

کشف دستکاری به وسیله فیلتر میانه در تصاویر فشرده

وحیده امانی پور^۱، شاهرخ قائم مقامی^{۲*}

۱- دانشجوی دکتری، ۲- استاد، دانشگاه صنعتی شریف

(دریافت: ۹۷/۰۹/۲۴، پذیرش: ۹۷/۱۱/۲۹)

چکیده

بررسی فیلتر میانه، به عنوان فرآیندی حافظ محتوا، که برای هموارسازی و حذف نویز از تصاویر به کار می‌رود، مورد توجه جدی پژوهشگران حوزه مستندسازی بوده است. در این مقاله، روشی برای کشف به کارگیری فیلتر میانه در تصاویر فشرده بر اساس تجزیه مقادیر تکین ماتریس فرآیند، پیشنهاد شده است. در این روش، ماتریس فرآیند از تخمین خطی فرآیند کدگذاری، اعمال فیلتر میانه و فشرده‌سازی مجدد تصویر حاصل می‌گردد. سپس از تصویر داده‌های ورودی بر فضاهای ویژه این ماتریس به عنوان ویژگی‌های تصویر استفاده می‌شود. به کمک تعداد اندکی از ویژگی‌های مذکور، طبقه‌بندی تصویر به عنوان تصویری اصیل یا پردازش شده انجام می‌پذیرد تا روشی سریع و موثر برای کشف فیلتر میانه طراحی گردد. شبیه‌سازی‌ها نشان می‌دهند که روش پیشنهادی بالاخص در نرخ فشرده‌سازی بالا، عملکرد بهتری نسبت به سایر روش‌های موجود دارد و خطای آشکارسازی آن در مقایسه با روش‌های دیگر ۲٪ تا ۵٪ کمتر است. تجزیه مقادیر تکین ماتریس فرآیند را که در این مقاله معرفی شده است، می‌توان برای کشف سایر دستکاری‌های صورت گرفته روی تصویر نیز به کار برد.

کلیدواژه‌ها: احراز اصالت تصویر، فیلتر میانه، تجزیه مقادیر تکین، مستندسازی تصویر

۱- مقدمه

اعوجاج‌ها را به عنوان اثر مراحل پردازشی صورت گرفته منظور نمود. رویکرد دیگری که برای تعیین مراحل پردازشی اعمال شده روی سیگنال چندرسانه‌ای استفاده می‌شود، درج نشانه به عنوان یک شاخص است تا به کمک آن بتوان گذشته سیگنال را با دقت بیشتری مشخص کرد. این مقاله در چارچوب رویکرد اول به کشف ویرایش‌های صورت گرفته روی تصویر می‌پردازد.

به طور کلی فرآیندهای ویرایشی به دو دسته ملایم و مخرب تقسیم می‌شوند [۱]. ویرایش‌های مخرب محتوای تصویر و اطلاعات موجود در آن را با افزودن و حذف اشیایی به آن و دیگر فرآیندهایی از این دست، تغییر می‌دهند. در مقابل، در ویرایش‌های ملایم، محتوای اصلی و اطلاعات موجود در تصویر حفظ می‌شوند، درحالی که تصویر به شکلی مطلوب‌تر یا قابل استفاده‌تر عرضه می‌گردد. مثال‌های ویرایش ملایم شامل فشرده‌سازی، بهبود کنتراست، هموارسازی، تیز کردن لبه‌ها و حذف نویز است. چنین تغییراتی ممکن است برای از بین بردن آثار قابل مشاهده دستکاری‌های صورت گرفته بر روی تصویر هم به کار گرفته شوند، تا جعل صورت گرفته واقعی‌تر به نظر برسد. به علاوه، این پس‌ویرایش‌های عمومی می‌توانند به عنوان روش‌های ضد مستندسازی برای تخریب آثار باقی‌مانده از دست‌کاری‌های صورت گرفته بر روی تصویر هم مورد استفاده قرار گیرند.

ویرایش تصویر و تغییر محتوای آن با استفاده از نرم‌افزارهایی که در اختیار عموم مردم قرار دارند با پیشرفت فناوری دیجیتال در سال‌های اخیر بسیار ساده شده است. این موضوع باعث آسیب پذیر شدن محتوای تصویر در برابر حملات ویرایشی گردیده است که می‌توانند به طور موثر و نامحسوس محتوای تصویر را تغییر دهند. بر این اساس، کشف تاریخچه ویرایش‌های صورت گرفته بر یک تصویر، به خصوص در حوزه‌هایی مانند مستندسازی، مالکیت معنوی و فیلوژنی، مسئله‌ای مهم و محوری محسوب می‌شود.

برای آشکارسازی پردازش‌های اعمال شده به سیگنال، رویکرد اصلی غیرفعال^۲ و فعال^۳ مورد استفاده قرار می‌گیرند. در رویکرد اول، تنها سیگنال پردازش شده در دسترس است. از آنجا که هر پردازشی اعوجاج‌های ناخواسته و غیرقابل برگشتی روی سیگنال اصلی ایجاد می‌کند؛ مانند اعوجاج‌های حاصل از نرخ نمونه‌برداری ناکافی، عارضه‌های کدگذاری در فشرده‌سازی با اتلاف و یا ناکامل بودن راهبردهای حذف نویز، می‌توان این

* رایانامه نویسنده مسئول: ghaemmag@sharif.edu

² Passive

³ Active

۲- کارهای مرتبط قبلی

فیلتر میانه معمولاً نواحی با شدت روشنایی ثابت یا نزدیک به ثابت ایجاد می‌کند. این خصوصیت به پدیده‌ای منجر می‌شود که به آن «عارضه نواری»^۴ گفته می‌شود [۴]. این عارضه اولین بار توسط کرشنر و فردریش [۵] برای آشکارسازی فیلتر میانه مورد مطالعه قرار گرفت. هرچند این تکنولوژی برای آشکارسازی در حوزه تصاویر غیرفشرده بسیار موثر عمل می‌کند، عملکرد آن برای آشکارسازی فیلتر میانه برای تصاویر JPEG مورد اعتماد نیست. «ماتریس تفاضلی اتصال نقاط»^۵ (SPAM) [۶] برای استخراج دسته‌ای از ویژگی‌ها مورد استفاده قرار می‌گیرد که می‌تواند فیلتر میانه را در تصاویر فشرده آشکار کند. این ویژگی‌های ۶۸۶ بعدی، از روی ماتریس احتمال گذار مربوط به یک مدل مارکوف مرتبه بالا برای تصویر مرتبه اول ساخته می‌شوند و توسط نویسندگان [۵] برای آشکارسازی فیلتر میانه در تصاویر فشرده مورد استفاده قرار می‌گیرند. وقتی کیفیت تصویر JPEG بالا یا متوسط باشد، روش ارائه‌شده، که به روش SPAM موسوم است، در آشکارسازی فیلتر میانه عملکرد خوبی دارد. روش SPAM پیشگام آشکارسازی فیلتر میانه در تصاویر فشرده بوده است.

