



دانشگاه کاشان  
University of Kashan

مجله محاسبات نرم

## SOFT COMPUTING JOURNAL

تارنمای مجله: [sci.kashanu.ac.ir](http://sci.kashanu.ac.ir)



استفاده از تکنیک‌های مشابهت رشته‌ای برای تشخیص فعالیت‌های روزانه در خانه‌های مجهز به شبکه

حسگر دودویی

اشکان نیک‌آیین<sup>۱</sup>، دانشجوی دکتری، محسن رحمانی<sup>۲\*</sup>، دانشیار

<sup>۱</sup> گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه اراک، اراک، ایران.

### چکیده

### اطلاعات مقاله

#### تاریخچه مقاله:

دریافت ۰۵ دی ماه ۱۴۰۰

پذیرش ۱۲ مهر ماه ۱۴۰۱

#### کلمات کلیدی:

تشخیص فعالیت

مدل مخفی شبه‌مارکف

مشابهت رشته‌ها

فاصله لونتس‌تاین وزنی

تاب‌خوردگی زمان پویا

در سیستم‌هایی که افراد در فعالیت‌های روزانه خود به مراقبت ویژه نیاز دارند، الگوریتم‌های تشخیص فعالیت انسانی کاربرد دارند. روش‌های مختلف یادگیری ماشین، از جمله مدل مخفی مارکوف و روش‌های مرتبط به آن، به طور گسترده‌ای برای حل مساله تشخیص فعالیت انسانی استفاده شده‌اند. در کارهای قبلی، روش‌های مبتنی بر مدل مخفی مارکوف از فرض استقلال شرطی برای محاسبه احتمال مشاهدات استفاده شده است. در این تحقیق، به جای فرض استقلال شرطی، یک مدل احتمالی جدید برای فضای رشته‌ها، بر اساس تاب‌خوردگی زمان پویا و فاصله لونتس‌تاین وزنی پیشنهاد شده است. مدل احتمالی پیشنهادی، که با یک مدل مخفی شبه‌مارکف ترکیب شده، روی یکی از مجموعه داده‌های در دسترس اعمال شده است. نتایج حاصله نشان می‌دهد که استفاده از مدل پیشنهادی دقت شناسایی فعالیت‌های روزانه را به میزان قابل توجهی افزایش می‌دهد. کلیه کدها و داده‌ها مقاله حاضر، از طریق پیوند [github.com/ashnik1353](https://github.com/ashnik1353) در دسترس هستند.

© ۱۴۰۱ نویسندگان. مقاله با دسترسی آزاد تحت مجوز CC-BY

### ۱. مقدمه

کاربران مخالف حضور دوربین در زندگی خصوصی خود هستند. از طرف دیگر، سیستم‌های فیلمبرداری نیاز دارند حجم زیادی از داده را ذخیره کنند، که این مساله نیز می‌تواند به عنوان یک محدودیت برای استفاده از این سیستم‌ها تلقی شود. به علاوه این که برخی از مشکلات مانند وجود موانع می‌تواند کیفیت ویدیو را کاهش دهد [۵]. لذا گرایش زیادی نسبت به استفاده از تجهیزات حسگر ساده و شبکه حسگر [۶]، به جای دوربین در خانه‌های هوشمند وجود دارد [۷]، [۸]. در این محیط‌ها به طور معمول از حسگرهای دودویی<sup>۳</sup> برای تولید و ثبت دنباله‌ای از مقادیر دودویی با مهرهای زمانی<sup>۴</sup> مربوطه استفاده می‌شود [۷].

استفاده از ابزارهای تشخیص خودکار فعالیت‌های روزمره (یا ADL)<sup>۱</sup> آسایش بیشتری در زمینه مراقبت از سالمندان در خانه را فراهم می‌کند و سبک زندگی آنها را بهبود می‌بخشد [۱]–[۳]. از جمله متقاضیان اصلی چنین سیستم‌هایی خانه‌های هوشمند<sup>۲</sup> هستند که به طور معمول، مجهز به حسگرهای متنوعی از قبیل دوربین، ضبط صدا و غیره هستند [۴]. با این وجود، بسیاری از

\* نوع مقاله: پژوهشی

# نویسنده مسئول

پست‌های (های) الکترونیک: [ashkannikaiin@gmail.com](mailto:ashkannikaiin@gmail.com) (نیک‌آیین)

[m-rahmani@araku.ac.ir](mailto:m-rahmani@araku.ac.ir) (رحمانی)

<sup>3</sup> Binary sensors

<sup>4</sup> Time stamp

<sup>1</sup> Activity of Daily Living

<sup>2</sup> Smart homes

می‌شود.

در ادامه مقاله، ابتدا نمادها و برخی مفاهیم اولیه در مورد معیارهای تشابه رشته‌ها<sup>۱۲</sup> و HsMM معرفی شده و سپس، روش پیشنهادی بیان خواهد شد. پس از آن، مجموعه داده<sup>۱۳</sup> معرفی گردیده و آزمایش‌ها و نتایج مورد بحث قرار می‌گیرند. در نهایت نتیجه‌گیری ذکر می‌شود.

## ۲. کارهای مرتبط

تحقیقات زیادی در زمینه تشخیص خودکار فعالیت در محیط‌هایی که مجهز به حسگرها هستند، وجود دارد [۱۵]. نویسندگان در [۱۶] اشاره کرده‌اند که رویکردهای مدل‌سازی و شناخت فعالیت‌ها به دو دسته رویکردهای دانش محور<sup>۱۴</sup> و داده محور<sup>۱۵</sup> دسته‌بندی می‌شوند. رویکردهای دانش محور که عموماً از مدل‌سازی هستی‌شناسی<sup>۱۶</sup> فعالیت‌ها استفاده می‌کنند [۱۷]، [۱۸]، از عدم توانایی در توصیف وابستگی‌های زمانی رنج می‌برند. علاوه بر این، در آنها فرمول‌بندی فعالیت‌ها بر حسب زیرفعالیت‌ها<sup>۱۷</sup> دشوار است. رویکردهای داده محور از طیف گسترده‌ای از روش‌های یادگیری ماشین از جمله شبکه‌های عصبی<sup>۱۸</sup> [۱۹]–[۲۱]، ماشین‌های بردار پشتیبان<sup>۱۹</sup> [۲۲]، [۲۳]، داده کاوی<sup>۲۰</sup> [۲۴]، الگوکاوی<sup>۲۱</sup> [۲۵]، [۲۶]، یادگیری عمیق<sup>۲۲</sup> [۲۷]، [۲۸] و همچنین مدل‌های احتمالی شامل مدل نیو بیزین<sup>۲۳</sup> [۷]، مدل مخفی مارکوف [۱۲]، مدل مخفی شبه مارکوف [۱۲] و میدان‌های تصادفی شرطی<sup>۲۴</sup> [۲۹]، استفاده می‌کنند. تقریباً همه مدل‌های ذکر شده، به جز مدل‌های مارکوف، به یک پنجره زمانی<sup>۲۵</sup> برای در نظر گرفتن وابستگی‌های دوربرد نیاز دارند.

وظیفه شناسایی فعالیت<sup>۱</sup> پذیرفتن دنباله‌ای از این نوع اطلاعات و سپس تقسیم دنباله به بخش‌هایی به نام قطعات<sup>۲</sup> است که به هر قطعه یک برجسب فعالیت اختصاص داده می‌شود [۹].

به دلیل وجود وابستگی بین فعالیت‌های متوالی و نیز وابستگی بین دنباله داده‌های حسگرها در طول مدت انجام یک فعالیت، فرض توزیع یکسان مستقل<sup>۳</sup>، فرض خوبی برای این داده‌ها نیست. یکی از بهترین مدل‌های احتمالی که برای چنین داده‌هایی مناسب است، مدل مخفی مارکوف (HMM)<sup>۴</sup> [۱۰] و انواع مختلفی از آن مانند مدل مخفی شبه‌مارکوف (HsMM)<sup>۵</sup> [۱۱]، می‌باشد. مدل HsMM در حالت کلاسیک خود، برای مساله تشخیص فعالیت به کاربرده شده است [۱۲]. در این صورت، دنباله مشاهدات در هر حالت به عنوان رویدادهای مستقل در نظر گرفته می‌شود. به نظر می‌رسد با اعمال یک مدل احتمالی مناسب‌تر برای رویدادهایی که در هر حالت HsMM رخ می‌دهند، نتایج بهتری حاصل می‌شود. اصلاح HsMM برای محاسبه این احتمال در [۹] مورد توجه قرار گرفته است.

در این تحقیق، توزیع احتمال جدیدی بر اساس تاب‌خوردگی زمان پویا (DTW)<sup>۶</sup> [۱۳] و فاصله لونشتاین وزنی (WLD)<sup>۷</sup> [۱۴] پیشنهاد شده است. مدل پیشنهادی با HsMM ادغام می‌شود تا شباهت‌های بین دنباله داده‌های حسگرها در نظر گرفته شود. دنباله داده‌های هر حسگر در دوره‌های یکسان نمونه‌برداری شده و مقادیر دودویی آنها در هر نمونه زمانی<sup>۸</sup> به صورت یک بردار دودویی<sup>۹</sup> نمایش داده می‌شوند. این بردارهای دودویی به عنوان نشانه‌های یک الفبا<sup>۱۰</sup> در نظر گرفته شده و شباهت‌های بین رشته‌های این نمونه‌های زمانی که مربوط به یک فعالیت هستند، با DTW یا WLD محاسبه می‌گردند. در ضمن این فواصل به عنوان ویژگی<sup>۱۱</sup> به مدل توزیع احتمالی داده

<sup>12</sup> String similarities

<sup>13</sup> Dataset

<sup>14</sup> Knowledge-driven

<sup>15</sup> Data-driven

<sup>16</sup> Ontology

<sup>17</sup> Sub-activities

<sup>18</sup> Neural networks

<sup>19</sup> Support vector machines

<sup>20</sup> Data mining

<sup>21</sup> Pattern mining

<sup>22</sup> Deep learning

<sup>23</sup> Naïve Bayesian

<sup>24</sup> Conditional random fields

<sup>25</sup> Time window

<sup>1</sup> Activity Recognition

<sup>2</sup> Segments

<sup>3</sup> Independent and identically distributed

<sup>4</sup> Hidden Markov Model

<sup>5</sup> Hidden semi Markov Model

<sup>6</sup> Dynamic Time Warping (DTW)

<sup>7</sup> Weighted Levenstein Distance (WLD)

<sup>8</sup> Time instance

<sup>9</sup> Binary vector

<sup>10</sup> Alphabet

<sup>11</sup> Feature

سلسله مراتبی به درک عمیقی از چگونگی تجزیه یک فعالیت به زیرفعالیت‌ها نیاز دارند و مدل‌های پیچیده‌ای به شمار می‌روند که به سختی برای مشکلات تشخیص فعالیت در دنیای واقعی قابل استفاده هستند.

