

دریافت مقاله: ۱۴۰۳/۰۵/۲۸

پذیرش مقاله: ۱۴۰۳/۰۶/۱۸

نوع مقاله: پژوهشی

یک روش نیمه نظارت شده و مبتنی بر شباهت حالت بدن برای تشخیص ناهنجاری رفتاری مرتبط با تقلب در ویدئوهای نظارتی آزمون‌های الکترونیکی

حبیب الله آق آتابای*

آزمایشگاه پردازش تصویر و داده کاوی، دانشگاه صنعتی شاهرود، شاهرود، ایران
پست الکترونیکی: habib.atabay@shahroodut.ac.ir

حمید حسن پور

استاد، آزمایشگاه پردازش تصویر و داده کاوی، دانشگاه صنعتی شاهرود، شاهرود، ایران
پست الکترونیکی: h.hassanpour@shahroodut.ac.ir

چکیده

تشخیص ناهنجاری در ویدئوهای نظارتی مرتبط با رفتارهای انسانی در کاربردهای مختلف از اهمیت بسیاری برخوردار است. در آزمون‌های الکترونیکی، امکان شناسایی تقلب از طریق دوربین‌های نظارتی وجود دارد، اما تحقیقات گذشته بیشتر بر الگوهای از پیش تعریف شده متمرکز بوده و به روش‌هایی که رفتارهای غیرعادی را بدون مشاهده نمونه‌هایی از آنها می‌توانند تشخیص دهند، کمتر پرداخته‌اند. این مطالعه یک رویکرد نیمه‌نظارت شده^۱ مبتنی بر اسکلت بدن برای تشخیص رفتارهای غیرطبیعی در ویدئوهای نظارتی آزمون‌های الکترونیکی پیشنهاد می‌دهد. روش ارائه شده، بردارهای ویژگی مبتنی بر اسکلت قاب‌های متوالی را بر اساس شباهت آن‌ها تقسیم‌بندی می‌کند. شباهت با استفاده از فاصله اقلیدسی بین مفاصل اسکلت‌ها و میانگین و انحراف معیار آنها محاسبه می‌شود. سپس بخش‌های مشابه از مجموعه آموزشی، که فاقد ناهنجاری هستند، ترکیب شده

و بخش‌های متمایزی را تشکیل می‌دهند که برای تشخیص نمونه‌های عادی استفاده می‌شوند. در مرحله آزمایش، قابی که به هیچ یک از الگوهای به‌دست آمده از مرحله آموزش شباهت نداشته باشد، به عنوان ناهنجاری تشخیص داده می‌شود. برای بهبود رتبه‌بندی قاب‌های غیرهنجار، از تخصیص امتیاز ناهنجاری با در نظر گرفتن اندازه قطعه و حداکثر فاصله بین ویژگی‌ها استفاده شده است. در مقایسه با الگوریتم‌های پیشرفته تشخیص ناهنجاری مبتنی بر بازسازی داده‌ها، روش پیشنهادی در معیار AUC ۱۲ درصد بهبود را نشان داده و به عدد ۰/۸۳ دست یافت. همچنین با تعیین برچسب داده‌ها بدون نیاز به پردازش تمام ورودی‌ها، امکان استفاده از این روش در کاربردهای برخط نیز وجود دارد.

واژه‌های کلیدی: نظارت ویدئویی، آزمون الکترونیکی، تشخیص ناهنجاری نیمه‌نظارت شده، ویژگی‌های مبتنی بر اسکلت، تشخیص تقلب، اندازه‌گیری شباهت اسکلت

* نویسنده مسئول

۱. مقدمه

حفظ یکپارچگی و صداقت تحصیلی در طول آزمون الکترونیکی از راه دور (آزمون الکترونیکی) در مقایسه با آزمون‌های حضوری سنتی چالش قابل توجهی است. نمای محدود دوربین و دشواری‌های نظارت بر چندین آزمون‌دهنده به‌طور هم زمان، تشخیص تقلب در آزمون الکترونیکی را پیچیده‌تر می‌کند. علاوه بر این، در صورتی که امکان مرور ویدئوهای آزمون‌ها فراهم باشد، بررسی دستی تعداد زیادی از این ویدیوها فرآیندی زمان بر است. توسعه سیستم‌های هوشمند برای خلاصه کردن ویدئوهای آزمون الکترونیکی برای غلبه بر این محدودیت‌ها ضروری است. این سیستم‌ها می‌توانند به‌طور خودکار صحنه‌های مشکوک به تقلب را شناسایی کنند و برش‌های کوتاه‌تری از ویدئوها را برای بررسی سریع‌تر و کارآمدتر توسط ناظر انسانی تولید کنند.

در نظارت بر آزمون سنتی، از ناظران انسانی برای جلوگیری از تقلب استفاده می‌شود. استفاده از ناظران انسانی برای نظارت بر آزمون برخط از طریق ویدئوهای نظارتی نیز یک روش رایج برای حفظ صداقت در آزمون‌های راه دور است. با این حال، عیب روش سنتی، هزینه‌ای است که برای استخدام افراد برای نظارت بر آزمون تحمیل می‌شود. نظارت برخط انسانی همچنان مشکلات نظارت حضوری از جمله نیاز به نیروی انسانی مجرب و مورد اعتماد سیستم آموزشی و عدم وجود روش‌های ارزیابی استاندارد برای سنجش اثربخشی آنها را دارد. استفاده از سیستم‌های هوشمند پردازش ویدئو هم می‌تواند از میزان کار نیروی انسانی بکاهد و هم امکان استناد به شواهد استخراج شده از ویدئو را فراهم می‌آورد.

اگرچه سیستم‌های نظارتی نیمه‌خودکار در دسترس هستند، یک بررسی اخیر [۱] اشاره می‌کند که این سیستم‌ها عمدتاً بر روی ویژگی‌های چهره [۲، ۳]، ردیابی نگاه [۴، ۵]، تجزیه و تحلیل داده‌های ترافیک شبکه [۶] و تشخیص تغییر IP [۶] تمرکز داشته‌اند، در حالی که تجزیه و تحلیل زبان

بدن را نادیده می‌گیرند. اگرچه در [۷] نویسندگان با ترکیب موقعیت دست‌ها با زوایای چرخش سر و انحراف آن که توسط دوربین Microsoft Kinect استخراج می‌شود، پایه‌گذار استفاده از حالت بالاتنه بدن در تشخیص تقلب در آزمون‌های راه دور بودند، اما این روش در سایر آثار دنبال نشده و آنها به ویژگی‌های استخراج شده محدودتر مانند زوایای چرخش سر تکیه کرده [۸، ۹] و عمدتاً از قوانین از پیش تعریف شده یا مدل‌های آموزش داده شده به روش نظارت شده برای تشخیص تقلب استفاده کرده‌اند. متأسفانه، هنگام نظارت بر گروه بزرگی از شرکت‌کنندگان که حالت‌های نشستن متفاوتی دارند، این روش ممکن است به‌تنهایی چندان موفق نباشد [۱]. علاوه بر این، در پژوهش‌های گذشته، رفتارهای ناهنجار عمدتاً به الگوهای از پیش تعریف شده مشخص محدود شده‌اند و روش‌های بدون نظارت یا نیمه‌نظارت به‌ندرت مورد توجه قرار گرفته‌اند. بنابراین، از نظر ما، ترکیبی از حالت‌های سر و دست باید برای تشخیص تقلب علاوه بر روش‌های تشخیص بدون نظارت در نظر گرفته شود که این یک خلأ در پژوهش‌های گذشته در این زمینه بوده است.

