



دانشگاه کاشان
University of Kashan

مجله محاسبات نرم

SOFT COMPUTING JOURNAL

تارنمای مجله: scj.kashanu.ac.ir



راهکارهای تشخیص عملکرد کاربران و ارائه روشی برای تعیین میزان خطر رفتار غیر معمول کاربران در

خانه‌ی هوشمند مبتنی بر منطق فازی

حانیه عباسی^۱، کارشناسی ارشد، محبوبه شمسی^{۱*}، استادیار، عبدالرضا رسولی کناری^۱، استادیار
^۱ دانشکده برق و کامپیوتر، گروه مهندسی کامپیوتر، دانشگاه صنعتی قم، قم، ایران.

چکیده

اطلاعات مقاله

تاریخچه مقاله:

دریافت ۰۳ شهریور ماه ۱۳۹۹

پذیرش ۰۷ خرداد ماه ۱۴۰۰

کلمات کلیدی:

خانه‌ی هوشمند

شناسایی فعالیت

افراد مسن

بیماری آلزایمر

منطق فازی

در سال‌های اخیر، جمعیت افراد بیمار و سالمند که تنها هستند و نیاز به مراقبت دارند، افزایش یافته‌است. همین مسئله احتیاج به داشتن خانه‌ی هوشمند برای باخبر بودن از شرایط بیمار را افزایش می‌دهد. شناسایی فعالیت بیمار با استفاده از حسگرهای تعبیه شده در محیط، اولین قدم برای رسیدن به خانه‌ی هوشمندی است که در آن اطرافیان بیمار می‌توانند با نگرانی کمتری، بیمار را در خانه تنها بگذارند. در این پژوهش، انواع روش‌های تشخیص عملکرد کاربران در خانه‌ی هوشمند ارائه می‌شود و پس از آن به روش جدیدی برای شناسایی میزان خطر که در آن از منطق فازی در مواردی مثل زمان شروع فعالیت استفاده شده، پرداخته می‌شود. سیستم استفاده شده برای تشخیص میزان خطر، در سه فاز از منطق فازی استفاده کرده است. در این روش به دلیل آنکه برای افراد با شرایط خاص پیاده‌سازی شده است، از حسگرهای پوششی استفاده نشد زیرا اگر از سنسورهای پوشیدنی برای بررسی بروز این مشکل استفاده شود، برای سالمند سختی به همراه دارد و حتی یک فرد آلزایمری ممکن است فراموش کند آن را پوشد که با توجه به این شرایط، پیاده‌سازی این لایه نیز نتایج خوبی - یعنی دقت ۸۴٪ - را بدست آورد.

© ۱۴۰۰ - مجله محاسبات نرم، کلیه حقوق محفوظ است.

۱. مقدمه

اولین علت وابستگی و نیازمندی در سالمندان تلقی می‌شود و افراد کافی برای مراقبت از این قشر پرجمعیت وجود ندارد. با توجه به افزایش تعداد سالمندان نسبت به کل افراد، بروز این بیماری بیشتر شده و مسئله‌ی مراقبت از آنها نیز، اهمیت بیشتری پیدا کرده است [۲، ۳].

طراحی یک خانه‌ی هوشمند می‌تواند در کمک‌رسانی به این افراد بسیار موثر باشد. خانه‌ی هوشمند رفتار کاربر را با استفاده از حسگرهای تعبیه شده در محیط، مورد بررسی قرار داده و نقش یک مراقب را ایفا می‌کند و تنها در صورت احساس بروز مشکل، آن را به یکی از وابستگان بیمار - برای بررسی بیشتر - اطلاع می‌دهد. یکی از مشکلاتی که می‌تواند برای یک سالمند

در سال‌های اخیر، جمعیت افراد سالمند روز به روز در حال افزایش است. طبق آمار سازمان بهداشت جهانی (WHO)، جمعیت افراد بالای ۶۵ سال بین سال‌های ۲۰۱۵ تا ۲۰۵۰ از ۹۰۰ میلیون به دو میلیارد خواهد رسید که این به معنای رسیدن به ۲۲ درصد سالمند در سال ۲۰۵۰ می‌باشد [۱]. زوال عقل،

* نوع مقاله: پژوهشی

نویسنده مسئول

پست(های) الکترونیک: h.abasi1372@gmail.com (عباسی)

shamsi@qut.ac.ir (شمسی)

rasouli@qut.ac.ir (رسولی کناری)

[۱۴]، از یک الگوریتم ترکیبی به نام AR-CBC^۱ استفاده شده است. در این روش، ابتدا با استفاده از الگوریتم PCA یک سری ویژگی‌ها انتخاب می‌شوند، بعد با استفاده از الگوریتم K-means روی داده‌ها خوشه‌بندی انجام می‌شود. در انتها برای ایجاد دقت بیشتر، در هر خوشه با استفاده از الگوریتم K-NN دسته‌بندی انجام می‌شود، این روش در تشخیص برخی فعالیت‌ها مثل خروج از خانه و شستن ظرف‌ها دقت بسیار پایینی داشته است و همچنین برای بررسی میزان خطر کاری انجام نداده است. در مقاله [۹]، بیان شده که به علت اینکه کاربران یک سلسله مراتبی از فعالیت‌ها را برای یک کار انجام می‌دهند خوشه‌بندی به تنهایی، برای مدل کردن رفتار کاربر مناسب نیست. در این مقاله از یک روش ترکیبی جدید برای خوشه‌بندی به نام K-pattern clustering استفاده کرده است؛ در این روش بعد از یک پیش پردازش روی داده‌های خام اولیه، داده‌ها به الگوریتم FP-Growth داده می‌شوند تا الگوهای مکرر در بین داده‌ها، شناسایی شوند. در مرحله‌ی بعد، الگوهای بدست آمده به یک الگوریتم خوشه‌بندی داده می‌شوند تا فعالیت‌ها را خوشه‌بندی کند و در مرحله نهایی، از الگوریتم شبکه عصبی برای پیش‌بینی رفتار بعدی کاربر استفاده می‌شود. طبق ادعای خود مقاله، مزیت این روش تشخیص فعالیت‌های همزمان و از هم گسسته می‌باشد و همچنین توانسته از فعالیت‌ها در بازه‌های زمانی مختلف تفسیرهای متفاوتی داشته باشد اما هیچ گزارشی از نتایج و دقت نهایی آزمایشات داده نشده است.