از طرف دیگر، یک مجموعه داده قابل اعتماد به اندازه یک مدل خوب برای تشخیص فعالیت ضروری است. اگر چه مجموعه داده‌های آزمایشگاهی<sup>۸</sup> [۳۵]، [۳۷]، [۴۱]، یا شبیه‌سازی شده<sup>۹</sup> [۴۲]، [۴۳]، به انجام مطالعات کمک کرده‌اند، یک مجموعه داده دنیای واقعی<sup>۱۰</sup> نقش مهمی در بهبود این زمینه ایفا می‌کند. در مرجع [۱۲] برخی از روش‌هایی که عموماً برای جمع‌آوری داده‌های دنیای واقعی استفاده می‌شوند، ذکر شده است، از آن جمله می‌توان به شبکه حسگر بی‌سیم و دوربین‌ها اشاره کرد. مجموعه داده تهیه شده توسط این مرجع از طریق آدرس اینترنتی <http://sites.google.com/site/tim0306> در دسترس عموم قرار داده شده است. داده‌های مقاله حاضر نیز از همین منبع گرفته شده است. دقت داشته باشید که جزئیات نحوه ایجاد داده‌ها نیز در مرجع مربوطه توضیح داده شده است. این مجموعه داده در این مقاله با نام مجموعه داده van Kasteren شناخته می‌شود.

### ۳. پیش‌زمینه‌ها

در این بخش به بیان مختصر پیش‌زمینه‌های مورد نیاز در روش پیشنهادی پرداخته خواهد شد.

#### ۳.۱. نمادها

در ادامه پیش از بیان روش پیشنهادی، با وام گرفتن برخی از اصطلاحات و نمادها از مرجع [۹]، نمادهای استفاده شده در این مقاله به صورت جدول (۱) بیان می‌شود.

مقدار دودویی حسگر  $z$  ام در زمان  $t_m$  با یک متغیر دودویی  $X_{t_m}^j$  نمایش داده شده و مقادیر متناظر با  $N$  حسگر در زمان  $t_m$  با یک بردار دودویی  $X_{t_m} = (X_{t_m}^1, X_{t_m}^2, \dots, X_{t_m}^N)^T$  نمایش داده می‌شود و دنباله  $X_{t_1:t_2}$  دنباله  $X_{t_1} X_{t_1+1} \dots X_{t_2}$  می‌باشد، بنابراین دنباله

تعیین اندازه این پنجره نیز مشکل ساز است، به خصوص در شرایطی که مدت زمان فعالیت‌ها بسیار متنوع هستند.

یکی از مواردی که تعیین و تشخیص فعالیت را دشوار می‌کند این است که زمان شروع و پایان یک فعالیت مشخص نیست [۳]، [۳۰]، [۳۱]. در موارد ساده که مرز فعالیت‌ها مشخص است، هدف اختصاص دادن دنباله ورودی حسگرها به یکی از دسته‌های فعالیت می‌باشد. در این موارد می‌توان از DTW یا سایر معیارهای فاصله برای سری‌های زمانی<sup>۱</sup> استفاده کرد [۳۲]، [۳۳]. سری زمانی الگو<sup>۲</sup>، با استفاده از نمونه‌های هر فعالیت ساخته می‌شوند. سری‌های زمانی هر فعالیت جدید با این الگوها مقایسه می‌شوند و فعالیت به یک الگو اختصاص می‌یابد.

مدل‌های پنهان مارکوف، از جمله روش‌های اولیه‌ای بودند که برای شناسایی فعالیت‌ها مورد استفاده قرار گرفتند [۳۴]، [۳۵]. توزیع نمایی مدت زمان حضور در یک حالت به عنوان یکی از مهم‌ترین نقص‌های مدل‌های پنهان مارکوف معرفی می‌شود [۱۰]. مورفی<sup>۳</sup> مدل موجود را اصلاح نموده و مدل مخفی شبه مارکوف را به عنوان زیرمجموعه‌ای از شبکه‌های بیزین<sup>۴</sup> فرموله کرد [۳۶]. کارهای بعدی توسط دانگ و همکاران<sup>۵</sup> با استفاده از مدل‌های مخفی شبه مارکوف برای نزدیک‌تر شدن تشخیص فعالیت به داده‌های واقعی انجام شد [۳۷].

از آنجایی که مدل‌های پنهان مارکوف و گسترش یافته آن یعنی مدل‌های مخفی شبه مارکوف، وابستگی‌های دوربرد بین داده‌های مشاهده را در نظر می‌گیرند، به طور گسترده استفاده می‌شوند. در ضمن چندین گونه از مدل‌های پنهان مارکوف، به ویژه انواع سلسله مراتبی<sup>۶</sup> آن بیشتر مورد استفاده قرار گرفته‌اند [۳۸]–[۴۰]. در مدل‌های سلسله مراتبی، عموماً فعالیت‌ها به زیرفعالیت‌ها تجزیه می‌شوند و سطوح پایین‌تر سلسله مراتب مسئول شناسایی این زیرفعالیت‌ها و سپس تحویل آنها به سطوح بالاتر، برای شناسایی فعالیت‌های سطح بالا<sup>۷</sup>، هستند. مدل‌های

<sup>1</sup> Time series

<sup>2</sup> Template

<sup>3</sup> Murphy

<sup>4</sup> Bayesian networks

<sup>5</sup> Duong et al

<sup>6</sup> Hierarchical

<sup>7</sup> High level activities

<sup>8</sup> Laboratory dataset

<sup>9</sup> Simulated dataset

<sup>10</sup> Real world dataset

$T$ . در ضمن پارامتر  $u_i$  برچسب قطعه  $i$  ام است. به عبارت دیگر  $u_i \in \{1, 2, \dots, L\}$  که  $L$  تعداد فعالیت‌هایی است که باید شناسایی شوند.

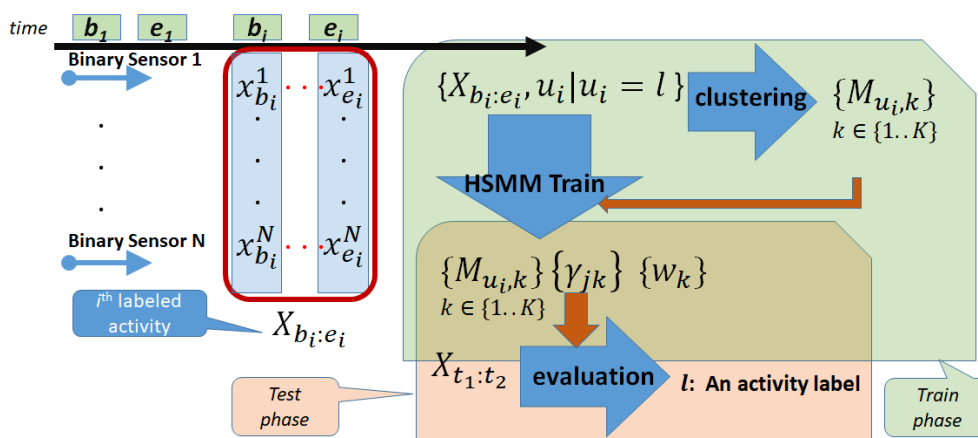
شکل (۱) نمای کلی پارامترهای توصیف شده و موقعیت آنها را در بلوک دیاگرام کار انجام شده نشان می‌دهد. دقت داشته باشید که برخی از پارامترهای این شکل در بخش‌های مربوطه با وضوح بیشتر شرح داده خواهند شد.

ورودی الگوریتم  $X_{1:T}$  است. هر  $X_{t_m}$  با یک برچسب فعالیت  $u_{t_m} \in \{1, 2, \dots, L\}$  متناظر می‌شود.

اگر  $T$  نمونه زمانی موجود باشد، یک برچسب‌زنی قطعه‌ای  $S$  روی  $X_{1:T}$  دنباله‌ای با طول  $U$  از قطعات و یا سه‌تایی‌های مرتب  $s_i = (b_i, e_i, u_i)$  خواهد بود به قسمی که  $b_1 = 1$  و  $e_U = T$  و به ازای هر  $1 \leq i < U$  داریم  $b_{i+1} = e_i + 1$ . پارامتر  $d_i = e_i - b_i + 1$  مدت زمان قطعه  $i$  ام نامیده شده و مشاهده متناظر آن  $X_{b_i:e_i}$  می‌باشد. می‌توان مشاهده نمود که  $\sum_{i=1}^U d_i = U$

جدول (۱): نمادهای استفاده شده در مقاله

نماد	شرح
$T$	تعداد نمونه‌های زمانی در دنباله ورودی
$N$	تعداد حسگرها
$L$	تعداد فعالیت‌ها یا تعداد برچسب‌ها
$x_{t_m}^j$	مقدار حسگر دودویی $j$ در زمان $t_m$ در ضمن $x_{t_m}^j \in \{0, 1\}$
$X_{t_m}$	بردار دودویی حسگرها در زمان $t_m$ . $X_{t_m} = (x_{t_m}^1, x_{t_m}^2, \dots, x_{t_m}^N)^T$ $1 \leq t_m \leq T$
$X_{t_1:t_2}$	دنباله‌ای از بردارهای دودویی از زمان $t_1$ تا زمان $t_2$ . $X_{t_1:t_2} = X_{t_1} \dots X_{t_2}$
$X_{1:T}$	دنباله ورودی الگوریتم $X_{1:T} = X_1 X_2 \dots X_T$
$U$	طول برچسب‌زنی قطعه‌ای روی دنباله ورودی $X_{1:T}$ . تعداد قطعه‌ها
$u$ and $u_i$	برچسب‌های فعالیت $u \in \{1, \dots, L\}$
$s_i = (b_i, e_i, u_i)$	قطعه $i$ ام. $X_{b_i:e_i}$ که دارای یک برچسب $u_i$ هستند.
$S = s_1 s_2 \dots s_U$	برچسب‌زنی قطعه‌ای روی $X_{1:T}$ . دنباله‌ای از قطعات را نشان می‌دهد.
$J_U$	تعداد دنباله‌های آموزشی مرتبط با فعالیت $u$ .
$D_u$	تعداد دنباله‌های آموزشی مرتبط با فعالیت $u$ . $D_u = \{X_{u,1}, X_{u,2}, \dots, X_{u,J_u}\}$
$M_{u,k}$	$k$ امین نماینده عضو وسط برای فعالیت $u$
$K$	تعداد خوشه‌ها



شکل (۱): بلوک دیاگرام کلی روش پیشنهادی

### ۳.۲. مدل شبه مخفی مارکوف

همان‌طور که ذکر شد، مدل مخفی مارکوف و انواع آن به ویژه انواع سلسله مراتبی به طور گسترده در زمینه تشخیص فعالیت استفاده می‌شوند. در مقایسه با مدل‌های مخفی مارکوف که بر روی مشاهدات و انتقال حالت‌های<sup>۱</sup> مخفی تمرکز می‌کنند، مدل‌های شبه مخفی مارکوف مدت زمان ماندن در هر حالت<sup>۲</sup> را نیز مدل می‌کنند. یک مدل شبه مخفی مارکوف، یک توزیع احتمال صریح<sup>۳</sup> را برای مدت زمان حالت‌ها یا متغیرهای مخفی<sup>۴</sup> در نظر می‌گیرد [۹]. شکل (۲) نمای کلی از بردارهای مشاهده و قطعه‌بندی آنها را نشان می‌دهد.