تشخیص رفتارهای غیرعادی (ناهنجار) در طول آزمون می‌تواند به تشخیص تقلب کمک شایانی نماید. تشخیص ناهنجاری شامل شناسایی موارد و رویدادهایی است که به‌ندرت در داده‌های آموزشی موجود رخ می‌دهد. به عبارت دیگر، تشخیص ناهنجاری روشی برای جستجوی مفاهیمی است که کمتر رخ می‌دهند. تشخیص ناهنجاری در ویدیوها یک مسئله چالش برانگیز در بینایی رایانه است، زیرا شناسایی رویدادهای غیرمعمول معمولاً به اطلاعات زمینه‌ای و محیط اطراف متکی است و به پیچیدگی کار می‌افزاید. یکی از کاربردهای تشخیص ناهنجاری رفتاری، در نظارت تصویری آزمون از راه دور و الکترونیکی (آزمون الکترونیکی) برای تشخیص رفتارهای غیرمجاز و رویدادهای تقلب است که موضوعی چالش برانگیز است. روش‌های یادگیری نظارت‌نشده و نیمه‌نظارت‌نشده برای

با تقسیم توالی قباب ویدئوهای آموزشی به بخش‌های متوالی در مرحله آموزش شروع می‌کند. سپس، بخش‌های مشابه برای تولید خوشه‌های آموزشی ادغام می‌شوند. برای مشخص کردن ناهنجاری، ما یک برچسب مجزا (صفر یا یک) یا امتیاز ناهنجاری (از صفر تا یک) به هر قباب اختصاص می‌دهیم. در مرحله ارزیابی، شباهت بین ویژگی‌های مبتنی بر اسکلت هر قباب و قطعات شناسایی شده در مجموعه آموزشی اندازه‌گیری می‌شود و از حداکثر فاصله هر ویژگی قباب و اندازه بخش‌های آموزشی برای محاسبه امتیاز ناهنجاری استفاده می‌شود. برای تخصیص برچسب ناهنجاری از معیارهای انحراف معیار استفاده می‌شود به طوری که اگر فاصله تمام ویژگی‌های اسکلت در قباب مورد مشاهده با ویژگی‌های متناظر در بردار ویژگی میانگین یک خوشه آموزشی در محدوده انحراف معیار قرار گیرد، آن قباب نرمال در نظر گرفته می‌شود (با برچسب صفر).

روش پیشنهادی بر روی مجموعه داده جمع‌آوری شده متشکل از ۹۱ ویدئوی آزمون الکترونیکی آزمایشی ارزیابی شده است. بخش اول (قباب‌های ابتدایی) از هر ویدیو به عنوان داده‌های آموزشی استفاده می‌شود. دو رویکرد برای آموزش در نظر گرفته شده است. رویکرد کلی (GM) که از بخش‌های آغازین تمام ویدیوهای موجود در مجموعه داده به عنوان یک مجموعه آموزشی برای استخراج الگوهای نرمال استفاده می‌کند. دیگری رویکرد منحصراً به ویدئو (VSM) نام دارد که در آن هر ویدیو به طور جداگانه پردازش می‌شود. در حالی که قسمت آغازین هر ویدیو برای آموزش مدل مربوطه استفاده می‌شود، قسمت باقیمانده همان ویدیو برای آزمایش آن مدل استفاده می‌شود. در نهایت، نتایج با چندین الگوریتم تشخیص ناهنجاری نیمه نظارت شده مقایسه شده است. در تخصیص برچسب، معیار دقت^۳ در تشخیص نمونه‌های عادی و معیار فراخوانی^۴ در تشخیص نمونه‌های غیرطبیعی

کاربردهای تشخیص ناهنجاری مناسب هستند. روش‌های نظارت نشده هیچ دانش قبلی در مورد برچسب‌های داده ندارند در حالی که رویکردهای نیمه نظارت شده تنها از نمونه‌های محدودی یاد می‌گیرند. اساس آنها این است که وقایع عادی به وفور اتفاق می‌افتد در حالی که رویدادهای غیرعادی به ندرت رخ می‌دهد که این فرض در تشخیص ناهنجاری نیز صدق می‌کند.

در ویدئوهای نظارتی مرتبط با رفتار انسان، استخراج ویژگی‌های اسکلت بدن راه حل مناسبی برای استخراج الگوهای رفتاری آنهاست در حالی که استفاده از این ویژگی‌ها حفاظت از حریم خصوصی افراد را فراهم آورده و پیچیدگی روش‌ها را کاهش می‌دهد، به‌ویژه زمانی که تنها هدف آن تشخیص رفتارهای ناهنجار در کنش‌های انسان باشد. روش‌های مبتنی بر اسکلت [۱۰] فقط بر مفاصل بدن تمرکز می‌کنند و هویت چهره، اسکن کامل بدن یا اطلاعات پس زمینه را نادیده می‌گیرند. بنابراین، این روش‌ها نسبت به نوفل^۲ ناشی از روشنایی، جهت مشاهده و درهم‌ریختگی پس‌زمینه حساس نیستند و از بار اضافی مدل‌سازی تغییرات در آن نواحی صحنه رها می‌شوند.

ناهنجاری‌های رفتاری در طول آزمون به رفتارهای غیرعادی اشاره دارد که توسط آزمون‌دهندگان نشان داده می‌شود و ممکن است نشان‌دهنده تقلب در هنگام پاسخ دادن به سوالات آزمون باشد. هدف خاص در این پژوهش شناسایی رفتارهایی است که نشان‌دهنده تقلب در پشت صحنه ویدیو است. از آنجایی که نوع ناهنجاری با حالات و حرکات بدن داوطلب مرتبط است، استخراج ویژگی بر اساس اسکلت بدن مورد تأکید قرار گرفته است. این رویکرد نه تنها فرآیند تشخیص را تسهیل می‌کند، بلکه به حفظ حریم خصوصی شرکت‌کننده نیز کمک می‌کند. علاوه بر این، روش پیشنهادی یک روش نیمه نظارت شده است، زیرا رفتارهای غیرعادی افراد در طول آزمون بسیار متفاوت است، در حالی که نمونه‌هایی از رفتارهای عادی را می‌توان به راحتی جمع‌آوری کرد. روش پیشنهادی ابتدا

حدود ۹۹ درصد است، یعنی الگوریتم به درستی نمونه‌های آزمایشی مشابه قطعات آموزشی را تشخیص می‌دهد، اما دقت تشخیص نمونه‌های غیرعادی واقعی همچنان پایین است (حدود ۲۰ درصد). از نظر امتیازدهی ناهنجاری، عملکرد الگوریتم با استفاده از سطح زیر منحنی ROC یا AUC از الگوریتم‌های تشخیص ناهنجاری مبتنی بر بازسازی مقایسه شده، ۱۲ درصد بهتر عمل می‌کند و به عدد ۰/۸۳ در معیار AUC دست می‌یابد. از این الگوریتم می‌توان برای خلاصه کردن ویدیوهای انسان محور بر اساس شباهت حالت اسکلت استفاده کرد. یکی دیگر از مزایای روش ارائه شده نسبت به سایر روش‌های تشخیص ناهنجاری مبتنی بر بازسازی نیمه نظارت شده این است که برچسب‌های داده را بدون نیاز به پردازش تمام ورودی‌ها تعیین می‌کند که امکان استفاده از آن در کاربردهای برخط را فراهم می‌کند.

