

قطعه‌بندی جریان داده حسگرها در محیط‌های هوشمند فراگیر*

وحید قاسمی^۱

محمد جوادیان^۲

سجاد حیاتی^۳

چکیده

در بسیاری از رویکردهای بازشناسی اعمال، ابتدا جریان داده ورودی قطعه‌بندی شده و سپس عمل مربوط به هر قطعه تشخیص داده می‌شود. در این رویکردها یک گام اولیه بسیار مهم، قطعه‌بندی جریان داده‌های حسگرها است. در این مقاله به این مسئله پرداخته و برای حل آن روش جدیدی را بر مبنای یک مسئله برنامه‌ریزی تفاضل محدب، پیشنهاد داده‌ایم. در روش پیشنهادی، برای هر رویداد حسگر در جریان داده‌ها، یک بردار ویژگی یا استفاده از رویکردی بیزی محاسبه شده و دنباله این بردارها در یک تابع هزینه تفاضل محدب به کار گرفته شده است. بردارهای ویژگی و تابع هزینه را با در نظر گرفتن مکاشفه‌هایی که مطابق با شرایط محیط‌های هوشمند فراگیر هستند، محاسبه کرده‌ایم. قطعات داده با کمینه‌سازی این تابع استخراج می‌گردند. در ارزیابی‌ها، از یک شبیه‌ساز خانه‌های هوشمند برای تولید جریان داده‌های حسگرها استفاده شده است. میزان خلوص قطعات و آنتروپی شرطی قطعه‌بندی، برای سنجش میزان کارایی روش پیشنهادی محاسبه گردیده‌اند. ارزیابی‌ها نشان می‌دهند که در مقایسه با تعدادی از رویکردهای موجود، روش پیشنهادی عملکرد قابل قبولی را از خود نشان می‌دهد.

کلمات کلیدی: بهینه‌سازی محدب، جریان داده حسگرها، قطعه‌بندی، محیط‌های هوشمند فراگیر.

* تاریخ دریافت: ۹۷/۷/۱۰؛ تاریخ پذیرش: ۹۷/۱۰/۲۵.

^۱. استادیار گروه مهندسی کامپیوتر، دانشکده برق و کامپیوتر، دانشگاه صنعتی کرمانشاه، کرمانشاه، ایران (نویسنده مسئول)

v.ghasemi@kut.ac.ir

^۲. استادیار گروه مهندسی کامپیوتر، دانشکده برق و کامپیوتر، دانشگاه صنعتی کرمانشاه، کرمانشاه، ایران

mo.javadian@kut.ac.ir

^۳. استادیار گروه مهندسی برق، دانشکده برق و کامپیوتر، دانشگاه صنعتی کرمانشاه، کرمانشاه، ایران

sajadhayati@gmail.com

مقدمه

اصطلاح "محاسبات فراگیر"^۱ اولین بار توسط مارک ویزر^۲ مطرح شد. طبق این دیدگاه، پیش‌بینی شده بود که در آینده کامپیوترها به گونه‌ای به انسان خدمت خواهند کرد که اشخاص از حضور بدون مزاحمت این کامپیوترها در مکان‌هایی مانند لباس‌ها، اتومبیل‌ها و دیگر وسایل، هیچ اطلاعی نخواهند داشت (ویزر، ۱۹۹۱). محیط‌هایی را که از انواع ادوات محاسباتی (مانند انواع حسگرها، بازوهای حرکتی، پروتکل‌های ارتباطی بیسیم و سیم‌بندی شده و...) به منظور جمع‌آوری و پردازش داده‌ها استفاده کرده و با استنتاج بر روی این داده‌ها به صورت منفعل به کاربران خود خدماتی ارائه می‌دهند، محیط‌های فراگیرنده^۳ هوشمند می‌نامند. در چنین محیط‌هایی، داده‌ها با استفاده از حسگرها، میکروفون‌ها، دوربین‌های ویدئویی و... دریافت شده و به صورت جریانی از داده‌ها^۴ (یک سری زمانی) در دسترس قرار می‌گیرند. برای خلق چنین محیط‌هایی نیاز به استفاده از ابزارهای مختلفی از حوزه‌های بینایی ماشین، یادگیری ماشین، فناوری‌های بیسیم و تعامل کامپیوتر و انسان^۵ است تا محیط بتواند یادگیری داشته باشد و با نیازهای کاربران تطبیق یافته و به آنها پاسخ دهد.

به عنوان مثال، خانه‌های هوشمند^۶ که نمونه‌ای از محیط‌های فراگیر می‌باشند، در دهه گذشته به موضوعی جالب برای محققین تبدیل شده‌اند. یک خانه هوشمند محیطی خودکار است که از انواع مختلفی از حسگرها برای تشخیص اعمال ساکنین و ارائه خدمات به آنها 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 یا اعمال غیرطبیعی ساکنین را شناسایی کنند یا به ساکنین خود، کارهایی را که باید انجام دهند یادآوری نمایند. از جمله دیگر کاربردها می‌توان به مراقبت‌های پزشکی، کاربردهای امنیتی و امداد و نجات (مثلاً شناسایی حرکات مشکوک در فرودگاه‌ها و معابر

