

## مدیریت جریان داده‌ها در تشخیص فعالیت

عاطفه علیزاده<sup>۱</sup>، حوا علیزاده نوقایی<sup>۲</sup>

<sup>۱</sup>گروه مهندسی برق و کامپیوتر، مجتمع آموزش عالی گناباد

[h.alizadeh@gonabad.ac.ir](mailto:h.alizadeh@gonabad.ac.ir)

چکیده – امروزه انسان در دنیای زندگی می‌کند که اطرافش با حسگرهای مختلفی که کاربردهای متنوع دارند، پوشیده شده است. این استفاده روزافزون از حسگرها سبب شده است که از داده‌های حسگری برای کاربردهای مختلفی استفاده شود که یکی از این کاربردهای مهم خانه‌های مراقبت سلامت و خانه‌های هوشمند هستند. در این سیستم‌ها افراد باید قادر باشند که کارهای روزانه خود را انجام داده و زندگی مستقلی داشته باشند. بنابراین شناسایی خودکار و ردیابی این فعالیت‌ها گامی مهم در جهت نظارت بر سلامت عملکرد فرد ساکن در این سیستم-هاست. بنابراین "تشخیص فعالیت انسان" یک مسئله کلیدی در حوزه پژوهش خانه‌های مراقبت سلامت است. از طرف دیگر باید در نظر داشت که داده‌های حسگری یک جریان داده غیرایستا و پویاست که با سرعت دریافت می‌شوند، بنابراین مدیریت آن‌ها نیازمند رویکردهای خاصی می‌باشد تا بتوان با پردازش آن، فعالیت‌های انسان را بطور درست و دقیق شناسایی کرد. در این مقاله رویکردهای پایه رایج جهت پردازش جریان داده حسگری مورد بررسی قرار گرفته است. سپس مشکلات مربوطه به این روش‌ها بیان شده و برای رفع هر کدام یک روش بهبودیافته توضیح داده شده است.

کلید واژه – تشخیص فعالیت، جریان داده، پنجره حسگری، پنجره رویدادی.

مدل آموزش داده شده، فعالیت را شناسایی می‌کند. شکل ۱ این سه کامپوننت را نشان می‌دهد.

۱- مقدمه

مطابق شکل ۱، روش‌های یادگیری در پروسه تشخیص فعالیت بکار گرفته می‌شود. این روش‌ها در سه دسته یادگیری بانظارت، یادگیری بدون نظارت و نیمه نظارتی تقسیم بندی میشوند. یادگیری بانظارت، داده‌های برچسب گذاری شده را برای آموزش مدل بکار می‌برد و سپس با کمک مدل دسته بندی که ایجاد میشود با دریافت داده‌های ورودی بدون برچسب به شناسایی فعالیت‌ها می‌پردازد. روشهای یادگیری بانظارت به سه گروه مولد، افتراقی و ترکیبی تقسیم می‌شود. یکی از روشهای موثر در گروه مولد، Navie Bayes است که محققان در [5] تشخیص فعالیت را با بهره‌گیری از آن انجام دادند یا به عنوان مثالی دیگر از این گروه مدل مخفی مارکوف است که برای موضوع تشخیص فعالیت از آن استفاده شد. [6] در گروه مدل‌های افتراقی، بکارگیری درخت تصمیم [7]، نزدیکترین همسایه [8]، از جمله نمونه‌هایی است که برای تشخیص فعالیت بکار رفته است. از نمونه کارهایی که در گروه یادگیری ترکیبی انجام شده است مقاله [9] می‌باشد که محققان با تغییراتی در AdaBoost از آن برای تشخیص فعالیت استفاده کردند. برای مطالعه کارهای انجام شده بیشتر جدول ۱ مشاهده شود.

سنسورهای تعبیه شده در گوشی‌های هوشمند، دوربین‌ها، ساختمان‌ها، ماشین‌ها و سایر اشیاء، داده‌های انبوه را به صورت پیوسته تولید می‌کنند. پردازش بلادرنگ داده‌های سنسوری از ملزومات موضوع "تشخیص فعالیت" می‌باشد. سیستم‌های تشخیص فعالیت با فراهم کردن اطلاعاتی راجع به رفتارها و فعالیت‌ها، کاربردهای فراوانی از جمله در سیستم‌های مراقبت سلامت [1]، شبکه‌های اجتماعی [2]، مانیتورینگ محیط [3]، نظارت و پاسخگویی اضطراری [4] و غیره دارد.

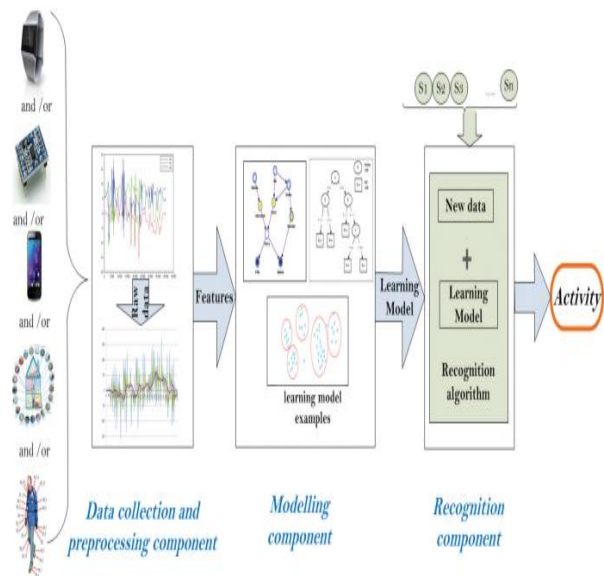
پروسه تشخیص فعالیت شامل سه کامپوننت اصلی: جمع‌آوری و پیش‌پردازش داده، مدل‌سازی، و تشخیص می‌باشد. کامپوننت جمع‌آوری داده، داده‌های سنسوری را از منابع مختلف مانند سنسورهای پوشیدنی، سنسورهای گوشی یا محیط هوشمند دریافت می‌کند، سپس این داده‌های خام برای استخراج ویژگی‌هایی که فعالیت‌ها را از یکدیگر متمایز می‌کند، پردازش می‌شود. کامپوننت مدل‌سازی، ویژگی‌های استخراج شده را برای آموزش مدل یادگیری، بکار می‌گیرد. کامپوننت تشخیص با ورود داده‌های سنسوری جدید براساس

