

تشخیص و کلاس بندی رفتار انسان در سیستم های مراقبت هوشمند با استفاده از مدل مخفی مارکوف

عادله فرزد¹، راهبه نیارکی اصلی²

1- دانشجوی کارشناسی ارشد مهندسی برق دانشگاه آزاد اسلامی واحد علوم تحقیقات گیلان

2- استادیار گروه مهندسی برق دانشگاه گیلان

چکیده

امروزه موضوع نظارت های ویدئویی بسیار مهم و مورد توجه است. یکی از کاربردهای نظارت ویدئویی بحث مراقبت از سالمندان و تحلیل رفتارهای آنها می باشد. در این مقاله، روشی کاربردی جهت دسته بندی و تشخیص رفتارهای انسان، با استفاده از مدل مخفی مارکوف¹ ارائه می شود. برای این منظور، ابتدا به استخراج ویژگی های رفتاری و تولید بردار ویژگی می پردازیم. سپس این ویژگی ها توسط مدل مخفی مارکوف دسته بندی می شوند. در نهایت رفتارهای غیرعادی توسط سیستم شناسایی و تشخیص داده می شود. نتایج به دست آمده از روش پیشنهادی بیانگر دقت 94 درصدی است و مقایسه آن با روش های مشابه نشان می دهد که روش پیشنهادی از کارایی بالایی در تشخیص صحیح رفتار افراد برخوردار است.

واژه های کلیدی: نظارت های ویدئویی، تشخیص رفتارهای انسان، مدل مخفی مارکوف، استخراج ویژگی.

¹-HMM

1. مقدمه

در سال‌های اخیر تشخیص رفتار افراد و کاربرد آن در زمینه‌های مراقبت ویدئویی بسیار مورد توجه قرار گرفته است. از طرفی تعداد افراد سالمند و بیماری که تنها زندگی می‌کنند و نیاز به نظارت مستمر دارند رو به افزایش است. در نتیجه وجود سیستم‌هایی هوشمند جهت نظارت دائم این افراد بسیار ضروری و کاربردی خواهد بود. پردازش ویدئوهای دوربین‌های امنیتی با هدف کنترل و تشخیص رفتارهای غیرمعمول، در نهایت یک سیستم مراقبتی-نظارتی خودکار را پدید می‌آورد، که یک نمونه از سیستم‌های تشخیص رفتار انسان است. سامانه‌های شناسایی خودکار رفتار انسان در ویدئو، دو مرحله اساسی دارند: یکی مرحله استخراج ویژگی‌ها از فریم‌های ورودی و دوم، مرحله کلاس‌بندی رفتارهاست [1]. در حقیقت توجه داشتن به خصوصیات رفتارهای انسان و استخراج ویژگی‌های مناسب این رفتارها و همچنین به‌کارگیری دسته‌بند مناسب بسیار ضروری است. در این مقاله، تمرکز اصلی ما روی طراحی سیستمی جهت دسته‌بندی رفتارها و تشخیص رفتارهای غیرعادی می‌باشد. به این منظور، برای استخراج ویژگی با توجه به موقعیت بدن و با توجه به مرکز ثقل بدن نقاط انتهایی با دقت مناسب شناسایی شده و بردار ویژگی نهایی تولید می‌شود. این ویژگی‌ها توسط دسته‌بند HMM دسته‌بندی و در نهایت رفتارهای غیرعادی شناسایی و تشخیص داده می‌شوند.

