

<https://dorl.net/dor/20.1001.1.23223871.1401.13.50.4.5>

Research Article

Double JPEG Compression Detection Using Spatial-Domain Deep Neural Networks

Mohammad Rahmati¹, *PhD Student*, Farbod Razzazi¹, *Associate Professor*, Alireza Behrad²,
Professor

¹Department of Electrical and Computer Engineering- Science and Research Branch, Islamic Azad University, Tehran, Iran

²Electrical Engineering Department- Shahed University, Tehran, Iran
mohrahmati@gmail.com, razzazi@srbiau.ac.ir, behrad@shahed.ac.ir

Abstract

With the increasing interest in Joint Photographic Experts Group (JPEG) image compression, one of the most important issues in digital image manipulation is finding a proper method to detect double JPEG compression. This paper introduces a trained adaptive filter based on spatial-domain convolutional autoencoder (CAE). This filter can remove interference information caused by image content to have a more accurate detection. The convolutional neural network (CNN) has been widely employed for accurate image classification; therefore, a CNN is used in the classification part of the proposed algorithm. The proposed model is based on consecutive CAE with CNN, which is able to provide acceptable detection accuracy and sensitivity to quality factors (QFs) in two scenarios, i.e. aligned and non-aligned forgeries. This model improves the sensitivity to quality factors by up to 86% in the relative error reduction (RER) rate in some cases. Other experiments such as manipulation localization on the RAISE dataset have been performed to evaluate the proposed method. These results show the superior performance of this method compared to similar algorithms in the situations that the quality factor of the second compression is greater the quality factor of the first compression.

Keywords: adaptive filter, convolutional neural network, convolutional autoencoder, detection accuracy, manipulation localization

Received: 10 May 2021

Revised: 8 June 2021

Accepted: 13 August 2021

Corresponding Author: Dr. Farbod Razzazi

Citation: M. Rahmati, F. Razzazi, A. Behrad,, "Double JPEG compression detection using spatial-domain deep neural networks", Journal of Intelligent Procedures in Electrical Technology, vol. 13, no. 50, pp. 67-82, September 2022 (in Persian).

<https://dorl.net/dor/20.1001.1.23223871.1401.13.50.4.5>

مقاله پژوهشی

آشکارسازی فشرده‌سازی JPEG مضاعف با استفاده از شبکه‌های عصبی عمیق در حوزه مکان

محمد رحمتی^۱، دانشجوی دکتری، فرید رزازی^۱، دانشیار، علیرضا بهراد^۲، استاد

۱- دانشکده مهندسی برق و کامپیوتر- واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

۲- دانشکده فنی و مهندسی- دانشگاه شاهد، تهران، ایران

mohrahmati@gmail.com, razzazi@srbiau.ac.ir, behrad@shahed.ac.ir

چکیده: با افزایش علاقه‌مندی به فشرده نمودن تصاویر با فرمت گروه مشترک متخصصان عکاسی (JPEG)، یکی از مهم‌ترین مباحث در دست‌کاری تصاویر دیجیتال، یافتن روشی مناسب جهت آشکارسازی فشرده‌سازی JPEG مضاعف است. در این مقاله با معرفی یک فیلتر تطبیقی آموزش‌دیده بر پایه خودرمزگذار پیچشی (CAE) و در حوزه مکان، به این موضوع پرداخته می‌شود تا با حذف اطلاعات تداخلی ناشی از محتوای تصویر، آشکارسازی دقیق‌تری داشته باشیم. از آنجایی که شبکه عصبی پیچشی (CNN) توانسته عملکرد موفقی در طبقه‌بندی تصاویر داشته باشد، از این شبکه‌ها در قسمت طبقه‌بندی استفاده می‌شود. مدل پیشنهادی بر اساس CAE متوالی شده با CNN است که توانسته دقت آشکارسازی و حساسیت به ضرایب کیفیت (QFs) قابل قبولی را در دو سناریوی هم‌تراز و ناهم‌تراز ارائه نماید. این مدل توانسته در برخی از حالت‌ها، حساسیت نسبت به ضرایب کیفیت را تا ۸۶ درصد در مقدار کاهش خطای نسبی (RER) بهبود دهد. آزمایش‌های دیگری از جمله مکان‌یابی محل دست‌کاری بر روی مجموعه داده RAISE برای ارزیابی روش پیشنهادی انجام شده است. این نتایج نشان‌دهنده عملکرد بسیار خوب این روش نسبت به الگوریتم‌های مشابه در شرایطی است که ضریب کیفیت فشرده‌سازی دوم بزرگ‌تر از ضریب کیفیت فشرده‌سازی اول باشد.

کلمات کلیدی: شبکه عصبی پیچشی، خودرمزگذار پیچشی، فیلتر تطبیقی، صحت آشکارسازی، مکان‌یابی محل دست‌کاری

تاریخ ارسال مقاله: ۱۴۰۰/۲/۲۰

تاریخ بازنگری مقاله: ۱۴۰۰/۳/۱۸

تاریخ پذیرش مقاله: ۱۴۰۰/۵/۲۲

نام نویسنده‌ی مسئول: دکتر فرید رزازی

نشانی نویسنده‌ی مسئول: تهران- دانشگاه آزاد اسلامی واحد علوم و تحقیقات- دانشکده مهندسی برق و کامپیوتر

۱- مقدمه

با ظهور وسیله‌های پیشرفته ضبط اسناد دیجیتال و فناوری‌های جدید پردازش تصاویر دیجیتال، دست‌کاری در تصاویر به راحتی امکان‌پذیر شده است. این تصاویر ممکن است به عنوان مدرکی از یک پرونده رسمی یا پزشکی باشند که در دادگاه مورد ارزیابی و صحت‌سنجی قرار می‌گیرند. روش‌های جعل‌شناسی با توجه به ویژگی‌های آماری و ناسازگاری‌های ناشی از جعل ایجاد شده در تصویر، قادر به تعیین اعتبار تصاویر دیجیتال هستند. از آنجایی که بسیاری از این تصاویر با فرمت گروه مشترک متخصصان عکاسی^۱ (JPEG) ذخیره می‌شوند، بررسی اصالت و حفاظت از تصاویر JPEG مورد اهمیت است. معمولاً با استفاده از نرم‌افزارهای مختلف مانند فتوشاپ [۱] و بیوتی‌کم^۲ [۲]، دست‌کاری در تصاویر اتفاق می‌افتد و این تصاویر مجدداً به صورت JPEG ذخیره می‌شوند. این موضوع سبب می‌شود که علاقه به بررسی عوارض^۳ ناشی از فشرده‌سازی JPEG مضاعف به عنوان یکی از مهم‌ترین اثرات نشان‌دهنده دست‌کاری تصویر، افزایش یابد. از طرفی، با توجه به اینکه مربع‌بندی^۴ فشرده‌سازی JPEG دوم نسبت به اول در حالت هم‌تراز^۵ یا ناهم‌تراز^۶ قرار می‌گیرد، عوارض متفاوتی ایجاد می‌شود. به همین دلیل معمولاً دو سناریوی جهت تحلیل و ارزیابی می‌تواند مورد توجه باشد. این در حالی است که متأسفانه روش‌های پیشنهادی بسیاری از مقاله‌ها تنها قادر به آشکارسازی فشرده‌سازی JPEG مضاعف در یکی از این دو سناریو هستند [۳-۵]. در این مقاله روشی برای آشکارسازی در هر دو سناریو و تحت عنوان آشکارسازی فشرده‌سازی JPEG مضاعف هم‌تراز^۷ (A-DJPEG) و آشکارسازی فشرده‌سازی JPEG مضاعف ناهم‌تراز^۸ (NA-DJPEG)، بررسی شده است.

۱-۱- پیشینه تحقیق

مطالعات بسیاری عوارض باقیمانده از فشرده‌سازی JPEG مضاعف را در حوزه مکان [۶]، حوزه تبدیل [۷-۸] و یا ترکیب هر دو حوزه جهت استفاده هم‌زمان از مزایای آنها [۹] را بررسی نموده‌اند. در این راستا از روش‌های بر پایه ویژگی‌های دست‌ساز^۹ [۱۰، ۱۱] و یا روش‌های داده‌محور بر پایه شبکه عصبی پیچشی^{۱۰} (CNN) [۶، ۱۲] استفاده کرده‌اند. پژوهشگران در مرجع [۱۳] با استفاده از الگوریتم استاندارد SIFT [۱۴] جهت آشکارسازی جعل اقدام نموده‌اند. برخی از مطالعات توزیع اولین ارقام پراهمیت ضرایب کسینوسی گسسته^{۱۱} (DCT) بلوکی [۷، ۱۵] و برخی دیگر تحلیل فوریه-بنفورد^{۱۲} [۸] را به کار گرفته‌اند. پژوهشگران در مرجع [۱۶] از یک مدل آماری بر اساس هیستوگرام ضرایب DCT استفاده نموده‌اند. این در حالی است که محمود و همکاران، گشتاورهای چبیشف^{۱۳} را از بلوک‌های دارای هم‌پوشانی یک تصویر دیجیتال استخراج نموده و پس از کاهش تعداد ویژگی‌ها، با استفاده از تجزیه مقادیر منفرد^{۱۴} (SVD) آشکارسازی جعل را انجام داده‌اند [۱۷].

