Archive of SID

شبکه عصبی عمیق برای پیش‌بینی تعامل انسان در ویدئو با استفاده از روابط فازی و شار نوری

مه‌لقا افراسیابی[۱]، دانشجوی دکتری؛ حسن ختن‌لو[۲]، دانشیار؛ محرم منصوری‌زاده[۳]، استادیار
۱- دانشکده فنی و مهندسی- دانشگاه بوعلی سینا- همدان- ایران– m.afrasiabi@basu.ac.ir
۲- دانشکده فنی و مهندسی- دانشگاه بوعلی سینا- همدان- ایران– Khotanlou@basu.ac.ir
۳- دانشکده فنی و مهندسی- دانشگاه بوعلی سینا- همدان- ایران– mansoorm@basu.ac.ir

چکیده: پیش‌بینی تعامل در ویدئو یکی از موضوعات فعال در بینایی کامپیوتر است، که هدف آن پیش‌بینی تعامل قبل از انجام کامل آن است. این موضوع به دلیل چالش‌های موجود در این زمینه هنوز مورد توجه است. در این مقاله یک شبکه عصبی عمیق برای پیش‌بینی تعامل با استفاده از روابط فازی و شار نوری ارائه شده است. نوآوری این روش ایجاد دو تصویر فازی از یک ویدئو است. این تصاویر فازی بر مبنای گرادیان و شار نوری ایجاد می‌شود. توابع عضویت فازی مناسب برای روابط مکانی بین افراد در حال تعامل در تصاویر گرادیان و شار نوری ایجاد شده است. از طرفی یک تابع عضویت فاصله برای ارزش‌دهی به فریم‌ها و یک تابع عضویت فاصله برای ارزش‌دهی به ناحیه‌ی بین افراد در حال تعامل تعریف شده است. سپس ویژگی‌های مناسب مکانی-زمانی از این تصاویر با استفاده از معماری شبکه عصبی کانولوشن استخراج‌شده است. نتایج این روش بر روی دو مجموعه داده استاندارد تشخیص تعامل، BIT و UT ارزیابی شده است. نتایج نشان می‌دهد ایجاد تصاویر فازی و استخراج ویژگی‌های عمیق از آن تصاویر باعث افزایش دقت پیش‌بینی تعامل نسبت به روش‌های پیشین شده است.

واژه‌های کلیدی: رابطه مکانی فازی، گرادیان، شار نوری، شبکه کانولوشن.

Deep neural network for interaction prediction in video using fuzzy relationship and optical flow

Mahleqa Afrasiabi[1], PhD student; Hassan Khotanlou[2], Associate professor; Moharram Mansoorizadeh[3], Assistant professor

1- Department of Computer Engineering, Bu-Ali Sina University, Hamedan, Iran, Email: m.afrasiabi@basu.ac.ir
2- Department of Computer Engineering, Bu-Ali Sina University, Hamedan, Iran, Email: Khotanlou@basu.ac.ir
3- Department of Computer Engineering, Bu-Ali Sina University, Hamedan, Iran, Email: Mansoorm@basu.ac.ir

Abstract: The aim of interaction prediction in videos is to predict the interaction before it actually happens. Recently, this task has been important in computer vision domain and is gaining a lot of attention due to its challenges. In this paper, a deep neural network using fuzzy relationship and optical flow is proposed to deal with the problem. In this approach for each frame of a given video, first, two fuzzy images are obtained based on the gradient and the optical flow of the frame. Then, two set of features are extracted by a convolutional neural network trained on these images. Final prediction is made by aggregating the two outputs of the network. The proposed method shows promising results on two interaction datasets, namely BIT-Interaction and UT-Interaction.

Keywords: Fuzzy spatial relationship, gradient, optical flow, convolutional neural network.

تاریخ ارسال مقاله: ۱۳۹۷/۱۰/۱۰
تاریخ اصلاح مقاله: ۱۳۹۷/۱۲/۲۰، ۱۳۹۸/۰۲/۲۴و ۱۳۹۸/۰۳/۱۸
تاریخ پذیرش مقاله: ۱۳۹۸/۰۴/۰۴
نام نویسنده مسئول: حسن ختن‌لو
نشانی نویسنده مسئول: دانشکده فنی و مهندسی- دانشگاه بوعلی سینا- همدان- ایران.

www.SID.ir

Archive of SID

۱- مقدمه

تشـــخیص و پیش‌بینی کنش و فعالیت یکی از مباحث مهم در بینایی کامپیوتر اســت. در تشـخیص کنش، به بررســی رفتار یک انســان و در تشخیص فعالیت به بررسی رفتار بین دو یا چند فرد (مانند دست‌دادن) یا تعامل انســان و یک شــی (مانند بســتن‌پنجره) پرداخته می‌شــود. تشخیص فعالیت به‌دلیل پیچیدگی رفتار افراد در زمان تعامل با یکدیگر و واکنش‌های متفاوت آنان، نسبت به تشخیص کنش دشوارتر است. در پیش‌بینی، هدف تشـــخیص فعالیت قبل از اتمام آن خواهد بود [۱]. به‌طور مثال همان‌طور که در شــکل ۱ نشــان داده شــده، هنگامی‌که قسمتی از ویدئو دیده شده انتظار می‌رود بتوان نوع فعالیت در قسمت دیده‌نشــده ویدئو را پیش‌بینی کرد. هدف این مقاله پیش‌بینی فعالیت بین دو فرد اســت. از کاربردهای پیش‌بینی تعامل و فعالیت می‌توان به شــناســایی حوادث خطرناک در محیط‌های نظارتی و شــناســایی تعامل انسان و ربات نام برد.

از چالش‌های موجود در زمینه پیش‌بینی تعامل می‌توان به اختلاف ظاهر و ســـرعت حرکت افراد اشـــاره کرد. از طرفی چالش‌های محیط مانند تغییرات نور، پیش زمینه شلوغ و تصادم بین فرد مورد بررسی و محیط، بر روی روش‌های تشخیص تعامل تاثیرگذار خواهند بود [۲، ۳].

برای پیش‌بینی تعامل نیاز به فهمیدن رفتار افراد در طول زمان است. بنابراین تشخیص تعامل بر اساس یک فریم کاری دشوار است، روش‌های زیادی در این زمینه ارائه‌شـــده‌اند که از ویژگی حرکتی مانند انرژی حرکت تصویر[۱](MEI) و تصویر تاریخچه حرکت[۲](MHI) استفاده کرده‌اند. امروزه شبکه‌های عصبی عمیق نشان داده‌اند که توانایی بسیار بالایی برای استخراج ویژگی دارند [۴]. از بین این شبکه‌ها، شبکه‌های عصبی کانولوشن (CNN)[۳] [۵] برای تشخیص کنش و شناسایی اشیا به‌کار رفته‌اند، و نتایج بسـیار خوبی داشـته‌اند. برای اسـتخراج اطلاعات حرکتی از یک مجموعه فریم پی‌درپی شار نوری[۴] استفاده می‌شود. این فریم‌ها به شـــبکه CNN داده می‌شـــوند تا اطلاعاتی زمانی- مکانی را استخراج کند. علاوه‌بر آن ویژگی‌های CNN که از فریم‌ها استخراج‌شده به روش‌های دسـته‌بندی مانند شـبکه‌های LSTM[۵] داده می‌شـوند تا با استفاده از پردازش توالی ویژگی به پیش‌بینی تعامل پرداخته شود.

در سال‌های گذشته روش‌های فازی مانند سیستم استنتاج فازی مرتبه اول، مدل مخفی مارکوف فازی و روش‌های هیبریدی در تشخیص فعالیت با مدل‌کردن غیرقطعی ویژگی‌ها نتایج خوبی داشـته‌اند [۹- ۶]. این روش‌ها توانایی مدل‌سازی و پیش‌بینی فعالیت‌های پیچیده انسان را دارند. از آنجایی‌که انجام هر کنش یا تعامل ماهیتی فازی دارد و نمی‌توان حرکت مشخصی برای تعریف آن در نظر گرفت، استفاده از روش فازی می‌تواند باعث افزایش دقت تشخیص فعالیت شود.

در این مقاله روشـــی جدید برای نمایش اطلاعات حرکتی برای پیش‌بینی تعامل ارائه‌شـــده اســـت. در این روش برای نمایش اطلاعات حرکتی یک تصویر فازی ایجاد می‌شود. این تصویر حاوی اطلاعات مهم حرکت افراد شـرکت‌کننده در تعامل اسـت. تصـویر فازی ارائه‌شـده بر محدودیت تصـاویر رنگی که نیاز به کنتراسـت بالا برای جداکردن افراد شـــرکت‌کننده در تعامل و پیش‌زمینه اســـت، غلبه می‌کند. همچنین تصـویر ایجادشـده ترکیب وزن‌داری از اطلاعات حرکتی مناسـب در هر ناحیه از مراحل انجام تعامل است.

ورودی روش ارائه‌شده تصاویر ویدئوهای RGB است. ابتدا دو تصویر فازی از فریم‌های ویدئو ایجاد می‌شـــود که این تصـــاویر برمبنای رابطه فازی بین افراد در حال تعامل اسـت. هر تصـویر به یک شـبکه CNN، داده می شود تا ویژگی‌های منا سب از آن ا ستخراج شود، در نهایت از شبکه تماماً متصل برای پیش‌بینی تعامل ا ستفاده می شود. ویژگی این روش این است، که نیازی به جداکردن پیش‌زمینه نیست و تصویر فازی استخراج‌شده دارای اطلاعات حرکتی برای پیش‌بینی نوع تعامل است.

روش ارائه‌شـده بر روی دو مجموعه داده تعامل انسـان UT و BIT تست شده است. نتایج نشان می‌دهد دقت بالاتری نسبت به روش‌های پیشین به‌دست آمده است، به‌طور مثال دقت تشخیص بر روی مجموعه BIT حدود ۴ درصد افزایش یافته است.

نوآوری روش ارائه‌شده در ادامه بیان شده است:

- ارائه یک تصـویر فازی بر مبنای گرادیان تصـاویر برای پیش‌بینی تعامل
- ارائه یک تصویر فازی بر مبنای تصاویر شار نوری برای پیش‌بینی تعامل
- ارائه یک شـبکه عمیق برای پیش‌بینی تعامل در ویدئو با اسـتفاده از روابط فازی و شارنوری.

