد به وجود می‌آید. در [۱۰۴] توده باور<sup>۲</sup> حسگرها به صورت آماری محاسبه می‌شود و سپس به منظور نمایش عدم قطعیت، و بسته به نوع حسگر، با نرخ خاصی تقلیل داده می‌شوند. داده‌های حسگرها به هستان شناسی‌های تعریف شده برای اعمال، نگاشت داده می‌شوند. این هستان شناسی‌ها با ساختار شبکه‌ای تک لایه تعریف می‌شوند. شکل ۲-۶ هستان شناسی مربوط به عمل "استفاده از سرویس بهداشتی" را که در این کار معرفی شده نشان می‌دهد. سپس توده‌های باور تقلیل داده شده متعلق به حسگرهایی که از نظر زمانی با هم مرتبط هستند، با استفاده از نظریه DS با هم ترکیب می‌شوند. بر حسب نتیجه به دست آمده در مورد عمل انجام شده تصمیمی اتخاذ می‌گردد. با توجه به اینکه در فصل آتی از این رویکرد به منظور مقایسه استفاده می‌کنیم، آن را BDS<sup>۳</sup> می‌نامیم.



شکل ۲-۶. هستان شناسی عمل "استفاده از سرویس بهداشتی" در BDS [104].

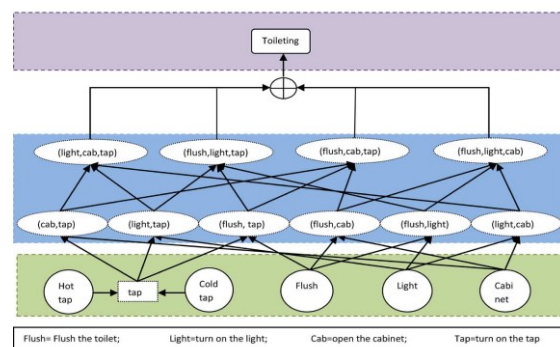
در [۱۰۵] ساختارهای شبکه‌ای سلسله‌مراتبی سه سطحی با توجه به هستان شناسی اعمال، برای هر عمل ایجاد می‌گردد که مدل آنرا نشان می‌دهد. در ساختار سه سطحی، لایه‌ها عبارتند از لایه

<sup>۱</sup> Dempster-Shafer theory

<sup>۲</sup> Belief mass

<sup>۳</sup> Basic Dempster-Shafer theory

اشیاء، لایه متن، و لایه عمل. عناصر هر لایه به عناصر لایه بعدی خود با توجه به تعریف هستان شناسی عمل مربوطه متصل شده‌اند. هر اتصال دارای وزنی است که عدم قطعیت در ارتباط بین عناصر را نشان می‌دهد. حسگرها به ساختار سلسله مراتبی نگاشت می‌شوند و توده‌های باور آنها از لایه اول به لایه آخر منتشر می‌گردد و با استفاده از تئوری DS با هم ترکیب می‌گردند. بر حسب نتیجه این ترکیب، تصمیمی در خصوص عمل انجام شده اتخاذ می‌گردد. در این کار دو نوع از این معماری با لایه متن یک و دو سطحی پیاده سازی و با هم مقایسه گردیده. با توجه به استفاده از این دو رویکرد در ارزیابی‌ها، رویکردهای مبتنی بر لایه متن یک سطحی و دوسطحی را به ترتیب <sup>1</sup> 2LDS و <sup>2</sup> 3LDS می‌نامیم. شکل ... هستان شناسی های مربوط به 3LDS برای عمل استفاده از سرویس بهداشتی را نشان می‌دهد. در [۱۰۷]، رویکردهای قبلی با معرفی یک روش جدید برای تعیین وزن اتصالات در ساختار لایه‌ای بهبود داده شده است.



شکل ۲-۷. هستان شناسی عمل "استفاده از سرویس بهداشتی" در 3LDS [۱۰۵].

در [۱۰۶]، مدل اعمال با استفاده از یک گراف جهت دار بدون دور (DAG)<sup>۳</sup> نمایش داده شده است. این گراف اطلاعات زمانی را نیز در بر می‌گیرد. در این ساختار، گره‌های DAG با مشخصه‌های حسگرها، اطلاعات متنی و اعمال برچسب خورده‌اند. گره‌ها به صورت لایه‌ای به هم متصل شده‌اند و هر

<sup>۱</sup> 2 Layered Dempster-Shafer based

<sup>۲</sup> 3 Layered Dempster-Shafer based

<sup>۳</sup>Directed Acyclic Graph

اتصال دارای یک ضریب است که عدم قطعیت آن ارتباط را نمایش می‌دهد. مدت زمان انجام هر عمل، و زمان قطعی انجام هر عمل نیز در DAG جای داده شده‌اند. برای استنتاج یک عمل، شواهد (داده‌های حسگرها) در مدت زمان اجرای اعمال جمع آوری شده و با استفاده از تئوری DS، توده‌های باور آنها با هم ترکیب می‌گردند.

همانطور که دیده می‌شود روش‌های فوق برای هر عمل ساختار ثابتی را با استفاده از هستان شناسی‌های مربوطه استخراج کرده و داده‌های حسگرها را به آن نگاشت می‌کنند. مشکل دیگری که در این وضعیت پیش می‌آید، تضمین عمومیت ساختارهای تعریف شده برای اعمال در بین کاربران مختلف می‌باشد.

## ۳-۲-۳-۲ روش‌های هیبریدی<sup>۱</sup>

در این روش‌ها از خصوصیات روش‌های مبتنی بر دانش و مبتنی بر داده به صورت توأم بهره گرفته می‌شود. به طور کلی در این رویکردها ابتدا یک ساختار مبتنی بر دانش پیشین به عنوان مدل اولیه اعمال تعریف می‌گردد. سپس، این مدل کلی با توجه به نحوه انجام اعمال، و با استفاده از الگوریتم‌های یادگیری ماشین مبتنی بر داده، منطبق با عادات رفتاری کاربر تغییر داده می‌شود.

از جمله رویکردهای ترکیبی، می‌توان به [۱۰۸] و [۱۰۹] اشاره کرد. در [۱۰۸] یک رویکرد مبتنی بر چرخه تکرار ارائه شده که در آن مدل‌های اولیه اعمال<sup>۲</sup> با استفاده از تکنیک‌های مهندسی هستان‌شناسی ایجاد می‌شوند. چرخه تکرار از سه فاز تشکیل شده است. در اولین فاز، مدل‌های اولیه اعمال با روش‌های مهندسی هستان‌شناسی (منطق توصیفی) ایجاد می‌شوند. در فاز دوم، با داشتن داده‌های حسگرها، از مدل‌های فاز اول برای رده بندی داده‌های حسگرها استفاده می‌گردد. اگر مدل‌سازی

---

<sup>۱</sup> Hybrid

<sup>۲</sup> Seed

اولیه به درستی (منطبق با عادات و محیط کاربر) انجام شده باشد، عمل کاربر به درستی تشخیص داده می‌شود. در صورت عدم انطباق داده‌های حسگرها با مدل‌های اولیه، خروجی رده‌بندی اطلاعات مفیدی را برای فاز سوم، یعنی یادگیری مبتنی بر داده فراهم می‌آورد. در فاز سوم، مدل‌های مربوط به اعمال جدید (متفاوت) کاربر با استفاده از روش‌های یادگیری مبتنی بر داده آموزش داده می‌شوند و از آنها برای به روز رسانی مدل‌های قبلی (فاز ۱) استفاده می‌شود. در فاز سوم، از شباهت مفهومی بین دنباله داده‌های جدید برای خوشه بندی آنها استفاده شده و نهایتاً هر خوشه مربوط به یک عمل جدید خواهد بود. در این چرخه سه مرحله‌ای، فاز اول با مداخله انسان و فازهای دوم و سوم به صورت خودکار صورت می‌گیرند. به طور مشابه ایده اصلی در [۱۰۹] نیز ایجاد مدل‌های اولیه ناکامل اعمال با استفاده از دانش پیشین، و سپس یادگیری دیگر اجزای مدل با استفاده از الگوریتم‌های مبتنی بر داده می‌باشد.

هرچند در روش‌های ترکیبی مشکل ایستایی مدل اعمال کم رنگ شده اما هنوز باید مدل‌های اولیه با دخالت انسان ایجاد گردند. ضمن اینکه استنتاج در این روش‌ها معمولاً مبتنی بر مدل‌های تکامل یافته است که در آنها مدیریت عدم قطعیت یک چالش محسوب می‌گردد.

## ۴-۲ جمع بندی

در این فصل به مرور کارهای مرتبط با شناسایی اعمال در محیط‌های هوشمند پرداختیم. این رویکردها می‌توانند مبتنی بر تصویر و یا مبتنی بر حسگرها باشند. رویکردهای مبتنی بر تصویر به دلیل بهره‌گیری از داده‌های جامع در خصوص وضعیت کاربر و محیط، شناسایی اعمال را با دقت و صحت بالاتری نسبت به رویکردهای مبتنی بر حسگر می‌توانند انجام دهند؛ اما از سوی دیگر با نقض حریم شخصی افراد، برای آنان ایجاد تزاخم می‌کنند. این مساله موجب عدم مقبولیت رویکردهای مبتنی بر تصویر در بسیاری از کاربردها مانند خانه‌های هوشمند می‌گردد. رویکردهای مبتنی بر حسگرها نیز خود

می‌توانند مبتنی بر حسگرهای پوشیدنی و یا مبتنی بر حسگرهای محیطی (سنجش متراکم) باشند. از آنجا که حسگرهای پوشیدنی باید مدام بر روی بدن کاربر قرار داشته باشند، به لحاظ مصرف انرژی و قابلیت حمل می‌توانند محدودیت‌هایی را ایجاد کنند. همچنین، در شرایطی که رفت و آمد در یک محیط به دفعات انجام می‌شود، و یا کاربر توانایی و یا تمایلی برای پوشیدن این حسگرها ندارد، استفاده از این حسگرها در عمل غیر ممکن خواهد بود. با توجه به این محدودیت‌ها، تمرکز این رساله بر رویکردهای مبتنی بر سنجش متراکم قرار گرفته است. بسته به روش مورد استفاده برای ایجاد مدل اعمال کاربران، هر یک از رویکردهای شناسایی اعمال می‌توانند مبتنی بر داده، مبتنی بر دانش، و یا هیبریدی باشند. در این فصل به تفصیل به بیان این رویکردها برای روش‌های مبتنی بر سنجش متراکم پرداختیم. جدول ۱-۲ برخی ویژگی‌های روش‌های بازشناسی اعمال که در حال حاضر مرسوم و معمول هستند را به صورت خلاصه بیان می‌کند.

جدول ۱-۲. ویژگی‌های معمول در رویکردهای موجود.

| نیاز به مدل‌های از پیش تعریف شده برای اعمال | ایجاد تراکم | پشتیبانی از عدم قطعیت             | محیط چند کاربره | محیط تک کاربره | رویکرد                    |
|---|-------------|-----------------------------------|-----------------|----------------|---------------------------|
| -----                                       | √           | -----                             | √               | √              | مبتنی بر تصویر            |
| ×   | √           | -----                             | √               | √              | مبتنی بر حسگرهای پوشیدنی  |
| ×   | ×           | پشتیبانی از ماهیت احتمالاتی اعمال | √               | √              | سنجش متراکم-مبتنی بر داده |
| √   | ×           | ضعیف                              | √               | √              | سنجش متراکم-مبتنی بر دانش |
| √   | ×           | ضعیف                              | ×               | √              | سنجش متراکم-هیبریدی       |

روش‌های مبتنی بر داده دارای این مزیت هستند که می‌توانند عدم قطعیت نوع اول را، که ناشی از احتمالاتی بودن ماهیت یک فرآیند است، مدل کنند؛ هرچند، با استفاده از این روش‌ها مدیریت عدم قطعیت نوع دوم که ناشی از عدم آگاهی و شهود کافی در خصوص یک فرآیند است، دشوار می‌باشد. همچنین، روش‌های مبتنی بر داده (مانند مدل‌های گرافیکی احتمالاتی) قابلیت مدل سازی زمانی را نیز دارا می‌باشند. به علاوه، از آنجا که این روش‌ها با استفاده از داده‌های کاربران آموزش داده می‌شوند، از

ابتدا منطبق با عادات رفتاری کاربران می‌باشند و نیازی به دانش پیشین در خصوص نحوه انجام اعمال ندارند. از جمله معایب این روش‌ها می‌توان به برچسب گذاری داده‌ها و لزوم وجود داده کافی برای آموزش اشاره کرد. روش‌های مبتنی بر دانش عموماً مبتنی بر دانش پیشین در مورد اعمال کاربران هستند. در این روش‌ها اعمال کاربران با ساختارهای ایستای از پیش تعریف شده (مانند هستان‌شناسی‌ها) مدل می‌شوند. لذا به دلیل دانش ناکافی در خصوص نحوه انجام اعمال، این روش‌ها ممکن است عمومیت لازم را نداشته باشند. از دیگر معایب این روش‌ها می‌توان به ضعف آنها در مدیریت عدم قطعیت اشاره کرد. از سوی دیگر، این روش‌ها دارای این مزیت هستند که اولاً ساختار مدل اعمال کاربر کاملاً واضح و قابل فهم است و ثانیاً نیازی به داده برای آموزش ندارند. در روش‌های هیبریدی از خصوصیات روش‌های مبتنی بر داده و مبتنی بر دانش به صورت توأم بهره گرفته می‌شود. به طور کلی در این روش‌ها ابتدا یک مدل اولیه مبتنی بر دانش پیشین ایجاد شده، و سپس با استفاده از الگوریتم‌های مبتنی بر داده با اعمال کاربران خاص تطبیق می‌یابد. در این روش‌ها، مشابه روش‌های مبتنی بر دانش، استنتاج بر مبنای مدل تطبیق یافته انجام می‌گیرد؛ لذا مدیریت عدم قطعیت در تصمیم‌گیری چالش برانگیز می‌باشد.

تا کنون کارهای زیادی در خصوص شناسایی اعمال مبتنی بر سنجش متراکم انجام شده، اما اغلب آنها، (شامل مواردی که مورد بحث قرار گرفتند) محیط را تک کاربره در نظر گرفته‌اند. همچنین، بسیاری از این کارها مدیریت عدم قطعیت نوع دوم که ناشی از وجود ناآگاهی در خصوص داده‌های حسگرها است را لحاظ نکرده‌اند. لذا در این رساله به مطالعه این دو موضوع خواهیم پرداخت.





فصل ۳. راهکار پیشنهادی اول برای شناسایی  
اعمال، مبتنی بر نظریه دمپستر-شافر

### ۳-۱ مقدمه

در حالت کلی، در یک محیط هوشمند، اعمال مختلف به انحاء متفاوتی می‌توانند صورت گیرند. در خانه‌های هوشمند، تصمیمات بر مبنای اعمال انجام شده کابرن اتخاذ می‌گردد. لذا شناسایی اعمال از اهمیت ویژه‌ای برخوردار می‌باشد. همانطور که در فصل ابتدایی بیان شد، هدف ما شناسایی اعمال در شرایط پیچیده خواهد بود. یکی از ویژگی‌های چنین شرایطی وجود عدم قطعیت (ناآگاهی) در داده‌های حسگرها می‌باشد. در این فصل به بیان راهکاری با در نظر گرفتن عدم قطعیت در داده‌های حسگرها برای شناسایی اعمال می‌پردازیم.

منشا عدم قطعیت در داده‌های حسگرها می‌تواند دلایل مختلفی از جمله خطاهای سخت‌افزاری در فعال‌سازی حسگرها باشد. در چنین شرایطی، از مقادیر صحیح داده‌ها مطمئن نخواهیم بود (عدم قطعیت افزایش می‌یابد). نظریه دمپستر-شافر ( $DS^1$ ) یکی از روش‌هایی است که در کاهش تاثیر عدم قطعیت در شناسایی اعمال می‌تواند موثر واقع شود [۱۱۰]. در روش‌های مبتنی بر دانش قبلی مانند [۱۰۴, ۱۰۵, ۱۰۷] از این تئوری در روش‌های مبتنی بر دانش برای شناسایی اعمال استفاده شده است. اما در حالت کلی، همانطور که قبلاً نیز بیان شد، روش‌های مبتنی بر دانش قابل استفاده برای افراد مختلف در محیط‌های جدید و با خصوصیات فردی جدید نمی‌باشد. زیرا این روش‌ها بر پایه ساختارهای ثابتی هستند که به صورت دستی، و بر مبنای هستان‌شناسی یک عمل در یک محیط خاص تعریف شده‌اند و انعطاف‌پذیری اندکی در سناریوهای جدید دارند. در روش‌های مبتنی بر داده (مانند انواع CRF، DBN، HMM، و غیره) نیز، عدم قطعیت با مقادیر دقیق احتمالاتی (مثلاً احتمال یک عمل به شرط فعال شدن حسگرها) بازنمایی می‌شود. در حالیکه عدم قطعیت می‌تواند به معنای عدم آگاهی در خصوص صحت داده‌ها باشد. در این فصل، ابتدا قالب یک رویکرد کلی برای کاهش تاثیر عدم قطعیت را ارائه خواهیم

---

<sup>1</sup> Dempster-Shafer

نمود. سپس، نمونه‌ای از این رویکرد را با استفاده از نظریه DS پیاده‌سازی خواهیم نمود که در آن مدل‌های اعمال به صورت خودکار استخراج شده، و سپس از نظریه DS برای تجمیع<sup>۱</sup> داده‌های حسگرها در شناسایی اعمال استفاده می‌شود. روش پیشنهادی منطبق با ساختار لایه دوم معماری پیشنهادی فصل اول می‌باشد.

## ۲-۳ قالب کلی رویکرد پیشنهادی برای شناسایی اعمال

عدم قطعیت به معنی میزان ناآگاهی در مورد صحت یک قلم داده می‌باشد. این کمیت با مقیاس‌های از پیش تعریف شده توسط طراح سیستم اندازه‌گیری می‌شود. مثلاً در مورد یک حسگر، طراح ممکن است از نرخ خطایی که در فعال یا غیر فعال شدن یک حسگر رخ می‌دهد مطلع باشد و آن را به عنوان میزان عدم قطعیت در داده‌های آن حسگر در نظر بگیرد [۱۰۵]. در مورد یک رویداد، اگر احتمال رخداد آن  $b$ ، و احتمال عدم رخداد آن  $d$  باشد، آنگاه در شرایط وجود عدم قطعیت خواهیم داشت  $b + d < 1$ . در نظریه احتمال کلاسیک، داده‌ها به صورت قطعی در نظر گرفته می‌شوند در حالی که همیشه اینطور نیست. در بحث شناسایی اعمال، داده‌های حسگرها توأم با خطا خواهند بود. مثلاً این خطا می‌تواند سخت افزاری، و یا در اثر فعال سازی ناصحیح یک حسگر توسط کاربر ایجاد شده باشد. در چنین حالتی مشخص نخواهد بود که داده حسگر در اثر انجام عمل مورد بررسی ایجاد شده یا خیر. لذا با عدم قطعیت مواجه خواهیم شد. در این بخش، قالب کلی اولین رویکرد پیشنهادی خود را برای شناسایی اعمال در یک محیط تک کاربره ارائه می‌نمائیم. این رویکرد مطابق با لایه دوم در معماری ارائه شده در فصل ۱ (شکل ۲-۱) می‌باشد.

در شکل ۳-۱ قالب کلی رویکرد پیشنهادی برای شناسایی اعمال کاربران با در نظر گرفتن عدم قطعیت داده‌ها نشان داده شده است. در این ساختار، شناسه هر حسگر تحریک شده به عنوان داده آن

---

<sup>۱</sup>Fusion


حسگر در نظر گرفته می‌شود. در مرحله آموزش، قبل از اینکه مدل‌های اعمال از داده‌های آموزشی استخراج شوند، داده‌های با عدم قطعیت بالا حذف می‌گردند. سپس، مدل‌های اعمال، با استفاده از داده‌های باقی‌مانده محاسبه می‌شوند. اما از آنجا که در ابتدا داده‌ها غیر قطعی فرض شده‌اند، هنوز مقداری عدم قطعیت در داده‌های باقی‌مانده وجود خواهد داشت. برای کاستن تاثیر این عدم قطعیت، از تجمیع داده‌ها در مرحله استنتاج (آزمون) استفاده خواهیم کرد.

در مرحله آزمون، ابتدا بخش‌های داده‌ای مربوط به اعمال با یک روش بخش‌بندی بدون ناظر از جریان داده‌های حسگرها استخراج می‌گردند. برای هر زیردنباله باید یک عمل استنتاج شود. از آنجا که هنوز مقداری عدم قطعیت در داده‌های باقی‌مانده وجود دارد، از تجمیع داده‌ها برای تصمیم‌گیری در مورد عمل انجام شده استفاده می‌شود. به این ترتیب که در فرآیند استنتاج، رده‌بندی چندین بار، و هر بار بر حسب ویژگی‌های متفاوتی که از زیردنباله استخراج می‌شود، انجام می‌گیرد. خروجی رده بند به ازای هر ویژگی، تعلق دنباله داده‌ها به هر یک از کلاس‌ها (اعمال) را با یک مقدار احتمالاتی بازنمایی می‌کند. برای تصمیم‌گیری نهایی در خصوص عمل انجام شده، خروجی‌های رده‌بندها باهم تجمیع می‌گردند. در بخش بعدی این رویکرد کلی با به کارگیری نظریه DS پیاده‌سازی شده است.

### ۳-۳ پیاده سازی رویکرد پیشنهادی با استفاده از DST

در این بخش، یک پیاده‌سازی از رویکرد پیشنهادی بخش قبلی (شکل ۳-۱)، با به کارگیری نظریه دمپستر-شافر ارائه می‌گردد. این رویکرد برای استفاده در محیط‌های تک کاربره به منظور تشخیص اعمال ترتیبی ارائه گردیده است. ساختار مربوطه در شکل ۳-۲ نمایش داده شده است. فرض بر این است که مقادیر حسگرها گسسته هستند (حسگرهای دودویی) و در صورت استفاده از حسگرهای با مقادیر پیوسته، آنها را به فرم گسسته تبدیل خواهیم نمود. مثلاً اگر از حسگرهای دما استفاده می‌کنیم،

برای دمای زیر ۲۰ درجه سانتیگراد مقدار "Cold"، برای دمای بالاتر مقدار "Hot" را می‌توان در نظر گرفت.



شکل ۳-۱. قالب کلی اولین رویکرد پیشنهادی برای شناسایی اعمال.

مراحل آموزش و آزمون در این روش به شرح ذیل می‌باشند. در شکل ۳-۲،  $e_i$  شاهد فعال شده  $i$  ام،  $OW_a$  مجموعه شاهد‌های عمل  $a$ ، و  $R(a)$  مقدار نهایی باور در خصوص عمل  $a$  پس از ترکیب

عقاید شاهد‌های فعال شده، یعنی  $O_{e_i}$  ها، را نشان می‌دهد.

**مرحله آموزش:** در این مرحله، ابتدا شاهد‌هایی را از دنباله داده‌های مربوط به هر عمل به طور مجزا، استخراج می‌کنیم. این شاهد‌ها در واقع چندتایی‌های مرتبی هستند که از دنباله داده‌های حسگرهای تحریک شده برای هر عمل استخراج می‌گردند. سپس، میزانی از باور، عدم باور، و عدم قطعیت برای هر یک از این شاهد‌ها در مورد هر عمل محاسبه می‌گردد و شاهد‌های با عدم قطعیت بالا حذف می‌گردند. سه تایی باور، عدم باور، و عدم قطعیت یک عقیده<sup>۱</sup> را نشان می‌دهد. در نهایت، برای هر عمل، مجموعه شاهد‌های با عدم قطعیت پایین و عقاید آنها مدل آن عمل را ایجاد می‌کنند. برای عملی مثل  $a$ ، مجموعه شاهد‌های آن را با  $OW_a$  نشان می‌دهیم.

**مرحله آزمون:** در مرحله آزمون، وقتی جریانی از داده‌های حسگرها را داریم یک روش بخش‌بندی بدون نظارت برای استخراج زیردنباله‌ای از داده‌های مربوط به یک عمل، که هنوز ناشناخته است، مورد استفاده قرار می‌گیرد. بدین منظور، از خوشه‌بندی داده‌های حسگرها بر حسب زمان رخداد آنها بهره گرفته‌ایم. سپس، برای هر زیردنباله از داده‌ها، شاهد‌های فعال شده را استخراج، و عقاید این شاهد‌ها در مورد رخداد هر یک از اعمال را با استفاده از عملگر ترکیب دمپستر با هم ترکیب می‌کنیم. عملی که بیشترین میزان باور برای آن محاسبه می‌شود، به عنوان عمل مربوطه استنتاج می‌گردد.


در این رویکرد، برای قطعه‌بندی جریان داده حسگرها از این واقعیت استفاده شده که در انجام ترتیبی اعمال، داده‌های ایجاد شده مربوط به یک عمل باید از نظر زمانی به هم نزدیک باشند. بنابراین، اگر داده‌ها را بر حسب زمان رخداد آنها خوشه‌بندی کنیم، احتمال اینکه داده‌های هر خوشه مربوط به یک عمل باشند بالا خواهد بود. پس از خوشه‌بندی، هر خوشه به عنوان یک قطعه در نظر گرفته شده و

---

<sup>۱</sup> Opinion

با یک عمل برچسب زده می‌شود.

در تطبیق با لایه دوم معماری پیشنهادی در فصل اول (شکل ۱-۲)، خوشه بندی معادل قطعه بندی داده‌های حسگرها می‌باشد. همچنین، محاسبه شاهدها و عقاید آنها در خصوص اعمال، معادل با استخراج ویژگی از دنباله داده‌های قطعه‌بندی شده در معماری پیشنهادی است. در ادامه، ابتدا به بیان نظریه دمپستر-شافر می‌پردازیم و سپس هریک از مراحل آموزش و آزمون، با جزئیات مورد بحث قرار خواهند گرفت.



شکل ۳-۲. پیاده‌سازی رویکرد پیشنهادی با به کار گیری نظریه DS.

### ۳-۳-۱ نظریه DS و محاسبه BPA

نظریه  $DS^1$  یک نظریه ریاضی در خصوص شهود<sup>۲</sup> می‌باشد. با استفاده از این نظریه می‌توان شهود مختلف که از منابع متعددی در خصوص یک رویداد به دست آمده را با هم ترکیب و به میزانی از باور<sup>۳</sup>، که نشان دهنده اجماع همه شواهد در خصوص رویداد مربوطه است، دست یافت.