یوان [۷] ویژگی «مستندسازی فیلتر میانه»^۶ (MFF) را معرفی کرد که در آن اثر فیلتر میانه بر ترتیب و مقادیر سطوح خاکستری تصویر مورد بررسی قرار می‌گیرد. او با استفاده از ویژگی‌های MFF عارضه‌های همبستگی موضعی فیلتر میانه را شناسایی کرد. عملکرد روش‌هایی که بر اساس MFF طراحی شده‌اند در آشکارسازی فیلتر میانه روی تصاویری که نرخ فشرده‌سازی JPEG متوسط دارند، بهتر یا به‌خوبی عملکرد روش‌های طراحی‌شده بر مبنای SPAM است. با این وجود، عملکرد هر دوی این روش‌ها با کاهش «معیار کیفیت»^۷ (QF) تصویر یا کوچک شدن اندازه تصویر (یا پنجره انتخاب شده از تصویر) ضعیف می‌شود.

چن و همکاران او [۸] با ترکیب ویژگی‌های احتمالاتی سرتاسری که از هیستوگرام جابجایی تصویر تفاضلی مرتبه اول و دوم به‌دست می‌آید، با ویژگی‌های همبستگی موضعی (یعنی همبستگی بین پیکسل‌های مجاور) تصویر تفاضلی، مجموعه «ویژگی‌های سرتاسری و موضعی»^۸ (GLF) را معرفی کردند. آشکارسازی که بر اساس ویژگی‌های سرتاسری و موضعی صورت

فیلتر میانه یکی از ویرایش‌های ملایم متداول است که برای هموارسازی و حذف نویز از تصویر به‌کار گرفته می‌شود. به‌علاوه، این فیلتر به‌عنوان ابزار مستندسازی هم قابل استفاده است: اگر تصویر دستکاری‌شده شامل ناحیه‌ای باشد که با فیلتر میانه پردازش شده باشد، کشف آنها می‌تواند باعث کشف دستکاری صورت‌گرفته بر روی تصویر شود. کشف به‌کارگیری فیلتر میانه بر روی تصاویر به‌طور گسترده‌ای مورد مطالعه قرار گرفته است. در بخش بعد کارهای مرتبط مرور شده و به پیشرفت‌های مهم حاصله در این حوزه اشاره می‌شود.

در این مقاله، یک روش آشکارسازی عمومی براساس «تجزیه مقادیر تکین»^۱ (SVD) معرفی شده و با استفاده از آن به آشکارسازی فیلتر میانه در تصویر پرداخته می‌شود. برای هر فرآیند دلخواه F که داده ورودی X را دریافت و ویرایش می‌کند و به‌صورت داده خروجی $Y = F(X)$ تحویل می‌دهد، ابتدا فرآیند با نگاشتی خطی تخمین زده شده که به آن «ماتریس فرآیند»^۲ گفته می‌شود. سپس از تجزیه مقادیر تکین ماتریس فرآیند [۳-۲] برای استخراج مجموعه ویژگی‌های داده ورودی استفاده می‌شود. این ویژگی‌ها شامل نرم‌های داده ورودی و داده خروجی (به‌عنوان بردارهای حقیقی)، به‌همراه تصویر بردار X بر فضاهای ویژه ماتریس فرآیند است که متناظر با مقادیر ویژه بزرگ این ماتریس هستند. به این ترتیب برداری به‌دست می‌آید که به آن «بردار ویژگی‌ها»^۳ گفته می‌شود. این بردار ویژگی‌ها را می‌توان برای دسته‌بندی داده ورودی به یکی از دو دسته پردازش‌شده یا پردازش‌نشده استفاده کرد. در این مقاله برای آشکارسازی فیلتر میانه در تصویر از روش SVD با بردار ویژگی‌های سه‌بعدی استفاده می‌شود. روش پیشنهادی، به‌علت استفاده از تعداد بسیار کم ویژگی‌ها در تشخیص پردازش، در مقایسه با سایر روش‌های آشکارسازی که به‌همان منظور در حوزه تصویر معرفی شده‌اند، بسیار سریع‌تر عمل می‌کند. این درحالی است که دقت آشکارسازی روش پیشنهادی، به‌خصوص در نرخ‌های بالای فشرده‌سازی، بهتر از روش‌های متداول برای آشکارسازی فیلتر میانه در حوزه تصویر است.

در بخش دوم به‌مرور کارهای صورت‌گرفته مرتبط با این موضوع پرداخته شده است. در بخش سوم، روش آشکارسازی SVD معرفی شده و موضوعات ریاضی مرتبط با استخراج بردار ویژگی‌ها در این روش به‌همراه جزئیات مورد بحث قرار می‌گیرند. نتایج شبیه‌سازی‌ها در بخش چهارم گزارش می‌شود و نکات پایانی و نتیجه‌گیری در بخش آخر این مقاله ارائه گردیده‌اند.

² Streaking Artifact

³ Subtractive Pixel Adjacency Matrix

⁴ Median Filtering Forensics

⁵ Quality Factor

⁶ Global and Local Features

¹ Singular Value Decomposition

از آن برای کاربردهای واقعی مرتبط با حوزه پردازش تصویر استفاده کرد.

نیو و همکارانش [۱۲] «توصیفگر تفاوت موضعی»^۸ (LDD) را معرفی کردند که از «الگوهای دودویی موضعی»^۹ (LBP) یکنوای ناوردا تحت دوران به‌عنوان یک دسته از ویژگی‌ها استفاده می‌کند. این دسته از ویژگی‌ها با دسته دیگری از ویژگی‌ها که از ماتریس تفاضل پیکسل‌ها استخراج می‌شود، در آشکارسازی مورد استفاده قرار می‌گیرند. آزمایش‌ها و شبیه‌سازی‌هایی که در [۱۲] گزارش شده‌اند نشانگر عملکرد بهتر روش LDD در مقایسه با روش‌های MFF و AR و GLF بر روی پنجره‌های کوچک درون تصاویر فشرده است.

روش‌های یادشده برای آشکارسازی فیلتر میانه از روش طبقه‌بندی «ماشین بردار پشتیبان»^{۱۰} (SVM) بر روی دسته‌ای از ویژگی‌ها استفاده می‌کنند که از تصویر استخراج می‌گردد. رهیافت متفاوتی توسط چن و همکاران [۱۳] مورد استفاده قرار گرفته است که از «شبکه‌های عصبی درهم پیچیده»^{۱۱} (CNN) برای طراحی آشکارساز فیلتر میانه استفاده می‌کنند. در روش پیشنهادشده در [۱۳] با استفاده از لایه دیگری که به CNN اضافه می‌شود، «مانده فیلتر میانه» استخراج می‌گردد و در اختیار شبکه عصبی درهم پیچیده قرار می‌گیرد.

در مقاله [۱۴] از «مدل مخلوط گاوسی»^{۱۲} (GMM) برای تشخیص پردازش‌های مختلف تصویر شامل فیلتر گاوسی، فیلتر میانه، اضافه‌شدن نویز سفید گاوسی، فشرده‌سازی JPEG تغییر اندازه تصویر و تیزکردن آن استفاده شده است. در مقاله [۱۵] برای کشف فیلتر میانه، فیلتر محوکننده گاوسی، اضافه‌شدن نویز گاوسی و تغییر اندازه، شبکه عصبی درهم پیچیده به‌کار رفته است. در مقاله [۱۶] نیز از شبکه عصبی درهم پیچیده برای تشخیص سه پردازش فیلتر محوکننده گاوسی، فیلتر میانه، و اصلاح گاما و ترکیب‌های ممکن این سه پردازش استفاده شده است. مقاله [۱۷] با استخراج مجموعه‌ای از ویژگی‌های مناسب و طبقه‌بندی چند کلاسه، ویرایش‌هایی شامل یکسان‌سازی هیستوگرام، اصلاح گاما، فشرده‌سازی، فیلتر تیزکننده، میانه، وینر، گاوسی، میانگین‌گیری و تغییر اندازه تصویر را آشکار می‌کند.