ادامه این مقاله به‌صورت زیر ساختاربندی شده است. در بخش ۲، کارهای مرتبط مورد بحث قرارگرفته، در بخش ۳، پیش‌زمینه مطالب مرتبط به مقاله بیان شده و در بخش ۴ روش پیشنهادی تشریح شده

شکل ۱: پیش‌بینی تعامل انسان در ویدئو، هدف پیش‌بینی تعامل این است که قبل از اینکه تعامل کامل اتفاق بیافتد نوع تعامل تشخیص داده شود.

www.SID.ir

Archive of SID

است. بخش ۵ نتایج تجربی و تحلیل را ارائه می‌کند. درنهایت، در بخش ۶ نتیجه‌گیری بیان شده است.

۲- کارهای پیشین

کارهای مرتبط در زمینه پیش‌بینی تعامل و فعالیت بر اساس انتخاب ویژگی به سه دسته تقسیم می‌شوند[۱۰]:

در اولین گروه، ویژگی‌های سطح پایین استخراج می شود. این نوع ویژگی‌ها اطلاعات مکانی و زمانی را استخراج می‌کنند. ویژگی‌های هیستوگرام گرادیان[۶](HOG)، هیستوگرام شار نوری[۷](HOF)، هیستوگرام مرز حرکت[۸](MBH) و نقاط موردنظر زمان-مکان[۹](STIP) جز این دسته ویژگی‌ها هستند، که در تشخیص تعامل استفاده‌شده‌اند.

در مقاله [۱۱] از ترکیب ویژگی‌های HOG، HOF و MBH ویژگی HM[۱۰] ارائه‌شده، که از الگوریتم SVM[۱۱] برای تشخیص تعامل استفاده‌شده است.

در [۱۲] ویژگی‌های خط‌سیر چگال، HOG، HOF، MBH، STIP و تبدیل ویژگی نامتغیر مقیاس(SIFT[۱۲]) از یک ویدئو استخراج‌شده، سپس هر بردار ویژگی با استفاده از تکنیک فیشر به یک بردار به طول ثابت تبدیل‌شده، سرانجام با استفاده از الگوریتم SVM نوع تعامل تشخیص داده‌شده است.

در روش MTSSVM[۱۳] هر ویدئو را به تعداد بخش‌های مساوی تقسیم، سپس نقاط موردنظر و خط‌سیر چگال از هر بخش استخراج، و از مدل بسته کلمات[۱۴] برای نمایش هر بخش استفاده شده است. برای تشخیص تعامل الگوریتم MTSSVM به‌کاررفته، که یک مدل SVM ساختاریافته است که محدودیت تکاملی حرکت زمانی و محدودیت سازگاری برچسب به آن اضافه شده است [۱۳]. در روش MMAPM[۱۵] [۱۴] که بهبودیافته MTSSVM است از ترکیب کرنل‌های غیرخطی در الگوریتم SVM برای تشخیص و پیش‌بینی تعامل استفاده‌شده است.

در [۱۵] ویژگی‌ها را با استفاده از یک توصیف‌گر مکانی- زمانی، محاسبه کرده‌اند، سپس روابط زمانی و علیت را با استفاده از حوزه‌های تصادفی مارکوف مدل‌سازی کرده‌اند. یک روش دیگر بر مبنای یادگیری گراف‌های CRF برای مدل‌سازی تعامل‌های انسانی فراهم‌شده [۱۶]، که در آن HOG و HOF از بخش‌های تصویر بدن انسان استخراج‌شده است.

سیستم استنتاج فازی توانایی مدل‌کردن عدم‌قطعیت و ترکیب ویژگی‌های مختلف را دارد. از این سیستم با ورودی ویژگی‌های سطح پایین برای تشخیص فعالیت استفاده‌شده است [۱۷، ۱۸]. در مقاله [۱۸] که هدف آن تشخیص فعالیت است، ویژگی زمانی- مکانی استخراج شده است. ابتدا تصویر شبح[۱۶] و سپس ویژگی‌هایی از آن‌که شامل اطلاعات ظاهری و سرعت است، استخراج می‌شود. این ویژگی‌ها به‌عنوان ورودی به سیستم استنتاج فازی داده می شود. این کار برای یادگیری توابع عضویت از الگوریتم FCM استفاده کرده است.

روشHMM در تشخیص فعالیت بسیار استفاده شده است. در [۱۹] ابتدا تصویر شبح استخراج‌شده، سپس اسکلت تصویر به‌دست می آید. با توجه به حرکت نقاط اسکلت یک سیستم تشخیص بر مبنای الگوریتم HMM ارائه‌شده، که Fuzzy HMM نام دارد. در این روش فاصله هر بردار مشاهده بر مرکز دسته‌بند محاسبه می‌شود و عکس این فاصله درجه عضویت بردار مشاهده به دسته‌بند است.

دومین دسته ویژگی‌ها، ویژگی‌های سطح میانه هستند. معمولاً این ویژگی‌ها بر پایه ویژگی‌های سطح پایین هستند. Poselet جز این دسته ویژگی‌هاست، که حالت انسان‌ها را تحت یک دید معین توصیف می کند. در روشی از Poselet مبتنی بر HOG با Poselet های مدل بسته کلمات که حاوی توصیف‌گرهای انبوه (SIFT, HOG, MBH) است، برای تشخیص فعالیت استفاده‌شده است[۲۰].

به‌منظور یادگیری حرکات پیچیده، در روشی حرکات انسان با ترکیبی از کوچک‌ترین واحد سازنده الگوهای حرکتی انسان به نام dyneme نشان داده‌شده است [۲۱]. Dyneme کوچک‌ترین واحد حرکت انسان است و حرکت کامل بدن یک توالی از حرکت این واحدهای کوچک می‌باشد. بردار فازی تدریجی (FVQ) به‌عنوان تابعی است که گذار بین تصمیم‌گیری های نرم را کنترل می‌کند و تصمیم‌گیری‌های نرم برای ترسیم یک بردار موقعیت ورودی در فضای dyneme به‌کاررفته شده است. در نهایت هر حرکت به‌صورت یک مدل حرکت فازی با محاسبه میانگین حسابی متشکل از حالت‌های مختلف حرکت در فضای dyneme نمایش داده‌شده است.

این دو دسته ویژگی سطح پایین و سطح میانه، ویژگی‌های دستی[۱۷] هستند که طراح خبره براساس تأثیر آن بر دقت و کارایی روش، آن را انتخاب می‌کند [۲۲]. دسته سوم استخراج ویژگی، ویژگی‌های بدون ناظر است. ویژگی‌هایی که برمبنای ویژگی‌های دستی است، قدرت کافی برای استخراج اطلاعات حرکتی مهم به‌خاطر از دست‌دادن ساختار تصویر ندارند. اخیراً شبکه‌های عصبی عمیق مانند CNN نشان داده‌اند، که نتایج خوبی نسبت به روش‌های سنتی دارند. به این ویژگی‌ها، ویژگی‌های عمیق گویند که مستقل از نوع دسته‌بند خاص است و مستقیم از تصاویر به‌دست می‌آید[۲۲]. این ویژگی‌ها مقاومت بیشتری به تغییر پذیری درون کلاسی دارند، در نتیجه قدرت تعمیم بالایی دارند[۲۲].

در مقالاتی که هدف تشخیص تعامل یا کنش در ویدئوهای-RGB D است، از روش‌های فازی برای تشخیص استفاده شده است. به‌طور مثال یک نمایش جدید بر مبنای روش فازی ارائه شده[۲۳]، که در این روش ابتدا یک الگوی حرکتی بر مبنای MHI و MEI از فریم‌ها ایجاد می‌شود، سپس براساس رابطه زمانی فازی فریم‌ها، الگوها با یکدیگر ترکیب می‌شوند. خروجی این تصویر به یک شبکه CNN داده‌شده است. این روش برای تشخیص کنش مناسب است. در مقاله [۲۴] برای تشخیص کنش ابتدا یک پیش‌پردازش با استفاده از فیلتر گابور برای جداکردن پس‌زمینه استفاده‌شده، سپس با CNN ویژگی استخراج و در نهایت وزن‌دهی فازی به ویژگی انجام‌شده است. در مقاله [۲۵] نیز برای تشخیص شی از وزن‌دهی فازی بعد از استخراج ویژگی CNN از تصاویر

www.SID.ir

Archive of SID

استفاده‌شده است. برخلاف روش ارائه‌شده که ابتدا تصویر فازی ایجادشده، سپس از CNN استفاده می‌شود، در این دو روش [۲۴، ۲۵] ابتدا ویژگی‌های باCNN استخراج می‌شوند، سپس از وزن‌دهی فازی در مرحله دسته‌بندی استفاده می‌شود.

در [۲۶] روشی ارائه داده‌اند که در آن تصاویر کدگذاری شده شار، از فریم‌های متوالی محاسبه‌شده و به شبکه CNN برای استخراج ویژگی های عمیق زمانی ارسال‌شده‌اند. در کار دیگر که گسترش‌یافته این روش ا ست از گرفتن اطلاعات سرا سری و محلی ا ستفاده شده ا ست [۲۷]. این روش شامل چهار مدل اصلی است. در مدل‌های مکانی و فضایی، تصاویر رنگی و تصاویر شار نوری، و در مدل‌های ساختاری مکانی و زمانی، اطلاعات شار نوری و رنگی تصویر هر فرد در حال تعامل و ق سمت بالا و پایین بدن آن به شبکه‌های متمایز CNN ار سال شده است. ویژگی عمیق مختلف استخراج‌شده به شبکه‌های حافظه بلندمدت (LSTM) منتقل‌شده و سپس از آن یک لایه به‌طور کامل متصل شده‌اند. چهار امتیاز حاصل از مدل مکانی، مدل زمانی، ساختاری مکانی و ساختار زمانی با یکدیگر ترکیب‌شده تا نوع تعامل پیش‌بینی شود.

در مقاله [۲۸] یک مدل تکراری بلندمدت (LRCN) پیشنهاد شده، که یک شبکه CNN همراه با LSTM است. آن‌ها همچنین هر دو ورودی‌های RGB و شار را در نظر می‌گیرند. برای هر فریم یک بردار ویژگی عمیق ا ستخراج شده و به یک LSTM ار سال شده ا ست، سپس خروجی های لا یه softmax شبکه در تمام فریم ها به‌طور میانگین گرفته‌شده و محتمل‌ترین برچسب یافته شده است.