در نظریه DS، مجموعه همه مقادیر ممکن برای یک رویداد<sup>۴</sup> را با  $\Theta$  نمایش می‌دهیم. در خصوص رویدادهای دودویی<sup>۵</sup>،  $\Theta = \{a, \sim a\}$  می‌باشد که در آن  $a$  نشان دهنده رخداد  $a$  و  $\sim a$  نشان دهنده عدم رخداد  $a$  می‌باشد. برای یک شاهد مثل  $A$ ، تخصیص احتمال پایه (BPA) با تابع

$$m_A: 2^\Theta \rightarrow [0,1] \text{ نشان داده می‌شود، طوری‌که } m(\emptyset) = 0 \text{ و } \sum_{A \subseteq \Theta} m(A) = 1$$

برای رویدادهای دودویی، میزان شواهد  $A$  در خصوص رخداد مجموعه‌های  $\{a\}$ ،  $\{\sim a\}$  و  $\{a, \sim a\}$  را به ترتیب، باور ( $b_A$ )، ناباوری ( $d_A$ )، و عدم قطعیت ( $u_A$ ) در خصوص رویداد  $a$  می‌نامیم و مقادیر آنها را با محدودیت  $\sum_{A \subseteq \{a, \sim a\}} m(A) = 1$ ، به صورت رابطه (۳-۱) بیان می‌کنیم.

$$\begin{cases} b_A = m_A(\{a\}) \\ d_A = m_A(\{\sim a\}) \\ u_A = m_A(\{a, \sim a\}) \end{cases} \quad (۳-۱)$$

ملاحظه می‌شود که در رابطه (۳-۱)، عدم قطعیت ( $u_A$ ) به معنی میزان شواهد موجود برای رخداد  $a$  و یا  $\sim a$  می‌باشد و یا به عبارتی دیگر، ناآگاهی شاهد  $A$  در خصوص عمل  $a$  را بازنمایی می‌کند. برای محاسبه  $b_A$ ،  $d_A$  و  $u_A$  می‌توان از تابع توزیع بتا به شرح ذیل استفاده نمود [۱۱۱]. اگر تعداد مشاهدات

<sup>۱</sup> Dempster Shafer

<sup>۲</sup> Evidence

<sup>۳</sup> Belief

<sup>۴</sup> Frame of Discernment

<sup>۵</sup> Binary

<sup>۶</sup> Basic Probability Assignment



مثبت رویداد  $a$  را  $r$ ، و تعداد مشاهدات منفی  $a$ ، یعنی  $a \sim s$  در نظر بگیریم، آنگاه توزیع احتمال پسین متغیر  $p$ ، که  $p$  نیز احتمال رخداد  $a$  می باشد، را می توان با حالت خاصی از توزیع بتا با رابطه (۲-۳) به دست آورد. در رابطه (۲-۳)،  $\Gamma(\cdot)$  تابع گاما می باشد. امید ریاضی  $p$  با رابطه (۳-۳) نمایش داده شده است.

$$f(p|r, s) = \frac{\Gamma(r + s + 2)}{\Gamma(r + 1)\Gamma(s + 1)} p^r (1 - p)^s. \quad (2-3)$$

$$E(p) = \frac{r+1}{r+s+2}. \quad (3-3)$$

از سوی دیگر، با داشتن  $b_A, d_A$  و  $u_A$  امید ریاضی  $p$  را می توان با رابطه  $E_a = b_A + \frac{1}{2}u_A$  نیز محاسبه نمود [۱۱۱]. لذا با حل دستگاه معادله (۴-۳) می توان مقادیر باور، عدم باور، و عدم قطعیت شاهد  $A$  در خصوص رویداد  $a$  را محاسبه نمود. با حل این دستگاه رابطه (۵-۳) به دست خواهد آمد.

$$\begin{cases} E(p) = E_a \\ b_A + d_A + u_A = 1 \end{cases} \Rightarrow \begin{cases} b + \frac{1}{2}u = \frac{r+1}{r+s+2} \\ b + d + u = 1 \end{cases} \quad (4-3)$$

$$\begin{cases} b = \frac{r}{r+s+2} \\ d = \frac{s}{r+s+2} \\ u = \frac{2}{r+s+2} \end{cases} \quad (5-3)$$

در نظریه DS، با داشتن BPA دو شاهد  $A$  و  $B$  در مورد یک رویداد مثل  $a$ ، می توان از رابطه (۶-۳) برای تجمیع BPA آنها استفاده نمود. در این رابطه  $A_i \subseteq \Theta$  می باشد. رابطه (۶-۳) را می توان بسط داده و برای ترکیب BPA بیش از دو شاهد در خصوص یک رویداد نیز به کار گرفت.

$$m_A \oplus m_B(a) = \begin{cases} \frac{1}{1 - \sum_{A_i \cap A_j = \emptyset}^{i,j} m_1(A_i)m_2(A_j)} \sum_{A_i \cap A_j = a}^{i,j} m_1(A_i)m_2(A_j) & \text{if } A \neq \emptyset \\ 0 & \text{if } A = \emptyset \end{cases}, \quad (6-3)$$

### ۲-۳-۳ به دست آوردن شاهدها برای یک عمل


به هنگام انجام یک عمل واحد در محیط، تقریباً ترتیب خاصی از داده‌های حسگرها تحریک خواهند شد. لذا روئیت یک ترتیب خاص از داده‌های حسگرها می‌تواند نشان دهنده یک یا چند عمل خاص باشد. بنابر این یک چندتایی مرتب از داده‌های حسگرها (یعنی شناسه حسگرهای تحریک شده) را می‌توان به عنوان شاهدهی برای یک یا چند عمل در نظر گرفت. لذا اگر مجموعه شاهدها را  $E$  بنامیم، آن را به صورت مجموعه‌ای از چندتایی‌ها، با رابطه (۷-۳) بیان می‌کنیم:

$$E = \{ \langle s_1, s_2, \dots, s_n \rangle \mid n = 1, 2, \dots, d, s_i \in S \}, \quad (7-3)$$

که در آن  $S$  مجموعه همه داده‌های حسگرها و  $d$  تعداد گروه‌های چندتایی‌ها را نشان می‌دهد. مشاهده مثبت یک شاهد (یعنی یک چندتایی مرتب از داده‌های حسگرها)، در مورد یک عمل زمانی اتفاق می‌افتد که عمل انجام شده منجر به تولید داده‌های چندتایی مربوط به شاهد با همان ترتیب گردد. در چنین حالتی، یک مشاهده مثبت برای آن شاهد در خصوص عمل انجام شده ثبت می‌گردد. و در غیر این صورت، یک مشاهده منفی برای او ثبت خواهد شد. با استخراج این رویدادهای مثبت و منفی از مجموعه‌های آموزشی، می‌توان مقادیر باور، ناباوری، و عدم قطعیت یک شاهد در خصوص رخداد عملی مثل  $a$  را با رابطه (۵-۳) محاسبه نمود.

### ۳-۳-۳ فضای عقاید و تشخیص شاهد‌های مربوط به یک عمل

عقیده<sup>۱</sup> شاهدی مثل  $A$  در مورد عملی مثل  $a$  را با سه تایی مرتب  $(b_A(a), d_A(a), u_A(a))$  نشان می‌دهیم. با توجه به اینکه  $b_A(a) + d_A(a) + u_A(a) = 1$ ، لذا می‌توان فضای مقادیر همه عقاید برای هر عمل را با یک مثلث متساوی‌الاضلاع نمایش داد. این مثلث در شکل ۳-۳ نمایش داده شده است. در این مثلث، میان‌ها محورهای مربوط به عدم قطعیت ( $u$ )، باور ( $b$ )، و ناباوری ( $d$ ) را نمایش می‌دهند. مختصات نقاط را می‌توان با عمود کردن بر هر محور به دست آورد. این مثلث را مثلث عقاید<sup>۲</sup> یا فضای عقاید<sup>۳</sup> نیز می‌نامیم [۱۱۱].



شکل ۳-۳. فضای عقاید.

هر ناحیه در فضای عقاید مفهوم خاصی می‌تواند داشته باشد. مثلاً قسمت پایین این مثلث عقایدی را شامل می‌شود که عدم قطعیت آنها کم است. در بحث شناسایی اعمال، عقاید شاهد‌های مربوط به هر عمل، با توجه به میزان باور، عدم باور، و عدم قطعیت آنها در مورد آن عمل، در ناحیه خاصی از فضای عقاید قرار می‌گیرند. از آنجا که انتظار داریم عقاید شاهد‌های یک عمل، عدم قطعیت کمتری

<sup>۱</sup>Opinion

<sup>۲</sup>Opinion Triangle

<sup>۳</sup>Opinion space

داشته باشند، و نیز رخداد‌های آن عمل را قبلاً به دفعات مشاهده کرده باشند، لذا ناحیه‌ای در فضای عقاید با چنین ویژگی‌هایی را به عنوان ناحیه پذیرش<sup>۱</sup> برای آن عمل تعریف می‌کنیم. در شکل ۳-۳ یک ناحیه پذیرش هاشور خورده با مقدار عدم باور کمتر از ۰/۵، باور بیشتر از ۰/۵، و عدم قطعیت کمتر از ۰/۱ نشان داده شده است. برای عملی مثل  $a$ ، هر کدام از شاهدها که عقیده آن در مورد  $a$  در ناحیه پذیرش عمل  $a$  قرار گیرد را به مجموعه شاهدهای  $a$  می‌افزاییم و این مجموعه را  $OW_a$  می‌نامیم. به عنوان مدل مربوط به اعمال، مجموعه  $OW = \{OW_a | a \in \text{set of all activities}\}$ ، و نیز عقاید آنها، در مرحله آموزش و با استفاده از داده‌های آموزشی محاسبه می‌شوند. مجموعه  $OW$  شامل مجموعه شاهدها برای هر یک از اعمال می‌باشد.

### ۳-۴ ترکیب عقاید شاهدها و استنتاج

همانطور که قبلاً نیز بیان شد، به هنگام رویت دنباله‌ای از داده‌های حسگرها، ابتدا از یک روش بخش‌بندی بدون نظارت برای به دست آوردن زیردنباله‌ای از داده‌های حسگرها که مرتبط با یک عمل هستند استفاده می‌شود. برای یک زیردنباله، ابتدا شاهدهای فعال شده در آن استخراج می‌گردند. سپس برای هر عمل مثل  $a$ ، عقاید شاهدهای فعال شده متعلق به  $OW_a$  با هم ترکیب می‌شوند. عمل ترکیب با استفاده از عملگر ترکیب دمپستر انجام خواهد گرفت. این روند در شکل ۳-۴ نشان داده شده است. در این شکل،  $O_a^{<s_1, s_2, \dots, s_k>}$  عقیده شاهد  $<s_1, s_2, \dots, s_k>$  در مورد عمل  $a$  را نشان می‌دهد. همچنین،  $\oplus$ ، عملگر ترکیب دمپستر را نشان می‌دهد.


پس از ترکیب عقاید شاهدهای فعال شده برای همه اعمال، عملی که مقدار باور در نتیجه نهایی ترکیب برای آن از همه بیشتر است، برای زیر رشته  $S_i$  استنتاج می‌شود. به بیان دیگر، با رابطه (۳-۸) عمل مربوطه استنتاج می‌گردد. در این رابطه  $IA$  عمل استنتاج شده،  $Acts$  مجموعه همه اعمال، و

---

<sup>۱</sup>Accept Area

$R(a)$  مقدار باور در خصوص رخداد عمل  $a$  پس از ترکیب عقاید همه شاهد‌های فعال شده می‌باشد.

$$IA = \operatorname{argmax}_{a \in \text{Acts}} (R(a)). \quad (۸-۳)$$



شکل ۳-۴. نحوه ترکیب عقاید شاهد‌ها.

### ۵-۳-۳ پیاده سازی و ارزیابی

رویکرد پیشنهادی را با انجام دو آزمایش مورد ارزیابی قرار می‌دهیم. در آزمایش اول، مقایسه‌ای بین روش پیشنهادی و سه رویکرد مبتنی بر دانش، که از هستان‌شناسی‌ها استفاده می‌کنند انجام شده است. این سه رویکرد مربوط به مراجع [۱۰۴] و [۱۰۵] هستند که به اختصار آنها را  $BDS^1$ ،  $2LDS^2$  و  $3LDS^3$  می‌نامیم. در  $BDS$  ([۱۰۴])، هستان‌شناسی اعمال با بهره‌گیری از دانش پیشین تعریف شده و حسگرهای فعال شده به این هستان‌شناسی‌ها نگاهت می‌شوند. سپس توده باور آنها در خصوص هریک از اعمال با یک نرخ ثابت (که مربوط به نرخ خطای آنها می‌باشد) تخفیف می‌یابد. سپس عقاید تخفیف یافته با استفاده از نظریه  $DS$  با هم ترکیب شده و عملی که بیشترین باور در مورد آن وجود دارد استنتاج می‌گردد. در  $2LDS$  و  $3LDS$  ([۱۰۵])، ساختارهای شبکه‌ای به ترتیب دو لایه و سه لایه

<sup>۱</sup> Basic Dempster-Shafer

<sup>۲</sup> 2-layered Dempster-Shafer

<sup>۳</sup> 3-layered Dempster-Shafer

به عنوان هستان‌شناسی اعمال تعریف شده است. حسگرها در لایه اول نگاشت شده و عقاید آنها در خصوص اعمال با نظریه DS با هم ترکیب شده و به بالاترین لایه انتشار می‌یابد. در آزمایش دوم، روش پیشنهادی با رویکردهای NBC، HMM، و HSMM منطبق با مرجع [۶۰] پیاده سازی شده است.

در هر دو آزمایش، رویکرد پیشنهادی را با استخراج دوتایی‌ها از دنباله داده‌های حسگرها اجرا کرده‌ایم. به بیان دیگر، پارامتر  $d$  را برابر با ۲ در نظر گرفتیم. همچنین، از الگوریتم خوشه‌بندی k-means برای بخش بندی جریان داده‌های ورودی بر حسب زمان رخداد فعال یا غیرفعال شدن حسگرها استفاده کرده‌ایم. در این الگوریتم، حداکثر تعداد خوشه‌ها را به صورت شهودی تعیین کرده، و پس از خوشه‌بندی، خوشه‌های تهی را حذف می‌کنیم. در مرحله آغازین مراکز خوشه‌ها را با توزیع یکنواخت انتخاب می‌کنیم. در ارزیابی‌ها از معیارهای دقت<sup>۱</sup>، یادآوری<sup>۲</sup>، صحت<sup>۳</sup> و F-measure استفاده شده است. پس از محاسبه تعداد کل نمونه‌های مثبت صحیح (TP<sup>۴</sup>)، منفی صحیح (TN<sup>۵</sup>)، مثبت ناصحیح (FP<sup>۶</sup>) و منفی ناصحیح (FN<sup>۷</sup>)، این معیارها با معادلات رابطه (۹-۳) محاسبه می‌شوند. لازم به ذکر است که در آزمون اول مقادیر TP، TN، FP، و FN در ارتباط با برچسب یک رویداد حسگر و در آزمون دوم در ارتباط با برچسب عمل مربوط به یک برش زمانی تعیین می‌شوند.

$$Precision = \frac{TP}{TP + FP} \quad (9-3)$$

$$Recall = \frac{TP}{TP + FN}$$

- 
- <sup>۱</sup> Precision
  - <sup>۲</sup> Recall
  - <sup>۳</sup> Accuracy
  - <sup>۴</sup> True positive
  - <sup>۵</sup> True negative
  - <sup>۶</sup> False positive
  - <sup>۷</sup> False negative

$$F - measure = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

### ۱-۵-۳-۳ آزمایش اول

در این آزمایش، از مجموعه داده‌های مرجع [۵۹] استفاده شده است. در این مجموعه داده از حسگرهای دودویی که بر روی لوازم خانگی مختلفی نصب شده‌اند استفاده شده است. با استفاده از این حسگرها، اعمال یک کاربر و داده‌های حسگرهای مربوطه، در مدت ۱۶ روز ثبت شده است. کاربر اعمال روزمره مختلفی، شامل "ترک کردن منزل"، "استفاده از سرویس بهداشتی"، "رفتن به رخت خواب"، و غیره را انجام می‌دهد. با توجه به اینکه رویکردهای BDS، 2LDS، و 3LDS به شناسایی عمل "استفاده از سرویس بهداشتی"<sup>۱</sup> با تعریف هستان‌شناسی آن پرداخته‌اند، به منظور مقایسه، ما نیز روش پیشنهادی را برای شناسایی این عمل مورد آزمایش قرار می‌دهیم. در ارزیابی‌ها مطابق با [۱۰۵]، از استراتژی LOOCV<sup>۲</sup> استفاده شده است. بدین شکل که در هر دور، مشاهدات یک روز کامل به عنوان مجموعه آزمون کنار گذاشته شده و داده‌های روزهای باقی مانده به عنوان مجموعه آموزش به کار برده شده‌اند. جدول ۱-۳ نتایج ارزیابی را برای روش پیشنهادی نشان می‌دهد. نتایج مربوط به رویکردهای BDS، 2LDS و 3LDS در جدول ۱-۳ برگرفته از [۱۰۵] هستند (نتایج مربوط به رویکرد BDS در [۱۰۴] نیز آورده شده است). لازم به ذکر است که در [۱۰۵]، از زیر مجموعه‌ای از داده‌های مجموعه داده مربوط به [۵۹] در پیاده سازی‌ها استفاده شده است (داده‌های ۲۰۹ عمل متفاوت)؛ اما در پیاده سازی رویکرد پیشنهادی، کل مجموعه داده (بیش از ۲۷۰ عمل متفاوت) را در نظر گرفته‌ایم. هرچند حجم داده‌های مورد ارزیابی متفاوت به نظر می‌رسد، اما باید توجه داشت که جامعه آماری بزرگی برای محاسبه

<sup>۱</sup> Use toilet

<sup>۲</sup> Leave one out cross validation

معیارهای ارزیابی در بازشناسی اعمال شخص واحد، و در بازه زمانی یکسان استفاده شده است. بنابراین، مقایسه نتایج به دست آمده با نتایج گزارش شده در [۱۰۵] می‌تواند با اطمینان بالایی بیانگر جایگاه روش پیشنهادی باشد.

در مقایسه با رده‌بند NBC، که نتایج آن در [۵۹] گزارش شده، دقت روش پیشنهادی با ۰.۸۴٪، از NBC با ۰.۶۱٪ بیشتر است. هرچند، یادآوری روش پیشنهادی با ۰.۸۰٪ با اختلاف اندکی کمتر از ۰.۸۳٪ یادآوری NBC (که در [۵۹] گزارش شده) می‌باشد. در مجموع، روش پیشنهادی ما با F-measure ۰.۸۲ عملکرد بهتری نسبت به NBC داشته است.

نتایج روش‌های BDS، 2LDS و 3LDS در جدول ۳-۲ آورده شده است. همانطور که مشاهده می‌شود، روش پیشنهادی در مقایسه با BDS، صحت، و F-measure بالاتری را داشته که نشان از عملکرد بهتر این روش نسبت به BDS دارد. در مقایسه با 3LDS، روش پیشنهادی صحت بالاتری داشته اما دیگر مقیاس‌های ارزیابی آن با اختلاف اندکی، کمتر است. در حالت کلی، در مقایسه با دیگر روش‌های مبتنی بر دانش (یعنی BDS، 2LDS و 3LDS)، می‌توان گفت که روش پیشنهادی عملکرد قابل مقایسه‌ای را از خود نشان داده است. باید توجه داشت که در روش‌های مبتنی بر دانش مورد مقایسه، هستان‌شناسی‌های دقیقی با روش‌های مهندسی دانش تعریف شده اند اما در روش پیشنهادی چنین هستان‌شناسی‌هایی وجود ندارند.

برای بررسی وجود تفاوت معنی دار بین روش پیشنهادی و روش‌های 2LDS و 3LDS، از یک تحلیل آماری بهره می‌گیریم. بدین منظور از آزمون  $t$  زوجی<sup>۱</sup> استفاده می‌کنیم. برای این کار، صحت رده‌بندی هر یک از رده‌بندها را به ازای داده‌های مربوط به هر روز محاسبه می‌کنیم.

---

<sup>۱</sup> Paired t-test



جدول ۳-۱. نتایج روش پیشنهادی برای شناسایی اعمال.

| Date         | TP        | FP        | FN        | TN         | PR         | RC         |
|--------------|-----------|-----------|-----------|------------|------------|------------|
| 27/3/2003    | 1         | 1         | 1         | 12         | 50%        | 50%        |
| 28/3/2003    | 3         | 0         | 1         | 11         | 100%       | 75%        |
| 29/3/2003    | 5         | 1         | 3         | 11         | 83.3%      | 62.5%      |
| 30/3/2003    | 4         | 1         | 2         | 7          | 80%        | 66.67%     |
| 31/3/2003    | 2         | 0         | 1         | 9          | 100%       | 66.67%     |
| 1/4/2003     | 5         | 0         | 0         | 9          | 100%       | 100%       |
| 2/4/2003     | 3         | 0         | 2         | 17         | 100%       | 60%        |
| 3/4/2003     | 2         | 1         | 1         | 12         | 66.67%     | 66.67%     |
| 4/4/2003     | 4         | 1         | 0         | 13         | 80%        | 100%       |
| 5/4/2003     | 5         | 0         | 0         | 8          | 100%       | 100%       |
| 6/4/2003     | 7         | 0         | 2         | 11         | 100%       | 77.78%     |
| 7/4/2003     | 5         | 0         | 2         | 8          | 100%       | 71.42%     |
| 8/4/2003     | 5         | 1         | 0         | 7          | 83.3%      | 100%       |
| 9/4/2003     | 7         | 1         | 0         | 10         | 87.5%      | 100%       |
| 10/4/2003    | 6         | 3         | 1         | 16         | 66.67%     | 85.7%      |
| 11/4/2003    | 4         | 3         | 1         | 12         | 57.1%      | 80%        |
| <b>Total</b> | <b>68</b> | <b>13</b> | <b>17</b> | <b>173</b> | <b>84%</b> | <b>80%</b> |

جدول ۳-۲. نتایج روش‌های BDS، 2LDS، 3LDS و روش

پیشنهادی.

| Method                 | PR         | RC         | FM         | ACC          |
|------------------------|------------|------------|------------|--------------|
| BDS                    | 69.4%      | 88.3%      | 77.7%      | 81.4%        |
| 2LDS                   | 84.7%      | 93.5%      | 88.9%      | 92.34%       |
| 3LDS                   | 88.2%      | 80%        | 84.2%      | 86.6%        |
| <b>proposed method</b> | <b>84%</b> | <b>80%</b> | <b>82%</b> | <b>88.9%</b> |

PR= precision, RC= recall, FM= F-measure, ACC= accuracy.

میانگین صحت هریک از روش‌های 3LDS، 2LDS و روش پیشنهادی به ترتیب عبارتند از: ۰/۸۹/۶، ۰/۸۵/۴ و ۰/۸۹؛ و به نظر می‌رسد تفاوت چندانی بین صحت آنها نباید وجود داشته باشد. لذا با استفاده از آزمون  $t$ ، فرض تساوی میانگین صحت روش پیشنهادی را با میانگین صحت هریک از روش‌های 2LDS و 3LDS در سطح معنی داری  $\alpha = 0.05$  می‌آزمائیم. در واقع فرض صفر را برابری میانگین صحت روش پیشنهادی با هریک از روش‌ها، و فرض یک را نابرابری آنها در نظر می‌گیریم. نتایج این آزمون فرض در جدول ۳-۳ نشان داده شده‌اند. با توجه به اینکه  $p$ -مقدارها از  $\alpha$  بیشتر هستند، تفاوت معنی داری را نمی‌توان نتیجه گرفت.

جدول ۳-۳. مقایسه روش پیشنهادی با 2LDS و 3LDS  
با استفاده از آزمون فرض  $t$ .

|                              | Proposed method | Comparison with 2LDS | Comparison with 3LDS |
|------------------------------|-----------------|----------------------|----------------------|
| mean                         | 0.890           | 0.896                | 0.854                |
| variance                     | 0.0048          | 0.0151               | 0.0186               |
| observations                 | 16              | 16                   | 16                   |
| hypothesized mean difference |                 | 0                    | 0                    |
| df                           |                 | 15                   | 15                   |
| t-Stat                       |                 | -0.1908              | 1.0371               |
| P(T<=t) one-tail             |                 | 0.4256               | 0.1580               |
| t-critical one-tail          |                 | 1.7530               | 1.7530               |
| P(T<=t) two-tail             |                 | 0.8512               | 0.3161               |
| t-critical two-tail          |                 | 2.1314               | 2.1314               |

### ۲-۵-۳-۳ آزمایش دوم

در این آزمایش روش پیشنهادی را با سه رویکرد مبتنی بر NBC، HMM، و HSMM، که در [۶۰] پیاده سازی شده مقایسه می‌کنیم. از مجموعه داده‌های ارائه شده توسط کاسترن<sup>۱</sup> [۶۰] بدین منظور استفاده می‌کنیم. در این مجموعه داده ۱۴ حسگر مختلف دودویی بر روی درب‌ها، لوازم خانگی و غیره نصب شده‌اند. برچسب گذاری داده‌ها به صورت کامل توسط کاربر برای مدت ۲۵ روز انجام شده است. اعمال روزمره مختلفی در محیط توسط کاربر انجام می‌گیرد که شامل: "ترک کردن منزل"، "استفاده از سرویس بهداشتی"، "رفتن به رخت خواب"، و غیره می‌باشد. همانطور که در [۶۰] نیز عنوان شده، از داده‌های حسگرها می‌توان سه دسته ویژگی را استخراج نمود: داده‌های خام (RD)<sup>۲</sup>، نقطه تغییر (CP)<sup>۳</sup>، و آخرین فعال سازی (LF)<sup>۴</sup> [۶۰]. برای ویژگی CP تنها زمانی خروجی مربوط به یک حسگر را ۱ در نظر می‌گیریم که وضعیت آن از فعال به غیر فعال، یا برعکس، تغییر کرده باشد. برای ویژگی LF در هر زمان صرفاً "آخرین حسگری که فعال بوده مقدار ۱ و بقیه مقدار صفر دارند. مثالی از داده‌های خام و ویژگی‌های مربوطه در شکل ۳-۵ نشان داده شده‌اند. در این کار برای هر بازه زمانی به


<sup>۱</sup> Kasteren

<sup>۲</sup> Raw data

<sup>۳</sup> Change point

<sup>۴</sup> Last fired

اندازه ۶۰ ثانیه یک بردار ویژگی استخراج شده، سپس با الگوریتم‌های HMM، NBC و HSMM عمل مربوط به آن برش زمانی استنتاج گردیده است.



شکل ۳-۵. الف- داده‌های خام حسگرها، ب- ویژگی‌های CP، ج- ویژگی‌های LC [۶۰].

اما مسأله‌ای که وجود دارد این است که روش پیشنهادی ما در واقع به هر رویداد حسگر فعال یا غیر فعال شده عملی را نسبت می‌دهد نه به هر برش زمانی. لذا به منظور انجام مقایسه ای صحیح، در روش پیشنهادی پس از استنتاج یک عمل برای یک بخش از داده‌ها در جریان داده‌های حسگرها، از زمان شروع آن بخش تا زمان شروع بخش بعدی را با عمل استنتاج شده برچسب می‌زنیم. سپس مقایسه را با در نظر گرفتن برش‌های زمانی به اندازه ۶۰ ثانیه انجام می‌دهیم. در واقع هر تشخیص درست (TP) عبارت است از تشخیص صحیح برچسب یک برش زمانی به اندازه ۶۰ ثانیه.

نتایج ارزیابی در جدول ۳-۴ آورده شده است. همانطور که ملاحظه می‌شود، به ازای تمامی ویژگی‌های مورد استفاده، روش پیشنهادی عملکرد نسبتاً بهتری را نسبت به NBC و HMM از خود نشان داده است. در مقایسه با HSMM، ویژگی‌های RD، و CP منجر به نتایجی ضعیف‌تر و یا قابل مقایسه با رویکرد پیشنهادی ما شده‌اند. در استفاده از HSMM توام با ویژگی LF نیز، F-measure روش پیشنهادی با ۸۵/۵٪ نسبتاً بهتر است، اما صحت روش پیشنهادی (۹۴/۲٪) با صحت HSMM (۹۵٪) قابل مقایسه می‌باشد. با این وجود باید توجه داشت که HSMM علاوه بر ترتیب داده‌های حسگرها، مدت زمان فعال ماندن آنها را نیز در مدل‌سازی و استنتاج در نظر می‌گیرد.

جدول ۳-۴. نتایج به دست آمده از روش پیشنهادی، NBC، HMM و HSMM.

| Method          | Feature      | PR           | RC           | FM           | ACC          |
|-----------------|--------------|--------------|--------------|--------------|--------------|
| NBC             | raw data     | 74.4%        | 58.4%        | 64.9%        | 77.6%        |
|                 | change-point | 73.5%        | 53.3%        | 61.3%        | 56.3%        |
|                 | last-Fired   | 86.8%        | 74.6%        | 80.0%        | 95.9%        |
| HMM             | raw data     | 56.7%        | 66.3%        | 60.0%        | 61.0%        |
|                 | change-point | 81.5%        | 84.2%        | 82.6%        | 90.1%        |
|                 | last-Fired   | 76.4%        | 84.0%        | 79.6%        | 93.0%        |
| HSMM            | raw data     | 57.3%        | 67.7%        | 60.8%        | 62.0%        |
|                 | change-point | 82.1%        | 84.9%        | 83.2%        | 91.5%        |
|                 | last-Fired   | 81.1%        | <b>86.8%</b> | 83.5%        | <b>95.0%</b> |
| proposed method | -----        | <b>86.7%</b> | 84.4%        | <b>85.5%</b> | 94.2%        |

PR= precision, RC= recall, FM= F-measure, ACC= accuracy.

### ۳-۴ جمع بندی

در این فصل یک معماری مبتنی بر نظریه DS برای شناسایی اعمال ترتیبی در محیط‌های تک کاربره ارائه گردید. در این معماری، ابتدا دنباله داده‌های حسگرها با یک روش بدون نظارت طوری بخش بندی می‌شوند که هر بخش مربوط به یک عمل باشد. سپس عمل مربوط به هر بخش تشخیص داده می‌شود. بدین منظور، زیر دنباله‌هایی از داده‌های حسگرها به صورت چند تایی‌های مرتب، استخراج و به عنوان شاهد در نظر گرفته می‌شوند. سپس عقاید این شاهد‌ها در مورد هر عمل با استفاده از نظریه DS با هم ترکیب می‌شوند. نهایتاً عملی که بیشترین باور در مورد آن به دست می‌آید به عنوان عمل مربوطه استنتاج می‌گردد. عقاید شاهد‌ها در مورد هر عمل در مرحله آموزش و با استفاده از تابع توزیع بتا بدست می‌آیند. در مرحله آموزش شاهد‌هایی که عدم قطعیت بالایی در خصوص یک عمل دارند، از مجموعه شاهد‌های آن عمل حذف می‌گردند. در مرحله آزمون، صرفاً عقاید شاهد‌هایی که عدم قطعیت پایینی در مورد یک عمل دارند با هم ترکیب می‌شوند.

برای ارزیابی، روش پیشنهادی با سه رویکرد مبتنی بر دانش (مبتنی بر هستان‌شناسی)، و نیز سه روش مبتنی بر داده (NBC، HMM و HSMM)، و بر روی دو مجموعه داده معروف مقایسه گردید.

ارزیابی‌ها نشان دادند که در مقایسه با رویکردهای مبتنی بر دانش، روش پیشنهادی عملکردی قابل مقایسه دارد. اما از آنجا که در روش پیشنهادی از ساختارهای ثابت، و از پیش تعریف شده هستان‌شناسی‌ها استفاده نمی‌شود، طراحی و توسعه آن دارای پویایی بیشتری است. همچنین، نتایج نشان دادند که روش پیشنهادی از روش‌های مبتنی بر NBC و HMM مورد ارزیابی، کارایی بیشتری داشته و در مقایسه با HSMM نیز در اکثر حالات بهتر بوده و یا قابل مقایسه است. هرچند، این مساله به ویژگی‌های مورد استفاده (مثل ویژگی‌های LC، و یا CP) بستگی دارد.