در مقاله [۱۵]، از الگوریتم SVM که برای دسته‌بندی داده‌ها کارایی دارد، استفاده شده است؛ به این صورت که ابتدا با استفاده از الگوریتم PCA، یک سری از ویژگی‌ها انتخاب شده و بعد از نرمال کردن داده‌ها الگوریتم مذکور روی داده‌ها اعمال می‌شود. یکی دیگر از روش‌های تشخیص فعالیت کاربر که در مقاله [۱۶] به آن اشاره شده، استفاده از منطق فازی می‌باشد. روش کار به این نحو است که هر کدام از فعالیت‌ها طبق بازه‌های زمانی مختلف موجود در شبانه روز، به زمانی

به وجود بیاید، سقوط وی است. پدیده‌ی افتادن، معمولاً با عوارض و ناتوانی‌های جسمی و حتی مرگ همراه است؛ به طوری که طبق گزارشی، مرگ در افراد بالای ۶۵ سال، از سال ۲۰۰۷ تا ۲۰۱۶ به میزان ۳۱ درصد افزایش یافته است [۴، ۵]. مشکل دیگر می‌تواند اختلالات بیمار و درست انجام ندادن کارهای معمول روزانه از قبیل رعایت نشدن زمان شروع فعالیت و انجام آن در یک بازه زمانی نامتعارف و یا طولانی شدن آن فعالیت باشد [۶، ۷].

همه این مسائل سبب افزایش اهمیت طراحی سیستمی جهت تعیین فعالیت غیرعادی کاربران از راه دور شده است. در این پژوهش ابتدا به روش‌های مختلف در رابطه با شناسایی فعالیت کاربران و تعیین میزان غیرعادی بودن فعالیت در مقالات مختلف پرداخته می‌شود و در بخش سوم مدل ارائه شده جهت تعیین میزان غیرعادی بودن فعالیت کاربران در خانه‌های هوشمند مورد بررسی قرار می‌گیرد و در بخش نهایی نیز نتایج و مقایسه این روش با روش‌های دیگر صورت می‌گیرد.

۲. کارهای مرتبط

تحقیقات زیادی پیرامون ابعاد مختلف خانه هوشمند از قبیل امنیت، مدیریت انرژی و شناسایی رفتار کاربران مطرح شده است [۸-۱۰]. در بخش شناسایی رفتار، برخی تحقیقات به شناسایی رفتار غیرمعمول کاربر با استفاده از تشخیص سقوط و برخی با استفاده از الگوریتم‌های مختلف داده‌کاوی و تحلیل فعالیت‌های قبلی کاربر پرداخته‌اند که برای گروه‌های مختلف افراد از قبیل بیماران آلزایمری، مبتلا به پارکینسون، افراد با بیماری‌های قلبی، کودکان، افراد با فلجی نسبی و ... کارآمد است [۱۱].

در شاخه‌ی تشخیص فعالیت کاربر نیز از الگوریتم‌های متفاوتی استفاده می‌شود؛ به عنوان مثال در مقاله [۱۲، ۱۳] از الگوریتم Flocking برای تشخیص رفتار کاربر استفاده کرده و بیان کرده که مزیت این الگوریتم نسبت به روش‌های دیگر عدم نیاز به تعیین تعداد خوشه‌ی اولیه است اما این سیستم کاری را در زمینه بررسی میزان خطر برای فرد مسن انجام نداده است. در مقاله

^۱ Activity recognition approach by clustering and classification

حاصله و فرمول‌های الگوریتم شبکه بیزین، احتمالات وقوع پیشامدهای مختلف محاسبه می‌شوند. عیب این روش امنیت پایین آن برای حفظ حریم خصوصی و از طرفی عدم ارائه راهکاری برای شناسایی میزان خطر می‌باشد.

در مقاله [۲۰] از حسگرهای باینری استفاده شده و دقت پیش‌بینی رویداد (فعالیت) بعدی با استفاده از روش‌های احتمالی و شبکه‌های LSTM مقایسه شده است که این روش دقت ۸۳٪ را به دست آورده است.

در مقاله [۲۱] نیز برای پیش‌بینی فعالیت یک یا دو کاربر حاضر در خانه از الگوریتم‌های یادگیری ماشین و حسگرهای آلتراسونیک استفاده شده است. سیستم پیشنهادی قادر به شناسایی فعالیت‌ها و ساکنان در خانه می‌باشد که البته دقت تشخیص در برخی از فعالیت‌ها که هر دو نفر در خانه بوده‌اند، کمتر است.

در مقاله [۲۲] برای پیش‌بینی فعالیت بعدی کاربر، فعالیت‌ها را در گره‌های مجزا قرار داده و با استفاده از تعریف قوانین فازی و ساختار FSM از هر کدام از گره‌ها به گره دیگر پرش می‌کند ولی در این مقاله نیز برای تعیین میزان خطر راهکاری پیشنهاد نشده است و دقت بین ۸۵ تا ۱۰۰ درصد برای فعالیت‌های مختلف وجود دارد.

در فاز بررسی رفتار غیرعادی باید به این نکته توجه کرد که آیا تشخیص رفتار غیرعادی با هدف تشخیص حملات سایبری به سیستم خانه هوشمند است و یا منظور فعالیت‌های غیرعادی‌ای است که توسط خود بیمار رخ می‌دهد. در رابطه با حالت اول مقالات مختلفی [۲۳-۲۵] پیشنهاد شده است که با استفاده از بررسی توالی رویدادهای مختلف انجام شده توسط کاربر، حملات را شناسایی می‌کنند. اما در این مقاله منظور از رفتار غیرعادی، حالت دوم است و غیرعادی بودن فعالیت خود بیمار مورد بررسی قرار می‌گیرد.

در واقع دو روش برای تشخیص غیرعادی بودن رفتار وجود دارد که در روش اول مدل‌سازی رفتار طبیعی انجام می‌شود و هر ورودی جدیدی که با این مدل مطابقت نداشته باشد، به عنوان ناهنجاری محسوب می‌شود؛ اما در روش دوم برای

اختصاص پیدا می‌کنند و با استفاده از قوانین تعریفی، نوع فعالیت پیش‌بینی می‌شود.

در مقاله [۶, ۷]، از یک روش سلسله مراتبی برای تشخیص فعالیت‌ها و میزان غیرعادی بودن آنها استفاده شده است. چارچوب سلسله مراتبی به این صورت طراحی شده که فاکتورهای با اولویت بالاتر در لایه‌های پایین تر هستند و هر لایه در صورتی قابل اجرا است که لایه‌ی پایین‌تر گزارش غیرعادی بودن آن فعالیت را ندهد. در هر لایه، برای خروجی گرفتن از آن، از یکی از الگوریتم‌های هوش مصنوعی به نام MLN^۱ استفاده کرده است؛ مزیت این الگوریتم آن است که در هر لایه، بر حسب ساختار تعریف شده برای آن، هم می‌توان از قوانین نرم (قوانینی که سیستم از روال موجود در داده‌ها به دست آورده است) و هم از قوانین سخت (قوانینی که توسط افراد خبره تعریف می‌شود) استفاده کرد ولی این روش توانایی شناسایی فعالیت‌های پیچیده را ندارد. در [۱۷] از روش HMM برای شناسایی فعالیت‌ها استفاده شده است. در روش سلسله مراتبی که در قبل بیان شد، به جای MLN از HMM در هر لایه استفاده کرده بود ولی استفاده از این روش را مناسب نمی‌دانست، چون در HMM از قوانین سخت استفاده نمی‌شود.