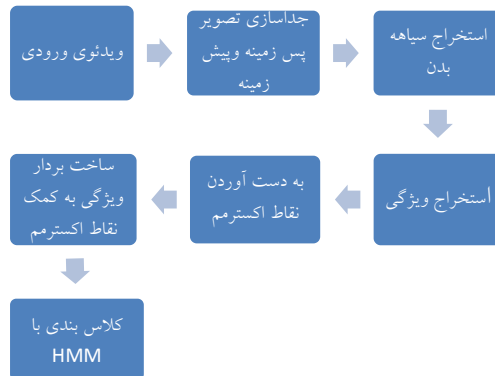
در هر روش تشخیص رفتار، ابتدا نیاز به استخراج اطلاعات مفید از ویدئو و سپس کلاس‌بندی آنها می‌باشد. در دو دهه اخیر، تحقیقات در زمینه‌های متنوعی بر روی کلاس‌بندی رفتارهای انسان صورت گرفته است [2]. این تحقیقات با توجه به نوع رفتار مورد مطالعه کاربردهای متفاوتی دارند. مطالعه رفتار برای کاربردهای نظارتی به چند روش انجام می‌گیرد که پر کاربردترین آنها استفاده از سنسورها و دوربین‌ها هستند. در برخی از کارها از شتاب به دست آمده از سنسورها برای تشخیص رفتار استفاده می‌شود. در [3و4]، بر روی مراقبت از افراد سالمند در خانه‌های هوشمند با استفاده از سنسور تحقیق صورت گرفته است. از مهم‌ترین معایب روش‌های سنسوری این است که فرد باید قطعه یا سنسور مشخص را همراه داشته باشد یا در مکان خاصی قرار گیرد. روش دیگر روش نظارت ویدئویی است که در این روش با نصب یک یا چند دوربین در مکان‌های مورد نظر به نظارت و تشخیص رفتار افراد می‌پردازند. از این نوع نظارت می‌توان برای موارد امنیتی مانند تشخیص حرکات ناهنجار در مکان‌های عمومی استفاده کرد [5] تحقیق با استفاده از روش نظارت ویدیویی برای آنالیز رفتارهای غیرعادی در گروه‌های کوچک افراد صورت گرفته است. از کاربردهای دیگر نظارت ویدیویی می‌توان به موارد مراقبت و تحلیل رفتارهای سالمندان برای موارد اورژانسی اشاره کرد. در [6]، بر روی تشخیص رفتارهای غیرعادی افراد مثل: افتادن، درد سینه و غش کردن با استفاده از مدل مخفی مارکوف انجام شده است. ما در این مقاله نیز از روش نظارت ویدئویی برای تحلیل داده‌های ورودی خود استفاده می‌کنیم.

در ادامه این مقاله در بخش دو به مراحل تحلیل رفتار پرداخته و بخش سه به روش دسته‌بندی مورد استفاده، توضیحات تکمیلی و آزمایش‌ها اختصاص یافته است. نتیجه‌گیری و جمع‌بندی در بخش چهارم آمده است.

2. مراحل تحلیل رفتار

به صورت کلی هر سامانه تحلیل رفتار انسان در ویدئو شامل چند مرحله اساسی (شکل 1) است که دسته از این‌ها به عنوان پیش‌پردازش (تشخیص پس‌زمینه و پیش‌زمینه و ردگیری فرد در فریم‌های متوالی) و دسته دیگر، به عنوان مساله اصلی محسوب می‌شوند که عبارتند از: استخراج ویژگی، انتخاب کلاس‌بند یا مدل مناسب، دسته‌بندی، شناسایی و اعتبارسنجی بر

مبنای ویژگی‌های استخراج شده. اولین مرحله در زمینه تشخیص رفتار یک شی، شناسایی شی متحرک در تصویر و قطعه‌بندی آن می‌باشد. مشهورترین راهکار برای تشخیص اشیای در حال حرکت از یک توالی ویدئو، تفریق پس‌زمینه [7] است. این راهکار از مقایسه هر فریم از ویدئو با پیش‌زمینه ایستا به دست می‌آید.



شکل 1- شمای کلی سامانه تحلیل رفتار انسان در ویدئو

1.2 استخراج ویژگی

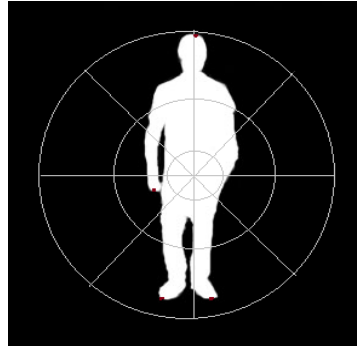
یکی از مراحل تشخیص رفتار انسان مرحله استخراج ویژگی است. در این میان گزینه‌های مختلفی برای انتخاب ویژگی وجود دارد. گزینه‌هایی مانند روش ستاره اسکلت² [8] که به سراغ ویژگی‌های جدیدتری رفته‌اند. یکی از این ویژگی‌ها می‌تواند نقاط انتهایی بدن یا به عبارت دیگر نقاط مهم محیط پیرامون بدن باشد. برای این منظور ابتدا سیاهه بدن بدست می‌آید سپس طبق یک معیار فاصله، فاصله همه نقاط پیرامون شخص از یک نقطه مبدأ که البته مکان آن بسیار مهم است، محاسبه می‌شود. در این صورت می‌توانیم با تحلیل نمودار مربوط به فاصله نقاط روی کانتور، نقاط مهم یا همان نقاط انتهایی بدن را به دست آوریم. در حالت کلی، ابتدا سیاهه بدن استخراج می‌شود. سپس مرکز جرمی بدن یک نقطه مبدأ یا یک تک ستاره و شاخص محاسبه می‌شود و هیستوگرام فاصله نقاط کانتور از مرکز محاسبه شده و در نهایت نقاط انتهایی به دست می‌آیند.