با پیشرفت فناوری، امکان پیاده‌سازی روش‌های یادگیری عمیق در الگوریتم‌های پردازش تصاویر دیجیتال میسر گردید و نتایج موفق‌تری حاصل شد. به همین دلیل مطالعات زیادی سعی در آشکارسازی ویژگی‌های لازم بر اساس شبکه‌های عصبی عمیق در کاربردهای بازجویی تصاویر نموده‌اند. در مرجع [۱۲] یک شبکه CNN یک‌بعدی با استفاده از هیستوگرام ضرایب DCT قسمت Y تصویر، آموزش داده شده است. اخیراً روش‌های دیگری نیز از مزایای حوزه DCT و عوارض باقیمانده در هر مرحله فشرده‌سازی JPEG جهت آشکارسازی، استفاده نموده‌اند. پژوهشگران در مرجع [۴] از ضرایب DCT خام و ماتریس کوانتیزاسیون کمک گرفته‌اند. حال آنکه در مرجع [۳]، از هیستوگرام ضرایب DCT و ماتریس کوانتیزاسیون استفاده شده است. در کلیه این روش‌ها، آشکارسازی تنها در حالت هم‌تراز امکان‌پذیر است و الگوریتم‌ها در حالت ناهم‌تراز با شکست مواجه می‌شوند. به‌منظور آشکارسازی در حالت ناهم‌تراز، پژوهشگران در مرجع [۱۸] از اطلاعات رنگی موجود در تصاویر رنگی و تبدیل کسینوسی کمک گرفته و نتایج خوبی را ارائه نموده‌اند. این روش نیز صرفاً در حالت ناهم‌تراز بوده و برای تصاویر خاکستری پاسخگو نیست. مطالعه جامعی در مرجع [۶] انجام شده و سه روش مختلف بر پایه CNN جهت آشکارسازی فشرده‌سازی JPEG مضاعف پیشنهاد شده است. این مطالعه توانسته نتایج بسیار خوبی را در حالت‌های هم‌تراز و ناهم‌تراز به‌دست آورد. در روش‌های اول و دوم با استفاده از پیش‌پردازش تلاش کرده‌اند که اطلاعات تداخلی محتوای تصویر را جهت تصمیم‌گیری مناسب CNN در حوزه مکان حذف نمایند. به‌این منظور در روش اول متوسط تصاویر از هر تصویر کم شده و در روش دوم از اپراتور حذف نویز^{۱۵} مطرح شده در مرجع [۱۹] استفاده نموده‌اند. از طرفی عوارض باقیمانده جهت آشکارسازی فشرده‌سازی JPEG مضاعف در حالت هم‌تراز در حوزه DCT

بیشتر است [۶]. بنابراین در روش سوم مطرح شده در این مطالعه، با کمک هیستوگرام ضرایب DCT توانسته‌اند که آشکارسازی بهتری را در حالت هم‌تراز به دست آورند.

اهمیت حذف محتوای تصویر به عنوان یک سیگنال تداخلی در آشکارسازی دست‌کاری در تصاویر دیجیتال قابل تأمل است [۲۰]. به همین دلیل برخی از مطالعات تلاش کرده‌اند که قابلیت اجرایی طبقه‌بند خود را با حذف محتوای تصویر افزایش دهند [۲۱]. در این راستا از فیلترهای مختلفی مانند فیلتر بالاگذر تفاضلی استفاده نموده‌اند تا اطلاعات فرکانس پایین تصویر را حذف نمایند [۲۱]. در مرجع [۲۲] با کمک ۳۰ فیلتر بالاگذر بر اساس مدل غنی فضایی^{۱۶} [۲۳] در ورودی شبکه CNN پیشنهادی، اقدام به حذف محتوای تصویر نموده‌اند. پژوهشگران در مطالعه‌ای دیگر از فیلتر پایین‌گذر میانه استفاده کردند و باقیمانده فیلتر میانه^{۱۷} را وارد شبکه CNN نموده‌اند [۲۴]. روش دیگری نیز از ساختار فیلترهای بالاگذر الهام گرفته و یک لایه پیچشی بر اساس روابط محلی بین پیکسل‌ها را در ورودی شبکه CNN پیشنهاد نموده است [۲۵]. از طرفی مطالعات انجام شده نشان می‌دهد که با کمک شبکه خودرم‌گذار پیچشی^{۱۸} (CAE) می‌توان جهت حذف نویز فرکانس بالا اقدام نمود و نتایج خوبی را به دست آورد [۲۶]. این موضوع به علت استفاده از تمام ظرفیت شبکه CAE با وجود عملکرد پیچش است. زیرا وزن‌ها در کل فضای تصویر به اشتراک گذاشته می‌شوند و در نتیجه کل فضای تصویر در تعیین بهینه وزن‌ها نقش خواهد داشت.

۱-۲- انگیزش و نوآوری

بررسی‌ها نشان می‌دهد که مطالعات زیادی جهت حذف محتوای تصویر از فیلترهای بالاگذر استفاده نموده‌اند. اما بسیاری از آنها از فیلترهایی که منطبق بر کاربرد موردنظر باشد، استفاده نموده‌اند. در این مقاله فیلتر بر اساس کاربرد موردنظر که آشکارسازی فشرده‌سازی JPEG مضاعف است، طراحی شده است. از طرفی با بررسی پژوهش‌های مشابه مشاهده می‌شود که اکثر مقاله‌ها، آشکارسازی را تنها در حالت هم‌تراز یا ناهم‌تراز انجام داده‌اند. بنابراین نیاز به یک راه حل جامع برای آشکارسازی در هر دو حالت احساس می‌گردد. ضمن اینکه مقاله‌های اخیر از ماتریس کوانتیزاسیون به عنوان اطلاعات اضافی استفاده نموده‌اند [۳،۴،۱۸]. این ماتریس در بسیاری کاربردها در دسترس نیست و یا به دست آوردن آن فرایندی چالشی است. مطمئناً پیشنهاد یک روش مستقل از این اطلاعات اضافی، می‌تواند گام مفیدی در جهت بهبود این فناوری باشد. ضمن اینکه با پیشنهاد روشی که در هر دو حالت هم‌تراز و ناهم‌تراز آشکارسازی موفق داشته باشد، امکان آشکارسازی در صورت از دست رفتن هم‌ترازی^{۱۹} نیز امکان‌پذیر می‌شود. از طرف دیگر یکی از مهم‌ترین نکاتی که بایستی در طراحی آشکارساز مدنظر قرار داد، تعیین محل دست‌کاری شده در تصویر است. این در حالی است که بسیاری از مقاله‌ها به اینکه آیا تصویر دست‌کاری شده یا خیر، قناعت می‌نمایند. در این مطالعه، با بلوک‌بندی تصویر با ابعاد مناسب برای تعیین محل دست‌کاری اقدام شده است. واضح است که با تعیین بلوک‌های با اندازه بسیار کوچک، فرایند آشکارسازی در هر بلوک مشکل خواهد بود و از طرفی با در نظر گرفتن بلوک‌های با اندازه بزرگ، دقت مکان‌یابی در تصویر کاهش می‌یابد. به طور خلاصه اصلی‌ترین نوآوری‌های روش پیشنهادی به قرار زیر است:

- در این مقاله یک شبکه CAE به عنوان فیلتر تطبیقی حذف‌کننده محتوای تصویر آموزش داده شده است. در این صورت CAE آموزش دیده با تصاویر JPEG و DJPEG انطباق مناسبی بر فرایند آشکارسازی خواهد داشت. در این صورت با این نوآوری و استفاده از فیلتر منطبق بر کاربرد امکان بهبود آشکارسازی فراهم شده است.

- در این مقاله از معماری جدیدی برای شبکه‌های عصبی عمیق استفاده شده است.

- آشکارسازی در حوزه مکان انجام شده تا امکان آشکارسازی برای تصاویر با فرمت تصاویر شبکه‌ای قابل حمل^{۲۰} (PNG) و نقشه بیتی (bitmap) هم امکان‌پذیر شود.

- با در نظر گرفتن بلوک‌های با اندازه کوچک ۶۴×۶۴ توانستیم محل دست‌کاری در تصویر را با دقت خوبی مشخص نماییم.

- معماری شبکه‌ها در حالت هم‌تراز و ناهم‌تراز یکسان در نظر گرفته شده تا آشکارسازی را در حالتی که هم‌ترازی از دست برود، داشته باشیم.

۱-۳- ساختار مقاله

باقیمانده مطالب ارائه شده در این مقاله به قرار زیر است. در بخش ۲ الگوریتم پیشنهادی و معماری شبکه‌های مورد استفاده مطرح می‌گردد. در بخش ۳ به منظور ارزیابی نتایج، ابتدا به معرفی مجموعه داده^{۲۱} و چگونگی تنظیم پارامترهای شبکه می‌پردازیم. سپس آزمایش‌های مختلفی بر روی شبکه انجام می‌شود و با برخی از روش‌های مطرح شده قبلی مقایسه می‌گردد تا مزایای شبکه پیشنهادی مشخص گردد. در نهایت نتیجه‌گیری در بخش ۴ بیان شده است.

۲- روش پیشنهادی

در این قسمت روش پیشنهادی جهت بررسی بلوک‌های ۶۴×۶۴ تصویر و آشکارسازی فشرده‌سازی JPEG مضاعف در هر بلوک مطرح می‌شود. در این روش از یک شبکه CAE به‌عنوان پیش‌پردازش و حذف‌کننده محتوای تصویر و یک شبکه CNN برای کلاس‌بندی استفاده شده است. بلوک دیاگرام کلی روش پیشنهادی در شکل (۱) نشان داده شده است. این شبکه شامل یک حذف‌کننده محتوای تصویر تطبیقی^{۲۲} (AICR) بر پایه CAE است که به‌صورت متوالی با CNN قرار گرفته است.