در مقاله [۱۸] لایه جدیدی به نام لایه محدودکننده در

می‌گیرد برای تصاویر با اندازه کوچک یا نرخ فشرده‌سازی بالا عملکرد خوبی دارد.

روش «خودبازگشتی»^۱ (AR) یکی از روش‌های مهم و موثر آشکارسازی فیلتر میانه است که در ادامه توسط کنگ و همکارانش [۹] معرفی شد. آنها «مانده فیلتر میانه»^۲ (MFR) را به یک مدل خود بازگشتی تطبیق دادند و بدین وسیله ویژگی‌های آماری MFR را استخراج کردند. با استفاده از ضرایب AR به‌عنوان ویژگی‌ها، آنها روشی را برای آشکارسازی فیلتر میانه طراحی کردند که بر مجموعه‌ای ۱۰ بُعدی از ویژگی‌ها تکیه داشت. با وجود بُعد پایین مجموعه ویژگی‌ها، روش AR موفق‌تر از روش‌های پیش از خود عمل کرد (بالاخص روی تصاویری که ابعاد کوچکی داشتند و یا پنجره‌های کوچکی از یک تصویر، و یا در حالتی که نرخ فشرده‌سازی بالا بود). بُعد پایین مجموعه ویژگی‌ها و عملکرد مطلوب روش AR در آشکارسازی فیلتر میانه، از این آشکارساز روشی سریع، مطلوب و موثر ساخت و روش‌هایی که پس از AR معرفی شدند، همگی عملکرد خود را با این روش مقایسه می‌کنند تا وجوه قوت و توانمندی‌های خود را به اثبات برسانند.

یانگ و همکاران او [۱۰] با به‌کار گرفتن مدل خودبازگشتی دوبعدی برای بررسی ویژگی‌های آماری MFR، و همچنین «مانده فیلتر میانگین»^۳ (AFR) و «مانده فیلتر گاوسی»^۴ (GFR)، روش AR را بهبود بخشیدند. این روش که به روش AR دوبعدی موسوم است بر اساس مجموعه‌ای ۸۱ بُعدی از ویژگی‌ها عمل می‌کند.

ژنگ و همکاران او [۱۱] یک «عملگر بافت موضعی»^۵ را معرفی کردند که به آن «الگوی سه‌گانه موضعی»^۶ (LTP) می‌گویند و براساس آن روشی برای آشکارسازی معرفی می‌کنند که روش LTP خوانده می‌شود. عملگر LTP که از یک تابع کد با سه مولفه استفاده می‌کند، مشتقات موضعی تغییرات جهتی را کد می‌کند. این عملگر می‌تواند به‌طور موثری تغییرات بافت موضعی را که در اثر فیلتر میانه ایجاد می‌شود مورد شناسایی قرار دهد. با استفاده از «آنالیز مولفه‌های اصلی هسته»^۷ (KPCA) بُعد مجموعه ویژگی‌ها کاهش می‌یابد تا حجم محاسبات لازم برای پیاده‌سازی این روش در محدوده قابل پردازشی قرار گیرد و بتوان

¹ Auto-Regressive

² Median Filter Residual

³ Average Filter Residual

⁴ Gaussian Filter Residual

⁵ Local texture operator

⁶ Local Ternary Pattern

⁷ Kernel Principal Component Analysis

⁸ Local Difference Descriptor

⁹ Local binary patterns

¹⁰ Support Vector Machine

¹¹ Convolutional Neural Networks

¹² Gaussian Mixture Model

$$X = (X_1, X_2, \dots, X_n) \text{ و } Y = (Y_1, Y_2, \dots, Y_n) \quad (۱)$$

که مولفه‌های هر کدام از آنها اعداد صحیح نامنظم هستند. بردار ورودی، «بردار اصلی» و بردار خروجی «بردار پردازش شده» منظور می‌شود. وضعیت خاص مورد نظر در اینجا، حالتی است که بردار اولیه تصویر یا پنجره‌ای درون آن باشد و فرآیند هم از ویرایشی بر روی تصویر به دست آمده باشد. در این حالت، فرآیند به عنوان نگاشتی در نظر گرفته می‌شود که تصویر (یا پنجره‌ای درون آن) را به تصویر پردازش شده (یا پنجره متناظر با آن در تصویر پردازش شده) می‌فرستد. هدف ما طراحی روشی است که مشخص کند بردار داده شده $Z = (Z_1, Z_2, \dots, Z_n)$ یک بردار اصلی (بدون دستکاری) یا یک بردار پردازش شده است. در واقع، هدف مشخص در اینجا، عبارت از طراحی روشی برای تشخیص تصویر اصلی (یا پنجره‌ای درون آن) از تصویری است که تحت فرآیند خاصی، نظیر فیلتر میانه، فشرده‌سازی و امثال آن قرار گرفته است.

۳-۱- ماتریس فرآیند

برای ساختن ماتریس فرآیند، از دنباله‌ای مانند:

$$X = (X^1, X^2, \dots, X^N) \quad (۲)$$

از نمونه‌های بردارهای اصلی که تعداد آنها به اندازه کافی زیاد است استفاده می‌شود.

$$Y = F(X) = (Y^1, Y^2, \dots, Y^N) \quad (۳)$$

متناظر با این بردارهای اصلی، بردارهای پردازش شده به دست می‌آیند که آموزش آشکارساز SVD با استفاده از آنها انجام می‌گیرد. جفت بردارهای

$$(X^1, Y^1), (X^2, Y^2), \dots, (X^N, Y^N) \quad (۴)$$

«دنباله نمونه‌های آموزشی» محسوب می‌شود. با استفاده از این نمونه‌های آموزشی، «ماتریس فرآیند»

$$A = (A_{ij}^k)_{i,j=1}^n \quad (۵)$$

به گونه‌ای ساخته می‌شود که به بهترین تخمین خطی از فرآیند F منجر شود. برای بیان دقیق‌تر این شرط، فرض می‌کنیم که نمونه‌های آموزشی به صورت:

$$X^k = (X_1^k, X_2^k, \dots, X_n^k) \text{ و } Y^k = (Y_1^k, Y_2^k, \dots, Y_n^k) \quad (۶)$$

$$k = 1, 2, \dots, N$$

داده شده باشند. حال باید ماتریسی به دست آید که برای آن، خطای تخمین، که با عبارت:

شبکه عصبی در هم پیچیده پیشنهاد شده است که محتوای تصویر را حذف کرده و ویژگی‌های مناسب کشف دستکاری روی تصویر را یاد می‌گیرد. روش ارائه شده نسبت به کار پیشین نویسندگان مقاله، یعنی [۱۵]، عملکرد بهتری دارد. در تمام مقالات ذکر شده، تنها به مسئله کشف گروهی از پردازش‌ها (شامل فیلتر میانه) بدون آن که پس‌پردازشی مانند فشرده‌سازی روی تصویر صورت گیرد، پرداخته شده است. همان‌طور که گفته شد، آشکار کردن فیلتر میانه پس از فشرده‌سازی مشکل‌تر می‌شود، در حالی که برای تصویر غیرفشرده، به راحتی می‌توان فیلتر میانه را کشف کرد. در مقاله [۱۷] صریحاً گزارش شده است که نتایج به دست آمده نسبت به پس‌پردازش JPEG مقاوم نیست. از این‌رو، در مقاله [۱۹] سعی شده است با فرض پس‌پردازش فشرده‌سازی JPEG ویرایش‌های صورت گرفته روی تصویر را به دسته‌های فیلتر پایین‌گذر، فیلتر بالاگذر، حذف نویز و بهبود کنتراست طبقه‌بندی کند. در این مقاله فیلتر میانه به صورت فیلتر پایین‌گذر و حذف نویز طبقه‌بندی می‌شود.

ویژگی‌های قطعی فیلتر میانه در کار پاسکویینی و همکاران او [۲۰] مورد تحلیل قرار گرفته است و براساس این مطالعه، روشی برای آشکارسازی فیلتر میانه در یک بُعد ارائه شده است که در تئوری، نرخ هشدار نادرست آن صفر درصد است. موانع متعددی برای تعمیم این روش به دو بُعد و استفاده از آن برای بررسی تصاویر وجود دارد. چنان که خود نویسندگان این مقاله اشاره می‌کنند، در بررسی فیلترهای میانه دو بُعدی مشکلات متعدد نظری و پیچیدگی محاسباتی به وجود می‌آیند که رفع آنها نیاز به تغییرات وسیعی در روش ارائه شده، بهینه‌سازی‌های مختلف و بررسی موضوعات جدید دارد.

مطالعات متعددی نیز به ضد مستندسازی و راه‌های مقابله با آن به کمک فیلتر میانه اختصاص یافته است. در میان چنین مطالعاتی، شاید اشاره به [۲۱-۲۳] مناسب باشد.

قابل ذکر است که روش پیشنهاد شده ابتدا در مقاله [۲۴] برای کشف فیلتر میانه در ویدئوی فشرده به کار رفته و در آن تنها با روش AR مقایسه صورت گرفته است. در این مقاله، آشکارسازی اثر فیلتر میانه در حوزه تصاویر فشرده انجام پذیرفته و نتایج با روش‌های متعددی مقایسه شده است.

۳- روش پیشنهادی آشکارسازی ویرایش در تصویر

برای فرآیندی مانند F ، که یک ورودی مانند X را به یک خروجی مانند $Y = F(X)$ تبدیل می‌کند، ورودی و خروجی به صورت بردارهای زیر فرض می‌شوند:

(یعنی عدد n بزرگ باشد).

۳-۲- استخراج ویژگی‌ها

وقتی تعداد نمونه‌های آموزشی به اندازه کافی بزرگ باشد، انتظار می‌رود که ماتریس فرآیند دارای n مقدار ویژه متفاوت مختلط (یا حقیقی) باشد که با $\lambda_1, \lambda_2, \dots, \lambda_n$ نشان داده می‌شوند. می‌توان این مقادیر ویژه را به‌گونه‌ای مرتب کرد که رابطه (۱۳) برقرار باشد.

$$\|\lambda_1\| \geq \|\lambda_2\| \geq \dots \geq \|\lambda_n\| > 0 \quad (13)$$

اگر λ یک مقدار ویژه ماتریس فرآیند باشد، مزدوج مختلط λ^* با λ^* نشان داده می‌شود، هم یک مقدار ویژه ماتریس فرآیند خواهد بود، زیرا درایه‌های ماتریس فرآیند، همگی حقیقی هستند. به‌علاوه، ماتریس فرآیند A و مزدوج مختلط آن (که با A^* نشان داده می‌شود)، مقادیر ویژه یکسانی دارند. در ضمن، این مزدوج مختلط در واقع همان ترانهاد ماتریس فرآیند است. بردارهای ویژه متناظر با مقادیر ویژه $\lambda_1, \lambda_2, \dots, \lambda_n$ با V_1, V_2, \dots, V_n نشان داده می‌شوند. به عبارت دیگر فرض می‌شود که روابط زیر در (۱۴) برقرار هستند.

$$V_k A = \lambda_k V_k \quad \text{for } k = 1, 2, \dots, n \quad (14)$$

همچنین بردارهای ویژه W_1, W_2, \dots, W_n به‌گونه‌ای انتخاب می‌شوند که روابط ذکر شده در (۱۵) صادق باشند.

$$W_k A^* = \lambda_k^* W_k \quad \text{for } k = 1, 2, \dots, n \quad (15)$$

برای هر بردار داده X می‌توان بردار تفاضلی متناظر با آن را به‌صورت ترکیب خطی زیر می‌توان نوشت:

$$\bar{X} = X - F(X) = a_1(X)V_1 + \dots + a_n(X)V_n \quad (16)$$

که در آن، ضرایب $a_1(X), a_2(X), \dots, a_n(X)$ اعدادی مختلط هستند و به آنها «ویژگی‌های تکین» بردار داده X گفته می‌شود.

با نمایش ماتریس فرآیند در پایه V_1, V_2, \dots, V_n ، این ماتریس صورت قطری در می‌آید.

$$\begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & & 0 \\ \vdots & \ddots & \ddots & \vdots \\ 0 & 0 & \dots & \lambda_n \end{bmatrix} \quad (17)$$

ماتریس‌های تغییر پایه‌ای، که این نمایش از ماتریس فرآیند را ایجاد می‌کنند، در واقع تجزیه مقادیر تکین (SVD) [۳-۲] را ایجاد می‌کنند، در این حالت خاص به‌دست می‌دهند. باید توجه داشت که متفاوت بودن مقادیر ویژه ماتریس فرآیند برای وجود چنین نمایشی لازم است، و این خاصیت در گرو زیادبودن

$$E = \sum_{k=1}^N \|\bar{Y}^k - \bar{X}^k A\|^2 \quad (7)$$

$$= \sum_{k=1}^N \sum_{i=1}^n \left(\bar{Y}_i^k - \sum_{j=1}^n \bar{X}_j^k A_i^j \right)^2$$

داده می‌شود، حداقل باشد. در رابطه بالا، بردارهای

$$\bar{X}^k = X^k - F(X^k) = (\bar{X}_1^k, \bar{X}_2^k, \dots, \bar{X}_n^k) \quad \text{و} \\ \bar{Y}^k = Y^k - F(Y^k) = (\bar{Y}_1^k, \bar{Y}_2^k, \dots, \bar{Y}_n^k) \quad (8)$$

«بردارهای تفاضل» وابسته به X^k و Y^k هستند.

در روابط بالا، از بردارهای تفاضل به‌جای داده‌های اولیه استفاده شده است، زیرا فرآیندهای ویرایشی معمولاً بردار ورودی را به برداری مشابه با آن تبدیل می‌کنند. برای پررنگ کردن آنچه بر روی داده‌های ورودی اتفاق می‌افتد، بردارهای تفاضلی را در نظر می‌گیریم تا ماتریس فرآیند از ماتریس همانی فاصله بگیرد.