در این روش‌ها ویژگی‌های عمیق استخراج می‌شوند، روش‌های طبقه‌بندی مانند LSTM مورداستفاده قرارگرفته‌اند، اما معایب این روش را می‌توان با فرآیند محاسبات بالا بیان کرد.

هر دو دسته ویژگی سطح پایین و سطح میانه نسبت به ویژگی بدون ناظر دقت کمتری دارند، از طرفی مشکل روش‌های فازی ارائه‌شده در مقاله‌های[۱۷، ۱۸] جداکردن تصویر انسان از زمینه ا ست. که دقت روش وابسته به‌دقت استخراج تصویر شبح می‌باشد. در ویدئو که نیاز به بررسی ویژگی‌ها در طول زمان است، پیداکردن ویژگی مناسب که بیانگر اطلاعات ویدئو باشد کار ساده‌ای نیست. امروزه با قدرت ماشین‌های موازی (مانند GPU و CPU clusters) شبکه‌های کانولوشن عصبی توسعه پیدا کرده‌اند، که در تشخیص کنش در ویدئو استفاده شده‌اند. اما ویژگی‌های استخراج شده با استفاده از این شبکه‌ها بصری هستند و به‌تنهایی برای پیش‌بینی تعامل محدودیت دارند. به‌همین دلیل در این مقاله قبل از استخراج ویژگی‌های عمیق تصویر فازی برمبنای حرکت افراد ایجاد می شود تا قدرت ا ستنتاج را بالا ببرد. این روش شامل دو مرحله ا ست. ابتدا با ا ستفاده از ویژگی‌های سطح پایین یک تصویر فازی از کل ویدئو ا ستخراج می شود. در مرحله بعد از یک CNN برای استخراج ویژگی از این تصویر استفاده شده است.

این تصویر فازی برای حفظ اطلاعات حرکتی استفاده می‌شود و ا ستفاده از CNN باعث ا ستخراج ویژگی محلی از این ت صویر می شود. برتری این روش سرعت بالا [۲۹] و عدم وابستگی به مقیاس و انتقال و حفظ اطلاعات حرکتی دانست [۲۲]. چون از کل فریم‌ها یک تصویر ایجادشده و برای استخراج ویژگی به CNN ارسال می‌شود، می‌توان گفت سرعت آن از روش‌هایی که نیاز به ارسال هر فریم به‌تنهایی به CNN است، بالاتر خواهد بود. این روش نسبت به روش‌هایی که بر مبنای LSTM با بار محا سباتی بالایی ه ستند نیز سریع‌تر خواهد بود. ا ستفاده از ویژگی‌های عمیق نیز باعث افزایش قدرت تعمیم روش شده است.

۳- پیش‌زمینه

ازآنجایی‌که در روش ما از رابطه مکانی فازی، اطلاعات گرادیان، ت صاویر کد شده شار و CNN ا ستفاده شده، در این ق سمت مخت صراً این موارد توضیح داده‌شده‌اند.

۳-۱- رابطه مکانی فازی

مشخص‌کردن رابطه مکانی بین اشیا و انسان‌ها در یک تصویر در بینایی کامپیوتر امر مهمی است [۳۰]. در سال‌های گذشته توجه زیادی به تحلیل روابط فازی مکانی شده است [۳۱]، که در حوزه‌های گوناگون مانند تحلیل حرکت انسان و ربات [۳۲] و تحلیل تصاویر پزشکی [۳۳، ۳۴] به‌کاررفته است. توانایی تمایز بین رابطه‌های مکانی شبیه‌به‌هم، به‌خصوص در فضای ویژگی‌های دوبعدی کار دشواری است. استفاده از متغیرهای زبانی فازی رویکرد خوبی در فرآیند استدلال روابط مکانی فازی دارد.

تعدادی از تحقیقات در زمینه تعریف رابطه مکانی فازی است [۳۳]. در این مقالات، رابطه مکانی شامل راست، چپ، نزدیک و دور است. برای مدل‌کردن این روابط نیاز به تعریف متغیرهای زبانی فازی ا ست. با توجه به اهمیت فاصله در پردازش تصویر، بیان فازی آن برای حل مسائل این حوزه بسیار مفید است. برای مثال "A نزدیک B است" ، یک مدل فازی نزدیک، یک مقدار عددی μ_{near} به جفت (A,B) نسبت می دهد که نشان‌دهنده درستی جمله بالا است. تعاریف گوناگونی برای بیان نزدیکی در روابط مکانی فازی تعریف‌شده که به مسئله موردبررسی بستگی دارد.

رابطه فازی چپ و راست بر اساس توابع $\cos^2\theta$،$sin^2\theta$ یا توابع عضویت مثلثی، ذوزنقه‌ای و توابع دیگر قابل‌تعریف است. این توابع عضویت با μ_{left} و μ_{right} نشان داده می‌شوند، که این مقدار نشان‌دهنده رابطه جهت‌دار بین دو شی ا ست. معمولاً در هر شی یک نقطه مرجع در نظر گرفته می شود، سپس مقدار ع ضویت بر ا ساس درجه ر ضایت رابطه مکانی برای نقاط اطراف آن نقطه مرجع تعریف می‌شود.

به‌طور مثال در شکل ۲ یک شی مرجع و رابطه مکانی فازی چپ آن نشان داده‌شده است.

www.SID.ir

Archive of SID

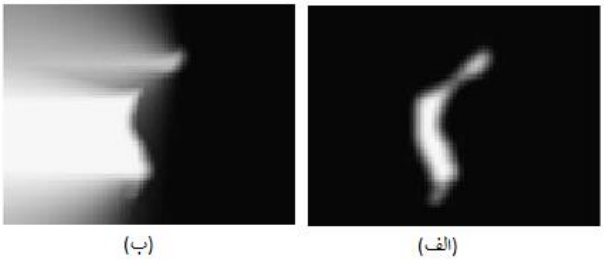

شکل ۲: الف) شی مرجع، ب) رابطه مکانی چپ برای شی مرجع [۳۳]

۳-۲- اطلاعات گرادیان

ویژگی گرادیان مکانی برای استخراج ویژگی‌های سطح پایین تصویر استفاده می شود. این ویژگی قابلیت استخراج لبه‌ها در تصویر را دارد. ابتدا تصویر با استفاده از کرنل $[1\ 0\ -1]$ در جهت x و y فیلتر می شود تا گرادیان تصویر در جهت x و y محاسبه شود.

برای محاسبه گرادیان هر پیکسل (x,y) در راستای محور افقی و عمودی به‌ترتیب $g_x(x,y)$ و $g_y(x,y)$ از رابطه (۱) محاسبه می‌شوند.

$$g_x(x,y) = -f(x,y-1) + f(x,y+1)$$
$$g_y(x,y) = -f(x-1,y) + f(x+1,y) \quad (۱)$$

که $f(x,y)$ شدت پیکسل (x,y) در تصویر است.اندازه بردار گرادیان از رابطه (۲) به‌دست می‌آید.

$$|g(x,y)| = \sqrt{g_x(x,y)^2 + g_y(x,y)^2} \quad (۲)$$

و برای فریم‌های رنگی گرادیان هر کانال جداگانه محاسبه می‌شود.

۳-۳- شار نوری

مفهوم شار نوری در سال ۱۹۴۰ توسط گیبسون [۳۵] برای توصیف محرک‌های دیداری فراهم شده است. اهمیت شار نوری به‌دلیل قابلیت درک و توانایی تشخیص حالات ممکن برای انجام یک عمل موردتوجه قرارگرفته است. شار نوری یک روش مناسب برای استخراج اطلاعات حرکتی از دنباله فریم‌ها است. استفاده از شار نوری روی فریم‌های پی درپی می‌تواند حرکت هر پیکسل را در جهت عمودی و افقی استخراج کند. یک توصیف مناسب از همه این حرکت‌ها در هر پیکسل می‌تواند در کاربردهای گوناگون متفاوت باشد [۳۶].

روش‌های شار نوری سعی بر محاسبه حرکت بین دو فریم در زمان‌های t و $t+\Delta t$ را دارند. برای نمونه برای یک پیکسل در موقعیت (x,y,t) با شدت پیکسل $I(x,y,t)$به اندازه‌های v_x, v_y بین دو فریم پی‌درپی از تصاویر حرکت خواهد کرد و محدودیت پایداری روشنایی به صورت زیر است:

$$I(x,y,t) = I(x+v_x, x+, v_y, t+1) \quad (۳)$$

برای هر بردار شار نوری $V = [v_x, v_y]^T$ هر پیکسل، اندازه (ρ) و جهت $(-\pi \le \theta \le \pi)$ از رابطه (۴) محاسبه می‌شود[۳۷].

$$\rho = \sqrt{v_x^2 + v_y^2}$$
$$\theta = \arctan(\frac{v_y}{v_x}) \quad (۴)$$

۳-۴- شبکه‌های عصبی کانولوشن

شبکه‌های عصبی کانولوشن (CNN) یکی از شبکه‌های عمیق می‌باشند، که نتایج خوبی برای دسته‌بندی تصاویر دارد. این شبکه دارای چند لایه و یک لایه تماماً متصل است. لایه کانولوشن روی تمام تصویر با کرنل های با محدوده کوچک را کانوالو می‌کند. این لایه ها باعث استخراج ویژگی‌های مناسب از تصاویر هستند. هر لایه کانولوشن یک لایه ادغام ماکزیمم دارد. این لایه باعث کاهش دامنه ویژگی‌ها می شود. سرانجام لایه تماماً متصل قرار دارد که پردازش نهایی را انجام می‌دهد، و منجر به کلاس‌بندی می‌شود [۵].