۲-۱- حذف‌کننده محتوای تصویر تطبیقی

بررسی‌ها نشان می‌دهد که با آموزش شبکه عصبی پیچشی به‌وسیله تصاویر JPEG و DJPEG امکان طبقه‌بندی درست وجود ندارد. به عبارتی محتوای تصویر به‌عنوان سیگنال تداخلی، طبقه‌بندی CNN را دچار مشکل می‌نماید. به همین دلیل روش‌های مختلفی مطرح شده که اقدام به حذف سیگنال فرکانس پایین محتوای تصویر نموده‌اند. در این مطالعه با کمک یک شبکه CAE که به‌صورت بدون نظارت و با تصاویر JPEG و DJPEG آموزش دیده است، اقدام به حذف تطبیقی محتوای تصویر نمودیم. این موضوع از آنجایی به ذهن می‌آید که شبکه CAE قادر است اطلاعات فرکانس پایین تصویر ورودی را در خروجی خود تولید نماید. در آموزش CAE تأثیر تصاویر JPEG و DJPEG یکسان فرض شده است. به عبارتی ۵۰ درصد تصاویر آموزشی وارد شده به CAE تصاویر JPEG و ۵۰ درصد باقیمانده DJPEG است تا جهت‌گیری در تصمیم‌گیری ایجاد نشود. بلوک دیاگرام حذف‌کننده محتوای تصویر تطبیقی در شکل (۲) نشان داده شده است. در مرحله آزمایش، با وارد نمودن هر تصویر I، خروجی خودرمزگذار پیچشی، محتوای تصویر (IC) است که به‌ازای تصاویر JPEG و یا DJPEG به قرار زیر است:


$$IC = \begin{cases} L_J & \text{if } I=JPEG \\ L_{DJ} & \text{if } I=DJPEG \end{cases} \quad (1)$$

که در این رابطه I تصویر ورودی است که می‌تواند JPEG یا DJPEG باشد، L_J خروجی CAE به‌ازای تصویر ورودی JPEG و L_{DJ} خروجی CAE به‌ازای تصویر ورودی DJPEG است. در مرحله بعد جهت حذف محتوای تصویر باید خروجی CAE را از ورودی آن کم نمود.


$$CAER = I - IC = \begin{cases} I - L_J & \text{if } I=JPEG \\ I - L_{DJ} & \text{if } I=DJPEG \end{cases} \quad (2)$$

۲-۲- طبقه‌بندی بر پایه CNN

اطلاعات به‌دست آمده در خروجی شبکه AICR شامل تصاویر JPEG و یا DJPEG است که محتوای آنها حذف شده است. در ادامه این اطلاعات باید با استفاده از یک طبقه‌بند در دو کلاس JPEG یا DJPEG دسته‌بندی گردد.



شکل (۱): بلوک دیاگرام کلی روش پیشنهادی
Figure (1): Block diagram of proposed method



شکل (۲): حذف‌کننده محتوای تصویر تطبیقی (AICR)
Figure (2): Adaptive image content remover

شبکه‌های عصبی پیچشی نشان داده‌اند که در کاربردهای مختلف پردازش تصویر قادر هستند با استخراج ویژگی‌های مناسب طبقه‌بندی بهینه‌ای را داشته باشند. بنابراین مقادیر CAER به‌دست آمده از مرحله قبل وارد یک CNN می‌شود که به‌صورت با نظارت توسط باقیمانده تصاویر JPEG و DPJEG آموزش دیده است. با توجه به اینکه کلاس JPEG با مقدار صفر و کلاس JPEG با مقدار یک متناظر شده است، با مقایسه خروجی CNN با یک آستانه ۰/۵، کلاس موردنظر مشخص خواهد شد.

$$\text{out}_f = \begin{cases} \text{JPEG} & \text{if } \text{out} \geq 0.5 \\ \text{DJPEG} & \text{if } \text{out} < 0.5 \end{cases} \quad (3)$$

۲-۳- معماری شبکه‌های عصبی پیشنهادی

یکی از مواردی که هنگام طراحی و آموزش شبکه‌های عصبی جهت طبقه‌بندی تصاویر مورد توجه قرار می‌گیرد، استفاده از شبکه‌های از پیش آموزش دیده مانند وی‌جی‌جی‌نت^{۲۳}، رزنت^{۲۴} [۲۷] یا تی‌رزنت^{۲۵} [۲۸] است. این شبکه‌ها نسبت به شبکه‌هایی که از ابتدا آموزش دیده‌اند، مزایایی را دارند. این مزایا شامل صحت آشکارسازی^{۲۶} خوب، کمک گرفتن از یادگیری انتقالی جهت آموزش سریع‌تر و کارایی بالاتر در بررسی داده‌ها^{۲۷} است [۲۹]. نکته‌ای که باید مدنظر قرار گیرد این است که این شبکه‌ها بر اساس محتوای تصویر آموزش می‌بینند. حال آنکه در آشکارسازی فشرده‌سازی JPEG مضاعف، محتوای تصویر یک سیگنال تداخلی است که باید حذف گردد. بنابراین استفاده از شبکه‌های از پیش آموزش دیده برای کاربرد ما مناسب نیست. با در نظر گرفتن این مسئله، یک شبکه CAE به‌عنوان حذف‌کننده محتوای تصویر و یک شبکه CNN را به‌عنوان طبقه‌بند آموزش دادیم. جزئیات معماری این دو شبکه در جدول‌های (۱) و (۲) نشان داده شده است. همان‌طور که مشاهده می‌شود در لایه پیچشی از توابع فعال‌سازی کمک گرفته شده تا به مقادیر نگاشت‌های ویژگی اعمال گردد. یکی از این توابع که به‌صورت موفقیت‌آمیزی در کاربردهای بینایی ماشین مورد بهره‌برداری قرار گرفته است، تابع فعال‌سازی ReLU است [۳۰]. با این حال پژوهشگران در مرجع [۳۱]، تابع فعال‌سازی واحد خطی-نمایی^{۲۸} (ELU) را مطرح نمودند که به‌طور قابل توجهی سرعت یادگیری را افزایش می‌دهد و کمتر از ۱۰ درصد خطای طبقه‌بندی را در مقایسه با ReLU با همان معماری ایجاد می‌نماید [۲۵].

از طرف دیگر محققان جهت نرمال‌سازی داده‌ها در معماری شبکه‌های عصبی عمیق از روش‌های مختلفی بهره گرفته‌اند. در این راستا، ابتدا از نرمال‌سازی پاسخ محلی^{۲۹} (LRN) استفاده گردید که ضریب مرکزی درون یک پنجره لغزنده در نگاشت ویژگی را با توجه به همسایه‌های آن نرمالیزه می‌نماید. بعد از آن محققان در دریافتند که با کمک یک لایه نرمال‌سازی دسته‌ای^{۳۰} می‌توان به‌طور چشم‌گیری آموزش شبکه عمیق را تسریع نمود [۳۲]. در این حالت داده ورودی به شبکه آموزش با میانگین صفر و واریانس یک نرمال‌سازی می‌شود تا شیفتم‌نوسان داخلی^{۳۱} حداقل گردد.

۳- ارزیابی نتایج

در این قسمت نتایج الگوریتم پیشنهادی مورد ارزیابی قرار گرفته و با نتایج مطالعات دیگر مقایسه شده است. به این منظور، ابتدا مجموعه داده مناسب جهت ارزیابی انتخاب می‌شود و سپس پارامترهای شبکه‌های عصبی پیشنهادی تحت فرایند آموزش تنظیم می‌گردند. نتایج به‌دست آمده با روش‌های مطالعات [۶] و [۱۲] به‌عنوان بهترین روش‌های مطرح شده بر اساس شبکه‌های عصبی عمیق و مطالعات [۷] و [۱۵] به‌عنوان دو روش مطرح در آشکارسازی فشرده‌سازی JPEG مضاعف مقایسه گردید. در اینجا جهت ساده‌سازی، مطالعات [۱۲]، [۱۵] و [۷] را به ترتیب با WZ، TR و KH نشان می‌دهیم. از سه روش مطرح شده در مرجع [۶]، روش نوین و هیستوگرام نتایج بهتری دارند که آنها را به ترتیب با BB_n و BB_h نشان می‌دهیم.

۳-۱- مجموعه داده

به‌منظور ارزیابی نتایج و آموزش شبکه‌های عصبی از مجموعه داده RAISE استفاده شده که شامل ۸۱۵۶ تصویر خام برای کاربردهای بازجویی تصاویر دیجیتال است [۳۳]. برای ایجاد مجموعه داده‌های لازم، تصاویر خام را با ابعاد $256(m \times n)$ برش دادیم طوری که m و n اعداد طبیعی با مقادیر ۲ تا ۵ باشند. تصاویر حاصل به‌صورت تصادفی در دسته‌های آموزش، اعتبارسنجی و آزمایش قرار گرفتند. سپس تصاویر هر دسته را برای ایجاد مجموعه داده‌های لازم در سناریوهای هم‌تراز و ناهم‌تراز فشرده نمودیم.

