

**Fire Detection Based on Extraction of Spatio-Temporal Features by Convolutional Neural Networks and Fractal Analysis****Monir Torabian^{1,2}, Ph.D. Student, Hossein Pourghassem^{1,2}, Professor, Homayoun Mahdavi-Nasab^{1,3}, Associate Professor, Payam Sanaee^{1,2}, Assistant Professor**¹Department of Electrical Engineering- Najafabad Branch, Islamic Azad University, Najafabad, Iran²Digital Processing and Machine Vision Research Center- Najafabad Branch, Islamic Azad University, Najafabad, Iran³Smart Microgrid Research Center- Najafabad Branch, Islamic Azad University, Najafabad, Iran
monir_torabian@yahoo.com, h_pourghasem@iaun.ac.ir, mahdavinhasab@iaun.ac.ir, p.sanaee@pel.iaun.ac.ir**Abstract**

Fire is one of the dangers that can endanger human health in a short time and if it is not controlled in time, it will cause a lot of damage. Therefore, timely and accurate identification of the location of the fire can prevent the consequences of its expansion. In this research, a new method for fire detection is proposed based on the extraction of its temporal-spatial features in video frames. In the proposed algorithm, a multiscale convolutional neural network along with a YOLO (you only look once) network is used to extract spatial features and identify fire candidate regions. Then, fractal analysis based on the temporal blanket method is then used to remove non-moving textures similar to fire and to examine the temporal features of the candidate region. Finally, the fire region is separated from the other parts of the image by fusion the results of the two steps. The evaluation results of the proposed method on three data sets show that the accuracy of fire detection is about 96.1%, while the precision and recall values are 92% and 96.9%, respectively. Experimental results show that the proposed method performs better than existing algorithms and thus confirms the ability of this method for efficient use in the real world.

Keywords: blanket, fire detection, fractal, multiscale convolutional neural network, YOLO network**Received:** 13 May 2022**Revised:** 11 July 2022**Accepted:** 16 October 2022**Corresponding Author:** Dr. Hossein Pourghassem



مقاله پژوهشی

آشکارسازی آتش بر اساس استخراج ویژگی‌های مکانی-زمانی از طریق شبکه‌های عصبی کانولوشنی و تجزیه و تحلیل فراکتال

منیر ترابی^{۱،۲}، دانشجوی دکتری، حسین پورقاسم^{۱،۲}، استاد، همایون مهدوی نسب^{۱،۳}، دانشیار، پیام سنائی^{۱،۲}، استادیار

۱- دانشکده مهندسی برق- واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

۲- مرکز تحقیقات پردازش دیجیتال و بینایی ماشین- واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

۳- مرکز تحقیقات ریز شبکه‌های هوشمند- واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

monir_torabian@yahoo.com, h_pourghasem@iaun.ac.ir, mahdavinassab@iaun.ac.ir, p.sanaee@pel.iaun.ac.ir

چکیده: آتش‌سوزی یکی از خطراتی است که می‌تواند سلامت انسان را در مدت زمان کوتاهی به خطر اندازد و اگر به موقع محدود نشود، خسارات زیادی به همراه خواهد داشت. تشخیص به موقع و دقیق مکان آتش‌سوزی می‌تواند از پیامدهای انتشار آن جلوگیری کند. در این تحقیق روش جدیدی برای تشخیص آتش بر مبنای استخراج ویژگی‌های زمانی-مکانی آتش در قالب‌های ویدئویی پیشنهاد شده است. در الگوریتم پیشنهادی، از یک شبکه عصبی کانولوشنی چند مقیاسی به همراه یک شبکه یولو (YOLO) جهت استخراج ویژگی‌های مکانی و شناسایی مناطق نامزد آتش استفاده شده است. سپس به منظور حذف بافت‌های غیرمتحرک مشابه آتش و بررسی ویژگی‌های زمانی ناحیه نامزد، روش تجزیه و تحلیل فراکتال بر اساس پتوی پوشان زمانی به کار برده شده است. در نهایت ناحیه آتش از طریق تلفیق نتایج دو مرحله از سایر قسمت‌های تصویر جدا می‌گردد. نتایج ارزیابی بر روی سه مجموعه داده نشان می‌دهد که صحت روش پیشنهادی تشخیص آتش حدود ۹۶/۱ درصد است و این در حالی است که عوامل دقت و بازیابی به ترتیب ۹۲ درصد و ۹۶/۹ درصد است. بنابر نتایج تجربی، روش پیشنهادی از سایر الگوریتم‌های ارائه شده عملکرد بهتری دارد و بنابراین الگوریتم طراحی شده در دنیای واقعی به صورت کارآمد قابل استفاده است.

کلمات کلیدی: آشکارسازی آتش، پتوی پوشان، چند مقیاسی، شبکه یولو، شبکه عصبی کانولوشنی، فراکتال

تاریخ ارسال مقاله: ۱۴۰۱/۲/۲۳

تاریخ بازنگری مقاله: ۱۴۰۱/۴/۲۰

تاریخ پذیرش مقاله: ۱۴۰۱/۷/۲۴

نام نویسنده‌ی مسئول: دکتر حسین پورقاسم

نشانی نویسنده‌ی مسئول: نجف‌آباد- بلوار دانشگاه- دانشگاه آزاد اسلامی واحد نجف‌آباد- دانشکده مهندسی برق

۱- مقدمه

آتش سوزی یکی از رویدادهایی است که پتانسیل بالایی برای گسترش سریع و تخریب در مدت زمان کوتاه دارد. بنابراین، تشخیص زودهنگام آن در فضاهای صنعتی، مسکونی، جنگلی و عمومی می‌تواند از پیامدهای ناشی از گسترش آن جلوگیری کند. امروزه از سامانه‌های اعلام حریق که مجموعه‌ای از تجهیزات و حسگرهایی مانند آشکارساز دود، شعله و گرما را شامل می‌شود، برای تشخیص آتش سوزی استفاده می‌گردد. این سامانه‌ها هنگام بروز دود، آتش سوزی، مونوکسید کربن یا سایر علائم آتش هشدار می‌دهند. حسگرهای تشخیص آتش از نوع تماس مستقیم هستند و تا زمانی که آتش و دود پخش نشود کار نمی‌کنند، بنابراین سامانه‌های تشخیص آتش مبتنی بر این حسگرها سرعت کمی دارند. علاوه بر این، برای افزایش دقت و قدرت تشخیص این سامانه‌ها، لازم است از تعداد زیادی حسگر استفاده شود که این امر باعث افزایش هزینه اجرای پروژه می‌شود. همچنین استفاده از برخی از این حسگرها در محیط‌های باز مانند جنگل‌ها امکان‌پذیر نیست. بنابراین، این سامانه‌ها از عملکرد مناسب و دقیقی در محیط‌های باز و گسترده برخوردار نیستند. در سال‌های اخیر، به دلیل گسترش دوربین‌های دیجیتال، روش‌های شناسایی آتش از طریق دوربین‌های مداربسته نظارتی بر اساس پردازش تصویر گسترش یافته‌اند که غالباً قادر به جبران کاستی‌های سامانه‌های قبلی بوده است. با توجه به ضعف‌های آشکارسازهای سنتی به‌خصوص در مناطق باز، استفاده از روش‌های هوشمند برای آشکارسازی آتش در این مناطق بسیار مورد توجه قرار گرفته است. از آنجا که استفاده از تنها یک دوربین می‌تواند طیف گسترده‌ای از مکان مورد نظر را تحت پوشش قرار دهد، هزینه اجرای پروژه‌های آشکارساز آتش در این روش‌ها بسیار کاهش می‌یابد. همچنین مدت زمان تشخیص آتش سوزی نسبت به سامانه قبلی کمتر است. علاوه بر این، همزمان با شناسایی آتش، با استفاده از این روش، اطلاعات حیاتی در مورد اندازه، حجم، محل و سرعت انتشار آتش به راحتی حاصل می‌شود. علی‌رغم این مزایا، طراحی یک سیستم تشخیص آتش کارآمد با چالش‌های زیادی مانند وابستگی به شرایط نورپردازی، شرایط آب و هوا، وجود اجسام متحرک و اشیای مشابه با آتش مواجه است. چنین دشواری‌ها و چالش‌هایی در شناسایی و جداسازی آتش به‌ویژه از اجسام مشابه با آن، الگوریتم‌های متنوعی را پدید آورده است که از ویژگی‌های متفاوتی برای جداسازی مناطق آتش استفاده می‌کنند.