¹ Ubiquitous Computing

² Mark Weiser

³ Pervasive Environments

⁴ Data Stream

⁵ Human Computer Interaction

⁶ Smart Homes

(کاهن و همکاران، ۲۰۰۸)، استفاده‌های صنعتی (مثلاً نظارت بر کارهای انجام شده توسط کارگران در خطوط تولید (کاسکیماکی و همکاران، ۲۰۰۹)، و اتوماسیون‌ها (مثلاً اتوماسیون کنترل دما، تهویه هوا و تهویه مطبوع (هاگراس و همکاران، ۲۰۰۴) اشاره نمود. برای آن که محیط بتواند به طور هوشمندانه به نیازهای کاربران پاسخ دهد، ابتدا باید بتواند اعمال آنان را بر مبنای جریان داده‌های دریافت شده از محیط فیزیکی بازشناسی کرده تا متناسب با این اعمال خدماتی را ارائه دهد. لذا مسئله تشخیص اعمال اشخاص به موضوعی جالب در توسعه محیط‌های فراگیرنده هوشمند تبدیل شده است.

تاکنون روش‌های متعددی برای بازشناسی اعمال در محیط‌های هوشمند مطرح شده‌اند. در بسیاری از این روش‌ها، ابتدا جریان داده ورودی به قطعاتی تقسیم‌بندی شده و سپس برای هر قطعه داده یک عمل بازشناسی می‌شود. این کار از اهمیت ویژه‌ای برخوردار است زیرا در این روش‌ها اگر در قطعات استخراج شده داده‌های اضافه (یا کم) وارد شوند، ممکن است عمل مربوط به آن قطعه به درستی تشخیص داده نشده و در نتیجه به نیازهای کاربران به درستی پاسخ داده نشود. لذا گام مهم اولیه، قطعه‌بندی^۱ کارآمد جریان داده تولید شده در محیط است به نحوی که در گام‌های بعدی برای هر قطعه از داده‌ها عمل انجام شده مربوطه بازشناسی گردد.

در این مقاله قصد داریم موضوع قطعه‌بندی جریان داده‌ها در محیط‌های فراگیر هوشمند را مورد مطالعه قرار داده و راهکاری را برای این مسئله ارائه نمائیم. با توجه به پیچیدگی زیاد این مسئله، مفروضات زیر را برای حل آن در نظر می‌گیریم:

- محیط تک کاربره است.
- اعمال به صورت ترتیبی انجام می‌گیرند.
- از حسگرهای با مقادیر گسسته (مانند حسگرهای دودویی) استفاده شده است و در صورت استفاده از حسگرهای پیوسته مقادیر آن‌ها را گسسته‌سازی می‌کنیم.

- با توجه به این که حسگرهای صدا و تصویر حریم خصوصی افراد را در محیط‌های خصوصی نقض می‌کنند، استفاده از این حسگرها مدنظر نخواهد بود.

- قصد داریم یک روش مبتنی بر داده برای این کار ارائه دهیم.

سایر قسمت‌های مقاله بدین شرح است: در بخش پیشینه پژوهش مروری بر کارهای انجام شده خواهیم داشت. در ادامه به بیان مسئله و نمادگذاری‌های مورد استفاده می‌پردازد. در بخش روش‌شناسی پژوهش به بیان رویکرد پیشنهادی پرداخته و نحوه استخراج ویژگی و قطعه‌بندی را شرح خواهیم داد. در نهایت نحوه پیاده‌سازی و نتایج ارزیابی‌ها آورده شده‌اند. در پایان، به جمع‌بندی رویکرد پیشنهادی خواهیم پرداخت.

پیشینه پژوهش

در بسیاری از رویکردهای بازشناسی اعمال در محیط‌های هوشمند فراگیر، قطعه‌بندی جریان داده‌ها به صورت دستی و توسط ناظر انسانی انجام گرفته و سپس با به کارگیری سازوکارهای مبتنی بر یادگیری ماشین و مهندسی دانش، عمل مربوط به هر قطعه بازشناسی می‌گردد. از جمله این کارها می‌توان به پژوهش‌های (فاهاد، خان و راجاراجان، ۲۰۱۵)، (لیاو، بی و ناجنت، ۲۰۱۰) و (لیاو، بی و ناجنت، ۲۰۱۱) اشاره کرد.

در حالت کلی، در مورد سایر روش‌ها می‌توان گفت که غیر از روش‌های بازشناسی اعمال مبتنی بر مدل‌های یادگیرنده گرافیکی مانند مدل‌های مخفی مارکوف (HMM^1) (سینگلا و کوک و اسمیتر اجکامپ، ۲۰۱۰)، مدل‌های مخفی مارکوف کوپل شده ($CHMM^2$) (وانگ و گو و تاو و چن و لو، ۲۰۱۱)، میدان‌های تصادفی شرطی (CRF^3) (ون کاسترن و انگلین، ۲۰۱۱) و انواع آن که قطعه‌بندی به صورت ضمنی و توأم با رده‌بندی صورت می‌گیرد، در سایر روش‌ها قبل از رده‌بندی، جریان داده حسگرها با توجه به معیارهایی قطعه‌بندی می‌گردد. در روش‌های مبتنی بر مدل‌های گرافیکی، داده‌های