فعالیت استفاده می‌کند، خانه‌های مراقبت سلامت و محیط‌های هوشمند هستند. در این سیستم‌ها افراد باید قادر به انجام کارهای روزانه نظیر غذا خوردن، پخت و پز، استراحت کردن و مصرف دارو باشند تا بتوانند زندگی مستقلی داشته باشند. بنابراین شناسایی خودکار و ردیابی این فعالیت‌ها گامی مهم در جهت نظارت بر سلامت عملکرد فرد ساکن در یک خانه هوشمند است که خانواده‌ها و مراقبین بیماران آلزایمر نیز آن را پذیرفته اند. همین مسئله انگیزه اصلی بسیاری از تحقیقات تشخیص فعالیت در محیط‌های هوشمند است. تحقیقات زیادی در زمینه تشخیص فعالیت بر روی داده‌های از پیش طبقه بندی شده انجام شده است که در بخش مقدمه نیز به بررسی آن پرداخته شد اما این اولین گام در جهت توسعه تشخیص فعالیت است. استفاده از این سیستم در دنیای واقعی نیاز به تکنیک‌های تشخیص فعالیت برای کار بر روی داده‌های جریانی دارد ضمن اینکه موارد دیگر مثل اجرای همزمان و متقابل فعالیت‌ها نیز باید در نظر گرفته شود. یک مشکل چالش برانگیز در چنین شرایطی، در دسترس نبودن داده ای است که به طور کامل یک فعالیت را توصیف می‌کند و بنابراین الگوریتم باید به اطلاعات جزئی مشاهده شده همراه با سایر اطلاعات زمینه ای برای تصمیم گیری در مورد فعالیت توجه کند.

در ادامه این مقاله ابتدا سه رویکرد پایه رایج برای پردازش داده-های جریانی تشریح می‌شود سپس در بخش ۳ مشکلاتی که در این رویکردهای پایه وجود دارد مطرح گردیده و روش‌های بهبودیافته‌ای که به رفع این مشکلات می‌پردازند، بیان می‌شود.

## ۲- روش‌های مدیریت جریان داده در تشخیص فعالیت

در اینجا به سه رویکرد رایج برای پردازش داده‌های جریانی پرداخته می‌شود. این سه رویکرد در زمینه دیتاست‌های خانه هوشمندی که در مقاله [24] استفاده شده است، مورد بررسی قرار گرفته است. حسگرهای خانه‌های هوشمند، حسگرهای تعبیه شده درب و حرکتی هستند که دو حالت ON و OFF برای حسگرهای حرکتی و OPEN و CLOSE برای حسگرهای درب وجود دارد. این حسگرها نرخ نمونه گیری مختلفی بر اساس فعالیت انسان دارند. شکل ۲ نمونه‌ای از دنباله‌ی حسگرها را نشان می‌دهد که به صورت خط‌های عمودی نشان داده شده است. همچنین چانک‌های داده ای که هر یک از سه رویکرد ارائه شده استفاده می‌کنند و در نهایت هم دنباله فعالیتی که از این حسگرها حاصل می‌شود نیز نشان داده شده است. هر فعالیتی بر



شکل ۱- کامپوننت‌های تشخیص فعالیت


در روش‌های یادگیری بانظارت نیاز است تا داده‌های برچسب دار قابل توجهی برای آموزش مدل دسته بند وجود داشته باشد که این محدودیت در روش‌های بدون نظارت وجود ندارد. هدف اصلی روش‌های یادگیری بدون نظارت در پروسه تشخیص فعالیت، کشف شباهت‌ها و تفاوت‌های بین داده هاست. در [10] امکان بکارگیری یادگیری بدون نظارت برای داده‌های سنسوری ناهمگون و با ابعاد بالا بررسی شده است. در هر حال این روش‌ها به تعداد زیادی داده‌های بدون برچسب برای پیدا کردن الگوها نیاز دارد. و اما برای استفاده از مزایای هر دو روش، مفهوم یادگیری نیمه نظارتی ارائه شد. یادگیری نیمه نظارتی به عنوان یک رویکرد مناسب در زمان کمبود داده‌های برچسب دار و استفاده از داده‌های بدون برچسب در زمان آموزش مطرح می‌باشد. این روش یادگیری خود به چهار گروه تقسیم می‌شود و نمونه کارهایی از هر کدام در زمینه تشخیص فعالیت در جدول ۱ آورده شده است.

جدول ۱- روش‌های یادگیری در تشخیص فعالیت

رویکردهای یادگیری	
[5] [11] [6]	مولد
[7] [12] [8] [13]	افتراقی
[9] [14] [1]	ترکیبی
[15] [16] [10] [17] [18]	بدون نظارت
[19] [20] [21] [22] [23] [17]	نیمه نظارتی

همانطور که قبلاً نیز اشاره شد، تشخیص فعالیت یک مسئله مهم در محاسبات فراگیر است. یک برنامه کاربردی که از تشخیص

اساس تعداد خاصی از انواع حسگرهای مختلف بدست می‌آید.



شکل ۲: خلاصه رویکردهای پردازش داده‌های جریانی، نمایش حسگرهای درب و حرکتی با خطوط عمودی با رنگ‌های مختلف بیانگر نوع و مکان مختلف هر حسگر [24]

## ۲-۱- قطعه بندی صریح:

برخی روش‌ها از رویکرد دو مرحله‌ای برای تشخیص فعالیت جریانی استفاده می‌کنند. در گام نخست جریان رخداد‌های حسگر به چانک‌هایی تقسیم می‌شود و هر چانک به صورت بالقوه به یک فعالیت مربوط است و طبقه بندی هر چانک در گام بعدی انجام می‌شود. یک مثال در شکل ۲ نشان داده شده است که فرایند قطعه بندی منجر به ایجاد ۶ چانک  $C_1, C_2, \dots, C_6$  می‌شود. اولین نکته‌ای که باید به آن توجه شود این است که این فرایند منجر به مرزبندی دقیق فعالیت نخواهد شد و این ویژگی مشترک الگوریتم‌های قطعه بندی است. اگر چه فرایند قطعه بندی می‌تواند منجر به ایجاد چانک‌هایی شود که نشانگر فعالیت‌های خاصی هستند اما مشکلاتی نیز دارد. اولین و مهم‌ترین مسئله این است که باید اندازه چانک مناسبی برای یادگیری مدل‌ها در طول فاز یادگیری تعیین شود. برای آموزش طبقه بندی، از یک دنباله رویداد حسگر مربوط به یک فعالیت که از قبل قطعه بندی شده استفاده می‌شود. با این حال در طول تست چون چانک‌ها لزوماً کل دنباله رویدادهای حسگر برای یک فعالیت خاص را نشان نمی‌دهند، کارایی طبقه بندی کاهش می‌یابد. ثانیاً این رویکرد باید منتظر داده بعدی بماند تا در مورد داده قبلی تصمیم بگیرد و این تا حدودی منجر به این می‌شود که رویکرد غیر جریانی تفسیر شود. علاوه بر این چون این رویکرد به داده‌های بعدی وابسته است، سبب بروز شکاف‌های زمانی بزرگی در رویدادهای حسگری پیوسته که در فعالیت‌ها اجتناب ناپذیر است، می‌شود تا رویکرد مدت زمان طولانی برای تصمیم