2.2 بردار ویژگی

در هر پروسه تشخیص رفتار که در آن هر رفتار با یک دنباله از تصاویر یا یک دنباله ویدئویی نمایش داده می‌شود، کلید اصلی، تبدیل هر فریم به یک نماد یا سمبل و ساخت بردار ویژگی است. در مجموع از هر روشی برای استخراج ویژگی استفاده کنیم در نهایت به مجموعه‌ای از نقاط انتهایی می‌رسیم. در اینجا ما برای توصیف نقاط انتهایی به دست آمده از سامانه نمایش قطبی استفاده می‌کنیم [9]. این کار به این صورت انجام می‌گیرد که با استفاده از دستگاه مختصات قطبی که مرکز آن روی مرکز ثقل بدن قرار می‌دهیم و از روی محل قرارگیری نقاط انتهایی در هر قسمت می‌توانیم بردار ویژگی مورد نظر را ایجاد نماییم. تعداد تقسیمات بر اساس نیمساز و فاصله، بردار ویژگی نهایی را تعیین می‌کند. ما تعداد تقسیمات زاویه‌ای یا همان قطاع‌ها را 8 و تقسیمات فاصله‌ای یا طولی یا همان شیارها را 3 در نظر گرفتیم.

² - star skeleton (ss)

بنابراین با این تقسیمات بردار ویژگی به طول 24 تشکیل می‌شود. بر این اساس، تعداد نقاط انتهایی که در هر شیار و قطاع قرار گیرد شمرده می‌شود و بردار ویژگی نهایی برای بدن تشکیل می‌شود (شکل 2).



شکل 2- نقاط انتهایی به دست آمده از روی استخوان‌بندی در روش ستاره اسکلت.

3.2 مدل مخفی مارکوف

مدل مخفی مارکوف یک مدل قدرتمند در بازشناسی پدیده‌های تصادفی به ویژه فرآیندهایی که دارای رفتار متغیر با زمان هستند، است. یکی از قابلیت‌های مهم HMM قابلیت آموزش این مدل است که این آموزش با اعمال یک سری از مجموعه داده‌های متوالی به یک HMM و تخمین پارامترهای اولیه آن صورت می‌گیرد. ما در این مقاله به کلاسه‌بندی و تشخیص رفتار انسان با استفاده از HMM گسسته خواهیم پرداخت.

در این حالت HMM شامل تعدادی از حالات است بصورتی که در واحدهای زمانی گسسته می‌تواند با احتمالاتی بین این حالت‌های مختلف حرکت کند و حالتی که سیستم در لحظه خاص t در آن قرار دارد را نیز با q_t نشان می‌دهیم ($t = 1, 2, \dots$). مانند مدل مارکوف، حالات در هر لحظه فقط به آخرین حالت قبلی بستگی دارند. حالات HMM به صورت مستقیم قابل مشاهده نیستند و تنها در طول یک دنباله از مشاهدات، قابل مشاهده می‌باشند [10]. برای توصیف یک HMM گسسته از پارامترهای زیر استفاده می‌شود [11]:

• N : تعداد حالات مدل

• M : تعداد خروجی‌های قابل مشاهده در هر حالت

• $V = \{v_1, v_2, \dots, v_M\}$: دنباله‌ای از خروجی‌های احتمالی

• $Q = \{q_1, q_2, q_3, \dots, q_t\}$: دنباله‌ای از حالات

آرایه‌های ماتریس احتمال انتقال را که با $A = \{a_{ij}\}$ نمایش می‌دهیم مطابق رابطه (1) به دست می‌آید:

$$a_{ij} = P[q_{t+1} = j | q_t = i] \quad 1 \leq i, j \leq N \quad (1)$$

که در آن a_{ij} احتمال انتقال بین حالت i و j است.