روش‌های تشخیص آتش مبتنی بر بینایی ماشین بر ویژگی‌هایی مانند رنگ، حرکت، بافت و شکل تمرکز می‌کنند. مهم‌ترین ویژگی منطقه آتش، رنگ آن است. از این‌رو، در بسیاری از مطالعات قوانین ساده‌ای را در فضاهای رنگی مختلف مانند قرمز-سبز-آبی^۱، درخشندگی-کرومینانس-آبی-کرومینانس قرمز^۲، طیف رنگ-اشباع-شدت روشنایی^۳ و درخشندگی-طرح آبی-طرح قرمز^۴ برای جداسازی پیکسل‌های آتش پیشنهاد کرده‌اند [۸-۱۱]. با وجود سادگی و هزینه محاسباتی کم، آستانه‌های متعددی در این روش‌ها استفاده شده است. در برخی از روش‌ها از قوانین مدل‌های رنگی پیچیده‌تر بر اساس آمار و احتمالات استفاده شده است. در مرجع [۹] توزیع رنگ آتش از تصاویر آزمایشی، توسط روش مخلوط گاوسی‌ها^۵ در فضای رنگی قرمز-سبز-آبی مدل‌سازی شده است. این روش از آستانه‌های ابتکاری استفاده می‌کند اما نتایج خوبی را نشان می‌دهد. در مرجع [۲] مدل‌های احتمالی رنگ با استفاده از توزیع گاوسین نامشخص از تصاویر نمونه که حاوی صحنه‌های آتش سوزی پویا هستند، تولید می‌شوند و پیکسل‌های آتش با استفاده از این مدل‌های احتمال قرمز-سبز-آبی شناسایی می‌شوند.

پویایی و متحرک بودن آتش در قاب‌های متوالی یکی دیگر از ویژگی‌های اصلی آن است که در بسیاری از پژوهش‌ها مورد توجه قرار گرفته است. یکی از روش‌های تشخیص اشیای متحرک، مدل تفریق پس‌زمینه^۶ است، که با توجه به سرعت بالای آن در تحقیقات زیادی استفاده شده است [۵، ۶، ۹، ۱۰، ۱۱]. با این حال در این الگوریتم تصویر پس‌زمینه باید به‌صورت پیوسته به‌روز رسانی گردد، زیرا در صورت داشتن پس‌زمینه‌ای پویا و متحرک و به‌روز نکردن آن، این الگوریتم در شناسایی اشیای متحرک با مشکل مواجه خواهد شد. یکی دیگر از روش‌های ساده و سریع در شناسایی اجسام متحرک در قاب‌های یک ویدئو استفاده از روش مدل مخلوط گاوسی است [۱۲، ۱۳]. در این روش، هر پیکسل به‌عنوان ترکیبی از توزیع‌های گاوسی مدل‌سازی شده است و مقدار شدت هر پیکسلی که در یکی از این توزیع‌ها قرار نگیرد، به‌عنوان پیکسل پیش‌زمینه مشخص می‌شود. جریان نوری^۷ نیز یکی دیگر از روش‌های تشخیص اجسام متحرک در ویدئو است [۱۴].

استفاده از ویژگی‌های رنگ و حرکت به‌تنهایی در ویدئوهایی که دارای اجسام متحرک مشابه آتش هستند، دقت تشخیص را کاهش می‌دهد. از این‌رو در بسیاری از مطالعات تلاش شده است تا ویژگی‌های مکانی و زمانی مخصوص مناطق آتش سوزی را


ارائه دهند. به عنوان مثال، در مرجع [۱۲] این واقعیت که مساحت مناطق آتش در قاب‌های متوالی تغییر می‌کند و رفتار تصادفی دارد به عنوان ویژگی‌ای برای بهبود تشخیص استفاده می‌شود. ردیابی تاریخچه فرکانسی پیکسل‌های آتش و تجزیه و تحلیل اطلاعات فرکانس بالای آن توسط تحلیل موجک [۹] از دیگر ویژگی‌های معرفی شده است. روش الگوی باینری محلی-سه صفحه متعامد^۸ (LBP-TOP) در مرجع [۱۵] برای تجزیه و تحلیل بافت آتش پیشنهاد شده که این روش می‌تواند جسم غیر متحرک، جسم متحرک و آتش را تشخیص دهد.

در اکثر مطالعات، پس از مشخص کردن مناطق آتش نامزد، ویژگی‌های مناطق آتش و مناطق مشابه آتش استخراج شده و سپس از یک طبقه‌بند مانند ماشین بردار پشتیبان^۹ (SVM)، شبکه عصبی یا شبکه‌های بیزین برای شناسایی مناطق آتش واقعی و تصمیم‌گیری نهایی، به عنوان آخرین مرحله استفاده شده است [۲، ۴، ۱۲]. در مرجع [۹] تصمیم نهایی با استفاده از استراتژی تلفیق^{۱۰} گرفته می‌شود. در مقاله [۵] از رگرسیون منطقی^{۱۱} استفاده شده است. رگرسیون منطقی یک مدل خطی تعمیم‌یافته برای طبقه‌بندی باینری از یک بردار ویژگی داده شده را ارائه می‌دهد.

روش‌های سنتی مبتنی بر ویژگی‌های دست‌ساز، نیازمند مهندسی ویژگی‌های پیچیده هستند که بسیار زمان‌بر است. همچنین این روش‌ها برای تعداد کمی از نمونه‌ها دقت بالایی را نشان می‌دهند اما در صورت تعمیم، دقت تشخیص به دلیل نیاز به کالیبره کردن نقاط تنظیم و آستانه‌ها کاهش می‌یابد. در سال‌های اخیر برای غلبه بر این مشکلات از روش‌های مبتنی بر یادگیری عمیق استفاده شده است. در مرجع [۱۶]، تصاویر حاوی آتش توسط یک مدل شبکه عصبی کانولوشنی با معماری مشابه با شبکه اسکویزنت^{۱۲} شناسایی می‌شوند که برای هدف این مقاله اصلاح شده است. سپس نقشه‌های ویژگی لایه‌های ۸، ۲۶ و ۳۲ استخراج و میانگین مقدار نقشه فعال‌سازی برای آنها محاسبه می‌شود. در نهایت مناطق آتش‌سوزی با استفاده از روش آستانه‌گیری از سایر مناطق جدا می‌شوند. در این مطالعه، کاهش اندازه مدل شبکه باعث کاهش هزینه‌ها و در نتیجه امکان پیاده‌سازی آن در سامانه‌های نظارتی می‌شود. برخی تحقیقات از شبکه عصبی کانولوشنی با پیچیدگی کمتر استفاده کرده‌اند [۱۷، ۱۸]. در تحقیق [۱۷] از مدلی مشابه گوگل‌نت^{۱۳} استفاده شده است. دلیل استفاده از این مدل نسبت به سایر مدل‌ها دقت طبقه‌بندی بهتر و مدل کوچک‌تر آن است. همچنین این مدل برای پیاده‌سازی بر روی آرایه دريچه‌ای برنامه‌پذیر میدانی^{۱۴} (FPGA) و سایر سخت افزارهای با حافظه محدود مناسب‌تر است. در مرجع [۱۸] الکسنت به عنوان یک معماری پایه در نظر گرفته شده است. در این روش دقت و پیچیدگی شبکه با توجه به مشکل شناسایی آتش تنظیم می‌شود. همچنین مکانیزم اولویت‌بندی تطبیقی برای دوربین‌های موجود در سیستم نظارتی پیشنهاد شده است که می‌تواند وضعیت دوربین‌ها را با توجه به اهمیت آنها تغییر دهد. در یک سری از مطالعات، روش‌های سنتی با شبکه‌های یادگیری عمیق برای افزایش دقت تشخیص ترکیب شده‌اند. به عنوان مثال، در مرجع [۱۹] خاصیت پویایی آتش از طریق روش تفریق پس زمینه و ویژگی سوسو زدن آتش استخراج می‌شود. سپس یک شبکه عصبی کانولوشنی با نور تطبیقی^{۱۵} برای استخراج ویژگی ایستایی آتش استفاده می‌شود. در نهایت، نتایج این دو روش برای ایجاد یک روش تشخیص آتش ترکیب می‌شوند. در اکثر مطالعات بر مبنای مدل‌های مختلف شبکه‌های عصبی کانولوشنی، محل دقیق آتش‌سوزی مشخص نشده و تنها وجود یا عدم وجود آتش در تصویر مشخص می‌شود. در مرجع [۲۰]، شبکه سریع مبتنی بر منطقه^{۱۶} برای شناسایی محل دقیق آتش‌سوزی استفاده شده است. در این مقاله، ابتدا نواحی رنگ آتش با استفاده از ماسک رنگ شعله جدا می‌شوند. لنگرهای این شبکه در اطراف اجسامی که از نظر رنگ شبیه به شعله هستند پخش می‌شوند. بنابراین، استراتژی شبکه سریع مبتنی بر منطقه به یک استراتژی لنگرگاه با هدایت رنگ تغییر یافته است. در این کار، همچنین برای استخراج اطلاعات عمومی از تصویر، یک شبکه به موازات شبکه قبل برای هدایت فرآیند تشخیص شعله متصل شده است.