در مقاله [۱۸]، از ESN برای پیش‌بینی مقادیر فعالیت‌های یک فرد استفاده شده؛ مزیت این روش نسبت به روش‌های قبل در این است که داده‌های ورودی می‌توانند در هر زمانی به سیستم وارد شوند در حالی که در رویکردهای قبلی داده‌ها باید در یک زمان وارد سیستم می‌شدند. در مقاله [۱۹]، بررسی کرده که امکان دارد در یک خانه بیش از یک فرد زندگی کند و برای برطرف کردن این مشکلات از دوربین‌های فیلم‌برداری در سه بعد استفاده می‌کند و با پردازش این فیلم‌ها سرعت، نوع رفتار و سایر ویژگی‌های هر کاربر را به طور مجزا بدست می‌آورد. با استفاده از این ویژگی‌ها شبکه‌های بیزین مختلف که از این ویژگی‌ها حاصل می‌شوند، بدست می‌آیند و بهترین مدل با استفاده از الگوریتم‌هایی مثل الگوریتم تپه‌نوردی که در این مقاله از آن استفاده شده، استخراج می‌شود. حال با استفاده از مدل

^۱ Markov Logic Network

استفاده شده با معماری مذکور شامل متغیرهای مختلفی می‌شود. در مرحله اول، داده‌هایی که از حسگرهای مختلف تعبیه شده در خانه‌ی هوشمند ارسال می‌شوند، پیش‌پردازش شده و به شکل یکسان درمی‌آیند؛ این بدان جهت است که حسگرها از نوع‌های مختلف هستند و خود این یکسان‌سازی یک چالشی است که در این زمینه مطرح است.

جدول (۲): متغیرهای به کار رفته در پژوهش

نوع متغیر	بازه مقداری
زمان روشن شدن حسگر	ساعات شبانه روز
زمان خاموش شدن حسگر	ساعات شبانه روز
نوع حسگر	حسگرهای تعبیه شده
نوع فعالیت	خوابیدن، استراحت (کارهایی مثل تماشای تلویزیون)، آماده‌سازی غذا، شستن ظرف‌ها، تمیز کردن خانه، کار کردن (مطالعه و انجام کارهای شخصی در اتاقی یا میز مخصوص این کار) و ترک خانه

مرحله دوم، برای شناسایی نوع فعالیت است. در این مرحله، با استفاده از داده‌های بدست آمده از مرحله قبل، داده‌ها در ساختار الگوریتم مد نظر قرار داده شده و نوع فعالیت تشخیص داده می‌شود که هرچه دقت بیشتر باشد، این معنا را می‌دهد که الگوریتم عملکرد بهتری داشته است.

مرحله سوم به تشخیص میزان غیرطبیعی بودن یک عمل می‌پردازد که برای بررسی این موضوع معیارها و ویژگی‌های مختلفی از قبیل زمان شروع و طول زمان فعالیت مورد بررسی قرار می‌گیرند.

در بخش قبل روش‌هایی که در مقالات مختلف برای شناسایی نوع فعالیت کاربر (مرحله دوم) پیشنهاد شده بودند با دید کلی روی هر روش و به اختصار بیان شد. تشخیص حالت غیرعادی در خانه هوشمند، به دلیل اینکه فردی که قرار است هشدار را دریافت کند در خارج از منزل و یا یک مکان دور است، باید با دقت بسیار بالایی صورت بگیرد و اگر این‌گونه نشود در عمل سیستم نتوانسته به هدفش برسد؛ به همین جهت باید تمام تلاش‌ها در جهت رساندن دقت به صد درصد باشد. جدول (۳) الگوریتم‌های استفاده شده در مقالات مختلف برای تشخیص

ناهنجاری‌ها با استفاده از پیشینه داده‌ها الگویی را پیدا کرده و با ورود داده‌های جدید، در صورتی که با این الگو مطابقت داشته باشند به عنوان ناهنجاری شناسایی می‌شوند. استراتژی اول کارآمدتر و واقعی‌تر به نظر می‌رسد، چون داده‌های ناهنجاری به ندرت در زندگی واقعی دیده می‌شود (جدول ۱) [۱۰، ۲۶]. Forkan و همکاران به دو عیب سیستم تشخیص ناهنجاری در روش دوم اشاره کرده‌اند؛ که مورد اول عدم توانایی پیش‌بینی ناهنجاری‌های پیش‌رو می‌باشد و دوم اینکه استفاده از یک زمینه برای تصمیم‌گیری باعث ایجاد هشدارهای غلط بیشتر شده است [۲۷].


در ادامه، به روش جدیدی برای شناسایی و تعیین میزان خطری که در وقوع هر فعالیت به وجود می‌آید، پرداخته می‌شود. در این روش یکی از موارد مهم در بیماران آلزایمری یعنی «زمان شروع هر فعالیت» نیز مورد بررسی قرار می‌گیرد که از آن می‌توان به غیرعادی بودن رفتار بیمار پی برد.

جدول (۱): روش‌های مختلف تشخیص غیرعادی بودن رفتار

الگوریتم / منبع	مزایا	معایب
طبقه‌بندی (نظارت) [۲۸]	اندازه‌گیری دقت مدل با استفاده از ماتریس سردرگمی	۱. نیاز به داده برای فاز آموزش ۲. برچسب‌گذاری دستی توسط انسان
خوشه‌بندی و مبتنی بر آمار (بدون نظارت) [۲۹، ۳۰]	عدم نیاز به داده نمونه	۱. عملکرد و کارایی وابسته به نوع توزیع داده ۲. بهینه نشده برای تشخیص ناهنجاری

۳. کلیات مسئله

سیستم‌هایی که برای شناسایی فعالیت بیماران و به دنبال آن تشخیص حالت غیرعادی آنها، تعریف می‌شوند دارای معماری پایه‌ای مطابق شکل (۱) هستند.



شکل (۱): معماری کلی فرآیند تشخیص فعالیت کاربران در خانه‌ی هوشمند

همانطور که در جدول (۲) نشان داده شده است خانه هوشمند

دسته‌بندی نشود. برای بهره‌گیری از این ویژگی، در این مرحله از منطق فازی استفاده شد. سه ویژگی زمان شروع فعالیت، مدت زمان روشن بودن حسگر و مدت زمان خاموش بودن حسگر مواردی هستند که در تعیین میزان خطر ناشی از فعالیت یک کاربر ساکن در خانه، موثر هستند که در ادامه نحوه به‌کارگیری هر کدام از آنها به تفصیل بیان می‌شوند.