فصل ۴. راهکار پیشنهادی دوم برای شناسایی  
اعمال، مبتنی بر بهینه سازی

## ۴-۱ مقدمه

در فصل قبل، رویکردی مبتنی بر نظریه دمپستر-شافر برای شناسایی اعمال ارائه گردید. در این رویکرد، ابتدا چندتایی‌های مرتب را به عنوان شاهد‌هایی برگزیدیم و میزان باور، عدم باور، و عدم قطعیت یک شاهد در مورد هر یک از اعمال را با استفاده از تابع توزیع بتا محاسبه نمودیم. در این فرآیند، عدم قطعیت یک شاهد در مورد یک عمل، به صورت تابعی نزولی از مجموع دفعات فعال شدن آن شاهد (یعنی مجموع دفعات مشاهده چندتایی مربوط به آن شاهد در دنباله داده‌های اعمال مختلف)، با رابطه (۳-۵) به دست آمد. با توجه به این رابطه، اگر تعداد دفعات رخداد یک شاهد به سمت بی نهایت میل کند، عدم قطعیت آن در مورد اعمال به سمت صفر میل خواهد کرد. در واقع این خصوصیت بیانگر این واقعیت شهودی است که با افزایش تعداد رخداد‌های شاهد‌ها، خطای مقادیر باور و عدم باور آنها (عدم قطعیت آنها) در مورد اعمال کاهش می‌یابد.

اما باید در نظر داشت که اگر مقادیر باور و عدم باور یک شاهد در مورد اعمال مختلف نزدیک به هم باشند، آنگاه با داشتن آن شاهد نمی‌توان در مورد عمل در حال انجام با ضریب اطمینان بالایی تصمیم‌گیری کرد. به بیان دیگر، نزدیک به هم بودن مقادیر باور یک شاهد در خصوص اعمال مختلف، نوعی عدم قطعیت را ایجاد می‌کند. به عنوان مثال، اگر یک حسگر مجاورت<sup>۱</sup> که برای تشخیص حضور یا عدم حضور استفاده می‌شود، در آشپزخانه نصب شده باشد، هر بار که شخص برای اعمال "شستن ظرف‌ها"، "آشپزی"، و یا "غذا خوردن" در آشپزخانه حاضر می‌شود، این حسگر فعال خواهد شد. اگر تعداد دفعات این اعمال نزدیک به هم باشد، آنگاه مقدار باوری که با فعال شدن این حسگر در خصوص اعمال فوق‌القاء می‌شود نزدیک به هم خواهد بود. در فصل قبل، این نوع از عدم قطعیت را با ترکیب

---

<sup>۱</sup> Proximity sensor



عقاید شاهدهایی که در یک زیر دنباله بخش بندی شده، مربوط به عملی نامشخص بودند تخفیف دادیم. در این فصل، این عدم قطعیت را با مفهوم آنروپی<sup>۱</sup> بیان می کنیم و سعی خواهیم کرد که آن را مینیمم کنیم.

همچنین، باید توجه داشت که در اولین رویکرد پیشنهادی (فصل قبل)، فرض بر این بود که اعمال ترتیبی هستند و با خوشه بندی داده ها با استفاده از زمان رخداد آنها، می توان بخش های مربوط به اعمال ترتیبی را از هم جدا کرد. اما زمانی که اعمال به صورت متداخل انجام گیرند، در صورت خوشه بندی بر حسب زمان رخداد، داده های اعمال مختلف که از نظر زمانی نزدیک به هم هستند در یک خوشه قرار خواهند گرفت و امکان رده بندی اشتباه وجود خواهد داشت.

در این فصل، تشخیص اعمال متداخل و ترتیبی را برای محیط های تک کاربره، منطبق با لایه دوم معماری پیشنهادی، برای بازشناسی اعمال (شکل ۳-۱) مورد بررسی قرار خواهیم داد. روش پیشنهادی قادر است که: ۱- استنتاجی سراسری، با در نظر گرفتن کل دنباله داده حسگرها انجام دهد، و ۲- عدم قطعیت (به مفهوم آنروپی) مشاهدات حسگرها در مورد اعمال و در نتیجه عدم قطعیت استنتاج را مدیریت کند (کاهش دهد). در این روش نیازی به بخش بندی داده های حسگرها از قبل نیست. این روش مبتنی بر حل یک مساله برنامه ریزی تفاضل محدب (DCP<sup>۲</sup>) می باشد. به بیان دقیق تر، ابتدا به ازای هر قلم داده در جریان داده حسگرها، یک بردار باور اولیه موسوم به PBV<sup>۳</sup> با یک رویکرد بیزین محاسبه می شود. هر عنصر در بردار باور، امکان رخداد یکی از اعمال را بازنمایی می کند. در تطبیق با لایه دوم معماری پیشنهادی (شکل ۱-۲)، بردارهای باور اولیه را می توان به عنوان بردار ویژگی استخراج

---

<sup>۱</sup> Entropy

<sup>۲</sup> Difference of convex programming

<sup>۳</sup> Primary belief vectors

شده برای هر رویداد حسگر در نظر گرفت. سپس، بردارهای باور اولیه با حل مساله DCP هموار<sup>۱</sup> شده و متناظر با هر PBV، یک بردار باور ثانویه متناظر، موسوم به SBV<sup>۲</sup>، به دست می‌آید. مساله DCP را با استفاده از الگوریتم روال محدب-مقعر (CCP<sup>۳</sup>) [۱۱۲] حل می‌کنیم. استنتاج اعمال با استفاده از بردارهای باور ثانویه انجام می‌شود. در مساله DCP مربوطه، محدودیت‌های زیر، که منطبق بر مفروضات دنیای واقعی در خصوص اعمال متداخل هستند، برای هموارسازی PBV ها اعمال می‌گردند.

۱. هر قدر عدم قطعیت یک بردار باور اولیه کمتر باشد، بردار باور ثانویه متناظر، به آن نزدیکتر خواهد بود، و برعکس، هر قدر عدم قطعیت بردار اولیه کمتر باشد، بردار باور ثانویه امکان دور شدن از آن را خواهد داشت.

۲. تعداد بخش‌های<sup>۴</sup> مربوط به هر عمل که به صورت متداخل انجام می‌شود، محدود است.

۳. عدم قطعیت (آنتروپی) بردارهای باور ثانویه بسیار پایین است.

در محدودیت‌های فوق از فاصله اقلیدسی برای محاسبه فاصله بین بردارهای باور استفاده شده است. همچنین، عدم قطعیت معادل با مفهوم آنتروپی در نظر گرفته شده است.

## ۲-۴ جریان داده حسگرها و نمادگذاری های مربوطه

داده‌ها با حسگرهای مختلفی در محیط جمع‌آوری می‌شوند. در این فصل، یک رویداد حسگر به صورت زوج شناسه (ID) و مقدار حسگر فعال شده در نظر گرفته می‌شود. هر رویداد حسگر را می‌توان با یک مقدار عددی کدگذاری نمود. دامنه مقادیر حسگرها می‌تواند گسسته یا پیوسته باشد. در صورت

---

<sup>۱</sup> Smooth

<sup>۲</sup> Secondary belief vectors

<sup>۳</sup> Convex-concave procedure


<sup>۴</sup> segment

استفاده از حسگرهای پیوسته می‌توان از یک روش بخش‌بندی<sup>۱</sup> [۱۱۳] برای گسسته‌سازی<sup>۲</sup> دامنه آنها استفاده کرد. بنابراین، می‌توان حسگرها را گسسته فرض کرد. دامنه حسگر  $i$  را با  $D_i$  نمایش می‌دهیم. جدول ۱-۴ مثالی از شناسه حسگرها، نوع، دامنه، و رویدادهای ممکن برای آنها را نشان می‌دهد (مربوط به مجموعه داده‌های مرجع [۱۱۴]).

جدول ۱-۴. مثالی از شناسه، نوع، دامنه، و رویدادهای ممکن برای حسگرها.

| ID  | Sensor Type              | Sensor Domain                   | Sensor Events       |
|-----|--------------------------|---------------------------------|---------------------|
| M15 | Motion (Discrete)        | $D_{M01} = \{"ON", "OFF"\}$     | M01_ON, M01_OFF     |
| T03 | Temperature(Continuous)  | $D_{T01} = \{1,2,3\}$           | T03_1, T03_2, T03_3 |
| D07 | Switch Sensor (Discrete) | $D_{D07} = \{"CLOSE", "OPEN"\}$ | D07_CLOSE, D07_OPEN |

جریان داده حسگرها دنباله‌ای از رویدادهای حسگرهاست که بر حسب زمان وقوع مرتب شده‌اند. این جریان داده حسگرها را دنباله یا جریان رویدادهای حسگرها نیز می‌نامیم. جریانی از داده‌های حسگرها، به طول  $T$  را با  $x_{1:T} = x_1, \dots, x_t, \dots, x_T$  نشان می‌دهیم که در آن  $x_i$  ها رویدادهای حسگرها را نشان می‌دهند. در شکل ۱-۴ یک جریان داده حسگر نمایش داده شده است.



شکل ۱-۴. مثالی از جریان داده حسگرها.


با توجه به نمادگذاری فوق مساله شناسایی اعمال را به فرم زیر تعریف کرده و در ادامه از نمادگذاری‌های آن استفاده می‌کنیم:

<sup>۱</sup> Partitioning

<sup>۲</sup> Discretization

تعریف ۱-۴. (مساله شناسایی اعمال). فرض کنید  $\mathcal{A} = \{a_1, \dots, a_n\}$  مجموعه‌ای از  $n$  عمل روزمره،  $\mathcal{D} = \{x_{1:T_i}^i | x_{1:T_i}^i = x_1^i, \dots, x_{T_i}^i, T_i \in \mathbb{N}, i = 1, \dots, L\}$  مجموعه آموزشی از  $L$  جریان داده برچسب گذاری شده، و  $x_{1:T} = x_1, \dots, x_T$  یک جریان داده جدید با طول  $T$  را نشان دهد. آنگاه مساله شناسایی اعمال عبارت است از آموزش یک مدل بر مبنای  $\mathcal{D}$  که با استفاده از آن بتوان زیرمجموعه‌ای از عناصر مجموعه  $\mathcal{A}$  را به عنوان برچسب هر رویداد حسگر مثل  $x_t \in x_{1:T}$  تخصیص داد.

همانطور که در فصل ۱ نیز بیان شد، اعمال می‌توانند به سه صورت ترتیبی، متداخل و هم‌روند انجام شوند. این وضعیت‌ها در شکل ۲-۴ نشان داده شده‌اند. در این فصل، تمرکز اصلی بر استنتاج اعمال ترتیبی و متداخل است.

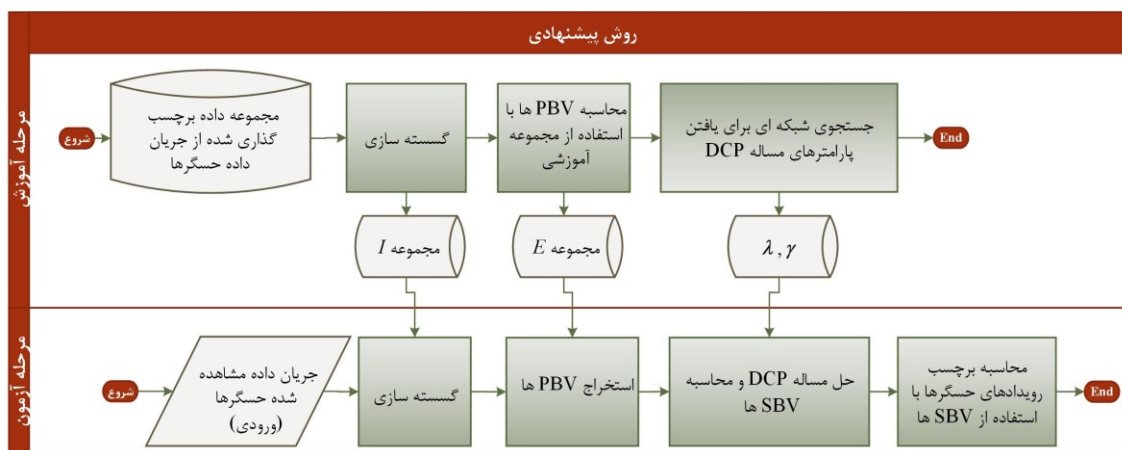


شکل ۲-۴. نحوه انجام اعمال به صورت ترتیبی، متداخل و هم‌روند.

## ۳-۴ روش پیشنهادی

روش پیشنهادی از دو فاز آموزش و آزمون تشکیل شده است. یک شمای کلی از این روش در شکل ۳-۴ و شبه کدهای شکل ۴-۴ و شکل ۵-۴ نشان داده شده است. در ادامه، فلوچارت و شبه کدهای مربوطه را توضیح خواهیم داد. در زیربخش‌های بعدی به بیان اجزای اصلی روش پیشنهادی خواهیم پرداخت. با توجه به اینکه در روش پیشنهادی از یک مساله برنامه ریزی تفاضل محدب استفاده می‌کنیم، این روش را  $DCPAR^1$  می‌نامیم.

<sup>1</sup> Difference of convex programming-based activity recognition



شکل ۴-۳. فازها و مراحل روش پیشنهادی (DCPAR).

**مرحله آموزش:** شبه کد این فاز در شکل ۴-۴ آورده شده است. در این فاز، ابتدا دامنه حسگرهای پیوسته گسسته‌سازی می‌گردند (تابع *Discretization*). هر بازه با یک شناسه نشان داده می‌شود. هر زمان که مقدار حسگر پیوسته تغییر می‌کند، شناسه بازه‌ای را می‌گیرد که مقدار حسگر به آن تعلق دارد. مجموعه همه بازه‌های گسسته را با  $I$  نمایش می‌دهیم. پس از این پیش‌پردازش، برای هر رویداد حسگر، یک بردار به اندازه  $n$ ، به عنوان  $PBV$  مربوطه محاسبه می‌گردد (تابع *Compute\_PBVs*). محاسبه این  $PBV$  ها در زیربخش بعدی توضیح داده شده است. مجموعه همه  $PBV$  ها با  $E$  نمایش داده شده است. از آنجا که تعداد و مقادیر حسگرها محدود است، محاسبه مجموعه  $E$  با پیچیدگی زمانی معقول  $\theta(n|S|)$ ، که  $n$  تعداد اعمال و  $|S|$  مجموع تعداد رویدادهای ممکن برای حسگرها را نشان می‌دهد) امکان پذیر خواهد بود. سپس، پارامترهای مساله DCP با استفاده از تابع *Grid\_Search* تعیین می‌گردند. مساله DCP دنباله‌ای از  $PBV$  ها را به عنوان ورودی گرفته و دنباله‌ای از  $SBV$  ها را به عنوان خروجی برمی‌گرداند. در مجموع، خروجی‌های مرحله آموزش عبارتند از مجموعه‌های  $I$ ،  $E$ ، و پارامترهای مساله DCP.

**مرحله آزمون:** شبه کد این مرحله در شکل ۴-۵ آورده شده است. در این فاز، ابتدا جریان داده ورودی از حسگرها، مثل  $x_{1:T}$ ، در صورت لزوم، با استفاده از مجموعه  $I$  گسسته‌سازی می‌گردد (تابع

(Discretize). سپس، دنباله‌ای از PBV ها، به صورت  $\mathbf{B} = [\mathbf{b}_1, \dots, \mathbf{b}_T]^T$ ، برای آن استخراج خواهد شد (تابع *Extract\_PBV*). آنگاه مساله DCP با دریافت دنباله  $\mathbf{B}$  به عنوان ورودی با استفاده از الگوریتم CCP [۱۱۲] حل شده (تابع *Solve\_With\_CCP*)، و دنباله‌ای از SBV ها به صورت  $\mathbf{M} = [\mathbf{M}_1, \dots, \mathbf{M}_T]^T$  به دست می‌آید. در نهایت، برچسب هر رویداد حسگر مثل  $x_i \in x_{1:T}$ ، با استفاده از معادله  $l_i = \operatorname{argmax}_j (M_{i,j})$  محاسبه می‌شود، که در آن عنصر  $M_{i,j}$  زام در بردار باور ثانویه  $\mathbf{M}_i$  است.

- 
1. **Input**
  2. Annotated training set:  $\mathcal{D} = \{x_{1:T_i}^i | i = 1, \dots, L\}$
  3. Formulated DCP problem (equation (7)):  $P$
  4. Maximum and minimum of  $\lambda$ , and  $\gamma$ :  $Max_\lambda, Min_\lambda, Max_\gamma, Min_\gamma$
  5. **Output**
  6. Set of possible PBVs:  $E$
  7. Set of discrete intervals:  $I$
  8. Regularization parameters:  $\lambda, \gamma$
  9. **Variables**
  10. Discretized training set:  $\mathcal{D}'$
  11. **Body**
  12.  $[I, \mathcal{D}'] = \text{Discretization}(\mathcal{D})$
  13.  $E = \text{Compute\_PBVs}(\mathcal{D}')$
  14.  $[\lambda, \gamma] = \text{Grid\_Search}(P, E, \mathcal{D}', Max_\lambda, Min_\lambda, Max_\gamma, Min_\gamma)$
  15. **End**
- 

شکل ۴-۴. شبه کد مرحله آموزش.

- 
1. **Input**
  2. Input sensor data stream:  $x_{1:T} = x_1, \dots, x_T$
  3. Set of discretized Intervals:  $I$
  4. Set of PBVs:  $E$
  5. Formulated DCP problem (equation (7)):  $P$
  6. DCP regularization parameters:  $\lambda, \gamma$
  7. **Output**
  8. Sequence of inferred activity IDs:  $l_{1:T} = l_1, \dots, l_T$
  9. **Variables**
  10. Matrix of PBVs:  $\mathbf{B} \in \mathbb{R}^{T \times n}$  //  $i$ 'th row (i.e.  $\mathbf{B}_i$ ) is the  $i$ 'th PBV
  11. Matrix of SBVs:  $\mathbf{M} \in \mathbb{R}^{T \times n}$  //  $i$ 'th row (i.e.  $\mathbf{M}_i$ ) is the  $i$ 'th SBV
  12. **Body**
  13. **For**  $i = 1$  to  $T$
  14. **If**  $x_i$  is continuous
  15.  $x_i = \text{Discretize}(x_i, I)$
  16. **End**
  17.  $\mathbf{B}_i = \text{Extract\_PBV}(x_i, E)$
  18. **End**
  19.  $\mathbf{M} = \text{Solve\_With\_CCP}(P, \mathbf{B}, \lambda, \gamma)$
  20. **For**  $i = 1$  to  $T$
  21.  $l_i = \operatorname{argmax}_{j \in \{1, \dots, n\}} (M_{i,j})$
  22. **End**
  23. **End**
- 

شکل ۴-۵. شبه کد مرحله آزمون.

لازم به ذکر است که در تطبیق با لایه دوم معماری پیشنهادی، در DCPAR قطعه‌بندی به صورت غیر ضمنی انجام نمی‌گیرد. همچنین، استخراج PBV ها برای هر رویداد حسگر معادل با استخراج بردار ویژگی در لایه دوم معماری پیشنهادی می‌باشد.

### ۴-۳-۱ محاسبه بردارهای باور اولیه (PBV)

با داشتن  $n$  عمل، و مجموعه رویدادهای حسگرها به نام  $S$ ، بردار ویژگی  $\mathbf{b}_i = (b_{i,1}, \dots, b_{i,j}, \dots, b_{i,n})$  به عنوان بردار باور اولیه (یعنی PBV) برای رویداد حسگر  $x_i \in S$  محاسبه می‌گردد. در این بردار،  $b_{i,j} \geq 0$  مقدار باور رویداد حسگر  $x_i$  در مورد عمل  $a_j$  است طوریکه داریم:  $\sum_{j=1}^n b_{i,j} = 1$ . بردار باور اولیه یک رویداد حسگر را به صورت تابعی از احتمال پسین اعمال به شرط آن رویداد، و نیز میزان تسطیح<sup>۱</sup> این توزیع احتمال پسین، به شرح ذیل محاسبه می‌کنیم.

مقدار باور  $b_{i,j}$  را به طور مستقیم متناسب با احتمال پسین رخداد عمل  $a_j$  به شرط  $x_i$  در نظر می‌گیریم (رابطه (۱-۴))

$$b_{i,j} \propto p(A = a_j | X = x_i), \quad (1-4)$$

که در آن،  $A$  و  $X$  متغیرهایی هستند که، به ترتیب، شناسه‌های یک عمل و یک رویداد حسگر را اختیار می‌کنند.

در یک محیط هوشمند انتظار می‌رود که مقادیر  $p(A = a_j | X)$  به ازای تعداد محدودی از رویداد حسگرها که مرتبط با عمل  $a_j$  هستند بالا، و برای بقیه رویدادها پایین باشد. زیرا افراد در هر عمل معمولاً با تعداد اندکی از لوازم خانگی (و در نتیجه تعداد معدودی از حسگرها) سر و کار دارند. بنابراین، انتظار می‌رود  $p(A = a_j | X)$  مسطح نباشد. بر این اساس فرض زیر را تعریف می‌کنیم:

---

<sup>۱</sup> Flatness

فرضیه ۴-۱. (نامسطح بودن توزیع پسین اعمال). توزیع احتمال پسین اعمال به شرط رویدادهای

حسگرها، یعنی  $f(x) = p(A = a_j|x)$  نباید مسطح باشد.

مشابه توابع توزیع احتمال، میزان تسطیح  $p(A = a_j|x)$  را پس از نرمال سازی آن، می توان با

مفهوم آنتروپی به صورت زیر محاسبه کرد:

$$R_j = -\sum_{k=1}^{|S|} (\bar{p}(A = a_j|X = x_k) \times \log(\bar{p}(A = a_j|X = x_k))), \quad (۲-۴)$$

که در آن،  $R_j \geq 0$  میزان تسطیح تابع  $p(A = a_j|X)$  بوده، و داریم:  $\bar{p}(A = a_j|X = x_k) =$

هر قدر  $p(A = a_j|X)$  مسطح تر باشد، مقدار  $R_j$  بیشتر خواهد بود. لذا  $\frac{p(A = a_j|X = x_k)}{\sum_{k'=1}^{|S|} p(A = a_j|X = x_{k'})}$

با توجه به فرضیه ۴-۱،  $b_{i,j}$  را به طور عکس متناسب با  $R_j$  تعریف می کنیم. بنابراین، خواهیم داشت:

$$b_{i,j} \propto \frac{1}{R_j + \varepsilon}, \quad (۳-۴)$$

که در آن  $\varepsilon \in \mathbb{R}^+$  مقدار کوچکی است که مانع از صفر شدن مخرج می گردد. از روابط (۴-۱) و (۴-۳)،

رابطه (۴-۴) را نتیجه می گیریم:

$$b_{i,j} = \frac{p(A = a_j|X = x_i)}{R_j + \varepsilon} \cdot Z_i, \quad (۴-۴)$$

که در آن،  $Z_i$  ضریب نرمال سازی است که از رابطه (۴-۵) محاسبه می گردد.

$$Z_i = \left( \sum_{k=1}^n \frac{p(A = a_k|X = x_i)}{R_k + \varepsilon} \right)^{-1}. \quad (۵-۴)$$

لازم به ذکر است که  $p(A = a_k|X = x_i)$  را می توان با روش هایی همچون  $MLE^1$  و یا  $MAP^2$  محاسبه نمود. با داشتن تعابیر فوق، بردار باور اولیه را به صورت رسمی به فرم زیر تعریف می کنیم:

<sup>1</sup> Maximum likelihood estimation

<sup>2</sup> Maximum a posteriori estimation



تعریف ۲-۴. (بردارهای باور اولیه (PBV)). بردار باور اولیه برای رویداد حسگری مثل  $x_i$

عبارت است از برداری مثل  $b_i \in \mathbb{R}^n$  که در آن، میزان باور القاء شده توسط حسگر  $x_i$  برای عمل  $a_j$  است، طوریکه  $\sum_{k=1}^n b_{i,k} = 1$  و  $b_{i,j}$  با رابطه (۴-۴) محاسبه می‌شود.

هر بردار باور اولیه دارای  $n$  عنصر می‌باشد و با پیچیدگی زمانی خطی  $\theta(n)$  محاسبه می‌گردد. با توجه به محدود بودن تعداد رویدادهای حسگرها، یعنی  $|S|$ ، در زمان آموزش محاسبه بردارهای باور اولیه با پیچیدگی زمانی  $\theta(n|S|)$  انجام خواهد شد. در مرحله آزمون، با مشاهده یک رویداد حسگر، بردار باور اولیه مربوط به آن بازیابی خواهد شد. لذا در زمان آموزش، محاسبه یک بردار باور اولیه با پیچیدگی زمانی اسکالر، یعنی  $\theta(1)$  انجام می‌گیرد. حال اگر جریانی به طول  $T$  از رویدادهای حسگرها داشته باشیم، آنگاه پیچیدگی زمانی استخراج بردارهای باور اولیه برای آن برابر با  $\theta(T)$  خواهد بود.

## ۲-۳-۴ شناسایی اعمال با استفاده از یک مساله برنامه ریزی تفاضل محدب (DCP)

در این بخش، روشی بر مبنای بهینه سازی یک تابع هدف غیر محدب برای شناسایی اعمال مطرح می‌گردد. در این روش، عدم قطعیت بردارهای باور اولیه با فرآیند بهینه سازی تخفیف می‌یابد. در ادامه، ابتدا به تعریف عدم قطعیت بردارهای باور با استفاده از مفهوم آنتروپی پرداخته و سپس مساله بهینه سازی DCP را مطرح می‌کنیم.


در نظریه اطلاعات، عدم قطعیت یک متغیر تصادفی به صورت آنتروپی آن متغیر در نظر گرفته می‌شود. به طور مشابه، عدم قطعیت یک بردار باور (اولیه یا ثانویه) را می‌توان با مفهوم آنتروپی به صورت زیر تعریف نمود.

تعریف ۳-۴. (عدم قطعیت بردار باور). اگر  $x \in \mathbb{R}^n$  یک بردار باور را نشان دهد، آنگاه عدم

قطعیت  $x$  را با تابع  $u(x): \mathbb{R}^n \rightarrow \mathbb{R}$  نشان داده، و آنرا به صورت آنتروپی بردار باور با رابطه زیر تعریف می‌کنیم:

$$u(x) = - \sum_{j=1}^n x_j \log(x_j). \quad (6-4)$$

باید توجه داشت که  $u(x)$  زمانی ماکزیمم می‌شود که عناصر بردار باور  $x$  همگی با هم برابر باشند (یعنی کاملا مسطح باشد). همچنین این تابع زمانی مینیمم میگردد که یکی از عناصر بردار  $x$  برابر با ۱ و بقیه صفر هستند (یعنی کاملا قله‌ای<sup>۱</sup> باشد). تابع  $u(x)$  و ماکزیمم و مینیمم‌های آن در شکل ۶-۴ نشان داده شده است. همچنین، باید توجه داشت که  $u(x)$  یک تابع مقعر<sup>۲</sup> است.



شکل ۶-۴. تابع  $u(x)$ ، و اکسترم‌های آن.

### ۳-۳-۴ شناسایی اعمال با استفاده از بردارهای باور ثانویه

همانطور که قبلا گفته شد، برای حل مساله عدم قطعیت بردارهای باور اولیه (یعنی کاهش آنتروپی)، به ازای هر بردار باور اولیه  $b_i$  (یعنی هر PBV)، یک بردار باور ثانویه (یعنی SBV)، موسوم به

<sup>۱</sup> Peaked

<sup>۲</sup> Concave

$M_i$ ، برای هر رویداد حسگر  $x_i \in x_{1:T}$  محاسبه می‌نمائیم. SBV ها با هموار سازی<sup>۱</sup> PBV ها محاسبه می‌شوند. بدین منظور، SBV ها را طوری محاسبه می‌کنیم که شروط جدول ۴-۲ را برآورده سازند. توجه داریم که SBV ها باید خصوصیات بردارهای باور را حفظ کنند یعنی  $M_{i,j} \geq 0$  و  $\sum_{k=1}^n M_{i,k} = 1$ .

**جدول ۴-۲. محدودیت‌های لازم برای محاسبه بردارهای باور ثانویه  $(M_i, i = 1, \dots, T)$**

۱- هر قدر عدم قطعیت  $b_i$  کمتر باشد،  $M_i$  باید نزدیکتر به  $b_i$  باشد و هر قدر عدم قطعیت  $b_i$  بیشتر باشد، امکان دور شدن  $M_i$  از  $b_i$  نیز بیشتر باشد.

۲- تعداد بخش‌های داده‌های مربوط به اعمال در جریان داده‌های حسگرها (یعنی  $x_{1:T}$ ) محدود است. از آنجا که انتظار داریم باورهای ثانویه محاسبه شده برای داده‌های هر بخش از یک عمل یکسان باشند، این شرط می‌تواند بدان معنی باشد که تعداد SBV های متوالی نامساوی باید محدود باشند. یعنی:

$$\exists K \in \mathbb{R}^+, \quad \sum_{i=1}^{T-1} \|M_i - M_{i+1}\|_2 < K$$

۳- عدم قطعیت SBV های محاسبه شده باید کمترین مقدار ممکن باشد.

برآورده ساختن محدودیت‌های جدول ۴-۲ منجر به بردارهای باوری خواهد شد که عدم قطعیت در آنها توسط رویدادهای حسگر مجاور، در جریان داده‌های حسگرها تخفیف داده می‌شود. بدین صورت که اولین محدودیت جدول ۴-۲ موجب می‌شود تا در صورت پایین بودن عدم قطعیت بردارهای باور اولیه، بردارهای باور ثانویه محاسبه شده در نزدیکی آنها باقی بمانند. محدودیت دوم باعث می‌شود تا بردارهای باور ثانویه که در همسایگی هم قرار دارند، به یکدیگر نزدیک شوند. با اعمال هم‌راند این دو محدودیت، بردارهای باوری که عدم قطعیت بالایی دارند به بردارهای باوری که عدم قطعیت پایینی داشته و نیز در همسایگی آنها هستند نزدیک خواهند شد. بنابراین، از عدم قطعیت آنها به طور ضمنی کاسته خواهد شد. همچنین، محدودیت سوم موجب می‌شود تا عدم قطعیت بردارهای باور به صورت غیر ضمنی کاسته شود.