روش‌های تشخیص آتش همچنان با مشکلاتی نظیر وجود اجسام شبیه آتش، پیچیدگی صحنه‌های نظارت شده، کیفیت پایین تصاویر دوربین، وجود نور نامنظم و کنتراست پایین تصاویر روبه‌رو هستند. لذا برای پرداختن به مسائل فوق، در این کار، یک روش تشخیص آتش هوشمند بر اساس ویژگی‌های ایستایی و پویایی آتش با استفاده از شبکه‌های عصبی یادگیری عمیق و تجزیه و تحلیل فراکتالی پیشنهاد شده است. ایده‌ها و دستاوردهای اصلی این تحقیق را می‌توان به شرح زیر خلاصه کرد:

- ارائه یک روش تشخیص آتش بر اساس شبکه کانولوشنی متصل شده به شبکه یولو^{۱۷} V2 و روش تحلیل فراکتال جهت دستیابی به منطقه دقیق آتش در تصویر، نرخ تشخیص بالا، نرخ هشدار کاذب پایین و سرعت بالا.



شکل (۱): معماری روش تشخیص آتش پیشنهادی

Figure (1): The architecture of the proposed fire detection algorithm

- جداسازی منطقه آتش، با استفاده از تلفیق بین روش استخراج ویژگی‌های مکانی مبتنی بر شبکه کانولوشنی متصل به شبکه یولو v2 و روش استخراج ویژگی‌های زمانی بوسیله‌ی تجزیه و تحلیل فراکتال.

- اجتناب از فرآیند تکراری و زمان‌بر مهندسی ویژگی و یادگیری خودکار ویژگی‌های مهم و موثر از داده‌های خام آتش.

- مقایسه نتایج به‌دست‌آمده از روش پیشنهادی با روش‌های پیشرفته که صحت تشخیص آتش و میزان تشخیص مثبت کاذب برتر آن را نشان می‌دهد.

این مقاله در ادامه به‌شرح زیر سازماندهی شده است. در بخش ۲ جزئیات روش پیشنهادی ارائه شده است. بخش ۳ نتایج تجربی روش پیشنهادی را ارائه و مورد بحث قرار می‌دهد و عملکرد آن را با سایر الگوریتم‌های تشخیص آتش مقایسه می‌کند. در نهایت، بخش ۴ نتیجه‌گیری تحقیق را ارائه می‌دهد.

۲- روش پیشنهادی

معماری روش پیشنهادی تشخیص آتش در شکل (۱) معرفی شده است. این معماری شامل سه مرحله اصلی است: (۱) تشخیص اشیای مشابه آتش با استفاده از یک شبکه کانولوشنی چند مقیاسی متصل شده به زیرشبکه یولو v2، (۲) تشخیص اشیای متحرک با استفاده از تجزیه و تحلیل فراکتال محلی بر مبنای روش پتوی پوشان زمانی^{۱۸} و روش آستانه‌گیری براساس هیستوگرام و (۳) تلفیق نواحی استخراج شده از دو مرحله قبل. در روش پیشنهادی به‌منظور تشخیص نواحی آتش، هر دو ویژگی مکانی و زمانی آتش مورد استفاده قرار گرفته است. در این تحقیق به‌طور خاص، از یک شبکه کانولوشنی استخراج ویژگی چند مقیاسی به همراه یک شبکه یولو استفاده شده تا بتواند قدرت تمایز اشیای مشابه آتش را بهبود بخشد. در واقع استفاده از لایه‌های کانولوشن با ابعاد مختلف، باعث استخراج جزئیات مکانی قوی‌تری می‌گردد. لایه‌های کانولوشن با ابعاد کوچک محتویات فرکانس پایین تصویر و لایه‌های کانولوشن با ابعاد بزرگ اطلاعات فرکانس بالای تصویر را استخراج می‌کند و این درحالی است که یک شبکه کانولوشنی معمولی به‌طور همزمان قادر به استخراج همگی این اطلاعات نیست. همچنین استفاده از شبکه یولو باعث شناسایی مکان دقیق اشیای مشابه آتش می‌گردد. سپس به‌منظور حذف بافت‌های غیرمتحرک مشابه آتش از روش تجزیه و تحلیل فراکتال محلی بر اساس آنالیز فراکتال و روش آستانه‌گیری استفاده شده است. از آنجا که یکی از ویژگی‌های اشیای فراکتال در تصویر تغییر سطح خاکستری آن در مقیاس‌های مختلف است، بنابراین می‌توان با استفاده از روش تجزیه و تحلیل فراکتال محلی در مقیاس‌های مختلف زمانی، اشیای متحرک را در تصویر جدا نمود. در مرحله بعدی، با تلفیق نتایج دو مرحله قبلی هر دو ویژگی مکانی و زمانی آتش مد نظر قرار گرفته می‌شود و در نهایت مناطق آتش از سایر نواحی تصویر جدا می‌گردد.

۲-۱- تشخیص مناطق نامزد با استفاده از شبکه عصبی کانولوشنی و یولو

به‌طور کلی، ساختار کانولوشن معمولی اطلاعات مکانی قوی و کافی را نشان نمی‌دهد. بنابراین در این کار، یک ماژول کانولوشنی چند مقیاسی پیشنهاد شده که برای به‌دست آوردن اطلاعات بیشتر در مورد جزئیات مکانی، به یک شبکه یولو متصل است.

همان‌طور که در شکل (۲) نشان داده شده است، ماژول کانولوشن پیشنهادی شامل ۳ شاخه مختلف و ۴۴ لایه است. در یک شاخه کانولوشن 3×3 و در دو شاخه دیگر از کانولوشن 5×5 و 7×7 برای به‌دست آوردن جزئیات مکانی محلی در محدوده وسیع‌تری استفاده شده است. در هر شاخه ۴ لایه کانولوشن وجود دارد و تعداد فیلترهای این لایه‌ها به‌ترتیب ۳۲، ۶۴، ۱۲۸ و ۲۵۶ است. بعد از هر کانولوشن، تابع فعال‌سازی واحد یکسوسده خطی^{۱۹} به‌عنوان عامل غیرخطی استفاده می‌شود. لایه‌های رأی‌گیری حداکثر^{۲۰} نیز برای نمونه‌برداری از تصاویر در مناطق تجمع استفاده می‌شود. لایه‌های رأی‌گیری حداکثر در شاخه کانولوشنی 3×3 دارای اندازه 2×2 هستند و در دو شاخه دیگر 2×2 و 3×3 هستند. در شاخه اول با کانولوشن 3×3 ، گام تمام لایه‌ها ۲ است و در شاخه دوم، گام لایه‌های اول و چهارم به‌ترتیب ۳ و ۱ و لایه‌های دیگر ۲ است. در شاخه سوم، گام اولین لایه ۳، لایه دوم ۱ و بقیه ۲ است. تصویر ورودی با اندازه $224 \times 224 \times 3$ در ماژول ذکر شده در سه شاخه تغذیه می‌شود تا سه نقشه ویژگی مختلف ایجاد شود. سپس این سه دسته نقشه ویژگی با یکدیگر ادغام شده و نقشه ویژگی جدیدی به‌دست می‌آید. این نقشه ویژگی جدید به‌عنوان ورودی به شبکه تشخیص شیء یولو داده شده است. الگوریتم یولو برای شناسایی و مکان‌یابی اجسام شبیه به آتش به‌کار گرفته شده است. لایه انتقال شبکه یولو برای افزایش ثبات شبکه برای محلی‌سازی شیء و لایه خروجی برای تصحیح محل جعبه‌های محصور کننده^{۲۱} برای منطقه آتش نامزد استفاده می‌شود [۲۱].