۴.۱. زمان شروع فعالیت

یکی از عوامل مهم و تاثیرگذار در تشخیص میزان غیرطبیعی بودن یک فعالیت، زمان شروع آن فعالیت می‌باشد که با استفاده از منطق فازی مورد بررسی قرار گرفته است.

ناهنجاری در یک خانه هوشمند را به همراه مزایا و معایب هر کدام نشان داده که ما سعی کردیم در روش پیشنهادی این پژوهش این معایب را نیز برطرف کنیم.

در بخش بعد با استفاده از قوانین پزشکی حاکم بر بیماران آزایمیری که با استناد به قوانین کلی موجود در مقالات مختلف درباره این بیماران وجود دارد و همچنین منطق فازی سعی شده است راهکاری ارائه شود که بتواند در راستای رسیدن به اهداف مرحله سوم که بیان شد، گام موثری بردارد.

۴. روش پیاده سازی

یکی از مهم‌ترین مراحل در تشخیص حالت غیرعادی کاربران در خانه‌های هوشمند، تعیین میزان خطر هر فعالیت می‌باشد که باعث می‌شود هر فعالیتی به صورت مطلق، عادی یا غیرعادی

جدول (۳): مقایسه توابع مختلف در تعیین ناهنجاری یک فعالیت

معایب	مزایا	الگوریتم / منبع
۱. در نظر گرفتن اطلاعات غیرمرتبط	۱. توانایی شناسایی فرکانس فعالیت	هیستوگرام [۳۱]
۲. عدم توانایی در ثبت ساختار وابستگی داده‌ها	۲. توانایی شناسایی فرکانس مکانی که فعالیت در آن به وقوع پیوسته است	
۳. عدم در نظر گرفتن وابستگی بین دو داده		
۱. عدم توانایی افزودن قوانین جدید توسط کاربر و ترکیب آن با قوانین افزوده شده از طریق لایه پنهان	۱. توانایی افزودن قوانین جدید با انطباق لایه پنهان برای نگهداری قوانین جدید	شبکه عصبی مصنوعی [۳۲]
۲. معماری پیچیده شبکه		
۳. عدم توانایی انسان در درک و خواندن قوانین در ساختار پیچیده نرون‌ها		
	۱. توانایی در نظر گرفتن ارتباط دو ویژگی در طبقه‌بندی فعالیت‌ها (مدل‌سازی)	GMM [۲۶]
۱. عدم در نظر گرفتن داده‌های نویز	۱. توانایی کاهش نرخ ناهنجاری‌های غلط	قوانین معنایی [۳۳]
	۲. قوانین منطقی و قابل خواندن برای انسان	
	۱. توانایی در ثبت ساختار وابستگی داده‌ها	منطق فازی
	۲. آسان بودن تعریف قوانین جدید	
	۳. توانایی انسان در درک قوانین	
	۴. تعیین درصد خطر ناشی از انجام هر فعالیت	
۱. مدیریت داده‌های باینری	۱. آسان بودن محاسبه تفاوت‌ها در فرمول‌های توابع	توابع اندازه‌گیری تشابه دودویی [۳۴, ۳۵]
۲. مناسب بودن در تجزیه و تحلیل داده‌های باینری سطح پایین و نه داده‌های حسی سطح بالا		
۳. عدم توانایی در تعیین جزئیات یک ناهنجاری از قبیل زمان و مکان وقوع ناهنجاری		

(۴) شب (night)، در این زمان تا پایان شب، امکان افسردگی وجود دارد اما این میزان افسردگی و بهم‌ریختگی پایین‌تر از زمان غروب می‌باشد و تاثیر کمتری دارد اما باز هم حائز اهمیت است و (۵) قبل خواب (before sleep)، این زمان که حدود ۲۲ تا ۲۴ شب است. ورودی بعدی نوع فعالیت است که در حال انجام است؛ از آنجایی که طبق تحقیقات صورت گرفته روی این گروه بیماران، تذکر بی‌رویه به بیماران آلزایمری باعث تشدید بیماری آنها می‌شود [۳۸]، برای جلوگیری از این موضوع، تنها یک سری از فعالیت‌ها که اگر در خارج از ساعت طبیعی انجام شوند، مخاطره ایجاد می‌کنند مورد بررسی قرار گرفته است؛ این فعالیت‌ها شامل فعالیت خوابیدن، استراحت (کارهایی مثل تماشای تلویزیون)، تهیه غذا، شستن ظرف‌ها، تمیزکردن خانه و ترک خانه می‌شود.

بعد از تعریف ورودی‌های فازی، قوانینی بر اساس همین ورودی‌ها و با در نظر گرفتن عادت‌های روزمره بیمار آلزایمری تعریف می‌شوند که برای مثال اگر بیمار در ساعت ۲ بامداد مشغول شستن ظرف‌ها و یا تهیه غذا شود، این امر غیرطبیعی است و با دادن هشدار زیاد به مراقب بیمار، او را مطلع می‌سازد که احتمالاً بیمار در شرایط مناسب روانی به سر نمی‌برد و وضعیت او را مورد بررسی قرار دهد. نموداری از قوانین تعریف شده در شکل (۴) قابل مشاهده است. باید به این نکته توجه کرد که نامعمول بودن رفتار برای هر شخص جدا تعریف می‌شود؛ مثلاً رفتاری مثل آشپزی در نیمه‌شب غیرمعمول به نظر می‌رسد ولی اگر فرد بیمار از جوانی عادت به آشپزی در نیمه‌شب داشته باشد، انجام آن در دوره بیماری‌اش نامعمول نیست، چون در این بیماری حافظه بلند مدت فرد قوی‌تر عمل می‌کند و بیمار خاطرات دور را به خوبی به یاد می‌آورد. برای تعریف قوانین، طبق رفتار معمول اغلب افراد جامعه در نظر می‌گیریم (که این نیز با بررسی رفتار چند سالمند بدست آمد) و فرض می‌کنیم این شخص شب‌ها فقط می‌خوابد و به دستشویی می‌رود و در نتیجه کارهای مثل تمیز کردن خانه، تلویزیون تماشا کردن و ... برای این فرد نامعمول است یا اینکه در زمان قبل از خواب شروع به درست کردن غذا نمی‌کند.


همانطور که در شکل (۲) مشاهده می‌شود، این سیستم برای بررسی میزان غیرعادی بودن فعالیت شناسایی شده، زمان شروع فعالیت و نوع فعالیت شناسایی شده را به منطق فازی می‌دهد و میزان غیرعادی بودن فعالیت را با سه میزان هشدار بی‌خطر، متوسط و زیاد مشخص می‌کند؛ در صورتی که این هشدار با درجه‌ی زیاد باشد نتیجه به خروجی فرستاده می‌شود و به لایه‌های بعدی نمی‌رود ولی اگر هشدار متوسط باشد، میزان هشدار برای بررسی‌های بعدی به لایه‌ی بعد فرستاده می‌شود.