گیری در مورد داده‌های قبلی منتظر بماند. و در نهایت نیز رویکرد دو سطحی پیچیدگی اضافی مربوط به مسائل مختلف قطعه بندی نظیر تکه تکه کردن و ادغام چانک‌ها دارد. اگر فعالیت‌ها مرزهای کاملاً متمایز داشته باشند این رویکرد خوب است ولی این امر در حالت عادی غیرمعمول است.

## ۲-۲- پنجره‌های زمانی:

در دومین رویکرد برای مدیریت جریان داده‌ها، کل دنباله رویدادهای حسگر به فاصله‌های زمانی با اندازه یکسان تقسیم می‌شود. همانطور که در شکل ۲ نشان داده شده دنباله رویدادهای حسگر به ۹ چانک  $T_1, \dots, T_9$  تقسیم شده است. این رویکرد توسط بسیاری از محققین به کار گرفته شده است. این رویکرد روش ساده تری برای یادگیری مدل‌های فعالیت در طول فاز آموزش نسبت به رویکرد قطعه بندی صریح، پیشنهاد می‌کند. علاوه بر این پیچیدگی اضافی مربوط به قطعه بندی صریح را نیز کاهش می‌دهد. این رویکرد برای حسگرهایی که پیوسته در طول زمان عمل می‌کنند مناسب است. همچنین بیاد در نظر داشت که این رویکرد برای سناریوهایی که با شتاب سنج و ژيروسکوپ کار می‌کنند رایج است چون داده‌ها با سرعت ثابتی از حسگرها نمونه برداری می‌شوند. با این حال یک مسئله چالش برانگیز مهم وجود دارد و آن هم تعیین اندازه پنجره است. اگر طول پنجره کم انتخاب شود احتمال این که حاوی اطلاعات کافی برای تصمیم‌گیری مناسب در مورد فعالیت مربوطه نباشد، وجود دارد. اگر طول پنجره بیش از حد بزرگ باشد، اطلاعات مربوط به فعالیت‌های متعدد با هم تداخل پیدا می‌کند و بنابراین فعالیتی که در این پنجره غالب است تاثیر بیشتری در تصمیم‌گیری کلاس دارد. این مسئله زمانی که حسگرها نرخ نمونه‌گیری ثابتی ندارند، خود را نشان می‌دهد. در زمینه رویدادهای حسگر درب و حرکتی، این مسئله که در برخی از پنجره‌ها رویداد حسگری رخ نداده است، محتمل است. (مانند  $T_6$  در شکل ۲) بنابراین هیورستیک‌هایی لازم است تا رویداد فعالیتی صورت گرفته در پنجره قبلی را به پنجره فعلی بسط دهد.

## ۲-۳- پنجره‌های رویدادی:

سومین رویکرد پردازش جریان داده، دنباله را به پنجره‌هایی با تعداد مساوی رویداد حسگر تقسیم می‌کند. در شکل ۲ این مسئله با چانک‌های  $S_1, S_2, \dots, S_{26}$  نشان داده شده است. همانطور که در شکل نیز واضح است پنجره‌ها از نظر مدت زمان

بدست آید. یکی از فاکتورهایی که بر  $\Delta S$  تاثیر می‌گذارد، میانگین تعداد رویدادهای حسگری است که در طول مدت فعالیت‌های مختلف رخ می‌دهد. در یک انتهای طیف، فعالیت‌هایی مانند "ترک خانه" وجود دارد که با عملکرد سریع مجموعه ی کوچکی از حسگرها همانطور که در شکل ۳ نشان داده شده است، تعریف می‌شود؛ در سمت دیگر طیف فعالیت‌هایی مثل "خواب" وجود دارد که به مدت چند ساعت ادامه می‌یابد و معمولا منجر به عملکرد گاه به گاه یک یا چند حسگر همانگونه که در شکل ۳ نشان داده شده است، می‌شود.

```
2009-07-17 15:56:55.484001 FrontDoor OPEN Leave_Home begin
2009-07-17 15:56:58.078001 FrontDoor OFF
2009-07-17 15:56:59.796001 FrontDoor ON
2009-07-17 15:57:03.703001 FrontDoor OFF
2009-07-17 15:57:04.406001 FrontDoor CLOSE Leave_Home end
...
2009-07-17 22:14:11.250001 Bedroom ON Sleep begin
2009-07-17 22:14:15.546001 Bedroom OFF
...
2009-07-17 22:20:09.921001 Bedroom OFF
2009-07-18 00:11:32.703001 Bedroom ON
...
2009-07-18 00:14:19.296001 Bedroom OFF
2009-07-18 01:10:37.640001 Bedroom ON
...
2009-07-18 01:57:30.375001 Bedroom OFF
2009-07-18 03:34:18.000001 Bedroom ON
...
2009-07-18 05:59:16.234001 Bedroom OFF
2009-07-18 06:34:37.687001 Bedroom ON
...
2009-07-18 06:35:13.296001 Bedroom OFF
2009-07-18 06:35:16.859001 Bedroom ON Sleep end
```

شکل ۳: نمونه ای از رویدادهای حسگر یک خانه هوشمند

هنگامی که پنجره  $S_i$  تعریف شد، گام بعدی تبدیل این پنجره به بردار ویژگی است که محتوای اطلاعاتش را در برمی‌گیرد. این گام با ساخت بردار ویژگی با ابعاد ثابت  $X_i$  اجرا می‌شود که شامل زمان وقوع اولین و آخرین رویداد حسگر، طول عمر پنجره و تعداد رویدادهای حسگری داخل پنجره می‌باشد. مثلا با ۱۵ حسگر مختلف بعد  $X_i$  برابر ۱۸ خواهد بود. هر  $X_i$  با برچسب  $y_i$  آخرین رویداد حسگر ( $S_i$ ) در  $S_i$  برچسب زده می‌شود. هر برچسب  $y_i$  مربوط به یک کلاس فعالیت است. سپس یک مجموعه از  $X_i$  و  $y_i$  برای آموزش به طبقه بند داده می‌شود تا مدل‌های فعالیت را به شیوه افتراقی یاد بگیرد.