Table (1): CAE Architecture Details

جدول (۱): جزئیات معماری CAE

توابع فعال‌سازی	تعداد پارامترها	گام	تعداد فیلترها	ابعاد فیلترها	اندازه خروجی	اندازه ورودی	لایه
ELU	۱۶۰	۱	۱۶	۳×۳	۱۶×۶۴×۶۴	۱۶×۶۴×۶۴	Conv2D-1
-	۶۴	-	-	-	۱۶×۶۴×۶۴	۱۶×۶۴×۶۴	BN-1
-	۰	۲	-	۲×۲	۱۶×۳۲×۳۲	۱۶×۶۴×۶۴	MaxPooling2D-1
ELU	۲۳۲۰	۱	۱۶	۳×۳	۱۶×۳۲×۳۲	۱۶×۳۲×۳۲	Conv2D-2
-	۶۴	-	-	-	۱۶×۳۲×۳۲	۱۶×۳۲×۳۲	BN-2
-	۰	۲	-	۲×۲	۱۶×۶۴×۶۴	۱۶×۳۲×۳۲	UpSampling2D-1
Sigmoid	۱۴۵	۱	۱	۳×۳	۱۶×۶۴×۶۴	۱۶×۶۴×۶۴	Conv2D-3

Table (2): CNN Architecture Details

جدول (۲): جزئیات معماری CNN

توابع فعال‌سازی	تعداد پارامترها	گام	تعداد فیلترها	ابعاد فیلترها	اندازه خروجی	اندازه ورودی	لایه
ELU	۱۲۸۰	۱	۱۲۸	۳×۳	۱۲۸×۶۲×۶۲	۱×۶۴×۶۴	Conv2D-1
-	۵۱۲	-	-	-	۱۲۸×۶۲×۶۲	۱۲۸×۶۲×۶۲	BN-1
ELU	۱۴۷۵۸۴	۱	۱۲۸	۳×۳	۱۲۸×۶۰×۶۰	۱۲۸×۶۲×۶۲	Conv2D-2
-	۵۱۲	-	-	-	۱۲۸×۶۰×۶۰	۱۲۸×۶۰×۶۰	BN-2
-	۰	۲	-	۲×۲	۱۲۸×۳۰×۳۰	۱۲۸×۶۰×۶۰	MaxPooling2D-1
ELU	۸۱۹۴۵۶	۱	۲۵۶	۵×۵	۲۵۶×۲۶×۲۶	۱۲۸×۳۰×۳۰	Conv2D-3
-	۱۰۲۴	-	-	-	۲۵۶×۲۶×۲۶	۲۵۶×۲۶×۲۶	BN-3
ELU	۱۶۳۸۶۵۶	۱	۲۵۶	۵×۵	۲۵۶×۲۲×۲۲	۲۵۶×۲۶×۲۶	Conv2D-4
-	۱۰۲۴	-	-	-	۲۵۶×۲۲×۲۲	۲۵۶×۲۲×۲۲	BN-4
-	۰	۲	-	۲×۲	۲۵۶×۱۱×۱۱	۲۵۶×۲۲×۲۲	MaxPooling2D-2
ELU	۳۲۷۷۳۱۲	۱	۵۱۲	۵×۵	۵۱۲×۷×۷	۲۵۶×۱۱×۱۱	Conv2D-5
-	۲۰۴۸	-	-	-	۵۱۲×۷×۷	۵۱۲×۷×۷	BN-5
-	۰	۲	-	۲×۲	۵۱۲×۴×۴	۵۱۲×۷×۷	MaxPooling2D-3
-	۰	-	-	-	۸۱۹۲	۵۱۲×۴×۴	FC-1 (Flatten)
-	۳۲۷۶۸	-	-	-	۸۱۹۲	۸۱۹۲	BN-6
ELU	۱۶۳۸۶۰۰۰	-	-	-	۲۰۰۰	۸۱۹۲	FC-2 (Dense)
-	۸۰۰۰	-	-	-	۲۰۰۰	۲۰۰۰	BN-7
ELU	۱۰۰۰۵۰۰	-	-	-	۵۰۰	۲۰۰۰	FC-3 (Dense)
Sigmoid	۵۰۱	-	-	-	۱	۵۰۰	FC-4 (Dense)

در سناریوی هم‌تراز تصاویر با قابلیت تفکیک بالا^{۳۲} با ابعاد ۶۴×۶۴ برش داده می‌شوند و به‌صورت تصادفی در دو دسته JPEG و DJPEG قرار می‌گیرند. تصاویر موجود در دسته DJPEG، ابتدا با ضریب کیفیت QF1 در مجموعه {۵۰، ۶۰، ۷۰، ۸۰، ۹۰} و آنگاه در مجموعه {۷۵، ۸۵} یا با ضریب کیفیت QF1 در مجموعه {۶۰، ۷۰، ۸۰، ۹۰، ۹۸} و آنگاه QF2 برابر ۹۵ فشرده می‌شوند. حال آنکه تصاویر موجود در دسته JPEG متناظر تنها با ضریب کیفیت QF2 فشرده می‌شوند. مجموعه داده تولید شده را مطابق جدول (۳) با D_A^{QF2} نامگذاری نمودیم. در سناریوی ناهم‌تراز تصاویر با قابلیت تفکیک بالا با ابعاد $(۸+۶۴) \times (۸+۶۴)$ برش داده می‌شوند و به‌صورت تصادفی در دو دسته JPEG و DJPEG قرار می‌گیرند. تصاویر موجود در دسته DJPEG پس از فشرده شدن با ضریب کیفیت QF1 به اندازه مقدار تصادفی (p,q) بین صفر تا ۷ شیفت داده شده و با ابعاد ۶۴×۶۴ بریده می‌شوند. سپس این

تصاویر با ضریب کیفیت QF2 فشرده می‌شوند. حال آنکه در دسته JPEG تصاویر با ابعاد ۶۴×۶۴ برش داده شده و با ضریب کیفیت QF2 فشرده می‌شوند. در این سناریو مقادیر QF1 و QF2 متناظر مشابه حالت هم‌تراز در نظر گرفته شده‌اند. مجموعه داده‌های ایجاد شده در این حالت در جدول (۳) با D_{NA}^{QF2} نشان داده شده است.

۳-۲- تنظیم پارامترها در فرایند آموزش

با بررسی معماری شبکه‌های پیشنهادی در جدول‌های (۱) و (۲) مشاهده می‌شود که ورودی شبکه‌ها یک تصویر ۶۴×۶۴ است. این تصویر در واقع قسمت روشنایی یک تصویر رنگی در فضای YCbCr است. از آنجایی که وزن‌دهی مناسب شبکه سبب همگرایی سریع‌تر می‌شود، از روش داده شده در مطالعه [۳۴] استفاده می‌گردد. به‌منظور بهینه‌سازی در فرایند آموزش از بهینه‌ساز آدام^{۳۳} استفاده می‌شود [۳۵]. نرخ یادگیری اولیه^{۳۴} برابر ۰/۰۰۰۱ در نظر گرفته شده است. از طرفی تعداد پارامترهای قابل تنظیم در شبکه CAE کم و در شبکه CNN زیاد است. به همین دلیل تعداد دوره^{۳۵} لازم جهت کامل شدن آموزش در شبکه CAE برابر با ۳ و در شبکه CNN برابر ۱۰ در نظر گرفته شده است. ضمناً با توجه به اهمیت طبقه‌بندی صحیح تصاویر در فرایند آشکارسازی، معیار ارزیابی را صحت آشکارسازی در نظر گرفته‌ایم. از جمله نکاتی که هنگام تنظیم دقیق پارامترها بایستی مدنظر قرار گیرد، تأثیر تعداد تصاویر آموزشی و مدت زمان لازم جهت آموزش است. شکل (۳) تأثیر تعداد تصاویر جهت آموزش شبکه CNN در هر دوره به ازای QF2 برابر ۹۵ را نمایش می‌دهد. مشاهده می‌شود که با وارد نمودن حدود ۴۰ درصد تصاویر آموزشی به شبکه، پارامترها تا حدود مؤثری تنظیم می‌شوند و بعد از آن تقریباً شبکه اشباع می‌گردد. این در حالی است که با افزایش تعداد تصاویر، زمان لازم جهت آموزش به‌صورت خطی افزایش می‌یابد. به همین دلیل در این مقاله ۴۰ درصد تصاویر مجموعه داده‌ها را جهت آموزش در نظر گرفته‌ایم.

۳-۳- ارزیابی مدل پیشنهادی

در این قسمت قابلیت الگوریتم پیشنهادی در آشکارسازی فشرده‌سازی JPEG مضاعف برای سناریوهای هم‌تراز و ناهم‌تراز بررسی شده است. سپس ارزیابی را به حالتی که هم‌ترازی از دست برود، گسترش می‌دهیم. درنهایت پس از بررسی حساسیت شبکه نسبت به ضرایب کیفیت^{۳۶} (QFs)، مکان دست‌کاری در تصویر را مشخص می‌نماییم. با وجود چالش برانگیز بودن آشکارسازی دست‌کاری در بلوک‌های تصویری با اندازه کوچک، آشکارسازی و مقایسه‌های انجام شده را در این شرایط و با اندازه ۶۴×۶۴ مطرح می‌نماییم تا قادر به تعیین مکان دست‌کاری شده در تصویر باشیم.


۳-۳-۱- قابلیت آشکارسازی در حالت‌های هم‌تراز و ناهم‌تراز

در این بخش، ضمن بررسی نتایج الگوریتم پیشنهادی در آشکارسازی فشرده‌سازی JPEG مضاعف، مقایسه با روش‌های KH، WZ، TR، BB_n و BB_h انجام می‌شود. با توجه به نحوه استخراج ویژگی‌ها در روش WZ، امکان آشکارسازی در حالت ناهم‌تراز وجود ندارد.