ماتریس احتمال مشاهدات را که با $B = \{b_j(k)\}$ نمایش می‌دهیم مطابق رابطه (2) به دست می‌آید:

$$b_j(k) = P[O_t = v_k | q_t = j] \quad 1 \leq k \leq M \quad (2)$$

که در آن $O = (o_1, o_2, \dots, o_T)$ دنباله مشاهدات، O_t نشان دهنده خروجی مشاهده شده در لحظه t و T بیانگر تعداد کل مشاهدات انجام شده است.

توزیع احتمالی حالت شروع را که با $\pi = \{\pi_i\}$ نمایش می‌دهیم مطابق رابطه (3) به دست می‌آید:

$$\pi_i = P[q_1 = i] \quad 1 \leq i \leq N \quad (3)$$

با داشتن مقداری برای هر کدام از پارامترهای فوق می‌توان مدل مورد نظر را بطور کامل تعریف کرد. در نتیجه می‌توانیم یک HMM مثل λ را بصورت مجموعه‌ای از سه ماتریس به شکل زیر نشان دهیم:

$$\lambda = (A, B, \pi) \quad (4)$$

1.3.2. مسائل اساسی در مدل مخفی مارکوف

برای تشخیص دنباله نمادهای خروجی مشاهده شده، ما برای هر کلاس یک HMM در نظر می‌گیریم. برای یک کلاس‌بند با C کلاس، مدلی که بهترین انطباق را از بین C، HMM داراست انتخاب می‌شود.

$$\lambda_i = \{A_i, B_i, \pi_i\} \quad i=1, \dots, C \quad (5)$$

معنای آن این است که وقتی یک دنباله مشاهدات از کلاس نامشخص داده می‌شود، ما احتمال $\Pr(\lambda_i|O)$ را برای هر HMM یا λ_i محاسبه می‌کنیم و λ_{c^*} را انتخاب می‌کنیم که در آن:

$$c^* = \arg \max (P_r(\lambda_i|O)) \quad (6)$$

با در دست داشتن دنباله مشاهدات خروجی $O = (o_1, o_2, \dots, o_T)$ و λ_i ، با توجه به قانون بیز یکی از مسائل محاسبه $P_r(\lambda_i|O)$ است یعنی احتمال اینکه دنباله مشاهدات خروجی به وسیله λ_i تولید شده باشد. این احتمال به وسیله الگوریتم پیشرو محاسبه می‌شود. الگوریتم پیشرو به صورت زیر تعریف می‌شود:

$$a_t(i) = P(o_1, o_2, \dots, o_T | q_t = i, \lambda) \quad (7)$$

$a_t(i)$ متغییر پیشرو نام دارد و به صورت استقرایی محاسبه می‌شود:

$$\begin{aligned} a_1(i) &= \pi_i b_i(o_1) \quad 1 \leq i \leq N \\ a_{t+1}(j) &= \left[\sum_{i=1}^N a_t(i) a_{ij} \right] b_j(o_{t+1}) \quad \begin{matrix} 1 \leq t < T \\ 1 \leq j \leq N \end{matrix} \\ P(O|\lambda) &= \sum_{i=1}^N a_T(i) \end{aligned} \quad (8)$$

ما شباهت هر HMM را با استفاده از معادلات بالا محاسبه می‌کنیم و مشابه‌ترین HMM را به عنوان نتیجه تشخیص انتخاب می‌کنیم.