برای تعیین ماتریس فرآیند به‌گونه‌ای که خطای تخمین حداقل شود، از روش ضرایب نامعین لاگرانژ بهره می‌گیریم. براساس این روش، برای ماتریسی که خطا را حداقل می‌کند، روابط زیر برقرار خواهند بود:

$$\sum_{k=1}^N \bar{X}_l^k \left(\bar{Y}_i^k - \sum_{j=1}^n \bar{X}_j^k A_i^j \right) = 0, \\ \text{for } i, l = 1, 2, \dots, n \quad (9)$$

برقرار بودن این روابط برای هر مقدار i, l دقیقاً به این معنا است که روابط:

$$\langle \bar{X}_l, \bar{Y}_i \rangle = \sum_{j=1}^n \langle \bar{X}_l, \bar{X}_j \rangle A_i^j \\ \text{for } i, l = 1, 2, \dots, n \quad (10)$$

برقرار هستند. در اینجا، $\bar{X}_l = (\bar{X}_l^k)_{k=1}^N$ و $\bar{Y}_j = (\bar{Y}_j^k)_{k=1}^N$ ماتریس‌های تک‌سطری است. با تعریف ماتریس‌های

$$P = (P_i^j)_{i,j=1}^n \quad \text{و} \quad Q = (Q_i^j)_{i,j=1}^n \quad (11)$$

با عبارت‌های $Q_j^i = \langle \bar{X}_i, \bar{Y}_j \rangle$ و $P_j^i = \langle \bar{X}_i, \bar{X}_j \rangle$ ، رابطه بالا را می‌توان به صورت‌های زیر بازنویسی کرد:

$$Q = PA \iff A = P^{-1}Q \quad (12)$$

به این ترتیب فرمولی صریح برای محاسبه ماتریس فرآیند بر اساس دنباله نمونه‌های آموزشی به‌دست می‌آید. در عمل، تعداد نمونه‌های آموزشی باید در مقایسه با طول بردارهای داده

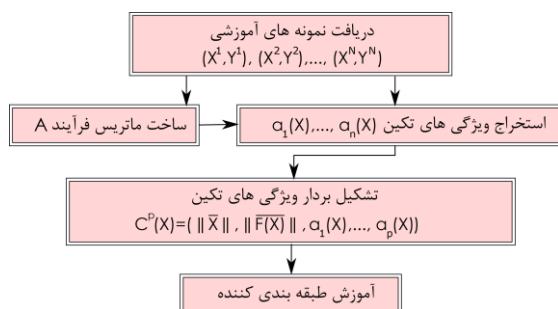
X را به صورت:

$$C^p(X) = (\|\bar{X}\|, \|\overline{F(X)}\|, a_1(X), a_2(X), \dots, a_p(X)) \in \mathbb{C}^{p+1} \quad (22)$$

به بردار بالا، «بردار ویژگی‌های تکین» داده ورودی X می‌گوییم که از آن برای طبقه‌بندی داده ورودی استفاده می‌شود.

از آنجا که بردارهای اصلی و پردازش شده بردارهایی حقیقی و درایه‌های ماتریس فرآیند هم حقیقی هستند، ویژگی تکین متناظر با یک مقدار ویژه λ مزدوج مختلط ویژگی تکین متناظر با مزدوج مختلط λ است. به این ترتیب، ویژگی تکین متناظر با مقدار ویژه λ^* اطلاعات جدیدی در خود ندارد. به علاوه، اگر مقدار ویژه λ حقیقی باشد، ویژگی تکین متناظر با آن هم حقیقی خواهد بود. به طور خاص، اگر تعداد p مقدار ویژه اول ماتریس فرآیند حقیقی باشند، بردار ویژگی‌های تکین یک بردار حقیقی از بُعد $p + 2$ خواهد بود.

بردارهای ویژگی‌های تکین متناظر با دنباله داده‌های آزمایشی (X^i, Y^i) ، $i = 1, \dots, N$ دو توزیع از نقاط $C^p(X^i)$ و $C^p(Y^i)$ در \mathbb{R}^{p+2} به دست می‌دهند که می‌توان از آنها برای آموزش آشکارساز «تجزیه مقادیر تکین» SVD استفاده کرد. سپس می‌توان از این آشکارساز برای طبقه‌بندی بردارهای ورودی به دو دسته اصلی و پردازش شده، بر اساس میزان شباهت آنها به هر یک از توزیع‌های یادشده، استفاده کرد. نمودار روش SVD در شکل (۱) نمایش داده شده است.



شکل (۱). نمودار آشکارساز SVD

۴-۳- فیلتر میانه و مساله طبقه‌بندی

در صورتی که تصویر به صورت فشرده باشد، برای انجام هرگونه فرآیند ویرایشی (نظیر اعمال فیلتر میانه، یا فیلترهای دیگر) ابتدا باید آن را کدگشایی کرد و پس از انجام ویرایش، تصویر مجدداً فشرده شود. بنابراین، فرآیندی که با آن مواجه هستیم از یک مرحله کدگشایی، یک مرحله ویرایش و یک مرحله فشرده‌سازی مجدد تشکیل شده است. این ترکیب سه‌مرحله‌ای در شکل (۲)

تعداد نمونه‌های آموزشی (یعنی بزرگ بودن N در مقایسه با n) است، هرچند در عمل لازم نیست تعداد نمونه‌ها در مقایسه با اندازه بردار داده چندان بزرگتر باشد.

از متفاوت بودن مقادیر ویژه ماتریس فرآیند و تساوی نتیجه می‌شود:

$$\lambda_i \langle V_i, W_j \rangle = (\lambda_i V_i)(W_j)^* = (V_i A)(W_j)^* = V_i (W_j A)^* = V_i (\lambda_j^* W_j)^* = \lambda_j \langle V_i, W_j \rangle \quad (18)$$

اگر اندیس‌های i و j متفاوت باشند داریم:

$$\lambda_i \langle V_i, W_j \rangle = \lambda_j \langle V_i, W_j \rangle, \lambda_i \neq \lambda_j \implies \langle V_i, W_j \rangle = 0 \quad (19)$$

بنابراین، نتیجه می‌شود:

$$\begin{aligned} \langle \bar{X}, W_j \rangle &= a_1(X) \langle V_1, W_j \rangle + a_2(X) \langle V_2, W_j \rangle + \dots \\ &\quad + a_n(X) \langle V_n, W_j \rangle \\ &= a_j(X) \langle V_j, W_j \rangle \end{aligned} \quad (20)$$

به عبارت دیگر، ویژگی‌های تکین با رابطه زیر به طور صریح داده می‌شوند:

$$a_j(X) = \frac{\langle \bar{X}, W_j \rangle}{\langle V_j, W_j \rangle} = \frac{\langle X - F(X), W_j \rangle}{\langle V_j, W_j \rangle} \quad (21)$$

به این ترتیب، فرمول صریحی هم برای ویژگی‌های تکین بر اساس بردارهای ویژه ماتریس فرآیند و مزدوج مختلط آن به دست می‌آید. این بردارهای ویژه، پس از استخراج ماتریس فرآیند، یک بار برای همیشه محاسبه می‌شوند و به این ترتیب، بار محاسباتی بزرگی برای محاسبه ویژگی‌های تکین تحمیل نمی‌شود. لذا محاسبه ویژگی‌های تکین برای یک بردار داده، محاسبه‌ای بسیار سریع و ساده است.