ساختار مقاله به صورت زیر است. بخش دوم، کارهای مرتبط در زمینه تشخیص تقلب در ویدئوهای آزمون‌های الکترونیکی را مرور می‌کند. بخش سوم، مجموعه داده به کاربرده شده و ویژگی‌های استخراج شده مبتنی بر اسکلت را توصیف می‌کند. بخش چهارم الگوریتم تشخیص ناهنجاری ویدیویی مبتنی بر اسکلت را پیشنهاد می‌کند. بخش پنجم نتایج آزمایش‌ها را ارائه می‌دهد و در بخش ششم خلاصه و جمع‌بندی مقاله ارائه می‌گردد.

۲. کارهای مرتبط

رویکردهای متعددی برای شناسایی عدم صداقت تحصیلی در آزمون‌های از راه دور پیشنهاد شده است که شامل نظارت بر انواع داده‌های متنوعی مانند متن، تصاویر، صدا، سیگنال‌های حرکتی و داده‌های شبکه است. در این مطالعه، ما دامنه تحقیق خود را بر تکنیک‌های تشخیص تقلب از طریق تجزیه و تحلیل ویدیویی متمرکز کردیم. برای تحلیل داده‌های ویدئویی از ویژگی‌های تصویری متنوعی که قابل استخراج از ویدئو هستند استفاده می‌شود.

رایج‌ترین انواع ویژگی‌های به کاربرده شده در کارهای گذشته حالت سر و جهت نگاه چشم [۴، ۱۱-۱۴] است. برخی دیگر از محققان حالت لب را نیز در کنار حالت چهره و جهت نگاه به کار برده‌اند [۱۵-۱۷]. برخی از کارها موقعیت دست‌ها در صفحه نمایش را به عنوان ویژگی کمکی برای تشخیص رفتارهای تقلب‌آمیز استفاده کرده‌اند [۷، ۱۸]. برخی از کارها نیز موقعیت نقاط کلیدی صورت را به خصوص برای تشخیص حالت چهره و در برخی موارد برای استخراج حالت سر به کار گرفته‌اند [۹، ۱۹] و اخیراً محققان از ویژگی‌های عمیق قاب‌های ویدئو، که اکثراً مبتنی بر شبکه‌های CNN هستند، نیز برای استخراج رفتارهای غیرعادی به خصوص تشخیص حالت چهره مورد استفاده قرار داده‌اند [۲۰-۲۲]. در کارهای گذشته حالت دست‌ها و بالاتنه بدن کمتر مورد توجه قرار گرفته است. با استفاده از ویژگی‌های مبتنی بر اسکلت بدن که در بسیاری از کاربردهای تشخیص ناهنجاری‌ها در ویدئو [۱۰] محبوبیت یافته‌اند، می‌تواند حالت بالاتنه را نیز در تشخیص رفتارهای مشکوک به تقلب در ویدئوهای نظارتی آزمون‌های راه دور به کار برد.

اکثر مقالات در این حوزه تحقیقاتی از مجموعه داده‌های خصوصی برای آزمایش‌های خود استفاده کرده‌اند، به جز مقاله‌ای که Atoum و همکاران [۴] منتشر کرده و در آن یک مجموعه داده عمومی، به نام نظارت بر آزمون برخط (OEP) را معرفی می‌کنند که حاوی ویدیوهای نمای جلو و نمای معکوس استفاده می‌کند. OEP همچنین در [۲۱] برای اعتبارسنجی روش تشخیص تقلب استفاده شده است. شایان ذکر است که تقریباً اکثر محققان به مجموعه داده‌های نسبتاً کوچکی متکی هستند که معمولاً شامل کمتر از ۵۰ نمونه هستند. متأسفانه، کمبود مجموعه داده‌های معیار در دسترس عموم، چالشی برای پیشبرد پیشرفت در این راستا است.

دو رویکرد اساسی در مقالات موجود در ادبیات این حوزه به کار برده شده‌اند، روش مبتنی بر قانون و

آزمایشی از راه دور است که حداکثر به مدت ۳۰ دقیقه برگزار می‌شود. ویدیوهای این مجموعه داده از نمای دوربین کناری گرفته شده و وضعیت کامل شرکت‌کنندگان در پشت میز کامپیوتر را نشان می‌دهد. از آنجایی که اکثر آثار مشابه از زاویه دید لپ‌تاپ (زاویه روبه‌رو) استفاده کرده‌اند، مجموعه داده جمع‌آوری شده متمایز است زیرا شامل حالت دست و بالاتنه است. قاب‌های ویدیویی با سرعت ۱ قاب در ثانیه توسط نرم‌افزار پیاده‌سازی شده برای برگزاری آزمون‌ها از راه دور ضبط شدند. قاب‌های ویدیویی بر اساس وضعیت فرد در صحنه در مورد وجود تقلب توسط مدرسان خبره برچسب‌گذاری شدند. چند تصویر نمونه از مجموعه داده مذکور در شکل (۱) نشان داده شده است. ویژگی‌های اسکلت استخراج شده از مجموعه داده‌های جمع‌آوری شده و کدهای پیاده‌سازی در صفحه GitHub نویسنده^۵ در دسترس محققان قرار می‌گیرد. از شرکت‌کنندگان خواسته شد که در ابتدای آزمون رفتار عادی داشته باشند تا بتوان از آن به‌عنوان مجموعه آموزشی برای روش‌های نیمه نظارت استفاده کرد.

فرض کنید مجموعه داده به‌صورت زیر بیان گردد:

$$\text{Dataset} = \{X^i \mid i \in 1..N^d\} \quad (1)$$

که در آن X^i ویژگی‌های فریم‌های ویدیو i و $N^d = 91$ تعداد ویدیوهای مجموعه داده است. X^i شامل قاب‌های آغازین X^{it} و قاب‌های باقیمانده X^{iv} است. به عبارت دیگر:

$$X^i = [X^{it}, X^{iv}], \quad X^{it} = \{F_k^i \mid k \in 0..N^{it}\}, X^{iv} = \{F_k^i \mid k \in N^{it}..N^i\} \quad (2)$$

که در آن F_k^i بردار ویژگی مبتنی بر اسکلت استخراج شده از قاب k ام از ویدیو i ام است و $N^{it} \approx 0.3 \times N^i$ یعنی تقریباً ۳۰ درصد از قاب‌های آغازین هر ویدیو بدون هیچ‌گونه ناهنجاری در نظر گرفته می‌شود. چارچوب MoveNet که در TensorFlow [۲۳] پیاده‌سازی شده است، برای استخراج ویژگی‌های اسکلت دو بعدی بدن