انواع مختلف مدل شبه مخفی مارکوف در مرجع [۱۱] توضیح داده شده است. با این همه، در این مقاله روش بیان شده در منبع [۳۶] مورد استفاده قرار گرفته است. در این روش، مدل با فرض  $S = s_1 s_2 \dots s_U$  و  $X_{1:T} = X_1 X_2 \dots X_T$  به عنوان دنباله ورودی و به عنوان یک برچسب‌زنی قطعه‌ای، احتمال توأم<sup>۵</sup> زیر تعریف می‌شود:

$$P(X, S) = \prod_{i=1}^U P(u_i | u_{i-1}) P(s_i) \quad (1)$$

که در آن

$$P(s_i) = P(d_i | u_i) P(X_{b_i:e_i} | u_i) \quad (2)$$

هدف یافتن برچسب‌زنی قطعه‌ای  $S^*$  می‌باشد که رابطه (۱) را بیشینه کند. کاربرد مدل شبه مخفی مارکوف در این مقاله از این نظر با بعضی کاربردهای آن در بازشناسی گفتار که در آنها برای هر کلاس یک مدل مارکوف ساخته می‌شود و سپس نمونه در هر کدام از مدل‌ها ارزیابی شده و کلاس با بهترین جواب ارزیابی به نمونه نسبت داده می‌شود، متفاوت است.

$$S^* = \operatorname{argmax}(P(X, S)) \quad (3)$$

در رابطه (۱)،  $P(u_i | u_{i-1})$  ماتریس گذار<sup>۶</sup> می‌باشد و

$P(u_1 | u_0) = P(u_1)$  احتمال اولیه<sup>۷</sup> ای است که قطعه  $s_1$  دارای برچسب  $u_1$  باشد. در مرجع [۱۲]، محققان از یک توزیع هیستوگرام<sup>۸</sup> با ۵ سطل<sup>۹</sup> برای محاسبه  $P(d_i | u_i)$  استفاده نموده‌اند. در این تحقیق برای مقایسه نتایج از همان روش استفاده شده است. آنها از  $P(X_t | u_i) = \prod_{t=b_i}^{e_i} P(X_t | u_i)$  برای HsMM پایه<sup>۱۰</sup> استفاده نموده‌اند. این بدان معنا است که احتمالات در هر نمونه زمانی، مشروط به فعالیت  $u_i$ ، مستقل از بقیه هستند. علاوه بر آن برای محاسبه  $P(X_t | u_i)$  از نیو بی‌زین استفاده شده است:

$$P(X_t | u_i) = \prod_{j=1}^N P(x_t^j | u_i) \quad (4)$$

که در آن  $N$  تعداد حسگرها می‌باشد.

### ۳.۳. فاصله وزنی لونشتاین

فاصله لونشتاین فاصله بین دو رشته  $\alpha$  و  $\beta$  را به عنوان حداقل عملیات پایه<sup>۱۱</sup> برای تبدیل  $\alpha$  به  $\beta$  تعریف می‌کند. این عملیات پایه شامل "حذف"<sup>۱۲</sup> یک نشانه<sup>۱۳</sup> از  $\alpha$ ، "درج"<sup>۱۴</sup> یک نشانه در  $\alpha$  یا "جایگزینی"<sup>۱۵</sup> نشانه‌ای از  $\alpha$  با نشانه‌ای دیگر است. به این معنا که به ازای دو رشته  $\alpha$  و  $\beta$  که از اعضای  $\Sigma^*$  می‌باشند، برای تبدیل  $\alpha$  به  $\beta$  قواعد زیر به کار می‌روند:

الف) حذف:  $\alpha = cxd$  را به  $\beta = cd$  با حذف  $x$  از  $\alpha$  تبدیل می‌کند.

ب) درج:  $\alpha = cd$  را به  $\beta = cxd$  با درج نشانه  $x$  میان  $c$  و  $d$  در  $\alpha$  تبدیل می‌کند.

ج) جایگزینی:  $\alpha = cxd$  را به  $\beta = cyd$  با جایگزینی  $x$  در  $\alpha$  با  $y$  تبدیل می‌کند.

<sup>7</sup> Initial probability

<sup>8</sup> Histogram distribution

<sup>9</sup> Bin

<sup>10</sup> Plain HsMM

<sup>11</sup> Basic operation

<sup>12</sup> Deletion

<sup>13</sup> Symbol

<sup>14</sup> Insertion

<sup>15</sup> Substitution

<sup>1</sup> State transition

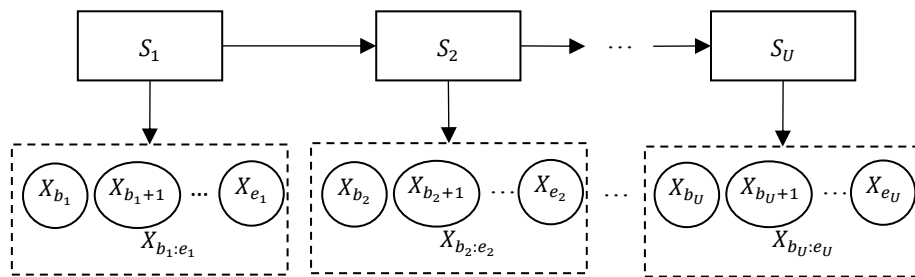
<sup>2</sup> State duration

<sup>3</sup> Explicit probability distribution

<sup>4</sup> Latent variables

<sup>5</sup> Joint probability

<sup>6</sup> Transition matrix



شکل (۲): نمودار HsMM که برجسب‌زنی قطعه‌ای را نشان می‌دهد

حذف، درج و جایگزینی برابر در نظر گرفته می‌شود، اما در روش وزنی برای هر عملیات پایه، یک ضریب وزنی به طور جداگانه در نظر گرفته می‌شود. این اندازه‌گیری دیگر متریک نیست، اما همچنان در استخراج ویژگی در برنامه‌هایی که نیازی به متریک ندارند، مفید است.

### ۳.۴. تاب‌خوردگی زمان پویا

یکی دیگر از معیارهای تشابه رشته‌ها تاب‌خوردگی زمان پویا است که به طور گسترده برای مقایسه سری‌های زمانی استفاده می‌شود. هدف این معیار در شکل گسسته آن، یافتن هزینه تبدیلی است که رشته اصلی را با در نظر گرفتن شباهت به رشته‌ای دیگر نگاشت می‌کند. مانند الگوریتم فاصله وزنی لونشتاین، الگوریتمی مبتنی بر برنامه‌نویسی پویا برای محاسبه تاب‌خوردگی زمان پویا وجود دارد. این الگوریتم علاوه بر یافتن مطابقت‌های بین نشانه‌ها، مقدار عددی را به عنوان خروجی برمی‌گرداند که معیاری برای تشابه بین دو رشته ورودی است. نشانه‌های متوالی یکسان از رشته اول به نشانه‌های متوالی مشابه از یک رشته دیگر نگاشت می‌شوند. گونه‌ای از تاب‌خوردگی زمان پویا وجود دارد که تاب‌خوردگی زمان پویا ایتاکورا<sup>۲</sup> نامیده می‌شود که در آن طول زیررشته‌های متوالی از حد به خصوصی فراتر نمی‌رود و از در نظر گرفتن نشانه‌های متوالی طولانی با نشانه‌های متوالی کوتاه ممانعت می‌کند [۴۵].

در این تحقیق از تاب‌خوردگی زمان پویا ایتاکورا و فاصله وزنی لونشتاین برای تخمین  $P(X_{b_i:e_i} | u_i)$  استفاده شده است.

که  $c, d \in \Sigma^*$  دو زیررشته  $\alpha$  و  $\beta$  هستند. همچنین  $x, y \in \Sigma$  دو نشانه مختلف می‌باشند [۱۴]. به عنوان مثال  $LD(abcde, acdf) = 2$  که با حذف  $b$  و جایگزینی  $e$  با  $f$  در رشته اول انجام می‌شود.

هر چه شباهت بین دو رشته  $\alpha$  و  $\beta$  بیشتر باشد،  $LD$  آنها کمتر خواهد بود. ثابت شده که  $LD$  یک متریک در فضای رشته‌ها را تعریف می‌کند، به این معنی که:

$$1. \forall \alpha \in \Sigma^* \text{ and } \forall \beta \in \Sigma^* : LD(\alpha, \beta) \geq 0 \text{ and } LD(\alpha, \beta) = LD(\beta, \alpha)$$

$$2. \forall \alpha \in \Sigma^*, \forall \beta \in \Sigma^* \text{ and } \forall \gamma \in \Sigma^* : LD(\alpha, \beta) \leq LD(\alpha, \gamma) + LD(\beta, \gamma)$$

یک الگوریتم بازگشتی ساده برای محاسبه  $LD$  دو رشته  $a_{1:m} = a_1 a_2 \dots a_m$  و  $b_{1:n} = b_1 b_2 \dots b_n$  به شکل زیر است:

$$LD(a_{1:m}, b_{1:n}) = f(a_m, b_n) + \min(LD(a_{1:m-1}, b_{1:n}), LD(a_{1:m}, b_{1:n-1}), LD(a_{1:m-1}, b_{1:n-1})) \quad (5)$$

که در آن،  $f(a_m, b_n)$  به شکل زیر می‌باشد:

$$f(a_m, b_n) = \begin{cases} 0 & \text{if } a_m = b_n \\ 1 & \text{otherwise} \end{cases} \quad (6)$$

شرط پایان زمانی اتفاق می‌افتد که طول یک رشته صفر شود و در این حالت فاصله لونشتاین برابر با طول رشته دیگر می‌باشد. با روش‌های برنامه‌نویسی پویا، یک الگوریتم کارآمد وجود دارد که  $LD(a, b)$  را در  $O(|a| \cdot |b|)$  محاسبه می‌کند [۴۳].