الگوریتم یولو تعداد زیادی جعبه‌های لنگر^{۲۲} را که در مناطق مختلف تصویر هستند تشخیص می‌دهد، بنابراین برای انتخاب بهترین آنها، ابتدا جعبه‌های لنگر با استفاده از روش K-نزدیکترین همسایه^{۲۳} و فاصله اقلیدسی به چند گروه طبقه‌بندی می‌شوند. سپس حداقل مختصات نسبت به مبدأ هر تصویر و حداکثر عرض و ارتفاع جعبه‌های لنگر انتخاب می‌شوند تا بهترین جعبه لنگر در هر گروه به‌دست آید. در نهایت، بهترین جعبه‌های لنگر رسم می‌شوند. نتایج تشخیص آتش در این مرحله در شکل (۳-الف) و نتایج انتخاب بهترین جعبه لنگر با استفاده از روش پیشنهادی در شکل (۳-ب) نشان داده شده است.

۲-۲- تشخیص بافت‌های متحرک بر اساس روش پتوی پوشان زمانی

یکی از مهم‌ترین ویژگی‌های آتش، پویایی آن است. از آنجایی که امکان وجود اجسام ثابت هم‌رنگ آتش در یک تصویر وجود دارد، شناسایی اجسام متحرک یک گام کلیدی برای حذف اجسام غیر متحرک مشابه آتش است. در این قسمت، جزئیات روش پیشنهادی برای تشخیص اشیای متحرک بیان شده است. هندسه فراکتال یک الگوی تکراری در اشیاء و تصاویر را نشان می‌دهد که این ویژگی را خود شباهت^{۲۴} می‌نامند. سنجشی که برای بیان این شباهت به‌کار رفته است، بُعد فراکتال (D) است. برای برآورد یک مقدار اندازه محلی از پیچیدگی و خودشباهتی، روش بُعد فراکتال محلی در مرجع [۲۲] ارائه شده است. این روش مقدار یک تابع چگالی را به هر پیکسل اختصاص می‌دهد. عملکرد بُعد فراکتال محلی $D(z)$ در نقطه z به‌صورت زیر محاسبه می‌شود:

$$D(z) = \lim_{r \rightarrow 0} \frac{\log(\mu(B(z, r)))}{\log(r)} \quad (1)$$

که عامل z نشان دهنده پیکسل پردازش شده است و $B(z, r)$ یک گوی بسته با مرکز z و شعاع r را نشان می‌دهد. در این روش با استفاده از تجزیه و تحلیل فراکتال مبتنی بر روش چگالی، اشیاء متحرک در فیلم تشخیص داده می‌شود. در حقیقت، الگوریتم پیشنهادی پیکسل‌ها و بافت‌های پویا در ویدئو را با به‌دست آوردن بُعد فراکتال محلی با تجزیه و تحلیل روش‌های مکانی و زمانی براساس روش پتوی پوشان جدا می‌کند. یکی از ویژگی‌های اشیاء فراکتال در تصویر تغییر سطح خاکستری در مقیاس‌های مختلف است. تغییر در منطقه اندازه‌گیری شده با تغییر مقیاس به‌عنوان "امضای فراکتالی" از بافت استفاده می‌شود که از روش پتوی پوشان برای اندازه‌گیری آن مطابق با مرجع [۲۳] استفاده می‌شود. در روش پتوی پوشان، تمام نقاط با فاصله ε از سطح تصویر در هر دو طرف، یک پتو با قطر 2ε ایجاد می‌کنند. بنابراین، مساحت سطح از طریق تقسیم حجم پتو بر 2ε به‌دست می‌آید. این پتو توسط سطح بالای آن u_ε و سطح زیرین آن b_ε تعریف شده است. سطح پتو برای $\varepsilon = 1, 2, 3, \dots$ مطابق رابطه‌های (۲) و (۳) است:



شکل (۲): معماری ماژول کانولوشنی پیشنهادی متصل شده به شبکه یولو

Figure (2): The architecture of the proposed CNN module connected to the YOLO network


$$u_{\varepsilon}(i, j) = \max \left\{ \begin{array}{l} u_{\varepsilon-1}(i, j) + 1, \max_{|(m, n) - (i, j) \leq 1} u_{\varepsilon-1}(m, n) \end{array} \right\} \quad (2)$$

$$b_{\varepsilon}(i, j) = \max \left\{ \begin{array}{l} b_{\varepsilon-1}(i, j) + 1, \max_{|(m, n) - (i, j) \leq 1} b_{\varepsilon-1}(m, n) \end{array} \right\} \quad (3)$$

جایی که در آن (i, j) آدرس پیکسل مورد نظر است و نقاط با مختصات (m, n) چهار همسایه (i, j) هستند. حجم پتو و مساحت سطح خاکستری برابر است با:

$$v_{\varepsilon} = \sum_{i, j} (u_{\varepsilon-1}(i, j) - b_{\varepsilon-1}(i, j)) \quad (4)$$

$$A(\varepsilon) = \frac{(v_{\varepsilon} - v_{\varepsilon-1})}{2} \quad (5)$$



(الف) نتایج خروجی الگوریتم یولو (ب) نتایج خروجی بعد از اعمال الگوریتم پیشنهادی

شکل (۳): انتخاب بهترین جعبه لنگر با استفاده از الگوریتم پیشنهادی

Figure (3): Selection of the best anchor box using the proposed method, a) Output results of YOLO algorithm, b) Output results after applying the proposed algorithm

با توجه به این که سطح خاکستری بافت متحرک در قاب‌های مختلف متفاوت است، از روش پتوی پوشان زمانی برای تشخیص این بافت استفاده می‌شود. روش کار به این صورت است که مقدار ε به جای افزایش در فضا در زمان افزایش می‌یابد و حجم و مساحت سطح خاکستری پیکسل‌ها در زمان محاسبه می‌شود. برای محاسبه بُعد فراکتال هر پیکسل با استفاده از روش پتوی پوشان، از چندین قاب قبل و بعد از قاب جاری در دنباله‌ی یک ویدئو استفاده می‌شود. ابتدا مقادیر شدت روشنایی هر پیکسل در قاب f_t مطابق رابطه‌ی ریاضی (۶) به عنوان مقادیر u_0 و b_0 انتخاب می‌شوند. u_0 و b_0 به ترتیب سطح بالایی و سطح پایینی اولیه و $I(i,j,f_t)$ مقدار شدت روشنایی پیکسل (i,j) را در قاب جاری نشان می‌دهد.

$$u_0(i,j) = b_0(i,j) = I(i,j,f_t) \quad (6)$$

سپس با استفاده از قاب‌های f_{t-n} ، f_{t+n} سطح بالایی u_n و سطح پایینی b_n از هر پیکسل مطابق روابط (۷) و (۸) محاسبه می‌شود.

$$u_n(i,j) = \max \left\{ \begin{array}{l} u_{n-1}(i,j) + 1, \\ \max[u_{n-1}(i,j,f_{t-n}), u_{n-1}(i,j,f_{t+n})] \end{array} \right\} \quad (7)$$

$$b_n(i,j) = \min \left\{ \begin{array}{l} b_{n-1}(i,j) - 1, \\ \min[b_{n-1}(i,j,f_{t-n}), b_{n-1}(i,j,f_{t+n})] \end{array} \right\} \quad (8)$$

در اینجا مقدار n برابر با ۳ است، یعنی سه قاب قبل و بعد از قاب فعلی در نظر گرفته می‌شود. سپس با استفاده از روابط (۴) و (۵) حجم مقادیر خاکستری در هر پیکسل و مساحت سطح خاکستری هر پیکسل در زمان محاسبه می‌شود. پس از آن، برای بدست آوردن بُعد فراکتال هر پیکسل، A_ε در مقابل ε در مقیاس $\log\text{-}\log$ ترسیم می‌شود و شیب خط بدست آمده بُعد فراکتال را نشان می‌دهد. سرانجام، تصویر خروجی تصویری است که مقادیر بُعد فراکتال بدست آمده برای هر پیکسل با مقادیر شدت آنها جایگزین شده است. در این تصویر قطعات متحرک با سایر قسمت‌های تصویر کاملاً متفاوت است. نتایج این مرحله بر روی دو ویدئو آتش و غیر آتش در شکل (۴) نمایش داده شده است. شکل (۴-الف) یک قاب از ویدئوها و شکل (۴-ب) تصاویر خروجی را با مقدار بُعد فراکتال برای هر پیکسل نشان می‌دهد.