روش یادگیری نظارت شده. در رویکرد اول از هیچ مدل آموزشی استفاده نمی‌شود. در این موارد، قضاوت‌ها به قوانین و آستانه‌های از پیش تعریف شده‌ای که برای مقادیر ویژگی‌هایی مانند زوایای سر و نگاه چشم اعمال می‌شود، تکیه می‌کنند. از کاربرد این روش می‌توان به مراجعی مانند [۹، ۱۱، ۱۴] اشاره کرد. برعکس، برخی دیگر از محققان رویکرد آموزشی نظارت شده را اتخاذ کرده‌اند [۱۹-۲۱] که در این روش باید نمونه‌هایی برچسب‌دار از انواع الگوها چه نرمال و چه تقلب‌آمیز در دسترس باشد. قابل ذکر است که هیچ یک از کارهای گذشته، روش‌های آموزشی بدون نظارت را بررسی نکردند. از دیدگاه ما، رویکرد ایده‌آل برای این کار به سمت روش‌های بدون نظارت متمایل است، زیرا رفتارهای عادی در سناریوهای آزمون شایع‌تر هستند و تنوع کمتری از خود نشان می‌دهند، در حالی که رفتارهای غیرطبیعی آزمون معمولاً نادر و متنوع هستند. در نتیجه، در محیط‌های دنیای واقعی، مدل‌های تحت نظارت می‌توانند چالش‌ها و محدودیت‌هایی را ایجاد کنند.




شکل (۱): قاب‌های نمونه از ویدیوهای مجموعه داده جمع‌آوری شده

۳. مجموعه داده و استخراج ویژگی

برای آزمایش‌های این مقاله، مجموعه داده‌ای از ویدیوهای نظارتی برای هدف نهایی تشخیص تقلب در ویدیوهای آزمون الکترونیکی جمع‌آوری شد. این مجموعه داده شامل ۹۱ ویدیو از شرکت‌کنندگان در آزمون‌های

⁵ https://github.com/habibatabay/skeleton_clustering_anomaly



شکل (۲): (الف) محورهای چرخش سر شامل زوایای انحراف، گام و چرخش، (ب) تا (ه) موقعیت بینی (ن) و مرکز ثقل سر (س) را نشان می‌دهد. (ب) یک حالت طبیعی سر است و حالت‌های سر در (ج) تا (ه) غیرطبیعی در نظر گرفته می‌شود. در (ج) در مقایسه با (ب)، موقعیت (ن) هم در محور افقی و هم در محور عمودی (در فضای پیش‌بینی شده دو بعدی) تغییر کرده است. (د) بزرگترین تغییر در محور افقی مرکز سر قابل مشاهده است و در (ه) تفاوت کوچکی در مختصات افقی قابل مشاهده است. (ب) تا (ج) نشان می‌دهد که تغییرات در مختصات نقطه (ن) نسبت به (س) می‌تواند نشان‌دهنده تغییر در حالت سر باشد.


ارتفاع (محور عمودی) نسبت به مرکز ثقل نشان داد. زاویه چرخش به دلیل قرار گرفتن دوربین کمتر قابل محاسبه است و البته این زاویه در تشخیص تقلب اهمیت کمتری دارد. شکل (۲) زوایای سر و حالت‌ها را در سه موقعیت مختلف نشان می‌دهد. حالت سر با سه زاویه انحراف^۶، گام^۷ و چرخش^۸ بیان می‌شود. موقعیت متوسط بین دو مفصل گوش برای محاسبه مرکز ثقل سر استفاده می‌شود.

۴. روش پیشنهادی

شکل (۳) روند کلی روش تشخیص ناهنجاری پیشنهادی را نشان می‌دهد. پس از استخراج ویژگی‌های اسکلت از هر قاب ویدئو، قاب‌های متوالی با حالت‌های اسکلت مشابه با هم گروه‌بندی می‌شوند (شکل (۳.الف)). بخش‌های به‌دست آمده از ویدئوهای آموزشی بر اساس شباهت‌هایشان ادغام می‌شوند (شکل (۳.ب)) و حالت‌های متمایز شناسایی می‌شوند (شکل (۳.ج)). برای تشخیص بخش‌های غیرعادی در ویدیوی مورد آزمایش (در مرحله آزمایش) نیز، قاب‌های آن ابتدا مانند ویدیوی آموزشی قطعه‌بندی می‌شوند (شکل (۳.د)) و بخش‌هایی که شباهتی به بخش‌های شناسایی شده در مرحله آموزش ندارند به عنوان بخش‌های غیرعادی در نظر گرفته می‌شوند. ایده اصلی روش پیشنهادی، اندازه‌گیری شباهت بین حالت‌های اسکلت است که در دو حالت برچسب و امتیاز ناهنجاری

استفاده شد. MoveNet مختصات دو بعدی هر مفصل اسکلت را در محدوده نرمال [۰، ۱] استخراج می‌کند. در این مطالعه از مختصات دو بعدی مفاصل بالاتنه شامل ۱۱ وضعیت بینی، چشم چپ، چشم راست، گوش چپ، گوش راست، شانه چپ، شانه راست، آرنج چپ، آرنج راست، مچ دست چپ و مچ دست راست استفاده شد. بنابراین، ویژگی‌های پایه‌ای برای هر قاب یک بردار به طول ۲۲ را تشکیل می‌دهد. این مقاله علاوه بر مختصات مفصل دو بعدی، بردارهای ویژگی ساده شده را نیز آزمایش می‌کند که شامل ویژگی‌های سه نقطه مهم بدن یعنی بینی، مچ دست راست و مچ دست چپ است که یک بردار ویژگی به طول ۶ را تشکیل می‌دهد. ایده پشت این ساده‌سازی این است که شاید برای یک ناظر انسانی، محل قرارگیری مچ دست مهمتر از پیکربندی عضلات دست باشد. به عبارت دیگر، تغییر وضعیت دست بدون حرکت دادن مچ دست نمی‌تواند معنای خاصی داشته باشد. با این حال، تأیید اعتبار این نکته نیاز به بررسی و تجربه بیشتر دارد.

در مورد سر، از آنجایی که وضعیت سر یا جهت نگاه از اهمیت ویژه‌ای برخوردار است، مختصات خام بینی برای نشان دادن وضعیت سر مناسب نیست. به همین دلیل موقعیت بینی نسبت به مرکز ثقل سر یک ویژگی محسوب می‌شود. با این اصلاح، موقعیت بینی در امتداد محور افقی می‌تواند نشان‌دهنده تغییر در زاویه انحراف باشد و تغییرات در زاویه گام را می‌توان با موقعیت بینی در



شکل (۳): فرآیند کلی روش تشخیص ناهنجاری پیشنهادی: (الف) تقسیم‌بندی یک ویدیوی آموزشی بر اساس شباهت حالت‌های اسکلت، (ب) اسکلت متوسط برای هر بخش، (ج) ادغام بخش‌های مشابه، و (د) مقایسه بخش‌های شناسایی شده در ویدیوی آزمایشی با بخش‌های شناسایی شده در مرحله آموزش. بخش‌های (۱.د) و (۳.د) به ترتیب با بخش‌های مشابه (ج.۱) و (ج.۲) مطابقت دارند، در حالی که بخش‌های (۲.د) و (۳.د) را می‌توان به عنوان بخش‌های غیرعادی در نظر گرفت.