باید به این نکته توجه داشت که انتظار داریم بردارهای باور ثانویه برای یک بخش<sup>۲</sup> از یک عمل

<sup>۱</sup> Smoothing

<sup>۲</sup> Segment

با هم مساوی باشند. محدودیت دوم در جدول ۲-۴ این انتظار را برآورده می‌کند (این موضوع به نوعی در [۱۱۵] و [۱۱۶] بیان شده است).

محدودیت‌های جدول ۲-۴ می‌توانند با هم ترکیب شده و یک تابع هدف غیر محدب را تشکیل دهند. با مینیمم‌سازی این تابع هدف، بردارهای باور ثانویه به دست می‌آیند. بدین منظور، حل مساله بهینه‌سازی رابطه (۷-۴) را پیشنهاد می‌دهیم.

$$\mathbf{M} = \underset{\widehat{\mathbf{M}} \in \mathbb{R}^{T \times n}}{\operatorname{argmin}} \left( \sum_{i=1}^T \frac{1}{u(b_i)} \|\mathbf{b}_i - \widehat{\mathbf{M}}_i\|_2 + \lambda \sum_{i=1}^{T-1} \|\widehat{\mathbf{M}}_{i+1} - \widehat{\mathbf{M}}_i\|_2 + \gamma \sum_{i=1}^T u(\widehat{\mathbf{M}}_i) \right),$$

$$\text{s. t. } \begin{cases} \sum_{j=1}^n \widehat{M}_{i,j} = 1, & \forall i = 1, \dots, T \\ \widehat{M}_{i,j} \geq 0, & \forall i = 1, \dots, T, \text{ and } \forall j = 1, \dots, n \end{cases} \quad (7-4)$$

که در آن،  $\widehat{\mathbf{M}}_i \in \mathbb{R}^n$  و  $\mathbf{M}_i \in \mathbb{R}^n$ ، به ترتیب، سطرهای ماتریس‌های  $\widehat{\mathbf{M}} \in \mathbb{R}^{T \times n}$  و  $\mathbf{M} \in \mathbb{R}^{T \times n}$  هستند. همچنین،  $\lambda > 0$  و  $\gamma > 0$  پارامترهای تنظیم<sup>۱</sup> می‌باشند که با استفاده از مجموعه آموزشی مقداردهی می‌شوند.

در مساله بهینه‌سازی رابطه (۷-۴)، اولین عبارت، اولین شرط از جدول ۲-۴ را اعمال می‌کند. زیرا اگر عدم قطعیت کاهش داده شود، ضریب  $\frac{1}{u(b_i)}$  افزایش می‌یابد. بنابر این، در فرآیند مینیمم‌سازی بردار  $\mathbf{M}_i$  نزدیک به  $\mathbf{b}_i$  تعیین می‌گردد تا مقدار اولین عبارت را تعدیل کند.

جمله دوم در رابطه (۷-۴) دومین محدودیت جدول ۲-۴ را اعمال می‌کند. در واقع، این عبارت مجموع نرم‌آهای  $l_2$  بوده و بنابر این، منجر به پاسخ‌هایی می‌شود که در آنها تعداد زیادی از  $\mathbf{M}_i$  ها با

<sup>۱</sup> Regularization parameters

<sup>۲</sup> Norm

هم برابر هستند. کمینه سازی این جمله تعداد بخش‌های اعمال را محدود می‌کند. باید توجه داشت که توازنی بین جمله اول و دوم رابطه (۷-۴) وجود دارد. اولین جمله با  $T$  بخش مینیمم می‌شود در حالی که جمله دوم فقط با وجود یک بخش از اعمال مینیمم خواهد شد. این توازن با پارامتر  $\lambda$  کنترل می‌گردد. اگر  $\lambda$  افزایش یابد تعداد بخش‌های اعمال کاهش، و اگر  $\lambda$  کاهش یابد تعداد بخش‌ها افزایش خواهد یافت.

جمله سوم در رابطه (۷-۴)، سومین محدودیت جدول ۲-۴ را مستقیماً اعمال می‌کند. زیرا این جمله حاصل جمع عدم قطعیت SBV ها است. همچنین، پارامتر  $\gamma > 0$  مجموع مقدار عدم قطعیتی را کنترل می‌کند که SBV ها می‌توانند داشته باشند. افزایش (یا کاهش) این پارامتر باعث کاهش (یا افزایش) مجموع عدم قطعیت SBV ها خواهد شد. مثلاً اگر مقدار  $\gamma$  به مثبت بینهایت میل کند (مقدار بسیار بزرگی باشد)، آنگاه عدم قطعیت محاسبه شده در SBV ها به سمت صفر میل خواهد کرد.

باید توجه داشت که محدودیت‌های مساله بهینه سازی رابطه (۷-۴) تضمین کننده ویژگی‌های ذاتی بردارهای باور ثانویه خواهند بود. از آنجا که دو جمله اول رابطه (۷-۴) محدب و جمله سوم مقعر است، و نیز محدودیت‌های این مساله بهینه سازی همگی محدب هستند، لذا رابطه (۷-۴) یک مساله بهینه سازی تفاضل محدب (DCP) را نشان می‌دهد. این مساله را با استفاده از الگوریتم استاندارد CCP حل کرده و مقادیر بردارهای باور ثانویه را به دست می‌آوریم.

پس از محاسبه بردارهای باور ثانویه، یعنی  $\mathbf{M}_i \in \mathbb{R}^n, i = 1, \dots, T$ ، برای دنباله داده‌های  $\alpha_{1:T}$  برچسب عمل مربوط به رویداد  $i$  ام در دنباله داده‌های حسگرها، موسوم به  $l_i$ ، با رابطه زیر به دست می‌آید:

$$l_i = \operatorname{argmax}_j (M_{i,j}). \quad (۸-۴)$$

لازم به ذکر است که اگر عبارت مربوط به عدم قطعیت را از رابطه (۷-۴) حذف کنیم، رابطه (۹-۴) را خواهیم داشت. با تعبیری مشابه آنچه برای رابطه (۷-۴) انجام شد، این رابطه را نیز برای محاسبه بردارهای باور ثانویه پیشنهاد می‌دهیم. این رابطه صرفاً بر این مفروضات استوار است که بردارهای باور ثانویه باید حتی الامکان به بردارهای باور اولیه نزدیک باشند، و نیز آنکه تعداد بخش‌های داده‌ای اعمال محدود است. در این حالت، دیگر عدم قطعیت بردارهای باور نقشی در استنتاج ایفا نمی‌کند. از سوی دیگر، این رابطه بیانگر یک مساله بهینه‌سازی محدب است. لذا این راهکار را  $CPAR^1$  می‌نامیم و در شبیه‌سازی‌ها، خروجی‌های روابط (۷-۴) و (۹-۴) را نیز مقایسه می‌کنیم. این مقایسه می‌تواند تاثیر عدم قطعیت در استنتاج اعمال را بیان کند.

$$M = \underset{\hat{M} \in \mathbb{R}^{T \times n}}{\operatorname{argmin}} \left( \sum_{i=1}^T \|b_i - \hat{M}_i\|_2 + \lambda \sum_{i=1}^{T-1} \|\hat{M}_{i+1} - \hat{M}_i\|_2 \right) \quad (9-4)$$

$$\text{s. t. } \begin{cases} \sum_{j=1}^n \hat{M}_{i,j} = 1, & \forall i = 1, \dots, T \\ \hat{M}_{i,j} \geq 0, & \forall i = 1, \dots, T, \text{ and } \forall j = 1, \dots, n \end{cases}$$

حل مسائل بهینه‌سازی روابط (۸-۴) و (۹-۴) به روش مورد استفاده برای بهینه‌سازی بستگی دارد. مثلاً اگر از روش نقطه میانی برای حل یک معادله محدب استفاده کنیم، آنگاه پیچیدگی زمانی در حالتی خاص، از مرتبه  $\theta(v^3)$  خواهد بود که  $v$  تعداد متغیرها را نشان می‌دهد. با توجه به اینکه مساله بهینه‌سازی رابطه (۹-۴) در فرآیند حل، خود ممکن است به مسائل دوگان با تعداد متغیرهای بیشتری تبدیل گردد، لذا پیچیدگی زمانی حل در بهترین حالت، از مرتبه  $\Omega(v^3)$  می‌باشد؛ از طرفی، با داشتن  $v = nT$ ، پیچیدگی زمانی بهترین حالت در حل این مساله  $\Omega(n^3 T^3)$  می‌باشد. در حل مساله DCP رابطه (۸-۴)، اگر تعداد تکرارهای الگوریتم حل CCP را  $k$  در نظر بگیریم، آنگاه پیچیدگی زمانی کل

<sup>1</sup> Convex programming-based activity recognition

برای حل این رابطه در بهترین حالت از مرتبه  $\Omega(kn^3T^3)$  می‌باشد. در پیاده سازی‌ها، پارامتر  $k$  را برابر با ۱۰ در نظر گرفته‌ایم. با در نظر گرفتن این تحلیل، ملاحظه می‌شود که در بهترین حالت، پیچیدگی زمانی CPAR و DCPAR در مرحله آزمون از مرتبه چندجمله‌ای هستند. در صورت طولانی بودن دنباله داده ورودی، برای کاهش زمان حل، می‌توان زیر دنباله‌هایی غیر همپوشان، با طول مناسب از جریان داده حسگرها را در نظر گرفت و با هموار ساختن آنها، بردارهای باور ثانویه را محاسبه نمود.

## ۴-۴ پیاده سازی و ارزیابی

دو آزمایش برای ارزیابی روش پیشنهادی (DCPAR) صورت گرفت. در اولین آزمایش، DCPAR با چهار روش مبتنی بر مدل‌های گرافیکی HMM، CRF و SCCRIF مقایسه شد. در آزمایش دوم، DCPAR را با CPAR مورد مقایسه قرار دادیم تا تاثیر حذف عدم قطعیت را نیز بررسی نمائیم. برای ارزیابی از یک مجموعه داده موسوم به کیوتو<sup>۱</sup> [۷۵] از مجموعه داده‌های CASAS استفاده کردیم (جدول ۳-۴).

جدول ۳-۴. اعمال انجام شده توسط کاربران در مجموعه داده مرجع [۷۵].


| ID | Activity label            | Number of sensor events | ID | Activity label        | Number of sensor events |
|----|---------------------------|-------------------------|----|-----------------------|-------------------------|
| 1  | Fill medication dispenser | 624                     | 5  | Prepare birthday card | 854                     |
| 2  | Watch DVD                 | 1100                    | 6  | Prepare soup          | 1251                    |
| 3  | Water plants              | 1090                    | 7  | Cleaning              | 1765                    |
| 4  | Answer the phone          | 412                     | 8  | Choose outfit         | 564                     |

در این مجموعه داده، ۲۰ کاربر در یک آپارتمان، ۸ عمل روزمره را به شکل‌های مختلف (ترتیبی و متداخل) انجام می‌دهند (جدول ۳-۴). ۷۲ حسگر مختلف دودویی و ۶ حسگر با دامنه پیوسته (مثل

<sup>۱</sup> Kyoto

دما، و غیره) در محیط تعبیه شده است. دامنه حسگرهای پیوسته را به سه زیربازه افراز کردیم. در مجموع ۱۶۲ رویداد ممکن برای حسگرها وجود خواهد داشت.

مشابه فصل قبل، از معیارهای صحت<sup>۱</sup>، دقت<sup>۲</sup>، F-measure، و یادآوری<sup>۳</sup> توام با استراتژی LOOCV استفاده نمودیم. در هر دور از استراتژی LOOCV داده‌های یکی از کاربران را به عنوان نمونه آزمون و بقیه را به عنوان نمونه آموزشی استفاده کردیم. در روش DCPAR (مبتنی بر رابطه DCP (۷-۴)) مقدار  $\lambda$  و  $\gamma$  را با جستجوی شبکه‌ای<sup>۴</sup> طوری تعیین کردیم که صحت رده‌بندی روی مجموعه آموزشی ماکزیمم گردد. در همه دورها مقدار  $\lambda = 14$  و  $\gamma = 3$  بیشترین صحت (و یا نزدیک به بیشترین صحت) را حاصل آورد. لذا این مقادیر را انتخاب کردیم (شکل ۷-۴). به طور مشابه،  $\lambda = 1.5$  برای روش CPAR بیشترین (یا نزدیک به بیشترین) صحت را در پی داشت.



شکل ۷-۴. نتایج جستجو برای پارامترهای  $\lambda$  و  $\gamma$  در اولین دور از LOOCV.

## ۱-۴-۴ آزمایش اول

در پیاده‌سازی HMM، مشابه بسیاری از رویکردها، مانند [۸]، [۱۲]، و [۱۱۴]، پیاده‌سازی را

---

<sup>۱</sup> Accuracy  
<sup>۲</sup> Precision  
<sup>۳</sup> Recall  
<sup>۴</sup> Grid search



انجام دادیم. بدین منظور، متغیرهای مخفی را مربوط به اعمال، و داده‌های حسگرها را به عنوان مشاهدات در نظر گرفتیم. HMM را با MLE آموزش داده و از الگوریتم ویتربی برای استنتاج استفاده کردیم. نتایج ارزیابی در جدول ۴-۴ نمایش داده شده است. همانطور که مشاهده می‌شود، در تمام حالات به طور میانگین روش پیشنهادی دارای دقت، یادآوری، و F-measure بالاتری نسبت به HMM است. میانگین بالاتر و نیز واریانس پایین‌تر روش پیشنهادی برای مقیاس‌های ارزیابی، نشان دهنده این موضوع است که این روش ثبات بیشتری نسبت به HMM در تشخیص اعمال مختلف را دارا است. همچنین، با توجه به شکل ۴-۸ ملاحظه می‌شود که صحت روش پیشنهادی با  $0.82/0.61$  بسیار بهتر از صحت HMM (با  $0.76/0.83$ ) می‌باشد.

جدول ۴-۴. مقایسه HMM با DCPAR

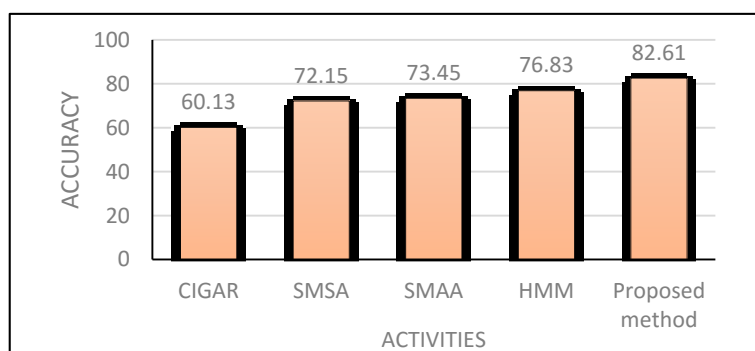
| Activity ID | Precision |              | Recall |              | F-Measure    |              |
|-------------|-----------|--------------|--------|--------------|--------------|--------------|
|             | HMM       | DCPAR        | HMM    | DCPAR        | HMM          | DCPAR        |
| 1           | 0.810     | 0.937        | 0.827  | 0.808        | 0.818        | <b>0.867</b> |
| 2           | 0.729     | 0.926        | 0.860  | 0.750        | 0.790        | <b>0.829</b> |
| 3           | 0.809     | 0.742        | 0.862  | 0.759        | <b>0.834</b> | 0.750        |
| 4           | 0.181     | 0.696        | 0.244  | 0.682        | 0.208        | <b>0.689</b> |
| 5           | 0.841     | 0.805        | 0.850  | 0.904        | 0.845        | <b>0.852</b> |
| 6           | 0.891     | 0.874        | 0.830  | 0.884        | 0.860        | <b>0.879</b> |
| 7           | 0.720     | 0.781        | 0.645  | 0.865        | 0.681        | <b>0.821</b> |
| 8           | 0.842     | 0.912        | 0.853  | 0.862        | 0.847        | <b>0.886</b> |
| Average     | 0.728     | <b>0.835</b> | 0.747  | <b>0.814</b> | 0.735        | <b>0.823</b> |
| Variance    | 0.052     | <b>0.008</b> | 0.046  | <b>0.006</b> | 0.049        | <b>0.005</b> |

در ادامه، دو پیاده سازی مختلف از CRF خطی (LCCRF) مشابه رویکردهای مطرح شده در [۸]، [۱۲]، و [۱۱۷]، برای شناسایی اعمال انجام گرفته است. در رویکرد اول، به ازای هر عمل، یک مدل CRF با دو حالت مخفی Y و N انجام گرفت که به ترتیب مربوط به "رخداد" و "عدم رخداد" آن عمل می‌باشند. این رویکرد را SMSA<sup>۱</sup> نامیدیم. در رویکرد دوم، برای همه اعمال یک مدل آموزش داده شد. اعمال را به عنوان متغیرهای مخفی و داده‌های حسگرها را به عنوان مشاهدات در نظر گرفتیم. این رویکرد را SMAA نامیدیم. علاوه بر LCCRF، CRF با زنجیره پرش را نیز مورد ارزیابی قرار دادیم. بدین

<sup>۱</sup> Single model single activity

منظور رویکرد موسوم به CIGAR را مطابق با [۶۵]، پیاده سازی کردیم. در این رویکرد اگر احتمال رخداد دو مشاهده پشت سر هم از یک حد آستانه بیشتر باشد، یک زنجیره پرش در ساختار LCCRF بین وضعیت‌های مخفی مربوط به آن دو مشاهده درج خواهد شد.

نتایج مربوط به مقایسه DCPAR، SMAA، SMSA، و SCCRف در جدول ۴-۵ نمایش داده شده است. همانطور که مشاهده می‌شود، مجدداً روش پیشنهادی با ۸۲/۲۳٪ میانگین F-measure بالاتری نسبت به بقیه داشته است. همچنین ملاحظه می‌شود که میانگین یادآوری و دقت روش پیشنهادی از بقیه بیشتر و واریانس آن کمترین است. لازم به ذکر است که عملکرد پایین CIGAR به دلیل درج زنجیره‌های پرش ناصحیح در ساختار آن است که در این روش اجتناب ناپذیر می‌باشد. همچنین، همانطور که در شکل ۴-۸ ملاحظه می‌شود، روش پیشنهادی با ۸۲/۳٪ بالاترین صحت را نسبت به دیگر روش‌های مبتنی بر مدل‌های گرافیکی به دست آورده است.



شکل ۴-۱. مقایسه صحت روش‌های مختلف.

جدول ۴-۵. نتایج ارزیابی برای روش‌های DCPAR، SMAA، SMSA، و SCCRف.

| Activity ID | Precision |       |       |              | Recall |       |       |              | F-Measure |              |              |              |
|-------------|-----------|-------|-------|--------------|--------|-------|-------|--------------|-----------|--------------|--------------|--------------|
|             | CIGAR     | SMSA  | SMAA  | DCPAR        | CIGAR  | SMSA  | SMAA  | DCPAR        | CIGAR     | SMSA         | SMAA         | DCPAR        |
| 1           | 0.654     | 0.117 | 0.923 | 0.937        | 0.027  | 0.973 | 0.575 | 0.808        | 0.052     | 0.209        | 0.709        | <b>0.867</b> |
| 2           | 0.870     | 0.681 | 0.752 | 0.926        | 0.576  | 0.914 | 0.816 | 0.750        | 0.693     | 0.780        | 0.782        | <b>0.829</b> |
| 3           | 0.824     | 0.739 | 0.947 | 0.742        | 0.395  | 0.817 | 0.343 | 0.759        | 0.534     | <b>0.776</b> | 0.504        | 0.750        |
| 4           | 0.298     | 0.117 | 0.526 | 0.696        | 0.087  | 0.676 | 0.097 | 0.682        | 0.135     | 0.199        | 0.164        | <b>0.689</b> |
| 5           | 0.803     | 0.831 | 0.855 | 0.805        | 0.754  | 0.873 | 0.855 | 0.904        | 0.778     | 0.852        | <b>0.855</b> | 0.852        |
| 6           | 0.589     | 0.847 | 0.805 | 0.874        | 0.810  | 0.626 | 0.846 | 0.884        | 0.682     | 0.720        | 0.825        | <b>0.879</b> |
| 7           | 0.477     | 0.958 | 0.595 | 0.781        | 0.955  | 0.624 | 0.948 | 0.865        | 0.637     | 0.756        | 0.731        | <b>0.821</b> |
| 8           | 0.694     | 0.693 | 0.789 | 0.912        | 0.257  | 0.905 | 0.876 | 0.862        | 0.375     | 0.785        | 0.830        | <b>0.886</b> |
| Average     | 0.650     | 0.624 | 0.774 | <b>0.835</b> | 0.485  | 0.801 | 0.671 | <b>0.814</b> | 0.486     | 0.636        | 0.673        | <b>0.823</b> |
| Variance    | 0.037     | 0.105 | 0.021 | <b>0.008</b> | 0.119  | 0.019 | 0.093 | <b>0.006</b> | 0.073     | 0.072        | 0.055        | <b>0.005</b> |

## ۴-۲-۴ آزمایش دوم

در این آزمایش، روش پیشنهادی (DCPAR) با CPAR (مبتنی بر بهینه سازی محدب رابطه (۴-۹)) مورد مقایسه قرار گرفته است. نتایج ارزیابی در جدول ۴-۶ آورده شده است. همانطور که ملاحظه می‌شود، روش پیشنهادی در تمامی حالات عملکرد بهتری نسبت به CPAR داشته است. این مساله نشان می‌دهد که مدیریت عدم قطعیت در معادله (۴-۷) امید بخش بوده است. اما این نکته را نیز باید در نظر گرفت که در مقایسه با دیگر روش‌ها (HMM, SMSA, SMAA, و CIGAR) روش CPAR عملکرد مناسبی را از خود نشان داده است. در واقع CPAR با  $F\text{-measure } 0.782$ ،  $F\text{-measure } 0.769$ ، و یادآوری، و  $0.823$  دقت، بعد از DCPAR، بهترین نتایج را به دست آورده است.

جدول ۴-۶. نتایج ارزیابی برای مقایسه DCPAR و CPAR.

| Activity ID | Precision    |              | Recall |              | F-Measure |              |
|-------------|--------------|--------------|--------|--------------|-----------|--------------|
|             | CPAR         | DCPAR        | CPAR   | DCPAR        | CPAR      | DCPAR        |
| 1           | 0.919        | 0.937        | 0.747  | 0.808        | 0.824     | <b>0.867</b> |
| 2           | 0.896        | 0.926        | 0.675  | 0.750        | 0.770     | <b>0.829</b> |
| 3           | 0.890        | 0.742        | 0.648  | 0.759        | 0.750     | <b>0.750</b> |
| 4           | 0.797        | 0.696        | 0.476  | 0.682        | 0.596     | <b>0.689</b> |
| 5           | 0.753        | 0.805        | 0.936  | 0.904        | 0.834     | <b>0.852</b> |
| 6           | 0.797        | 0.874        | 0.890  | 0.884        | 0.841     | <b>0.879</b> |
| 7           | 0.728        | 0.781        | 0.916  | 0.865        | 0.811     | <b>0.821</b> |
| 8           | 0.802        | 0.912        | 0.863  | 0.862        | 0.832     | <b>0.886</b> |
| Average     | 0.823        | <b>0.835</b> | 0.769  | <b>0.814</b> | 0.782     | <b>0.823</b> |
| Variance    | <b>0.005</b> | 0.008        | 0.026  | <b>0.006</b> | 0.007     | <b>0.005</b> |

## ۴-۵ جمع بندی

در این فصل، دو راهکار، یکی مبتنی بر برنامه ریزی تفاضل محدب (DCPAR) و دیگری بر مبنای برنامه ریزی محدب (موسوم به CPAR) را برای شناسایی اعمال ارائه نمودیم. در هر دوی این روش‌ها ابتدا بردارهای باور اولیه‌ای که نشان دهنده میزان باور در خصوص عمل در حال انجام است، محاسبه می‌شوند. سپس، این بردارهای باور با در نظر گرفتن مفروضاتی که غالباً در خانه‌های (محیط‌های) هوشمند برقرار هستند، طی یک فرآیند بهینه سازی، اصلاح (هموار) می‌شوند. در راهکار مبتنی بر DCPAR،

عدم قطعیت تصمیم‌گیری در خصوص عمل در حال انجام را با در نظر گرفتن باورهای القا شده در یک همسایگی از جریان داده‌های حسگرها کاهش می‌دهیم. نتایج نشان می‌دهند که هر دو روش پیشنهادی عملکردی بهتر از روش‌های معیار<sup>۱</sup>، که مبتنی بر مدل‌های گرافیکی احتمالاتی رایج (مانند CRF، HMM و SCCRF) هستند، دارند. همچنین، ارزیابی‌ها نشان دادند که با در نظر گرفتن عدم قطعیت (به صورت آنتروپی) و حل مساله DCP مربوطه، عملکرد روش پیشنهادی نسبت به روش CPAR بهتر خواهد بود.

---

<sup>۱</sup> Benchmark

## فصل ۵. بازشناسی اعمال در محیط‌های با چند کاربر

## ۵-۱ مقدمه

در فصل‌های گذشته تا کنون به شناسایی اعمال کاربران در محیط‌های تک کاربره، مطابق با لایه دوم معماری پیشنهادی پرداختیم. روش‌های عنوان شده قابلیت به‌کارگیری در محیط‌های با بیش از یک کاربر را ندارند. زیرا در این روش‌ها به صورت ضمنی فرض بر این بوده که جریان داده حسگرها توسط یک کاربر ایجاد شده و رویدادهای هم‌جوار در جریان داده حسگرها آنها مربوط به یک کاربر هستند. به عنوان مثال، بر همین اساس بود که در فصل قبل عدم قطعیت یک بردار باور را با استفاده از بردارهای باور مجاور آن هموار می‌کردیم. در واقع در محیطی تک کاربره ارتباط معنی داری بین رویدادهای حسگرهای هم‌جوار در جریان داده حسگرها و در طول زمان وجود دارد. اما در محیط‌های با بیش از یک کاربر، هم‌جوار بودن دو رویداد حسگر لزوماً به معنی ارتباط معنی دار بین آنها نیست. در واقع این ارتباط می‌تواند بسیار کم باشد. زیرا در این محیط‌ها امکان انجام چند کار متفاوت به صورت هم‌روند وجود خواهد داشت و با توجه به تنوع رفتاری هر کاربر، هم‌روند شدن همیشگی دو یا چند عمل خاص معمولاً با نرخ بالایی رخ نخواهد داد. مثلاً در یک محیط با دو کاربر، اگر کاربر اول در آشپزخانه به آشپزی مشغول باشد و کاربر دوم در اتاق خواب در حال استراحت باشد، آنگاه در اثر انجام دو عمل متفاوت، هر کاربر حسگرهای متفاوتی را تحریک می‌کند. مثلاً کاربر اول حسگرهای حرکتی موجود در محیط آشپزخانه و نیز حسگرهای دو‌حالتی واقع بر درب کابینت‌ها را تحریک خواهد کرد و کاربر دوم حسگرهای حرکتی واقع در اتاق خواب، و نیز حسگر فشار نصب شده در تخت خواب را تحریک خواهد کرد. در این وضعیت، داده‌های دو عمل متفاوت در جریان داده‌های حسگرها در لایه لای هم قرار خواهند گرفت و اصطلاحاً در هم تنیده<sup>۱</sup> خواهند شد. لذا، داده‌های مجاور به هم در جریان داده‌های حسگرها، با

---

<sup>۱</sup> Interwoven

احتمال بسیار بالایی مربوط به اعمالی متفاوتی هستند و ارتباط معنی داری با هم نخواهند داشت. به بیان دیگر، می توان گفت در این شرایط طول بخش های<sup>۱</sup> داده ای متوالی مربوط به یک عمل در جریان داده حسگرها بسیار کوچک خواهد شد، طوریکه عدم شهود کافی در هر بخش مانع از تشخیص درست عمل مربوط به یک داده حسگر خواهد بود. لازم به ذکر است که در این شرایط، جریان داده حسگرها را داده های مجتمع<sup>۲</sup> می نامند.

در این فصل، به شناسایی اعمال در یک محیط چند کاربره مطابق با لایه سوم معماری پیشنهادی خواهیم پرداخت. لایه سوم این معماری مجددا در شکل ۵-۱ آورده شده است. مطابق با ساختار این لایه، به منظور مدل سازی داده های کاربران فرض می کنیم که این دنباله داده ها مطابق با یک زنجیره مارکوف واحد تولید می شوند. لذا ابتدا بیان خواهیم کرد که چگونه می توان یک مدل مارکوف<sup>۳</sup> را با استفاده از دنباله داده های درهم تنیده کاربران آموزش داد. این کار بسیار چالش برانگیز است زیرا داده های کاربران در مجموعه آموزشی صرفا با عمل مربوط به آنان برچسب زده شده اند نه با شناسه کاربران. لذا در عمل، جدا سازی دنباله داده های کاربران و سپس آموزش مدل مارکوف امکان پذیر نمی باشد. بنابراین، این کار را بدون جدا سازی دستی دنباله های معنی دار، از داده های مجتمع انجام خواهیم داد. سپس، مطابق با ساختار لایه سوم (شکل ۵-۱)، از مدل استخراج شده در یک رویکرد مبتنی بر فیلتر ذرات<sup>۴</sup> برای جداسازی دنباله داده های کاربران در محیط استفاده خواهیم کرد. پس از استخراج این دنباله ها، با استفاده از الگوریتم های ارائه شده برای شناسایی اعمال در محیط تک کاربره فصل گذشته (الگوریتم های DCPAR و CPAR)، اعمال کاربران را روی این دنباله ها استنتاج خواهیم کرد.