فاصله وزنی لونشتاین [۱۴]، نیز مانند  $LD$  یک معیار مشابهت<sup>۱</sup> رشته‌ها را با کمی تغییر ارائه می‌دهد. در  $LD$  کلاسیک، وزن

<sup>2</sup> Itakura DTW

<sup>1</sup> Similarity measure

## ۴. روش پیشنهادی

### ۴.۱. توجه برای بهبود احتمال شرطی

انتظار می‌رود که در صورت استفاده از دانش پیشین<sup>۱</sup>، به جای فرض مدل نیو بیزین، نتایج بهتری برای محاسبه  $P(X_{b_i:e_i}|u_i)$  به دست آید [۹]. در اینجا منظور از دانش پیشین این است که اگر  $X_{b_i:e_i}$  به هر یک از رشته‌های آموزشی فعالیت  $u_i$  شبیه‌تر باشد، احتمال شرطی آن نیز بیشتر است [۹].

این مقاله از معیارهای شباهت رشته‌ها برای استخراج برخی از ویژگی‌ها از مشاهدات استفاده کرده و سپس از آن‌ها در مدل توزیع احتمالی مناسب برای محاسبه  $P(X_{b_i:e_i}|u_i)$  استفاده می‌کند. معیارهای شباهت استفاده شده شامل تاب‌خوردگی زمان پویا و فاصله وزنی لونشتاین هستند و همچنین توزیع احتمالی که اعمال شده است توزیع مخلوط پواسون<sup>۲</sup> است. هر دو روش فاصله وزنی لونشتاین و تاب‌خوردگی زمان پویا به یک معیار فاصله پایه<sup>۳</sup> برای مقایسه نمادهای الفبا با یکدیگر نیاز دارند. در واقع این معیار یک تابع از زوج مرتب‌های نشانه‌های الفبا به روی اعداد مثبت می‌باشد و مقدار تابع شباهت دو نشانه الفبا و یا هر معیار دیگری، بسته به کاربرد در مساله می‌باشد. نشانه‌های الفبا در این مقاله بردارهای دودویی  $X_{t_i} = (x_{t_i}^1, x_{t_i}^2, \dots, x_{t_i}^N)^T$  می‌باشند. برای مقایسه این بردارها از فاصله همینگ<sup>۴</sup> استفاده می‌شود. فاصله همینگ بین دو بردار تعداد مولفه‌های مطابق در دو بردار است که مقادیر نابرابر دارند. برای تاب‌خوردگی زمان پویا از فاصله همینگ برای اندازه‌گیری عدم تشابه بین دو بردار استفاده شده و برای فاصله وزنی لونشتاین یک آستانه<sup>۵</sup>  $\tau$  در نظر گرفته شده که اگر فاصله همینگ دو بردار از این آستانه بزرگتر شود، دو بردار نامشابه در نظر گرفته شده و در غیر این صورت مشابه در نظر گرفته می‌شوند.

همچنین در این مطالعه یک الفبای  $\Sigma$  در نظر گرفته شده که نشانه‌های آن بردارهای دودویی با طول  $N$  می‌باشند. بنابراین هر

بردار نمونه زمانی  $X_{t_i} = (x_{t_i}^1, x_{t_i}^2, \dots, x_{t_i}^N)^T$  یک نشانه این الفبا است و دنباله زمانی  $X_{b_i:e_i} = X_{b_i} \dots X_{e_i}$  رشته‌ای روی این الفبا خواهد بود.

### ۴.۲. خوشه بندی

در مرحله آموزش در گام اول مشاهدات مربوط به هر فعالیت  $u$  در داده‌های آموزشی جدا می‌گردند. مجموعه دنباله‌های آموزشی  $J_u = \{X_{u,1}, X_{u,2}, \dots, X_{u,J_u}\}$  مرتبط با فعالیت  $u$  می‌باشد و تعداد این رشته‌های آموزشی است.

در گام بعدی خوشه‌بندی روی این داده‌ها انجام می‌شود. در این تحقیق از  $k$ -medoids [۴۶] که برای بردارهای داده غیرحقیقی<sup>۶</sup> مناسب است، استفاده می‌شود. این روش خوشه‌بندی شبیه روش خوشه‌بندی  $k$ -means [۴۷] است که در آن بردارها از یک فضای برداری عموماً دارای اجزای حقیقی می‌باشند. در این روش رشته‌ها به  $K$  خوشه تقسیم شده و برای هر خوشه یک عضو مرکز<sup>۷</sup> خوشه به عنوان نماینده<sup>۸</sup> خوشه معرفی می‌گردد. خصوصیت عضو مرکزی این است که اگر  $M_{u,k}$  نماینده خوشه  $K$  مرتبط با فعالیت  $u$  باشد، فرمول زیر می‌بایستی حداقل گردد.

$$\sum_{k=1}^K \sum_{j=1}^{J_u} \varphi(X_{u,j}, M_{u,k}) \cdot g(X_{u,j}, k) \quad (۷)$$

که

$$g(X_{u,j}, k) = \begin{cases} 1 & X_{u,j} \text{ is in } k^{\text{th}} \text{ cluster} \\ 0 & \text{otherwise} \end{cases} \quad (۸)$$

و  $\varphi$  تاب‌خوردگی زمان پویا و یا فاصله وزنی لونشتاین می‌باشد، بنابراین  $\varphi(X_{u,j}, M_{u,k})$  برابر با  $WLD(X_{u,j}, M_{u,k})$  و یا  $DTW(X_{u,j}, M_{u,k})$  خواهد بود.

در این مطالعه ما  $\varphi_{k,u}(X_{u,j}) = \varphi(X_{u,j}, M_{u,k})$  را ویژگی می‌نامیم و لذا  $\{\varphi_{k,u}(X_{u,j}) \mid k = 1:K\}$  بردار ویژگی‌ها است. این ویژگی‌ها استخراج شده و به مدل احتمالی داده می‌شوند.

<sup>1</sup> Prior knowledge

<sup>2</sup> Mixture of Poisson

<sup>3</sup> Base distance metric

<sup>4</sup> Hamming distance

<sup>5</sup> Threshold

<sup>6</sup> Non-real vector

<sup>7</sup> medoid

<sup>8</sup> representor



### ۴.۳. مدل احتمالی

$$\frac{\partial E}{\partial \lambda_k} = 0 \quad (12)$$

$$\Rightarrow \sum_{j=1}^{J_U} \frac{w_k (-\lambda_k^{\varphi_{jk}} + \varphi_{jk} \lambda_k^{\varphi_{jk}-1}) e^{-\lambda_k}}{(\varphi_{jk})!} = 0$$

که در آن به خاطر ساده‌نویسی از  $\varphi_{jk}$  به جای  $\varphi_k(X_{u,j})$  استفاده شده است. اگر متغیر  $\gamma_{jk}$  به صورت زیر تعریف شود:

$$\gamma_{jk} = \frac{\text{Poisson}(\varphi_{jk}, \lambda_k)}{\sum_{k=1}^K w_k \text{Poisson}(\varphi_{jk}, \lambda_k)} \quad (13)$$

$$= \frac{w_k (e^{-\lambda_k} \lambda_k^{\varphi_{jk}})}{(\varphi_{jk})!} = \frac{e^{-\lambda_k} \lambda_k^{\varphi_{jk}}}{\sum_{k=1}^K w_k \frac{e^{-\lambda_k} \lambda_k^{\varphi_{jk}}}{(\varphi_{jk})!}}$$

می‌توانیم از رابطه (۱۲) نتیجه زیر را به دست آوریم:

$$-\sum_{j=1}^{J_U} \gamma_{jk} + \sum_{j=1}^{J_U} \frac{1}{\lambda_k} \varphi_{jk} \gamma_{jk} = 0 \quad (14)$$

که از آن، رابطه زیر نتیجه می‌شود:

$$\lambda_k = \frac{\sum_{j=1}^{J_U} \varphi_{jk} \gamma_{jk}}{\sum_{j=1}^{J_U} \gamma_{jk}} \quad (15)$$

برای محاسبه  $w_k$  ها با توجه به قید  $\sum_{k=1}^K w_k = 1$  از روش ضرایب لاگرانژ استفاده می‌کنیم.

$$L(D_u, \mathbf{w}, \boldsymbol{\lambda}, \delta) = E(D_u, \mathbf{w}, \boldsymbol{\lambda}) + \delta \left( \sum_{k=1}^K w_k - 1 \right) \quad (16)$$

که در آن  $\delta$  ضریب لاگرانژ است. با صفر قرار دادن مشتق رابطه (۱۶) نسبت به  $w_k$ ، نتیجه زیر به دست می‌آید:

$$\sum_{j=1}^{J_U} \frac{e^{-\lambda_k} \lambda_k^{\varphi_{jk}}}{(\varphi_{jk})!} + \delta w_k = 0 \quad (17)$$

که نتیجه می‌دهد:

$$\sum_{j=1}^{J_U} \gamma_{jk} + \delta w_k = 0 \quad (18)$$

و جمع زدن رابطه (۱۸) روی  $K$  خوشه منجر به نتیجه زیر می‌شود:

$$\sum_{j=1}^{J_U} \sum_{k=1}^K \gamma_{jk} + \delta \sum_{k=1}^K w_k = 0 \quad (19)$$

مدل احتمال یک مخلوط پواسون است. چون فضای داده‌ها گسسته است مدل مخلوط پواسون بر مدل‌های پیوسته نظیر مخلوط گوسین<sup>۱</sup> قابل ترجیح است. لذا  $P(X|u)$  را می‌توان به صورت زیر بیان نمود:

$$P(X|u) = \sum_{k=1}^K w_k \text{Poisson}(\varphi_k(X), \lambda_k) \quad (9)$$

$$= \sum_{k=1}^K w_k \frac{e^{-\lambda_k} \lambda_k^{\varphi_k(X)}}{\varphi_k(X)!}$$

در این رابطه  $\lambda_k = \lambda_{k,u}$  و  $w_k = w_{k,u}$  و  $\varphi_k(X) = \varphi_{k,u}(X)$  فعالیت  $u$  تعلق دارند. از این به بعد هر جا که واضح باشد اندیس  $u$  حذف می‌گردد.