Table (3): Datasets created for aligned and non-aligned scenarios

جدول (۳): مجموعه داده‌های ایجاد شده برای سناریوهای هم‌تراز و ناهم‌تراز

تعداد تصاویر آزمایش	تعداد تصاویر اعتبارسنجی	تعداد تصاویر آموزش	QF2	QF1	مجموعه داده
۱۰۰K	۲۰۰K	۸۰۰K	۷۵	۵۰،۶۰،۷۰،۸۰،۹۰	D_A^{75}
۱۰۰K	۲۰۰K	۸۰۰K	۸۵	۵۰،۶۰،۷۰،۸۰،۹۰	D_A^{85}
۱۰۰K	۲۰۰K	۸۰۰K	۹۵	۶۰،۷۰،۸۰،۹۰،۹۸	D_A^{95}
۱۰۰K	۲۰۰K	۸۰۰K	۷۵	۵۰،۶۰،۷۰،۸۰،۹۰	D_{NA}^{75}
۱۰۰K	۲۰۰K	۸۰۰K	۸۵	۵۰،۶۰،۷۰،۸۰،۹۰	D_{NA}^{85}
۱۰۰K	۲۰۰K	۸۰۰K	۹۵	۶۰،۷۰،۸۰،۹۰،۹۸	D_{NA}^{95}

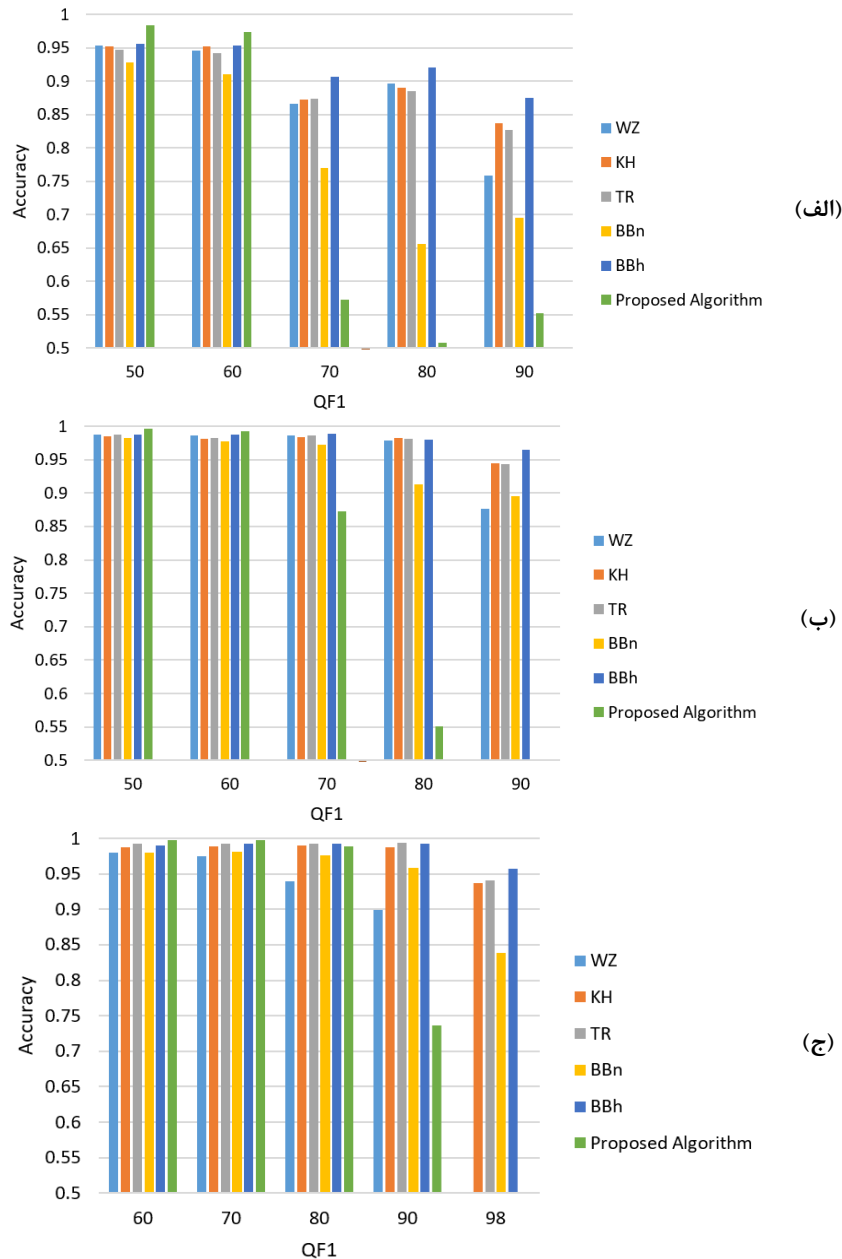


شکل (۳): تأثیر تعداد تصاویر آموزش بر صحت آشکارسازی به ازای $QF_2=95$
 Figure (3): Impact of training images number on detection accuracy for $QF_2=95$

به همین دلیل در مقایسه‌های انجام گرفته در حالت ناهم‌تراز روش WZ لحاظ نشده است. شکل (۴) نتایج حاصل از آشکارسازی در حالت هم‌تراز را به‌وسیله الگوریتم پیشنهادی برای شبکه‌های آموزش‌دیده با مجموعه داده‌های جدول (۳) نمایش می‌دهد. با در نظر گرفتن تفاضل ضرایب کیفیت با مقدار QF_d رابطه (۴) را خواهیم داشت:

$$QF_d = QF_2 - QF_1 \quad (4)$$

همان‌طور که از شکل (۴) مشاهده می‌شود به ازای مقادیر مثبت QF_d نتایج همه الگوریتم‌ها خوب بوده، اما روش پیشنهادی بهتر از سایرین عمل می‌نماید. این در حالی است که با کاهش مقدار QF_d عملکرد آشکارسازها نیز تضعیف می‌گردد. علت این است که با کاهش QF_d عوارض باقیمانده از فشرده‌سازی JPEG اول پس از فشرده‌سازی مجدد کمتر باقی می‌مانند. نکته‌ای که باید مورد توجه قرار گیرد نحوه عملکرد الگوریتم پیشنهادی نسبت به تغییرات QF_d است. به عبارتی، الگوریتم پیشنهادی بهترین نتایج را در مقایسه با سایر الگوریتم‌ها در حالتی که مقدار QF_d مثبت و فاصله QF_1 و QF_2 زیاد باشد، دارد. اما مشکل اینجاست که با نزدیک شدن مقدار QF_1 به QF_2 و عبور از آن، صحت آشکارسازی به شدت کاهش می‌یابد. می‌توان دلیل این مسئله را در ساختار حذف‌کننده محتوای تصویر جستجو نمود. از آنجایی که در این الگوریتم، CAE با تصاویر JPEG و DJPEG آموزش می‌بیند، محتوای تصویر ایجاد شده در خروجی آن و به ازای مقادیر منفی QF_d ، شامل اطلاعاتی از هر دو نوع تصاویر است. بنابراین فضای ویژگی اطلاعاتی که وارد CNN می‌شود (مخصوصاً در حالتی که QF_1 به QF_2 نزدیک شده و از آن بیشتر شود) به هم نزدیک است و آشکارسازی با شکست مواجه می‌شود. در سناریوی NA-DJPEGE، شبکه بر اساس مجموعه داده‌های D_{NA}^{95} و D_{NA}^{85} ، D_{NA}^{75} معرفی شده در جدول (۳) آموزش می‌بیند. نتایج حاصل از آشکارسازی در شکل (۵) قابل مشاهده است. در این سناریو نیز با کاهش مقدار QF_d از مقادیر مثبت به سمت مقادیر منفی، صحت آشکارسازی کاهش می‌یابد. در این حالت روش پیشنهادی به‌طور متوسط بهتر از سایر روش‌ها به‌جز BB_n عمل کرده است. با این حال در مقادیر زیاد QF_d از همه روش‌ها بهتر بوده است. نتایج در حالت هم‌تراز و ناهم‌تراز و در مقایسه با سایر روش‌ها نشان‌دهنده عملکرد خوب روش پیشنهادی در مقادیر مثبت QF_d و عملکرد عالی در $QF_d \gg 0$ است. از طرفی با مقایسه صحت آشکارسازی حاصل از الگوریتم‌ها مشاهده می‌شود که روش‌های حوزه مکان در حالت ناهم‌تراز عملکرد بهتری نسبت به روش‌های بر پایه حوزه DCT دارند. این مسئله از آنجایی ناشی می‌شود که عوارض باقیمانده در حوزه DCT ناشی از فشرده‌سازی JPEG مضاعف در حالت هم‌تراز بیشتر از حوزه مکان است. به همین دلیل بهترین عملکرد در سناریوی هم‌تراز مربوط به روش BB_n بوده است. موارد مطرح شده در بالا مربوط به شرایطی است که مقادیر QF_1 و QF_2 به‌صورت دقیق در دسترس باشد. مقدار QF_2 احتمالاً در سرفایل JPEG موجود است، حال آنکه مقدار QF_1 باید به‌واسطه روش‌های پرچالشی تخمین زده شود [۳۶]. اگر تصویر دست‌کاری شده به‌صورت خام در حوزه مکان ذخیره‌سازی شده باشد، مقدار QF_2 نیز در دسترس نیست و بایستی تخمین زده شود. به همین دلیل حساسیت روش پیشنهادی را نسبت به ضرایب کیفیت بررسی کرده و نتایج را با روش BB_n به‌عنوان یکی از بهترین روش‌ها مقایسه می‌نماییم. به‌منظور ارزیابی بهبود صحت آشکارسازی روش پیشنهادی نسبت به روش‌های مشابه از یکی از معیارهای معروف تحت عنوان کاهش خطای نسبی^{۳۷} استفاده می‌کنیم.




شکل (۴): مقایسه نتایج آشکارسازی روش پیشنهادی در حالت هم‌تراز با روش‌های WZ [12]، KH [7]، TR [15]، BB_n (روش نویز در مرجع [6]) و BB_h (روش هیستوگرام در مرجع [6]) برای سه مقدار QF2=75 (الف)، 85 (ب) و 95 (ج)

Figure (4): Detection results comparison of proposed method with WZ [12], KH [7], TR [15], BB_n (noise method in [6]) and BB_h (histogram method in [6]) in aligned case for (a) QF2=75 (b) QF2=85 (c) QF2=95.

$$RER(\text{in percent}) = \left(1 - \frac{1 - Acc_{pro}}{1 - Acc_{old}}\right) \times 100 \quad (5)$$

در این رابطه Acc_{pro} صحت آشکارسازی روش پیشنهادی و Acc_{old} صحت آشکارسازی روش قبلی (در اینجا BB_n) است. با ضرب مقدار RER به دست آمده در عدد ۱۰۰، میزان بهبود بر حسب درصد محاسبه می‌شود. نتایج حاصل از محاسبه صحت آشکارسازی و مقادیر RER برای حالت‌های هم‌تراز و ناهم‌تراز جهت بررسی حساسیت نسبت به ضرایب کیفیت فشرده‌سازی به ترتیب در جدول‌های (۴) و (۵) نشان داده شده است. مقادیر پرننگ^{۳۸} شده در جدول نشان‌دهنده الگوریتم با عملکرد بهتر است. از آنجایی که به ازای QF2 برابر ۹۵ نتایج الگوریتم پیشنهادی به مراتب بهتر از QF2 برابر ۷۵ و ۸۵ است، در این قسمت نتایج داده شده در شرایط سخت‌تر را لحاظ نموده‌ایم. با توجه به جدول مشاهده می‌شود که به‌طور متوسط روش پیشنهادی در QF2 برابر ۷۵ تقریباً مشابه روش BB_n عمل می‌نماید، حال آنکه در QF2 برابر ۸۵ به مراتب بهتر از روش BB_n بوده است.