---

<sup>۱</sup> Segment

<sup>۲</sup> Aggregate data

<sup>۳</sup> Markov model

<sup>۴</sup> Particle filter



شکل ۵-۱. لایه سوم معماری پیشنهادی.

## ۵-۲ مدل سازی دنباله داده های کاربره

در این بخش به بیان نحوه آموزش یک زنجیره مارکوف برای تولید دنباله های معنی دار که مربوط هریک می تواند مربوط به یک کاربر باشد می پردازیم.

### ۵-۲-۱ ساختار شبکه حسگر، و وضعیت های محیط

همانطور که قبلا نیز بیان شد، حسگرها را به صورت دودویی با دو وضعیت ۰ و ۱ در نظر میگیریم. این حسگرها می توانند حسگرهای حرکتی (یا مجاورت) باشند که حضور شخص را تشخیص می دهند، و یا حسگرهایی دو وضعیتی باشند که روی اشیاء مختلف محیط نصب شده اند. این حسگرها تعامل کاربر با اشیاء یا محیط را نشان می دهند. هر زمان که کاربر تعاملی با یک شیء دارد، حسگر مربوط به آن شیء مقدار ۱ و در غیر این صورت مقدار صفر را به عنوان خروجی برمی گرداند. هرچند، اگر حسگرها دودویی نیز نباشند می توان داده های آنها را به این شکل تبدیل کرد.

مقدار همه حسگرهای محیطی در هر بازه زمانی نشانگر وضعیت محیط در آن بازه است. برای محاسبه وضعیت محیط، زمان را به برش های کوچک به اندازه  $\Delta t$  تقسیم بندی کرده و برای هر بازه




مطابق با تعریف ۱-۵ برداری را حساب می‌کنیم که وضعیت محیط را نشان می‌دهد. بازه  $\Delta t$  را آنقدر کوچک فرض می‌کنیم که تحریک هر حسگر در آن را بتوان صرفاً به یک کاربر نسبت داد.

**تعریف ۱-۵. (بردار وضعیت محیط).** با داشتن  $n$  حسگر، برداری مثل  $x_t \in \{0,1\}^n$  را برای برش

زمانی  $t$  ام محاسبه می‌کنیم طوری که عنصر  $i$  ام آن، یعنی  $x_{t,i}$ ، مقدار حسگر  $i$  ام در این برش زمانی را نشان دهد.  $x_t$  بردار وضعیت محیط در زمان  $t$  نامیده می‌شود.


شکل ۲-۵ مثالی از مقادیر حسگرها و بردارهای وضعیت محیط در یک محیط AAL با دو کاربر و سه حسگر را نشان می‌دهد. هر حسگر با یک دایره در کنار خروجی آن نمایش داده شده است. بردار وضعیت محیط به صورت یک ماتریس در قسمت پایین نمودار نشان داده شده است. هر ستون در این ماتریس مقدار بردار وضعیت محیط در یک بازه زمانی را نشان می‌دهد. خروجی هم‌زمان صفر برای همه حسگرها نشان دهنده عدم تعامل کاربران با محیط و یا اشیاء (غیر فعال بودن کاربران) است. به عنوان مثال، این مساله می‌تواند زمانی اتفاق بیفتد که کاربران در محیط حضور ندارند. در چنین شرایطی، آخرین محیط حفظ خواهد شد. لذا چنین بازه‌های زمانی را حذف می‌کنیم. ناحیه مشخص شده در شکل ۲-۵ چنین بازه زمانی را نشان می‌دهد.



شکل ۲-۵. مثالی از نحوه فعال شدن حسگرها در محیطی با دو کاربر و سه حسگر.

## ۲-۲-۵ دنباله داده‌های کاربران و بیان مساله مدل‌سازی آنها

دنباله داده‌های یک کاربر را به صورت دنباله‌ای از شناسه حسگرهای فعال شده در نظر می‌گیریم که توسط او در طول زمان فعال شده است. مثالی از دنباله داده‌های کاربران در شکل ۳-۵ در پایین نمودار و به رنگ خاکستری نشان داده شده است. این نمودار مربوط به شکل ۲-۵ است، که در آن دنباله داده‌های کاربران به تفکیک مشخص شده‌اند. دنباله داده‌های کاربران با فلش‌های خاکستری و سیاه، به ترتیب، برای کاربر ۱ و ۲ بر روی دیاگرام زمانی مشخص شده‌اند. توجه داریم که در بعضی حالات، یک کاربر ممکن است بیش از یک دنباله داده را تولید کند. این بدان علت است که کاربر ممکن است هم‌روند با چند شیء تعامل داشته باشد. مثلاً برای کاربر ۲ در برش زمانی ۲۳ تا ۲۷ این اتفاق رخ داده است. در واقع، در چنین مواردی، کاربر بیش از یک دنباله داده تولید کرده است.



شکل ۳-۵. نحوه ایجاد داده‌های مجتمع توسط دنباله داده‌های کاربران.

با تعاریف و توضیحات فوق، قصد داریم یک مدل مارکوف را طوری آموزش دهیم تا بتواند دنباله

داده‌های تشکیل دهنده داده‌های مجتمع را تولید کند. توجه داریم که برای این کار از دنباله‌های معنی دار از قبل تفکیک شده استفاده نمی‌کنیم. برای این منظور، یک زنجیره مارکوف ارگودیک<sup>۱</sup> و زمان-همگن را بر روی فضای وضعیت  $S = \{1, \dots, n\}$  که  $S$  مجموعه حسگرها و  $n$  تعداد حسگرها را نشان می‌دهد، در نظر می‌گیریم؛ همچنین، شناسه حسگرها را از ۱ تا  $n$  تعریف می‌کنیم. از آنجا که زنجیره مارکوف را ایستا فرض کرده‌ایم، پارامترهای آن مستقل از زمان خواهند بود. بنابراین، اگر دنباله‌ای مثل  $R = r_1, r_2, \dots, r_T, r_i \in S$  داشته باشیم، احتمال آن با رابطه (۱-۵) به دست خواهد آمد.

$$p(R) = \pi(r_1) \prod_{t=1}^{T-1} P(r_t, r_{t+1}), \quad (1-5)$$

که در آن  $P$  ماتریس انتقال  $n \times n$  است، طوری که  $P(i, j)$  احتمال انتقال از حسگر  $i$  به حسگر  $j$  را نشان می‌دهد، و بردار  $\pi \in \mathbb{R}^n$  توزیع احتمال آغازین وضعیت‌ها می‌باشد، که با توجه به ایستا بودن زنجیره مارکوف، با رابطه (۲-۵) حساب می‌شود.

$$\pi^T P = \pi^T. \quad (2-5)$$

حال، مساله تخمین پارامترهای زنجیره مارکوف را در نظر می‌گیریم. از آنجا که زنجیره مارکوف را ایستا در نظر گرفته‌ایم، تنها پارامتری که باید تخمین بزنیم، ماتریس انتقال  $P$  می‌باشد (توزیع احتمال آغازین با رابطه (۲-۵) به دست خواهد آمد). اگر دنباله داده کاربر از قبل تفکیک شده باشد، انگاه می‌توان از الگوریتم MLE با رابطه (۳-۵) برای تخمین ماتریس انتقال استفاده کرد.

$$P(i, j) = \frac{N(i \rightarrow j)}{N(i)}, \quad (3-5)$$

---

<sup>۱</sup> Ergodic

در رابطه (۳-۵)،  $N(i \rightarrow j)$  مجموع تعداد دفعاتی است که حسگر  $i$  بعد از حسگر  $j$ ، و  $N(i)$  مجموع تعداد دفعاتی است که حسگر  $i$  به تنهایی در جریان داده‌های حسگرها ظاهر شده باشد. هرچند استفاده از MLE راهکاری مستقیم برای محاسبه ماتریس انتقال تلقی می‌شود، اما از آنجا که در عمل نمی‌توانیم جریان داده‌های کاربران تفکیک کنیم، استفاده از آن ناممکن خواهد بود. در واقع قصد داریم به صورت مستقیم، با استفاده از داده‌های تجمیع شده ماتریس انتقال را محاسبه کنیم. از MLE صرفاً برای محاسبه ماتریس انتقال حقیقی<sup>۱</sup>، به منظور ارزیابی روش پیشنهادی خود استفاده خواهیم نمود. مساله مدل‌سازی دنباله داده‌ها را به صورت زیر تعریف می‌کنیم:

**تعریف ۲-۵. (مساله مدل‌سازی دنباله داده‌ها).** با داشتن دنباله‌ای از بردارهای وضعیت

محیط، ماتریس انتقال یک زنجیره مارکوف ارگودیک، زمان-همگن، و ایستا را به گونه‌ای محاسبه کنید که بتواند دنباله داده‌های کاربران را به بهترین شکل تولید کند.

در ادامه، تخمین کم‌ترین مربعات شرطی (CLS<sup>۲</sup>) را برای حل مساله فوق‌الذکر معرفی، و

ویژگی‌های آن را بیان خواهیم کرد.

### ۳-۲-۵ تخمین کمترین مربعات شرطی (CLS)

CLS روشی سنتی برای محاسبه ماتریس انتقال یک زنجیره مارکوف به طور مستقیم، از روی داده‌های مجتمع می‌باشد [۱۱۸]. در CLS، فرض بر این است که برای یک دنباله از بردارهای وضعیت محیط به طول  $T$ ، بردار وضعیت  $x_t$  باید نزدیک به امید آن، به شرط داشتن  $x_{t-1}$  باشد. در واقع باید داشته باشیم:

$$\forall t \in 2, \dots, T \quad x_{t-1}^T P \approx x_t^T, \quad (۴-۵)$$

<sup>۱</sup> Ground truth

<sup>۲</sup> Conditional least squares

که در آن  $\mathbf{P}$   $\mathbf{x}_{t-1}^T \mathbf{P}$  امید  $\mathbf{x}_t^T$  به شرط  $\mathbf{x}_{t-1}^T$  می‌باشد. با توجه به رابطه (۴-۵)، ماتریس انتقال  $\mathbf{P}$  را با مینیمم سازی یک سیستم حداقل مربعات به صورت رابطه می‌توان محاسبه نمود.

$$\mathbf{P}_{CLS} = \underset{\hat{\mathbf{P}}}{\operatorname{argmin}} \left( \sum_{t=2}^T (\mathbf{x}_{t-1}^T \hat{\mathbf{P}} - \mathbf{x}_t^T)(\mathbf{x}_{t-1}^T \hat{\mathbf{P}} - \mathbf{x}_t^T)^T \right). \quad (۵-۵)$$

اگر  $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_{T-1}]^T$  و  $\mathbf{Y} = [\mathbf{x}_2, \dots, \mathbf{x}_T]^T$  را به ترتیب، به عنوان دنباله بردار وضعیت‌های فعلی و بعدی در نظر بگیریم، آنگاه رابطه (۵-۵) را می‌توان به صورت رابطه (۶-۵) ساده کرد.

$$\mathbf{P}_{CLS} = \underset{\hat{\mathbf{P}}}{\operatorname{argmin}} (\|\mathbf{X}\hat{\mathbf{P}} - \mathbf{Y}\|_F^2), \quad (۶-۵)$$

که در آن  $\|\cdot\|_F$  نرم فرابینیوس<sup>۱</sup> است. اگر بیش از یک دنباله از بردارهای وضعیت محیطی داشتیم، ماتریس‌های فعلی و بعدی آنها را به ترتیب، به انتهای ماتریس‌های  $\mathbf{X}$  و  $\mathbf{Y}$  اضافه می‌کنیم.

می‌دانیم که تخمین  $\mathbf{P}_{CLS}$  در شرایط تقریبی  $T \rightarrow \infty$ ، سازگار است (یعنی  $\operatorname{plim}_{T \rightarrow \infty} \mathbf{P}_{CLS} = \mathbf{P}$ )

[۱۱۸]. با این وجود دو ایراد در تخمین CLS وجود دارد: ۱- می‌توان ثابت کرد زمانی که داده‌ها مخدوش (دارای نویز) باشند، CLS ناسازگار خواهد بود [۱۱۹]، و ۲- دنباله با طول بینهایت از بردارهای وضعیت محیطی در عمل ممکن است رخ ندهد. بنابراین، پارامتر تخمین زده شده  $\mathbf{P}_{CLS}$  ممکن است در عمل توأم با خطا باشد. در بخش بعدی روشی برای مقابله با این مشکل پیشنهاد خواهیم کرد.

---

<sup>۱</sup> Frobenius norm

## ۴-۲-۵ روش پیشنهادی برای تخمین پارامترهای زنجیره مارکوف

همانطور که در بخش قبل بیان شد، تخمین CLS می‌تواند توام با خطا باشد. برای مقابله با این مشکل، تخمین‌های انجام شده توسط CLS را با استفاده از دانش پیشین که معمولاً در محیط‌های هوشمند عمومیت دارند، تنظیم<sup>۱</sup> می‌کنیم. این کار را با استفاده از ویژگی‌های توپولوژیکی شبکه حسگر مورد استفاده انجام می‌دهیم. در این بخش، ابتدا مفهوم گراف دسترسی را معرفی کرده و بر مبنای آن، فرضیه‌ای عمومی را برای بیان ارتباط بین احتمال انتقال حسگرها و موقعیت مکانی آنها ارائه می‌دهیم. سپس، فرآیند تنظیم پارامترها را با جزئیات بیان خواهیم کرد.

### ۱-۴-۲-۵ گراف دسترسی

برای یک شبکه حسگر که در خانه هوشمند پیاده سازی شده است، می‌توان یک گراف مطابق تعریف ۳-۵ ایجاد کرد که آن را گراف دسترسی می‌نامیم.

**تعریف ۳-۵. (گراف دسترسی<sup>۲</sup>).** اگر  $S = \{1, \dots, n\}$  مجموعه شناسه حسگرهای نصب شده در محیط را نشان دهد، آنگاه، گراف بدون جهت  $G = (V, E)$ ، که در آن  $V$  مجموعه رئوس، و  $E$  مجموعه یال‌های گراف است، گراف دسترسی شبکه حسگر خواهد بود اگر دو شرط زیر برقرار باشند:

$$V = S - 1$$

۲- یال  $e_{i,j} = (i, j)$ ،  $(i, j \in S)$ ، متعلق به مجموعه  $E$  است اگر و فقط اگر پس از تحریک حسگر  $i$ ، امکان تحریک (یا دسترسی) حسگر  $j$  بدون اینکه حسگر دیگری تحریک شود فراهم باشد.


در شکل ۴-۵ یک گراف دسترسی برای بخشی از یک خانه هوشمند نمایش داده شده است. در

---

<sup>۱</sup> Regularize

<sup>۲</sup> Accessibility graph

این شکل، شناسه‌هایی که با M، L، و D آغاز می‌شوند، به ترتیب نشان دهنده حسگرهای حرکتی، نور، و حسگرهای نصب شده بر روی درب‌ها هستند. به عنوان مثال، با توجه به شکل، اگر کاربر از نقطه A به نقطه B برود، پس از تحریک حسگر M023 و بدون تحریک حسگر دیگری، می‌تواند M022 را تحریک کند. لذا با توجه به تعریف گراف دسترسی، یک یال بین M023 و M022 در گراف قرار می‌گیرد. همین سناریو می‌تواند برای حسگرهای M023 و D012، با رفتن از نقطه A به نقطه B، و باز کردن درب مربوط به حسگر D012 اتفاق بیفتد. پس یالی بین این دو حسگر نیز در گراف درج می‌گردد.



شکل ۴-۵. گراف دسترسی برای بخشی از خانه هوشمند پیاده سازی شده در [۶۱].

از نظر شهودی، زمانی که یک کاربر با محیط یا اشیاء تعامل دارد، انتظار می‌رود که حسگرهای نزدیک به هم را تحریک کند. در [۵۸] این موضوع مورد بررسی قرار گرفته و با تحلیل آماری نشان داده شده که حسگرهایی که از نظر مکانی به هم نزدیک هستند امکان تحریک پشت سر هم آنها به هنگام انجام اعمال بسیار زیاد است. این مساله فرضیه زیر را القا می‌کند.

**فرضیه ۱-۵.** فرض کنید  $G = (V, E)$  یک گراف دسترسی را نشان دهد، و  $i$  و  $j$  دو راس از گراف  $G$  باشند. اگر  $D(i, j)$  فاصله بین  $i$  و  $j$  روی گراف دسترسی، و  $P(i, j)$  احتمال انتقال از حسگر  $i$  به  $j$  باشد، آنگاه هر قدر  $D(i, j)$  کمتر باشد، مقدار  $P(i, j)$  بیشتر خواهد بود.

فرضیه فوق در واقع ارتباط بین موقعیت مکانی حسگرها و احتمال انتقال بین آنها را بیان می‌کند. باید توجه داشت که افزایش یا کاهش  $P(i, j)$  در مقابل تغییرات فاصله مکانی می‌تواند خطی یا غیر خطی باشد. ما یک نرخ خطی متناسب با تابع نمایی فاصله بین حسگرها را در نظر گرفتیم. از فرضیه فوق برای تنظیم تخمین‌های CLS استفاده خواهیم کرد.

### ۲-۴-۲-۵ تنظیم تخمین‌های CLS

برای تنظیم تخمین‌های CLS، فرضیه ۱-۵ با یک رابطه ریاضی بیان گردید و به مساله بهینه‌سازی در CLS استاندارد، یعنی رابطه (۶-۵)، اضافه شد. در نتیجه، یک مساله بهینه‌سازی محدب جدید به صورت رابطه (۷-۵) دست آمد، که حاصل آن، تخمینی تنظیم شده از ماتریس انتقال خواهد بود. این تخمین را  $P_{proposed}$  می‌نامیم.

$$P_{Proposed} = \underset{\hat{P}}{\operatorname{argmin}} \left( \|X\hat{P} - Y\|_F^2 + \lambda \left( \| \exp(D) \cdot \hat{P} \|_F^2 \right) \right),$$

$$s. t. \begin{cases} \forall i \in \{1, \dots, n\} \quad \sum_{j=1}^n P_{proposed}(i, j) = 1 \\ \forall i, j \in \{1, \dots, n\} \quad P_{proposed}(i, j) \geq 0 \end{cases} \quad (7-5)$$

در رابطه (۷-۵)،  $X$  و  $Y$  همان تعاریف مورد استفاده در رابطه (۶-۵) را دارند،  $n$  تعداد حسگرها،  $\hat{P} \in \mathbb{R}^{n \times n}$  متغیر بهینه‌سازی،  $P_{Proposed} \in \mathbb{R}^{n \times n}$  ماتریس انتقال تخمین زده شده به روش پیشنهادی، و  $D \in \mathbb{R}^{n \times n}$  ماتریس فاصله بین حسگرها روی گراف دسترسی است. همچنین،  $\exp(\cdot)$



تابع نمایی، و  $exp(D)$ ، نشان دهنده ماتریسی است که با اعمال تابع نمایی بر روی عناصر ماتریس  $D$  به دست می‌آید. عملگر " " در این رابطه همان ضرب داخلی، و پارامتر  $\lambda \in \mathbb{R}^+$  ضریب تنظیم است که با استفاده از یک مجموعه آموزشی تعیین می‌گردد.

در مساله بهینه‌سازی محدب رابطه (۷-۵)، عبارت  $\|X\hat{P} - Y\|_F^2$  فرضیه اصلی در CLS را اعمال می‌کند (یعنی رابطه (۶-۵)). همچنین، عبارت  $\|exp(D) \cdot \hat{P}\|_F^2$  فرضیه ۱-۵ را در محاسبه ماتریس انتقال اعمال می‌کند. به این معنی که با افزایش فاصله  $D(i, j)$ ، مقدار  $exp(D(i, j))$  افزایش یافته و در نتیجه، در فرآیند بهینه‌سازی،  $\hat{P}(i, j)$  کاهش می‌یابد تا حاصل ضرب داخلی  $exp(D) \cdot \hat{P}$  تعدیل گردد. به طور مشابه، اگر مقدار  $D(i, j)$  کاهش یابد، آنگاه  $\hat{P}(i, j)$  افزایش خواهد یافت. بنابراین، عبارت  $\|exp(D) \cdot \hat{P}\|_F^2$  تنظیم تخمین را مطابق با فرضیه ۱-۵ انجام می‌دهد. همچنین، محدودیت‌های مساله بهینه‌سازی رابطه (۷-۵) تضمین می‌کنند که فرآیند تنظیم تخمین‌ها ویژگی‌های اصلی توزیع احتمال در ماتریس انتقال را نقض نمی‌کند، (یعنی مجموع هر سطر باید برابر ۱ و هر عنصر باید از صفر بزرگتر باشد).

به عنوان جمع‌بندی این بخش، به منظور مدل‌سازی دنباله داده‌های کاربران، یک زنجیره مارکوف واحد را در نظر می‌گیریم. برای محاسبه ماتریس انتقال این زنجیره، ماتریس فاصله بین حسگرها را در گراف دسترسی شبکه حسگر بیسیم محاسبه، و سپس با حل مساله بهینه‌سازی رابطه (۷-۵) ماتریس انتقال را به دست می‌آوریم.

### ۳-۵ استخراج دنباله داده‌های کاربران

در این بخش، به استخراج دنباله داده‌های کاربران از داده‌های مجتمع می‌پردازیم. بدین منظور، ماتریس انتقال تخمین زده شده زنجیره مارکوف را برای استخراج دنباله داده‌های کاربران به کار

می‌گیریم. برای استخراج این دنباله‌ها، مطابق با لایه سوم معماری پیشنهادی (شکل ۵-۱)، از یک روش مبتنی بر فیلتر ذرات بهره گرفته شده، و ماتریس انتقال تخمین زده شده به منظور امتیاز دهی به ذرات به کار گرفته شده است.

فرض کنید مجموعه شناسه حسگرها را با  $S = \{1, \dots, n\}$  و  $\mathcal{D} = \mathbf{x}_1, \dots, \mathbf{x}_T$  دنباله‌ای از بردارهای وضعیت محیط (یعنی همان داده‌های مجتمع) با طول  $T$  باشد. همچنین، فرض کنید  $k$  ماکزیمم تعداد کاربران در محیط را نشان دهد. در این صورت، دنباله داده‌های  $\mathbf{z}$  ام که مربوط به یک کاربر ناشناخته است را با  $tr_j$ ، نشان می‌دهیم. همچنین،  $tr_j(i) \subseteq \{1, \dots, n\}$  را شناسه  $i$  امین حسگر تحریک شده در  $i$  امین برش زمانی  $tr_j$  در نظر می‌گیریم. با این نمادگذاری، مساله استخراج دنباله داده‌های کاربران، موسوم به  $MUT^1$ ، را به فرم زیر تعریف می‌کنیم.

**تعریف ۴-۵. (مساله  $MUT$ ).** با داشتن داده‌های مجتمع  $\mathcal{D} = \mathbf{x}_1, \dots, \mathbf{x}_T$ ، و ماکزیمم تعداد

کاربران  $k$ ، حداکثر  $k$  دنباله  $\{tr_1, \dots, tr_k\}$  را طوری استخراج کنید که هر دنباله با امکان زیادی مربوط به یک کاربر بوده و محدودیت زیر نیز برقرار باشد:

$$\forall t \in \{1, \dots, T\}, \forall s \in \{1, \dots, n\}, \quad x_{t,s} = \max_j (\delta(s \in tr_j(t))), \quad (۸-۵)$$

که در آن  $\delta(\cdot)$  تابع نشانگر است.

محدودیت (۸-۵) تضمین می‌کند که تجمیع دنباله‌های استخراج شده مجدداً داده‌های مجتمع اولیه را ایجاد خواهد کرد. در [۱۲۰] نشان داده شده که مساله  $MUT$  را به صورت قطعی نمی‌توان حل کرد. لذا، برای حل این مساله از یک راهکار احتمالاتی مبتنی بر فیلتر ذرات بهره گرفته‌ایم.

---

<sup>1</sup> Mining users' traces

## ۵-۳-۱ الگوریتم فیلتر ذرات برای تفکیک دنباله داده‌های کاربران

ایده فیلتر ذرات برای تعقیب هدف، مبتنی بر حسگرهای دودویی در [۱۲۱] و [۱۲۲] مورد بررسی قرار گرفته است. در این کارها از فیلتر ذرات برای استخراج موقعیت مکانی افراد استفاده شده است. ما از ایده مربوط به این کارها برای حل مساله MUT استفاده می‌کنیم.


شبه کد الگوریتم فیلتر ذرات مربوطه برای استخراج دنباله داده‌های کاربران در شکل ۵-۶ آورده شده است. در این الگوریتم، هر ذره را دارای  $k$  کانال مجزا، که هر کانال دنباله داده یک کاربر را نشان می‌دهد، در نظر می‌گیریم ( شکل ۵-۵). برای دنباله‌ای از  $T$  بردار وضعیت محیط متوالی، با  $t = 1$  شروع می‌کنیم و تا  $t = T$  ادامه می‌دهیم. در هر برش زمانی، تعدادی ذره را با بسط ذرات برش زمانی قبلی ایجاد کرده (تابع *extend*) و آنها را با یک تابع ارزیابی (تابع *score*) امتیاز دهی می‌کنیم. امتیاز دهی به یک ذره بر مبنای وابستگی زمانی بین داده‌های پشت سر هم، و نیز احتمال مشاهده پشت سر هم داده‌ها در کانال‌های آن ذره صورت می‌گیرد. سپس،  $Q$  ذره کاندید، که به بهترین شکل نشان دهنده دنباله داده‌های مجزای کاربران هستند (یعنی تعداد  $Q$  ذره با بالاترین امتیاز)، را نگه داشته و بقیه را حذف می‌کنیم (تابع *select*). در انتهای این الگوریتم، یعنی پس از زمان  $T$ ، کانال‌های ذره با بیشترین امتیاز (یعنی بهترین ذره)، دنباله داده‌های مجزای هر کاربر را نشان می‌دهد.

باید توجه داشت که هر ذره در زمان میانی  $t$ ،  $k$  دنباله به طول  $t$  را شامل می‌شود. اگر  $H_q^t$  را ذره شماره  $q$  در زمان  $t$ ،  $H^t = \{H_q^t | q = 1, \dots, Q\}$  را مجموعه همه ذرات کاندید در زمان  $t$ ،  $\perp$  را مجموعه تهی، و  $S$  را مجموعه شناسه تمام حسگرها در نظر بگیریم، آنگاه، هر ذره مثل  $H_q^t$ ، یک ماتریس  $k \times t$  خواهد بود، که در آن عنصر  $[H_q^t]_{i,j}$  زیرمجموعه‌ای از شناسه‌های حسگرها را در دنباله  $t$  و برش زمانی  $j$  نشان می‌دهد. بدیهی است که برای ذره  $H_q^t$ ، طول ذره را نشان می‌دهد. شکل ۵-۵ ساختار یک ذره با سه کانال در زمان  $t = 5$  (و طبیعتاً به طول ۵) را نشان می‌دهد. توجه داریم که

هر برش زمانی در کانال‌های یک ذره زیر مجموعه‌ای از شناسه حسگرهای فعال در آن زمان را در بر می‌گیرد؛ زیرا یک کاربر ممکن است بیش از یک حسگر را در یک زمان فعال سازد. بنا بر این داریم:

$$[H_q^t]_{i,j} \subseteq \mathcal{L} \cup \mathcal{S}$$

در بخش‌های آتی، بسط ذرات و نحوه امتیاز دهی به آنها مورد بحث قرار گرفته است.



شکل ۵-۵. ساختار یک ذره در محیطی با سه کاربر.

1. **Input:**
2.  $\mathcal{D} = \mathbf{x}_1, \dots, \mathbf{x}_T$ : Users' aggregate data.
3.  $Q$ : Number of candidate particles in each time span.
4.  $k$ : Maximum number of residents.
5.  $score(\mathbf{H}_i^t)$ : The scoring function, that returns a real score for particle  $H_i^t$ .
6.  $extend(\mathbf{H}^t, S_A^{t+1})$ : The extension function.
7. **Output:**
8.  $H_{best}^T$ : The best particle at time span  $T$ .
9. **Variables:**
10.  $\hat{\mathbf{H}}^t = \{H_i^t | i = 1, \dots, n_t\}$ : The set of extended particles from time  $t$  to  $t + 1$ .
11. **Body:**
12.  $\mathbf{H}^0 = \mathbf{H}_1^0 = [\mathcal{L}]_{k \times 0}$  // Matrix of  $k$  empty channels.
13. for  $t = 0$  to  $T - 1$
14.  $S_A^{t+1} = \{s | s \in \{1, \dots, n\}, \text{ and } \mathbf{x}_{t+1,s} = 1\}$
15.  $\hat{\mathbf{H}}^{t+1} = extend(\mathbf{H}^t, S_A^{t+1})$
16.  $\hat{\mathbf{H}}^{t+1} = sort(\hat{\mathbf{H}}^{t+1}, @score)$
17.  $\mathbf{H}^{t+1} = select(\hat{\mathbf{H}}^{t+1}, Q)$
18. End
19.  $\mathbf{H}_{best}^T = \mathbf{H}_1^t$
20. **End**
- 21.

شکل ۵-۶. الگوریتم فیلتر ذرات برای استخراج دنباله داده‌های کاربران.