یکی از مهم‌ترین مراحل در مدل مخفی مارکوف مرحله آموزش است، در مرحله آموزش، هر HMM باید به گونه‌ای آموزش یابد تا بیشترین شباهت برای تولید پارامترهای مربوط به کلاس خود را داشته باشد. آموزش یک HMM به معنی بهینه‌سازی پارامترهای مدل، (A, B, π) برای بیشینه کردن احتمال مشاهده دنباله مشاهدات خروجی $P_r(\lambda_i|O)$ است. برای این منظور از الگوریتم بام-ولج استفاده می‌شود. قبل از تعریف الگوریتم بام-ولج چند متغییر را باید تعریف کنیم:

$$\beta_t(i) = P(o_{t+1}, o_{t+2}, \dots, o_T | q_t = i, \lambda) \quad (9)$$

$\beta_t(i)$ متغییر پسرو نام دارد و به روشی مشابه روش الگوریتم پیشرو تعریف می‌شود:

$$\beta_T(i) = 1 \quad 1 \leq i \leq N$$

$$\beta_t(i) = \sum_{j=1}^N a_{ij} b_j(o_{t+1}) \beta_{t+1}(j) \quad t = T-1, T-2, \dots, 1$$

$$1 \leq i \leq N$$

$$P(O|\lambda) = \sum_{i=1}^N \pi_i \times b_i(o_1) \times \beta_1(i) \quad (10)$$

برای مشخص کردن دنباله حالات بهینه نیازمند تعریف متغییری به نام γ به ترتیب زیر هستیم:

$$\gamma_t(i) = P(q_t = i | O, \lambda) = \frac{P(O, q_t = i | \lambda)}{P(O | \lambda)} = \frac{P(O, q_t = i | \lambda)}{\sum_{i=1}^N P(O, q_t = i | \lambda)} \quad (11)$$

رابطه فوق را می‌توان بصورت زیر خلاصه کرد:

$$\gamma_t(i) = \frac{a_t(i) \beta_t(i)}{\sum_{i=1}^N a_t(i) \beta_t(i)} \quad (12)$$

و در نهایت الگوریتم بام-ولج به این صورت تعریف می‌شود:

$$\xi_t(i, j) = P(q_t = i, q_{t+1} = j | O, \lambda) = \frac{\alpha_t(i) a_{ij} b_j(o_{t+1}) \beta_{t+1}(j)}{P(O | \lambda)} \quad (13)$$

با استفاده از این معادله، پارامترهای $\lambda = (A, B, \pi)$ HMM را می‌توانیم به این صورت $\bar{\lambda} = (\bar{A}, \bar{B}, \bar{\pi})$ بهینه کنیم. که در نتیجه تخمین بهینه این سه ماتریس، از $\bar{\lambda}$ به این صورت خواهد بود:

$$\bar{\pi}_i = \gamma_1(i) \quad (14)$$

$$\bar{a}_{ij} = \frac{\sum_{t=1}^{T-1} \xi_t(i, j)}{\sum_{t=1}^{T-1} \gamma_t(i)} \quad (15)$$

$$\bar{b}_i(k) = \frac{\sum_{t=1}^T \gamma_t(i) \mathbb{1}_{o_t = v_k}}{\sum_{t=1}^T \gamma_t(i)} \quad (16)$$

الگوریتم بام-ولج همیشه به ماکزیمم سراسری نخواهد رسید، اما می‌تواند ماکزیمم محلی $P_r(O|\lambda)$ را پیدا کند.

3. تشخیص رفتار

در این بخش، به روش دسته‌بندی، رفتارهای مورد نظر، مجموعه داده‌های مورد استفاده و در نهایت ارائه نتایج خواهیم پرداخت. همان طور که پیش‌تر اشاره شد، در ابتدا سیاهه بدن استخراج می‌شود سپس در مراحل بعد با استفاده از روش‌هایی که توضیح داده شد به استخراج نقاط انتهایی بدن و ساخت بردار ویژگی مناسب می‌پردازیم پس از اینکه برای هر فریم ویدئویی، یک بردار ویژگی با توجه به توضیحات داده شده ساخته شد، با تبدیل بردار ویژگی به سمبل‌های گسسته، یک دنباله زمانی به دست می‌آوریم. همان طور که گفتیم HMM یک روش موثر برای تحلیل چنین دنباله‌هایی است. در این مقاله ما بیشتر تمرکز خود را بر روی رفتارهایی که در مراقبت از سالمندان کاربرد بیشتری دارند قرار داده‌ایم. به منظور تهیه مجموعه رفتارهای مراقبتی، اقدام به تهیه مجموعه داده‌های متناسب با کار خود کردیم (شکل 3) به این صورت که یک سری از اعمال مورد نظر را مانند: افتادن از تخت، افتادن از صندلی، غش کردن، نشستن و خم شدن که شامل 5 رفتار می‌شود را با چند فرد مختلف برای این منظور تهیه کردیم. این مجموعه شامل 5 عمل مختلف است و برای هر یک از این عمل‌ها 7 نمونه مختلف را بررسی کردیم که در مجموع 35 دنباله ویدئویی مختلف را شامل می‌شود. برای آموزش از روش Leave-one-out استفاده شده است. به این صورت که در هر بار انجام عملیات، یکی از نمونه‌های ویدئویی به عنوان تست و 7 تای باقیمانده برای آموزش استفاده شده است و هر بار این نمونه تست عوض شده و سایر نمونه‌ها برای آموزش انتخاب شده است.