¹ Hidden Markov Models

² Coupled HMM

³ Conditional Random Fields

حسگرها را به عنوان مشاهدات و اعمال را به عنوان متغیرهای مخفی در نظر می‌گیرند، سپس با استفاده از الگوریتم‌های استنتاج دنباله وضعیت‌های مخفی، مانند ویتربی^۱، اعمال را تخمین می‌زنند. از جمله روش‌های بازشناسی اعمال که قطعه‌بندی جریان داده را به صورت غیرضمنی قبل از رده‌بندی انجام می‌دهند می‌توان به (کریشن‌ان و کوک، ۲۰۱۴)، (یالا، فرگانی و فلری، ۲۰۱۷)، (وان، اوگرادی و اوهاره، ۲۰۱۵)، (چو و همکاران، ۲۰۱۵)، (اوکیو، چن و وانگ استریت، ۲۰۱۴) و (هوانگ و نوجنت، ۲۰۱۳) به شرح ذیل اشاره کرد.

در پژوهش کریشن‌ان و کوک (۲۰۱۴) سه رویکرد قطعه‌بندی جریان داده‌های حسگرها قبل از رده‌بندی استفاده شده است. این رویکردها عبارتند از: قطعه‌بندی با طول زمانی ثابت (پنجره‌های زمانی با طولانی ثابت)، قطعه‌بندی با تعداد ثابت رویدادها (پنجره‌هایی از تعداد رخداد‌های ثابت از فعالیت حسگرها) و قطعاتی با طول ثابت از رخداد‌های حسگرها که وزن‌دهی شده‌اند. سپس، از این قطعات بردارهای ویژگی استخراج و برای بازشناسی اعمال مورد استفاده قرار می‌گیرند. در (یالا، فرگانی و فلری، ۲۰۱۷) رویکرد (کریشن‌ان و کوک، ۲۰۱۴) با معرفی یک ویژگی جدید برای بازشناسی اعمال مورد مطالعه قرار گرفته است. در رویکردهای فوق، از آنجا که طول قطعات ثابت در نظر گرفته می‌شود (چه مبتنی بر تعداد رویداد‌های حسگرها و چه زمان) امکان حضور داده‌های نامرتب با یک عمل و در نهایت، افت کارایی رده‌بندها در بازشناسی اعمال وجود دارد.

در پژوهش وان، اوگرادی و اوهاره (۲۰۱۵) قطعه‌بندی جریان داده ورودی قبل از رده‌بندی، به صورت پویا انجام گرفته است. در این رویکرد قطعاتی با طول زمانی و تعداد رویداد‌های حسگرهای متفاوت می‌توانند محاسبه گردند. در این رویکرد همبستگی و میزان ارتباط زمانی داده جدید با آخرین داده یک قطعه محاسبه می‌گردد. در صورتی که اختلاف زمانی بیشتر از یک حد آستانه بود یا همبستگی آن‌ها از یک حد آستانه کمتر بود، یک قطعه جدید تشکیل می‌شود و در غیر این صورت، داده جدید به قطعه قبلی افزوده می‌گردد.

هرچند، این رویکرد به صورت حریصانه عمل کرده و امکان اصلاح قطعات قبلی تشکیل شده با ورود داده‌های جدید در جریان داده حسگرها وجود ندارد، لذا می‌تواند منجر به نتایجی ناصحیح گردد.

در پژوهش چو، آن و هوانگ و لی (۲۰۱۵) از معیار فاصله جارو-وینکلر^۱ برای مقایسه زیردنباله‌هایی در جریان داده ورودی با قطعات داده از قبل تعیین شده در مجموعه آموزشی استفاده می‌گردد. بدین صورت که از ابتدای جریان داده‌ها، داده‌ها یکی پس از دیگری به یک قطعه اضافه می‌شوند و هر بار فاصله جارو-وینکلر قطعه با قطعات مجموعه آموزشی محاسبه می‌گردد. زمانی که این فاصله به حداکثر مقدار خود رسید، قطعه جدید از جریان ورودی جدا شده و رده‌بندی می‌گردد.

در پژوهش اوکیو، چن و وانگ استریت (۲۰۱۴) رویکردی مبتنی بر دانش برای قطعه‌بندی داده‌های حسگرها با توجه به هستان‌شناسی اعمال پیشنهاد شده است. این رویکرد نیاز به روش‌های مهندسی دانش برای استخراج هستان‌شناسی‌های^۲ اعمال دارد. در پژوهش هوانگ و نوجنت (۲۰۱۳) نیز سه رویکرد مبتنی بر دانش برای قطعه‌بندی جریان داده حسگرها پیشنهاد شده است. در این رویکردها از ارتباط بین مکان، حسگرها، و اعمال ممکن در هر مکان، برای قطعه‌بندی جریان داده‌ها استفاده شده است. این رویکرد نیز نیاز به استخراج دانشی دقیق از محل رخداد اعمال و حسگرهایی که در هر عمل ممکن است فعال شوند دارد. یکی از ایرادات روش‌های مبتنی بر دانش آن است که ممکن است دانش استخراج شده به اندازه کافی عمومیت نداشته باشد و با تغییر کاربر یا محیط، قوانین طراحی نیز تغییر خواهند کرد.