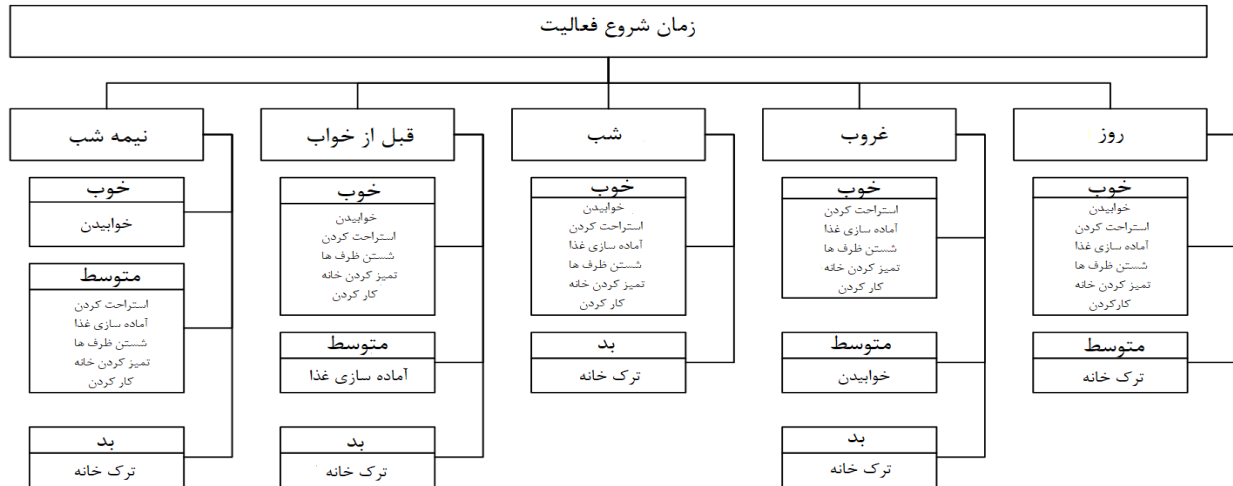
شکل (۲): ورودی‌های منطق فازی برای زمان شروع فعالیت

در فاز بررسی زمان شروع فعالیت باید به این نکته توجه داشت که بیماران آلزایمری به طور معمول در زمان غروب دچار افسردگی می‌شوند و این حالت در بعضی مواقع تا انتهای شب ادامه دارد و به این حالت سندروم غروب می‌گویند [۳۶, ۳۷]. بنابراین این بازه زمانی هم باید در تقسیم‌بندی شبانه روز در نظر گرفته شود و رفتارهای بیمار در این زمان‌ها با دقت بیشتری مورد بررسی قرار گیرد؛ برای مثال اگر بیرون رفتن از خانه در ساعات قبل از ظهر فعالیتی نرمال باشد ولی اگر در شب یا غروب صورت گیرد غیرنرمال است و باید توسط شخصی که مراقب فرد است (که ممکن است در جایی دورتر باشد) مورد بررسی قرار گیرد، البته این غیرنرمال بودن نسبی است و برای فردی که بیرون رفتن در روز جز عادت وی نبوده است، ممکن است غیرنرمال باشد.

بعد از لحاظ کردن این موارد، شبانه روز به ۵ قسمت تقسیم می‌شود که این تقسیم‌بندی در شکل (۳) مشاهده می‌شود: (۱) نیمه‌شب (midnight)، که ساعت ۱۲ تا حدود ۶ صبح است، (۲) روز (day)، که شامل صبح تا بعد از ظهر می‌شود، (۳) غروب (sunset)، این زمان غروب است که بیمار به دلایل مختلف از قبیل افسردگی بهم می‌ریزد و باید مراقب کارهای او بود که این زمان از جمله زمان‌های تاثیرگذار به حساب می‌آید،




شکل (۳): تقسیم‌بندی شبانه روز به ۵ دسته



شکل (۴): قوانین تعریف شده برای زمان شروع فعالیت (منظور از فعالیت کار کردن، مطالعه و انجام کارهای شخصی در اتاقی یا میز مخصوص این کار می باشد)

خاموش نشود که این غیرطبیعی نیست، پس با توجه به این نکات، لایه سوم با دریافت سه ورودی میزان غیرمعمول بودن فعالیت را بررسی می‌کند. همانطور که در شکل (۵) مشاهده می‌شود، این سه ورودی عبارتند از (۱) مدت زمان روشن بودن حسگر، (۲) نوع حسگر و (۳) نوع فعالیت که به منطق فازی داده می‌شوند و با استفاده از قوانین تعریف شده، میزان غیرعادی بودن را در خروجی می‌دهد.



شکل (۵): ورودی‌های منطق فازی برای مدت زمان روشن بودن حسگر

یک سری از فعالیت‌ها مثل تمیز کردن خانه از فعالیت‌هایی هستند که چون فرد در حال تحرک است حسگر آن مکان تا

البته این مبحث جز یکی از مواردی است که باید برای بررسی میزان خطری که در هر لحظه یک بیمار را تهدید می‌کند، می‌باشد و موارد دیگری همچون مدت زمانی که فعالیت طول می‌کشد نیز در تعیین میزان خطر کلی موثر هستند.


۴.۲. مدت زمان روشن بودن حسگر

مدت زمان روشن بودن هر حسگر، یکی دیگر از فاکتورهای موثر در تعیین میزان غیرمعمول بودن یک فعالیت است؛ زیاد روشن بودن یک حسگر بیانگر این است که ممکن است حال بیمار بد شده باشد و او در تلاش برای اطلاع دادن به دیگران و نجات خود باشد و به همین دلیل یک حسگر بیش از حد معمول روشن مانده است. البته نوع فعالیتی هم که در حال انجام است نیز مهم است؛ مثلاً ممکن است بیمار در حال تمیز کردن قسمتی از منزل باشد و تا حدود نیم ساعت هم حسگر آن مکان

بسیار خطرناک است و مشکلاتی را برای آنها به همراه دارد. از طرفی اگر از سنسورهای پوشیدنی برای بررسی بروز این مشکل استفاده شود، برای سالمند سختی به همراه دارد و برای یک فرد آزریمری ممکن است بعد از حمام رفتن و یا تعویض لباس فراموش کند آن را بپوشد.