در مرحله آموزش برای تخمین پارامترها، با استفاده از حداکثر درست‌نمایی<sup>۲</sup>، از رابطه (۱) لگاریتم گرفته شده و در ادامه این رابطه بیشینه می‌گردد. از آنجا که پس از اعمال لگاریتم، حاصل ضرب‌های رابطه به مجموع لگاریتم‌ها تبدیل می‌شوند، پارامترهای  $\mathbf{w} = (w_1, w_2, \dots, w_K)^T$  و  $\boldsymbol{\lambda} = (\lambda_1, \lambda_2, \dots, \lambda_K)^T$  مستقل از سایر متغیرهای مدل مخفی شبه مارکوف نظیر ماتریس گذار و احتمالات مدت زمان<sup>۳</sup>، به دست می‌آیند. بنابراین با در نظر گرفتن رابطه (۲)، می‌بایست رابطه (۱۰) نسبت به  $\mathbf{w}$  و  $\boldsymbol{\lambda}$  بیشینه گردد.

$$E(D_u, \mathbf{w}, \boldsymbol{\lambda}) = \ln \left( \prod_{j=1}^{J_U} P(X_{u,j}|u, \mathbf{w}, \boldsymbol{\lambda}) \right) \quad (10)$$

از روابط (۹) و (۱۰) داریم:

$$E(D_u, \mathbf{w}, \boldsymbol{\lambda}) = \sum_{j=1}^{J_U} \ln \left( \sum_{k=1}^K w_k \frac{e^{-\lambda_k} \lambda_k^{\varphi_k(X)}}{\varphi_k(X)!} \right) \quad (11)$$

برای بیشینه کردن این تابع از الگوریتم EM<sup>۴</sup> استفاده شده است. به منظور حداکثر کردن رابطه (۱۱) نسبت به  $\lambda_k$  می‌بایست مشتق موجود در رابطه (۱۲) برابر با صفر در نظر گرفته شود.

<sup>1</sup> Mixture of Gaussian

<sup>2</sup> Maximum likelihood

<sup>3</sup> Duration probabilities

<sup>4</sup> Expectation Maximization



هر فعالیت، یک حداکثر مدت زمان  $D$  در نظر گرفته می‌شود که از داده‌های آموزشی برای هر فعالیت استخراج شده است. در ضمن  $\theta_t(u_j, d)$  بهترین احتمال برای رابطه (۲) تا نمونه زمانی  $t$  می‌باشد، در صورتی که آخرین فعالیتی که در آخرین قطعه از این زمان انجام شده  $u_j$  با مدت زمان  $d$  باشد. به عبارت دیگر اگر  $s = (t - d + 1, t, u_j) \in S^*$  باشد، در رابطه (۲۲) از رابطه (۹) برای محاسبه  $P(X_{t-d+1}|u_j)$  استفاده می‌گردد.

مراحل آموزش و آزمون در شکل (۳) نشان داده شده است. فرآیند با فاز آموزش آغاز شده و تمام پارامترهای مدل استخراج می‌شوند. تفاوت این فرآیند با روش‌هایی که در مراجع [۹] و [۱۲] ارائه شده‌اند، در مدل احتمال مخلوط پواسون است که برای احتمالات مشاهده (بلوک‌های رنگی) استفاده می‌شود. در مرجع [۱۲]، یک رویکرد نیویزین و در مرجع [۹] برخی از روش‌های الگوکاوای برای توزیع احتمال مشاهدات پیشنهاد شده است. در بخش بعدی، نتایج این تحقیق نشان داده شده و با نتایج مرجع [۱۲] مقایسه شده است.

لذا با توجه به قید  $\sum_{k=1}^K w_k = 1$  و با در نظر گرفتن تعریف  $\gamma_{jk}$  در رابطه (۱۳) می‌توان نوشت:

$$\delta = - \sum_{k=1}^K (1) = -J_u \quad (20)$$

در نتیجه با در نظر گرفتن روابط (۱۸) و (۲۰)، رابطه زیر برای محاسبه  $w_k$  به دست می‌آید:

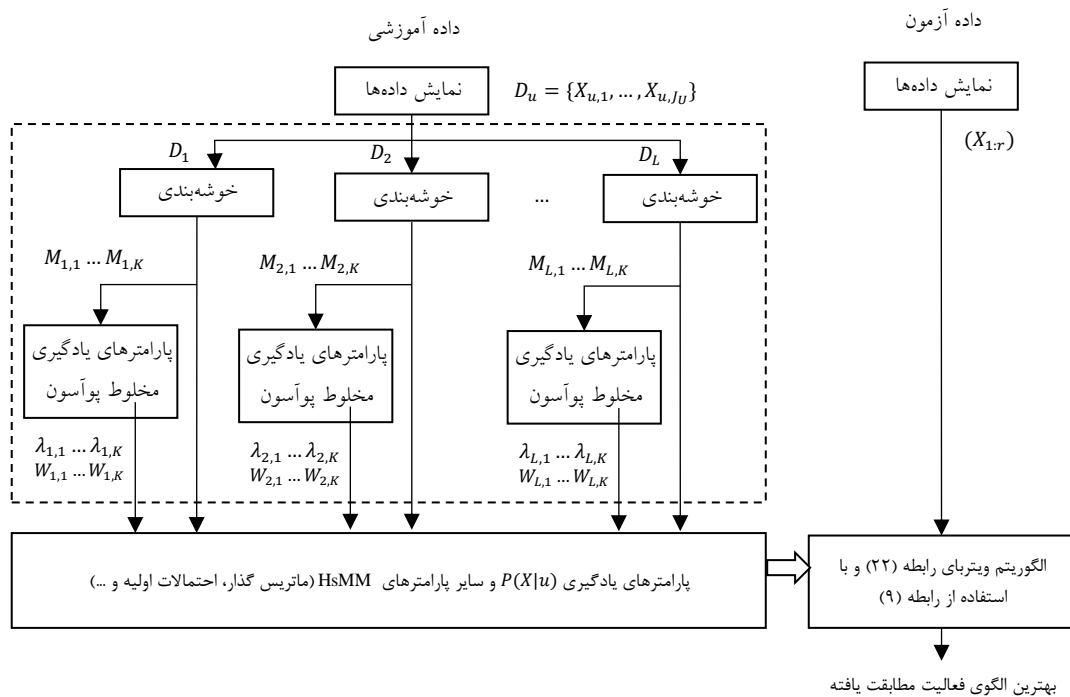
$$w_k = \frac{\sum_{j=1}^J \gamma_{jk}}{J_u} \quad (21)$$

بنابراین در مرحله  $E$  (امید) با استفاده از رابطه (۱۳)  $\gamma_{jk}$  محاسبه شده و سپس در مرحله  $M$  (بیشینه کردن) از روابط (۱۵) و (۲۱)،  $w$  و  $\lambda$  به دست می‌آیند.

در مساله رمزگشایی برای یافتن  $S^*$  در رابطه (۳)، الگوریتم معروف ویتربی (Viterbi) [۱۰]، استفاده می‌گردد.

$$\begin{aligned} \theta_t(u_j, d) &= \max_{1 \leq u_i \leq L} \left( \max_{1 \leq d' \leq D} (\theta_{t-d}(u_i, d')) P(u_j|u_i) \right) \\ &\times P(d|u_j) P(X_{t-d+1}|u_j) \end{aligned} \quad (22)$$

این فرمول بازگشتی بر هر نمونه زمانی  $t$  اعمال می‌شود و برای




شکل (۳): فرآیند کلی روش پیشنهادی

## ۵. آزمایش‌ها و ارزیابی

### ۵.۱. مجموعه داده

(۴) نشان‌دهنده «نقطه-تغییر» است که در آن مقادیر حسگرها تنها در زمان‌هایی که حالت خود را از فعال به غیرفعال و یا برعکس تغییر می‌دهند برابر با یک در نظر گرفته می‌شود. در نهایت، در بخش (ج) از شکل (۴) موقعیتی نشان داده شده است که در آن آخرین حسگر فعال تا زمانی که حسگر دیگری فعال شود، در سطح یک باقی می‌ماند، سپس حسگر قبلی صفر شده و حسگر جدید یک می‌شود. پس در هر زمان، تنها یک حسگر مقدار یک دارد و بقیه می‌بایست صفر در نظر گرفته شوند.



الف) خام (ب) نقطه-تغییر (ج) آخرین شلیک

شکل (۴). نمایش داده‌ها (گرفته شده از مرجع [۸]).

در بین تمام نمایش‌ها، آخرین شلیک ( $L$ ) و نقطه-تغییر ( $C$ ) به عنوان مؤثرترین ذکر شده‌اند [۴۸]. علت بهتر بودن سایر نمایش‌ها نسبت به نمایش خام این است که شخص به عنوان مثال می‌تواند هنگام باز بودن در و یا بسته بودن آن شروع به پخت و پز کند. در حالت نمایش خام، در طول زمان، حسگرهای ورودی «در» مقادیر متفاوتی دارند اما در سایر نمایش‌ها، این مقادیر متفاوت نیستند. نتایج این مقاله که در ادامه خواهد آمد نیز این مزیت را نشان می‌دهد.

### ۵.۳. روش‌های ارزیابی

در یادگیری ماشین، روش‌هایی که بر اساس حداکثر درستیابی هستند، ممکن است دچار برازش بیش از حد<sup>۴</sup> شوند. یک رهیافت برای غلبه بر این مشکل، اعتبارسنجی متقابل<sup>۵</sup> است. برای این کار از روش «خارج نگه داشتن یک روز»<sup>۶</sup> یا (LOO) استفاده شده و مجموعه داده به دو گروه مجموعه آموزش<sup>۷</sup> و مجموعه اعتبارسنجی<sup>۸</sup> تقسیم می‌شوند. این به آن معنا است که

اگر چه مجموعه داده‌های آزمایشگاهی [۳۵]، [۳۷]، [۴۱]، یا شبیه‌سازی شده [۴۲]، [۴۳]، کمک زیادی به مطالعات کرده‌اند، اما وجود یک مجموعه داده دنیای واقعی نقشی اساسی در پیشرفت این حوزه داشته باشد زیرا هدف تمام این مدل‌سازی‌ها قابل استفاده بودن در دنیای واقعی است. در مرجع [۱۲]، به برخی از روش‌هایی که به طور معمول برای جمع‌آوری داده‌های دنیای واقعی استفاده می‌شوند، اشاره شده است، از آن جمله می‌توان به استفاده از شبکه حسگر بی‌سیم و دوربین‌ها اشاره کرد. به هر حال، روش پیشنهادی این مقاله روی مجموعه داده ارائه شده توسط مرجع [۱۲] ارزیابی شده است. این مجموعه داده در این مقاله، به عنوان مجموعه داده van Kasteren نامیده می‌شود.