از آنجا که روش‌های مبتنی بر دانش نیاز به استخراج دانش پیشین دقیق داشته و می‌توانند به اندازه کافی عمومیت نداشته باشند، در رویکرد پیشنهادی به دنبال آن خواهیم بود تا یک روش پویا (قطعات با طول متغیر) و مبتنی بر داده برای قطعه‌بندی جریان داده

¹ Jaro-Winkler Distant Measure

² Ontologies

ورودی ارائه دهیم. لازم به ذکر است که در ارزیابی‌ها، روش پیشنهادی را با رویکردهای وان، اوگرادی و اوهاره (۲۰۱۵) و چو و همکاران (۲۰۱۵) مقایسه می‌کنیم.

روش‌شناسی پژوهش

بیان مسئله و نشانه‌گذاری‌های مورد استفاده


داده‌ها با حسگرهای مختلفی در محیط جمع‌آوری می‌شوند. 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 استفاده از حسگرهای پیوسته می‌توان از یک روش بخش‌بندی برای گسسته‌سازی دامنه آن‌ها استفاده کرد. بنابراین، دامنه حسگرها را گسسته فرض می‌کنیم. دامنه حسگر i را با D_i نمایش می‌دهیم. جدول (۱) مثالی از شناسه حسگرها، نوع، دامنه و رویدادهای ممکن برای آن‌ها را نشان می‌دهد.

جدول ۱. مثالی از شناسه، نوع، دامنه و رویدادهای ممکن برای حسگرها، پس از گسسته‌سازی دامنه

آن‌ها

ID	نوع حسگر	دامنه مقادیر حسگر	رویدادهای حسگر
M15	حرکتی	$D_{M01} = \{"ON", "OFF"\}$	M01_ON, M01_OFF
T03	دما	$D_{T01} = \{1,2,3\}$	T03_1, T03_2, T03_3
D07	سوئیچ	$D_{D07} = \{"CLOSE", "OPEN"\}$	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_t ها رویدادهای حسگرها را نشان می‌دهند. در شکل ۱ جریانی از داده‌های حسگرها نمایش داده شده است.



شکل ۱. مثالی از جریان داده حسگرها و دو قطعه داده در آن

با توجه به نمادگذاری فوق، مسئله قطعه‌بندی جریان داده‌ها را به فرم زیر تعریف کرده و در ادامه از نمادگذاری‌های آن استفاده می‌کنیم:

تعریف ۱ (مسئله قطعه‌بندی). فرض کنید $x_{1:T}$ دنباله‌ای از T رویداد متوالی حسگرها باشد. یک بخش‌بندی از $x_{1:T}$ را با m تایی مرتب $\langle P_1, \dots, P_m \rangle$ نشان می‌دهیم، که در آن P_i قطعه i ام است و برای هر دو قطعه متوالی مثل P_k و P_{k+1} داریم: $\exists h, j, k \in \{1..T\}: P_k = x_{h:j}, P_{k+1} = x_{j+1:i}$ به طوری که هر قطعه داده مربوط به یک عمل متوالی کاربر باشد.

روش پیشنهادی

در این بخش، ابتدا به بیان نحوه استخراج بردارهای ویژگی برای رویدادهای حسگرها می‌پردازیم. سپس، نحوه قطعه‌بندی جریان داده حسگرها را با استفاده از یک مسئله برنامه‌ریزی تفاضل محدب بیان خواهیم کرد.

استخراج ویژگی

با داشتن n عمل مشخص، برای رویداد حسگر مثل $x_i \in S$ بردار ویژگی $b_i = (b_{i,1}, \dots, b_{i,j}, \dots, b_{i,n})$ محاسبه می‌گردد. در این بردار، $b_{i,j} \geq 0$ مقدار باور رویداد حسگر x_i در مورد عمل a_j است، به طوری که داریم: $\sum_{j=1}^n b_{i,j} = 1$. بردار ویژگی یک رویداد حسگر را به صورت تابعی از احتمال اعمال به شرط آن رویداد، و میزان تسطیح^۱ این توزیع، به شرح ذیل محاسبه می‌کنیم.

^۱ Flatness

مقدار باور $b_{i,j}$ را به طور مستقیم متناسب با احتمال پسین رخداد عمل a_j به شرط x_i در نظر می‌گیریم:

$$b_{i,j} \propto p(A = a_j | X = x_i) \quad \text{رابطه ۱}$$

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 اشیاء محیطی (و در نتیجه تعداد معدودی از حسگرها) سروکار دارند. بنابراین، انتظار می‌رود $p(A = a_j | X)$ مسطح نباشد. بر این اساس فرض زیر را تعریف می‌کنیم:

فرضیه 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 نرمال‌سازی آن، می‌توان با مفهوم آنتروپی به صورت زیر بیان کرد:

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

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

$$\begin{aligned} & \bar{p}(A = a_j | X = x_k) \\ &= \frac{p(A = a_j | X = x_k)}{\sum_{k'=1}^{|S|} p(A = a_j | X = x_{k'})} \bar{p}(A = a_j | X = x_k) \\ &= \frac{p(A = a_j | X = x_k)}{\sum_{k'=1}^{|S|} p(A = a_j | X = x_{k'})} \end{aligned} \quad \text{رابطه ۳}$$