شکل 3 - داده‌های آزمایشی برای رفتارهای مراقبتی

1.3. نتایج شبیه‌سازی برای تشخیص رفتارهای مراقبتی توسط HMM

ابتدا ویژگی مورد نظر ما در قالب یک بردار ویژگی برای هر یک از فریم‌های ویدئویی حاصل می‌شود. یعنی تعداد نقاط انتهایی شمرده شده و در بردار ویژگی ذخیره می‌شود. پس از این مرحله، بردار ویژگی ساخته شده به عنوان ورودی مرحله آموزش استفاده می‌شود و پارامترهای HMM آموزش داده می‌شوند. برای به‌دست آوردن پارامترهای HMM از روی بردار ویژگی، از الگوریتم baum-welch استفاده می‌شود. یعنی با توجه به تقسیم‌بندی انجام شده برای هر کلاس رفتاری، پارامترهای مربوط به همان کلاس حاصل می‌شود. پس از اینکه برای هر کلاس رفتاری و البته در هر مرحله از Leave-one-out، پارامترهای HMM به دست آمدند و آموزش داده شدند، نوبت به تست نمونه‌های رفتاری جدید می‌رسد. برای این منظور تابعی تنظیم

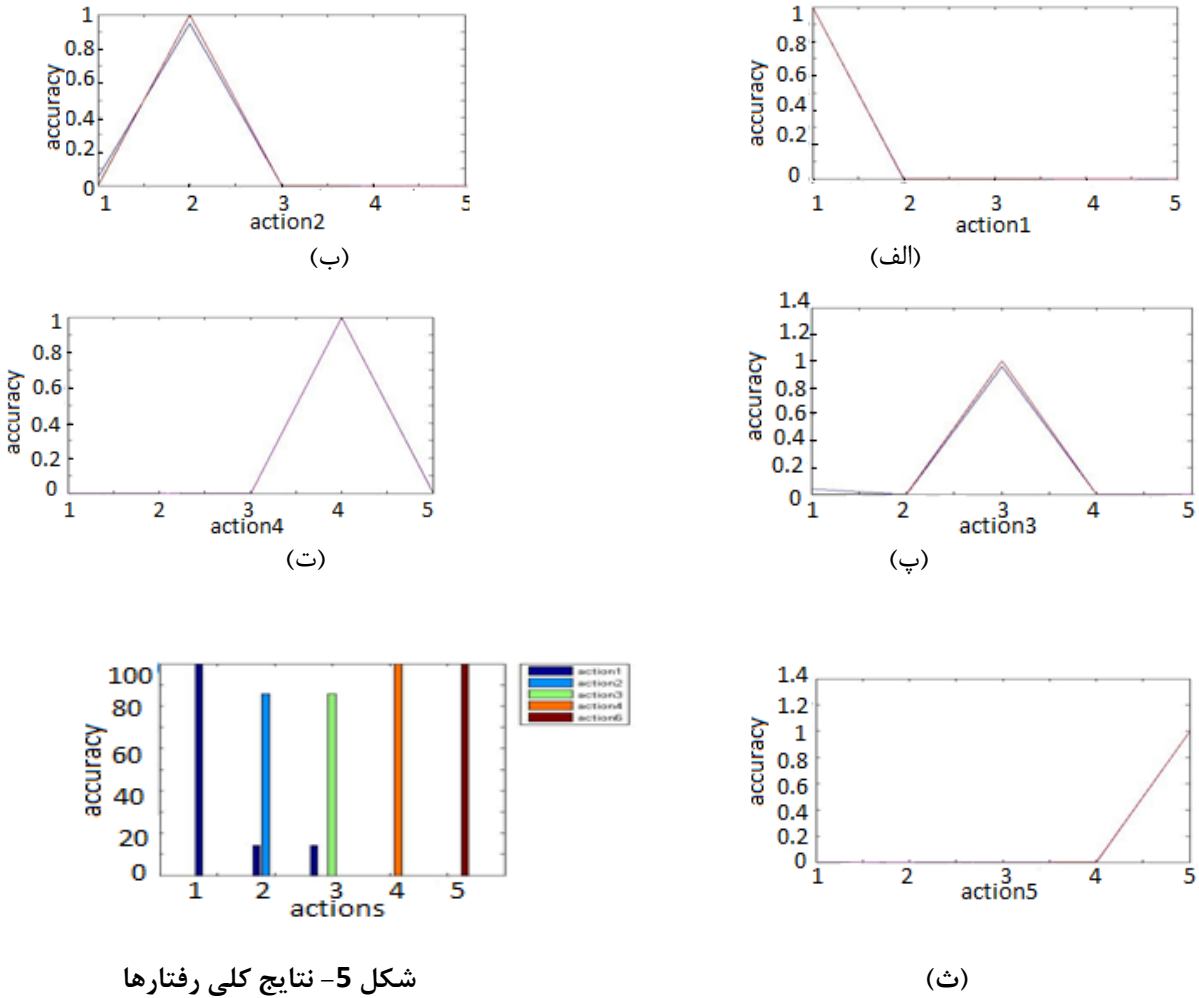
کردیم تا بر اساس پارامترهای بدست آمده برای HMM در مرحله آموزش، ویدئوهای جدیدی را به عنوان ورودی می‌گیرد و بر اساس ویژگی‌های به دست آمده از فریم‌های این ویدئو به مقایسه آن با تک تک HMM‌های مربوط به هر رفتار می‌پردازد و برای هر یک از آن‌ها احتمالی را به دست می‌آورد. کلاسی را که بیشترین احتمال تعلق را دارد، به عنوان کلاس این نمونه تست انتخاب می‌گردد و در قالب یک ماتریس با نمایش میزان درصد احتمال تعلق هر مشاهده به هر کلاس ارائه می‌شود. نتایج دسته‌بندی را در جدول (1) به صورت یک ماتریس سردرگمی ارائه کرده‌ایم.

جدول 4- جدول سردرگمی داده‌های آزمایشی

	1	2	3	4	5