### ۵.۲. نمایش داده‌ها

در مراجع [۹] و [۴۸] سه نوع نمایش برای داده‌های دریافتی از حسگرها مورد استفاده قرار گرفته است.

۱) نمایش خام: مقدار هر لحظه که گره حسگر به طور فعال کار می‌کند برابر با یک و برای لحظات دیگر صفر در نظر گرفته می‌شود.

۲) نمایش نقطه تغییر: در این شرایط، درست زمانی که وضعیت حسگر تغییر می‌کند، مقدار آن برابر یک در نظر گرفته می‌شود.

۳) نمایش آخرین شلیک: مقدار آخرین حسگری که تغییر وضعیت داشته است، تا زمان تغییر حسگر بعدی برابر با یک در نظر گرفته می‌شود و بعد از آن صفر می‌شود.

در بخش (الف) در شکل (۴) مقادیر دو حسگر دودویی در زمان نشان داده شده است. در زمان فعالیت حسگر مقدار برابر با یک و در غیر این صورت صفر می‌باشد. بخش (ب) از شکل

<sup>4</sup> Over-fit

<sup>5</sup> Cross-validation

<sup>6</sup> Leave-One-day-Out

<sup>7</sup> Training set

<sup>8</sup> Validation set

<sup>1</sup> Raw representation

<sup>2</sup> Change-point representation

<sup>3</sup> Last-fired representation

شده، ثبت گردیده است. اولین خانه، خانه A، با ۱۴ حسگر در مدت ۲۵ روز برای ۱۰ نوع فعالیت که با بلوتوث حاشیه نویسی<sup>۹</sup> نویسی<sup>۹</sup> شده، مورد مطالعه قرار گرفته است. نتایج از خانه B، برای ۱۴ روز و ۲۳ حسگر و ۱۳ نوع فعالیت به صورت لیست روزانه استخراج شده‌اند و خانه C، برای ۱۹ روز با ۲۱ حسگر و ۱۶ نوع فعالیت به روشی مانند خانه A مورد مطالعه قرار گرفته است. مؤلفان در [۱۲] نشان داده‌اند که نتایج آزمایشات برای چهار مدل احتمال نیو بیزین، HMM، HsMM و CRF (میدان تصادفی شرطی)، به نفع HsMM می‌باشد. بنابراین مدل‌های پیشنهادی این مقاله، اگرچه می‌توان آنها را بر روی مدل‌های دیگر نیز به کار برد، بر روی HsMM بررسی شده‌اند.

نتایج HsMM پایه که در مرجع [۲۹] توضیح داده شده است، با مدل پیشنهادی این مقاله مقایسه شده و در جدول (۲) آورده شده‌اند. در این جدول اعدادی که جلوی آنها از علامت «±» استفاده شده است، معرف انحراف معیار اندازه‌گیری مورد نظر بر روی تعداد روزهای مورد آزمایش هستند. در ستون اول جدول، نوع نمایش داده‌ها با C و L نشان داده شده است. این نمایش‌ها به ترتیب مخفف نقطه-تغییر و آخرین شلیک می‌باشند. دو سطر اول نتایج اعمال HsMM پایه هستند که در مرجع [۱۲] استفاده شده‌اند. در برخی از مطالعات که از DTW استفاده کرده‌اند، فعالیت‌های سطح پایین مانند قدم‌زدن یا پایین آمدن از پله‌ها و یا ژست‌ها<sup>۱۰</sup>، مورد بررسی قرار گرفته‌اند [۳۲]، [۳۳]. این مراجع از حسگرهای پوشیدنی<sup>۱۱</sup> و یا دوربین‌ها استفاده کرده‌اند. فرض آنها این بوده که فعالیت‌ها قطعه‌بندی شده و ابتدا و انتهای آنها مشخص است. در مقابل، در این مقاله فعالیت‌های سطح بالای زندگی روزمره مورد مطالعه و تشخیص قرار گرفته‌اند. اگرچه استفاده از یک DTW ساده به شکلی که در مرجع [۳۳] استفاده شده، قابل مقایسه با کار این مقاله نیست، ولی برای روشن شدن موضوع، روش مورد استفاده در [۳۳] نیز روی داده‌های مقاله اعمال شده و نتایج آن در سطرهای سوم و چهارم جدول (۲) با نام‌های DTW+C و DTW+L آورده شده است. در ضمن چهار

یک روز برای اعتبارسنجی کنار گذاشته شده و از بقیه روزها برای آموزش مدل استفاده می‌شود. هر کدام از روزهای مجموعه داده به نوبت جهت اعتبارسنجی کنار گذاشته می‌شوند. چندین اجرای سیستم با روش‌های اندازه‌گیری استاندارد دقت<sup>۱</sup>، فراخوانی<sup>۲</sup>، معیار F1<sup>۳</sup> و صحت<sup>۴</sup> ارزیابی و اعتبارسنجی می‌شوند. روابط مربوط به این روش‌ها در زیر بیان شده است.

$$Prec. = \frac{TP}{TP + FP} \quad (23)$$

$$Rec. = \frac{TP}{TP + FN} \quad (24)$$

$$F1 = 2 \frac{Prec. \times Rec.}{Prec. + Rec.} \quad (25)$$

$$Acc. = \frac{TP + TN}{TP + FP + TN + FN} \quad (26)$$

که در آنها TP، FN، TN و FP به ترتیب نسبت مثبت‌های درست<sup>۵</sup>، مثبت‌های غلط<sup>۶</sup>، منفی‌های درست<sup>۷</sup> و منفی‌های غلط<sup>۸</sup> هستند [۴۷]. در بین این اندازه‌گیری‌ها معیار FI مورد توجه بیشتری قرار دارد زیرا میانگین توافقی دقت و فراخوانی بوده و شامل هر دوی این اندازه‌گیری‌ها است.

بخش بعدی تنظیمات مورد استفاده برای رهیافت این مقاله را توضیح می‌دهد و در ادامه نتایج ارزیابی ارائه خواهد شد.

#### ۵.۴. نرخ تشخیص

مجموعه داده‌های منبعی که به صورت رایگان در دسترس است و داده‌های ضروری را برای این مطالعه فراهم کرده در مراجع [۴۸] و [۴۹] ذکر شده است. اطلاعات سه ماه از فعالیت داوطلبان که از شبکه حسگر به دست آمده است، در مجموعه داده ذکر شده آمده است. مجموعه داده van Kasteren از سه خانه جمع‌آوری شده است. در هر خانه یک داوطلب برای چند روزی زندگی کرده و فعالیت‌هایی که از پیش برای وی تعیین

<sup>9</sup> Annotated with bluetooth

<sup>10</sup> Gustures

<sup>11</sup> Wearable sensors

<sup>1</sup> Precision

<sup>2</sup> Recall

<sup>3</sup> F1-Measure

<sup>4</sup> Accuracy

<sup>5</sup> True Positive

<sup>6</sup> False Positive

<sup>7</sup> True Negative

<sup>8</sup> False Negative

عمل کرده است. همچنین می‌توان مشاهده کرد که نتایج در خانه A از دو خانه دیگر بهتر است. هرچند حسگرهای کمتری در خانه A به کار رفته است ولی تنوع فعالیت‌های مورد تشخیص در آن کمتر است و نیز این فعالیت‌ها ساده‌تر هستند. به عنوان مثال فعالیت‌هایی که در مورد نظافت مورد مطالعه قرار می‌گیرند، تعداد کمتری دارند و چون این فعالیت‌ها معمولاً مرتبط با یک ناحیه مکانی هستند، بنابراین می‌بایست در آن مکان حسگرهای بیشتری برای تشخیص فعالیت‌های متنوع‌تر نصب گردد. جدول‌های (۳) تا (۵) نتایج تشخیص فعالیت‌ها در خانه‌های A، B و C را به طور جداگانه نشان می‌دهند که مربوط به پیکربندی DTW+L است و در مقایسه با پیکربندی L می‌باشند.

سطر آخر نشان‌دهنده نتایج این تحقیق و DTW یا LEV در این سطرها نشان‌دهنده نوع ویژگی استخراج شده هستند. به عنوان مثال، DTW+L مخفف پیکربندی است که در آن از مخلوط پواسون برای احتمال مشاهدات و DTW برای ویژگی‌های داده شده به مدل، در کنار نمایش آخرین شلیک استفاده شده است. برای WLD پارامتر  $\tau$  که در بخش ۴.۱ توضیح داده شد، برابر ۳۰٪ تعداد حسگرها و برای DTW ضریب ایتاکورا برابر ۶۰٪ حداقل طول دو رشته ورودی الگوریتم در نظر گرفته شده است. عددهای با قالب توپر حداکثر نتایج به دست آمده بر حسب معیارهای مختلف را نشان می‌دهند. بر اساس این مدل در تمام آزمایش‌ها نسبت به مدل HsMM پایه، با توجه به معیار F1 بهتر

جدول (۲): میانگین نتایج آزمایش‌ها روی فعالیت‌ها در سه خانه مربوط به مجموعه داده VAN KASTEREN

Feature	House A				House B				House C			
	Prec.	Rec.	F1	Acc.	Prec.	Rec.	F1	Acc.	Prec.	Rec.	F1	Acc.
pHSMM+C	60±15	74±13	66±14	91±7	41±12	53±11	46±11	67±25	42±11	<b>56±15</b>	48±11	84±13
pHSMM+L	71±16	75±12	72±14	92±6	50±16	65±13	56±15	82±14	44±10	52±13	47±11	78±15
DTW+C	5±4	18±9	7±6	12±8	8±13	17±8	8±8	8±7	6±6	11±6	7±7	20±13
DTW+L	42±19	42±19	42±19	90±6	20±11	24±12	21±11	41±29	23±9	32±17	27±11	74±17
HSMM+DTW+C	66±16	73±13	69±14	<b>94±6</b>	47±13	58±12	51±12	74±24	45±17	<b>56±15</b>	50±16	<b>85±13</b>
HSMM+DTW+L	<b>75±16</b>	<b>77±12</b>	<b>76±14</b>	92±6	<b>55±12</b>	63±14	<b>58±12</b>	83±12	46±11	53±13	49±11	78±15
HSMM+LEV+C	66±16	74±13	69±15	93±6	51±9	55±10	53±9	87±13	44±17	54±16	48±16	<b>85±13</b>
HSMM+LEV+L	75±15	<b>77±12</b>	<b>76±13</b>	93±6	55±10	61±9	<b>58±8</b>	82±13	<b>48±11</b>	54±13	<b>51±11</b>	78±14