هر قدر $p(A = a_j | X)$ مسطح‌تر باشد، مقدار R_j بیشتر خواهد بود. لذا با توجه به

فرضیه ۱، $b_{i,j}$ را به طور عکس متناسب با R_j تعریف می‌کنیم. بنابراین، خواهیم داشت:

$$b_{i,j} \propto \frac{1}{R_j + \epsilon} \quad \text{رابطه ۴}$$

که در آن $\mathcal{E} \in \mathbb{R}^+$ مقدار کوچکی است که مانع از صفر شدن مخرج می گردد. از روابط (۱)، (۲)، (۳) و (۴) داریم:

$$b_{i,j} = \frac{p(A = a_j | X = x_i)}{R_j + \mathcal{E}} \cdot Z_i \quad \text{رابطه ۵}$$

که در آن، Z_i ضریب نرمال سازی است که از رابطه (۶) محاسبه می گردد.

$$Z_i = \left(\sum_{k=1}^n \frac{p(A = a_k | X = x_i)}{R_k + \mathcal{E}} \right)^{-1} \quad \text{رابطه ۶}$$

لازم به ذکر است که $p(A = a_k | X = x_i)$ را می توان با روش هایی همچون MLE^1 یا MAP^2 محاسبه نمود.

قطعه بندی با استفاده از یک مسئله برنامه ریزی تفاضل محدب

به بیان بسیار ساده، برای قطعه بندی جریان داده ها قصد داریم بردارهای ویژگی مربوط به رویدادها را خوشه بندی کنیم. در انتها، هر خوشه بیانگر یک قطعه خواهد بود. این خوشه بندی با روش های کلاسیک تفاوت های عمده ای دارد. زیرا اولاً رویدادهای یک خوشه باید متوالی باشند. ثانیاً، دیگر ویژگی های محیط های فراگیر هوشمند باید برآورده شوند. سه ویژگی در این محیط ها را در نظر می گیریم: ۱- تعداد قطعات اعمال محدود است (زیرا هر کاربر تعداد اعمال محدودی را انجام می دهد و در نتیجه تعداد بخش های مربوط به اعمال محدود خواهد بود) ۲- رویدادهایی که با قطعیت بالایی مربوط به اعمال مختلف هستند باید در قطعات داده متفاوتی قرار بگیرند و ۳- مراکز خوشه ها باید عدم قطعیت پایینی داشته باشند. اگر مرکز خوشه ای که رویداد x_i در جریان ورودی متعلق به آن است را با M_i نشان دهیم، محدودیت های فوق را می توان در جدول (۲) خلاصه کرد. با این محدودیت ها قصد داریم مراکز خوشه ها (بردارهای M_i) را طوری محاسبه کنیم که اگر مرکز خوشه نظیر به دو رویداد متوالی با هم برابر باشند، آن گاه آن دو رویداد در یک قطعه قرار بگیرند.

¹ Maximum Likelihood Estimation
² Maximum A Posteriori Estimation

جدول ۲. محدودیت‌های مورد نظر برای خوشه‌بندی

ردیف	محدودیت
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	۲- تعداد بخش‌های داده‌های مربوط به اعمال در جریان داده‌های حسگرها (یعنی $x_{1:T}$) محدود است. یعنی تعداد مراکز خوشه متفاوت باید محدود باشند.
۳	۳- رویدادهای هر خوشه باید متوالی باشند.
۴	۴- مراکز خوشه‌ها باید عدم قطعیت پایینی داشته باشند.

از آنجا که بردارهای ویژگی نرمال بوده، و مؤلفه‌های آن‌ها میزان باور به رخداد اعمال مختلف را نشان می‌دهد، می‌توان عدم قطعیت یک بردار باور (بردار ویژگی) را با آنتروپی آن بردار نشان داد. اگر عدم قطعیت یک بردار ویژگی را با تابع $u(\cdot)$ نشان دهیم، داریم:

$$u(b_i) = -\sum_{j=1}^n b_{i,j} * \log(b_{i,j}) \quad \text{رابطه (۷)}$$

محدودیت‌های جدول (۲) می‌توانند با هم ترکیب شده و یک تابع هدف تفاضل محدب را تشکیل دهند. با مینیمم‌سازی این تابع هدف، مراکز خوشه‌ها به دست می‌آیند. بدین منظور، حل مسئله بهینه‌سازی رابطه (۸) را پیشنهاد می‌دهیم.

$$M = \arg \min_{\bar{M}} \left(\sum_{i=1}^T \frac{1}{u(b_i)} \|b_i - \bar{M}_i\| + \lambda \sum_{i=1}^T \|\bar{M}_{i+1} - \bar{M}_i\| + \gamma \sum_{i=1}^T u(\bar{M}_i) \right) \quad \text{رابطه (۸)}$$

$$\begin{cases} \sum_{j=1}^n \bar{M}_{i,j} = 1 \\ \bar{M}_{i,j} \geq 0 \end{cases}, \forall i = 1, \dots, T \wedge j = 1, \dots, T$$

که در آن، $M_i \in \mathbb{R}^n$ و $\bar{M}_i \in \mathbb{R}^n$ به ترتیب سطرهای ماتریس‌های $M \in \mathbb{R}^{T \times n}$ و $\bar{M} \in \mathbb{R}^{T \times n}$ هستند. همچنین، $\lambda > 0$ و $\gamma > 0$ پارامترهای تنظیم^۱ می‌باشند که با استفاده از مجموعه آموزشی مقداردهی می‌شوند. از آنجا که جملات اول و دوم در رابطه (۸) محدب هستند و جمله سوم عبارتی مقعر است، با یک مسئله برنامه‌ریزی تفاضل محدب روبرو هستیم.