۴- روش پیشنهادی

همان‌طور که در فلوچارت شکل ۳ نشان داده‌شده، در این مقاله روشی برای پیش‌بینی تعامل که دارای سه بخش اصلی است، ارائه‌شده است. در بخش اول یک تصویر فازی بر مبنای گرادیان و در بخش دوم یک تصویر فازی بر مبنای شار نوری از تمام فریم‌های ویدئو ایجاد خواهد شد. تصویر فازی گرادیان از کل فریم‌ها ایجاد می‌شود تا اطلاعات حرکتی بین فریم‌ها را نشان دهد و تصویر شار نوری بر مبنای جهت تغییرات حرکت افراد است. سپس هر تصویر به یک شبکه عصبی عمیق داده خواهد شد، تا ویژگی‌های مناسب از هر تصویر استخراج شود. در لایه آخر این شبکه عمیق یک لایه softmax قرار داده شده که احتمال هر تصویر به کلاس‌های تعامل محاسبه می‌شود. نتیجه خروجی این دو شبکه با یکدیگر ترکیب شده تا نوع تعامل پیش‌بینی شود. در ادامه هر بخش شرح داده خواهد شد.

۴-۱- ایجاد تصویر گرادیان فازی

همان‌طور که در شکل ۴ نشان داده‌شده، ابتدا جعبه‌کران دو فرد در حال تعامل با استفاده از الگوریتم ردیابی [۳۸] استخراج شده، سپس روی هر فریم یک فیلتر میانگین اعمال‌شده تا تصویر هموار شود، در مرحله بعد (شکل ۴ (الف)) گرادیان هر تصویر محاسبه‌شده است.

سپس مرکز جعبه کران‌ها در نظر گرفته‌شده است. پیکسل‌هایی که بین دو فرد هستند اهمیت بیشتری خواهند داشت و ناحیه بین دو مرکز اهمیت زیادی در تشخیص خواهد داشت و هر چه از ناحیه مرکز جعبه‌کران در جهت مخالف حرکت دو فرد دور شده، اهمیت آن نواحی کم‌تر خواهد شد. برای هر تعاملی نمی‌توان رابطه مکانی فاصله را به‌طور

www.SID.ir

Archive of SID

دقیق تخمین زد، به‌همین دلیل استفاده از رابطه فازی مکانی فاصله که نشان‌دهنده رابطه نزدیکی دو فرد است، می‌تواند مؤثر باشد.

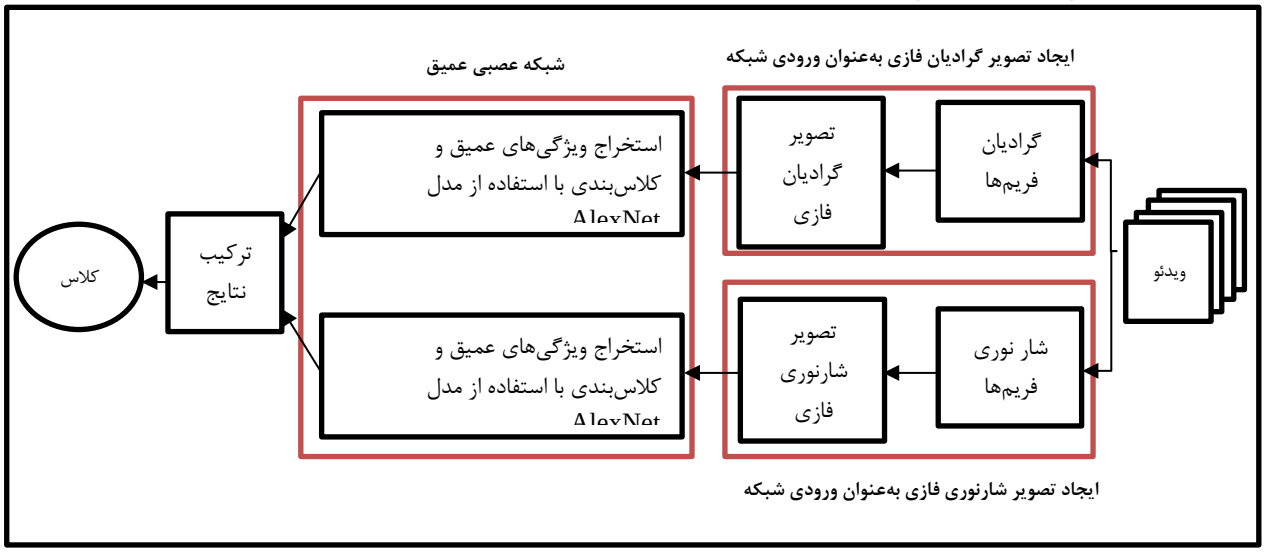

شکل ۳: فلوچارت روش ارائه‌شده

$$\mu_1(i,j)=\begin{cases}0 & j\le 0\\ \dfrac{j-a}{b-a} & a\le j\le b\\ 1 & b<j\le c\\ \dfrac{d-j}{d-c} & c\le j\le d\\ 0 & d\le j\end{cases} \qquad (۵)$$

که a، مقدار ستون ابتدای جعبه کران فرد سمت چپ، b مقدار ستون مرکز جعبه‌کران فرد سمت چپ، c، مقدار ستون ابتدای جعبه‌کران فرد سمت راست، d مقدار ستون مرکز جعبه‌کران فرد سمت راست است.

در شکل ۴ (ب)، تابع عضویت فاصله بر تصاویر اعمال می شود تا ناحیه بین دو فرد استخراج شود. در مرحله بعد اختلاف اندازه تصاویر گرادیان این ناحیه هر فریم با فریم بعدی محاسبه‌شده است (شکل ۴(ج)).

از طرفی در هنگام انجام تعامل در ویدئوهای مختلف زمان انجام آن یکسان نخواهد بود، به‌همین دلیل برای اهمیت‌دادن به فریم‌هایی که احتمال بیشتری دارند که تعامل در حال اجرا باشد از یک تابع عضویت فازی بر مبنای فاصله زمانی فریم‌ها استفاده می شود تا وزن درستی به هر فریم نسبت داده شود (شکل۶). هنگام انجام تعامل در فریم‌های وسط ویدئو احتمال انجام تعامل بیشتر است. به‌همین دلیل یک تابع عضویت که دارای سه حالت (آغاز، وسط، انتها) تعریف شده، که بر اساس شروع ویدئو تا انتهای آن است. در فریم‌های میانی ارزش پیکسل‌ها برای ایجاد تصویر فازی بیشتر است، از این تابع برای جمع فریم‌ها استفاده خواهد شد. از این تابع عضویت در مقاله [۲۳] نیز استفاده شده است.

$$\mu_2(i)=\begin{cases}\dfrac{2i}{n} & 0<i\le {}^{n}/_{2}\\ 2-\dfrac{2i}{n} & {}^{n}/_{2}<i\le n\end{cases} \qquad (۶)$$

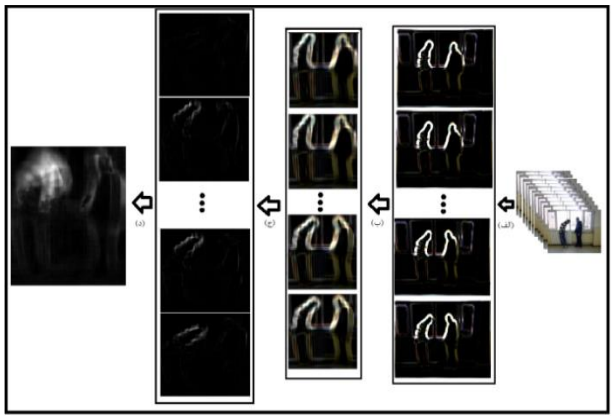

شکل ۴: ایجاد تصویر فازی بر مبنای گرادیان؛ (الف) محاسبه گرادیان هر فریم، (ب) اعمال تابع عضویت فاصله μ_1 بر تصویر گرادیان، (ج)محاسبه اختلاف تصاویر گرادیان هر فریم با فریم بعد آن، (د)ایجاد تصویر فازی با استفاده از تابع عضویت μ_2.

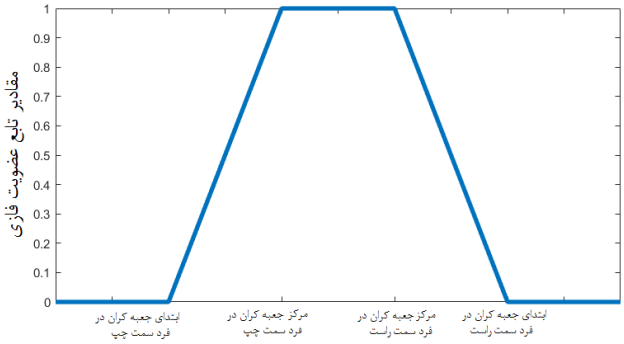

شکل ۵: تابع عضویت فاصله

در شکل ۵ تابع عضویت برای فاصله نشان داده‌شده است، که برای هر پیکسل (i,j) در فریم مقدار $\mu_1(i,j)$ از رابطه (۵) به‌دست می‌آید.

www.SID.ir

Archive of SID

در معادله (۶)، n تعداد فریم‌ها در ویدئو است. $\mu_2(i)$ نشان‌دهنده مقدار تابع عضویت در i امین فریم ویدئو است.

در شکل ۴ (د)، ترکیب وزن‌دار فریم‌ها بعد از اعمال تابع عضویت μ_2 نشان داده‌شده است. در این مرحله تصویر گرادیان فازی برای ورودی به شبکه ایجاد خواهد شد.

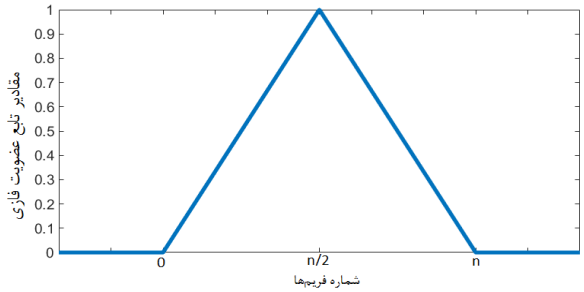

شکل۶: تابع عضویت فاصله زمانی فریم‌ها، n نشان‌دهنده تعداد فریم‌ها در ویدئو است.

در شکل ۷ نمونه‌هایی از تصویر فازی بر مبنای گرادیان نشان داده‌شده است.