جدول (۳): نتایج فعالیت‌های مجزا برای مجموعه داده VAN KASTEREN در خانه A

Activity	L			DTW+L		
	Prec.	Rec.	F1	Prec.	Rec.	F1
'Idle'	89.0	50.7	64.6	85.2	54.2	66.3
'Leave house'	94.4	99.7	97.0	94.8	99.0	96.9
'Use toilet'	73.9	82.2	77.8	75.1	84.1	79.3
'Take shower'	94.8	64.9	77.1	94.4	74.1	83.0
'Brush teeth'	17.2	34.4	22.9	36.7	34.4	35.5
'Go to bed'	90.1	96.5	93.2	90.4	96.5	93.4
'Prepare breakfast'	56.6	69.0	62.2	57.5	74.7	65.0
'Prepare dinner'	67.0	51.6	58.3	68.3	48.8	56.9
'Get snack'	42.6	54.8	47.9	40.4	54.8	46.5
'Get drink'	67.3	67.3	67.3	72.1	63.3	67.4

جدول (۴): نتایج فعالیت‌های مجزا برای مجموعه داده VAN KASTEREN در خانه B

Activity	L			DTW+L		
	Prec.	Rec.	F1	Prec.	Rec.	F1
'Idle'	52.7	55.8	54.2	72.7	59.8	65.7
'Leaving house'	85.4	93.9	89.5	82.1	97.1	89
'Use toilet'	27.5	80.7	41.1	45.6	73.4	56.3
'Take shower'	93.9	93.9	93.9	94.0	94	94
'Brush teeth'	8.7	37.7	14.1	9.6	23.5	13.7
'Go to bed'	95.2	68.7	79.8	94.7	72.7	82.2
'Get dressed'	13.7	80.4	23.4	71.1	64.3	67.5
'Prepare brunch'	46.9	62.0	53.4	35	74.7	47.7
'Prepare dinner'	24.2	37.6	29.4	0	0	NA
'Get a drink'	7.1	41.0	12.1	16.7	41.7	23.8
'Wash dishes'	4.3	23.4	7.3	1.0	1.0	1.0
'Eat dinner'	21.5	41.9	28.4	0	0	NA
'Eat brunch'	52.4	39.8	45.2	83.9	23.9	37.1

جدول (۵): نتایج فعالیت‌های مجزا برای مجموعه داده VAN KASTEREN در خانه C

Activity	L			DTW+L		
	Prec.	Rec.	F1	Prec.	Rec.	F1
'Idle'	58.8	39	46.9	57.6	39.3	46.7
'Leave house'	76.5	95.1	84.8	76.1	94.8	84.4
'Eating'	37.5	37.2	37.3	47.2	37.4	41.7
'Use toilet down'	38	58.2	46	53.2	57.6	55.3
'Take shower'	64.3	38.9	48.5	64.3	37.9	47.7
'Brush teeth'	30.6	40.6	34.9	34.2	37.6	35.8
'Use toilet up'	25.9	47.5	33.5	31.8	43.8	36.8
'Shave'	40.2	53.6	46	37.5	73.9	49.8
'Go to bed'	99.7	82.2	90.1	99.7	83	90.6
'Get dressed'	58.1	67	62.2	56.6	65.2	60.6
'Take medication'	30.8	26.7	28.6	60	20	30
'Prepare breakfast'	3.3	2.8	3	19.2	19.7	19.4
'Prepare lunch'	14.2	25	18.1	17	30	21.7
'Prepare dinner'	67.2	41.7	51.5	63.9	47.6	54.5
'Get snack'	13.6	37.5	20	20.6	29.2	24.1
'Get drink'	0	0	NA	0	0	NA

واقعی<sup>۵</sup> هستند. کمترین معیار F1 مربوط به فعالیت شماره «۵» یا «Brush teeth» می‌باشد. از جدول (۳) مشخص است که این فعالیت با فعالیت شماره «۳» یا «Use toilet» اشتباه گرفته می‌شود، زیرا این دو فعالیت در یک مکان انجام می‌شوند و نیز مدت زمان تقریباً یکسانی دارند. بنابراین، با افزودن حسگرهای بیشتر در این مکان و یا حسگرهایی که می‌توانند این دو فعالیت

ماتریس اشتباهات (سردرگمی)<sup>۱</sup> مربوط به جدول (۳) در جدول (۶) نشان داده شده است. سطرهای این جدول برچسب‌های واقعی<sup>۲</sup> و ستون‌های آن برچسب‌های استنتاج شده<sup>۳</sup> را نشان می‌دهند، در حالی که عناصر قطری<sup>۴</sup> برچسب‌های استنتاج شده

<sup>1</sup>Confusion matrix<sup>2</sup> True labels<sup>3</sup> Inferred labels<sup>4</sup>Diagonal elements<sup>5</sup> True inferred labels

را از هم مشخص کنند، می‌توان این مشکل را حل کرد. همین با فعالیت شماره «۷» یا «Prepare breakfast» تداخل دارد، انجام بحث را می‌توان در مورد فعالیت شماره «۹» یا «Get snack» که داد.

جدول (۶): ماتریس اشتباهات برای جدول (۳)

Activity number	1	2	3	4	5	6	7	8	9	10	Sum
1	2280	714	24	9	2	1089	10	63	6	10	4207
2	172	19149	8	0	1	0	0	0	7	0	19337
3	26	5	307	2	9	14	0	2	0	0	365
4	33	17	8	186	7	0	0	0	0	0	251
5	5	3	12	0	11	1	0	0	0	0	32
6	22	304	48	0	0	10454	1	0	0	0	10829
7	14	0	2	0	0	1	65	0	5	0	87
8	116	2	0	0	0	0	12	140	15	2	287
9	2	0	0	0	0	1	16	0	23	0	42
10	6	2	0	0	0	0	9	0	1	31	49
sum	2676	20196	409	197	30	11560	113	205	57	43	35486

نمی‌شود و می‌تواند در زمینه‌های دیگری که نیاز به برچسب‌گذاری بخش‌هایی از داده‌های متوالی دارند، اعمال شود. همچنین، می‌توان آن را با مدل‌های احتمالی غیر از مدل مخفی شبه‌مارکف ترکیب کرد.

تعارض منافع: نویسندگان اعلام می‌کنند که هیچ تعارض منافی ندارند.

## ۶. نتیجه‌گیری

در این تحقیق، یک روش جدید برای برچسب‌گذاری قطعه‌ای پیشنهاد شده است. این روش از معیارهای شباهت بین رشته‌ها مانند تاب‌خوردگی زمان پویا و فاصله لونشتاین وزنی برای محاسبه احتمال مشاهدات در مدل مخفی شبه‌مارکف بهره می‌برد. نتایج نشان می‌دهد که این روش می‌تواند به بهبود پیش‌بینی فعالیت‌هایی که در خانه‌های هوشمند انجام می‌شود، کمک کند. کاربرد این روش به شناسایی فعالیت محدود

## مراجع

- [1] S. Katz, T.D. Downs, H.R. Cash, and R.C. Grotz, "Progress in Development of the Index of ADL," The Gerontologist, vol. 10, pp. 20-30, 1970, doi: 10.1093/geront/10.1\_Part\_1.20.
- [2] H. Somboon and N. Ramakant, "Large-scale event detection using semi-hidden Markov models," in 9th IEEE Int. Conf. Comput. Vis. (ICCV 2003), Nice, France, pp. 1455-1462, 2003, doi: 10.1109/ICCV.2003.1238661.
- [3] J.K. Aggarwal and M.S. Ryoo, "Human activity analysis: A review," ACM Comput. Surv., vol. 43, no. 3, pp. 16:1-16:43, 2011, doi: 10.1145/1922649.1922653.
- [4] B. Bruno, J. Grosinger, F. Mastrogianni, F. Pecora, A. Saffiotti, S. Sathyakeerthy, and A. Sgorbissa, "Multi-modal sensing for human activity recognition," in 2015 24th IEEE International Symposium on Robot and Human Interactive Communication (RO-MAN), 2015, pp. 594-600, doi: 10.1109/ROMAN.2015.7333653.
- [5] L. Chen, J. Hoey, C.D. Nugent, D.J. Cook, and Z. Yu, "Sensor-Based Activity Recognition," IEEE Trans. Syst. Man Cybern. Part C, vol. 42, no. 6, pp. 790-808, 2012, doi: 10.1109/TSMCC.2012.2198883.
- [6] M. Khalily-Dermany, "A multiple criteria algorithm for planning the itinerary of mobile sink in wireless sensor networks," Soft Comput. J., vol. 7, no. 2, pp. 74-83, 2018, dor: 20.1001.1.23223707.1397.7.2.6.7 [In Persian].
- [7] E.M. Tapia, S.S. Intille, and K. Larson, "Activity Recognition in the Home Using Simple and Ubiquitous Sensors," in Pervasive Computing: 2nd