این لایه، مدت زمانی که یک حسگر خاموش می‌شود و اولین حسگری که بعد از آن روشن می‌شود را بررسی می‌کند و عادی بودن یا غیرعادی بودن آن را در صورتی که علامتی از وجود کاربر در قسمت‌های دیگر یافت نشود و کاربر در یک جا بیش از زمان مشخص شده‌ای و به حالت ساکن باشد، خطرناک است و امکان سقوط و یا بد شدن حال بیمار وجود دارد. این زمان بر اساس نوع حسگر متفاوت است؛ مثلاً اگر حسگر تخت‌خواب تا چند ساعت هم خاموش شود امری طبیعی است چون ممکن است فرد به خواب رفته باشد ولی اگر حسگری که در جلوی دستشویی است، ۳۰ دقیقه خاموش شود احتمال خطر دارد چون احتمالاً حال بیمار بد شده است و در نتیجه مدت زمان نامتعارفی را در دستشویی مانده است.

با توجه به نکات گفته شده، همانطور که در شکل (۶) مشاهده می‌شود منطق فازی این لایه، دارای دو ورودی مدت زمان خاموش بودن حسگر و نوع حسگر می‌باشد که نوع حسگرها همانطور که در بخش قبل بیان شد، به ۶ گروه تقسیم می‌شود و مدت زمان خاموش بودن هم به همان چهار دسته تقسیم می‌شود که البته بازه‌ها در این حالت طولانی‌تر هستند.



شکل (۶): ورودی‌های منطق فازی در مدت زمان خاموش بودن حسگر

قوانین لایه‌ی چهارم به این گونه‌اند که مثلاً اگر نوع حسگر «توالی» باشد و بیش از زمان حدود ۴۰ دقیقه که بیمار وارد دستشویی شده، هیچ حسگری روشن نشود و هیچ اطلاعی از بیمار نباشد، احتمالاً بیمار در دستشویی حالش بد شده و یا اتفاق بدی مثل افتادن برایش رخ داده است؛ برای مثال در قانون شماره ۲ بیان می‌شود که اگر مدت زمان خاموش بودن حسگر

حتی نیم ساعت هم خاموش نمی‌شود و این طبیعی است. بنابراین سه فعالیت شستن ظرف‌ها، آماده‌سازی غذا و تمیز کردن منزل که شامل این مطلب می‌شوند، در نظر گرفته می‌شوند.

مدت زمان روشن بودن، در حسگرهای مختلف معنای جداگانه‌ای دارد، مثلاً اگر فرد روی مبل نشسته و احتمالاً در حال تماشای تلویزیون است، طبیعی است که حسگر آن مکان خاموش نشود چون فرد بیدار است و دائم در حال حرکت است یا اینکه حسگرهایی که قابلیت پوشش دادن فضایی را دارند ممکن است بیمار به هر قسمتی از آن فضا (که این حسگر در آن فضا است) برود، روشن بمانند و مدت زمان زیادتری روشن باشند یا حسگرهای درها که باز و بسته شدن در را مشخص می‌کنند، می‌توانند تا ۲۰ دقیقه هم روشن باشند. همه این‌ها سبب شد که ما حسگرها را به ۶ گروه تقسیم کنیم. این تقسیم‌بندی همه‌جانبه است؛ در نتیجه در آن مدت زمان خاموش بودن که در لایه‌ی بعد قرار دارد، نیز لحاظ شده است، برای مثال اگر فرد به دستشویی یا حمام برود و مطابق ساختار خانه هوشمند موجود، حسگری داخل دستشویی یا حمام نباشد، طبیعی است که تا ۲۰ دقیقه هم هیچ حرکتی از وی گزارش نشود. بر این اساس، تقسیم‌بندی حسگرها به شش نوع زیر بیان شده است: (۱) حسگرهای خواب، که در آن مکان‌ها بیمار می‌خوابد و در نتیجه خاموش ماندن آنها تا زمان طولانی هم طبیعی است، (۲) حسگرهای استراحت، که حسگرهایی را شامل می‌شود که یا میزان پوشش‌دهی بالایی دارند و احتمالاً زمان زیادی روشن می‌مانند (ولی نه در حد حسگرهای خواب)، (۳) حسگرهای نقطه کور، که در جایی قرار دارند که تا فاصله‌ای توسط هیچ حسگر دیگر پوشش‌دهی نمی‌شود، (۴) حسگرهای در، که باز و بسته شدن درها را نشان می‌دهند، (۵) حسگرهای سرویس بهداشتی، که جلوی درب‌های توالت و حمام قرار دارند و (۶) بقیه حسگرها، که شامل حسگرهایی می‌شود که در هیچ کدام از گروه‌های بالا قرار نمی‌گیرند.

۴.۳. مدت زمان خاموش بودن حسگر

همانطور که پیش از این نیز بیان شده بود، سقوط در سالمندان

محاسبه و با نتایج حاصل از سیستم مقایسه شد. بعد از بدست آوردن نتایج فرم، مشاهده شد که پزشک با دقت حدودی ۸۸٪ و مراقب با دقت ۸۲٪ تشخیص داده‌اند که از این دو، دقت کلی ۸۴٪ بدست آمد؛ البته این صرفاً برای امتحان سیستم بوده است که نشان دهد قوانین تعریف شده بر اساس نیاز و روال زندگی عموم سالمندان و بیماران آلزایمری تهیه شده است و برای شخص خاصی نیست که با این حال دقت خوبی را فراهم کرده و پیش‌بینی می‌شود اگر عادات‌های خاص بیمار که از مراقب وی بدست آمده، در آن گنجانده شود، دقت بالاتر از این می‌رود.

جدول (۴) مقالات مختلف با هدف تشخیص ناهنجاری در یک خانه هوشمند را بر اساس ویژگی‌های مختلفی مورد بررسی قرار داده است که البته یکی از مزایای روش پیشنهادی این مقاله تعیین میزان (درصد) خطری است که ممکن است سلامت بیمار را تهدید کند و این به نوبه خود یک قدم در جلوگیری از وقوع پیوستن هشدارهای غلط می‌باشد، چون به صورت مطلق یک فعالیت عادی یا غیرعادی تلقی نمی‌شود و براساس نوع فعالیت و قانون انتخاب شده، میزان خطر و در نتیجه میزان غیرعادی بودن آن فعالیت تعیین شده و هشدارها به سه دسته تقسیم‌بندی می‌شوند تا بهبود فرد بیرون از خانه، دچار نگرانی و هشدارهای اشتباه نشود.