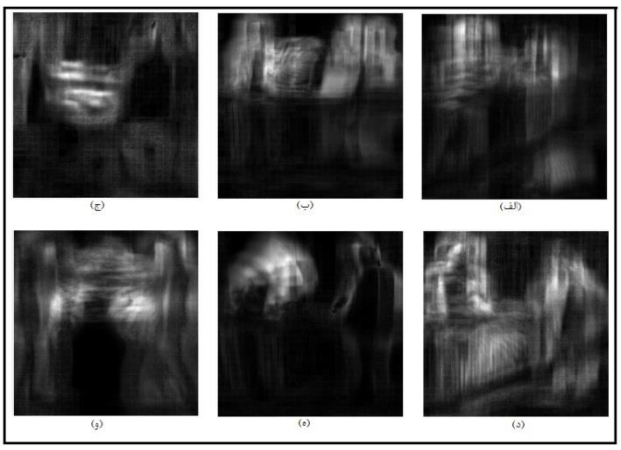

شکل ۷: نمونه‌ای از تصاویر گرادیان فازی به‌دست‌آمده؛ (الف)هل‌دادن، (ب) مشت‌زدن، (ج) دست‌دادن، (د) لگدزدن، (ه) تعظیم‌کردن، (و) بزن‌قدش.

۴-۲- ایجاد تصویر شار نوری فازی

برای ایجاد تصویر شار نوری فازی، بعد از پیداکردن جعبه‌کران هر دو فرد، جهت حرکت آن‌ها برر سی می شود. چون فرد در حال تعامل، یک نفر از چپ به راست و فرد دیگر از راست به چپ حرکت می‌کند، یک تابع عضویت بر اساس رابطه مکانی آن‌ها تعریف می‌شود. در فرد سمت چپ حرکت به سمت راست و فرد سمت راست بالعکس اهمیت دارد و حرکت بقیه پیکسل‌ها برای تشخیص تعامل اهمیتی ندارد، پس نقاطی که جهت آن به سمت موردنظر است، بررسی می‌شود.

تابع عضویت در شکل ۸ برای ارزش‌گذاری جهت حرکت‌های مؤثر در تشکیل نوع تعامل ارائه‌شده است. برای فرد سمت راست دو تابع μ_3،μ_4 و برای فرد سمت چپ دو تابع μ_5،μ_6 استفاده شده است. از جهت تصاویر شار نوری برای محاسبه جهت حرکت استفاده شده است.

$$\mu_{3,4,5,6}(i,j) = e^{\frac{-(\theta_{ij}-c)^2}{2\sigma^2}} \quad (۷)$$

چهار تابع عضویت بر اساس رابطه (۷) تشکیل شده‌اند که در شکل ۸ نشان داده‌شده است. مرکز توابع به‌ترتیب 0، pi/4، 3pi/4 و pi است. مقدار σ برابر pi/8 است. مقدار θ_{ij}برابر جهت پیکسل (i,j) در تصویر شار نوری است.

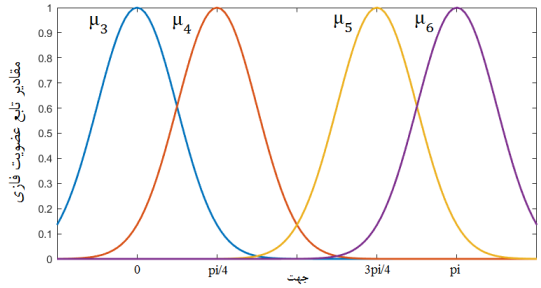

شکل ۸: تابع عضویت مکانی

برای هر پیکسل مقدار اندازه شارنوری فازی برابر مقدار زیر است:

$$\rho(i,j) = \mu\sqrt{v(i,j)_x^2 + v(i,j)_y^2} \quad (۸)$$

که مقدار μ برای هر پیکسل از تابع عضویت شکل ۸ به‌دست می‌آید. برای حالتی که پیکسلی مقدار μ_3,μ_4,μ_5,μ_6 در بیش از یک حالت غیر صفر است، ماکزیمم آن در نظر گرفته می‌شود.

از مجموع وزن‌دار تصاویر شار نوری تصویری ایجاد می‌شود که برای تشخیص تعامل استفاده می‌شود. چون در فریم‌های وسط ویدئو احتمال انجام تعامل بیشتر است، فریم‌های وسط ارزش بیشتری دارد و از تابع عضویت شکل۶ برای وزن‌دارکردن فریم‌ها استفاده خواهد شد.

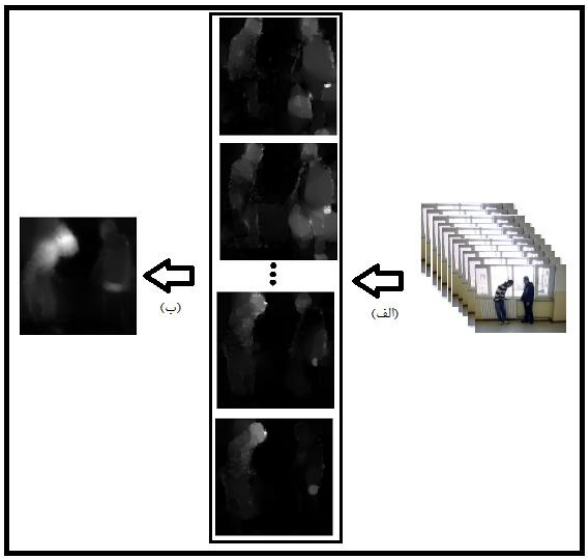

www.SID.ir

Archive of SID

شکل ۹: ایجاد تصویر فازی بر مبنای شارنوری؛ (الف) محاسبه شارنوری هر فریم با استفاده از توابع عضویت $\mu_{3,4,5,6}$، (ب) ایجاد تصویر فازی با استفاده از تابع عضویت μ_2.

در شکل ۹ مراحل ایجاد تصویر فازی شار نوری نشان داده شده است. همان‌طور که در قسمت (الف) این شکل نشان داده شده ابتدا تصویر شار نوری فازی برای هر فریم ایجاد، سپس در قسمت (ب) یک تصویر کامل از تمام تصاویر مرحله قبل ایجادشده است.

در شکل ۱۰ نمونه‌هایی از تصویر فازی برمبنای شار نوری نشان داده‌شده است. این تصاویر نشان می‌دهد تصویر فازی ایجادشده دارای اطلاعات حرکتی متمایز برای تشخیص نوع تعامل است.

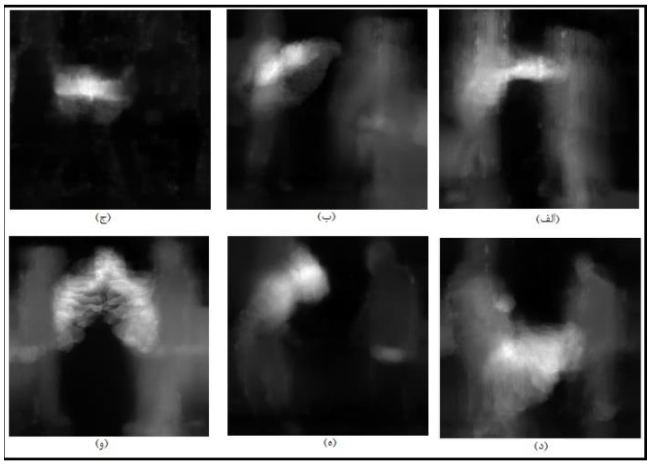

شکل ۱۰: نمونه‌ای از تصاویر شار نوری فازی به‌دست‌آمده؛ (الف)هل‌دادن، (ب) مشت‌زدن، (ج) دست‌دادن، (د) لگدزدن، (ه) تعظیم‌کردن، (و) بزن‌قدش.

۳-۴- شبکه عصبی عمیق

در بخش قبل فرآیند محاسبه تصویر فازی توضیح داده شد، مرحله بعد استخراج ویژگی از این تصاویر است. انتخاب ویژگی مهم‌ترین بخش برای نمایش ویژگی‌های مخفی و بصری داده است. به‌همین دلیل برای استخراج ویژگی از تصاویر فازی از یک شبکه کانولوشن استفاده شده است. در این کار از معماری AlexNet [۵] که بر روی ILSVRC-2012 [۳۹] آموزش داده‌شده، استفاده شده است. دو تصویر فازی استخراج‌شده از مرحله قبل هرکدام به یک شبکه CNN، از پیش‌آموزش‌داده‌شده، ارسال‌شده است. در مرحله آخر شبکه یک لایه softmax قرار داده‌شده که احتمال هر تصویر به کلاس‌های تعامل محاسبه می‌شود. دو خروجی از دو شبکه در یکدیگر ضرب شده و کلاسی که احتمال بیشتری دارد به‌عنوان کلاس تصاویر ورودی، نسبت داده می‌شود. ترکیب به‌صورت زیر انجام می‌شود[۴۰]:

$$label = F_{max}(v_1 \circ v_2) \quad (۹)$$

V بردار امتیازات است، ○ عملگر ضرب است و F_{max} تابعی است که ایندکسی که بیشترین مقدار را دارد، برمی‌گرداند.

۵- آزمایشات

در این بخش روش پیشنهادی ارزیابی و عملکرد آن با روش‌های دیگر مقایسه شده است. در بخش ۵-۱- دو مجموعه داده برای ارزیابی معرفی شده است. جزییات پیاده سازی در بخش ۵-۲- شرح داده شده است. در بخش ۵-۳- نتایج روش و تحلیل آن بیان شده است.

۵-۱- مجموعه داده

روش ارائه‌شده بر روی دو مجموعه داده تعامل که به‌طور گسترده بررسی و استفاده می شود به نام مجموعه داده تعامل BIT و UT چک شده است.

مجموعه داده تعامل BIT: این مجموعه داده شامل ۸ نوع تعامل (تعظیم‌کردن، مشت‌زدن، دست‌دادن، بزن‌قدش، بغل‌کردن، لگدزدن، نوازش‌کردن، هل‌دادن) بین دو انسان است [۴۱]. هر کلاس شامل ۵۰ ویدیو است. این مجموعه داده به‌خاطر تغییرات نور، تفاوت ظاهر و سایز افراد، نقطه دید و علاوه‌بر آن تصادم به‌دلیل وجود افراد دیگر، پل‌ها و .. بسیار چالش‌برانگیز است.