## ۵-۳-۲ بسط ذرات

در الگوریتم فیلتر ذرات، ذرات متعلق به برش زمانی  $t + 1$  با نمونه برداری<sup>۱</sup> از یک توزیع احتمال پیش‌فرض، در همسایگی ذرات متعلق به برش زمانی  $t$  انتخاب شده، و سپس با توجه به مشاهدات در

<sup>۱</sup> Sampling

برش زمانی  $t + 1$  امتیاز دهی می‌شوند. این همسایگی معمولاً اقلیدسی در نظر گرفته می‌شود. اما در خصوص پیکربندی ذرات برای مساله MUT، باید توجه داشت که اولاً همسایگی اقلیدسی برای ذرات دارای مفهوم خاصی نیست و ثانیاً تابع توزیع احتمال پیشین مذکور برای نمونه برداری نیز نامشخص است. در نظر داریم که فضای وضعیت در مساله MUT یک فضای گسسته خواهد بود. لذا برای تعریف همسایگی‌ها، از یک گراف همسایگی استفاده می‌کنیم. در این گراف، ذرات را به عنوان رئوس، و فاصله بین دو ذره را فاصله بین رئوس مربوط به آنها در این گراف در نظر می‌گیریم. این گراف را مطابق با تعریف زیر ایجاد می‌کنیم.

**تعریف ۵-۵. (گراف همسایگی).** گراف  $G = (V, E)$  با مجموعه راسی  $V$ ، و مجموعه یال  $E$ ، را

در نظر بگیرید که در آن هر راس نشان دهنده یک ذره به طول  $t$ ، مثل  $H_q^t$  می‌باشد. اگر راس  $v_i$  و  $v_j$  به ترتیب مربوط به دو ذره  $H_i^{t_i}$  و  $H_j^{t_j}$  باشند، آنگاه یالی بین این دو راس وجود خواهد داشت اگر و فقط اگر هر دو شرط زیر برقرار باشند:

$$|t_i - t_j| = 1 \quad -۱$$

$$\forall m \in \{1, \dots, k\}, n \in \{1, \dots, \min(t_i, t_j)\} : [H_j^{t_j}]_{m,n} = [H_i^{t_i}]_{m,n} \quad -۲$$

که در آن  $k$  تعداد کانال‌های ذرات می‌باشد.

با توجه به تعریف ۵-۵، و اینکه تابع توزیع احتمال پیشین برای نمونه برداری مشخص نیست، برای محاسبه ذرات بعدی، همسایگان با فاصله ۱ را برای هر ذره بر روی گراف همسایگی به دست می‌آوریم. محاسبه همسایگان یک ذره (یعنی ذرات بعدی) را بسط<sup>۱</sup> آن ذره می‌نامیم. می‌دانیم که ذرات در برش زمانی  $t$  باید دارای طول  $t$  باشند. همچنین، انتظار داریم صرفاً داده‌های حسگرهای فعال شده

<sup>۱</sup> Extend

در کانال‌های ذرات قرار بگیرند. لذا برای به دست آوردن ذرات بعدی، کافی است حالات مختلفی را که داده‌های حسگرهای فعال شده در زمان  $t + 1$  می‌توانند به کانال‌های ذرات در زمان  $t$  اضافه شوند، محاسبه کنیم. هرچند، این روش پیچیدگی زمانی بالایی می‌تواند داشته باشد. برای توضیح بیشتر، نمادگذاری الگوریتم شکل ۵-۶ را در نظر بگیرید. اگر مجموعه حسگرهای فعال شده در زمان  $t$  را با  $S_A^t$  نمایش دهیم، اضافه کردن داده‌های آنها به کانال‌های مختلف یک ذره منجر به تولید  $k^{|S_A^t|}$  ذره جدید خواهد شد. لذا در زمان  $t$ ، تعداد کل ذرات و در نتیجه پیچیدگی زمانی بسط همه ذرات (تابع  $extend(.)$  در الگوریتم شکل ۵-۶) از مرتبه  $O(Qk^{|S_A^t|})$  خواهد بود، که حداکثر تعداد ذرات در یک برش زمانی است. ملاحظه می‌شود که این زمان بر حسب  $k$  و  $|S_A^t|$ ، از مرتبه نمایی خواهد بود. از طرفی، با توجه به مرتب‌سازی این تعداد ذره در الگوریتم فیلتر ذرات شکل ۵-۶ (تابع  $sort(.)$ )، پیچیدگی زمانی این الگوریتم در دور  $t$  ام از مرتبه  $O(Qk^{|S_A^t|} \log(Qk^{|S_A^t|}))$  خواهد بود. حال اگر ماکزیمم تعداد حسگرهای فعال شده در یک برش زمانی را  $m$  فرض کنیم، یعنی  $m = \max_{1 \leq t \leq T} |S_A^t|$ ، آنگاه پیچیدگی زمانی کلی این الگوریتم از مرتبه  $O(TQk^m \log(Qk^m))$  می‌باشد. بنابراین، ملاحظه می‌شود که با بسط ذرات به این روش، پیچیدگی زمانی الگوریتم فیلتر ذرات بدتر از نمایی خواهد بود که مطلوب نیست.

شکل ۵-۸ مثالی از روند بسط ذرات در دور  $i$  ام الگوریتم شکل ۵-۷ (یعنی اضافه کردن  $i$  امین حسگر فعال شده به کانال‌های ذرات) را، وقتی که  $i$  امین حسگر فعال شده شماره ۱ است، نشان می‌دهد. در این شکل، ذرات در دور  $i - 1$  در پنل سمت چپ نشان داده شده‌اند. ذرات بسط داده شده مربوط به ذرات شماره ۱ و  $Q$  در سمت راست نمایش داده شده‌اند. در صورت استفاده از این نسخه تابع  $extend(.)$  در الگوریتم فیلتر ذرات، سطرهای ۱۶ و ۱۷ از این الگوریتم حذف خواهند شد؛ زیرا مرتب‌سازی و انتخاب در تابع  $extend(.)$  انجام می‌گیرد. اگر حداکثر تعداد حسگرهای فعال شده در یک برش زمانی را  $m$  در نظر بگیریم، آنگاه در یک فراخوانی تابع  $extend(.)$

حداکثر  $m$  دور وجود خواهد داشت؛ و از آنجا که در هر دور حداکثر  $Qk$  ذره مرتب سازی می‌شوند، پیچیدگی زمانی این تابع از مرتبه  $O(mQk \log(Qk))$  می‌باشد. در صورت بکارگیری این تابع در الگوریتم فیلتر ذرات شکل ۵-۶، پیچیدگی زمانی این الگوریتم نیز برابر با  $O(TmQk \log(Qk))$  خواهد شد که بسیار بهتر از پیچیدگی زمانی نمایی است.

---

```

1. Inputs:
2.    $\mathbf{H}^t = \{\mathbf{H}_i^t | i = 1, \dots, Q_t\}$ : Set of candidate particles at time  $t$ .
3.    $S_A^{t+1}$ : Set of activated sensor IDs at time  $t + 1$ .
4.    $Q$ : Maximum number of candidate particles.
5.    $score(\mathbf{H})$ : The scoring function, that returns a real score for particle  $\mathbf{H}$ .
6. Output:
7.    $\mathbf{H}^{t+1}$ : The set of extended particles from time  $t$  to  $t + 1$ .
8. Variables:
9.    $k$ : Maximum number of residents i.e. number of channels.
10. Body:
11.   $\ddot{\mathbf{H}}^{t+1} = \text{augment}(\mathbf{H}^t)$  // add an empty time slice to the channels of particles in  $\mathbf{H}^t$ 
12.  for  $i = 1$  to  $|S_A^{t+1}|$ 
13.     $cur\_sens = S_A^{t+1}(i)$  // select the  $i$ 'th activated sensor ID from  $S_A^{t+1}$ 
14.     $new\_particles = \{\}$ 
15.    for  $j = 1$  to  $|\ddot{\mathbf{H}}^{t+1}|$  // for each particle of  $\ddot{\mathbf{H}}^{t+1}$  in the previous round
16.      for  $l = 1$  to  $k$  // for each channel in a particle
17.         $\mathbf{H} = \ddot{\mathbf{H}}_j^{t+1}$  // initiate a new particle, named  $\mathbf{H}$ 
18.         $\mathbf{H}_{l,t+1} = \mathbf{H}_{l,t+1} \cup cur\_sens$  //add  $S_A^{t+1}(i)$  to the  $l$ 'th channel of  $\mathbf{H}$ 
19.         $new\_particles = new\_particles \cup \mathbf{H}$  //add  $\mathbf{H}$  to  $new\_particles$ 
20.      end
21.    end
22.   $remove\_repeated(new\_particles)$ . //discard particles with identical channel
    permutations to avoid repeated particles
23.   $\ddot{\mathbf{H}}^{t+1} = new\_particles$  // update  $\ddot{\mathbf{H}}^{t+1}$  with newly generated particles
24.   $\ddot{\mathbf{H}}^{t+1} = \text{sort}(\ddot{\mathbf{H}}^{t+1}, @score)$  // sorting  $\ddot{\mathbf{H}}^{t+1}$  according to a scoring function
25.   $\ddot{\mathbf{H}}^{t+1} = \text{select}(\ddot{\mathbf{H}}^{t+1}, Q)$  // selecting at most  $Q$  best particles
26.  end
27.   $\mathbf{H}^{t+1} = \ddot{\mathbf{H}}^{t+1}$ 
28. End

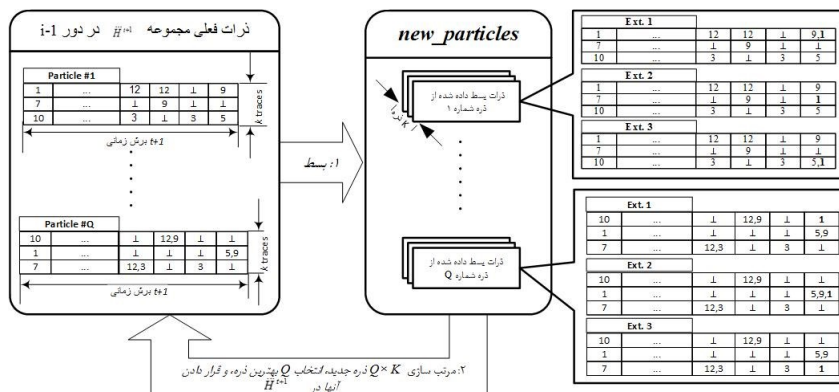
```

---

شکل ۵-۷. شبه کد مربوط به بسط ذرات تابع  $(\text{extend}(\cdot))$ .

### ۵-۳-۳ امتیاز دهی به ذرات

همانطور که در بخش قبلی بیان شد، ذرات بر اساس امتیاز آنها در الگوریتم فیلتر ذرات مرتب سازی می‌شوند. این امتیاز را با تابع  $score(\cdot)$  محاسبه می‌کنیم. دو عامل را برای امتیاز دهی به یک ذره



شکل ۵-۸. پروسه بسط ذرات در دور  $t$  ام از الگوریتم شکل ۵-۷.

در نظر گرفتیم: ۱- وابستگی زمانی بین داده‌های حسگرها در کانال‌های ذرات، و ۲- امکان رخداد دنباله داده‌های مربوط به کانال‌های ذرات. برای محاسبه امکان رخداد دنباله داده‌های کانال‌های هر ذره، از ماتریس احتمال انتقال بین حسگرها (یعنی  $P_{proposed}$  یا  $P_{CLS}$ ) استفاده می‌کنیم.

برای یک ذره مثل  $H_q^t$ ، ذره  $\bar{H}_q^t$  را بسطی از  $H_q^t$  در نظر بگیرید طوری که  $\bar{H}_q^t \neq H_q^t$  و در  $\bar{H}_q^t$  فقط شناسه یک حسگر، با شناسه  $s$ ، به آخرین برش زمانی کانال  $i$  ام آن اضافه شده باشد. همچنین،  $a_q^t(i) \neq \perp$  را آخرین زیر مجموعه از شناسه حسگرهای فعال شده در کانال  $i$  ام ذره  $H_q^t$  در نظر بگیرید.  $score(\bar{H}_q^t)$  به صورت تابعی باز گشتی از  $score(H_q^t)$  و  $score(H_q^{t-1})$ ، به شرح ذیل تعریف می‌شود. از آنجا که کانال‌های  $H_q^t$  زیر دنباله‌هایی از کانال‌های  $\bar{H}_q^t$  هستند،  $score(\bar{H}_q^t)$  به صورت مستقیم متناسب با  $score(H_q^t)$  در نظر گرفته می‌شود. یعنی داریم:

$$score(\bar{H}_q^t) \propto score(H_q^t). \quad (9-5)$$

هر قدر فاصله زمانی بین رخداد های  $s$  و  $a_q^{t-1}(i)$  کمتر باشد، وابستگی زمانی این دو رخداد با هم بیشتر در نظر گرفته می‌شود و امکان اینکه آنها در یک دنباله داده باشند، افزایش می‌یابد. بنابراین،  $score(\bar{H}_q^t)$  را به طور معکوس متناسب با فاصله زمانی بین رخداد های  $s$  و  $a_q^{t-1}(i)$  در نظر می‌گیریم.



این مساله با رابطه (۱۰-۵) به فرم زیر بیان می گردد.

$$score(\bar{H}_q^t) \propto \frac{1}{t_s - t_{a_q^{t-1}(i)}} \quad (10-5)$$

که در آن،  $t_s$  و  $t_{a_q^{t-1}(i)}$  به ترتیب زمان های رخداد  $a_q^{t-1}(i)$  و  $s$  هستند. از سوی دیگر، هر قدر احتمال فعال شدن حسگر  $s$  به شرط  $a_q^{t-1}(i)$  بالاتر باشد، امکان اینکه این رخدادها در یک دنباله داده قرار بگیرند افزایش خواهد یافت. بنابر این،  $score(\bar{H}_q^t)$  به طور مستقیم متناسب با  $p(s|a_q^{t-1}(i))$  در نظر گرفته می شود.  $p(s|a_q^{t-1}(i))$  با میانگین احتمال  $s$  به شرط هر یک از حسگرهای فعال شده در  $a_q^{t-1}(i)$  تخمین زده می شود. لذا خواهیم داشت:

$$score(\bar{H}_q^t) \propto \frac{1}{|a_q^{t-1}(i)|} \sum_{s' \in a_q^{t-1}(i)} p(s|s'). \quad (11-5)$$

با تجمیع روابط (۹-۵)، (۱۰-۵)، و (۱۱-۵)، و در نظر گرفتن شرایط خاص در محاسبه امتیاز

دهی به ذرات، تابع امتیازدهی بازگشتی زیر حاصل خواهد شد:

$$score(\bar{H}_q^t) = \begin{cases} score(H_q^t) \frac{\sum_{s' \in a_q^{t-1}(i)} p(s|s')}{|a_q^{t-1}(i)| (t_s - t_{a_q^{t-1}(i)})} & \text{if } |a_q^{t-1}(i)| \neq 0, t > 0, s \neq \perp \\ score(H_q^{t-1}) & \text{if } s = \perp, t > 0 \\ score(H_q^t) \pi(s) & \text{if } |a_q^{t-1}(i)| = 0, t > 0, s \neq \perp \\ 1 & \text{if } t = 0 \end{cases} \quad (12-5)$$

که  $p(s|s')$  احتمال انتقال از حسگر  $s'$  به حسگر  $s$ ، و  $\pi(s)$  احتمال رخداد اولیه حسگرها می باشد. مقادیر  $p(s|s')$  و  $\pi(s)$  به طور مستقیم با محاسبه  $P_{proposed}$  یا  $P_{CLS}$  قابل محاسبه هستند. در رابطه

(۵-۱۲)، اولین معادله صورت اصلی تابع امتیاز دهی را به صورت بازگشتی نشان می‌دهد و بقیه معادلات این رابطه مربوط به شروط بازگشت هستند. معادله دوم در این رابطه امتیاز آغازین یک ذره در برش زمانی  $t$  را وقتی که هیچ داده حسگری از مجموعه  $S_A^{t+1}$  به  $\bar{H}_q^t$  اضافه نشده است نشان می‌دهد. معادله سوم در رابطه (۵-۱۲) امتیاز یک ذره را در زمانی که  $S$  به یک کانال خالی اضافه شده، و معادله چهارم امتیاز یک ذره را در زمانی که هیچ داده‌ای در کانال‌های آن قرار ندارد، نشان می‌دهد.

همانطور که قبلاً نیز بیان شد، احتمال انتقال بین حسگرها و نیز احتمال آغازین فعال سازی حسگرها، با استفاده از  $P_{proposed}$  و  $P_{CLS}$ ، به طور مستقیم از روی داده‌های مجتمع قابل محاسبه هستند. در ارزیابی‌ها، کارایی الگوریتم فیلتر ذرات با اعمال هریک از این روش‌ها در تابع امتیاز دهی (رابطه (۵-۱۲))، مورد مطالعه قرار گرفته است.

## ۴-۵ شناسایی اعمال روی دنباله داده‌های استخراج شده

پس از استخراج دنباله داده‌های کاربران برای هر رویداد حسگر، یک عمل را استنتاج می‌کنیم (تعریف ۱-۱ و تعریف ۱-۴). یک رویداد حسگر عبارت است از دوتایی شامل: شناسه حسگر، و مقدار حسگر (ON/OFF). همانطور که قبلاً نیز بیان شد، این کار را با استفاده از یک فرآیند رده بندی تک کاربره انجام می‌دهیم. باید توجه داشت که در نظر داریم از روش‌های پیشنهادی مبتنی بر بهینه‌سازی (الگوریتم‌های CPAR و DCPAR)، که در فصل قبل مطرح گردیدند، به منظور شناسایی اعمال استفاده کنیم؛ زیرا در این رویکردها نیازی به آموزش رده بند بر روی دنباله‌های از قبل جدا شده کاربران نیست (بدین معنی که محاسبه بردارهای باور اولیه بدون جداسازی دنباله داده کاربران امکان پذیر است).

باید توجه داشت که الگوریتم فیلتر ذرات پیشنهادی دنباله برش‌های زمانی از لحظه آغاز تا پایان فعالیت یک حسگر را استخراج و به کانال‌های ذرات تخصیص می‌دهد. به عنوان مثال، فرض کنید حسگر

تشخیص حرکت  $s1$  در اثر حضور دو کاربر در میدان دید آن به طور هم‌روند، در ۲۰ برش زمانی متوالی فعال شده باشد. الگوریتم فیلتر ذرات برخی از این برش‌های زمانی را در دنباله داده‌های کاربر اول، و برخی را در دنباله داده‌های کاربر دوم قرار خواهد داد. اما از آنجا که مشخص نیست کدام برش‌ها متعلق به کدام کاربر است، در عمل رویداد این حسگر در این ۲۰ برش زمانی را به طور کامل متعلق به هر دو کاربر در نظر می‌گیرند (داده مشترک). از آنجا که قصد داریم برای هر رویداد حسگر یک عمل را استنتاج کنیم، پس از استخراج دنباله داده‌های کاربران توسط الگوریتم فیلتر ذرات، به ازای برش‌های زمانی فعال ماندن یک حسگر، رویدادهای فعال شدن و غیرفعال شدن آن حسگر را به طور کامل قرار می‌دهیم. با این کار، به ازای هر دنباله از داده‌های حسگرها (یعنی هریک از کانال‌های بهترین ذره استخراج شده)، جریانی از رویدادهای حسگرها مانند آنچه در شکل ۴-۱ نشان داده شد، به دست خواهد آمد. این کار را با الگوریتم شکل ۵-۹ انجام می‌دهیم. سپس، برای هر یک از رویدادهای به دست آمده ( $E_i$  ها در الگوریتم شکل ۵-۹)، یک عمل را استنتاج می‌کنیم.

- 
1. **Inputs:**
  2.  $H_{best}^T$ : The particle including  $k$  users' data channels.
  3. **Output:**
  4.  $E = \{E_1, \dots, E_k\}$ : Set of sensor event streams.  $E_i$  is the  $i$ 'th stream.
  5. **Variables:**
  6.  $e_l$ :  $l$ 'th sensor event.
  7. **Body:**
  8. for  $i = 1$  to  $k$
  9. for  $j = 1$  to  $T$
  10. if  $[H_{best}^T]_{i,j} \in e_l$
  11. add  $e_l$  to  $E_k$
  12. end
  13. end
  14. end
  15. **End**
- 

شکل ۵-۹. به دست آوردن جریان رویدادهای حسگرها از روی دنباله داده‌های استخراج شده.

لازم به ذکر است که پس از ایجاد دنباله رویدادهای حسگرها با استفاده از الگوریتم شکل ۵-۹، یک حسگر می‌تواند به طور هم‌روند در بیش از یک جریان داده قرار بگیرد و برچسب‌های متعددی (بیش

از یک عمل) برای آن استنتاج گردد. با این کار، مفهوم مشترک بودن یک قلم داده در بیش از یک عمل، و در نتیجه مفهوم همروند بودن اعمال پوشش داده می‌شود.

## ۵-۵ ارزیابی و پیاده سازی

ارزیابی‌ها شامل سه بخش می‌باشند. در بخش اول، میزان کارایی روش پیشنهادی برای تخمین پارامترهای زنجیره مارکوف ارزیابی گردیده است. بدین منظور، ماتریس انتقال بدست آمده از روش پیشنهادی را با ماتریس انتقال محاسبه شده با CLS مقایسه نموده‌ایم. در بخش دوم، کارایی روش مبتنی بر فیلتر ذرات برای تفکیک دنباله داده‌های کاربران را مورد بررسی قرار داده‌ایم. بخش سوم به بررسی میزان کارایی فرآیند تشخیص اعمال بر روی دنباله‌های رویدادهای تفکیک شده کاربران می‌پردازد. جزئیات هر بخش را به صورت مجزا، در ادامه آورده‌ایم.

در هر سه بخش، از یک مجموعه داده‌ای معروف متعلق به پروژه CASAS، موسوم به Kyoto [۶۱] استفاده کرده‌ایم. در این مجموعه داده ۲۰ زوج در یک آپارتمان، به طور مستقل، اعمال روزمره خود را انجام می‌دهند. در محیط ۳۵ حسگر دودویی داده‌های کاربران را دریافت می‌کنند. در این مجموعه داده ۱۵ عمل متفاوت توسط کاربران انجام می‌گیرد و در هر زمان دو کاربر در محیط حضور دارند. این اعمال در جدول ۵-۱ آورده شده‌اند. مزیت این مجموعه داده این است که تمام داده‌های حسگرها با شناسه کاربری که آن را ایجاد کرده و نیز شناسه عمل مربوطه، برچسب زده شده‌اند. این ویژگی به ارزیابی دقیق تر روش‌های پیشنهادی (برای مدل کردن دنباله داده‌های کاربران و نیز ارزیابی میزان کارایی الگوریتم فیلتر ذره برای استخراج دنباله‌های داده) کمک شایانی خواهد کرد. معیارهای ارزیابی در هر بخش به طور مجزا توضیح داده شده است.

جدول ۵-۱. اعمالی که در مجموعه داده وجود دارند.

1. *Fill medication dispenser.*
2. *Hang up clothes.*
3. *Move the couch and coffee table.*
4. *Sit on the couch and read a magazine.*
5. *Water plants located around the apartment.*
6. *Sweep the kitchen floor.*
7. *Play a game.*
8. *Set out ingredients for dinner.*
9. *Set dining room table for dinner.*
10. *Read a magazine.*
11. *Simulate paying an electric bill.*
12. *Gather food for a picnic*
13. *Retrieve dishes from a kitchen cabinet.*
14. *Pack supplies in the picnic basket.*
15. *Pack food in the picnic basket.*

## ۵-۵-۱ آزمایش اول

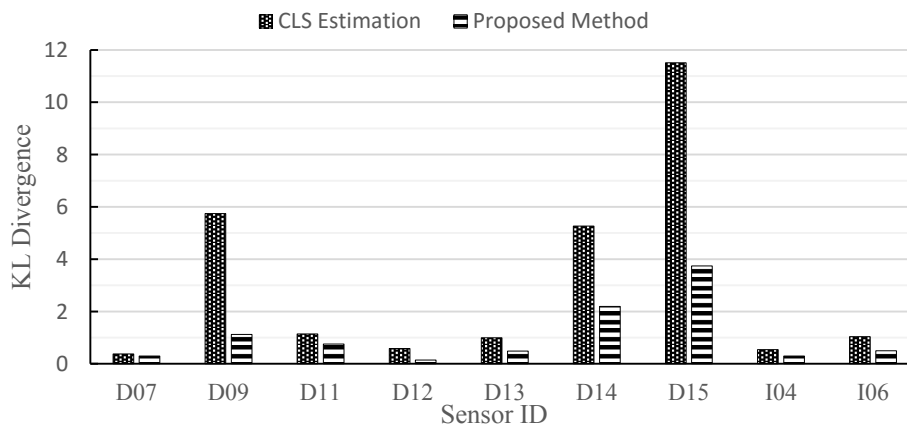
در این آزمایش، روش پیشنهادی برای تخمین پارامترهای زنجیره مارکوف با CLS مقایسه شده است. برای مقایسه این دو روش، ابتدا دنباله داده‌های کاربران به صورت دستی از هم جدا کردیم و سپس با استفاده از MLE ماتریس انتقال زنجیره مارکوف را محاسبه نمودیم. با توجه به اینکه داده‌های مورد استفاده با شناسه کاربران نیز برچسب خورده‌اند، تفکیک دنباله‌ها به صورت دستی قابل انجام می‌باشد. ماتریس انتقال حقیقی محاسبه شده را  $P_G$  می‌نامیم.

برای مقایسه روش پیشنهادی برای تخمین ماتریس انتقال با CLS، یعنی ماتریس تخمین زده شده  $P_{proposed}$  و  $P_{CLS}$ ، فاصله آنها را تا ماتریس انتقال حقیقی محاسبه کردیم. بدین منظور از تابع فاصله Kullback-Leibler استفاده کرده و فاصله هر یک از ماتریس‌های انتقال  $P_{proposed}$  و  $P_{CLS}$  را سطر به سطر با ماتریس حقیقی محاسبه نمودیم. اگر  $\bar{P}$  را یک ماتریس انتقال دلخواه در نظر بگیریم، فاصله Kullback-Leibler سطر  $i$  ام آن با سطر  $i$  ماتریس  $P_G$  از رابطه زیر محاسبه می‌شود.


$$D_{KL}(P_G(i, \cdot) || \bar{P}(i, \cdot)) = \sum_{j=1}^n P_G(i, j) \log \frac{P_G(i, j)}{\bar{P}(i, j)} \quad (13-5)$$

نتایج مقایسه در شکل ۵-۱۰ و شکل ۵-۱۱ آورده شده است. همانطور که مشاهده می‌شود، در مقایسه با  $P_{CLS}$ ، در تمامی حالات، سطرهای ماتریس  $P_{proposed}$  فاصله کمتری با  $P_G$  داشته‌اند. بنابراین می‌توان گفت که روش پیشنهادی تخمین مناسب‌تری از ماتریس انتقال داشته است.

همچنین، محاسبه میانگین خطای مربعی بین هر یک از ماتریس‌های تخمین زده شده با ماتریس حقیقی نشان داد که روش پیشنهادی با میانگین خطای  $2.7 \times 10^{-3}$  عملکردی بهتر از CLS با میانگین خطای  $3.2 \times 10^{-3}$  داشته است. با توجه به نتایج به دست آمده، می‌توان گفت که بکارگیری اطلاعات مکانی با استفاده از فرضیه ۵-۱ تاثیر مثبتی در محاسبه دقیق‌تر ماتریس انتقال داشته است.



شکل ۵-۱۰. فاصله Kullback-Leibler بین سطرهای ماتریس‌های انتقال تخمین زده شده و ماتریس انتقال واقعی (برای حسگرهای غیر حرکتی).



شکل ۵-۱۱. فاصله Kullback-Leibler بین سطرهای ماتریس‌های انتقال تخمین زده شده و ماتریس انتقال واقعی (برای حسگرهای حرکتی).

## ۵-۲-۵-۲ آزمایش دوم

در این بخش، به بررسی عملکرد الگوریتم مبتنی بر فیلتر ذرات برای تفکیک دنباله‌های داده کاربران با به‌کارگیری هر یک از تخمین‌های CLS ( $P_{CLS}$ )، و روش پیشنهادی ( $P_{proposed}$ ) می‌پردازیم. برای ارزیابی کارایی میزان تفکیک، از معیار خلوص<sup>۱</sup> استفاده می‌کنیم [۱۲۳]. این معیار بیان می‌کند که دنباله داده‌های استخراج شده تا چه میزان صرفاً داده‌های مربوط به یک کاربر را در خود جای داده‌اند. لذا میزان خلوص بالاتر نشان دهنده تفکیک بهتر بین دنباله داده‌های کاربران است. این معیار به فرم زیر تعریف می‌شود:

$$purity = \frac{1}{N} \sum_{A \in tr^e} \max_{B \in tr^g} |A \cap B|, \quad (۱۴-۵)$$

که در آن  $tr^g$  مجموعه دنباله داده‌های حقیقی است که در مجموعه داده برچسب گذاری شده است،  $tr^e$  مجموعه دنباله‌هایی است که از داده‌های مجتمع استخراج گردیده‌اند و  $N$  تعداد دنباله‌های


<sup>۱</sup> Purity

استخراج شده می‌باشد.

با محاسبه معیار خلوص برای دنباله‌های استخراج شده، استفاده از  $P_{proposed}$  و  $P_{CLS}$  برای امتیاز دهی به ذرات، به ترتیب منجر به  $0.76/6$  و  $0.75/68$  خلوص گردید.

از آنجا که در داده‌های مورد بررسی مقداری نویز (هشدار ناصحیح<sup>۱</sup>) وجود داشت، صرفاً برای بررسی دقیق‌تر عملکرد الگوریتم مبتنی بر فیلتر ذرات جریان داده‌های حسگرها را به قطعاتی (بر حسب تعداد برش‌های زمانی) کوچکتر تقسیم بندی کردیم و دنباله‌های داده کاربران را از این قطعات استخراج نمودیم. این کار منجر خواهد شد تا اثر نویز صرفاً در یک قطعه کوچک از داده‌ها باقی بماند و منجر به تولید دنباله‌های ناصحیح طولانی نگردد.