¹ Regularization Parameters

در رابطه (۸)، اولین عبارت، شرط اول از جدول (۲) را اعمال می‌کند. زیرا اگر عدم قطعیت کاهش داده شود، ضریب $\frac{1}{u(b_i)}$ افزایش می‌یابد. بنابراین، در فرآیند کمینه‌سازی، بردار M_i نزدیک به b_i تعیین می‌گردد تا مقدار اولین عبارت را تعدیل کند.

جمله دوم در رابطه (۸) محدودیت‌های دوم و سوم از جدول (۲) را اعمال می‌کند. در واقع، این عبارت مجموع نرم‌های l_2 بوده و بنابراین، منجر به پاسخ‌هایی می‌شود که در آن‌ها تعداد زیادی از M_i ‌های متوالی با هم برابر هستند. بنابراین، کمینه‌سازی این جمله نه تنها تعداد بخش‌ها را محدود می‌کند، بلکه موجب می‌شود تا رویدادهای متوالی در یک قطعه قرار بگیرند (زیرا در فرآیند بهینه‌سازی بردار M_i نظیر آن‌ها با هم برابر خواهد شد تا حداقل تفاضل به دست آید). باید توجه داشت که توازنی بین جمله اول و دوم رابطه (۸) وجود دارد. اولین جمله با T قطعه کمینه می‌شود در حالی که جمله دوم فقط با وجود یک قطعه از داده‌ها کمینه خواهد شد. این توازن با پارامتر λ کنترل می‌گردد.

به وضوح، جمله سوم رابطه (۸) موجب می‌شود تا مراکز خوشه‌ها به نحوی تعیین گردند که کمترین عدم قطعیت، یعنی کمترین آنتروپی، را داشته باشند. بنابراین، این جمله نیز مستقیماً چهارمین محدودیت جدول (۲) را اعمال خواهد کرد.

پس از محاسبه ماتریس M از رابطه (۸)، رویدادهای متوالی x_i و x_{i+1} در یک قطعه قرار می‌گیرند اگر رابطه $M_i = M_{i+1}$ برقرار باشد. برای حل این رابطه از روال محدب-مقعر (CCP²) (لیپ و بوید، ۲۰۱۶) استفاده می‌کنیم.

یافته‌های پژوهش

برای ایجاد جریان داده حسگرها در محیطی هوشمند، از یک شبیه‌ساز محیط‌های فراگیر هوشمند، به نام SDG³ (مندزواز کوز، هلال و کوک، ۲۰۰۹)، استفاده کردیم که از طریق صفحه اینترنتی آزمایشگاه خانه‌های هوشمند پروژه CASAS⁴ قابل دسترسی است. در شبیه‌سازی‌ها، جریانی از داده‌های حسگرها، شامل بیش از ۱۵۰۰ رویداد حسگر در یک خانه هوشمند، مربوط به ۵ عمل مختلف کاربر، تولید شده و سپس، قطعات صحیح داده به

¹ Norm

² Convex-Concave Procedure

³ Synthetic Data Generator

⁴ Center For Advanced Studies In Adaptive Systems

منظور ارزیابی روش پیشنهادی از جریان داده‌های حسگرها استخراج گردیدند. برای ارزیابی از معیارهای آنتروپی شرطی قطعه‌بندی و میزان خلوص، به شرح ذیل استفاده شد.

$$P_{Estimate} = \langle P_1^*, \dots, P_l^* \rangle \quad P_{GroundTruth} = \langle P_1, \dots, P_m \rangle$$

را قطعه‌بندی به روشی دلخواه در نظر بگیرید. برای ارزیابی کارایی $P_{Estimate}$ ، آنتروپی‌های شرطی ذیل را محاسبه کرده‌ایم:

$$H(P_{Estimate}|P_{GroundTruth}) = \sum_{j=1}^m \sum_{i=1}^l pr(P_i^*, P_j) \log(pr(P_i^*|P_j)) \quad \text{رابطه ۹}$$

$$H(P_{GroundTruth}|P_{Estimate}) = \sum_{i=1}^l \sum_{j=1}^m pr(P_i^*, P_j) \log(pr(P_j|P_i^*)) \quad \text{رابطه ۱۰}$$

که در آنها $pr(\cdot)$ تابع چگالی احتمال می‌باشد. هر قدر مقادیر هر دو آنتروپی شرطی حاصل از روابط (۹) و (۱۰) کوچک‌تر باشند، نشان دهنده آن است که قطعه‌بندی با کارایی بالاتری انجام شده است (بینقام، ۲۰۱۰).