جدول (۱): بررسی مقالات تشخیص ناهنجاری بر اساس ویژگی‌های مختلف

منطق فازی	قوانین معنایی	شبکه عصبی مصنوعی [۳۲]	منطق فازی [۳۳]
✓	✓		توانایی انسان در درک قوانین
✓		✓	تعیین درصد خطر ناشی از انجام هر فعالیت
✓	✓	✓	آسان بودن تعریف قوانین جدید
✓	✓	✓	توانایی در نظر گرفتن وابستگی داده‌ها

۶. نتیجه‌گیری

در این پژوهش ابتدا مروری بر کارهای انجام شده در تشخیص عملکرد کاربر در خانه هوشمند که شامل دو زیرمجموعه تشخیص سقوط و شناسایی فعالیت می‌شود، صورت گرفت. در

متوسط (حدود ۶ تا ۴۰ دقیقه) باشد و نوع حسگر، حسگر خواب باشد این فعالیت طبیعی است چون ممکن است فرد روی تختش به خواب رفته باشد یا در مورد قانون ۱۵ بیان می‌شود که اگر مدت زمان خیلی طولانی و بیش از ۲ ساعت باشد، در مورد هر نوع حسگری به جز حسگر خواب، این غیرطبیعی است و هرچه این زمان از دو ساعت بیشتر فاصله می‌گیرد بر میزان خطر افزوده می‌شود چون طبق رفتار فرد مورد بررسی و تحقیقاتی که پیرامون چند فرد مسن حاصل شده است، نشستن بیش از دو ساعت در حمام یا دستشویی و همچنین برای استراحت و تماشای تلویزیون و برای عبور از نقاط کور، غیرطبیعی به حساب می‌آید، ولی همانطور که در قانون ۱۴ نیز بیان شده است این زمان برای حسگرهای خواب، خطر کمتری دارد و شاید بسته به زمان شروع، خطر کمی داشته باشد و در حقیقت نیازمند بررسی بیشتر و جویا شدن حال بیمار می‌باشد.

۵. نتایج و بحث

برای ملاحظه اینکه آیا منطق فازی ما به درستی عمل می‌کند، دیتاستی که شامل بررسی میزان غیرعادی بودن فعالیت باشد، یافت نشد؛ به همین جهت تعدادی از تراکنش‌های دیتاست aruba از مجموعه دیتاست‌های CASAS [۳۹] که تعداد آن ۴۸ تراکنش بود، را به صورت تصادفی انتخاب کردیم و بعد از بدست آوردن نتیجه سیستم، طبق فرمی که توسط یک پزشک و یک فرد مطلع از رفتار افراد مسن و آلزایمری پر شده بود مقایسه‌ای بین نتایج صورت گرفت که در ادامه یک نمونه از مراحل روش کار به عنوان مثال آورده شده است.

برای بررسی اینکه «اگر بیمار در ساعت ۱۰ صبح مشغول شستن ظرفها شود.» در مرحله ی اول بعد از آنکه نوع فعالیت با استفاده از یکی از الگوریتم‌های بخش تعیین نوع فعالیت، شستن ظرف تشخیص داده شد، این فعالیت به همراه ساعت شروع آن به مرحله دوم فرستاده می‌شود و در آنجا با توجه به قوانین تعریف شده برای هر فرد میزان غیرطبیعی بودن آن فعالیت در سه مرحله مشخص می‌شود. این سناریوها به همین صورت به دو فرد متخصص داده شد و میانگین نظرات آنها درباره هر سناریو

نتایج خوبی - یعنی دقت ۸۴٪ - را ایجاد می‌کند. به عنوان کارهای آتی، استفاده از روشی جهت تکمیل تر کردن این سیستم و تشخیص حضور چند کاربر در خانه و پیاده‌سازی سیستم برای بیماران قلبی، کودکان و ... پیشنهاد می‌شود؛ همچنین پیاده‌سازی سخت‌افزاری این مدل نیز می‌تواند کمک زیادی به دقت بیشتر آن نماید.

سپاسگزاری

این پژوهش حاصل پایان‌نامه کارشناسی ارشد بوده و نویسندگان آن از تمامی کسانی که در انجام این پژوهش آنها را یاری نمودند مخصوصاً دکتر محمدرضا زارعی جراح طب اورژانس، عضو مرکز تحقیقات ترومای بیمارستان سینا و مشاور آماری دانشگاه تهران تشکر و قدردانی می‌نمایند.

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

ادامه نیز به برای تعیین میزان خطر فعالیت بیمار از منطق فازی استفاده شد تا بتوان عادات هر بیمار را متناسب با شرایط خاص وی به صورت قوانین بدست آورد و در تعیین میزان غیرطبیعی بودن فعالیت‌ها از این قوانین استفاده کرد. برای رسیدن به هدف تعریف شده، از سه گزینه استفاده شد و با توجه به آنها میزان غیرطبیعی بودن گزارش گردید. این گزینه‌ها شامل (۱) زمان شروع فعالیت، (۲) مدت زمان روشن بودن حسگر و (۳) مدت زمان خاموش بودن حسگر و در حقیقت بی‌حرکت بودن بیمار هستند. نکته قابل توجه دیگر این است که در روش پیشنهادی به دلیل پیاده‌سازی روش برای افراد با شرایط خاص، از حسگرهای پوششی استفاده نشده است، زیرا در صورت بهره‌گیری از چنین سنسورهایی برای بررسی بروز مشکلات، برای سالمند سختی به همراه دارد و به خصوص برای یک فرد آلزایمری ممکن است بعد از شرایط خاصی همانند حمام رفتن و یا تعویض لباس با فراموشی پوشیدن سنسورها همراه باشد. به هر حال با توجه به این شرایط ذکر شده، پیاده‌سازی این لایه نیز

مراجع

- [1] World Health Organization. 10 facts on ageing and health. 2017; Available from: <http://www.who.int/features/factfiles/ageing/en/>.
- [2] Alzheimer's Association Report, Alzheimer's disease facts and figures, Alzheimer's & dementia, 9(2):208-245, 2013.
- [3] World Health Organization, 10 facts on ageing and the life course. 2015; Available from: http://www.who.int/features/factfiles/ageing/ageing_facts/en/index.html.
- [4] Allen K., Deaths From Falls by Older Adults Sharply Increase. 2018; Available from: <https://www.aarp.org/health/conditions-treatments/info-2018/falling-deaths-surge-for-elderly.html>.
- [5] Shakeri S., "A Smartphone-based Fall Detection System using Accelerometer and Microphone", Iranian Journal of Biomedical Engineering, 9(4):399-410, 2016.
- [6] Gayathri K., Elias S., and Ravindran B., "Hierarchical activity recognition for dementia care using Markov Logic Network", Personal and Ubiquitous Computing, 19(2):271-285, 2015.
- [7] Gayathri K. and Easwarakumar K., "Intelligent decision support system for dementia care through smart home", Procedia Computer Science, 93:947-955, 2016.
- [8] Hossain M.M., Fotouhi M., and Hasan R., "Towards an Analysis of Security Issues, Challenges, and Open Problems in the Internet of Things", in 2015 IEEE World Congress on Services. 2015. New York, NY, USA: IEEE.
- [9] Sukanya P. and Gayathri K. S., "An Unsupervised Pattern Clustering Approach for Identifying Abnormal User Behaviors in Smart Homes", IJCSN, 2(3), 2013.
- [10] Bakar U.A.B.U.A., Ghayvat H., Hasanm S.F., and Mukhopadhyay S.C., "Activity and anomaly detection in smart home: A survey", in Next Generation Sensors and Systems, Springer. pp. 191-220, 2016.
- [11] Damaševičius R., Vasiljevas M., Šalkevičius J., and Woźniak M., "Human activity recognition in AAL environments using random projections",