سپس برای جدا کردن این پیکسل‌ها از سایر پیکسل‌های موجود در تصویر، از روش تعدیل هیستوگرام^{۲۵} و روش آستانه‌گذاری به وسیله هیستوگرام استفاده می‌شود. شکل (۵) نمودار هیستوگرام ابعاد فراکتال و هیستوگرام تعدیل شده را در یک قاب ویدیویی نشان می‌دهد. همان‌طور که در شکل (۵-الف) نشان داده شده است، بیشتر مقادیر دارای بُعد فراکتالی 0.36 هستند و فقط چند پیکسل دارای بُعد فراکتالی بزرگ‌تر از 0.36 و کوچک‌تر از 0.36 هستند.




(الف) یک قاب از دو ویدئو



(ب) تصاویر خروجی برای بُعد فراکتال

شکل (۴): نتایج تشخیص بافت‌های متحرک با استفاده از روش پتوی پوشان زمانی

Figure (4): Results of the moving objects detection based on temporal blanket method, a) A frame of two videos, b) Output images for the fractal dimension



(ب) اعمال تعدیل هیستوگرام

(الف) هیستوگرام بُعد فراکتال تصویر

شکل (۵): نمودار هیستوگرام

Figure (5): Histogram graph, a) Histogram of the fractal dimension, b) Histogram equalization applied to it



شکل (۶): نمونه‌ای از تصاویر پایگاه داده‌های ۱ تا ۴

Figure (6): Example images of datasets 1 to 4

اما هیستوگرام آن بسیار فشرده است و بنابراین، برای گسترش آن، از روش تعدیل هیستوگرام استفاده شده است. سپس با استفاده از رابطه‌ی ریاضی زیر، بافت‌های متحرک در تصویر جدا می‌شوند و در نهایت یک تصویر باینری به دست می‌آید.

$$IM(i, j) = \begin{cases} 1 & \text{if } \begin{cases} LD(i, j) > th1 \\ \text{or} \\ LD(i, j) < th2 \end{cases} \\ 0 & \text{else} \end{cases} \quad (9)$$

عامل $IM(i, j)$ پیکسل تصویر باینری خروجی در موقعیت i, j و LD بعد فراکتال تصویر در موقعیت‌های i و j است. مقادیر $th1$ و $th2$ با استفاده از روش سعی و خطا به دست می‌آیند.

۲-۳- تلفیق نتایج

در الگوریتم پیشنه‌ای، دو روش قبلی به‌طور موازی برای تشخیص دقیق بافت‌های آتش در هر قاب و برای جلوگیری از تشخیص نادرست بافت‌های شبیه آتش استفاده می‌شوند. در این قسمت، تصاویر خروجی مراحل قبلی با استفاده از منطق AND در سطح پیکسل ادغام می‌شوند تا همه پیکسل‌های متحرک آتش شناسایی شوند. لازم به ذکر است در صورت وجود ناحیه مشترک بین دو مرحله، ناحیه‌ای که توسط شبکه‌ی کانولوشنی شناسایی شده است، به‌عنوان ناحیه نامزد در نظر گرفته می‌شود.

۳- نتایج شبیه‌سازی

در این بخش، ابتدا جزئیات پایگاه داده‌های مورد استفاده در این کار شرح داده می‌شود. سپس نتایج به دست آمده از روش پیشنهادی مورد ارزیابی قرار گرفته و در نهایت این نتایج با روش‌های تشخیص آتش مبتنی بر روش‌های کانولوشنی و ویژگی‌های مهندسی دست‌ساز مقایسه می‌شوند.

۳-۱- معرفی پایگاه داده‌ها

در این تحقیق از پایگاه داده‌های جداگانه و متفاوتی برای آموزش و آزمون روش پیشنهادی استفاده شده است. در واقع پایگاه داده جدیدی برای آموزش شبکه بر اساس تصاویر و ویدئوهای موجود در مجموعه داده-آتش^{۲۶}، ویدئوهای مورد استفاده در آزمایشات کو^{۲۷} [۲۴] و تصاویر آتش و ویدئوهای موجود در اینترنت ایجاد شده است. این پایگاه داده شامل ۶۸۹۰ تصویر از آتش، ۱۲۶۹۰ تصویر غیر آتش است که برای آموزش شبکه کانولوشن پیشنهادی استفاده می‌شود. مجموعه داده-آتش و ویدئوهای مورد استفاده در آزمایشات کو را می‌توان به ترتیب از صفحات وب گیت‌هاب^{۲۸} و سی‌وی‌پی‌آر^{۲۹} بارگذاری کرد. مدل پیشنهادی توسط سیستمی با پردازنده مرکزی اینتل با هسته مدل i5-7200 و ۱۶ گیگابایت رم آموزش داده شده است. همچنین تعداد پارامترهای آموزشی در شبکه کانولوشن پیشنهادی ۴/۴ میلیون است. برای آزمایش روش پیشنهادی، سه مجموعه داده به نام پایگاه داده-۱، پایگاه داده-۲، پایگاه داده-۳ استفاده شده است. پایگاه داده-۱ شامل ۱۴ ویدئو آتش و ۸ ویدئو غیر آتش است که از ویدئوهای موجود در صفحه وب نایست^{۳۰} جدا شده‌اند [۲۵]. پایگاه داده-۲ تعداد ۳۱ ویدئو دارد که ۱۴ ویدئو اول شامل آتش و ۱۷ ویدئو دیگر، ویدئوهای غیر آتش هستند [۷]. پایگاه داده-۳ شامل ۱۱ ویدئو آتش و ۱۶ ویدئو غیر آتش است [۲۶]. نمونه‌ای از تصاویر پایگاه داده‌های ۱ تا ۴ در شکل (۶) نشان داده شده است.

۳-۲- معیارهای ارزیابی

دو مجموعه معیارهای ارزیابی برای تحلیل کارایی عملکرد روش‌های پیشنهادی در مقالات مورد استفاده قرار گرفته است. اولین مجموعه معیارها شامل صحت^{۳۱}، منفی کاذب^{۳۲} و مثبت کاذب^{۳۳} است. تعاریف این معیارها به شرح زیر نشان داده شده است.


- مثبت کاذب: ناحیه‌ای که به اشتباه در طبقه‌بندی آتش قرار می‌گیرد.
- منفی کاذب: ناحیه‌ای که به‌طور نادرست به عنوان قاب بدون آتش طبقه‌بندی می‌شود.

- صحت: نسبت تعداد نمونه‌هایی که به درستی شناسایی شده‌اند به کل مجموعه داده‌ها. مجموعه دوم شامل بازیابی^{۳۴}، دقت^{۳۵} و اندازه‌گیری اف^{۳۶} است.

- بازیابی، نسبت تعداد نمونه‌های مثبت تشخیص داده شده صحیح به تعداد کل نمونه‌های مثبت است.
- دقت، نسبت تعداد نمونه‌های مثبت تشخیص داده شده صحیح به تعداد کل نمونه‌های مثبت تشخیص داده شده است.
- اندازه‌گیری اف معیاری است که هم دقت و هم بازیابی را در یک اندازه واحد ترکیب می‌کند تا هر دو ویژگی را دربرگیرد. جزئیات کامل این معیارها را می‌توان در [۲۷] یافت.