یکی از مشکلات رویکرد پنجره حسگری مربوط به حسگرهای با نرخ نمونه گیری غیر ثابت است که پنجره می‌تواند شامل رویدادهای حسگری باشد که در زمان‌های مختلف به طور گسترده پخش شده اند. نمونه ای از این مشکل در شکل ۴ قسمت الف نشان داده شده است. اگر به برچسب زمانی دو رویداد آخر توجه کنید، فاصله بین این رویدادهای حسگر یک و

متفاوت هستند. این مسئله با توجه به این که در طول عملکرد فعالیت‌ها، چندین حسگر می‌تواند راه اندازی شود در حالی که در دوره خاموشی تعداد زیادی از این حسگرها فعال نخواهد بود، خوب است. آخرین رویدادهای حسگر در پنجره ماقبل، زمینه برای رویداد بعدی را مشخص می‌کند. این مدل مشکلاتی نیز دارد. به عنوان مثال، چانک  $S_{26}$  را در شکل ۲ در نظر بگیرید، آخرین رویداد حسگر این چانک مربوط به رویداد حسگر شروع فعالیت  $A_4$  است. یک تاخیر زمانی قابل توجهی بین این رویداد و رویداد حسگری ماقبل وجود دارد. اگر تاخیر زمانی بزرگ باشد، ارتباط همه رویدادهای حسگر در این چانک بر روی آخرین رویداد ممکن است کوچک باشد. بنابراین مسئله برخورد یکسان با همه رویدادهای حسگر که در این رویکرد وجود دارد، خوب نیست. این رویکرد مزایایی نسبت به روش قطعه بندی صریح دارد و نیازی به رویدادهای حسگر بعدی برای دسته بندی رویدادهای حسگر قبلی ندارد.

در جدول ۲ برخی از مقالاتی که از این سه روش برای پردازش جریان داده استفاده کرده‌اند به تفکیک بیان شده است.

جدول ۲: روش‌های پردازش جریان داده در مقالات

قطعه بندی صریح	پنجره زمانی	پنجره حسگری
[7] [25]	[26] [27] [28] [29]	[30] [31]

۳- روش‌های بهبود یافته مدیریت جریان داده برای تشخیص فعالیت

در این بخش برخی از مشکلاتی که در زمینه گام‌های مختلف تشخیص فعالیت جریان داده‌ها وجود دارد بیان شده و برای هر یک راهکاری با تغییر در انتخاب پنجره ارائه شده است که به تفکیک به بررسی هر یک پرداخته خواهد شد.

### ۳-۱- پنجره حسگری بهبود یافته

یک رویکرد ساده برای مشخص کردن زمینه یک رویداد حسگر، در نظر گرفتن رویدادهای حسگری پیش از آن است. دنباله  $S_1, S_2, \dots, S_n$  به پنجره‌های با تعداد مساوی رویداد حسگر  $S_1, S_2, \dots, S_m$  تقسیم شده است و پنجره  $S_i$  با دنباله  $[S_i - \Delta S, S_i]$  نشان داده می‌شود. مقدار پارامتر  $\Delta S$  بر اساس زمینه آزمایش تغییر می‌کند که می‌تواند از طریق یک فرایند تجربی بصورت مطالعه اثر مقادیر مختلف  $\Delta S$  بر عملکرد سیستم طبقه بندی

رویدادهای حسگر، از یک منطقه کاربردی نامرتبط آپارتمان یعنی FrontDoor است. در حالی که قطعاً مجموعه دوم زمینه فعالیت را تعریف می‌کند، ولی چون حسگرهای مربوط به یک فعالیت خاص بر روی زمینه پنجره غالب است، احتمال نتیجه-گیری نادرست در مورد آخرین رویداد حسگر پنجره نیز بالاتر است. برای غلبه بر این مشکل یک طرح وزن دهی مبتنی بر نوع اطلاعات متقابل بین حسگرها تعریف می‌شود که در بخش "وابستگی حسگری" به آن خواهیم پرداخت.

#### - وابستگی زمانی:

همانطور که قبلاً توضیح داده شد، در رویکرد پنجره حسگری با طول ثابت، ممکن است دو رویداد حسگری که از لحاظ زمانی با یکدیگر اختلاف دارند، بخشی از یک پنجره باشند. برای کاهش تاثیر این رویدادهای حسگری برای تصمیم‌گیری در مورد آخرین رویداد حسگر، ما از یک فاکتور وزن دهی مبتنی بر زمان برای هر رویداد حسگر نسبت به زمان آخرین رویداد حسگر استفاده می‌کنیم.

فرض کنید  $\{t_{i-\Delta s}, t_{i-\Delta s+1}, \dots, t_i\}$  زمان رویدادهای حسگری در پنجره  $\Delta s$  باشد. ما اختلاف زمانی هر رویداد حسگری نسبت به  $t_i$  را برای توصیف بردار ویژگی توصیف‌کننده پنجره بدست می‌آوریم. به طور خاص از یک تابع نمایی برای محاسبه وزن‌ها استفاده می‌شود. بنابراین سهم رویداد حسگری  $k$  در فاصله زمانی  $\Delta s$  به بردار ویژگی توصیف‌کننده پنجره  $i$  به شکل زیر است:

$$C(i, j) = \exp(-\chi(t_i - t_k))$$

اکنون شمارش ساده تعداد رویدادهای حسگری مختلف موجود در یک پنجره با مجموع سهم‌های مبتنی بر زمان رویدادهای حسگری مختلف آن، در بردار توصیفی پنجره جایگزین شده است. همانطور که در شکل ۵ مشخص است، مقدار  $\chi$  نرخ کاهش نفوذ را مشخص می‌کند. اگر  $X > 1$  آنگاه فقط رویدادهای حسگری که به لحاظ زمانی بسیار نزدیک به آخرین رویداد است، به بردار ویژگی کمک می‌کند. اگر  $0 < X < 1$  بردار ویژگی تحت تاثیر یک محدوده وسیع تری از رویدادهای حسگری قرار می‌گیرد و وقتی که  $X=0$ ، فاصله زمانی هیچ تاثیری بر روی بردار ویژگی ندارد، یعنی رویدادهای حسگری مختلف را شمارش می‌کند.