همچنین اندازه خوشه غیرعادی را برای کاهش امتیاز تحت تاثیر قرار می‌دهیم. امتیاز شباهت را می‌توان به صورت زیر بیان کرد.

$$SS^{ij} = w^j \left(1 - \frac{\max_{k \in 1..f} (|M_k^i - M_k^j|)}{\sum_{k \in 1..f} |M_k^i - M_k^j|} \right) \quad (4)$$

جایی که w^i اندازه خوشه i نسبت به حداکثر اندازه خوشه‌های شناسایی شده در ویدیو است و M^{ik} ویژگی بردار ویژگی متوسط قطعه است. ضریب w^i با این ایده اضافه شده است که هر چقدر یک الگوی حرکتی در زمان طولانی‌تری انجام شود احتمال ناهنجار بودن آن کاهش می‌یابد.

بر اساس اندازه‌گیری شباهت فوق، مراحل روش تشخیص ناهنجاری پیشنهادی به شرح زیر است: اگر X^i مجموعه قاب‌های آموزشی باشد.

(۱) اولین قدم تقسیم‌بندی قاب‌های هر ویدیوی آموزشی است. برای بخش بعدی یک توالی قاب، قاب‌ها را به ترتیب به یک بخش اضافه می‌کنیم تا زمانی که به بخش مورد نظر شباهت داشته باشد. اگر قاب بعدی به بخش جاری شبیه نباشد یک بخش جدید اضافه کرده و قاب بعدی را به همین ترتیب بررسی می‌کنیم. در نتیجه ما مجموعه‌ای از بخش‌های آموزشی S^i را خواهیم داشت:

محاسبه می‌شود. در حالت برچسب، شباهت را با یک برچسب دودویی صفر یا یک تعیین می‌کنیم. در حالی که، در حالت امتیاز ناهنجاری، امتیازی بین صفر تا یک به عنوان میزان ناهنجاری اختصاص می‌دهیم. برچسب شباهت، SL^{ij} ، بین دو قطعه از قاب‌ها، i و j ، را می‌توان به صورت زیر بیان کرد:

$$SL^{ij} = \begin{cases} 1: & D_k^{ij} < (SD_k^i + sd) \text{ or } D_k^{ij} < (SD_k^j + sd) \forall k \in 1..N^f \\ 0: & \text{otherwise} \end{cases} \quad (3)$$

میانگین بردارهای ویژگی (M^i و M^j)، N^f تعداد ویژگی‌ها، SD_k^i انحراف معیار ویژگی k قطعه i و sd مقدار افزوده انحراف معیار است. مقدار افزوده انحراف معیار برای جلوگیری از صفر بودن انحراف معیار یک قطعه (زمانی که فقط یک قاب دارد) در نظر گرفته می‌شود و همچنین این مقدار احتمال مشابه بودن آنها را تنظیم می‌کند. معادله (۳) نشان می‌دهد که اگر تفاوت همه فواصل متناظر دو اسکلت در محدوده انحراف معیار یکی از اسکلت‌ها قرار داشته باشد، آن دو اسکلت مشابه در نظر گرفته می‌شود در غیر این صورت متفاوت خواهند بود.

در حالت امتیازدهی از حداکثر تفاوت بین مقادیر ویژگی دو اسکلت متوسط به عنوان امتیاز تفاوت استفاده می‌کنیم.

جدول (۱): نتایج رویکرد آموزشی کلی با استفاده از امتیاز اندازه‌گیری شباهت

ویژگی‌های پایه ای اسکلت		ویژگی‌های ساده سازی شده		روش‌های تشخیص ناهنجاری
AP	AUC	AP	AUC	
۰,۵۷	۰,۷۷	۰,۵۷	۰,۷۷	UAE [13]
۰,۴۷	۰,۶۳	۰,۴۶	۰,۶۶	FCAE [13]
۰,۴۹	۰,۶۷	۰,۴۴	۰,۶۰	LSTM-ED [14]
۰,۳۶	۰,۵۲	۰,۳۱	۰,۴۵	TCN-ED [15]
۰,۳۴	۰,۵۲	۰,۳۰	۰,۵۱	VAE-LSTM [16]
۰,۴۳	۰,۸۱	۰,۳۵	۰,۷۱	روش پیشنهادی

جدول (۲): نتایج رویکرد آموزشی منحصر به ویدئو با استفاده از امتیاز اندازه‌گیری شباهت

ویژگی‌های پایه ای اسکلت		ویژگی‌های ساده سازی شده		روش‌های تشخیص ناهنجاری
AP	AUC	AP	AUC	
۰,۵۱	۰,۶۸	۰,۴۲	۰,۵۹	UAE [13]
۰,۴۹	۰,۶۴	۰,۴۷	۰,۶۲	FCAE [13]
۰,۴۳	۰,۵۷	۰,۳۲	۰,۵۲	LSTM-ED [14]
۰,۵۱	۰,۷۱	۰,۴۰	۰,۵۸	TCN-ED [15]
۰,۳۷	۰,۵۵	۰,۲۹	۰,۵۰	VAE-LSTM [16]
۰,۴۴	۰,۸۳	۰,۳۹	۰,۷۹	روش پیشنهادی

۵. نتایج

همان‌طور که اشاره شد هدف این مقاله ارائه راهکاری نیمه نظارت‌شده برای تشخیص ناهنجاری‌ها و صحنه‌های مشکوک به تقلب مرتبط با حالت رفتاری انسان است، به طوری که تنها از روی الگوهای رفتاری عادی بتوان رفتارهای نامتعارف را ممکن است نشان‌دهنده تقلب در آزمون باشد را شناسایی کرد. با توجه به مجموعه داده‌ای که در این زمینه به‌کار گرفته شده است، ابتدا ۳۰ درصد قاب‌های آغازین هر ویدیو از مجموعه داده را به‌عنوان مجموعه آموزشی و قسمت باقیمانده را به‌عنوان مجموعه آزمایش جدا می‌کنیم. برای آموزش، ما دو طرح آموزشی را بررسی می‌کنیم: رویکرد کلی و رویکرد منحصر به ویدئو. در رویکرد آموزشی کلی، قطعات شناخته شده از همه ویدئوهای آموزشی (بخش نرمال از ویدئوها) را به‌عنوان یک مجموعه آموزشی واحد از الگوها در نظر می‌گیریم. اما

$$S^t = \{S_k^t \mid k \in 1..N^{ts}\} \quad (5)$$

که در آن N^{ts} تعداد بخش‌های آموزشی است، هر کدام شامل قاب‌هایی هستند که حالت بدن در آنها مشابه است:

$$S_k^t = \{F_a^t, \dots, F_b^t \mid a \in 0..N^{f^{tk}}, b \in 0..N^{f^{tk}}, \text{ and } a \leq b\} \quad (6)$$

ما می‌خواهیم قاب‌ها را در یک بخش مرتب کنیم تا حالت بدنه تغییر چندانی نکند و هر زمان که حالت بدنه تغییر کند، بخش قاب دیگری تشکیل می‌شود.

(۲) شباهت بین بخش‌های غیرمتوالی در مجموعه داده آموزشی ارزیابی شده و بخش‌های مشابه برای جلوگیری از مقایسه‌های متعدد در مرحله آزمایش ادغام می‌شوند.