- Int. Conf., PERVASIVE 2004, Linz/Vienna, Austria, April 21-23, 2004, pp. 158-175, doi: 10.1007/978-3-540-24646-6\_10.
- [8] D.C. Ranasinghe, R.L.S. Torres, and A. Wickramasinghe, "Automated activity recognition and monitoring of elderly using wireless sensors: Research challenges," in 5th IEEE International Workshop on Advances in Sensors and Interfaces IWASI, 2013, pp. 224-227, doi: 10.1109/IWASI.2013.6576067.
- [9] U. AVCI, "Recognizing and Discovering Activities of Daily Living in Smart Environments," Ph.D. dissertation, University of Trento, Italy, 2013.
- [10] L.R. Rabiner, "A tutorial on hidden Markov models and selected applications in speech recognition," *Proc. IEEE*, vol. 77, no. 2, pp. 257-286, 1989, doi: 10.1109/5.18626.
- [11] S.-Z. Yu, "Hidden semi-Markov models," *Artif. Intell.*, vol. 174, no. 2, pp. 215-243, 2010, doi: 10.1016/j.artint.2009.11.011.
- [12] T. Kasteren, G. Englebienne, and B.J.A. Krose, "Activity recognition using semi-Markov models on real world smart home datasets," *J. Ambient Intell. Smart Environ.*, vol. 2, no. 3, pp. 311-325, 2010, doi: 10.3233/AIS-2010-0070.
- [13] B. Juang, "On the hidden Markov model and dynamic time warping for speech recognition - A unified view," *AT&T Bell Lab. Tech. J.*, vol. 63, no. 7, pp. 1213-1243, 1984, doi: 10.1002/j.1538-7305.1984.tb00034.x.
- [14] J. Xu and X. Zhang, "Kernels based on weighted Levenshtein distance," in 2004 IEEE International Joint Conference on Neural Networks (IEEE Cat. No.04CH37541), Budapest, 25-29 July 2004, doi: 10.1109/IJCNN.2004.1381147.
- [15] V.G. Sanchez, C.F. Pfeiffer, and N.-O. Skeie, "A Review of Smart House Analysis Methods for Assisting Older People Living Alone," *J. Sens. Actuator Networks*, vol. 6, no. 3, p. 11, 2017, doi: 10.3390/jsan6030011.
- [16] L. Liu, Y. Peng, M. Liu, and Z.G. Huang, "Sensor-based Human Activity Recognition System with A Multilayered Model Using Time Series Shapelets," *Knowl.-Based Syst.*, vol. 90, pp. 138-152, 2015, doi: 10.1016/j.knosys.2015.09.024.
- [17] H. Ning, F. Shi, T. Zhu, Q. Li, and L. Chen, "A novel ontology consistent with acknowledged standards in smart homes," *Comput. Networks*, vol. 148, pp. 101-107, 2019, doi: 10.1016/j.comnet.2018.11.004.
- [18] Z. Wang, S. Wang, and Q. Ji, "Capturing Complex Spatio-temporal Relations among Facial Muscles for Facial Expression Recognition," in 2013 IEEE Conference on Computer Vision and Pattern Recognition, 2013, pp. 3422-3429, doi: 10.1109/CVPR.2013.439.
- [19] D. Arifoglu and A. Bouchachia, "Activity Recognition and Abnormal Behaviour Detection with Recurrent Neural Networks," in 14th International Conference on Mobile Systems and Pervasive Computing (MobiSPC 2017), July 24-26, 2017, Leuven, Belgium, pp. 86-93, doi: 10.1016/j.procs.2017.06.121.
- [20] L. Song-Mi, Y. Sang Min, and C. Heeryon, "Human activity recognition from accelerometer data using Convolutional Neural Network," in 2017 IEEE International Conference on Big Data and Smart Computing (BigComp), Jeju Island, South Korea, 2017, pp. 131-134, doi: 10.1109/BIGCOMP.2017.7881728.
- [21] G. Bhat, R. Deb, V.V. Chaurasia, H. Shill, and U.Y. Ogras, "Online Human Activity Recognition using Low-Power Wearable Devices," in Proceedings of the International Conference on Computer-Aided Design, San Diego, CA, USA, November 05-08, 2018, pp. 1-8, doi: 10.1145/3240765.3240833.
- [22] K.G.M. Chathuramali and R. Rodrigo, "Faster human activity recognition with SVM," in International Conference on Advances in ICT for Emerging Regions (ICTer2012), Colombo, Sri Lanka, 2012, pp. 197-203, doi: 10.1109/ICTer.2012.6421415.
- [23] A. Palaniappan, R. Bhargavi, and V. Vaidehi, "Abnormal human activity recognition using SVM based approach," in 2012 International Conference on Recent Trends in Information Technology, Chennai, India, 2012, pp. 97-102, doi: 10.1109/ICRTIT.2012.6206829.
- [24] P. Palmes, H.K. Pung, T. Gu, W. Xue, and S. Chen, "Object relevance weight pattern mining for activity recognition and segmentation," *Pervasive Mob. Comput.*, vol. 6, no. 1, pp. 43-57, 2010, doi: 10.1016/j.pmcj.2009.10.004.
- [25] P. Rashidi and D.J. Cook, "Mining Sensor Streams for Discovering Human Activity Patterns over Time," in 2010 IEEE International Conference on Data Mining, Sydney, Australia, 2010, pp. 431-440, doi: 10.1109/ICDM.2010.40.
- [26] P. Rashidi, D.J. Cook, L.B. Holder, and M. Schmitter-Edgecombe, "Discovering Activities to Recognize and Track in a Smart Environment," *IEEE Trans. Knowl. Data Eng.*, vol. 23, no. 4, pp. 527-539, 2011, doi: 10.1109/TKDE.2010.148.
- [27] D. Liciotti, M. Bernardini, L. Romeo, and E. Frontoni, "A sequential deep learning application for recognising human activities in smart homes," *Neurocomputing*, vol. 396, pp. 501-513, 2020, doi: 10.1016/j.neucom.2018.10.104.
- [28] T. Su, H. Sun, C. Ma, L. Jiang, and T. Xu, "HDL: Hierarchical Deep Learning Model based Human Activity Recognition using Smartphone Sensors," in 2019 International Joint Conference on Neural



- Networks (IJCNN), Budapest, Hungary, 2019, pp. 1-8, doi: 10.1109/IJCNN.2019.8851889.
- [29] T.L.M. Kasteren, A.K. Noulas, and B.J.A. Krose, "Conditional Random Fields versus Hidden Markov Models for activity recognition in temporal sensor data," in 14th Annual Conference of the Advanced School for Computing and Imaging (ASCI 2008), Heijden, the Netherlands, 2008.
- [30] S. Aminikhanghahi, T. Wang, and D.J. Cook, "Real-Time Change Point Detection with Application to Smart Home Time Series Data," *IEEE Trans. Knowl. Data Eng.*, vol. 31, no. 5, pp. 1010-1023, 2019, doi: 10.1109/TKDE.2018.2850347.
- [31] S. Aminikhanghahi and D. Cook, "Enhancing activity recognition using CPD-based activity segmentation," *Pervasive Mob. Comput.*, vol. 53, 2019, doi: 10.1016/j.pmcj.2019.01.004.
- [32] Z. Ramezanzanpanah, M. Mallem, and F. Davesne, "Human Action Recognition Using Laban Movement Analysis and Dynamic Time Warping," in 24th International Conference on Knowledge-Based and Intelligent Information & Engineering Systems (KES 2020), Verona (Virtual Event), Italy, 2020, doi: 10.1016/j.procs.2020.08.040.
- [33] M. Masnad, G. M. MukitHasan, K.M. Iftekhar, and M.S. Rahman, "Human Activity Recognition using DTW Algorithm," in 2019 IEEE Region 10 Symposium (TENSYP), Kolkata, India, 2019, pp. 39-43, doi: 10.1109/TENSYP46218.2019.8971082.
- [34] D.H. Wilson and C. Atkeson, "Simultaneous tracking and activity recognition (STAR) using many anonymous, binary sensors," in International Conference on Pervasive Computing, Munich, Germany, 2005, pp. 62-79, doi: 10.1007/11428572\_5.
- [35] D.J. Patterson, D. Fox, H. Kautz, and M. Philipose, "Fine-grained activity recognition by aggregating abstract object usage," in 9th IEEE International Symposium on Wearable Computers (ISWC'05), Osaka, Japan, 2005, pp. 44-51, doi: 10.1109/ISWC.2005.22.
- [36] K.P. Murphy, "Hidden semi-markov models (hsmms)," unpublished notes, 2002.
- [37] T. Duong, D. Phung, H. Bui, and S. Venkatesh, "Efficient duration and hierarchical modeling for human activity recognition," *Artif. Intell.*, vol. 173, no. 7-8, pp. 830-856, 2009, doi: 10.1016/j.artint.2008.12.005.
- [38] P. Natarajan and R. Nevatia, "Online, Real-time Tracking and Recognition of Human Actions," in 2008 IEEE Workshop on Motion and Video Computing, Copper Mountain, CO, USA, 2008, pp. 1-8, doi: 10.1109/WMVC.2008.4544064.
- [39] C. Vogler and D. Metaxas, "Parallel hidden Markov models for American sign language recognition," in Proceedings of the Seventh IEEE International Conference on Computer Vision, Kerkyra, Corfu, Greece, 1999, pp. 116-122, doi: 10.1109/ICCV.1999.791206.
- [40] P.-C. Chung and C.-D. Liu, "A daily behavior enabled hidden Markov model for human behavior understanding," *Pattern Recognit.*, vol. 41, no. 5, pp. 1572-1580, 2008, doi: 10.1016/j.patcog.2007.10.022.
- [41] T.T. Truyen, D. Phung, H. Bui, and S. Venkatesh, "Hierarchical semi-Markov conditional random fields for recursive sequential data," in Advances in Neural Information Processing Systems, 2009, pp. 1657-1664.
- [42] E. Marhasev, M. Hadad, and G.A. Kaminka, "Non-stationary Hidden Semi-Markov Models in Activity Recognition," in: Proceedings of the AAAI Workshop on Modeling Others from Observations (MOO-06), 2006.
- [43] P. Natarajan and R. Nevatia, "Coupled Hidden Semi Markov Models for Activity Recognition," in 2007 IEEE Workshop on Motion and Video Computing (WMVC'07), Austin, TX, USA, 2007, pp. 10-10, doi: 10.1109/WMVC.2007.12.
- [44] R.A. Wagner and M.J. Fischer, "The String-to-String Correction Problem," *J. ACM*, vol. 21, no. 1, pp. 168-173, 1974, doi: 10.1145/321796.321811.
- [45] Z. Geler, V. Kurbalija, M. Ivanovic, and M. Radovanovic, "Weighted kNN and Constrained Elastic Distances for Time-Series Classification," *Expert Syst. Appl.*, vol. 162, p. 113829, 2020, doi: 10.1016/j.eswa.2020.113829.
- [46] P. Arora, Deepali, and S. Varshney, "Analysis of K-Means and K-Medoids Algorithm for Big Data," *Proc. Comput. Sci.*, vol. 78, pp. 507-512, 2016, doi: 10.1016/j.procs.2016.02.095.
- [47] A. Yoosofan and E. Yousofian, "Clustering provinces in Iran Based on Digital Divide Metric Using the K-means Algorithm," *Soft Comput. J.*, vol. 1, no. 1, pp. 32-45, 2012 [In Persian].
- [48] T.L.M. Kasteren, G. Englebienne, and B.J.A. Krose, "Human Activity Recognition from Wireless Sensor Network Data: Benchmark and Software," in Activity Recognition in Pervasive Intelligent Environments, L. Chen, C.D. Nugent, J. Biswas, and J. Hoey, Eds., ed Paris: Atlantis Press, 2011, pp. 165-186, doi: 10.2991/978-94-91216-05-3\_8.
- [49] U. Avcı and A. Passerini, "Improving Activity Recognition by Segmental Pattern Mining," in 2012 IEEE International Conference on Pervasive Computing and Communications Workshops, Lugano, Switzerland, 2012, doi: 10.1109/PerComW.2012.6197605.