نیم ساعت است. تمام رویدادهای حسگری که زمینه آخرین رویداد را تعریف می‌کنند در گذشته "دور" رخ داده است. بنابراین، در صورت نبود طرح وزن دهی، حتی اگر رویداد حسگر مربوط به پایان فعالیت «بهداشت شخصی» در گذشته اتفاق افتاده باشد، تأثیر یکسانی در تعریف زمینه رویداد مربوط به «ورود به خانه» دارد. به منظور غلبه بر این مشکل، می‌توان از یک طرح وزن‌دهی مبتنی بر زمان استفاده کرد که تفاوت نسبی در زمانی که حسگرها عمل می‌کنند را در نظر می‌گیرد که در بخش "وابستگی زمانی" به توصیف این روش پرداخته خواهد شد.

```
2009-07-19 10:18:59.406001 LivingRoom ON
2009-07-19 10:19:00.406001 Bathroom OFF Personal_Hygiene end
2009-07-19 10:19:03.015001 OtherRoom OFF
2009-07-19 10:19:03.703001 LivingRoom OFF
2009-07-19 10:19:07.984001 LivingRoom ON
2009-07-19 10:19:11.921001 LivingRoom OFF
2009-07-19 10:19:13.203001 OtherRoom ON
2009-07-19 10:19:14.609001 Kitchen ON
2009-07-19 10:19:17.890001 OtherRoom OFF
2009-07-19 10:19:18.890001 Kitchen OFF
2009-07-19 10:19:24.781001 FrontDoor ON Leave_Home begin
2009-07-19 10:19:28.796001 FrontDoor OFF
2009-07-19 10:19:31.109001 FrontDoor CLOSE Leave_Home end
2009-07-19 12:05:13.296001 FrontDoor OPEN Enter_Home begin
```

شکل ۴: الف) وابستگی زمانی

```
2009-07-23 19:59:58.093001 Bathroom ON
2009-07-23 20:00:02.390001 Bathroom OFF
2009-07-23 20:00:04.078001 Bathroom ON
2009-07-23 20:00:08.000001 LivingRoom ON
2009-07-23 20:00:08.640001 OtherRoom ON
2009-07-23 20:00:09.343001 Bathroom OFF Personal_Hygiene end
2009-07-23 20:00:12.296001 LivingRoom OFF
2009-07-23 20:00:22.171001 Kitchen ON
2009-07-23 20:00:25.140001 OtherRoom OFF
2009-07-23 20:00:27.187001 FrontDoor ON Leave_Home begin
2009-07-23 20:00:27.437001 Kitchen OFF
2009-07-23 20:00:30.140001 FrontDoor OFF
2009-07-23 20:00:32.046001 FrontDoor ON
2009-07-23 20:00:36.062001 FrontDoor OFF
2009-07-23 20:00:39.343001 FrontDoor ON
2009-07-23 20:00:43.671001 FrontDoor OFF
2009-07-23 20:00:46.265001 FrontDoor CLOSE Leave_Home end
```

ب) وابستگی حسگری

مشکل دیگر در شرایطی رخ می‌دهد که رویداد حسگری مربوط به گذر بین دو فعالیت است (یا هنگامی که فعالیت‌های چندگانه موازی توسط چند فرد انجام می‌شود)، رویدادهای حسگری داخل پنجره ممکن است مربوط به رویداد سنسور مورد نظر نباشد. یک مثال از این شرایط در شکل ۴ قسمت ب نشان داده شده است. این نمونه، دنباله خاصی از رویدادهای حسگری است که نشان دهنده گذر از فعالیت «بهداشت شخصی» به فعالیت «خروج خانه» است. توجه داشته باشید که تمامی رویدادهای حسگر اولیه‌ی پنجره، از یک منطقه کاربردی خاص آپارتمان یعنی حمام می‌آید، در حالی که مجموعه دوم




حسگرها در یک پنجره به کار گرفته می‌شود. همانند وزن دهی زمانی که در بخش "وابستگی زمانی" مطرح شد، هر رویداد در پنجره با توجه به آخرین رویداد حسگری در آن پنجره، وزن دهی می‌شود. بنابراین به جای شمارش تعداد رویدادهای مختلف حسگر، از مجموع سهم هر رویداد حسگری براساس اطلاعات متقابل استفاده و بردار ویژگی ایجاد می‌شود.

### ۳-۲- بکارگیری اطلاعات پنجره‌های قبلی برای پنجره فعلی

نکته قابل توجه دیگر این است که روش‌هایی که قبلاً شرح داده شد، فقط رویدادهای حسگر را در پنجره فعلی مورد بررسی قرار می‌دهند. بنابراین هیچ اطلاعاتی درباره گذشته در بردار ویژگی کدگذاری شده وجود ندارد. اطلاعات مربوط به فعالیت در پنجره قبلی یا رویداد قبلی فعالیت، عوامل مهمی هستند که فعالیت در پنجره فعلی را تعیین می‌کنند. در مجموعه داده‌ها، فعالیت‌های مشخصی وجود دارد که فعالیت‌های گذشته را بطور دقیق مشخص می‌کنند؛ "ورود به خانه" یک نمونه از چنین فعالیت‌هایی است که فقط پس از فعالیت "ترک خانه" رخ می‌دهد. بنابراین اضافه کردن اطلاعات فعالیت گذشته به بردار ویژگی معرف فعالیت در پنجره فعلی، توضیحات پنجره فعلی را افزایش می‌دهد.

حقایق زمینه‌ای بدست آمده برای پنجره قبلی و همچنین فعالیت‌های قبلی را می‌توان به سادگی به پنجره حسگر فعلی اضافه کرد، اما این رویکرد نمی‌تواند به خوبی تعمیم پیدا کند زیرا ما حقایق زمینه‌ای در مورد فعالیت گذشته را در طول شناسایی آنلاین نداریم. به این ترتیب این رویکرد به پیش بینی مدل پنجره قبلی برای به دست آوردن اطلاعات فعالیت گذشته- که مشابه نمونه یادگیری نیمه نظارتی است- تکیه می‌کند. این مسئله در یادگیری به صورت دو مرحله در شکل ۶ نشان داده شده است. در مرحله اول، مدل‌های فعالیت توسط یک طبقه بند با استفاده از داده‌های آموزشی که حاوی اطلاعات فعالیت گذشته نیست، آموزش می‌بینند. سپس هر یک از نمونه‌های آموزشی به این مدل فعالیت داده می‌شود تا احتمال هر پنجره مربوط به فعالیت‌های مختلف را بدست آورند.