(۳) در نهایت، در مرحله آزمایش شباهت بین قاب‌های مجموعه داده آزمایشی و بخش‌های آموزشی تعیین می‌شود و برچسب یا نمره شباهت برای هر یک محاسبه می‌شود.

انحراف معیار است که برای تشکیل یک خوشه مورد نیاز است. بر اساس مشاهدات و مقایسه قطعات ایجاد شده، مقدار ۰/۰۵ برای این پارامتر انتخاب شد. برای مقایسه روش‌ها از معیارهای AUC و AP استفاده شد.

جدول (۱ و ۲) نتایج الگوریتم‌های تشخیص ناهنجاری را با استفاده از رویکردهای آموزش کلی و منحصر به ویدئو و روش امتیازدهی ناهنجاری نشان می‌دهد. جدول (۱) نشان می‌دهد که در روش‌های آموزش کلی و امتیازدهی ناهنجاری، برای ویژگی‌های پایه‌ای روش ما توانسته است در معیار AUC از سایر روش‌ها بهتر عمل کند اما از لحاظ معیار AP کارایی متوسطی را نشان داده است. الگوریتم UAE از نظر معیار AP، از همه بهتر عمل کرده است. با جایگزین کردن ویژگی‌های ساده شده به جای ویژگی‌های مختصات اصلی نیز کیفیت امتیازدهی در سطح قاب در اکثر روش‌ها کاهش یافته است به جز UAE. کارایی روش ما از نظر معیار AUC بسیار بهتر از AP است. کاهش عملکرد از نظر معیار AP می‌تواند به این دلیل باشد که الگوریتم پیشنهادی به قاب‌های جداگانه امتیاز خوبی از لحاظ رتبه‌بندی داده‌ها نمی‌دهد. معیار AP به رتبه‌بندی نهایی داده‌ها حساس است که نشان‌دهنده این مشکل است. با این حال، الگوریتم پیشنهادی در مقایسه با سایرین در مورد معیار AUC، که حساسیت کمتری به رتبه‌بندی داده‌ها دارد، عملکرد خوبی دارد. از سوی دیگر، در جدول (۲)، نتایج الگوریتم ما از نظر معیار AUC بسیار بهتر از روش‌های مقایسه شده است. همان روندها بین ویژگی‌های اصلی و ساده شده را می‌توان در جدول (۲) نیز مشاهده کرد. در هر دو جدول، امتیازدهی برای ویژگی‌های اصلی بهترین کار را داشت. نکته جالب در این جدول این است که بر خلاف سایر روش‌ها که به دلیل کاهش داده‌های آموزش در رویکرد منحصر به ویدئو کارایی خود را تا حدودی از دست می‌دهند، روش ما نه تنها کارایی خود را از دست نمی‌دهد بلکه بهبود می‌یابد. این می‌تواند تاییدکننده این فرض باشد که رفتارهای عادی

در روش منحصر به ویدئو از الگوهای نرمال شناسایی شده از بخش نرمال از یک ویدئو برای آزمایش قسمت باقیمانده از قاب‌های همان ویدئو استفاده می‌کنیم. در حالت کلی، هدف استفاده از الگوهای نرمال مشاهده شده از همه شرکت‌کنندگان برای تشخیص الگوهای غیرعادی مشترک است. از طرف دیگر در روش دوم هر ویدئو به‌طور جداگانه پردازش می‌شود. ایده رویکرد آموزش منحصر به ویدئو این است که زاویه هر رکورد ویدئویی احتمالاً با یکدیگر متفاوت است، همچنین الگوهای رفتاری طبیعی افراد مختلف ممکن است با یکدیگر متفاوت باشد.

در حالت آموزش کلی، نرمال کردن دامنه ویژگی‌های اسکلت‌ها مهم است زیرا دو اسکلت می‌توانند حالت یکسان اما با مقیاس‌های متفاوت داشته باشند. اگرچه زاویه دوربین نیز عامل مهمی در شکل دادن به یک حالت خاص است که در ویژگی‌های اسکلت دو بعدی نمی‌توان از آن اجتناب کرد، اما نرمال‌سازی اسکلت‌ها می‌تواند تفاوت در حالت‌هایی با زوایای دید مشابه اما اندازه‌های متنوع را کاهش دهد. برای نرمال کردن ویژگی‌های اسکلت، موقعیت جعبه محاط ۹ اسکلت را محاسبه می‌کنیم و هر موقعیت اتصال را با توجه به موقعیت‌های پایین چپ و بالا و راست جعبه مرزی تغییر می‌دهیم. نرمال‌سازی در حالت منحصر به ویدئو نیز زمانی که شرکت‌کننده موقعیت خود را به سمت دوربین تغییر می‌دهد یا موقعیت دوربین در حین ضبط ویدئو تغییر می‌کند، مهم است.

عملکرد الگوریتم پیشنهادی با چندین روش تشخیص ناهنجاری نیمه نظارت شده مبتنی بر یادگیری عمیق و بازسازی داده‌ها، از جمله رمزگذار خودکار تک متغیره (UAE) [۲۴]، رمزگذار چند متغیره کاملاً متصل (FCAE) [۲۴]، LSTM-ED [۲۵]، TCN ED [۲۶] و VAE-LSTM [۲۷] مقایسه شده است. پارامترهای اصلی این روش‌ها طول توالی و اندازه فضای پنهان است که هر دو برای همه آنها به ترتیب ۱۵ و ۱۰ تنظیم شده اند. الگوریتم پیشنهادی همچنین دارای فوق پارامترهایی مانند مقدار اولیه کنترلی

می‌دهد که نمونه‌هایی که در روش ما دارای برچسب نرمال هستند، ۹۹ درصد نرمال هستند. از سوی دیگر، با استفاده از روش ما، اکثر نمونه‌های غیرطبیعی به عنوان ناهنجاری برچسب‌گذاری می‌شوند. جدول (۴) عملکرد مشابهی را با جدول (۳) با چند بهبود در نتایج با استفاده از ویژگی‌های ساده نشان می‌دهد.

۶. جمع‌بندی

در این مقاله روشی نیمه نظارت‌شده برای تشخیص ناهنجاری‌های رفتاری در ویدئوهای نظارتی آزمون الکترونیکی ارائه شده است. در این روش از یک معیار شباهت برای گروه‌بندی اسکلتهای مشابه و نمایش ویدیوها استفاده شده است. پس از بخش‌بندی قاب‌های ویدئویی آموزشی و استخراج الگوهای حرکتی متمایز، قاب‌های ناهنجار را در توالی قاب‌های مورد آزمون با محاسبه شباهت قاب‌ها به الگوهای آموزشی تعیین کرد. نتایج تجربی نشان داد که الگوریتم پیشنهادی به راحتی می‌تواند حالت‌های اسکلتهای بدن را که در میان الگوهای مجموعه یادگیری وجود ندارد، شناسایی کند. الگوریتم پیشنهادی در دو حالت آموزشی کلی و منحصر به ویدیو مورد استفاده قرار گرفت که کیفیت الگوریتم پیشنهادی با رویکرد آموزش منحصر به ویدئو نسبت به الگوریتم‌های مورد مقایسه مشهود بود. این برتری نسبت به حالت آموزشی کلی نشان می‌دهد که اگر نمونه داده‌های نرمال کافی برای تجزیه و تحلیل رفتار یک فرد در دسترس باشد، استفاده از این روش در حالت منحصر به ویدئو نتایج خوبی به همراه خواهد داشت و نیاز به داده‌های زیاد از افراد مختلف برای استخراج الگوهای رفتاری نخواهد بود. از مزایای این روش این است که می‌توان از آن برای خلاصه کردن ویدئوها بر اساس شباهت اسکلتهای افراد استفاده کرد، زیرا برخی از قاب‌های نمونه از هر بخش را می‌توان در ویدیوی خلاصه گنجاند. همچنین از آنجایی که این روش برای برچسب‌گذاری نمونه نیازی به