۳-۳- نتایج الگوریتم پیشنهادی بر روی پایگاه داده‌های مختلف

در این بخش، عملکرد روش پیشنهادی بر روی پایگاه داده-۱، پایگاه داده-۲ و پایگاه داده-۳ مورد ارزیابی قرار گرفته است. جدول (۱) این نتایج را نشان می‌دهد. با توجه به جدول (۱)، واضح است که بهترین نتایج برای عامل‌های مثبت کاذب، منفی کاذب، بازیابی و صحت از نتایج پایگاه داده-۲ به دست می‌آید و به ترتیب مقادیری برابر با ۲/۰۵ درصد، ۱/۵۹ درصد، ۹۸/۴ درصد و ۹۸ درصد دارد. با این حال، بهترین مقدار برای عامل‌های دیگر مربوط به نتایج آزمایش پایگاه داده-۳ است. عامل‌های مثبت کاذب، منفی کاذب، بازیابی و صحت کمترین مقادیر را در ارزیابی پایگاه داده-۱ داشتند. در پایگاه داده-۲، عامل دقت ۸۷/۵ درصد را نشان می‌دهد که کمترین مقدار در بین نتایج سه مجموعه داده است. در شکل (۷)، ماتریس سردرگمی^{۳۷} روش پیشنهادی برای همه مجموعه داده‌های ۱ تا ۳ نشان داده شده است. بر اساس این ماتریس، عامل صحت برای تمامی نمونه‌های مورد آزمایش ۹۶/۱ درصد است، در حالی که مقادیر دقت و بازیابی به ترتیب ۹۲ درصد و ۹۶/۹ درصد است. نتایج به دست آمده در ۳ مجموعه داده نشان می‌دهد که الگوریتم پیشنهادی در شرایط مختلف عملکرد مناسب و قابل قبولی دارد. شکل‌های (۸) و (۹) نمونه‌هایی از تشخیص آتش با روش پیشنهادی در مراحل مختلف را نشان می‌دهد. در ویدئوهای نشان داده شده در شکل (۸)، آتش وجود دارد. ستون (الف) یک ویدئو آتش‌سوزی است، در ستون‌های (ب-ه)، نتایج الگوریتم پیشنهادی در مراحل مختلف نمایش داده شده است. در ویدئوهای شکل (۹)، آتش وجود ندارد، اما اجسام متحرک و ساکن مشابه آتش وجود دارد. در ویدئوی دوم شکل (۹)، یک پسر متحرک با پیراهن قرمز توسط الگوریتم به عنوان یک جسم متحرک مشخص می‌شود. از آنجا که در مرحله اول هیچ منطقه‌ای به عنوان آتش شناخته نمی‌شود، منطقه متحرک در مرحله تلفیق حذف می‌شود. در ویدئوی چهارم در هر دو مرحله، هیچ منطقه‌ای شناسایی نشده است. در ویدئو آخر، نور خورشید در مرحله اول به عنوان آتش تشخیص داده می‌شود، اما از آنجا که متحرک نیست و توسط مرحله دوم شناسایی نمی‌شود، در مرحله سوم حذف شده و از شناسایی اشتباه جلوگیری می‌کند. شکل (۱۰) نمونه‌ای از نتایج نهایی تشخیص آتش در سه مجموعه داده را نشان می‌دهد.



شکل (۷): ماتریس سردرگمی روش پیشنهادی بر روی مجموعه داده ۱ تا ۳

Figure (7): Confusion matrix of the proposed method on datasets 1 to 3



شکل (۸): تصاویر مراحل الگوریتم پیشنهادی (الف) ویدئوهای آتش، (ب) تشخیص نواحی نامزد با استفاده از شبکه‌ی کانولوشنی چند

مقایسه و بولو، (ج) تشخیص اشیای متحرک، (د) ترکیب نتایج دو مرحله، (ه) نتایج روش پیشنهادی

Figure (8): Images of the proposed algorithm steps, a) Fire videos, b) Candidate region detection with Multi-scale CNN & YOLOv2, c) Moving object detection, d) Fusion of the results of two methods, e) Result of proposed method

Table (1): Evaluation results of the proposed method on Datasets 1 to 3

جدول (۱): نتایج ارزیابی روش پیشنهادی بر روی سه پایگاه داده

پایگاه داده	مثبت کاذب (%)	منفی کاذب (%)	بازیابی (%)	دقت (%)	صحت (%)	اندازه F
پایگاه داده-۱	۸/۳	۴/۱۳	۹۵/۵	۸۹	۹۳	۰/۹۲۱
پایگاه داده-۲	۲/۰۵	۱/۵۹	۹۸/۴	۸۷/۵	۹۸	۰/۹۲۶
پایگاه داده-۳	۵/۲۳	۲/۴۱	۹۷/۵	۹۸/۴	۹۶/۹	۰/۹۷۹


۳-۴- مقایسه روش پیشنهادی با سایر روش‌های تشخیص آتش

در این قسمت، عملکرد روش پیشنهادی بر روی پایگاه داده-۲ با نتایج سایر روش‌های ارائه شده بر روی همین پایگاه داده مقایسه شده است. نتایج بدست آمده بر اساس این مجموعه داده و مقایسه آن با روش‌های به‌روز تشخیص آتش در جدول (۲) نشان داده شده است. روش‌های تشخیص آتش‌سوزی منتخب شامل هر دو روش تشخیص آتش بر اساس یادگیری عمیق و روش‌های قدیمی تشخیص آتش بر اساس ویژگی‌های دست‌ساز است. لازم به ذکر است که برخی نتایج در مقالات گزارش نشده‌اند، بنابراین در جدول نمایش داده نشده است. از نتایج جدول (۲) مشخص است که بهترین نتیجه را برای عامل منفی کاذب، مرجع‌های [۲۸]، [۷] و [۲۹] داشته‌اند. با این حال، مقدار مثبت کاذب در این سه روش در مقایسه با روش‌های یادگیری عمیق، مقدار نسبتاً بالایی است. علاوه بر این، صحت این سه روش از همه روش‌های مبتنی بر یادگیری عمیق و روش پیشنهادی کمتر است. نتایج مرجع [۱۹] در مقایسه با روش‌های دیگر خوب است، با این حال مقدار مثبت کاذب هنوز ۲/۳۳ درصد است و هنوز هم جایی برای بهبود صحت و مثبت کاذب وجود دارد. کار پیشنهادی، بر اساس روش یادگیری عمیق، با افزایش دقت از ۹۷/۹۴ درصد به ۹۸ درصد و کاهش مثبت کاذب از ۲/۳۳ درصد به ۲/۰۵ درصد، روند تشخیص آتش را بهبود بخشیده است. همچنین ۱/۵۹ درصد برای عامل منفی کاذب در روش پیشنهادی گزارش شده است. در این روش، تعادل بهتری بین صحت، منفی کاذب و مثبت کاذب برقرار شده و بنابراین روش پیشنهادی برای تشخیص آتش مناسب‌تر است. لازم به ذکر است که سرعت استنتاج روش پیشنهادی بر روی این مجموعه داده با دقت ۹۸ درصد معادل ۴ قاب بر ثانیه است.

۳-۵- تجزیه و تحلیل عامل‌ها

در مرحله دوم، الگوریتم پیشنهادی از روش تجزیه و تحلیل فراکتالی برای شناسایی اجسام متحرک در قاب‌های ویدئویی استفاده می‌کند. در پایان این مرحله، از روش آستانه‌گذاری با دو سطح آستانه $th1$ و $th2$ برای جدا کردن مناطق در حال حرکت استفاده شده است. این دو مقدار با آزمایش ۲۵۰ قاب ویدئویی اشیاء در حال حرکت با استفاده از روش آزمون و خطا به دست آمده است.

th1 = 0.9 و th2 = 0.1 فرض شده است. شکل (۱۱) دو نمونه از تصاویر خروجی و نمودارهای مربوط به آنها را در مرحله تجزیه و تحلیل فراکتال نشان می‌دهد. در شکل (۱۱-الف) یک قاب ویدئو و در شکل (۱۱-ب) تصویر بُعد فراکتال مربوط به آن قاب نمایش داده شده است. شکل (۱۱-ج)، نمودار هیستوگرام شکل (۱۱-ب) است. نمودارها در شکل (۱۱-ج) نشان می‌دهد که مقادیر شدت روشنایی اکثریت پیکسل‌ها که همان پیکسل‌های غیرمتحرک هستند، بین ۰/۱ تا ۰/۹ قرار می‌گیرد، بنابراین بهترین انتخاب برای th1 مقدار ۰/۹ و برای th2 مقدار ۰/۱ است.