مجموعه داده تعامل UT: این مجموعه شامل دو دسته است [۴۲]. پیش‌زمینه دسته اول ساده و ایستاست. برخلاف آن مجموعه دوم دارای پیش‌زمینه پیچیده‌تر با حرکت ملایم است. هر مجموعه شامل ۶۰ ویدیو و شامل ۶ کنش دست‌دادن، بغل‌کردن، اشاره‌کردن، لگدزدن، هل‌دادن و مشت‌زدن است. هر ویدیوی تست تعامل را در ده نسبت مشاهده پیش‌بینی می‌کند. به‌عبارت دیگر ویدیو به ۱۰ قسمت تقسیم می‌شود.

۵-۲- جزییات پیاده‌سازی

برای انتخاب توابع عضویت استفاده در این مقاله، توابع گوسی، مثلثی و ذوزنقه موردبررسی قرار گرفت و با استفاده از آزمون هر تابع و محدوده های مختلف بهترین تابع با نظر افراد خبره برای هر حالت انتخاب شد. شبکه ارائه‌شده روی چهارچوب کافه[۱۸] [۴۳] پیاده‌سازی شده است. نرخ یادگیری برای تنظیم وزن‌ها ۰/۰۰۱ و پارامتر تنزل وزن ۰/۰۰۱ است. مقدار تعداد تکرار برای تنظیم وزن‌ها برابر ۱۰۰۰۰ تکرار است. در فاز تست، هر ویدئو به ۱۰ نرخ مشاهده از ۱/. تا یک تقسیم می‌شود. به‌طور مثال اگر ویدئویی n فریم داشته باشد و نرخ مشاهده p باشد $p \times n$ فریم اول برای استخراج تصویر فازی و پیش‌بینی تعامل استفاده خواهد شد.

۵-۳- نتایج و بحث

ابتدا نتایج دقت[۱۹] شبکه با ورودی تصویرگرادیان فازی و تصویر شارنوری فازی به صورت مجزا و ترکیب خروجی دو شبکه بر روی مجموعه داده BIT مورد بررسی قرار می‌گیرد. همان‌طور که در جدول ۱ نشان

www.SID.ir

Archive of SID

داده‌شده ترکیب نتایج با استفاده معادله (۶) نتایج بهتری را داشته است. در جدول ۱ نتایج بر اساس ترکیب نتایج این دو ورودی ارائه خواهد شد.

جدول ۱: دقت روش ارائه‌شده قبل از ترکیب نتایج شبکه

ورودی	دقت
تصویر گرادیان فازی	۸۵/۹۴
تصویر شارنوری فازی	۸۰/۴۷
هر دو تصویر	۸۹/۸۴

همان‌طور که در شکل ۱۱ نشان داده‌شده، تصاویر دو تعامل نشان داده‌شده است. تصویر (الف) و (ب) به‌ترتیب تصویر گرادیان فازی و تصویر شارنوری فازی مربوط به مشت‌زدن است که خروجی شبکه تصویر (ب) را به‌درستی مشت‌زدن و تصویر (الف) را به اشتباه هل‌دادن برچسب زده است، اما در هنگام ترکیب این دو نتیجه مشت‌زدن برگردانده شده است. در سطر دوم نیز تصویر (ج) و(د) به‌ترتیب تصویر گرادیان فازی و تصویر شارنوری فازی مربوط به تعامل بزن‌قدش است، خروجی شبکه برای تصویر (ج) به‌درستی تشخیص داده‌شده اما تصویر (د) را تعامل دست‌دادن برچسب زده است. در این حالت نیز ترکیب نتیجه دو شبکه نتیجه درست برگردانده است.

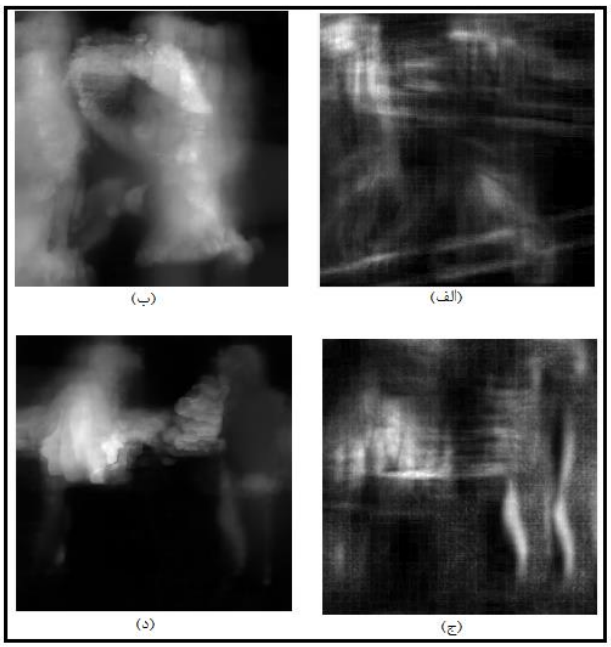

شکل ۱۱: سطر اول مربوط به تعامل مشت‌زدن؛ الف) تصویر گرادیان، ب) تصویر فازی شار نوری آن؛ سطر دوم مربوط به تعامل بزن‌قدش، ج) تصویر گرادیان، د) تصویر شارنوری.

در جدول ۲ نتایج مربوط به عدم اعمال تابع عضویت μ_1 و μ_2 نشان داده شده است. این نتایج بر روی مجموعه داده BIT و بر روی ساختار ارائه‌شده روش پیشنهادی است. در حالت اول تمام توابع عضویت به‌جز μ_1 و در حالت دوم تمام توابع عضویت به‌جز μ_2 اعمال شده است. همان‌طور که در جدول ۲ نشان داده شده، هنگامی‌که تابع عضویت فاصله زمانی در نظر گرفته نمی شود، دقت شبکه پایین می‌آید.

جدول ۲: دقت روش ارائه‌شده قبل از اعمال تابع عضویت μ_1 و μ_2

ورودی	دقت
قبل از اعمال تابع عضویت μ_1	۸۵/۱۶
بعد از اعمال تابع عضویت μ_2	۸۲/۰۳
بعد از اعمال تابع عضویت μ_1 و μ_2	۸۹/۸۴

در تصویر شارنوری اختلاف پیکسل‌ها در زمان محاسبه می‌شود، اما در تصویر گرادیان، اختلاف بین گرادیان‌ها محاسبه می‌شود.

در شکل ۱۲ ماتریس درهم‌ریختگی برای مجموعه داده BIT نشان داده‌شده است. همان‌طور که نشان داده‌شده در حالتی که کنش‌ها شبیه هم هستند به‌خاطر شباهت الگو حرکتی آن‌ها روش ارائه‌شده قادر به تشخیص نبوده است.

	دست‌دادن	بزن‌قدش	بغل‌کردن	تعظیم‌کردن	مشت‌زدن	لگدزدن	نوازش‌کردن	هل‌دادن
دست‌دادن	۱	-	-	-	-	-	-	-
بزن‌قدش	-	۰/۹۴	-	-	-	-	-	۰/۰۶
بغل‌کردن	-	-	۰/۸۸	-	-	۰/۰۶	-	۰/۰۶
تعظیم‌کردن	-	-	-	۰/۹۴	-	-	۰/۰۶	-
مشت‌زدن	-	-	-	-	۰/۹۴	-	۰/۰۶	-
لگدزدن	-	-	-	-	-	۰/۹۴	۰/۰۶	-
نوازش‌کردن	۰/۰۶	-	-	-	۰/۰۶	-	۰/۸۸	-
هل‌دادن	-	-	-	-	-	-	-	۱

شکل ۱۲: ماتریس درهم‌ریختگی بر روی مجموعه BIT

نمونه‌ای از تصاویر گرادیان فازی و شارنوری فازی مربوط به تعامل تعظیم‌کردن در نرخ‌های مشاهده مختلف در شکل ۱۳ نشان داده شده است.

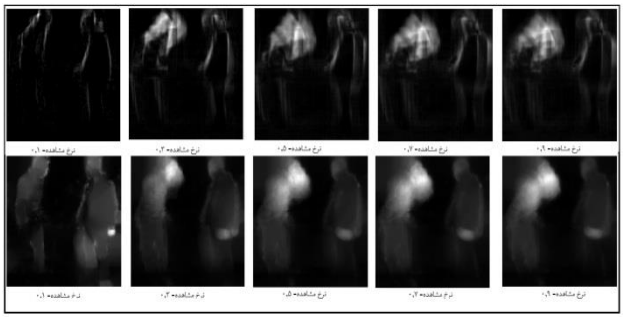

شکل ۱۳: نمونه‌ای از تصاویر مربوط به تعامل تعظیم‌کردن از مجموعه داده BIT، سطر اول: تصاویر گرادیان فازی با نرخ ۰/۱، ۰/۳، ۰/۵، ۰/۷، ۰/۹؛ سطر دوم: تصاویر شارنوری فازی با نرخ ۰/۱، ۰/۳، ۰/۵، ۰/۷، ۰/۹.

این روش را با سایر روش‌های تشخیص و پیش‌بینی تعامل مقایسه شده است. نتایج در شکل ۱۴(الف) و جدول ۳، نشان می‌دهد روش ارائه‌شده در ۵ نرخ مشاهده از ۱۰ نرخ بهترین دقت را داشته است.

www.SID.ir

Archive of SID

به‌طور مثال هنگامی‌که ۰/۷ فریم‌های یک ویدئو دیده شده حدود ۵ در صد روش ارائه شده دقت بهتری دا شته ا ست. در حالتی که نرخ بین ۰/۲ تا ۰/۵ از ویدئو مشاهده شده، روش ارائه دقت خیلی پایینی نسبت به روش‌های قبلی نداشته و تقریباً به بقیه روش‌ها نزدیک است.

نتایج این روش بر روی مجموعه داده UT نیز بررسی شده است. همان‌طور که در بخش ۵-۱- ذکر شد، این مجموعه شامل دو دسته است. نتایج بر روی دسته اول در

جدول ۴، شکل ۱۴(ب) و نتایج بر د سته دوم در جدول ۵، شکل ۱۴(ج) نشان داده شده ا ست. روش ارائه شده بر روی د سته اول در نرخ مشاهده ۰/۶، ۰/۸، ۰/۹ و یک، و بر روی دسته دوم در نرخ مشاهده ۰/۴، ۰/۷، ۰/۸، ۰/۹ و یک، نتایج بهتری داشته است. نتایج در سایر نرخ‌های مشاهده تقریباً مانند روش‌های دیگر بوده و دقت خوبی دا شته است.