نیز می‌توانند منحصر به فرد باشند، اگرچه متفاوت بودن زوایای دوربین در ویدئوهای مختلف نیز می‌تواند علت این امر باشد. آخرین نکته قابل توجه این است که نتایج الگوریتم ما به طور کامل با نتایج روش‌های مذکور ممکن است چندان قابل مقایسه نباشد، زیرا آن روش‌ها از یک اندازه پنجره ثابت روی جریان قاب‌ها استفاده می‌کنند اما در روش ما، این محدودیت وجود ندارد که خود باعث می‌شود که از تعداد فوق پارامترهای روش کاسته شود.

برای مقایسه عملکرد روش اختصاص برچسب‌های ناهنجاری دقیق با استفاده از الگوریتم‌های مختلف، ما بهترین آستانه قابل انتخاب را از امتیازات تولید شده توسط هر الگوریتم استخراج کرده و با توجه به آن برای هر نمونه آزمایشی برچسب صفر یا یک تعیین کردیم. اگرچه خود انتخاب حد آستانه برای برچسب‌گذاری قطعی ناهنجاری امری چالش برانگیز است اما ما در اینجا یک روش ایده‌آل را صرفاً برای مقایسه در اینجا بررسی می‌کنیم. به طور خاص با استفاده از منحنی AUC، آستانه t را پیدا می‌کنیم به گونه ای:

$$t = \text{Max}_{i \in \{0, T\}} (TPR_i - FPR_i) \quad (8)$$

جایی که T تعداد آستانه‌ها است. سپس معیارهای صحت طبقه‌بندی ۱۰، دقت و یادآوری برای نمونه‌های نرمال و دقت و یادآوری برای نمونه‌های غیرطبیعی را که به ترتیب با RecN ، ACC ، PreA ، RecA ، PreN و ACC و PreA ، RecA ، PreN و ACC (۳ و ۴) آمده است، محاسبه می‌کنیم. جدول (۳) عملکرد طبقه‌بندی دودویی را با استفاده از روش ما با رویکرد منحصر به ویدئو نشان می‌دهد. اگر تعادل بین دقت و یادآوری نمونه‌های غیرعادی را در نظر بگیریم، کیفیت روش ما پایین‌تر از سایر روش‌ها به نظر می‌رسد. اما نتایج جالبی را نشان می‌دهد. اولاً، کیفیت طبقه‌بندی بر اساس ویژگی ساده شده بالاتر از ویژگی‌های اصلی به نظر می‌رسد. ثانیاً، در روش ما، دقت تشخیص نمونه‌های نرمال و فراخوانی نمونه‌های غیرطبیعی بسیار بالا است این نشان

جدول (۳): کارایی روش هادر انتساب برچسب‌های ناهنجاری قطعی در رویکرد آموزش منحصر به‌ویژو

ویژگی‌های ساده‌سازی شده					ویژگی‌های پایه‌ای اسکلت					روش‌های تشخیص ناهنجاری
RecA	PreA	RecN	PreN	ACC	RecA	PreA	RecN	PreN	ACC	
۰.۶۹	۰.۵۹	۰.۵۲	۰.۶۳	۰.۵۲	۰.۷۳	۰.۸۳	۰.۷۰	۰.۶۸	۰.۵۱	UAE [13]
۰.۷۰	۰.۶۲	۰.۴۷	۰.۶۱	۰.۵۳	۰.۷۲	۰.۸۳	۰.۶۹	۰.۶۴	۰.۴۹	FCAE [13]
۰.۶۰	۰.۵۲	۰.۳۲	۰.۵۰	۰.۵۱	۰.۷۶	۰.۸۰	۰.۶۹	۰.۵۷	۰.۴۳	LSTM-ED [14]
۰.۶۶	۰.۵۸	۰.۴۰	۰.۶۴	۰.۴۹	۰.۷۴	۰.۸۳	۰.۷۲	۰.۷۱	۰.۵۱	TCN-ED [15]
۰.۵۱	۰.۵۰	۰.۲۹	۰.۴۵	۰.۴۱	۰.۷۱	۰.۷۷	۰.۶۲	۰.۵۵	۰.۳۷	VAE-LSTM [16]
۰.۸۷	۰.۲۱	۰.۵۷	۰.۹۷	۰.۶۱	۰.۹۹	۰.۱۴	۰.۲۰	۰.۹۹	۰.۳۰	روش پیشنهادی

جدول (۴): کارایی روش هادر انتساب برچسب‌های ناهنجاری قطعی در رویکرد آموزش کلی

ویژگی‌های ساده‌سازی شده					ویژگی‌های پایه‌ای اسکلت					روش‌های تشخیص ناهنجاری
RecA	PreA	RecN	PreN	ACC	RecA	PreA	RecN	PreN	ACC	
۰.۷۳	۰.۴۹	۰.۷۱	۰.۸۶	۰.۷۲	۰.۷۵	۰.۵۰	۰.۷۱	۰.۸۶	۰.۷۲	UAE [13]
۰.۵۷	۰.۴۶	۰.۷۴	۰.۸۱	۰.۷۰	۰.۵۵	۰.۵۳	۰.۷۷	۰.۸۱	۰.۷۱	FCAE [13]
۰.۴۹	۰.۴۹	۰.۷۸	۰.۸۰	۰.۷۰	۰.۶۱	۰.۵۰	۰.۷۳	۰.۸۲	۰.۷۰	LSTM-ED [14]
۰.۳۹	۰.۴۴	۰.۷۳	۰.۷۷	۰.۶۳	۰.۴۵	۰.۵۲	۰.۷۳	۰.۷۹	۰.۶۴	TCN-ED [15]
۰.۴۸	۰.۳۲	۰.۶۱	۰.۷۵	۰.۵۶	۰.۴۳	۰.۳۵	۰.۶۹	۰.۷۷	۰.۶۱	VAE-LSTM [16]
۰.۴۸	۰.۳۰	۰.۸۰	۰.۹۲	۰.۷۷	۰.۹۹	۰.۱۴	۰.۲۲	۰.۹۹	۰.۳۱	روش پیشنهادی

doi.org/10.1109/ TMM.2017. 2656064.