- Computational and mathematical methods in medicine, 2016.
- [12] Lapalu J., Bouchard K., Bouzouane A., Bouchard B., and Giroux S., "Unsupervised Mining of Activities for Smart Home Prediction", *Procedia Computer Science*, 19:503-510, 2013.
- [13] Bouchard K., "Unsupervised spatial data mining for human activity recognition based on objects movement and emergent behaviors", Université du Québec à Chicoutimi, 2014.
- [14] Fahad L.G., Tahir S.F., and Rajarajan M., "Activity Recognition in Smart Homes Using Clustering Based Classification", 22nd International Conference on Pattern Recognition. 2014.
- [15] Fleury A., Vacher M., and Noury N., "SVM-based multimodal classification of activities of daily living in health smart homes: sensors, algorithms, and first experimental results", *IEEE transactions on information technology in biomedicine*, 14(2):274-283, 2010.
- [16] Medjahed H., Istrate D., Boudy J., and Dorizzi B., "Human activities of daily living recognition using fuzzy logic for elderly home monitoring", in *Fuzzy Systems, FUZZ-IEEE 2009. IEEE International Conference on. IEEE*, 2009.
- [17] Kim E., Helal S., and Cook D., "Human activity recognition and pattern discovery", *IEEE Pervasive Comput*, 9(1): 48-53, 2010.
- [18] Lotfi A., Langensiepen C.S., Mahmoud S.M., and Akhlaghinia M.J., "Smart homes for the elderly dementia sufferers: identification and prediction of abnormal behaviour", *J. Ambient Intell. Humaniz. Comput*. 3(3): 205-218, 2012.
- [19] Hsueh Y.L., Lin N.H., Chang C.C., Chen O. T.-C., and Lie W.N., "Abnormal event detection using Bayesian networks at a smart home", in *Ubi-Media Computing (UMEDIA)*, 2015 8th International Conference on. IEEE, 2015.
- [20] Casagrande F.D. and Zouganeli E., "Activity Recognition and Prediction in Real Homes", in *Symposium of the Norwegian AI Society. Springer*, 2019.
- [21] Kashyap V.S., "Activity recognition and resident identification in smart home environment", Unitec Institute of Technology, Auckland, New Zealand, 2020.
- [22] Mohmed G., Lotfi A., and Pourabdollah A., "Human activities recognition based on neuro-fuzzy finite state machine", *Technologies*, 6(4):110, 2018.
- [23] Ramapatruni S., Narayanan S. N., Mittal S., Joshi A., and Joshi K. P., "Anomaly detection models for smart home security", in *IEEE 5th Intl Conference on Big Data Security on Cloud (BigDataSecurity), IEEE Intl Conference on High Performance and Smart Computing (HPSC), and IEEE Intl Conference on Intelligent Data and Security (IDS)* 2019.
- [24] Yamauchi M., Ohsita Y., Murata M., Ueda K., and Kato Y., "Anomaly detection for smart home based on user behavior", in *IEEE International Conference on Consumer Electronics (ICCE)*. 2019.
- [25] Yamauchi M., Ohsita Y., Murata M., Ueda K., and Kato Y., "Anomaly Detection in Smart Home Operation from User Behaviors and Home Conditions", *IEEE Transactions on Consumer Electronics*, 66(2):183-192, 2020.
- [26] Cardinaux F., Brownsell S., Hawley M., and Bradley D., "Modelling of behavioural patterns for abnormality detection in the context of lifestyle reassurance", *springer, Iberoamerican Congress on Pattern Recognition*, pp. 243-251, 2008.
- [27] Forkan A.R.M., Khalil I., Tari Z., Fofou S., and Bouras A., "A context-aware approach for long-term behavioural change detection and abnormality prediction in ambient assisted living", *Pattern Recognition*, 48(3):628-641, 2015.
- [28] Khan W.A., Hussain M., Afzal M., Amin M. B., and Lee S. "Healthcare standards based sensory data exchange for Home Healthcare Monitoring System", in *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. 2012.
- [29] Lee M.S., Lim J.G., Park K.R., and Kwon D.S., "Unsupervised clustering for abnormality detection based on the tri-axial accelerometer", in *ICCAS-SICE*. pp. 134-137, 2009.
- [30] Lee Y.S. and Chung W.Y., "Automated abnormal behavior detection for ubiquitous healthcare application in daytime and nighttime", in *Proceedings of 2012 IEEE-EMBS International Conference on Biomedical and Health Informatics*. 2012.
- [31] Virone G., Alwan M., Dalal S., Kell S.W., Turner B., Stankovic J.A., and Felder R.A., "Behavioral patterns of older-adults in assisted living", *IEEE Trans Inf Technol Biomed*, 12(3):387-98, 2008.

- [32] Hou T.H.T., Liu W.L., and Lin L., "Intelligent remote monitoring and diagnosis of manufacturing processes using an integrated approach of neural networks and rough sets", *Journal of Intelligent Manufacturing*, 14(2):239-253, 2003.
- [33] Barsocchi P., Cimino M.G., Ferro E., Lazzeri A., Palumbo F., and Vaglini G., "Monitoring elderly behavior via indoor position-based stigmergy", *Pervasive and Mobile Computing*, 23:26-42, 2015.
- [34] Rashidi P., Cook D.J., and Holder L.B., "Schmitter-Edgecombe M., Discovering activities to recognize and track in a smart environment", *IEEE transactions on knowledge and data engineering*, 23(4):527-539, 2010.
- [35] Yan Q., Xia S., and Shi Y., "An anomaly detection approach based on symbolic similarity", in *Chinese Control and Decision Conference*. 2010.
- [36] Roth E., *7 Tips for Reducing Sundowning*. 2016; Available from: <https://www.healthline.com/health/dementia-sundowning#take-care-ofyourself>.
- [37] Mokhtari G., Zhang Q., and Fazlollahi A., "Non-wearable UWB sensor to detect falls in smart home environment", in *Pervasive Computing and Communications Workshops (PerCom Workshops)*, pp. 274-278. IEEE, 2017.
- [38] Association; Available from: <https://iranalz.ir/site/index>.
- [39] CASAS, t.W.C.s.h. project, Editor. 2011.