1	100				
2	29/14	71/85			
3	29/14		71/85		
4				100	
5					100

در انتها سیستمی جهت هشدار در موقعیت‌های اضطراری طراحی کرده‌ایم به این صورت که دنباله مشاهدات ورودی اعمال شده توسط سیستم بررسی می‌شود در صورتی که ویژگی‌های این ورودی‌ها با درصد بالایی با ویژگی‌های استخراج شده از رفتارهای غیرعادی مثل: افتادن از تخت، افتادن از صندلی، غش کردن منطبق باشد آنگاه سیستم به بازبینی مجدد دنباله ورودی‌ها اقدام و در صورت تکرار انطباق این مشاهده به عنوان رفتار غیرعادی برچسب‌گذاری شده و سیستم هشدار فعال می‌شود نتایج نشان دهنده دقت 94 درصدی در تشخیص صحیح رفتار است که کارایی این روش در تشخیص رفتارهای فرد را به خوبی نشان می‌دهد. آزمایشات ما با استفاده از نرم افزار متلب 2013 و بر روی Core i5, X64, Windows7, 2.13 GB RAM, GHz پیاده‌سازی شده است.

برای نشان دادن کارایی کلی روش پیشنهادی به مقایسه آن با مقالات دیگر پرداختیم. مجموعه داده‌های مراقبتی کاملاً مشابه با مجموعه حالت‌های رفتاری تحت مقایسه است. به این منظور، [12] به دلیل شباهت روش دسته‌بندی استفاده شده، در این کار از دسته‌بند HMM در مراکز سالمندان برای نظارت بر حالت این افراد بر روی تخت و راهروها استفاده شده است. که دقت به دست آمده برای رفتارهای ناهنجار در این کار برابر 90 درصد می‌باشد. دسته بند چند کلاسه SVM که در [13] آمده است نیز برای تشخیص حرکات مراقبتی استفاده شده است که دقتی برابر 88/8 درصد را داراست. نتایج حاکی از کارایی بهتر روش پیشنهادی این مقاله با دقتی معادل 94 درصد نسبت به کارهای مشابه است.