۳-۳- طبقه‌بندی

هریک از ویژگی‌های تکین $a_j(X)$ ، $j = 1, 2, \dots, n$ معادل تصویری از بردار داده X روی صفحه مختلط محسوب می‌گردد. بالاخص، برای هر دنباله از داده‌های آموزشی $(X^1, Y^1), (X^2, Y^2), \dots, (X^N, Y^N)$ از N نقطه $a_j(X^1), a_j(X^2), \dots, a_j(X^N)$ در صفحه مختلط به دست می‌آید که می‌توان آن را با توزیع نقاط $a_j(Y^1), a_j(Y^2), \dots, a_j(Y^N)$ در همین صفحه مختلط مقایسه کرد. وقتی نرم مقدار ویژه λ_j در مقایسه با نرم سایر مقادیر ویژه بزرگ باشد، انتظار می‌رود این دو توزیع از نقاط با هم تفاوت زیادی داشته باشند. برای آشکارسدن این تفاوت، واضح است که باید نرمال‌سازی مناسب هم مد نظر قرار گیرد. برای این مقصود، برای هر بردار داده، به نرم بردارهای \bar{X} و $\overline{F(X)}$ و هم مراجعه و بردار ویژگی‌های متناظر با داده ورودی

به تصویر کشیده شده است. اکثر این تصاویر حاوی پیکسل‌های اشباع شده یا نواحی یکنواخت هستند که کار تشخیص تصاویر میانه‌شده از غیر آن را با چالش مواجه می‌سازند.

برای طبقه‌بندی از روش SVM استفاده می‌کنیم [۲۶] که در آن هسته «تابع پایه شعاعی»^۱ با عبارت زیر داده می‌شود.

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (25)$$

یک «اعتبارسنجی ضربدری»^۲ پنج لایه برای آموزش مورد استفاده قرار می‌گیرد تا دو پارامتر (C, γ) که در طبقه‌بندی مورد استفاده قرار می‌گیرند از شبکه؛

$$\{(2^i, 2^j) \mid i \in \{-5, -4, \dots, 14, 15\}, j \in \{-15, -14, \dots, 5\}\}$$

به‌گونه‌ای انتخاب شوند که عملکرد بهینه حاصل شود. ۷۵ درصد از تصاویر در مرحله آموزش آشکارساز مورد استفاده قرار می‌گیرند و ۲۵ درصد باقیمانده برای تست کردن آشکارساز استفاده می‌شوند.

عملکرد روش طبقه‌بندی در هر مورد با معیار «خطای آشکارسازی»، طبق رابطه (۲۶) سنجیده می‌شود.

$$Pe = \frac{FP+FN}{TP+TN+FP+FN} \quad (26)$$

در این رابطه FP, FN, TP, TN به ترتیب تعداد موارد هشدار مثبت درست، هشدار منفی درست، هشدار مثبت غلط و هشدار منفی غلط را نشان می‌دهند. فرض می‌شود که تعداد نمونه‌های مثبت و منفی، یعنی تعداد تصاویر یا پنجره‌های پردازش شده و پردازش نشده، با هم برابر هستند.

۴-۲- ارزیابی عملکرد روش آشکارسازی SVD و مقایسه با سایر روش‌ها

روش SVD را که در این مقاله معرفی شده است برای آشکارسازی فیلتر میانه به کار برده‌ایم. فیلترهای میانه 3×3 و 5×5 که به ترتیب با MF3 و MF5 نشان داده می‌شوند، روی تصاویر خاکستری اعمال می‌گردند. برای این کار، پنجره‌هایی با اندازه 64×64 ، 128×128 در $w \times h$ نظر گرفته می‌شوند که طول بردار داده متناظر با آنها به ترتیب برابر ۴۰۹۶ با ۱۶۳۸۴ است. این پنجره‌ها از مرکز تصویر بریده می‌شوند.


مقدار p را برابر با ۱ انتخاب می‌کنیم. به عبارت دیگر، تنها به ویژگی تکین متناظر با بزرگترین مقدار ویژه ماتریس فرآیند توجه

هر پنجره از تصویر را می‌توان به صورت یک بردار نمایش داد، که هر مولفه بردار متناظر با یکی از پیکسل‌های تصویر است و مقدار آن مولفه، با روشنایی پیکسل مورد نظر تعیین می‌گردد.

با این نمایش از داده‌های ورودی، می‌توان از آشکارساز SVD که طراحی آن در زیربخش‌های گذشته مورد اشاره قرار گرفت، برای تصمیم‌گیری در مورد اعمال فیلتر میانه بر روی یک داده ورودی استفاده نمود.

هر بردار X^k در دنباله نمونه‌های آموزشی شامل اطلاعات یک پنجره با اندازه $w \times h$ است که در آن، w عرض پنجره و h طول آن را نمایش می‌دهد. بنابراین، تعداد پیکسل‌های پنجره انتخاب شده برابر است با: $n = w \times h$ و هر پیکسل با یکی از مولفه‌های بردار در تناظر هست. به این ترتیب، بردارهای زیر ساخته می‌شوند:

$$X^k = (X_1^k, X_2^k, \dots, X_n^k) \quad k = 1, 2, \dots, N \quad (23)$$



شکل (۲): فرآیند از سه مرحله کدگذاری، ویرایش و فشرده‌سازی مجدد تشکیل شده است.

هر یک از این پنجره‌ها متناظر با پنجره‌ای در تصویر ویرایش شده است، که بردار دیگری را به دست می‌دهد:

$$Y^k = (Y_1^k, Y_2^k, \dots, Y_n^k) \quad k = 1, 2, \dots, N \quad (24)$$

با استفاده از دنباله نمونه‌های آموزشی $(X^1, Y^1), (X^2, Y^2), \dots, (X^N, Y^N)$ ماتریس فرآیند همان‌گونه که قبلاً به آن اشاره شد، تعیین می‌شود و ویژگی‌های تکین $a_1(X), a_2(X), \dots, a_n(X)$ استخراج می‌گردند. با استفاده از این ویژگی‌های مذکور، بردار ویژگی‌های تکین ساخته می‌شود و در یک فرآیند طبقه‌بندی مورد استفاده قرار می‌گیرد.

۴- نتایج آزمایش‌ها و شبیه‌سازی‌ها

۴-۱- داده‌ها و روش شبیه‌سازی

برای شبیه‌سازی‌ها از مجموعه تصاویر UCID استفاده می‌کنیم [۲۵]، که شامل ۱۳۳۸ تصویر رنگی غیرفشرده با اندازه

^۱Radial Basis Function (RBF) kernel

^۲Cross validation

در جدول (۳) بُعد مجموعه ویژگی‌های مربوط به هر یک از روش‌های [۵] SPAM و [۷] MFF و [۸] GLF و [۹] AR و [۱۰] 2D-AR و [۱۱] LTP و [۱۲] LDD گزارش شده است. روش طبقه‌بندی مورد استفاده توسط همه این آشکارسازها روش SVM است که از هسته RBF بهره می‌برد.