- Yadav, B. N. & Rao, M. K. 2022. Malpractice Detection in Online Assessments Using Eye Gaze Tracking and Object Detection in Rising Threats in Expert Applications and Solutions (FICR-TEAS) pp. 701-708, Springer, Singapore, https://doi.org/10.1007/978-981-19-1122-4_73.
- Tiong, L. C. O. & Lee, H. J. 2021. "E-cheating Prevention Measures: Detection of Cheating at Online Examinations Using Deep Learning Approach--A Case Study", arXiv preprint arXiv:210109841, <https://doi.org/10.48550/arXiv.2101.09841>.
- Fan, Z., Xu, J., Liu, W. & Cheng, W. 2016. Gesture-based misbehavior detection in online examination. 11th International Conference on Computer Science & Education (ICCSE), Nagoya, Japan, <https://doi.org/10.1109/ICCSE.2016.7581586>.
- Labayen, M., Vea, R., Flórez, J., Aginako, N. & Sierra, B. 2021. "Online student authentication and proctoring system based on multimodal biometrics technology", IEEE Access. vol. 9, pp. 72398-72411, <https://doi.org/10.1109/ACCESS.2021.3079375>.
- Tweissi, A., Al Etaiwi, W. & Al Eisawi, D. 2022. "The Accuracy of AI-Based Automatic Proctoring in Online Exams", Electronic Journal of e-Learning. vol. 20, pp.

دیدن نمونه‌های آزمایشی دیگر ندارد، می‌توان از آن در کاربردهای برخط برای تشخیص ناهنجاری استفاده کرد.

مراجع

- Kaddoura, S., Vincent, S. & Hemanth, D. J. 2023. "Computational Intelligence and Soft Computing Paradigm for Cheating Detection in Online Examinations", Applied Computational Intelligence and Soft Computing. vol. 2023, pp. 23, <https://doi.org/10.1155/2023/3739975>.
- Thampan, N. & Arumugam, S. 2022. Smart Online Exam Invigilation using AI-based Facial Detection and Recognition Algorithms. 2nd Asian Conference on Innovation in Technology (ASIANCON), <https://doi.org/10.1109/ASIANCON55314.2022.9908748>.
- Goud, S., Abhiram, R., Nayak, P. & Kaushal, P. 2022. Smart attendance monitoring system for online classes using facial recognition. International Conference on Innovative Computing and Communications (ICICC), https://doi.org/10.1007/978-981-19-2535-1_15.
- Atoum, Y., Chen, L., Liu, A. X., Hsu, S. D. & Liu, X. 2017. "Automated online exam proctoring", IEEE Transactions on Multimedia. vol. 19, pp. 1609-1624, <https://doi.org/10.1109/TMM.2017.2704444>.

- Signal Processing (ICCCSP), 10.1109/ICCCSP52374. 2021. 9465530.
21. Kaddoura, S. & Gumaei, A. 2022. "Towards effective and efficient online exam systems using deep learning-based cheating detection approach", *Intelligent Systems with Applications*. vol. 16, pp. 200153, <https://doi.org/10.1016/j.iswa.2022.200153>.
 22. Plochaet, J. & Goedemé, T. 2022. Towards Automatic Proctoring of Online Exams Using Video Anomaly Detection in Joint International Scientific Conferences on AI and Machine Learning, BNAIC/BeNeLearn, Belgium.
 23. Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., Devin, M., Ghemawat, S., Irving, G. & Isard, M. 2016. TensorFlow: a system for Large-Scale machine learning. 12th USENIX symposium on operating systems design and implementation (OSDI 16).
 24. Garg, A., Zhang, W., Samaran, J., Savitha, R. & Foo, C.-S. 2021. "An Evaluation of Anomaly Detection and Diagnosis in Multivariate Time Series", *IEEE Transactions on Neural Networks and Learning Systems*. vol. 33, pp. 2508 - 2517, <https://doi.org/10.1109/TNNLS.2021.3105827>.
 25. Malhotra, P., Ramakrishnan, A., Anand, G., Vig, L., Agarwal, P. & Shroff, G. 2016. "LSTM-based encoder-decoder for multi-sensor anomaly detection", *arXiv preprint arXiv:160700148*, <https://doi.org/10.48550/arXiv.1607.00148>.
 26. Bai, S., Kolter, J. Z. & Koltun, V. 2018. "An empirical evaluation of generic convolutional and recurrent networks for sequence modeling", *arXiv preprint arXiv:180301271*, <https://doi.org/10.48550/arXiv.1803.01271>.
 27. Park, D., Hoshi, Y. & Kemp, C. C. 2018. "A multimodal anomaly detector for robot-assisted feeding using an lstm-based variational autoencoder", *IEEE Robotics and Automation Letters*. vol. 3, pp. 1544-1551, <https://doi.org/10.1109/LRA.2018.2801475>.
 - 419-435, <https://doi.org/10.34190/ejel.20.4.2600>.
 10. Mishra, P. K., Mihailidis, A. & Khan, S. S. 2024. "Skeletal Video Anomaly Detection using Deep Learning: Survey, Challenges, and Future Directions", *IEEE Transactions on Emerging Topics in Computational Intelligence*. vol. 8, pp. 1073-1085, <https://doi.org/10.1109/TETCI.2024.3358103>.
 11. Kasinathan, V., Yan, C. E., Mustapha, A., Hameed, V. A., Ching, T. H. & Thiruchelvam, V. 2022. "ProctorEx: An Automated Online Exam Proctoring System", *Mathematical Statistician and Engineering Applications*. vol. 71, pp. 876-889-876-889.
 12. Kariyawasam, S., Lakshan, A., Liyanage, A., Gimhana, K., Piyawardana, V. & Mallawarachchi, Y. 2021. Standalone Application and Chromium Browser Extension-based System for Online Examination Cheating Detection. 2021 3rd International Conference on Advancements in Computing (ICAC).
 13. Abisado, M. B., Gerardo, B. D., Vea, L. A. & Medina, R. P. 2018. Towards academic affect modeling through experimental hybrid gesture recognition algorithm. *Proceedings of the 2018 International Conference on Data Science and Information Technology*.
 14. Li, H., Xu, M., Wang, Y., Wei, H. & Qu, H. 2021. A visual analytics approach to facilitate the proctoring of online exams. *Proceedings of the 2021 CHI Conference on Human Factors in Computing Systems*.
 15. Hu, S., Jia, X. & Fu, Y. 2018. Research on abnormal behavior detection of online examination based on image information. 10th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC), Hangzhou, China, <https://doi.org/10.1109/IHMSC.2018.10127>.
 16. Jia, J. & He, Y. 2021. "The design, implementation and pilot application of an intelligent online proctoring system for online exams", *Interactive Technology and Smart Education*.
 17. Masud, M. M., Hayawi, K., Mathew, S. S., Michael, T. & El Barachi, M. 2022. Smart Online Exam Proctoring Assist for Cheating Detection. *International Conference on Advanced Data Mining and Applications (ADMA)*, Cham, https://doi.org/10.1007/978-3-030-95405-5_9.
 18. Yang, B., Li, H., Xie, H., Zhao, J., Zhu, R. & Zhao, L. 2021. "Abnormal state recognition method for online intelligent examination based on improved genetic algorithm", *International Journal of Information and Communication Technology*. vol. 18, pp. 334-350.
 19. Luan, N. K., Ha, P. T. T. & Hung, P. D. 2022. An Automated Proctor Assistant in Online Exams Using Computer Vision. *International Conference on Cooperative Design, Visualization and Engineering*.
 20. A, J. S., Kumaran, H. S., S, U., Rajesh, K. P. B. V. & L, R. 2021. Deep Learning based Approach for Facilitating Online Proctoring using Transfer Learning. 2021 5th International Conference on Computer, Communication and