خروجی الگوریتم برای قطعات با اندازه‌های مختلف در شکل ۵-۱۲ و شکل ۵-۱۳ آورده شده است. همانطور که مشاهده می‌شود، محاسبه امتیاز ذرات با استفاده از  $P_{proposed}$  منجر به میزان خلوص بالاتری خواهد شد. لذا برای امتیازدهی به ذرات از این ماتریس انتقال استفاده خواهیم کرد.



شکل ۵-۱۲. خلوص دنباله‌های استخراج شده از قطعات با طول از ۲۰ تا ۲۵۰ برش زمانی.

<sup>۱</sup> False alarm






شکل ۵-۱۳. خلوص دنباله‌های استخراج شده از قطعات با طول از ۲۶۰ تا ۵۰۰ واحد زمانی.

### ۵-۳-۵ آزمایش سوم

در این بخش، به ارزیابی میزان کارایی فرآیند تشخیص اعمال بر روی دنباله رویدادهای استخراج شده توسط الگوریتم فیلتر ذرات می‌پردازیم. همانطور که در بخش ۵-۴ نیز اشاره شد، پس از به دست آوردن دنباله داده‌های تفکیک شده کاربران، جریان رویدادهای مربوط به هر دنباله را با استفاده از الگوریتم شکل ۵-۹ به دست می‌آوریم. سپس، بر روی هر دنباله از رویدادهای حسگرها از رویکردهای DCPAR و CPAR برای رده بندی رویدادها استفاده می‌کنیم.

روش پیشنهادی با دو رویکرد پایه برای شناسایی اعمال مورد مقایسه قرار گرفته است. این رویکردها مبتنی بر CHMM و FCRF بوده و مشابه با رهیافت‌های [۱۵] و [۱۶] پیاده‌سازی شده‌اند. هرچند، برخلاف [۱۶] و مشابه سناریوی دنیای واقعی فرض می‌کنیم که از قبل مشخص نیست که کدام کاربر سبب بروز چه رویداد حسگری شده است. بنابراین، رویدادهای حسگرها را مرتبط با اعمال انجام شده توسط هر دو کاربر در نظر می‌گیریم. ساختار مربوط به FCRF و CHMM مورد استفاده، در شکل ۵-۱۴ نشان داده شده است. در این شکل، هر یک از  $x_t$  ها یک رویداد حسگر مشاهده شده، و متغیرهای مخفی  $y_t^1$  و  $y_t^2$  به ترتیب مربوط به اعمالی هستند که کاربر ۱ و ۲ انجام داده‌اند. برای استنتاج نیز

می‌توان از هر یک از الگوریتم‌های ویتربی<sup>۱</sup> و یا LBP<sup>۲</sup> استفاده نمود.



شکل ۵-۱۴. الف) ساختار CHMM مورد استفاده، و ب) ساختار FCRF مورد استفاده در ارزیابی‌ها.

برای ارزیابی، از معیارهای صحت، دقت، یادآوری، و F-measure استفاده می‌کنیم. توجه داریم که در فرآیند رده‌بندی، هر رویداد حسگر ممکن است با بیش از یک عمل برچسب زده شود. لذا با یک مساله رده‌بندی با چند برچسب<sup>۳</sup> روبرو هستیم. فرض کنید در چنین حالتی یک نمونه متعلق به مجموعه کلاس  $Y$  با مجموعه  $\bar{Y}$  برچسب زده شده باشد. آنگاه یک نمونه مثبت صحیح (TP)، مثبت ناصحیح (FP)، منفی صحیح (TN)، و منفی ناصحیح (FN)، با رابطه (۵-۱۵) محاسبه می‌شود [۱۲۴]. با محاسبه این مقادیر، معیارهای ارزیابی را با استفاده از معادلات رابطه (۳-۹) محاسبه می‌کنیم.

$$\begin{aligned}
 \forall y \in Y, TP(y) = TP(y) + 1 &\Leftrightarrow y \in \bar{Y} \\
 \forall y \in Y, FN(y) = FN(y) + 1 &\Leftrightarrow y \notin \bar{Y} \\
 \forall y \in \bar{Y}, FP(y) = FP(y) + 1 &\Leftrightarrow y \notin Y \\
 \forall y \notin Y, TN(y) = TN(y) + 1 &\Leftrightarrow y \notin \bar{Y}
 \end{aligned}
 \tag{۵-۱۵}$$

در ارزیابی هر یک از روش‌ها، مشابه فصل گذشته از استراتژی LOOCV استفاده می‌کنیم. بدین

<sup>۱</sup> Viterbi

<sup>۲</sup> Loopy belief propagation

<sup>۳</sup> Multi-label classification

معنی که هر بار داده‌های مربوط به یک زوج کاربر را به عنوان نمونه آزمون، و بقیه را به عنوان نمونه‌های آموزشی در نظر می‌گیریم. همچنین، مشابه فصل گذشته برای محاسبه پارامترها، یعنی  $\gamma$  و  $\lambda$  در الگوریتم مبتنی بر CPD و الگوریتم CPAR از جستجوی شبکه‌ای<sup>۱</sup> استفاده کرده ایم.

نتایج حاصل از به کارگیری الگوریتم DCPAR، که در فصل قبل ارائه گردید، بر روی دنباله رویدادهای تفکیک شده کاربران، در جدول ۵-۲ نشان داده است. این الگوریتم را DCPAR+PF نامیده ایم. به جهت مقایسه، نتایج حاصل از دو رویکرد شناسایی اعمال مبتنی بر FCRF و CHMM که مشابه مراجع [۱۵]، [55, 16, 105] پیاده‌سازی شده‌اند را نیز در این جدول آورده‌ایم.

جدول ۵-۲. مقایسه رویکردهای DCPAR+PF، CHMM و FCRF.

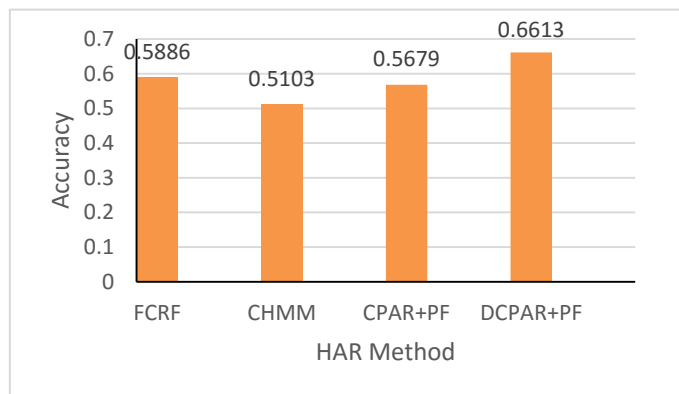
| Activity ID | Precision    |              |       | Recall       |       |       | F-Measure    |              |              |
|-------------|--------------|--------------|-------|--------------|-------|-------|--------------|--------------|--------------|
|             | DCPAR+PF     | CHMM         | FCRF  | DCPAR+PF     | CHMM  | FCRF  | DCPAR+PF     | CHMM         | FCRF         |
| 1           | 0.543        | 0.470        | 0.510 | 0.996        | 0.881 | 0.891 | <b>0.703</b> | 0.613        | 0.649        |
| 2           | 0.687        | 0.535        | 0.582 | 0.891        | 0.829 | 0.893 | <b>0.775</b> | 0.650        | 0.705        |
| 3           | 0.629        | 0.733        | 0.813 | 0.567        | 0.456 | 0.361 | <b>0.596</b> | 0.563        | 0.500        |
| 4           | 0.588        | 0.436        | 0.493 | 0.374        | 0.268 | 0.305 | <b>0.457</b> | 0.332        | 0.377        |
| 5           | 0.650        | 0.771        | 0.860 | 0.429        | 0.266 | 0.360 | <b>0.517</b> | 0.395        | 0.507        |
| 6           | 0.932        | 0.537        | 0.577 | 0.751        | 0.285 | 0.394 | <b>0.832</b> | 0.372        | 0.469        |
| 7           | 0.780        | 0.566        | 0.702 | 0.962        | 0.748 | 0.776 | <b>0.861</b> | 0.645        | 0.737        |
| 8           | 0.657        | 0.635        | 0.744 | 0.607        | 0.475 | 0.554 | 0.631        | 0.544        | <b>0.635</b> |
| 9           | 0.493        | 0.570        | 0.624 | 0.931        | 0.624 | 0.676 | 0.645        | 0.596        | <b>0.649</b> |
| 10          | 0.581        | 0.494        | 0.545 | 0.470        | 0.367 | 0.376 | <b>0.520</b> | 0.421        | 0.445        |
| 11          | 0.486        | 0.465        | 0.553 | 0.553        | 0.330 | 0.346 | <b>0.517</b> | 0.386        | 0.426        |
| 12          | 0.506        | 0.419        | 0.553 | 0.944        | 0.797 | 0.874 | 0.659        | 0.549        | <b>0.677</b> |
| 13          | 0.859        | 0.465        | 0.533 | 0.527        | 0.558 | 0.598 | <b>0.653</b> | 0.507        | 0.564        |
| 14          | 0.962        | 0.491        | 0.609 | 0.635        | 0.335 | 0.324 | <b>0.765</b> | 0.399        | 0.423        |
| 15          | 0.910        | 0.654        | 0.616 | 0.494        | 0.256 | 0.278 | <b>0.640</b> | 0.368        | 0.383        |
| Average     | <b>0.684</b> | 0.549        | 0.621 | <b>0.675</b> | 0.498 | 0.534 | <b>0.651</b> | 0.489        | 0.543        |
| Variance    | 0.025        | <b>0.011</b> | 0.011 | <b>0.044</b> | 0.048 | 0.050 | 0.013        | <b>0.012</b> | 0.014        |

PF = Particle filter

همانطور که در جدول ۵-۲ ملاحظه می‌شود، در تشخیص اعمال مختلف، مقدار F-measure برای DCPAR+PF بسیار بیشتر بوده و یا اختلاف کمی با دیگر روش‌ها دارد. همچنین، در مجموع ملاحظه می‌شود که DCPAR+PF با میانگین دقت، یادآوری، و F-measure به ترتیب،  $0.684/0.675/0.651$  و  $0.025/0.011/0.014$  و  $0.649/0.543/0.543$  می‌باشد.

<sup>۱</sup> Grid search

عملکرد بهتری نسبت به دیگر روش‌ها داشته است. به علاوه، همانطور که در شکل ۱۵-۵ نشان داده شده، DCPAR+PF منجر به صحت  $0.6613$  شده است که بسیار بهتر از  $0.5103$  و  $0.5886$  صحت رویکردهای مبتنی بر FCRF و CHMM می‌باشد.



شکل ۱۵-۵. صحت روش‌های شناسایی اعمال.

به منظور ارزیابی بیشتر، الگوریتم CPAR را نیز برای بازشناسی اعمال بر روی دنباله داده‌های تفکیک شده به کار گرفتیم. این رویکرد را CPAR+PF نامیده‌ایم. مقایسه رویکردهای DCPAR+PF و CPAR+PF در جدول ۳-۵ آورده شده است. همانطور که ملاحظه می‌شود، DCPAR+PF در تشخیص تمامی اعمال F-measure بیشتری نسبت به CPAR+PF داشته است. و این مجدداً نشان می‌دهد که کمینه سازی عدم قطعیت در فرآیند تشخیص اعمال تاثیر مثبتی داشته است. همچنین، ملاحظه می‌شود که CPAR+PF با میانگین دقت، یادآوری، و F-measure به ترتیب،  $0.5814$ ،  $0.6113$ ، و  $0.5314$ ، عملکرد ضعیف‌تری نسبت به DCPAR+PF از خود نشان داده است. به علاوه، همانطور که در شکل ۱۵-۵ نشان داده شده، CPAR+PF با صحت  $0.5679$  کارایی پایین‌تری نسبت به DCPAR+PF داشته است.

جدول ۵-۳. مقایسه DCPAR+PF و CPAR+PF

| Activity ID | Precision    |         | Recall       |         | F-Measure    |         |
|-------------|--------------|---------|--------------|---------|--------------|---------|
|             | DCPAR+PF     | CPAR+PF | DCPAR+PF     | CPAR+PF | DCPAR+PF     | CPAR+PF |
| 1           | 0.543        | 0.278   | 0.996        | 0.983   | <b>0.703</b> | 0.433   |
| 2           | 0.687        | 0.541   | 0.891        | 0.927   | <b>0.775</b> | 0.683   |
| 3           | 0.629        | 0.559   | 0.567        | 0.606   | <b>0.596</b> | 0.582   |
| 4           | 0.588        | 0.374   | 0.374        | 0.307   | <b>0.457</b> | 0.337   |
| 5           | 0.650        | 0.437   | 0.429        | 0.578   | <b>0.517</b> | 0.498   |
| 6           | 0.932        | 0.835   | 0.751        | 0.615   | <b>0.832</b> | 0.708   |
| 7           | 0.780        | 0.671   | 0.962        | 0.933   | <b>0.861</b> | 0.780   |
| 8           | 0.657        | 0.438   | 0.607        | 0.487   | <b>0.631</b> | 0.461   |
| 9           | 0.493        | 0.288   | 0.931        | 0.892   | <b>0.645</b> | 0.435   |
| 10          | 0.581        | 0.638   | 0.470        | 0.358   | <b>0.520</b> | 0.459   |
| 11          | 0.486        | 0.702   | 0.553        | 0.373   | <b>0.517</b> | 0.487   |
| 12          | 0.506        | 0.416   | 0.944        | 0.968   | <b>0.659</b> | 0.582   |
| 13          | 0.859        | 0.860   | 0.527        | 0.236   | <b>0.653</b> | 0.371   |
| 14          | 0.962        | 0.893   | 0.635        | 0.412   | <b>0.765</b> | 0.564   |
| 15          | 0.910        | 0.832   | 0.494        | 0.516   | <b>0.640</b> | 0.637   |
| Average     | <b>0.684</b> | 0.584   | <b>0.675</b> | 0.613   | <b>0.651</b> | 0.534   |
| Variance    | <b>0.025</b> | 0.041   | <b>0.044</b> | 0.064   | <b>0.013</b> | 0.015   |

## ۵-۶ جمع بندی

در این فصل، به بحث در خصوص مدل سازی دنباله داده های کاربران و تشخیص اعمال آنان در محیطی چند کاربره پرداختیم. بدین منظور، دنباله داده های کاربران را با یک زنجیره مارکوف مدل کردیم و پارامترهای مدل را از روی داده های مجتمع کاربران و بدون تفکیک دنباله های آنان محاسبه نمودیم. بدین منظور، روشی را پیشنهاد نمودیم که از اطلاعات مکانی حسگرها برای تنظیم و نهایتاً بهبود تخمین پارامترهای زنجیره مارکوف استفاده می نماید. در ارزیابی ها نشان دادیم که استفاده از این اطلاعات مکانی می تواند به تخمین دقیق تر پارامترها کمک کند. پس از تخمین پارامترهای زنجیره مارکوف (یعنی ماتریس انتقال)، از آن در یک الگوریتم فیلتر ذرات برای تفکیک دنباله های داده کاربران استفاده کردیم. در نهایت، پس از استخراج دنباله داده های کاربران از داده های مجتمع، با بکارگیری فرآیندهای بازشناسی اعمال در محیط های تک کاربره، به بازشناسی اعمال روی دنباله های از هم تفکیک شده پرداختیم. در ارزیابی ها، با به کارگیری یک مجموعه داده معروف، کارایی رویکرد بازشناسی اعمال پیشنهادی را با دو روش پایه و مرسوم که مبتنی بر مدل های گرافیکی CHMM و FCRF هستند،

مقایسه نمودیم. نتایج نشان دادند که رویکرد پیشنهادی با صحت بیش از ۶۶٪ و F-measure بیش از ۶۵٪ عملکرد بهتری نسبت به دیگر روش‌ها داشته است.

## فصل ۶. جمع‌بندی و کارهای آتی

## ۶-۱ جمع‌بندی

در این رساله یک معماری سه لایه برای شناسایی اعمال انسان در خانه‌های هوشمند مبتنی بر حسگرها ارائه گردید. لایه نخست در این معماری مربوط به اخذ داده‌ها توسط شبکه حسگر بیسیم است که در خانه هوشمند نصب گردیده؛ لایه دوم مربوط به تشخیص اعمال در محیط تک کاربره؛ و لایه سوم مربوط به بازشناسی اعمال در محیط چندکاربره می‌باشد.

در لایه دوم معماری پیشنهادی، سعی شده است که با کاهش عدم قطعیت در تصمیم‌گیری، اعمال استنتاج گردند. بدین منظور، دو رویکرد جدید برای بازشناسی اعمال در محیط‌های تک کاربره با تاکید بر کاهش عدم قطعیت ارائه گردیدند. راهکار اول مبتنی بر نظریه دمپستر-شافر، و راهکارهای دوم مبتنی بر بهینه‌سازی می‌باشد. راهکار اول بر این اساس است که با ترکیب عقاید شاهدان در خصوص یک رویداد، عدم قطعیت تصمیم‌گیری در مورد آن رویداد کاهش می‌یابد. در این رهیافت، هر دنباله از حسگرهای تحریک شده القاکننده میزانی از باور، عدم باور، و عدم قطعیت در خصوص هر یک از اعمال می‌باشد. با اجماع عقاید دنباله حسگرهای فعال شده در خصوص اعمال، عملی که بیشترین باور را به خود تخصیص می‌دهد به عنوان عمل انجام شده استنتاج می‌گردد. برای محاسبه عقاید شاهدان (یعنی چندتایی‌هایی از حسگرها)، از تابع توزیع بتا، و برای اجماع بین آنها از عملگر ترکیب دمپستر-شافر استفاده کرده‌ایم. هرچند، در این رویکرد با دو چالش روبرو بودیم: ۱- قطعه بندی جریان داده حسگرها و ۲- کاهش عدم قطعیت یک یا چند حسگر (شاهدان) در مورد اعمال، در صورت فعال شدن مکرر آنها توسط کاربر. در مورد چالش دوم باید گفت که در این رویکرد عدم قطعیت را به تنهایی ناشی از عملکرد خود حسگر (مانند خطاهای سخت افزاری) فرض کردیم و بنابراین منطقی خواهد بود اگر فرض کنیم که با افزایش تعداد فعال سازی‌های حسگرها تعداد دفعاتی که خطا رخ می‌دهد (هشدارهای ناصحیح) نسبت به دفعاتی که حسگرها بدون خطا فعال می‌شود بسیار کم، و در نتیجه عدم قطعیت نیز کاهش



خواهد یافت. اما همیشه عدم قطعیت ناشی از خود حسگر به تنهایی نیست. مثلاً اگر حسگری توسط طراح در مکانی ناصحیح نصب شده باشد ممکن است به ازای تعداد زیادی از اعمال و بدون هیچ خطایی فعال شده و در نتیجه عملاً عدم قطعیت القا شده توسط آن در تصمیم‌گیری در خصوص اعمال بالا باشد. برای مواجهه با دو چالش فوق، رویکردی مبتنی بر بهینه‌سازی محدب ارائه نمودیم. در این رویکرد، یک تابع هدف تفاضل محدب را طوری تعریف کردیم که بدون نیاز به قطعه‌بندی غیر ضمنی جریان داده، و با مینیمم‌سازی آن، بتوانیم باور القا شده توسط هر رویداد حسگر به هر عمل را تخمین بزنیم. این تابع هدف منطبق با مفروضات واقعی و رایج در خانه‌های هوشمند تعریف شد. در این تابع هدف، مفهوم آنتروپی را به عنوان عدم قطعیت در نظر گرفتیم. سعی کردیم آنتروپی باورهای اولیه القا شده توسط یک رویداد حسگر را با در نظر گرفتن باورهای همسایگان آن حسگر در جریان داده ورودی کمینه کنیم. ارزیابی‌ها نشان دادند که این رویکرد می‌تواند کارآیی بهتری در مقایسه با روش‌های مرسوم که مبتنی بر مدل‌های گرافیکی هستند، داشته باشد.

در مقایسه رویکردهای مطرح شده در لایه دوم، باید متذکر شد که در روش مبتنی بر DST، با توجه به اینکه قطعه‌بندی صرفاً بر مبنای زمان مشاهده داده‌های حسگرها انجام می‌گیرد، عمدتاً در محیط‌هایی که در آنها اعمال به صورت ترتیبی انجام می‌گیرند کارآیی مناسبی از خود نشان می‌دهد؛ اما در رویکردهای مبتنی بر بهینه‌سازی (یعنی CPAR و DCPAR) چنین محدودیتی وجود ندارد و همانطور که شبیه‌سازی‌ها نشان دادند، این رویکردها برای بازشناسی اعمال متداخل کارآیی مناسبی را از خود نشان می‌دهند. از سوی دیگر، در CPAR و DCPAR، به منظور استنتاج باید یک مساله بهینه‌سازی محدب یا تفاضل محدب حل شود، که این کار پیچیدگی زمانی بیشتری (از مرتبه چند جمله‌ای بر حسب تعداد متغیرها) نسبت به فرآیند استنتاج در رویکرد مبتنی بر DST خواهد داشت.

در لایه سوم معماری پیشنهادی، ساز و کاری برای تشخیص اعمال در محیط‌های چند کاربره

پیشنهاد داده شد و مورد ارزیابی قرار گرفت. چالش جدی که در محیط‌های چند کاربره با آن مواجه هستیم این است که دنباله داده کاربران در هم تنیده خواهند شد. لذا استفاده از الگوریتم‌های بازشناسی اعمال تک کاربره در چنین محیط‌هایی به صورت مستقیم قابل استفاده نخواهند بود. بدین منظور، در این لایه ابتدا سعی کردیم دنباله‌های داده کاربران را مدل سازی کنیم. مدل مربوطه را یک زنجیره مارکوف در نظر گرفته و پارامترهای آن را با پیشنهاد یک روش تنظیم پارامتر جدید، که مبتنی بر اطلاعات مکانی حسگرها می‌باشد، تخمین زدیم. سپس، با استفاده از مدل محاسبه شده و با ارائه یک راهکار مبتنی بر فیلتر ذرات، دنباله داده‌های کاربران را استخراج نمودیم. سرانجام، هر دنباله از رویدادهای حسگرها را مرتبط با یک کاربر فرض کرده و با فراخوانی الگوریتم‌های بازشناسی اعمال تک کاربره در لایه دوم، برچسب اعمال مربوط به هر رویداد حسگر را تعیین کردیم. ارزیابی‌ها نشان دادند که رویکرد پیشنهادی عملکردی بهتر از روش‌های پایه و مرسوم که عمدتاً مبتنی بر شبکه‌های بیزین پویا (مانند CHMM) و یا شبکه‌های مارکوف پویا (مانند FCRF) هستند، از خود نشان می‌دهد.

## ۶-۲ کارهای آتی

در این رساله به جهت حفظ حریم خصوصی و سادگی استفاده، بر استفاده از حسگرهای دودویی تاکید داشتیم. علیرغم این ویژگی‌ها، این حسگرها داده‌های محدودی را می‌توانند جمع‌آوری نمایند که باعث خواهد شد در برخی موقعیت‌ها، از جمله در محیط‌های چند کاربره با کاربران متعدد، فرآیند بازشناسی اعمال عملکرد مناسبی نداشته باشد. امروزه با پیشرفت فناوری‌های توسعه حسگرها، حسگرهایی وجود دارند که تا حد زیادی حریم خصوصی اشخاص را حفظ کرده و نیز داده‌های مفیدی را می‌توانند جمع‌آوری نمایند. از جمله این حسگرها، حسگرهای تشخیص عمق هستند که می‌توانند نقشه عمق در یک محیط را با دقت مناسبی در اختیار قرار دهند. لذا برآن خواهیم بود تا از این حسگرها در کنار دیگر حسگرهای مورد اشاره، برای ردیابی و تشخیص حضور افراد در محیط استفاده نمائیم.

در این رساله، به بازشناسی اعمال ساده پرداختیم. اما در زندگی روزمره ما اعمالی وجود دارند که خود از چندین عمل ساده تشکیل شده‌اند. برای تشخیص این گونه اعمال معمولاً از مدل‌های سلسله مراتبی استفاده می‌کنند. هرچند، آموزش چنین مدل‌هایی معمولاً پیچیدگی محاسباتی بالایی دارد. بررسی و توسعه رویکردهایی در ارتباط با تشخیص این گونه اعمال نیز به عنوان یک رویکرد آتی مد نظر خواهد بود.

امروزه اینترنت اشیا (IoT<sup>۱</sup>) یک فناوری نوظهور و در حال توسعه تلقی می‌شود. با شناسایی اعمال انسان در خانه‌های هوشمند در کنار IoT، می‌توان خدماتی متناسب با اعمال کاربران به آنها ارائه نمود. لذا در ادامه، طراحی یک سیستم پیشنهادگر<sup>۲</sup> مبتنی بر IoT برای ارائه خدماتی به صورت خودمختار در جهت کمک به کاربران مد نظر خواهد بود.

---

<sup>۱</sup> Internet of things

<sup>۲</sup> Recommender system



- [١] R. Amini, S. R. I., and R. Sahaf (2013), "AGING IN IRAN: PAST, PRESENT AND FUTURE", *J. Aging Emerg. Econ.*, pp. **18**.
- [٢] Brush, A., B. Lee, et al. (2011), "Home automation in the wild: challenges and opportunities", proceedings of the SIGCHI Conference on Human Factors in Computing Systems, pp. **2115-2124** .
- [٣] Lu, J., T. Sookoor, et al. (2010), "The smart thermostat: using occupancy sensors to save energy in homes", *Proceedings of the 8th ACM Conference on Embedded Networked Sensor Systems*, pp. **211-22**.
- [٤] Rashidi, P., D. J. Cook, et al. (2011), "Discovering activities to recognize and track in a smart environment", *IEEE transactions on knowledge and data engineering*, **23**, **4**, pp. **527-539**.
- [٥] Rashidi, P. and D. J. Cook (2013), "COM: A method for mining and monitoring human activity patterns in home-based health monitoring systems", *ACM Transactions on Intelligent Systems and Technology (TIST)*, **4**, **4**, pp. **64**.
- [٦] Krishnan, N. C. and D. J. Cook (2014), "Activity recognition on streaming sensor data", *Pervasive and mobile computing*, **10**, pp. **138-154**.
- [٧] Crandall, A. S. and D. J. Cook (2010), "Using a hidden markov model for resident identification", *Sixth International Conference on Intelligent Environments*, pp. **74-79** .
- [٨] Kim, E., S. Helal, et al. (2010), "Human activity recognition and pattern discovery", *IEEE Pervasive Computing*, **9**, **1**, pp. **1-10**.
- [٩] Van Kasteren, T., G. Englebienne, et al. (2010), "Activity recognition using semi-markov models on real world smart home datasets", *Journal of ambient intelligence and smart environments*, **2**, **3**, pp. **311-325**.
- [١٠] van Kasteren, T. L. M. (2011), Ph.D. thesis, "Activity recognition for health monitoring elderly using temporal probabilistic models", Faculty of Science, University Van Amstrdam, Amstrdam, Netherlands.
- [١١] Bellinger, C. and B. J. Oommen (2012), On the pattern recognition and classification of stochastically episodic events, pp. **1-35**, In: "Transactions on Computational Collective Intelligence VI."
- [١٢] Benmansour, A., A. Bouchachia, et al. (2016), "Multioccupant activity recognition in pervasive smart home environments", *ACM Computing Surveys (CSUR)*, **48**, **3**, pp. **34**.
- [١٣] "Center for Advanced Studies in Adaptive Systems (CASAS)", Retrieved 01-Feb-2015, from <http://ailab.wsu.edu/casas/datasets>.
- [١٤] Wang, L., T. Gu, et al. (2009), "Sensor-based human activity recognition in a multi-user scenario", *European Conference on Ambient Intelligence*, pp. **78-87** .

- [١٤] Wang, L., T. Gu, et al. (2011), "Multi-user activity recognition in a smart home", Activity recognition in pervasive intelligent environments, pp. **59-81**.
- [١٥] Wang, L., T. Gu, et al. (2011), "Recognizing multi-user activities using wearable sensors in a smart home", Pervasive and mobile computing, **7, 3**, pp. **287-298**.
- [١٦] Koller, D. and N. Friedman (2009), "Probabilistic graphical models: principles and techniques", Vol. 1, MIT press, Boston.
- [١٧] Weiser, M. (1991), "The computer for the twenty-first century", Scientific American, **5, 1**, pp. **94-100**.
- [١٨] Cohen, C. J., K. A. Scott, et al. (2008), "Behavior recognition architecture for surveillance applications", Applied Imagery Pattern Recognition Workshop, pp. **1-8**.
- [١٩] Koskimaki, H., V. Huikari, et al. (2009), "Activity recognition using a wrist-worn inertial measurement unit: A case study for industrial assembly lines", Mediterranean Conference on Control and Automation, pp. **401-405**.
- [٢٠] Hagaras, H., V. Callaghan, et al. (2004), "Creating an ambient-intelligence environment using embedded agents", IEEE Intelligent Systems, **19, 6**, pp. **12-20**.
- [٢١] Turaga, P., R. Chellappa, et al. (2008), "Machine recognition of human activities: A survey", IEEE Transactions on Circuits and Systems for Video Technology, **18, 11**, pp. **1473-1488**.
- [٢٢] Aggarwal, J. K. and M. S. Ryoo (2011) ", Human activity analysis: A review", ACM Comput. Surv., **43, 3**, pp. **1-43**.
- [٢٣] Akansha ,U. A., M. Shailendra, et al. (2016), "Analytical review on video-based human activity recognition", Computing for Sustainable Global Development (INDIACom), 2016 3rd International Conference on, pp. **3839-3844**.
- [٢٤] Liu, Y., X. Zhang, et al. (2010), "Visual analysis of child-adult interactive behaviors in video sequences", International Conference on Virtual Systems and Multimedia (VSMM), pp. **26-33**.
- [٢٥] Swears, E., A. Hoogs, et al. (2014), "Complex activity recognition using granger constrained dbn (gcdbn) in sports and surveillance video", Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. **788-795**.
- [٢٦] Wang, X. and Q. Ji (2014), "A hierarchical context model for event recognition in surveillance video", Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. **2561-2568**.
- [٢٧] Zhang, L., Y. Gao, et al. (2014), "Actively learning human gaze shifting paths for semantics-aware photo cropping", IEEE Transactions on Image Processing, **23, 5**, pp. **2235-2245**.
- [٢٨] Tai, Y.-W. and S. Lin (2012), "Motion-aware noise filtering for deblurring of noisy and blurry images", IEEE Conference on Computer Vision and Pattern Recognition, pp. **17-24**.
- [٢٩] Zhang, L., M. Song, et al. (2013), "Probabilistic graphlet cut: Exploiting spatial structure cue for weakly supervised image segmentation", Proceedings of the IEEE

Conference on Computer Vision and Pattern Recognition, pp. **1908-1915** .