همان‌طور که نتایج نشان می‌دهد، دقت روش در نرخ‌های پایین افزایش چندانی نسبت به روش‌های دیگر نداشته است.

دلیل این مسئله این است که تصویر فازی ایجادشده به‌دلیل جابه‌جایی کم و آغازی یک کنش اطلاعات حرکتی زیادی ندارد اما هر چه به سمت انجام کنش حرکت می‌کند تصاویر اطلاعات حرکتی بیشتری خواهند داشت.

روش پیشنهادی و سایر روش‌ها هنوز توانسته‌اند در نرخ‌های مشاهده بالا (۰/۹ و یک) به‌دقت ۱۰۰٪ بر سند، این به‌دلیل چالش‌های موجود مانند سرعت حرکت افراد و نحوه اجرای متفاوت آنان در انجام یک تعامل یکسان است.

روش LSCM نسبت به روش‌های ارائه‌شده قبلی نتیجه بهتری دارد این روش بر مبنای شبکه LSTM ا ست و نیاز به محا سبات بالایی دارد اما روش ما توا نسته با محا سبات کم‌تر نتایج مورد قبولی دا شته با شد. در این حالت فقط یک ت صویر به شبکه ار سال می شود درحالی‌که در بقیه روش‌ها تصویر فریم به فریم ویدئو باید به شبکه ارسال شود.

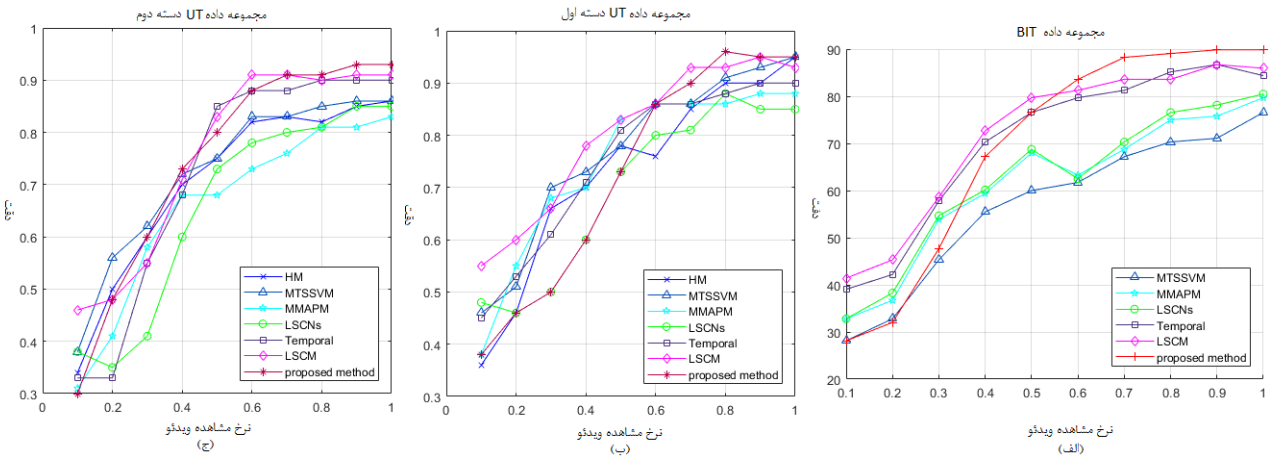

شکل ۱۴: مقایسه دقت مجموعه داده؛ الف) BIT، ب) UT دسته اول، ج) UT دسته دوم، با سایر روش‌ها.

جدول ۳: نتایج دقت پیش‌بینی تعامل روی مجموعه داده BIT با نرخ‌های مشاهده متفاوت

روش	نرخ مشاهده									
	۰/۱	۰/۲	۰/۳	۰/۴	۰/۵	۰/۶	۰/۷	۰/۸	۰/۹	۱
MTSSVM[13]	۲۸/۱۳	۳۲/۸۱	۴۵/۳۱	۵۵/۴۷	۶۰	۶۱/۷۲	۶۷/۱۹	۷۰/۳۱	۷۱/۰۹	۷۶/۵۶
MMAPM[14]	۳۲/۸۱	۳۶/۷۲	۵۳/۹۰	۵۹/۳۸	۶۷/۹۷	۶۳/۲۸	۶۸/۷۵	۷۵	۷۵/۷۸	۷۹/۶۹
LSCNs[28]	۳۲	۳۸	۵۴	۶۰	۶۸	۶۲	۷۰	۷۶	۷۸	۸۰
Temporal[26]	۳۹/۰۶	۴۲/۱۹	۵۷/۸۱	۷۰/۳۰	۷۶/۵۶	۷۹/۶۹	۸۱/۲۵	۸۵/۱۶	۸۶/۷۲	۸۴/۳۸
LSCM[27]	**۴۱/۴۱**	**۴۵/۳۱**	**۵۸/۵۹**	**۷۲/۶۶**	**۷۹/۶۹**	۸۱/۲۵	۸۳/۵۹	۸۳/۵۹	۸۶/۷۲	۸۵/۹۴
روش ارائه‌شده	۲۸/۱۳	۳۲/۰۳	۴۷/۶۶	۶۷/۱۹	۷۶/۵۶	**۸۳/۵۹**	**۸۸/۲۵**	**۸۹/۰۶**	**۸۹/۸۴**	**۸۹/۸۴**

www.SID.ir

Archive of SID

جدول ۴: نتایج دقت پیش‌بینی تعامل روی مجموعه داده دسته اول UT با نرخ‌های مشاهده متفاوت

روش	نرخ مشاهده									
	۰/۱	۰/۲	۰/۳	۰/۴	۰/۵	۰/۶	۰/۷	۰/۸	۰/۹	۱
HM[11]	۰/۳۸	۰/۵۵	۰/۶۸	۰/۷	۰/۸۳	۰/۸۶	۰/۸۶	۰/۸۶	۰/۸۸	۰/۸۸
MTSSVM[13]	۰/۳۶	۰/۴۶	۰/۶۶	۰/۷	۰/۷۸	۰/۷۶	۰/۸۵	۰/۹	۰/۹	۰/۹۵
MMAPM[14]	۰/۴۶	۰/۵۱	۰/۷۰	۰/۷۳	۰/۷۸	۰/۸۶	۰/۸۶	۰/۹۱	۰/۹۳	۰/۹۵
LSCNs[28]	۰/۴۸	۰/۴۶	۰/۵	۰/۶	۰/۷۳	۰/۸	۰/۸۱	۰/۸۸	۰/۸۵	۰/۸۵
Temporal[26]	۰/۴۵	۰/۵۳	۰/۶۱	۰/۷۱	۰/۸۱	۰/۸۶	۰/۸۶	۰/۸۸	۰/۹	۰/۹
LSCM[27]	**۰/۵۵**	**۰/۶**	**۰/۶۶**	۰/۷۸	**۰/۸۳**	۰/۸۶	**۰/۹۳**	۰/۹۳	**۰/۹۵**	۰/۹۳
روش ارائه‌شده	۰/۳۸	۰/۴۶	۰/۵	۰/۶	۰/۷۳	۰/۸۶	۰/۹	**۰/۹۶**	**۰/۹۵**	**۰/۹۵**

جدول ۵: نتایج دقت پیش‌بینی تعامل روی مجموعه داده دسته دوم UT با نرخ‌های مشاهده متفاوت

روش	نرخ مشاهده									
	۰/۱	۰/۲	۰/۳	۰/۴	۰/۵	۰/۶	۰/۷	۰/۸	۰/۹	۱
HM[11]	۰/۳۱	۰/۴۱	۰/۵۸	۰/۶۸	۰/۶۸	۰/۷۳	۰/۷۶	۰/۸۱	۰/۸۱	۰/۸۳
MTSSVM[13]	۰/۳۴	۰/۵	۰/۶	۰/۷	۰/۷۵	۰/۸۲	۰/۸۳	۰/۸۲	۰/۸۵	۰/۸۶
MMAPM[14]	۰/۳۸	**۰/۵۶**	**۰/۶۲**	۰/۷۲	۰/۷۵	۰/۸۳	۰/۸۳	۰/۸۵	۰/۸۶	۰/۸۶
LSCNs[28]	۰/۳۸	۰/۳۵	۰/۴۱	۰/۶	۰/۷۳	۰/۷۸	۰/۸	۰/۸۱	۰/۸۵	۰/۸۵
Temporal[26]	۰/۳۳	۰/۳۳	۰/۵۵	۰/۶۸	**۰/۸۵**	۰/۸۸	۰/۸۸	۰/۹	۰/۹	۰/۹
LSCM[27]	**۰/۴۶**	۰/۴۸	۰/۵۵	۰/۷۱	۰/۸۳	**۰/۹۱**	۰/۹۱	۰/۹	۰/۹۱	۰/۹۱
روش ارائه‌شده	۰/۳	۰/۴۸	۰/۶	**۰/۷۳**	۰/۸	۰/۸۸	۰/۹۱	**۰/۹۱**	**۰/۹۳**	**۰/۹۳**

۶- نتیجه‌گیری

در این مقاله یک شبکه عصبی عمیق برای پیش‌بینی تعامل با استفاده از روابط فازی و شار نوری ارائه‌شده است. در این روش ابتدا یک تصویر فازی بر مبنای گرادیان و یک تصویر فازی بر مبنای شار نوری ایجاد شده، سپس با استفاده از شبکه کانولوشن از این تصاویر ویژگی استخراج شده و در نهایت خروجی شبکه با یکدیگر ترکیب شده است. تصویر فازی ارائه شده دارای اطلاعات حرکتی مناسب برای تشخیص و پیش‌بینی تعامل است.

این تصویر ترکیبی از اطلاعات حرکتی مناسب در زمان‌های انجام فرآیند تعامل است، به‌همین دلیل به‌جای بررسی ویژگی‌های تک‌تک فریم‌های یک ویدئو فقط اطلاعات مناسب استخراج می شود. در روش پیشنهادی بر محدودیت بالابودن کنتراست فریم‌های رنگی برای استخراج ویژگی‌های ظاهری از تصاویر غلبه شده است.