در مرحله دوم، این احتمالات طبقه بند پنجره حسگر ماقبل به بردار ویژگی توصیف کننده پنجره حسگر فعلی همراه با آخرین فعالیت پیش بینی شده اضافه می‌شود. در مثال شکل ۶، پنجره حسگری  $S_{i+2}$  را در نظر بگیرید. احتمال طبقه بند پنجره حسگر  $S_{i+1}$ ، همراه با آخرین فعالیتی که قبلاً اتفاق افتاده است،



شکل ۵: تاثیر X بر وزن‌ها

### - وابستگی حسگری:

همانطور که قبلاً هم اشاره شد، استفاده از سنجش اطلاعات متقابل بین حسگرها، تاثیر رویدادهای حسگری مربوط به مناطق کاربردی بسیار مختلف بر روی بردار ویژگی تعیین کننده آخرین رویداد حسگری در یک پنجره را کاهش می‌دهد. اطلاعات متقابل معمولاً به عنوان کمیتی است که وابستگی متقابل دو متغیر تصادفی را اندازه‌گیری می‌کند. در اینجا هر حسگر یک متغیر تصادفی است که دو خروجی دارد یعنی «ON» و «OFF». اطلاعات متقابل یا وابستگی بین دو حسگر بصورت احتمال این که دو حسگر به صورت متوالی در کل جریان حسگر اتفاق می‌افتد، تعریف می‌شود. اگر  $S_i$  و  $S_j$  دو حسگر باشند، اطلاعات متقابل بین آن‌ها  $MI(i,j)$  و بصورت زیر تعریف می‌شود:

$$MI(i, j) = \frac{1}{N} \sum_{k=1}^{N-1} \delta(S_k, S_i) \delta(S_{k+1}, S_j)$$

جایی که:

$$\delta(S_k, S_i) = \begin{cases} 0 & \text{if } S_k \neq S_i \\ 1 & \text{if } S_k = S_i. \end{cases}$$

مقدار حاصلجمع، زمانی که حسگر فعلی  $S_i$  و حسگر بعدی  $S_j$  است، ۱ است. اگر دو حسگر مجاور یکدیگر باشند، به این ترتیب که راه اندازی یک حسگر به احتمال زیاد منجر به راه-اندازی حسگر دیگر شود، سپس اطلاعات متقابل بین این دو حسگر بالا خواهد بود، اگر حسگرها از هم دور باشند، به طوری که اغلب با یکدیگر همکاری نکنند، اطلاعات متقابل میان آنها کم می‌شود. باید توجه داشت که محاسبه اطلاعات متقابل با استفاده از این مدل دوبعدی، به ترتیب وقوع حسگرها بستگی دارد.

ماتریس اطلاعات متقابل با استفاده از دنباله حسگری که برای آموزش استفاده می‌شود و بصورت آفلاین محاسبه می‌شود. سپس در هنگام ساخت بردار ویژگی، برای وزن دهی تأثیر رویداد

حسگر  $S_i$  مرتبط است نیز تعیین می‌گردد. بنابراین با توجه به شناسه  $S_i$  حسگر برای رویداد مورد بررسی، می‌توان محتمل‌ترین فعالیت  $A^*$  مرتبط با آن را به شکل زیر تعیین کرد:

$$A^* = \underset{A_m}{\operatorname{argmax}}\{P(A_m/S_i)\}.$$

بنابراین برای رویداد حسگری  $S_i$ ، اندازه پنجره بهینه می‌تواند با ترکیب دو معادله طبق معادله زیر تعیین شود:

$$w^* = \max_{w_l} P(w_l/S_i) = \max_{w_l} [P(w_l/A_m) * P(A_m/S_i)].$$

بردارهای احتمالی مختلف با استفاده از داده‌های آموزشی محاسبه می‌شوند. سپس اندازه پنجره برای رویدادهای حسگر در داده‌های آموزشی و تست، با استفاده از این احتمالات محاسبه می‌شود.

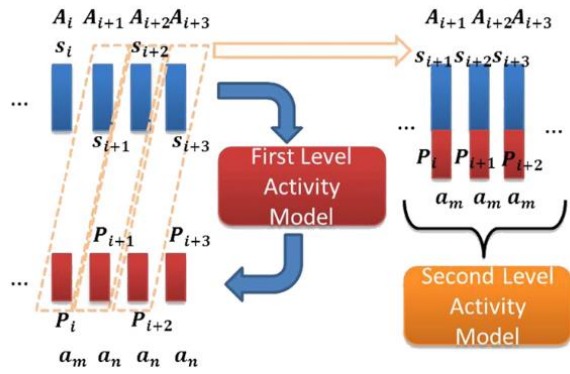
۳-۴- مدیریت کلاس‌های فعالیت نامشخص در پردازش جریان داده‌ها

اکثر رویکردهای فعلی تشخیص فعالیت، رویدادهای حسگری که به هیچ یک از کلاس‌های فعالیت شناخته شده مربوط نمی‌شود را نادیده می‌گیرند. مثلاً، مدل‌های فعالیتی که برای غذاپختن، غذا خوردن و خواب آموزش دیده‌اند، بر روی نقاط داده‌ای که فقط با این سه فعالیت مطابقت دارند، آزمایش می‌شوند. اما این در یک محیط دنیای واقعی امکان‌پذیر نیست، جایی که نقاط داده می‌توانند مربوط به سایر فعالیت‌های تعریف شده مانند "حمام" یا انتقال بین فعالیت‌های مختلف باشند. به طور معمول در داده‌های دنیای واقعی، داده‌های کلاس‌های فعالیت دیگر غالب هستند، همانطور که در جدول ۳ نیز مشخص است تعداد نمونه داده‌های مربوط به "فعالیت‌های دیگر" زیاد است و به طور متوسط نیمی از داده‌ها را تشکیل می‌دهند.

Dataset	B1	B2	B3
Bathing	7,198	16,177	5,113
Bed to toilet	4,168	14,418	2,806
Cook	101,899	55,080	44,824
Eat	28,687	24,403	39,380
Enter home	3,685	2,240	877
Leave home	4,304	2,457	1,246
Personal hygiene	40,506	16,949	37,054
Relax	39,929	38,879	8,207
Sleep	33,212	10,428	20,676
Take medicine	5,388	7,156	700
Work	0	0	108,645
Other	391,443	382,422	249,212
Total # of activity events	658,811	572,255	518,759

جدول ۳: تعداد رویدادهای حسگری/نمونه هر فعالیت برای هر آزمایش

رویکردهای فعلی تشخیص فعالیت حضور این کلاس‌های دیگر را هنگام ارزیابی عملکرد الگوریتم‌ها نادیده می‌گیرند. با این حال، برای ارزیابی عملکرد واقعی الگوریتم شناسایی فعالیت باید از رویدادهای حسگری مربوط به این کلاس‌های فعالیت دیگر نیز استفاده کرد.