شکل (۵): مقایسه نتایج آشکارسازی روش پیشنهادی در حالت ناهم‌تراز با روش‌های [WZ[12], KH[7], TR[15], BB_n (روش نویز در مرجع [۶]) و BB_n (روش هیستوگرام در مرجع [۶]) برای سه مقدار QF2 (الف) ۷۵، (ب) ۸۵ و (ج) ۹۵

Figure (5): Detection results comparison of proposed method with WZ[12], KH[7], TR[15], BB_n (noise method in [6]) and BB_n (histogram method in [6]) in non-aligned case for (a) QF2=75 (b) QF2=85 (c) QF2=95

به عبارتی، با افزایش مقدار QF_d به سمت مقادیر مثبت بالاتر، بهبود بسیار زیادی را می‌توان هم در حالت هم‌تراز و هم در حالت ناهم‌تراز مشاهده نمود. تا جایی که الگوریتم پیشنهادی در QF1 و QF2 به ترتیب برابر با ۵۵ و ۸۵ حدود ۹۶ درصد و ۵۴ درصد بهبود را به ترتیب در شرایط هم‌تراز و ناهم‌تراز ایجاد نموده است. این مسئله می‌تواند قدرت الگوریتم پیشنهادی را در شرایط عدم تخمین دقیق مقادیر ضرایب کیفیت فشرده‌سازی نشان دهد.

۳-۳-۲- قابلیت آشکارسازی در شرایط از دست دادن هم‌ترازی

بسیاری از مقالات آشکارسازی فشرده‌سازی JPEG مضاعف را تنها در حالت هم‌تراز یا ناهم‌تراز بررسی می‌نمایند. در این صورت با از دست دادن هم‌ترازی این الگوریتم‌ها قادر به آشکارسازی نیستند.

Table (4): Comparison of detection accuracy sensitivity to quality factors for the proposed method and BB_n in aligned case, and their corresponding RER values

جدول (۴): مقایسه حساسیت صحت آشکارسازی به ضرایب کیفیت برای روش پیشنهادی و BB_n (روش نویز در [۶]) در حالت هم‌تراز و مقادیر RER متناظر آنها

آموزش با QF2 برابر ۷۵			آموزش با QF2 برابر ۸۵			RER%	RER%
آزمایش (QF1, QF2)	صحت آشکارسازی		آزمایش (QF1, QF2)	صحت آشکارسازی			
	BB_n	پیشنهادی		BB_n	پیشنهادی		
(۵۵, ۷۵)	۰/۹۲۵	۰/۹۸۱	(۵۵, ۸۵)	۰/۹۶۳	۰/۹۹۵	۷۴/۶۷	۸۶/۴۹
(۶۵, ۷۵)	۰/۸۸	۰/۷۶۷۶	(۶۵, ۸۵)	۰/۹۶	۰/۹۶۸۸	-۹۳/۶۷	۲۲
(۶۰, ۷۸)	۰/۹	۰/۹۶۲۱	(۷۰, ۸۸)	۰/۸۶	۰/۹۰۳	۶۲/۱	۳۰/۷۲
(۷۰, ۷۸)	۰/۸۱	۰/۶۴۴۱	(۸۰, ۸۸)	۰/۶۴	۰/۵۲۵۶	-۸۷/۳۱	-۳۱/۷۸
(۶۰, ۸۰)	۰/۸۶	۰/۹۴۶۵	(۷۰, ۹۰)	۰/۷۱۸	۰/۸۷۱۶	۶۱/۷۹	۵۴/۴۷
(۷۰, ۸۰)	۰/۷۶	۰/۶۶۴۲	(۸۰, ۹۰)	۰/۵	۰/۵۱۷۶	-۵۹/۹	۳/۵۲

Table (5): Comparison of detection accuracy sensitivity to quality factors for the proposed method and BB_n in non-aligned case, and their corresponding RER values

جدول (۵): مقایسه حساسیت صحت آشکارسازی به ضرایب کیفیت برای روش پیشنهادی و BB_n (روش نویز در [۶]) در حالت ناهم‌تراز و مقادیر RER متناظر آنها

آموزش با QF2 برابر ۷۵			آموزش با QF2 برابر ۸۵			RER%	RER%
آزمایش (QF1, QF2)	صحت آشکارسازی		آزمایش (QF1, QF2)	صحت آشکارسازی			
	BB_n	پیشنهادی		BB_n	پیشنهادی		
(۵۵, ۷۵)	۰/۸۱۶	۰/۸۲۰۷	(۵۵, ۸۵)	۰/۸۹۷	۰/۹۵۲۵	۲/۵۶	۵۳/۸۹
(۶۵, ۷۵)	۰/۸۰۵	۰/۷۸۱۶	(۶۵, ۸۵)	۰/۸۷۸	۰/۹۲۰۵	-۱۲	۳۴/۸۴
(۶۰, ۷۸)	۰/۷۷۷	۰/۷۸۳۳	(۷۰, ۸۸)	۰/۷۵۱	۰/۸۸۵۱	۲/۸۳	۵۳/۸۶
(۷۰, ۷۸)	۰/۷۶۵	۰/۷۵۵۶	(۸۰, ۸۸)	۰/۷۳۸	۰/۸۵۳۸	-۴	۴۴/۲
(۶۰, ۸۰)	۰/۷۲۳	۰/۷۴۵۴	(۷۰, ۹۰)	۰/۶۵	۰/۷۶۶۲	۸/۱	۳۳/۲
(۷۰, ۸۰)	۰/۷۲	۰/۷۲۲۷	(۸۰, ۹۰)	۰/۶۳۴	۰/۷۵۸۶	۴/۵۴	۳۴/۰۵

از آنجایی که معماری شبکه‌های استفاده شده در این مقاله در حالت‌های هم‌تراز و ناهم‌تراز یکسان است، می‌توان با ترکیب مجموعه داده‌های در جدول (۳) و تشکیل مجموعه داده جدید (D_{MA}^{QF2}) شبکه را مجدداً آموزش داد. در این صورت با از دست رفتن هم‌ترازی، امکان آشکارسازی در هر دو حالت هم‌تراز یا ناهم‌تراز وجود دارد.

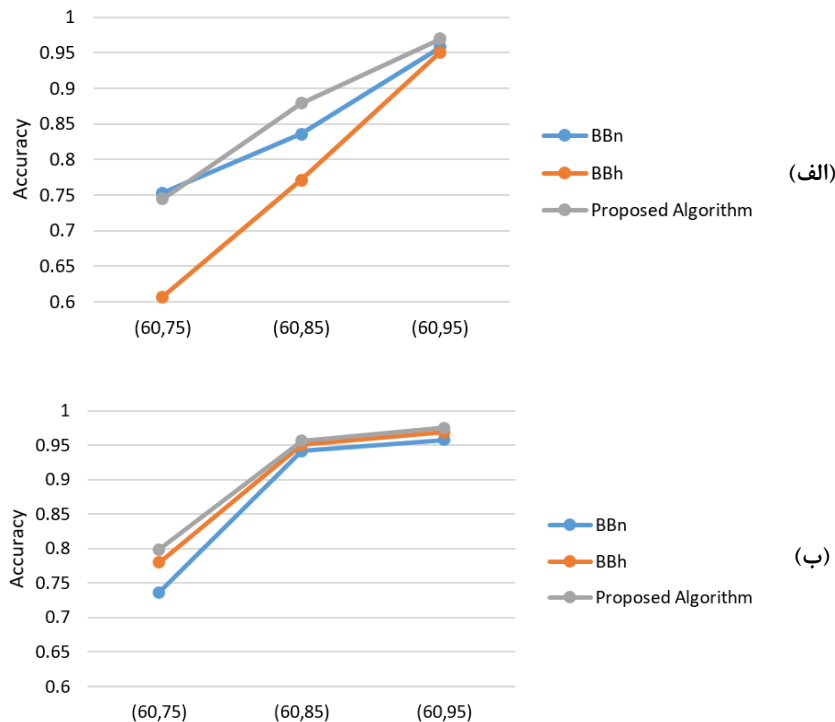
$$D_{MA}^{QF2} = D_A^{QF2} \cup D_{NA}^{QF2} \quad \text{for } QF2 \in \{75, 85, 95\} \quad (۶)$$

در این شرایط تعداد تصاویر مجموعه داده D_{MA}^{QF2} دو برابر D_A^{QF2} یا D_{NA}^{QF2} می‌شود. به‌منظور همسان‌سازی فرایند آموزش با حالت‌های قبل، ۲۰ درصد تصاویر موجود در مجموعه داده D_{MA}^{QF2} را جهت آموزش و اعتبارسنجی شبکه استفاده نمودیم. نتایج حاصل از آشکارسازی روش پیشنهادی به ازای QF1 برابر ۶۰ و QF2 برابر ۷۵، ۸۵ و ۹۵ در شکل (۶) نشان داده شده است. شکل (۶) عملکرد خوب روش پیشنهادی را مخصوصاً در مقادیر زیاد QF_d نشان می‌دهد. به‌منظور بررسی بهتر، الگوریتم پیشنهادی با روش‌های BB_n و BB_h مقایسه شده است. این نتایج ما را به استفاده از این الگوریتم دلگرم می‌نماید.