یک مسئله بسیار مهم در استفاده از هسته‌های RBF تعمیم یافته، بار محاسباتی آنها است [۲۷]. بالابودن بُعد ویژگی‌ها، حجم محاسبات لازم را برای روش آشکارسازی پیشنهادی افزایش می‌دهد. این افزایش، هم در مرحله آموزش آشکارساز و هم در مرحله آزمون آن، دیده می‌شود.

جدول (۳): بعد مجموعه ویژگی‌ها برای آشکارسازهای مختلف فیلتر میانه.

روش	ابعاد ویژگی
SPAM	۶۸۶
MFF	۴۴
GLF	۵۶
AR	۱۰
2D-AR	۸۱
LTP	۲۰۴۸
LDD	۱۲۸
SVD	۳

زمان آموزش یک طبقه‌بند غیرخطی SVM با هسته RBF برابر با $O(dN^3)$ یا $O(dN^2)$ است که در آن، d بُعد مجموعه ویژگی‌ها و N تعداد نمونه‌های آموزشی است که برای آموزش طبقه‌بند مورد استفاده قرار می‌گیرد. آزمون یک طبقه‌بند عمل پرهزینه‌ای است، زیرا ویژگی‌های هر داده باید با ویژگی‌های N داده دیگر که برای آموزش استفاده شده بودند، مورد مقایسه قرار گیرد. به این ترتیب، زمان آزمون این طبقه‌بند، از مرتبه $O(dNM)$ است که در آن، M تعداد نمونه‌هایی است که باید در آزمون شرکت داده شوند [۲۷].

بررسی فوق نشان می‌دهد که روش پیشنهادی، با وجود برخورداری از پیچیدگی محاسباتی به مراتب کمتر در مقایسه با میزان بار محاسباتی روش‌های مشابه، دست‌یابی به دقت نسبی بالاتری را در تشخیص دستکاری تصویر به‌وسیله فیلتر میانه ممکن می‌سازد.

۵- نتیجه‌گیری

در این مقاله روشی برای آشکارسازی فیلتر میانه در تصاویر فشرده ارائه شده است که آن را آشکارسازی بر اساس «تجزیه مقادیر تکین» نامیده‌ایم. در این روش، یک ماتریس فرآیند که

می‌شود. این بزرگترین مقدار ویژه در شبیه‌سازی‌های صورت‌گرفته حقیقی است. لذا، بُعد مجموعه ویژگی‌ها در آشکارساز طراحی شده برابر با ۳ است. به عبارت دیگر، بردارهای ویژگی‌های تکین $C^1(X^k)$ و $C^1(Y^k)$ بردارهایی در فضای سه‌بعدی \mathbb{R}^3 هستند.

همان‌طور که قبلاً ذکر شد، عملکرد روش‌های کشف فیلتر میانه با کاهش «معیار کیفیت» تصویر یا کوچک‌شدن اندازه تصویر (یا پنجره انتخاب شده از تصویر) ضعیف می‌شود. خطای آشکارسازی روش پیشنهادی (SVD)، برای کشف تصاویر میانه-شده در برابر تصاویر اصیل (ORI)، با روش‌های [۹] AR، [۸] GLF، [۱۱] LTP و [۱۲] LDD مورد مقایسه قرار می‌گیرد که نتایج آن در جدول (۱) گزارش شده‌اند. در این جدول، نتایج آزمایش برای تصاویر فشرده‌شده JPEG با فاکتورهای کیفیت ۳۰، ۴۰ و ۵۰ با استفاده از پنجره 128×128 ارائه گردیده‌اند. همان‌گونه که انتظار می‌رود، دقت آشکارسازی با بالارفتن نرخ فشرده‌سازی، کاهش می‌یابد و در میان روش‌های مختلف، روش ارائه‌شده در این مقاله در اغلب موارد عملکرد بهتری دارد.

جدول (۱): خطای آشکارسازی برای تصاویر فشرده به فرمت JPEG با معیارهای کیفیت مختلف.

QF	MF3 vs ORI %			MF5 vs ORI %		
	۵۰	۴۰	۳۰	۵۰	۴۰	۳۰
GLF	۱۲/۱	۱۲/۴	۱۳/۸	۵/۱	۶/۱۰	۶/۸
AR	۹/۱	۹/۴	۱۰/۶	۶/۹	۷/۱	۷/۸
LTP	۱۰/۷	۱۱/۵	۱۳/۷	۵/۴	۵/۶	۷/۴
LDD	۸/۹	۹/۸	۱۰/۱	۴/۷	۵/۶	۶/۴
SVD	۶/۶	۷/۱۰	۸/۱	۴/۸	۵/۲	۴/۸

در جدول (۲) خطای آشکارسازی برای دو اندازه مختلف تصویر 128×128 و 64×64 در حالی که فاکتور کیفیت ثابت و برابر ۷۰ است، گزارش شده است. همان‌گونه که جدول نشان می‌دهد، با کاهش اندازه تصویر، دقت آشکارسازی کمتر می‌شود و در مقایسه با سایر روش‌ها، روش SVD عملکرد بهتری دارد.

جدول (۲): خطای آشکارسازی برای تصاویر فشرده به فرمت JPEG با اندازه‌های مختلف.

اندازه	MF3 vs ORI %		MF5 vs ORI %	
	128×128	64×64	128×128	64×64
AR	۸/۹	۱۵/۱	۷/۱	۱۲/۳
LTP	۷/۷	۱۶/۳	۴/۱	۱۳/۷
LDD	۶/۴	۱۴/۹	۴/۳	۱۰/۱۰
SVD	۵/۴	۱۴/۱۰	۳/۸	۹/۹