[٣٧] Zhang, L., Y. Gao, et al. (2014), "Representative discovery of structure cues for weakly-supervised image segmentation", *IEEE Transactions on Multimedia*, **16**, **2**, pp. **470-479**.

[٣٨] Low, D. G. (1999), "Object recognition from local scale-invariant features", *Proceedings of the International Conference on Computer Vision*, pp. **1150-1157**.

[٣٩] Dalal, N. and B. Triggs (2005), "Histograms of oriented gradients for human detection", *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. **886-893** .

[٤٠] Laptev, I., M. Marszalek, et al. (2008), "Learning realistic human actions from movies", *IEEE Conference on Computer Vision and Pattern Recognition*, pp. **1-8** .

[٤١] Jain, M., H. Jegou, et al. (2013), "Better exploiting motion for better action recognition", *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. **2555-2562** .

[٤٢] Lillo, I., J. C. Niebles, et al. (2017), "Sparse composition of body poses and atomic actions for human activity recognition in RGB-D videos", *Image and Vision Computing*, **59**, pp. **63-75**.

[٤٣] Manzi, A., F. Cavallo, et al. (2016), "A 3D Human Posture Approach for Activity Recognition Based on Depth Camera", *European Conference on Computer Vision*, pp. **432-447** .

[٤٤] Mo, L., F. Li, et al. (2016), "Human physical activity recognition based on computer vision with deep learning model", *IEEE International Conference on Instrumentation and Measurement Technology*, pp. **1-6** .

[٤٥] Liu, Y., L. Nie, et al. (2016), "From action to activity: Sensor-based activity recognition", *Neurocomputing*, **181**, pp. **108-115**.

[٤٦] Chen, L., J. Hoey, et al. (2012), "Sensor-based activity recognition", *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, **42**, **6**, pp. **790-808**.

[٤٧] Rasch, K. (2013), Ph.D. thesis, "Smart assistants for smart homes", *Dep. of Computer Science, KTH Royal Institute of Technology, Sweden*.

[٤٨] Mukhopadhyay, S. C. (2015), "Wearable sensors for human activity monitoring: A review", *IEEE sensors journal*, **15**, **3**, pp. **1321-1330**.

[٤٩] Bao, L. and S. S. Intille (2004), "Activity recognition from user-annotated acceleration data", *International Conference on Pervasive Computing*, pp. **1-17** .

[٥٠] Wang, Z., D. Wu, et al. (2016), "A triaxial accelerometer-based human activity recognition via EEMD-based features and game-theory-based feature selection", *IEEE sensors journal*, **16**, **9**, pp. **3198-3207**.

[٥١] Ignatov, A. D. and V. V. Strijov (2016), "Human activity recognition using quasiperiodic time series collected from a single tri-axial accelerometer", *Multimedia tools and applications*, **75**, **12**, pp. **7257-7270**.

- [٤٢] Shoaib, M., S. Bosch, et al. (2016), "Complex human activity recognition using smartphone and wrist-worn motion sensors", *Sensors*, **16**, **4**, pp. **426**.
- [٤٣] Harms, H., O. Amft, et al. (2008), "Smash: A distributed sensing and processing garment for the classification of upper body postures", *International conference on Body area networks*, pp. **22** .
- [٤٤] Lara, O. D., A. J. Pérez, et al. (2012), "Centinela: A human activity recognition system based on acceleration and vital sign data", *Pervasive and mobile computing*, **8**, **5**, pp. **717-729**.
- [٤٥] Lara, O. D. and M. A. Labrador (2013), "A survey on human activity recognition using wearable sensors", *IEEE Communications Surveys and Tutorials*, **15**, **3**, pp. **1192-1209**.
- [٤٦] Patterson, D. J., L. Liao, et al. (2003), "Inferring high-level behavior from low-level sensors", *International Conference on Ubiquitous Computing*, pp. **73-89** .
- [٤٧] Ashbrook, D. and T. Starner (2003), "Using GPS to learn significant locations and predict movement across multiple users", *Personal and Ubiquitous computing*, **7**, **5**, pp. **275-286**.
- [٤٨] Liao, L., D. J. Patterson, et al. (2007), "Learning and inferring transportation routines", *Artificial Intelligence*, **171**, **5-6**, pp. **311-331**.
- [٤٩] Rashidi, P. and A. Mihailidis (2013), "A survey on ambient-assisted living tools for older adults", *IEEE journal of biomedical and health informatics*, **17**, **3**, pp. **579-590**.
- [٥٠] Jurek, A., C. Nugent, et al. (2014), "Clustering-based ensemble learning for activity recognition in smart homes", *Sensors*, **14**, **7**, pp. **12285-12304**.
- [٥١] Fahad, L. G., S. F. Tahir, et al. (2014), "Activity recognition in smart homes using clustering based classification", *22nd International Conference on Pattern Recognition* pp. **1348-1353** .
- [٥٢] Logan, B., J. Healey, et al. (2007), "A long-term evaluation of sensing modalities for activity recognition", *International conference on Ubiquitous computing*, pp. **483-500** .
- [٥٣] Chen, C., B. Das, et al. (2010), "A data mining framework for activity recognition in smart environments", *Sixth International Conference on Intelligent Environments*, pp. **80-83** .
- [٥٤] Wan, J., M. J. O'grady, et al. (2015), "Dynamic sensor event segmentation for real-time activity recognition in a smart home context", *Personal and Ubiquitous computing*, **19**, **2**, pp. **287-301**.
- [٥٥] Tapia, E. M., S. S. Intille, et al. (2004), "Activity recognition in the home using simple and ubiquitous sensors", *International Conference on Pervasive Computing*, pp. **158-175** .
- [٥٦] Kasteren, T. L., G. Englebienne, et al. (2011), Human activity recognition from wireless sensor network data: Benchmark and software, pp. **165-186**, In: "Activity recognition in pervasive intelligent environments".



- [١٠] Singla, G., D. J. Cook, et al. (2010), "Recognizing independent and joint activities among multiple residents in smart environments", *Journal of ambient intelligence and humanized computing*, **1**, **1**, pp. **57-63**.
- [١١] Duong, T. V., H. H. Bui, et al. (2005), "Activity recognition and abnormality detection with the switching hidden semi-markov model", *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. **838-845** .
- [١٢] Vail, D. L., M. M. Veloso, et al. (2007), "Conditional random fields for activity recognition", *International joint conference on Autonomous agents and multiagent systems*, pp. **235-245** .
- [١٣] Tong, Y. and R. Chen (2014), "Latent-Dynamic Conditional Random Fields for recognizing activities in smart homes", *Journal of ambient intelligence and smart environments*, **6**, **1**, pp. **39-55**.
- [١٤] Hu, D. H. and Q. Yang (2008), "CIGAR: Concurrent and Interleaving Goal and Activity Recognition", *AAAI*, pp. **1363-1368** .
- [١٥] Wilson, D. H. and C. Atkeson (2005), "Simultaneous tracking and activity recognition (STAR) using many anonymous, binary sensors", *International Conference on Pervasive Computing*, pp. **62-79** .
- [١٦] Kan, P., R. Huq, et al. (2011), "The development of an adaptive upper-limb stroke rehabilitation robotic system", *Journal of neuroengineering and rehabilitation*, **8**, **1**, pp. **33**.
- [١٧] Cho, H., J. An ,et al. (2015), "Automatic sensor data stream segmentation for real-time activity prediction in smart spaces", *Proceedings of the 2015 Workshop on IoT challenges in Mobile and Industrial Systems*, pp. **13-18** .
- [١٨] Yala, N., B. Fergani, et al. (2017), "Towards improving feature extraction and classification for activity recognition on streaming data", *J. Ambient Intelligence and Humanized Computing*, **8**, **1**, pp. **177-189**.
- [١٩] Ordóñez, F. J., P. de Toledo, et al. (2013), "Activity recognition using hybrid generative/discriminative models on home environments using binary sensors", *Sensors*, **13**, **5**, pp. **5460-5477**.
- [٢٠] Fatima, I., M. Fahim, et al. (2013), "A unified framework for activity recognition-based behavior analysis and action prediction in smart homes", *Sensors*, **13**, **2**, pp. **2682-2699**.
- [٢١] Fergani, B. (2012), "Evaluating C-SVM, CRF and LDA classification for daily activity recognition", *International Conference on Multimedia Computing and Systems*, pp. **272-277** .
- [٢٢] Rabiner, L. and B. Juang (1986), "An introduction to hidden Markov models", *IEEE ASSP Magazine*, **3**, **1**, pp. **4-16**.
- [٢٣] Chua, S.-L., S. Marsland, et al. (2009), "Behaviour recognition from sensory streams in smart environments", *Australasian Joint Conference on Artificial Intelligence*, pp. **666-675**.

- [VΔ] Singla, G. and D. J. Cook (2009), "Interleaved Activity Recognition for Smart Home residents", *Intelligent Environments*, **9**, **1**, pp. **145-152**.
- [Vϕ] Lafferty, J., A. McCallum, et al. (2001), "Conditional random fields: Probabilistic models for segmenting and labeling sequence data", *Proceedings of the eighteenth international conference on machine learning*, pp. **282-289** .
- [V∇] Gu, T., Z. Wu, et al. (2009), "epsicar: An emerging patterns based approach to sequential, interleaved and concurrent activity recognition", *IEEE International Conference on Pervasive Computing and Communications*, pp. **1-9** .
- [V^] Crandall, A. S. and D. J. Cook (2009), "Coping with multiple residents in a smart environment", *Journal of ambient intelligence and smart environments*, **1**, **4**, pp. **323-334**.
- [V^] Crandall, A. S. and D. J. Cook (2008), "Resident and Caregiver: Handling Multiple People in a Smart Care Facility", *AAAI Fall Symposium: AI in Eldercare: New Solutions to Old Problems*, pp. **39-47** .
- [^·] Chiang, Y.-T., K.-C. Hsu, et al. (2010), "Interaction models for multiple-resident activity recognition in a smart home", *International Conference on Intelligent Robots and Systems*, pp. **3753-3758** .
- [^] Palmes, P., H. K. Pung, et al. (2010), "Object relevance weight pattern mining for activity recognition and segmentation", *Pervasive and mobile computing*, **6**, **1**, pp. **43-57**.
- [^] Pentney, W., A.-M. Popescu, et al. (2006), "Sensor-based understanding of daily life via large-scale use of common sense", *AAAI*, pp. **4-9** .
- [^] Perkowitz, M., M. Philipose, et al. (2004), "Mining models of human activities from the web", *International conference on World Wide Web*, pp. **573-582** .
- [^] Nguyen, A., D. Moore, et al. (2007), "Unsupervised clustering of free-living human activities using ambulatory accelerometry", *Annual International Conference on Engineering in Medicine and Biology*, pp. **4895-4898** .
- [^Δ] Chua, S.-L., S. Marsland, et al. (2011), "Unsupervised learning of human behaviours", *AAAI*, pp. **319-324** .
- [^ϕ] Cook, D. J., N. C. Krishnan, et al. (2013), "Activity discovery and activity recognition: A new partnership", *IEEE transactions on cybernetics*, **43**, **3**, pp. **820-828**.
- [^∇] Cook, D. J. (2012), "Learning setting-generalized activity models for smart spaces", *IEEE Intelligent Systems*, **27**, **1**, pp. **32-38**.
- [^^] Guan, D., W. Yuan, et al. (2007), "Activity recognition based on semi-supervised learning", *IEEE International Conference on Embedded and Real-Time Computing Systems and Applications*, pp. **469-475** .
- [^] Ghazvininejad, M., H. R. Rabiee, et al. (2011), "HMM based semi-supervised learning for activity recognition", *Proceedings of the 2011 international workshop on Situation activity & goal awareness*, pp. **95-100** .
- [^·] Stikic, M., D. Larlus, et al. (2009), "Multi-graph based semi-supervised learning for activity recognition", *International Symposium on Wearable Computers*, pp. **85-92**.

- [٩١] Hu, D. H. and Q. Yang (2011), "Transfer learning for activity recognition via sensor mapping", IJCAI Proceedings-International Joint Conference on Artificial Intelligence, pp. **1962** .
- [٩٢] Van Kasteren, T., G. Englebienne, et al. (2008), "Recognizing Activities in Multiple Contexts using Transfer Learning", AAAI Fall Symposium on AI in Eldercare: New Solutions to Old Problems, pp. **142-149** .
- [٩٣] Rashidi, P. and D. J. Cook (2010), "Activity Recognition Based on Home to Home Transfer Learning", AAAI workshop on Plan, Activity, and Intent Recognition, pp. **1-10**.
- [٩٤] Wyatt, D., M. Philipose, et al. (2005), "Unsupervised activity recognition using automatically mined common sense", AAAI, pp. **21-27** .
- [٩٥] Tapia, E., T. Choudhury, et al. (2006), "Building reliable activity models using hierarchical shrinkage and mined ontology", International Conference on Pervasive Computing, pp. **17-32** .
- [٩٦] Carberry, S. (2001), "Techniques for plan recognition", User Modeling and User-Adapted Interaction, **11, 1**, pp. **31-48**.
- [٩٧] Shanahan, M. (1997), "Solving the frame problem: a mathematical investigation of the common sense law of inertia", Vol. 1, MIT press, Boston.
- [٩٨] Chen, L., C. D. Nugent, et al. (2008), "A logical framework for behaviour reasoning and assistance in a smart home", International Journal of Assistive Robotics and Mechatronics, **9, 4**, pp. **20-34**.
- [٩٩] Medjahed, H., D. Istrate, et al. (2009), "Human activities of daily living recognition using fuzzy logic for elderly home monitoring", IEEE International Conference on Fuzzy Systems, pp. **2001-2006**.
- [١٠٠] Iglesias, J. A., P. Angelov, et al. (2010), "Human activity recognition based on evolving fuzzy systems", International Journal of Neural Systems, **20, 05**, pp. **355-364**.
- [١٠١] Yamada, N., K. Sakamoto, et al. (2007), "Applying ontology and probabilistic model to human activity recognition from surrounding things", IPSJ Digital Courier, **3, 1**, pp. **506-517**.
- [١٠٢] Chen, L., C. D. Nugent, et al. (2012), "A knowledge-driven approach to activity recognition in smart homes", IEEE transactions on knowledge and data engineering, **24, 6**, pp. **961-974**.
- [١٠٣] Chen, L. and C. Nugent (2009), "Ontology-based activity recognition in intelligent pervasive environments", International Journal of Web Information Systems, **5, 4**, pp. **410-430**.
- [١٠٤] Liao, J., Y. Bi, et al. (2009), "Evidence fusion for activity recognition using the Dempster-Shafer theory of evidence", International Conference on Information Technology and Applications in Biomedicine, pp. **1-4** .
- [١٠٥] Liao, J., Y. Bi, et al. (2011), "Using the Dempster–Shafer theory of evidence with a revised lattice structure for activity recognition", IEEE Transactions on Information Technology in Biomedicine, **15, 1**, pp. **74-82**.

- [١٠٢] Mckeever, S., J. Ye, et al. (2010), "Activity recognition using temporal evidence theory", *Journal of ambient intelligence and smart environments*, **2**, **3**, pp. **253-269**.
- [١٠٣] Liao, J., Y. Bi, et al. (2011), "A weight factor algorithm for activity recognition utilizing a lattice-based reasoning structure", *IEEE International Conference on Tools with Artificial Intelligence*, pp. **906-907**.
- [١٠٤] Chen, L., C. Nugent, et al. (2014), "An ontology-based hybrid approach to activity modeling for smart homes", *IEEE Transactions on human-machine systems*, **44**, **1**, pp. **92-105**.
- [١٠٥] Azkune, G., A. Almeida, et al. (2015), "Extending knowledge-driven activity models through data-driven learning techniques", *Expert Systems with Applications*, **42**, **6**, pp. **3115-3128**.
- [١٠٦] Lee, H., J. S. Choi, et al. (2009), "Sensor data fusion using dsM theory for activity recognition under uncertainty in home-based care", *International Conference on Advanced Information Networking and Applications*, pp. **517-524**.
- [١٠٧] Jøsang, A. (2001), "A logic for uncertain probabilities", *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, **9**, **03**, pp. **279-311**.
- [١٠٨] Lipp, T. and S. Boyd (2016), "Variations and extension of the convex-concave procedure", *Optimization and Engineering*, **17**, **2**, pp. **263-287**.
- [١٠٩] Fayyad, U. and K. Irani (1993), "Multi-interval discretization of continuous-valued attributes for classification learning", *International Joint Conference on Uncertainty in Artificial Intelligence*, pp. **1022-1029**.
- [١١٠] Singla, G., D. J. Cook, et al. (2009), "Tracking activities in complex settings using smart environment technologies", *International journal of biosciences, psychiatry, and technology (IJBSPT)*, **1**, **1**, pp. **25**.
- [١١١] Katz, I. and K. Crammer (2015), "Outlier-Robust Convex Segmentation", *AAAI*, pp. **2701-2707**.
- [١١٢] Zhu, C., H. Xu, et al. (2014), "Convex optimization procedure for clustering: theoretical revisit", *International Conference on Advances in Neural Information Processing Systems*, pp. **1619-1627**.
- [١١٣] Nazerfard, E., B. Das, et al. (2010), "Conditional random fields for activity recognition in smart environments", *Proceedings of the 1st ACM International Health Informatics Symposium*, pp. **282-286**.
- [١١٤] Miller, G. A. (1952), "Finite Markov processes in psychology", *Psychometrika*, **17**, **2**, pp. **149-167**.
- [١١٥] Bernstein, G. and D. Sheldon (2016), "Consistently estimating markov chains with noisy aggregate data", *Artificial Intelligence and Statistics*, pp. **1142-1150**.
- [١١٦] Busnel, Y., L. Querzoni, et al. (2011), "Analysis of deterministic tracking of multiple objects using a binary sensor network", *ACM Transactions on Sensor Networks (TOSN)*, **8**, **1**, pp. **8**.
- [١١٧] Shrivastava, N., R. M. U. Madhow, et al. (2006), "Target tracking with binary

proximity sensors: fundamental limits, minimal descriptions, and algorithms", International conference on Embedded networked sensor systems, pp. **251-264** .

[١٢٢] Singh, J., U. Madhow, et al. (2007), "Tracking multiple targets using binary proximity sensors", Proceedings of the 6th international conference on Information processing in sensor networks, pp. **529-538** .

[١٢٣] Manning, C. D., P. Raghavan, et al. (2008), "Introduction to Information Retrieval", Vol. 20, Cambridge University Press, Cambridge.

[١٢٤] Tsoumakas, G., I. Katakis ,et al. (2009), Mining multi-label data, pp. **667-685**, In: "Data mining and knowledge discovery handbook."



## واژه نامه

|                              |                       |   |                                 |
|------------------------------|-----------------------|---|---------------------------------|
| Accelerometer                | شتاب سنج              | Imbalanced data                         | داده‌های نامتعادل               |
| Accept area                  | ناحیه پذیرش           | Information gain                        | بهره اطلاعاتی                   |
| Accessibility graph          | گراف دسترسی           | Interleaved                             | متداخل                          |
| Accuracy                     | صحت                   | Internet of things                      | اینترنت اشیاء                   |
| Actuator                     | عملگر                 | Interwoven                              | در هم تنیده                     |
| Aggregate data               | داده‌های مجتمع        | K nearest neighbor                      | K- نزدیکترین همسایه             |
| Ambient activity recognition | شناسایی اعمال محیطی   | Kernel function                         | تابع هسته                       |
| Artificial neural networks   | شبکه‌های عصبی مصنوعی  | Knowledge-driven                        | مبتنی بر دانش                   |
| Axiom                        | اصل                   | Latent                                  | نهان                            |
| Basic probability assignment | تخصیص احتمال پایه     | Latent dynamic conditional random field | میدان تصادفی شرطی نهان دینامیکی |
| Belief                       | باور                  | Log                                     | لاگ                             |
| Belief Mass                  | توده باور             | Manifold                                | منیفلد                          |
| Change point                 | نقطه تغییر            | Multi-label classification              | رده بندی با چند برچسب           |
| Cluster                      | خوشه                  | Multi-Layer perceptron                  | پرسپترون چند لایه               |
| Code Word                    | کلمه رمزی             | Naïve Bayes Classifier                  | رده بند ساده بیز                |
| Concave                      | مقعر                  | Norm                                    | نرم                             |
| Concurrent                   | هم‌روند               | Obtrusiveness                           | تزاحم                           |
| Conditional least squares    | کم‌ترین مربعات شرطی   | Offline                                 | برون خطی                        |
| Conditional random fields    | میدان‌های تصادفی شرطی | Ontology-based                          | مبتنی بر هستان شناسی            |
| Contact sensors              | حسگرهای تماسی         | Opinion                                 | عقیده                           |
| Context-aware                | آگاه به متن           | Opinion space                           | فضای عقاید                      |
| Contextual                   | متنی                  | Opinion Triangle                        | مثلث عقاید                      |
| Convex-concave procedure     | روال محدب-مقعر        | Paired t-test                           | آزمون t زوجی                    |
| Coupled hidden Markov model  | مدل مخفی مارکوف کوپل  | Parallel HMM                            | مدل مخفی مارکوف موازی           |
| Data-driven                  | مبتنی بر داده         | Particle filter                         | فیلتر ذرات                      |
| Deep learning                | یادگیری عمیق          | Partitioning                            | تفکیک                           |
| Dempster-Shafer theory       | نظریه دمپستر-شافر     | Peaked                                  | قله ای                          |
| Dense Sensing                | سنجش متراکم           | Plan                                    | برنامه                          |
| Dense sensing-based          | مبتنی بر سنجش متراکم  | Planning                                | برنامه ریزی                     |

|                                     |  |                                |                           |
|-------------------------------------|--|--------------------------------|---------------------------|
| Descriptive features                | ویژگی های توصیفی                       | Precision                      | دقت                       |
| Difference of convex programming    | برنامه-ریزی تفاضل محدب                 | Predicate                      | محمول                     |
| Directed acyclic graph              | گراف جهت دار بدون دور                  | Primary belief vector          | بردار باور اولیه          |
| Discretization                      | گسسته سازی                             | Prior Knowledge                | دانش پیشین                |
| Discriminative                      | تمایزی                                 | Privacy                        | حریم خصوصی                |
| Dynamic Bayesian network            | شبکه های بیزین دینامیک                 | Probabilistic graphical models | مدل های احتمالاتی گرافیکی |
| Edit distance                       | فاصله ویرایش                           | Proximity sensor               | حسگر مجاورت               |
| Emerging Pattern                    | الگوی در حال ظهور                      | Purity                         | خلوص                      |
| Emission matrix                     | ماتریس نشر                             | Raw data                       | داده های خام              |
| Ensemble                            | ترکیبی                                 | Recall                         | یادآوری                   |
| Entropy                             | آنتروپی                                | Regularization parameters      | پارامترهای تنظیم          |
| Environmental                       | محیطی                                  | Regularize                     | تنظیم کردن                |
| Ergodic                             | ارگودیک                                | Sampling                       | نمونه برداری              |
| Evaluation                          | ارزیابی                                | Secondary belief vector        | بردار باور ثانویه         |
| Event Calculus                      | حساب رویداد                            | Segmentation                   | قطعه بندی                 |
| Event                               | رویداد                                 | Self-organizing map            | نگاشت های خودسازمانده     |
| Evidence                            | شهود                                   | Semi-supervised                | نیمه نظارتی               |
| Evidence theory based KNN           | k-نزدیکترین همسایه مبتنی بر نظریه شهود | Sequential                     | ترتیبی                    |
| Extend                              | بسط                                    | Skip-chain                     | زنجیره پرش                |
| Factorial conditional random fields | میدان های تصادفی شرطی فاکتوری          | Smart house, Smart home        | خانه هوشمند               |
| False alarm                         | هشدار غلط                              | Smoothing                      | هموار سازی                |
| False negative                      | منفی ناصحیح                            | Stochastic Episodic Events     | رویدادهای مرحله ای تصادفی |
| False positive                      | مثبت ناصحیح                            | Supervised                     | با نظارت                  |
| Flatness                            | تسطیح                                  | Support vector machine         | ماشین بردار پشتیبان       |
| Formal                              | رسمی، مبتنی بر بیان ریاضی              | Switch Sensors                 | حسگرهای دو حالته (سویچ)   |
| Fragment                            | بخش                                    | Template graph                 | گراف قالب                 |
| Frame of Discernment                | قاب برآمدها                            | Temporal information           | اطلاعات زمانی             |
| Frobenius norm                      | نرم فراینیوس                           | Time Invariant                 | ثابت نسبت به زمان         |
| Fusion                              | تجمع                                   | Tokens                         | نشانه ها                  |
| Gaussian                            | گاوسی                                  | Tracking                       | تعقیب                     |



|                                  |                              |                        |                          |
|----------------------------------|------------------------------|------------------------|--------------------------|
| Generative                       | تولیدی                       | Transfer learning      | انتقال یادگیری           |
| Global Positioning System        | سیستم مکان یابی جهانی        | Triaxial accelerometer | شتاب سنخ سه محوره        |
| Ground truth                     | مقدار حقیقی                  | True negative          | منفی صحیح                |
| Gyroscope                        | ژیروسکوپ                     | Ubiquitous Computing   | محاسبات همیشه حاضر       |
| Hidden Markov model              | مدل مخفی مارکوف              | Uncertainty            | عدم قطعیت                |
| Hidden Semi-Markov Model         | مدل نیمه-مارکوف مخفی         | True positive          | مثبت صحیح                |
| Hierarchical hidden Markov model | مدل مخفی مارکوف سلسله مراتبی | Unobtrusive            | بدون تزاخم               |
| Home usage                       | خانگی                        | Unrolled               | باز شده                  |
| Human-computer interaction       | تعامل انسان-کامپیوتر         | Unsupervised           | بدون نظارت               |
| Hybrid                           | هیبریدی                      | Vision-based           | مبتنی بر تصویر           |
| Monitoring Systems               | سیستم های نظارتی             | Viterbi                | ویتربی                   |
| Sensor-based                     | مبتنی بر حسگر                | Wearable sensor-based  | مبتنی بر حسگرهای پوشیدنی |
|                                  |                              | Web Mining             | وب کاوی                  |



## ***Abstract***

Nowadays, development of smart homes, aiming at human convenient lives, has garnered substantial attentions. This issue is motivated by assisting elderly and infirm individuals, providing high levels of security, energy management, and medical healthcare. Making decisions on how to provide essential services, is carried out based on the residents' activities. So, human activity recognition (HAR) is of crucial importance in such environments. For this purpose, various sorts of sensors are hired to collect users' data. The acquired data is further processed via data mining and machine learning techniques to infer human activities.

Most of the current HAR approaches are based on simplified presumptions and real world complex circumstances are seldom taken into account. Such presumptions are restrictive and not applicable in many realistic scenarios. Some of the predominant common presumptions include: considering sequential activities, single subject environments, and neglecting the uncertainty in sensors' data and inference. It is necessary to reduce the effects of these assumptions in HAR schemes to make them applicable in empirical situations. In the presented thesis, we aim at developing a HAR scheme in such circumstances.

Regarding the above-mentioned circumstances, we propose a three layered HAR architecture. The layers pertain to *data acquisition*, *single-subject HAR*, and *multi-subject HAR*, respectively. In the first layer, namely data acquisition, users' data are collected by various environmental sensors and catered for the next layers as a sensor data stream. The second layer, i.e. single-subject HAR layer, achieves HAR regarding the mitigation of uncertainty in inference. In the third layer, i.e. multi-subject HAR layer, individual data traces are modeled and extracted out of users' aggregate data. Afterwards, users' activities are inferred on the extracted data traces using the procedures presented in the second layer. Results show that the proposed architecture can outperform common HAR approaches that are generally based on probabilistic graphical models.

**Keywords:** smart homes, activity recognition, uncertainty, multi-subject environments, dense sensing, wireless sensor networks.





**Shahrood University of Technology**

**Faculty of Computer and IT Engineering**

Ph.D. Dissertation in Artificial Intelligence

**An Architecture for Human Activity Recognition under Complex Circumstances  
in Smart Homes**

By: Vahid Ghasemi

Supervisor:

Dr. Ali A. Pouyan

Advisors:

Dr. Alireza Ahmadifard, and Dr. Mohsen Sharifi

August 2017