شکل (۹): تصاویر مراحل الگوریتم پیشنهادی (الف) ویدئوهای غیر آتش، (ب) تشخیص نواحی نامزد با استفاده از شبکه‌ی کانولوشنی چند مقیاسه و یولو، (ج) تشخیص اشیای متحرک، (د) ترکیب نتایج دو مرحله، (ه) نتایج روش پیشنهادی

Figure (9): Images of the proposed algorithm steps, a) Non-Fire videos, b) Candidate region detection with Multi-scale CNN & YOLOv2, c) Moving object detection, d) Fusion of the results of two methods, e) Result of proposed method




شکل (۱۰): نتایج روش پیشنهادی بر روی نمونه‌های مختلف

Figure (10): Result of proposed method on sample images

Table (2): Comparison of the proposed method with state-of-the-art fire detection methods

جدول (۲): نتایج مقایسه روش پیشنهادی با سایر روش‌های تشخیص آتش

روش	مثبت کاذب (%)	منفی کاذب (%)	صحت (%)
الگوریتم پیشنهادی	۲/۰۵	۱/۵۹	۹۸
[۳۳]	---	---	۹۵/۳
[۳۴]	۳/۰۴	۱/۷۳	۹۵
[۳۵]	۳/۹۱	۴/۵۸	۹۳/۲۱
[۱۶]	۸/۸۷	۲/۱۲	۹۴/۵
[۳۰]	۳/۰۲	۲/۲۶	۹۷/۳۶
[۱۸]	۹/۰۷	۲/۱۳	۹۴/۳۹
[۱۹]	۲/۳۳	۰/۸۴	۹۷/۹۴
[۲۸]	۲۹/۴۱	۰	۸۳/۸۷
[۷]	۱۱/۶۷	۰	۹۳/۵۵
[۲۷]	۵/۸۸	۱۴/۲۲	۹۰/۳۲
[۵]	۱۱/۷۶	۱۴/۲۲	۸۷/۱۰
[۲۹]	۱۳/۳	۰	۹۲/۸۶
[۳۱]	۴۱/۱۸	۷/۱۴	۷۴/۲۰
[۳۲]	۱۷/۶۵	۷/۱۴	۸۷/۱۰



شکل (۱۱): دو نمونه از تصاویر خروجی و نمودارهای مربوط به آنها در مرحله تجزیه و تحلیل فراکتال

Figure (11): Two examples of the output images and their related graphs in the fractal analysis stage, a) A fire video frame, b) Fractal image of the video frame, c) Fractal dimensional image histogram

۴- نتیجه‌گیری

تشخیص آتش یکی از مهم‌ترین نیازهای سیستم‌های نظارتی و امنیتی در کاربردهای صنعتی است. در این تحقیق الگوریتم جدیدی برای تشخیص آتش ارائه شده است. این الگوریتم مبتنی بر شبکه‌های عصبی یادگیری عمیق و تجزیه و تحلیل فراکتال است. در این روش سعی شده است که هر دو ویژگی مکانی و پویایی آتش مورد تجزیه و تحلیل قرار گیرد، بنابراین از یک شبکه کانولوشنی چند مقیاسی متصل شده به یک شبکه یولو v2 به منظور استخراج ویژگی‌های مکانی آتش و شناسایی مکان دقیق آن در الگوریتم پیشنهادی استفاده شده است. تجزیه و تحلیل فراکتال محلی بر اساس روش پتوی پوشان زمانی نیز برای بررسی

ویژگی پویایی اجسام استفاده شده است. نتایج تجربی بر روی چندین پایگاه داده شامل آتش واقعی و اشیاء مشابه آتش نشان می‌دهد که این الگوریتم قادر به تشخیص آتش واقعی با دقت و صحت بالا است. اگرچه الگوریتم پیشنهادی صحت و دقت تشخیص آتش را افزایش داده و باعث بهبود عامل مثبت کاذب شده است، اما همچنان این عامل به مقدار صفر نرسیده است. همچنین با وجود این که مقدار عامل منفی کاذب در الگوریتم پیشنهادی به مقدار قابل قبولی رسیده است، با این حال برای دستیابی به مقدار بهتر، تحقیقات بیشتری باید انجام گردد تا بتوان بر این نقیصه فایق آمد. از آنجایی که در بیشتر مواقع آتش‌سوزی با دود همراه است، بنابراین اضافه کردن الگوریتم‌های شناسایی دود در کنار شناسایی آتش باعث می‌گردد سامانه‌های تشخیص آتش در شرایط پیچیده دنیای واقعی بهتر کار کنند.

References

مراجع

- [1] W.S. Qureshi, M. Ekpanyapong, M.N. Dailey, S. Rinsurongkawong, A. Malenichev, O.Krasotkina, "QuickBlaze: Early fire detection using combined video processing approach", *Fire Technology*, vol. 52, no. 5, pp. 1293–1317, Sept. 2016 (doi: 10.1007/s10694-015-0489-7).
- [2] Z. Teng, J.H. Kim, D.J. Kang, "Fire detection base on hidden markov models", *International Journal of Control, Automation and Systems*, vol. 8, no. 4, pp. 822–830, Aug. 2010 (doi:10.1007/s12555-010-0414-2).
- [3] Th. H. Chen, P. H. Wu, Y. Ch. Chiou, "An early fire-detection method based on image processing", *Proceeding of the IEEE/ICIP*, vol. 3, pp.1707-1710, Singapore, Oct. 2004 (doi: 10.1109/ICIP.2004.1421401).
- [4] Y. H. Habiboğlu, O. Günay, A. E. Çetin, "Covariance matrix-based fire and flame detection method in video", *Machine Vision and Application*, vol. 23, no. 6, pp. 1103–1113, Nov. 2012 (doi:10.1007/s00138-011-0369-1).
- [5] S.G. Kong, D. Jin, Sh. Li, H. Kim, "Fast fire flame detection in surveillance video using logistic regression and temporal smoothing", *Fire Safety Journal*, vol. 79, pp. 37-43, Jan. 2016 (doi: 10.1016/j.firesaf.2015.11.015).
- [6] J. Seo, M. Kang, Ch. H. Kim, J. M. Kim, "An optimal many-core model-based supercomputing for accelerating video-equipped fire detection", *The Journal of Supercomputing*, vol. 71, no. 6, pp. 2275–2308, June 2015 (doi: 10.1007/s11227-015-1382-3).
- [7] P. Foggia, A. Saggese, M. Vento, "Real-time Fire Detection for Video Surveillance Applications using a Combination of Experts based on Color, Shape and Motion", *IEEE Trans. on Circuits and Systems for Video Technology*, vol. 25, no. 9, pp. 1545 – 1556, Sept. 2015 (doi: 10.1109/TCSVT.2015.2392531).
- [8] W. B. Horng, J. W. Peng, Ch. Y. Chen, "A new image-based real-time flame detection method using color analysis", *Proceedings of the IEEE/ICNSC, USA*, March 2005 (doi: 10.1109/ICNSC.2005.1461169).
- [9] B. Töreyn, Y. Dedeoğlu, U. Güdükbay and A. E. Çetin, "Computer vision based method for real-time fire and flame detection", *Pattern Recognition Letters*, vol. 27, no.1, pp. 49-58, Jan. 2006 (doi: 10.1016/j.patrec.2005.06.015).
- [10] Y.R. Pu, Y.J. Chen, S.H. Lee, "Fire recognition based on correlation of segmentations by image processing techniques", *Machine Vision and Application*, vol. 26, no. 7–8, pp. 849–856, Nov. 2015 (doi: 10.1007/s00138-015-0698-6).
- [11] S. Verstockt, S. V. Hoecke, T. Beji, B. Merci, B. Gouverneur, A. E. Cetin, P. DePotter, R. V. Walle, "A multi-modal video analysis approach for car park fire detection", *Fire Safety Journal*, vol. 57, pp. 44-57, Apr. 2013 (doi:10.1016/j.firesaf.2012.07.005).
- [12] T. X. Truong, J. M. Kim, "Fire flame detection in video sequences using multi-stage pattern recognition techniques", *Engineering Application of Artificial Intelligence*, vol. 25, no. 7, pp. 1365-1372, Oct. 2012 (doi: 10.1016/j.engappai.2012.05.007).
- [13] F. Yuan, "An integrated fire detection and suppression system based on widely available video surveillance", *Machine Vision and Application*, vol. 21, no. 6, pp. 941–948, Oct. 2010 (doi: 10.1007/s00138-010-0276-x).
- [14] M. Torabian, H. Pourghassem, "Dynamic-based fire detection using fusion of markov random field and PCA optical flow", *Proceeding of the IEEE/ICEE, Iran*, Apr. 2019 (doi: 10.1109/IranianCEE.2019.8786704).
- [15] F. Sthevanie, H. Nugroho, F.A. Yulianto, "Visual-based fire detection using local binary pattern-three orthogonal planes", *Proceeding of the IEEE/CYBERNETICSCOM*, pp. 155-159, Indonesia, Dec. 2013 (doi: 10.1109/CyberneticsCom.2013.6865801).
- [16] K. Muhammad, J. Ahmad, Z. Lv, P. Bellavista, P. Yang, S. W. Baik, "Efficient deep CNN-based fire detection and localization in video surveillance applications", *IEEE Trans. on Systems, Man, and Cybernetics: Systems*, vol. 49, no. 7, pp. 1419–1434, July 2019 (doi: 10.1109/TSMC.2018.2830099).