۳-۳-۳- مکان‌یابی محل دست‌کاری در تصویر

جهت جامعیت بخشیدن به آزمایش‌های انجام شده، محل دست‌کاری در تصویر را به‌صورت کمی و کیفی مورد ارزیابی قرار می‌دهیم. برای ارزیابی کمی از متریک استاندارد رابطه (۷) استفاده می‌شود:

$$F1\text{-score} = \frac{2TP}{2TP+FP+FN} \quad (۷)$$




شکل (۶): مقایسه صحت آشکارسازی روش پیشنهادی با BB_n (روش نویز در [۶]) و BB_h (روش هیستوگرام در [۶]) در شرایط از دست رفتن هم‌ترازی به ازای $QF1=60$ و $QF2 \in \{75,85,95\}$ در (الف) حالت ناهم‌تراز (ب) حالت هم‌تراز

Figure (6): Comparison of detection accuracy of the proposed method with BB_n (noise method in [6]) and BB_h (histogram method in [6]) in misaligned conditions for $QF1=60$ and $QF2 \in \{75,85,95\}$ in (a) non-aligned case (b) aligned case

که TP ، FP و FN به ترتیب تعداد پیکسل‌های واقعاً مثبت^{۳۹}، مثبت کاذب^{۴۰} و منفی کاذب^{۴۱} آشکار شده در تصویر است. در این صورت ۵۰۰ تصویر با قابلیت تفکیک بالا از مجموعه آزمایش به صورت تصادفی انتخاب می‌شوند. نصف این تصاویر با ضریب کیفیت $QF2$ یک‌بار فشرده و نصف دیگر تصویر ابتدا با $QF1$ و سپس با $QF2$ دو بار فشرده می‌نماییم.

جهت آشکارسازی دست‌کاری، تصویر ورودی با بلوک‌های 64×64 و گام ۸ بلوک‌بندی می‌شود. هر بلوک وارد الگوریتم آشکارسازی می‌شود تا مشخص گردد که آیا دست‌کاری شده یا خیر. اکنون با توجه به روش بلوک‌بندی و با قرار دادن مجدد بلوک‌ها در کنار هم می‌توان نقشه احتمال^{۴۲} دست‌کاری در هر پیکسل را به دست آورد. پس از حذف حاشیه نقشه احتمال به اندازه گام ۸ و با مقایسه مقادیر نقشه احتمال با آستانه $0/5$ وضعیت دست‌کاری در هر پیکسل مشخص می‌شود. نقشه آشکار شده دست‌کاری در هر پیکسل با معیار مبنای^{۴۳} مقایسه می‌گردد. مقادیر $F1$ -score به ازای $QF1$ برابر ۶۰ و $QF2$ برابر ۷۵، ۸۵ و ۹۵ در شکل (۷) نشان داده شده است. این نتایج با روش‌های BB_n و BB_h مقایسه شده است. در اینجا نیز می‌توان قدرت روش پیشنهادی را در $QF2$ - $QF1$ زیاد مشاهده نمود.

جهت ارزیابی کیفی، قسمتی از یک تصویر با قابلیت تفکیک بالا با ضرایب کیفیت $QF1$ و $QF2$ به ترتیب برابر ۶۰ و ۹۵ دو بار فشرده شده و سایر قسمت‌های تصویر با $QF2$ برابر ۹۵ یک بار فشرده شده است. این تصویر مشابه آنچه که در ارزیابی کمی مطرح شد، بلوک‌بندی شده و وارد آشکارساز می‌شود تا نقشه احتمال دست‌کاری ایجاد شود. شکل (۸) مکان‌یابی محل دست‌کاری را در حالت‌های هم‌تراز و ناهم‌تراز نشان می‌دهد. نقشه احتمال دست‌کاری بر روی شکل با طیف رنگ قرمز نشان داده شده است. به‌منظور مشخص نمودن ناحیه دست‌کاری شده (فشرده شده مضاعف) از مستطیل زرد رنگ استفاده شده که نواحی داخلی این مستطیل به صورت مضاعف فشرده شده‌اند. مشاهده می‌شود که به ازای این ضرایب کیفیت، نتایج آشکارسازی نواحی دست‌کاری شده بسیار مطلوب بوده است.

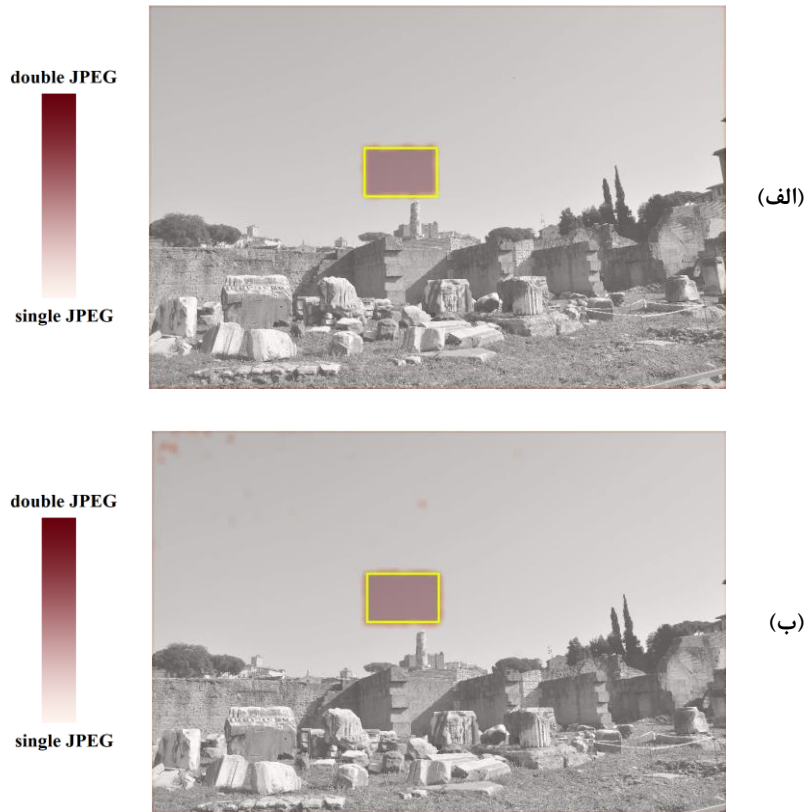


شکل (۷): مقایسه مقادیر F1-score روش پیشنهادی با BB_n (روش نویز در [۶]) و BB_n (روش هیستوگرام در [۶]) در (الف) حالت ناهم‌تراز (ب) حالت هم‌تراز

Figure (7): F1-score comparison of the proposed method with BB_n (noise method in [6]) and BB_n (histogram method in [6]) in (a) non-aligned case (b) aligned case

۴- نتیجه‌گیری

در این مطالعه یک روش تطبیقی جهت حذف محتوای تصویر و آشکارسازی فشرده‌سازی JPEG مضاعف را در حالت‌های هم‌تراز و ناهم‌تراز و از ترکیب شبکه CAE متوالی شده با CNN پیشنهاد شده است. برای رسیدن به این هدف شبکه CAE به صورت منطبق بر کاربرد موردنظر آموزش داده شده است. در اینجا با کمک CAE اطلاعات تداخلی ناشی از محتوای تصویر که در تصمیم‌گیری طبقه‌بند اختلال ایجاد می‌نماید، را حذف نمودیم. در نهایت طبقه‌بند مبتنی بر CNN توانست به آشکارسازی فشرده‌سازی JPEG مضاعف از بلوک‌های کوچکی از تصویر بپردازد و در نتیجه دقت مکان‌یابی محل دست‌کاری در تصویر افزایش داده شده است. نتایج آزمایش‌ها نشان می‌دهد که با وجود عملکرد بسیار خوب روش پیشنهادی در مقادیر QF2-QF1 بیشتر از صفر، این روش در مقادیر QE2-QF1 کمتر از صفر آشکارسازی چندان موفق‌تری ندارد. با این حال روش پیشنهادی حساسیت زیادی به تخمین دقیق ضرایب کیفیت نداشته و توانسته نتایج خوبی را هم در شرایط از دست‌دادن هم‌ترازی به نمایش بگذارد، این در حالی است که در چنین شرایطی در بسیاری از مقالات مشکلات اساسی بروز می‌نماید.