شکل ۶: روال یادگیری دو مرحله ای شامل اطلاعات زمینه ای گذشته

که در اینجا  $a_m$  است، به بردار توصیف‌کننده پنجره فعلی اضافه شده است. سپس این بردارهای ویژگی جدید اضافه شده برای آموزش یک مدل فعالیت دیگر مورد استفاده قرار می‌گیرند. در مرحله تست، بردار ویژگی توصیف‌کننده پنجره تست به اولین مدل فعالیت داده می‌شود؛ خروجی‌های احتمالی این مدل به بردار ویژگی اضافه شده و بردار ویژگی جدید به مدل دوم منتقل می‌شود تا فعالیت پیش‌بینی شده را بدست آورد.

### ۳-۳- پنجره پویا

در روش‌هایی که قبلاً شرح داده شد، از یک اندازه پنجره ثابت برای محاسبه بردارهای ویژگی استفاده می‌شود. یک چالش مهم در این روش شناسایی اندازه پنجره بهینه است. برای تعیین اندازه پنجره، می‌توان از روش‌های مختلفی نظیر میانگین طول فعالیت‌ها و فرکانس نمونه برداری از حسگرها استفاده کرد. با این حال بهترین روش این است که مقدار پنجره به صورت خودکار با استفاده از یک رویکرد مبتنی بر داده تعیین شود.

در اینجا از یک روش احتمالاتی برای محاسبه اندازه پنجره استفاده می‌کنیم. ابتدا با تعریف تعدادی اندازه پنجره ثابت  $\{W_1, W_2, \dots, W_L\}$  شروع می‌کنیم که:

$$W_1 = \min\{WS(A_1), WS(A_2), \dots, WS(A_m)\}$$

$$W_L = \text{median}\{WS(A_1), WS(A_2), \dots, WS(A_m)\}$$

$WS(A_m)$  میانگین اندازه پنجره فعالیت  $A_m$  است. اندازه پنجره‌های میانی بین  $W_1$  و  $W_L$  با تقسیم این فاصله به قسمت‌های با طول ثابت بدست می‌آید. بعد از تعیین اندازه پنجره احتمالی، محتمل‌ترین اندازه پنجره برای فعالیت  $A_m$  به صورت زیر بدست می‌آید:

$$w^* = \underset{w_l}{\operatorname{argmax}}\{P(w_l/A_m)\}$$

همچنین احتمال  $P(A_m/S_i)$  مربوط به فعالیت  $A_m$  که به

بهبودیافته‌ای که آن‌ها را حل کند بیان شد.

### مراجع

- [1] Do, T. M., Loke, S. W., & Liu, F. (2012, December). Healthylife: An activity recognition system with smartphone using logic-based stream reasoning. In International Conference on Mobile and Ubiquitous Systems: Computing, Networking, and Services(pp. 188-199). Springer, Berlin, Heidelberg.
- [2] Miluzzo, E., Lane, N. D., Fodor, K., Peterson, R., Lu, H., Musolesi, M., ... & Campbell, A. T. (2008, November). Sensing meets mobile social networks: the design, implementation and evaluation of the cenceme application. In Proceedings of the 6th ACM conference on Embedded network sensor systems (pp. 337-350). ACM.
- [3] Mun, M., Reddy, S., Shilton, K., Yau, N., Burke, J., Estrin, D., ... & Boda, P. (2009, June). PEIR, the personal environmental impact report, as a platform for participatory sensing systems research. In Proceedings of the 7th international conference on Mobile systems, applications, and services (pp. 55-68). ACM.
- [4] Zhang, D., Hariz, M., & Mokhtari, M. (2008, March). Assisting elders with mild dementia staying at home. In Pervasive Computing and Communications, 2008. PerCom 2008. Sixth Annual IEEE International Conference on (pp. 692-697). IEEE.
- [5] Ravi, N., Dandekar, N., Mysore, P., & Littman, M. L. (2005, July). Activity recognition from accelerometer data. In Aaai (Vol. 5, No. 2005, pp. 1541-1546).
- [6] Ward, J. A., Lukowicz, P., Troster, G., & Starner, T. E. (2006). Activity recognition of assembly tasks using body-worn microphones and accelerometers. IEEE transactions on pattern analysis and machine intelligence, 28(10), 1553-1567.
- [7] Bao, L., & Intille, S. S. (2004, April). Activity recognition from user-annotated acceleration data. In *International Conference on Pervasive Computing* (pp. 1-17). Springer, Berlin, Heidelberg.
- [8] Maurer, U., Smailagic, A., Siewiorek, D. P., & Deisher, M. (2006, April). Activity recognition and monitoring using multiple sensors on different body positions. In *Wearable and Implantable Body Sensor Networks, 2006. BSN 2006. International Workshop on*(pp. 4-pp). IEEE.
- [9] Viola, P., & Jones, M. (2001). Rapid object detection using a boosted cascade of simple features. In *Computer Vision and Pattern Recognition, 2001. CVPR 2001. Proceedings of the 2001 IEEE Computer Society Conference on* (Vol. 1, pp. I-I). IEEE.
- [10] Li, F., & Dustdar, S. (2011, January). Incorporating Unsupervised Learning in Activity Recognition. In *Activity Context Representation*.
- [11] Patterson, D. J., Fox, D., Kautz, H., & Philipose, M. (2005, October). Fine-grained activity recognition by aggregating abstract object usage. In *Wearable Computers, 2005. Proceedings. Ninth IEEE International Symposium on* (pp. 44-51). IEEE.
- [12] Logan, B., Healey, J., Philipose, M., Tapia, E. M., & Intille, S. (2007, September). A long-term evaluation of sensing modalities for activity recognition. In *International conference on Ubiquitous computing* (pp. 483-500). Springer, Berlin, Heidelberg.
- [13] Lee, S. W., & Mase, K. (2002). Activity and location recognition using wearable sensors. *IEEE pervasive computing*, 1(3), 24-32.
- [14] Lester, J., Choudhury, T., Kern, N., Borriello, G., & Hannaford, B. (2005). A hybrid discriminative/generative approach for modeling human activities.
- [15] Lee, M. S., Lim, J. G., Park, K. R., & Kwon, D. S. (2009). Unsupervised clustering for abnormality detection based on the tri-axial accelerometer. *ICCAS-SICE, 2009*, 134-137.
- [16] Wyatt, D., Philipose, M., & Choudhury, T. (2005, July). Unsupervised activity recognition using automatically mined common sense. In *AAAI* (Vol. 5, pp. 21-27).
- [17] Huynh, T., & Schiele, B. (2006, October). Towards less supervision in activity recognition from wearable sensors.