میزان خلوص^۱ قطعات نیز با رابطه (۱۱) محاسبه گردید (مانینگ و راقوان، ۲۰۱۰). این معیار بیان می‌کند که دنباله داده‌های استخراج شده تا چه میزان صرفاً داده‌های مربوط به یک قطعه (و نه قطعه دیگر) را در خود جای داده‌اند. خلوص بیشتر قطعات استخراج شده می‌تواند نشان دهنده کارایی بالاتر الگوریتم قطعه‌بندی مورد استفاده باشد.

$$P_{turity} = \frac{1}{T} \sum_{i=1}^l \max_j |P_i^* \cap P_j| \quad \text{رابطه ۱۱}$$

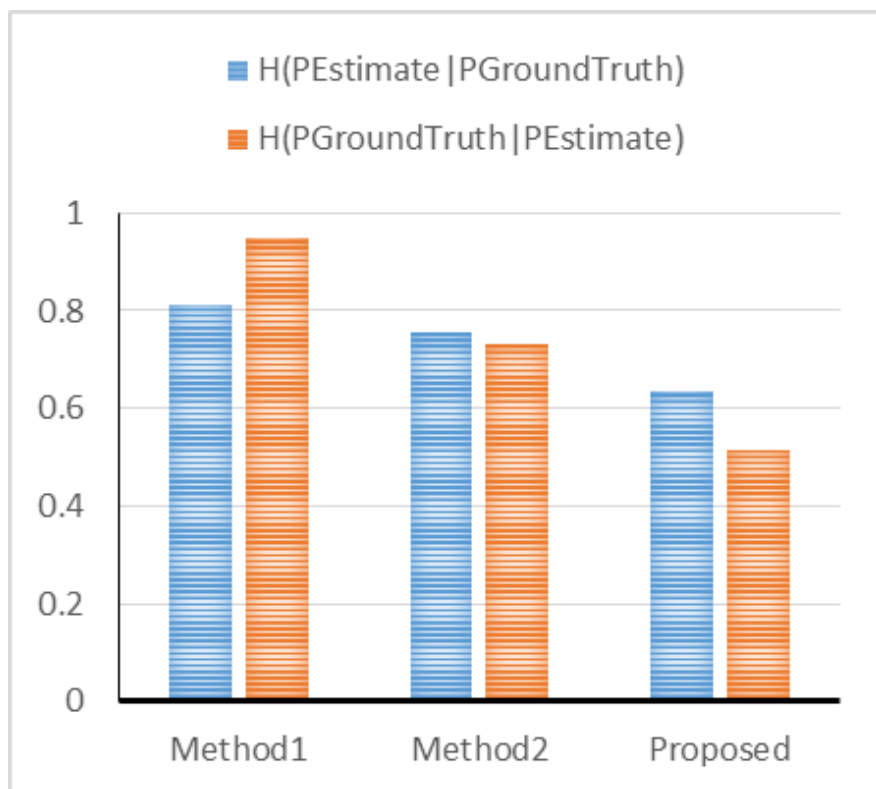
با استفاده از معیارهای فوق، روش پیشنهادی با رویکردهای وان، اوگرادی و اوهاره (۲۰۱۵) و چو و همکاران، (۲۰۱۵) مقایسه گردید. بدین منظور، رویکردهای وان، اوگرادی و اوهاره (۲۰۱۵) و چو و همکاران، (۲۰۱۵) به ترتیب Method1 و Method2 نامگذاری و پیاده‌سازی شدند.

نتایج در شکل‌های (۲) و (۳) نشان داده شده است. همان‌طور که در شکل (۲) مشاهده می‌شود،


$$H(P_{Estimate}|P_{GroundTruth}) \approx 63/0$$

^۱ Purity

و $H(P_{Estimate}|P_{GroundTruth}) \approx 0.51$ کمتر از دو روش دیگر می‌باشد که بیانگر عملکرد بهتر رویکرد پیشنهادی است. همچنین، همان‌طور که در شکل (۳) نشان داده شده است، در روش پیشنهادی میزان خلوص قطعات استخراج شده حدود ۰/۸ به دست آمده است که بهتر از دو روش دیگر می‌باشد.



شکل ۲. مقایسه آنتروپی‌های شرطی در روش‌های Method1، Method2 و روش پیشنهادی (Proposed) که با استفاده از روابط (۹) و (۱۰) محاسبه شده‌اند



شکل ۳. مقایسه میزان خلوص قطعات در Method1، Method2 و روش پیشنهادی (Proposed)

نتیجه‌گیری و پیشنهادها

در این مقاله روشی بر مبنای یک مسئله بهینه‌سازی تفاضل محدب به منظور قطع‌بندی جریان داده‌های حسگرها در محیط‌های فراگیر هوشمند ارائه گردید. در رویکرد پیشنهادی، ابتدا بردارهای ویژگی به صورت تابعی از احتمال پسین رخداد اعمال به شرط مشاهده داده‌های حسگرها و میزان تسطیح این توزیع محاسبه شدند. سپس، با توصیف رسمی مکاشفه‌هایی که در محیط‌های هوشمند مصداق دارند، تابع هزینه‌ای محدب-مقعر طراحی گردید. نشان دادیم که با کمیته‌سازی این تابع می‌توان جریان داده‌های حسگرها را قطع‌بندی کرد. ارزیابی‌های ما مشخص کردند که روش قطع‌بندی پیشنهادی، آنتروپی شرطی کمتری نسبت به تعدادی از روش‌های موجود دارد. همچنین، میزان خلوص قطعات

استخراج شده بیشتر از روش‌های مورد مقایسه ارزیابی شد. بنابراین، می‌توان گفت که رویکرد پیشنهادی عملکردی امید بخش داشته است.