در تصویر شارنوری اختلاف پیکسل‌ها در زمان، در تصویر گرادیان، اختلاف بین گرادیان‌ها محاسبه می شود، ترکیب نتایج دسته‌بندی این دو تصویر باعث بهبود دقت شده است. نتایج بر روی دو مجموعه داده استاندارد UT و BIT نشان داده که روش ارائه‌شده دقت قابل‌قبولی داشته است. در آینده هدف توسعه این روش را برای پیش‌بینی تعامل در فعالیت‌های گروهی و پیش‌بینی کنش‌های فردی است.

مراجع

[1] M. S. Ryoo, "Human activity prediction: Early recognition of ongoing activities from streaming videos," IEEE International Conference on Computer Vision, 2011.

[2] M. Ramanathan, W. Y. Yau and E. K. Teoh, "Human action recognition with video data: research and evaluation challenges," IEEE Transactions on Human-Machine Systems, vol. 44, no. 5, pp. 650-663, 2014.

[3] N. G. Cho, S. H. Park, J. S. Park, U. Park and S. W. Lee, "Compositional interaction descriptor for human interaction recognition," Neurocomputing, vol. 265, pp. 169-181, 2017.

[۴] امیر سزاوار، حسن فرسی، سجاد محمدزاده، «بازیابی تصویر مبتنی بر محتوا با استفاده از شبکه‌های عصبی کانولوشن عمیق»، مجله مهندسی برق دانشگاه تبریز، جلد ۴۸، شماره ۴، صفحه ۱۶۰۳- ۱۵۹۵، زمستان ۱۳۹۷.

[5] A. Krizhevsky, I. Sutskever and G.E. Hinton, "Imagenet classification with deep convolutional neural networks," Advances in Neural Information Processing Systems, pp.1097-1105, 2012.

[6] G. Acampora, P. Foggia, A. Saggese and M. Vento, "Combining neural networks and fuzzy systems for human behavior understanding," IEEE International Conference on Advanced Video and Signal-based Surveillance, 2012.

[7] J. Y. Chang, J. J. Shyu, and C. W. Cho, "Fuzzy rule inference based human activity recognition," IEEE Conference on Control Applications and IEEE International Symposium on Intelligent Control, 2009.

[8] H. Medjahed, D. Istrate, J. Boudy and B. Dorizzi, "Human activities of daily living recognition using fuzzy logic for elderly home monitoring," IEEE International Conference on Fuzzy Systems, 2009.

www.SID.ir

Archive of SID

[۹] ندا خانبانی، امیرمسعود افتخاری مقدم، «ارائه یک روش تشخیص زبان علامت مبتنی بر رویکرد MLRF فازی با استفاده از اطلاعات عمق تصویر»، مجله مهندسی برق دانشگاه تبریز، ۱۳۹۶ مجله مهندسی برق دانشگاه تبریز، جلد ۴۷، شماره ۳، صفحه ۹۸۷-۹۷۷، پاییز۱۳۹۶.

[10] N. P. Trong, H. Nguyen, K. Kazunori and B. Le Hoai, "A comprehensive survey on human activity prediction," International Conference on Computational Science and Its Applications, Springer, 2017.

[11] T. Lan, T. C. Chen, and S. Savarese, "A hierarchical representation for future action prediction," European Conference on Computer Vision, Springer, 2014.

[12] C. Gao, L. Yang, Y. Du, Z. Feng and J. Liu, "From constrained to unconstrained datasets: an evaluation of local action descriptors and fusion strategies for interaction recognition," World Wide Web, vol. 19, no. 2, pp. 265-276, 2016.

[13] Y. Kong, D. Kit, and Y. Fu, "A discriminative model with multiple temporal scales for action prediction," European Conference on Computer Vision, Springer, 2014.

[14] Y. Kong and Y. Fu, "Max-margin action prediction machine," IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 38, no. 9, pp. 1844-1858, 2016.

[15] W. Choi, K. Shahid, and S. Savarese, "What are they doing?: Collective activity classification using spatio-temporal relationship among people," IEEE International Conference on Computer Vision, Workshops, pp. 1282-1289, 2009.

[16] Z. Wang, S. Liu, J. Zhang, S. Chen, and Q. Guan, "A spatio-temporal CRF for human interaction understanding," IEEE Transactions on Circuits and Systems for Video Technology, vol. 27, no. 8, pp. 1647-1660, 2017.

[17] J. M. Le Yaouanc and J.-P. Poli, "A fuzzy spatio-temporal-based approach for activity recognition," International Conference on Conceptual Modeling, Springer, 2012.

[18] B. Yao, H. Hagras, M. J. Alhaddad and D. Alghazzawi, "A fuzzy logic-based system for the automation of human behavior recognition using machine vision in intelligent environments," Soft Computing, vol. 19, no. 2, pp. 499-506, 2015.

[19] K. Mozafari, N. M. Charkari, H. S. Boroujeni and M. Behrouzifar, "A novel fuzzy hmm approach for human action recognition in video," Knowledge Technology, Springer, pp. 184-193, 2012.

[20] M. Raptis and L. Sigal, "Poselet key-framing: A model for human activity recognition," IEEE Conference on Computer Vision and Pattern Recognition, 2013.

[21] A. Iosifidis, A. Tefas, and I. Pitas, "Activity-based person identification using fuzzy representation and discriminant learning," IEEE Transactions on Information Forensics and Security, vol. 7, no. 2, pp. 530-542, 2012.

[22] L. Nanni, S. Ghidoni, and S. Brahnam, "Handcrafted vs. non-handcrafted features for computer vision classification," Pattern Recognition, vol. 71, pp. 158-172, 2017.

[23] E. P. Ijjina and K. M. Chalavadi, "Human action recognition in RGB-D videos using motion sequence information and deep learning," Pattern Recognition, vol. 72, pp. 504-516, 2017.

[24] H. J. Kim, J. S. Lee, and H. S. Yang, "Human action recognition using a modified convolutional neural network," International Symposium on Neural Networks, Springer, 2007.

[25] R. J. Moreno, O. A. Sanchez, and D. M. Ovalle, "RGB-D training for convolutional neural network with final fuzzy layer for depth weighting," Contemp. Eng. Sci., vol. 10, no. 29, pp. 1419-1429, 2017.

[26] Q. Ke, M. Bennamoun, S. An, F. Boussaid, and F. Sohel, "Human interaction prediction using deep temporal features," European Conference on Computer Vision, Springer, 2016.

[27] Q. Ke, M. Bennamoun, S. An, F. Sohel and F. Boussaid, "Leveraging structural context models and ranking score fusion for human interaction prediction," IEEE Transactions on Multimedia, vol. 20, no. 7, pp. 1712-1723, 2018.

[28] J. Donahue, L. Anne Hendricks , S. Guadarrama, M. Rohrbach, S. Venugopalan, K. Saenko, and T. Darrell, "Long-term recurrent convolutional networks for visual recognition and description," IEEE Conference on Computer Vision and Pattern Recognition, 2015.

[29] A. Stergiou and R. Poppe, "Understanding human-human interactions: a survey," arXiv preprint arXiv:1808.00022, 2018.

[30] X. Wang and J.M. Keller, "Human-based spatial relationship generalization through neural/fuzzy approaches," Fuzzy Sets and Systems, vol. 101, no. 1, pp. 5-20, 1999.

[31] R. Pierrard, J. P. Poli, and C. Hudelot, "Learning Fuzzy Relations and Properties for Explainable Artificial Intelligence," IEEE International Conference on Fuzzy Systems, 2018.

[32] H. Hüttenrauch, K. S. Eklundh, A. Green and E. A. Topp, "Investigating spatial relationships in human-robot interaction," International Conference on Intelligent Robots and Systems, 2006.

[33] I. Bloch, "Fuzzy spatial relationships for image processing and interpretation: a review," Image and Vision Computing, vol. 23, no. 2, pp. 89-110, 2005.

[34] A. Delmonte, I. Bloch, D. Hasboun, C. Mercier, J. Pallud and P. Gori, "Segmentation of white matter tractograms using fuzzy spatial relations," Organization for Human Brain Mapping, 2018.

[35] J. J. Gibson, *The perception of the visual world*, 1950.

[36] T. Brox, A. Bruhn, N. Papenberg, and J. Weickert, "High accuracy optical flow estimation based on a theory for warping," European conference on Computer Vision, Springer, 2004.

[37] S. Baker, D. Scharstein, J. P. Lewis, S. Roth, M. J. Black and R. Szeliski, "A database and evaluation methodology for optical flow," International Journal of Computer Vision, vol. 92, no. 1, pp. 1-31, 2011.

[38] A. Ess, B. Leibe, K. Schindler and L. Van Gool, "A mobile vision system for robust multi-person tracking," IEEE Conference on Computer Vision and Pattern Recognition, 2008.

[39] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma and A. C. Berg, "Imagenet large scale visual recognition challenge," International Journal of Computer Vision, vol. 115, no. 3, pp. 211-252, 2015.

[40] C. Li, Y. Hou, P. Wang, and W. Li, "Joint distance maps based action recognition with convolutional neural networks," IEEE Signal Processing Letters, vol. 24, no. 5, pp. 624-628. 2017.

[41] Y. Kong, Y. Jia, and Y. Fu., "Learning human interaction by interactive phrases," European Conference on Computer Vision, Springer, 2012.

[42] M. S. Ryoo and J. Aggarwal., "UT-interaction dataset, ICPR contest on semantic description of human activities (SDHA)," IEEE International Conference on Pattern Recognition Workshops, 2010.

[43] Y. Jia, E. Shelhamer, J. Donahue, S. Karayev, J. Long, R. Girshick, and T. Darrell, "Caffe: Convolutional architecture for fast feature embedding," ACM International Conference on Multimedia, 2014.

زیرنویس‌ها

[1] Motion Energy Image
[2] Motion History Image
[3] Convolutional Neural Network
[4] Optical Flow
[5] Long short-term memory
[6] Histogram of Gradient
[7] Histogram of Optical Flow
[8] Motion Boundary Histogram
[9] Space Time Interest Points
[10] Hierarchical Movemes
[11] Support Vector Machine
[12] Scale-invariant feature transform
[13] Multiple Temporal Scale Support Vector Machine
[14] Bag of Word
[15] Max-Margin Action Prediction Machine
[16] silhouette
[17] handcrafted
[18] Caffe
[19] Accuracy

www.SID.ir