دو روش برای اداره رویدادهای کلاس دیگر وجود دارد. روش اول بر اساس احتمال طبقه بندی به دست آمده از مدل‌هایی است که فقط برای رویدادهای متعلق به کلاس‌های شناخته شده آموزش داده شده است. در نظر گرفتن یک حد آستانه برای این احتمال تعیین می‌کند که آیا این رویداد متعلق به کلاس دیگر است یا نه. در حالی که این رویکرد ساده است اما تعیین حد آستانه سخت است چون هیچ یادگیری در زمینه تعیین مقدار حد آستانه وجود ندارد. در رویکرد دوم، یک مدل صریح برای رویدادهای کلاس دیگر، با آموزش طبقه‌بندی که تحت هیچکدام از رویدادهای کلاس‌های شناخته شده نیست، آموزش داده می‌شود. با توجه به اینکه افزایش پیچیدگی محاسباتی این روش به دلیل یادگیری صریح یک کلاس جدید، یک فرایند آفلاین است، می‌تواند نادیده گرفته شود. مدل سازی رویدادهای کلاس دیگر سیستم تشخیص فعالیت را یک گام به پردازش جریان نزدیک‌تر می‌کند و از این رو گام مهمی است.

### جمع بندی

تشخیص فعالیت یک زمینه تحقیقاتی مهم و در حال رشد می‌باشد. در تحقیقات اولیه در این زمینه، بیشتر به مانیتورینگ و آنالیز داده‌های دیداری مانند تصاویر و ویدئوها می‌پرداختند، اما در سال‌های اخیر از داده‌های حسگرهای چندمنظوره که در محیط هوشمند قرار داده می‌شوند، جهت تشخیص فعالیت‌های ساده و پیچیده استفاده می‌کنند. تکنیک‌های تشخیص فعالیتی زیادی در این حوزه وجود دارد که در بخش ۲ نیز به آن پرداخته شد اما آنچه که مهم است داده‌هایی است که از این حسگرها می‌آیند، این داده‌ها بدون محدودیت هستند که با سرعت بالا دریافت می‌شوند. بنابراین این واقعیت که داده‌ها پویا و غیرایستا هستند وجود دارد. ضمن اینکه در دنیای واقعی نیاز به تکنیک‌های تشخیص فعالیت برای کار بر روی داده‌های جریانی دارد ضمن اینکه موارد دیگر مثل اجرای همزمان و متقابل فعالیت‌ها نیز باید در نظر گرفته شود. یک مشکل چالش برانگیز در چنین شرایطی، در دسترس نبودن داده ای است که به طور کامل یک فعالیت را توصیف می‌کند و بنابراین الگوریتم باید به اطلاعات جزئی مشاهده شده همراه با سایر اطلاعات زمینه ای برای تصمیم گیری در مورد فعالیت توجه کند. در این مقاله سه رویکرد پایه برای پردازش داده‌های جریانی ارائه شد، در ادامه مشکلات مربوط به این روش‌ها معرفی و برای هر یک روش



- In Wearable Computers, 2006 10th IEEE International Symposium on (pp. 3-10). IEEE.
- [18] Ye, J., Stevenson, G., & Dobson, S. (2015). USMART: An unsupervised semantic mining activity recognition technique. *ACM Transactions on Interactive Intelligent Systems (TiS)*, 4(4), 16.
- [19] Longstaff, B., Reddy, S., & Estrin, D. (2010, March). Improving activity classification for health applications on mobile devices using active and semi-supervised learning. In *Pervasive Computing Technologies for Healthcare (PervasiveHealth)*, 2010 4th International Conference on-NO PERMISSIONS (pp. 1-7). IEEE.
- [20] Stikic, M., Van Laerhoven, K., & Schiele, B. (2008). Exploring semi-supervised and active learning for activity recognition.
- [21] Lee, Y. S., & Cho, S. B. (2014). Activity recognition with android phone using mixture-of-experts co-trained with labeled and unlabeled data. *Neurocomputing*, 126, 106-115.
- [22] Stikic, M., Larlus, D., & Schiele, B. (2009, September). Multi-graph based semi-supervised learning for activity recognition. In *Wearable Computers, 2009. ISWC'09. International Symposium on* (pp. 85-92). IEEE.
- [23] Ali, A., King, R. C., & Yang, G. Z. (2008, June). Semi-supervised segmentation for activity recognition with Multiple Eigenspaces. In *Medical Devices and Biosensors, 2008. ISSS-MDBS 2008. 5th International Summer School and Symposium on* (pp. 314-317). IEEE.
- [24] Krishnan, N. C., & Cook, D. J. (2014). Activity recognition on streaming sensor data. *Pervasive and mobile computing*, 10, 138-154.
- [25] Junker, H., Amft, O., Lukowicz, P., & Tröster, G. (2008). Gesture spotting with body-worn inertial sensors to detect user activities. *Pattern Recognition*, 41(6), 2010-2024.
- [26] Wang, L., Gu, T., Tao, X., & Lu, J. (2012). A hierarchical approach to real-time activity recognition in body sensor networks. *Pervasive and Mobile Computing*, 8(1), 115-130.
- [27] Tapia, E. M., Intille, S. S., & Larson, K. (2004, April). Activity recognition in the home using simple and ubiquitous sensors. In *International conference on pervasive computing* (pp. 158-175). Springer, Berlin, Heidelberg.
- [28] Krishnan, N. C., & Panchanathan, S. (2008, March). Analysis of low resolution accelerometer data for continuous human activity recognition. In *Acoustics, Speech and Signal Processing, 2008. ICASSP 2008. IEEE International Conference on* (pp. 3337-3340). IEEE.
- [29] Van Kasteren, T. L. M., Englebienne, G., & Kröse, B. J. (2010). An activity monitoring system for elderly care using generative and discriminative models. *Personal and ubiquitous computing*, 14(6), 489-498.
- [30] Cook, D. J., Krishnan, N. C., & Rashidi, P. (2013). Activity discovery and activity recognition: A new partnership. *IEEE transactions on cybernetics*, 43(3), 820-828.
- [31] Yala, N., Fergani, B., & Fleury, A. (2015, September). Feature extraction for human activity recognition on streaming data. In *Innovations in Intelligent Systems and Applications (INISTA)*, 2015 International Symposium on (pp. 1-6). IEEE.