- [11] Y. Zhang, S. Li, S. Wang, and Y. Q. Shi, "Revealing the traces of median filtering using high-order local ternary patterns," *IEEE Signal Process. Lett.*, vol. 21, no. 3, pp. 275-279, 2014.
- [12] Y. Niu, Y. Zhao, and R. Ni, "Robust median filtering detection based on local difference descriptor," *Signal Process. Image Comm.*, vol. 53, pp. 65-72, 2017.
- [13] J. Chen, X. Kang, Y. Liu, and Z. J. Wang, "Median filtering forensics based on convolutional neural networks," *IEEE Signal Process. Lett.*, vol. 22, no. 11, pp. 1849-1853, 2015.
- [14] W. Fan, K. Wang, and F. Cayre, "General-purpose image forensics using patch likelihood under image statistical models," in *Proc. IEEE Int. Workshop Inf. Forensics security*, pp. 1-6, 2015.
- [15] B. Bayar and M. C. Stamm, "A deep learning approach to universal image manipulation detection using a new convolutional layer," in *Proc. ACM Workshop Inf. Hiding Multimedia security*, pp. 5-10, 2016.
- [16] H. Y. Choi, H. U. Jang, D. Kim, J. Son, S. M. Mun, S. Choi, and H. K. Lee, "Detecting composite image manipulation based on deep neural networks," in *Proc. the Int. Conf. on Syst. Signal and Image Processing*, IEEE, pp. 1-5, 2017.
- [17] H. Li, W. Luo, and X. Qiu, "Identification of various image operations using residual-based features," *IEEE Trans. on Circuits and Systems for Video Technology*, vol. 28, no. 1, pp. 31-45, Jan. 2018.
- [18] B. Bayar, and M. C. Stamm, "Constrained Convolutional Neural Networks: A New approach Towards General Purpose Image Manipulation Detection," *IEEE Tran. Inf. Forensics Security*, pp. 2691-2706, 2018.
- [19] M. Boroumand and J. Fridrich, "Deep learning for detecting processing history of images," in *Electronic Imaging*, no. 7, pp. 1-9, 2018.
- [20] C. Pasquini, G. Boato, N. Alajlan, and F. G. B. De Natale, "A deterministic approach to detect median filtering in 1D data," *IEEE Trans. Inf. Forensics Security*, vol. 11, no. 7, pp. 1425-1437, 2016.
- [21] W. Fan, K. Wang, F. Cayre, and Z. Xiong, "Median filtered image quality enhancement and anti-forensics via variational deconvolution," *IEEE Trans. Inf. Forensics Security*, vol. 10, no. 5, pp. 1076-1091, 2015.
- [22] Z. H. Wu, M. C. Stamm, and K. J. R. Liu, "Anti-forensics of median filtering," in *Proc. IEEE Int. Conf. Acoust. Speech, Signal Processing*, pp. 3043-3047, 2013.
- [23] H. Zeng, T. Qin, X. Kang, and L. Liu, "Countering anti-forensics of median filtering," in *Proc. IEEE Int. Conf. Acoust. Speech, Signal Processing*, pp. 2704-2708, 2014.
- [24] V. Amanipour and S. Ghaemmaghami, "Median Filtering Forensics in Compressed Video," *IEEE Signal Process. Lett.*, vol. 26, no. 2, pp. 287-291, Feb. 2019.
- [25] G. Schaefer and M. Stich, "UCID-an uncompressed color image database," in *Proc. SPIE, Storage and Retrieval Methods and Appl. for Multimedia*, no. 36, pp. 472-480, 2004.
- [26] C. C. Chang and C. J. Lin, "LIBSVM: A library for support vector machines," *ACM Trans. on Intelligent Syst. and Technol.*, vol. 2, no. 3, pp. 1-39, 2011.
- [27] V. Sreekanth, A. Vedaldi, C. V. Jawahar, and A. Zisserman, "Generalized RBF feature maps for efficient detection," in *Proc. Brit. Mach. Vision Conf.*, pp. 1-11, 2010.

بهترین تخمین خطی از فرآیند کدگشایی، اعمال فیلتر میانه و فشرده‌سازی مجدد تصویر است، بر اساس دنباله‌های از داده‌های آموزشی ساخته می‌شود. استخراج ویژگی‌های فیلتر میانه بر اساس تجزیه مقادیر تکین این ماتریس فرآیند صورت می‌گیرد. تصویر هر داده ورودی روی فضاهای ویژه ماتریس فرآیند، ویژگی‌های تکین داده را به‌وجود می‌آورد و بردار ویژگی‌ها که در مرحله طبقه‌بندی مورد استفاده قرار می‌گیرد، از ویژگی تکین مناظر با مقادیر ویژه بزرگ ماتریس فرآیند ساخته می‌شود. بار محاسباتی روش پیشنهادی، چه در مرحله آموزش آشکارساز و چه در مرحله آزمون آن، به مراتب سبک‌تر از بار محاسباتی روش‌های مشابه در حوزه تصویر است. شبیه‌سازی‌های صورت‌گرفته نشان می‌دهند که خطای آشکارسازی فیلتر میانه در تصاویر فشرده با استفاده از روش پیشنهادی، در مقایسه با خطای روش‌های موجود و بالاخص در نرخ فشرده‌سازی بالا، به میزان ۲٪ تا ۵٪ کمتر است.

۶- منابع

- [1] Reverse engineering of audio-visual content data, "Deliverable D3.1, State-of-the-art on multimedia footprint detection," FP7-ICT project REWIND, Grant Agreement no. 268478, Technical report, 2011.
<https://cordis.europa.eu/docs/projects/cnect/8/268478/080/deliverables/001-REWINDD31final.pdf>
- [2] S. Banerjee and A. Roy, "Linear Algebra and Matrix Analysis for Statistics," (Texts in Statistical Science), 1st ed. London, U.K., Chapman and Hall/CRC, 2014.
- [3] G. W. Stewart, "On the early history of the singular value decomposition," *SIAM Review*, vol. 35, no. 4, pp. 551-566, 1993.
- [4] A. C. Bovik, "Streaking in median filtered images," *IEEE Trans. Acoust. Speech, Signal Process.*, vol. 35, no. 4, pp. 493-503, 1987.
- [5] M. Kirchner and J. Fridrich, "On detection of median filtering in digital images," *Proc. SPIE, Media Forensics and Security II*, vol. 7541, pp. 1-12, 2010.
- [6] T. Pevny, P. Bas, and J. Fridrich, "Steganalysis by subtractive pixel adjacency matrix," *IEEE Trans. Inf. Forensics security*, vol. 5, no. 2, pp. 215-224, 2010.
- [7] H. Yuan, "Blind forensics of median filtering in digital images," *IEEE Trans. Inf. Forensics Security*, vol. 6, no. 4, pp. 1335-1345, 2011.
- [8] C. Chen, J. Ni, R. Huang, and J. Huang, "Blind detection of median filtering in digital images: A difference domain based approach," *IEEE Trans. Image Process.*, vol. 22, no. 12, pp. 4699-4710, 2013.
- [9] X. Kang, M. C. Stamm, A. Peng, and K. J. R. Liu, "Robust median filtering forensics using an autoregressive model," *IEEE Trans. Inf. Forensics Security*, vol. 8, no. 9, pp. 1456-1468, 2013.
- [10] J. Yang, H. Ren, G. Zhu, J. Huang, and Y. Q. Shi, "Detecting median filtering via two-dimensional AR models of multiple filtered residuals," *Multimed. Tools Appl.*, vol. 77, no. 7, pp. 7931-7953, 2018.

Detection of Median Filtering Manipulation in Compressed Images

V. Amanipour, S. Ghaemmaghani*

*Sharif University of Technology

(Received: 12/09/2018, Accepted: 05/03/2019)

ABSTRACT

Median filtering, as a nonlinear content preserving process that is often employed for smoothing and denoising images, has received significant attention from the forensics and documentation research community. In this paper, a detection scheme for median filtering of compressed images is proposed, based on singular value decomposition of the process matrix. In the proposed method, the process matrix is obtained by linear estimation of the decoding process, implementation of median filtering and recompression of the image. The projections of input data over eigenspaces of this process matrix is then used as features of the image. A small number of such features are utilized to classify the image as either original or processed, thus leading to a fast and effective detection scheme for median filtering. The experimental evaluations show that the proposed scheme outperforms the existing methods, particularly over highly compressed images, and its detection error is 2% to 5% lower in comparison to the errors introduced by other detection schemes. The singular value decomposition of the process matrix introduced in this paper, may also be used in detection of other cases of image content manipulation.

Keywords: Image authentication, Median filter, Singular value decomposition, Image Forensics

* Corresponding Author Email: ghaemmag@sharif.edu