- [17] K. Muhammad, J. Ahmad, I. Mehmood, S. Rho, B.S. Wook, "Convolutional neural networks based fire detection in surveillance videos", *IEEE Access*, vol. 6, pp.18174-18183, March 2018 (doi: 10.1109/ACCESS.2018.2812835).
- [18] K. Muhammad, J. Ahmad, S.W. Baik, "Early fire detection using convolutional neural networks during surveillance for effective disaster management", *Neurocomputing*, vol. 288, pp. 30–42, May 2018 (doi: 10.1016/j.neucom.2017.04.083).
- [19] Y. Xie, J. Zhu, Y. Cao, Y. Zhang, D. Feng, Y. Zhang, M. Chen, "Efficient video fire detection exploiting motion-flicker-based dynamic features and deep static features", *IEEE Access*, vol. 8, pp. 81904–81917, April 2020 (doi: 10.1109/ACCESS.2020.2991338).
- [20] C. Chaoxia, W. Shang, F. Zhang, "Information-guided flame detection based on faster R-CNN", *IEEE Access*, vol. 8, pp. 58923-58932, April 2020 (doi: 10.1109/ACCESS.2020.2982994).
- [21] S. Saponara, A. Elhanashi, A. Gagliardi, "Real-time video fire/smoke detection based on CNN in antifire surveillance systems", *Journal of Real-Time Image Processing*, vol. 18, pp. 889–900, Nov. 2021 (doi: 10.1007/s11554-020-01044-0).
- [22] Y. Xu, H. Ji, C. Fermüller, "Viewpoint invariant texture description using fractal analysis", *International of Journal Computer Vision*, vol. 83, no. 1, pp. 85-100, June 2009 (doi: 10.1007/s11263-009-0220-6).
- [23] S. Peleg, J. Naor, R. Hartley, D. Avnir, "Multiple resolution texture analysis and classification", *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 6, no. 4, pp. 518-523, July 1984 (doi: 10.1109/TPAMI.1984.4767557).
- [24] B. Ch. Ko, K. H. Cheong, J. Y. Nam, "Early fire detection algorithm based on irregular patterns of flames and hierarchical Bayesian Networks", *Fire Safety Journal*, vol. 45, no. 4, pp. 262-270, June 2010 (doi: 10.1016/j.firesaf.2010.04.001).
- [25] P. Li, W. Zhao, "Image fire detection algorithms based on convolutional neural networks", *Case Studies in Thermal Engineernig*, vol. 19, Article Number: 100625, June 2020 (doi: 10.1016/j.csite.2020.100625).
- [26] K. Dimitropoulos, P. Barmpoutis, N. Grammalidis, "Spatio-temporal flame modeling and dynamic texture analysis for automatic video-based fire detection", *IEEE Trans. on Circuits and Systems for Video Technology*, vol. 25, no. 2, pp. 339–351, Feb. 2015 (doi: 10.1109/TCSVT.2014.2339592).
- [27] K. Muhammad, M. Sajjad, M. Y. Lee, S. W. Baik, "Efficient visual attention driven framework for key frames extraction from hysteroscopy videos", *Biomedical Signal Processing and Control*, vol. 33, pp. 161-168, Mar. 2017 (doi: 10.1016/j.bspc.2016.11.011).
- [28] T. Çelik, H. Demirel, "Fire detection in video sequence using a generic color model", *Fire Safety Journal*, vol. 44, no. 2, pp. 147-158, Feb. 2009 (doi: 10.1016/j.firesaf.2008.05.005).
- [29] R. D. Lascio, A. Greco, A. Saggese, M. Vento, "Improving fire detection reliability by a combination of video analytics", *Peoceeding of the ICIAR*, vol. 8814, pp. 477-484, Oct. 2014 (doi: 10.1007/978-3-319-11758-4_52).
- [30] Y. Wua, Y. He, P. Shivakumara, Z. Li, H. Guo, Tong Lu, "Channel-wise attention model-based fire and rating level detection in video", *CAAI Transaction on Intelligence Technology*, vol. 4, no. 2, pp. 1-9, April 2019 (doi: 10.1049/trit.2019.0022).
- [31] A. Ra_ee, R. Dianat, M. Jamshidi, R. Tavakoli, S. Abbaspour, "Fire and smoke detection using wavelet analysis and disorder characteristics", *Proceeding of the IEEE/ICCRD*, pp. 262_265, China, Mar. 2011 (doi: 10.1109/ICCRD.2011.5764295).
- [32] S. Rudz, K. Chetehouna, A. Hafiane, H. Laurent, O. Séro-Guillaume, "Investigation of a novel image segmentation method dedicated to forest fire applications", *Measurement Science and Technology*, vol. 24, no. 7, Jun. 2013 (doi: 10.1088/0957-0233/24/7/075403).
- [33] S. Li, Q. Yan, P. Liu, "An efficient fire detection method based on multiscale feature extraction, implicit deep supervision and channel attention mechanism", *IEEE Trans. on Image Processing*, vol. 29, pp. 8467-8475, Aug. 2020 (doi: 10.1109/TIP.2020.3016431).
- [34] B. Kim, J. Lee, "A video-based fire detection using deep learning models", *Applied Sciences*, vol. 9, no. 14, July 2019 (doi: 10.3390/app9142862).
- [35] J. Zhang, H. Zhu, P. Wang, X. Linga, "Lightweight network for forest fire detection and recognition", *IEEE Access*, vol. 9, pp. 10858 – 10870, Jan. 2021 (doi: 10.1109/ACCESS.2021.3050628).

زیر نویس‌ها

1. Red-green-blue (RGB)
2. Luminance-chrominance blue-chrominance red (YCbCr)
3. Hue-saturation-intensity (HIS)
4. Luminance-blue projection-red projection (YUV)
5. Gaussian mixture

6. Background subtraction model
7. Optical flow
8. Local binary pattern-three orthogonal planes (LBP-TOP)
9. Support vector machine (SVM)
10. Fusion
11. Logistic regression
12. Squeeze-net
13. Google-net
14. Field programmable gate array (FPGA)
15. Adaptive light convolution neural network
16. Faster region convolution neural network (Faster R-CNN)
17. You only look once
18. Temporal blanket
19. Rectified linear unit (ReLU)
20. Max-pooling
21. Bounding boxes
22. Anchor boxes
23. k-nearest neighbors (KNN)
24. Self-similarity
25. Histogram equalization
26. Fire-dataset
27. Ko
28. <https://github.com/sulenn/fire-dataset>
29. <http://cvpr.kmu.ac.kr>
30. <https://www.nist.gov/fire>
31. Accuracy
32. False negative (FN)
33. False positive (FP)
34. Recall
35. Precision
36. F-Measure (F1-score)
37. Confusion matrix