شکل (۸): مکان‌یابی محل دست‌کاری برای تصاویر دست‌کاری شده به صورت (الف) هم‌تراز (ب) ناهم‌تراز
Figure (8): Manipulation localization for (a) aligned (b) non-aligned manipulated images

References

مراجع

- [1] A. Faulkner, C. Chavez, "Adobe photoshop CC classroom in a book (2018 release)", 1th Edition, Adobe Press, 2017.
- [2] W. Zhang, "Smartphone photography in urban china", International Journal of Social, Behavioral, Educational, Economic, Business and Industrial Engineering, vol. 11, no. 1, pp. 231–239, 2017 (doi: 10.5281/zenodo.1128985).
- [3] V. Verma, D. Singh, N. Khanna, "Block-level double JPEG compression detection for image forgery localization", arXiv preprint arXiv:2003.09393, 2020.
- [4] W. Ahn, S.H. Nam, M. Son, H.K. Lee, S. Choi, "End-to-end double JPEG detection with a 3D convolutional network in the DCT domain", Electronics Letters, vol. 56, no. 2, pp. 82-85, 2020 (doi: 10.1049/el.2019.2719).
- [5] C. Deng, Z. Li, X. Gao, D. Tao, "Deep multi-scale discriminative networks for double jpeg compression forensics", ACM Transactions on Intelligent Systems and Technology, vol. 10, no. 2, pp. 1-20, 2019 (doi: 10.1145/3301274).
- [6] M. Barni, L. Bondi, N. Bonettini, P. Bestagini, A. Costanzo, M. Maggini, B. Tondi, S. Tubaro, "Aligned and non-aligned double JPEG detection using convolutional neural networks", Journal of Visual Communication and Image Representation, vol. 49, pp.153-163, 2017 (doi: 10.1016/j.jvcir.2017.09.003).
- [7] P. Korus, J. Huang, "Multi-scale fusion for improved localization of malicious tampering in digital images", IEEE Trans. on Image Processing, vol. 25, no. 3, pp. 1312-1326, 2016 (doi: 10.1109/TIP.2016.2518870).
- [8] C. Pasquini, P. Schöttle, R. Böhme, G. Boato, F. Pérez-González, "Forensics of high quality and nearly identical jpeg image recompression", Proceedings of the IH&MMSec, pp. 11-21, Spain, June 2016 (doi: 10.1145/2909827.2930787).
- [9] B. Li, H. Zhang, H. Luo, S. Tan, "Detecting double JPEG compression and its related anti-forensic operations with CNN", Multimedia Tools and Applications, vol. 78, no. 7, pp. 8577-8601, 2019 (doi: 10.1007/s11042-018-7073-3).
- [10] L. Bondi, D. Güera, L. Baroffio, P. Bestagini, E.J. Delp, S. Tubaro, "A preliminary study on convolutional neural networks for camera model identification", Electronic Imaging, no. 7, pp.67-76, 2017 (doi: 10.2352/I-SSN.2470-1173.2017.7.MWSF-327).

- [11] B. Bayar, M.C. Stamm, "A deep learning approach to universal image manipulation detection using a new convolutional layer", Proceedings of the IH&MMSec, pp. 5-10, Spain, June 2016 (doi: 10.1145/2909827.29-30786).
- [12] Q. Wang, R. Zhang, "Double JPEG compression forensics based on a convolutional neural network", EURASIP Journal on Information Security, Article number: 23, pp. 1-12, Oct. 2016 (doi: 10.1186/s13635-016-0047-y).
- [13] I. Amerini, L. Ballan, R. Caldelli, A.D. Bimbo, G. Serra, "A sift-based forensic method for copy-move attack detection and transformation recovery", IEEE Trans. on Information Forensics and Security, vol. 6, no. 3, pp. 1099-1110, Sept. 2011 (doi: 10.1109/TIFS.2011.2129512).
- [14] D.G. Lowe, "Distinctive image features from scale-invariant keypoints", International Journal of Computer Vision, vol. 60, no. 2, pp. 91-110, 2004 (doi: 10.1023/B:VISI.0000029664.99615.94).
- [15] A. Taimori, F. Razzazi, A. Behrad, A. Ahmadi, M. Babaie-Zadeh, "Quantization-unaware double JPEG compression detection", Journal of Mathematical Imaging and Vision, vol. 54, no. 3, pp. 269-286, 2016 (doi: 10.1007/s10851-015-0602-z).
- [16] T. Bianchi, A. Piva, "Image forgery localization via block-grained analysis of JPEG artifacts", IEEE Trans. on Information Forensics and Security, vol. 7, no. 3, pp. 1003-1017, 2012 (doi: 10.1109/TIFS.2012.2187516).
- [17] T. Mahmood, M. Shah, J. Rashid, T. Saba, M. W. Nisar, M. Asif, "A passive technique for detecting copy-move forgeries by image feature matching", Multimedia Tools and Applications, vol. 79, no. 43, pp. 31759-31782, Aug. 2020 (doi: 10.1007/s11042-020-09655-2).
- [18] J. Wang, W. Huang, X. Luo, Y.Q. Shi, S.K. Jha, "Non-aligned double JPEG compression detection based on refined Markov features in QDCT domain", Journal of Real-Time Image Processing, vol. 17, no. 1, pp. 7-16, 2020 (doi: 10.1007/s11554-019-00929-z).
- [19] M.K. Mihcak, I. Kozintsev, K. Ramchandran, "Spatially adaptive statistical modeling of wavelet image coefficients and its application to denoising", Proceeding of the IEEE/ICASS, vol. 6, pp. 3253-3256, Phoenix, AZ, USA, March 1999 (doi: 10.1109/ICASSP.1999.757535).
- [20] V. Verma, N. Agarwal, N. Khanna, "DCT-domain deep convolutional neural networks for multiple JPEG compression classification", Signal Processing: Image Communication, vol. 67, pp. 22-33, Sept. 2018 (doi: 10.1016/j.image.2018.04.014).
- [21] B. Li, H. Zhang, H. Luo, S. Tan, "Detecting double JPEG compression and its related anti-forensic operations with CNN", Multimedia Tools and Applications, vol 78, no. 7, pp. 8577-8601, Sept. 2019 (doi: 10.1007/s11-042-018-7073-3).
- [22] Y. Rao, J. Ni, "A deep learning approach to detection of splicing and copy-move forgeries in images", Proceeding of the IEEE/WIFS, pp. 1-6, Abu Dhabi, United Arab Emirates, Dec. 2016 (doi: 10.1109/WIFS.2016.7823911).
- [23] J. Fridrich, J. Kodovsky, "Rich models for steganalysis of digital images", IEEE Trans. on Information Forensics and Security, vol. 7, no. 3, pp. 868-882, June 2012 (doi: 10.1109/TIFS.2012.2190402).
- [24] J. Chen, X. Kang, Y. Liu, Z.J. Wang, "Median filtering forensics based on convolutional neural networks", IEEE Signal Processing Letters, vol. 22, No. 11, pp.1849-1853, 2015 (doi: 10.1109/LSP.2015.2438008).
- [25] B. Bayar, M.C. Stamm, "Constrained convolutional neural networks: a new approach towards general purpose image manipulation detection", IEEE Trans. on Information Forensics and Security, vol. 13, no. 11, pp.2691-2706, 2018 (doi: 10.1109/TIFS.2018.2825953).
- [26] L. Gondara, "Medical image denoising using convolutional denoising autoencoders", Proceeding of the IEEE/ICDMW, pp. 241-246, Barcelona, Spain, Dec. 2016 (doi: 10.1109/ICDMW.2016.0041).
- [27] K. He, X. Zhang, S. Ren, J. Sun, "Deep residual learning for image recognition", Proceedings of the IEEE/CVPR, pp. 770-778, Las Vegas, USA, June 2016 (doi: 10.1109/CVPR.2016.90).
- [28] T. Ridnik, H. Lawen, A. Noy, I. Friedman, "TResNet: High performance GPU-dedicated architecture", arXiv preprint arXiv:2003.13630, 2020.
- [29] Y. Yousfi, J.B.E. Khvedchenya, J. Fridrich, "ImageNet pretrained CNNs for JPEG steganalysis", Proceeding of the IEEE/WIFS, pp. 1-6, New York, USA, Dec. 2020 (doi: 10.1109/WIFS49906.2020.9360897).
- [30] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, A. Rabinovich, "Going deeper with convolutions", Proceedings of the IEEE/CVPR, pp. 1-9, Boston, USA, June 2015 (doi: 10.1109/CVPR.2015.7298594).
- [31] D.A. Clevert, T. Unterthiner, S. Hochreiter, "Fast and accurate deep network learning by exponential linear units (elus)", arXiv preprint arXiv:1511.07289, 2015.
- [32] S. Ioffe, C. Szegedy, "Batch normalization: Accelerating deep network training by reducing internal covariate shift," arXiv preprint arXiv:1502.03167, 2015.
- [33] D.T. Dang-Nguyen, C. Pasquini, V. Conotter, G. Boato, "RAISE: A raw images dataset for digital image forensics", Proceedings of the MMSys, pp. 219-224, March 2015 (doi: 10.1145/2713168.2713194).

- [34] K. He, X. Zhang, S. Ren, J. Sun, "Delving deep into rectifiers: Surpassing human-level performance on imagenet classification", Proceedings of the IEEE/CV, pp. 1026-1034, Santiago, Chile, Dec.2015 (doi: 10.1109/ICCV.2015.123).
- [35] D.P. Kingma, J. Ba, "Adam: A method for stochastic optimization", arXiv preprint arXiv:1412.6980, 2014.
- [36] H. Yao, H. Wei, C. Qin, X. Zhang, "An improved first quantization matrix estimation for nonaligned double compressed JPEG images", Signal Processing, vol. 170, Article Number: 107430, May 2020 (doi: 10.1016/j.sigpro.2019.107430).

زیر نویس ها

1. Joint photographic experts group
2. Beauty cam
3. Artifacts
4. Grid
5. Aligned
6. Non-aligned
7. Aligned double JPEG compression
8. Non-aligned double JPEG compression
9. Hand-crafted features based methods
10. Convolutional neural network
11. Discrete cosine transform
12. Benford-Fourier analysis
13. Tchebichef moments
14. Singular value decomposition
15. Denoising
16. Spatial rich model
17. Median filter residual
18. Convolutional autoencoder
19. Alignment
20. Portable network graphics
21. Dataset
22. Adaptive image content remover
23. VGGNet
24. ResNet
25. TResNet
26. Detection accuracy
27. More data-efficient
28. Exponential linear unit
29. Local response normalization
30. Batch normalization
31. Internal covariate shift
32. High resolution
33. Adam optimizer
34. Initial learning rate
35. Epoch
36. Quality factors
37. Relative error reduction
38. Bold
39. True positive
40. False positive
41. False negative
42. Probability map
43. Ground truth