شکل 5- نتایج کلی رفتارها

شکل 4- نمودار نتایج آزمایشات (الف) رفتار 1

(ب) رفتار 2 (پ) رفتار 3 (ت) رفتار 4 (ث) رفتار 5

4. نتیجه‌گیری

در این مقاله یک سیستم تشخیص رفتار مراقبتی ارائه شده است که با استفاده از آن می‌توان به کلاس‌بندی و تشخیص رفتارهای غیرعادی پرداخت. در این روش به کمک روش استخوان‌بندی ستاره‌ای، نقاط انتهایی بدن مشخص شده، سپس بردار ویژگی مناسب ساخته شده و در نهایت این بردارها به یک کلاس‌بند HMM داده شد تا از روی آنها و با توجه به داده‌های آموزشی در مورد هر یک از رفتارها تصمیم‌گیری و قضاوت شود. دقتی که ما با استفاده از این روش بدست آوردیم برابر 94 درصد در تشخیص صحیح رفتار است با توجه به نتایج حاصل از دقت طبقه‌بندی انجام شده بیانگر کیفیت نسبی این روش نسبت به کارهای مشابه است.

مراجع

1. Al Mansur, Yasushi Makihara and Yasushi Yagi, (2011), Action Recognition using Dynamics Features, International Conference on Robotics and Automation, IEEE, pp. 4020 - 4025.
2. Zia Moghaddam and Massimo Piccardi, Senior Member, Training Initialization of Hidden Markov Models in Human Action Recognition, (2014), IEEE Transactions on Automation Science and Engineering, Vol.11, pp. 394-508.
3. N.K. Suryadevara , S.C. Mukhopadhyay , R. Wang , R.K. Rayudu, (2013), Forecasting the behavior of an elderly using wireless sensors data in a smart home, Elsevier, vol. 26, pp. 2641–2652 .
4. N. Noury, T. Hadidi, (2012), Computer simulation of the activity of the elderly person living independently in a Health Smart Home, Elsevier, vol. 108, pp. 1216–1228.
5. Dongping.Zhang, Jiao.Xu, Yafei.Lu, Huailiang.Peng, (2013), Daynamic Model Behavior Analysis of Small Groups, Based on Article Video Wireless Communications & Signal Processing (WCSP), IEEE Conference, pp.1 – 6.
6. Zafar Ali Khan, Won Sohn, (2010), Feature Extraction and Dimensions Reduction using R transform and Principal Component Analysis for Abnormal Human Activity Recognition, IEEE Conference , pp. 253 - 258.
7. Shahrizat Shaik Mohamed, Nooritawati Md Tahir, Ramli Adnan, (2010), Background Modelling and Background Subtraction Performance for Object Detection, IEEE, pp.1-6.
8. Xin Yuan, Xubo Yang, (2009), A Robust Human Action Recognition System using Single Camera, IEEE Conference Publications, pp.1-4.
9. Chih-Chiang Chen, Jun-Wei Hsieh, Yung-Tai Hsu, Chuan-Yu Huang, (2006), Segmentation of Human Body Parts Using Deformable Triangulation, 18th International Conference on Pattern Recognition (ICPR'06), IEEE, Vol.1, PP. 355 - 358.
10. Junji YAMATO, Jun OHYA, Ke nic hiro ISHII, (1992), Recognizing Human Act ion in Time Sequent ial Images using Hidden Markov Model, IEEE.
11. Lawrence R. Rabiner, Fellow, (1998), A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition, Proceeding of the IEEE, Vol.77, pp. 257 - 286.
12. Pau-Choo Chung, Chin-De Liu, (2008), Adaily behavior enabled hidden Markov model for human behavior understanding, Elsevier, vol. 41, pp. 1572-1580.
13. Homa Foroughi, Mohamad Alishahi, Hamidreza Pourreza, Maryam Shahinfar, (2010), Distinguishing Fall Activities using Human Shape Characteristics, springer, pp. 23-528