سپاسگزارى

از همکاری دانشگاه صنعتی کرمانشاه در انجام این تحقیق، کمال تشکر و قدردانی را داریم. این تحقیق در قالب طرح پژوهشی شماره ۱۱۵۱/ط/پ/ص با استفاده از اعتبارات پژوهشی دانشگاه صنعتی کرمانشاه انجام شده است.

منابع

- Bingham, E. (2010). Finding segmentations of sequences. In *Inductive Databases and Constraint-Based Data Mining* (pp. 177-197). Springer, New York, NY.
- Cho, H., An, J., Hong, I., & Lee, Y. (2015, May). Automatic Sensor Data Stream Segmentation for Real-time Activity Prediction in Smart Spaces. In *Proceedings of the 2015 Workshop on IoT challenges in Mobile and Industrial Systems* (pp. 13-18). ACM.
- Cohen, C. J., Scott, K. A., Huber, M. J., Rowe, S. C., & Morelli, F. (2008, October). Behavior recognition architecture for surveillance applications. In *2008 37th IEEE Applied Imagery Pattern Recognition Workshop* (pp. 1-8). IEEE.
- Fahad, L. G., Khan, A., & Rajarajan, M. (2015). Activity recognition in smart homes with self verification of assignments. *Neurocomputing*, 149, 1286-1298.
- Hagra, H., Callaghan, V., Colley, M., Clarke, G., Pounds-Cornish, A., & Duman, H. (2004). Creating an ambient-intelligence environment using embedded agents. *IEEE Intelligent Systems*, 19(6), 12-20
- Hong, X., & Nugent, C. D. (2013). Segmenting sensor data for activity monitoring in smart environments. *Personal and ubiquitous computing*, 17(3), 545-559.
- Koskimaki, H., Huikari, V., Siirtola, P., Laurinen, P., & Roning, J. (2009, June). Activity recognition using a wrist-worn inertial measurement unit: A case study for industrial assembly lines. In *2009 17th Mediterranean Conference on Control and Automation* (pp. 401-405). IEEE.
- Krishnan, N. C., & Cook, D. J. (2014). Activity recognition on streaming sensor data. *Pervasive and mobile computing*, 10, 138-154.
- Liao, J., Bi, Y., & Nugent, C. (2010, July). Activity recognition for Smart Homes using Dempster-Shafer theory of Evidence based on a revised lattice structure. In *2010 Sixth International Conference on Intelligent Environments* (pp. 46-51). IEEE.
- Liao, J., Bi, Y., & Nugent, C. (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), 74-82
- Lipp, T., & Boyd, S. (2016). Variations and extension of the convex-concave procedure. *Optimization and Engineering*, 17(2), 263-287.
- Manning, C., Raghavan, P., & Schütze, H. (2010). Introduction to information retrieval. *Natural Language Engineering*, 16(1), 100-103.
- Mendez-Vazquez, A., Helal, A., & Cook, D. (2009, April). Simulating events to generate synthetic data for pervasive spaces. In *Workshop on Developing Shared Home Behavior Datasets to Advance HCI and Ubiquitous Computing Research*. Citeseer.
- Okeyo, G., Chen, L., Wang, H., & Sterritt, R. (2014). Dynamic sensor data segmentation for real-time knowledge-driven activity recognition. *Pervasive and Mobile Computing*, 10, 155-172.
- Singla, G., Cook, D. J., & Schmitter-Edgecombe, M. (2010). Recognizing independent and joint activities among multiple residents in smart environments. *Journal of ambient intelligence and humanized computing*, 1(1), 57-63.
- van Kasteren, T. L., Englebienne, G., & Kröse, B. J. (2011). Human activity recognition from wireless sensor network data: Benchmark and software. In *Activity recognition in pervasive intelligent environments* (pp. 165-186). Atlantis Press.
- Wan, J., O'grady, M. J., & O'hare, G. M. (2015). Dynamic sensor event segmentation for real-time activity recognition in a smart home context. *Personal and Ubiquitous Computing*, 19(2), 287-301.
- Wang, L., Gu, T., Tao, X., Chen, H., & Lu, J. (2011). Recognizing multi-user activities using wearable sensors in a smart home. *Pervasive and Mobile Computing*, 7(3), 287-298.
- Weiser, M. (1991). The Computer for the 21 st Century. *Scientific american*, 265(3), 94-105.
- Yala, N., Fergani, B., & Fleury, A. (2017). Towards improving feature extraction and classification for activity recognition on streaming data. *Journal of Ambient Intelligence and Humanized Computing*, 8(2), 177-189

استناد به این مقاله: DOI: 10.22091/jemsc.2018.1273

قاسمی، وحید، جوادیان، محمد، حیاتی، سجاد. (۱۳۹۷). «قطعه‌بندی جریان داده حسگرها در محیط‌های هوشمند فراگیر». *مدیریت مهندسی و رایانش نرم*، ۶ (۲)، ۳۹-۲۳.