

# اصلاح معماری شبکه عصبی کانولوشنال جهت طبقه‌بندی تصاویر آغشته به نویز ضربه

محمد مؤمنی، مهدی آقا صرام، علی محمد لطیف و راضیه شیخ‌پور

هستند تشکیل شده است. شبکه‌های عصبی کانولوشنی تصویر اصلی را لایه به لایه از مقادیر اصلی پیکسل‌ها به امتیاز کلاس نهایی تبدیل می‌کنند [۵] تا [۹].

در [۱۰] شبکه NCNN توسط Audhkhasi و همکاران معرفی گردید و نشان داده شد که تزریق نویز به تصویر در شرایط خاص می‌تواند سرعت آموزش شبکه عصبی کانولوشنال را افزایش دهد. نتایج شبیه‌سازی مشخص‌کننده کاهش نرخ خطا و افزایش سرعت در طبقه‌بندی است. اهمیت تعیین میزان دقیق تزریق نویز به تصویر در افزایش سرعت طبقه‌بندی از معایب این روش است به طوری که اگر چگالی نویز از یک سطح آستانه بیشتر شود، آن گاه باعث کاهش شدید دقت طبقه‌بندی می‌گردد. در [۱۱] یک چارچوب حذف نویز جدید مبتنی بر شبکه عصبی کانولوشنال عمیق برای حذف نویز ضربه در تصاویر استفاده شده است. چارچوب این روش از دو ماژول تشکیل شده است: تشخیص نویز و بازسازی تصویر که هر دو توسط یک شبکه عصبی کانولوشنی عمیق اجرا می‌شوند. در ابتدا یک شبکه طبقه‌بندی کننده برای شناسایی در یک تصویر رنگی آموزش داده می‌شود. سپس با جایگزینی مقادیر کانال‌های نویزی با صفر و نگاه داشتن سایر کانال‌های بدون نویز، یک تصویر رنگی پراکنده محاسبه می‌شود. سرانجام، تصویر رنگی پراکنده برای بازسازی تصویر اصلی به یک شبکه دیگر تغذیه می‌شود. در [۱۲] یک روش بازیابی تصویر مبتنی بر شبکه‌های عصبی کانولوشنال عمیق برای حذف نویز ضربه ارائه شده است. چارچوب این روش به دو مؤلفه تقسیم می‌شود: یک شبکه طبقه‌بندی کننده که پیکسل‌های تصویر را به نویزی و بدون نویز تقسیم می‌کند و یک شبکه رگرسیون که برای بازسازی تصویر آموزش دیده است. در شبکه رگرسیون، پیکسل‌های بدون نویز برای بازیابی تصویر نویزی استفاده می‌شوند.

بروز هر گونه اختلال در تصاویر ورودی CNN در نتایج خروجی تأثیرگذار است. تصاویر آغشته به نویز باعث کاهش دقت طبقه‌بندی در شبکه عصبی کانولوشنال می‌شود [۱۳]. پیش‌پردازش برای حذف نویز از تصاویر ورودی CNN باعث بهبود دقت طبقه‌بندی می‌گردد. با این وجود، عدم بهبود کامل تصاویر در مرحله پیش‌پردازش در اثر چگالی بالای نویز ممکن است اثرات منفی در عملیات یادگیری و اعتبارسنجی CNN داشته باشد [۱۳].

عملیات پیش‌پردازش برای حذف نویز از تصاویر زمان‌بر و پرهزینه است و استفاده از فیلتر میانه از نخستین روش‌های حذف نویز ضربه می‌باشد. از معایب روش‌های مبتنی بر فیلتر میانه این است که اگر تصویر دارای نویز با چگالی بالا باشد این فیلترها کارایی خوبی ندارند و نمی‌توانند پیکسل‌های بدون نویز را از پیکسل‌های نویزی تشخیص دهند و این منجر به حذف اطلاعات مهم تصویر از جمله لبه‌ها می‌شود [۱۴]. از روش‌های حذف نویز ضربه و بهبود کیفیت تصویر می‌توان به انواع فیلترهای کلیدزنی از قبیل GLAM [۱۵]، OCS [۱۶] و FSM [۱۷]

چکیده: نویز ضربه موجب اختلال در فرایند طبقه‌بندی تصاویر توسط شبکه عصبی کانولوشنال می‌گردد. پیش‌پردازش جهت حذف نویز ضربه هزینه‌بر است و تصاویر تخریب‌شده به دلیل عدم بهبود کافی، اثر مخرب در مراحل آموزش و اعتبارسنجی این شبکه دارند. در این مقاله با اصلاح معماری شبکه عصبی کانولوشنال، یک مدل مقاوم در برابر نویز ضربه معرفی می‌شود. روش پیشنهادی، طبقه‌بندی تصاویر نویزی را بدون نیاز به هیچ گونه پیش‌پردازش انجام می‌دهد. لایه تشخیص نویز ضربه در بدنه شبکه عصبی کانولوشنال تعبیه می‌شود و از پردازش مقادیر نویزی جلوگیری می‌کند. برای آموزش مدل پیشنهادی از پایگاه داده ۲۰۱۲-ILSVRC استفاده شده است. نتایج شبیه‌سازی نشان می‌دهد که جلوگیری از تأثیرگذاری نویز ضربه در فرایند آموزش و طبقه‌بندی شبکه عصبی کانولوشنال، دقت و سرعت آموزش شبکه را افزایش می‌دهد. روش پیشنهادی با خطای ۰/۲۴ در طبقه‌بندی تصاویر آغشته به نویز ضربه با چگالی ۱۰٪ بهتر از سایر روش‌های مورد مقایسه می‌باشد. مرتبه زمانی (O(۱ در اصلاح CNN جهت مقاومت در برابر نویز نشان‌دهنده برتری روش پیشنهادی است.

کلیدواژه: نویز ضربه، شبکه عصبی کانولوشنال، طبقه‌بندی تصویر، شناسایی نویز.

## ۱- مقدمه

بهبود کیفیت تصاویر نویزی و حذف اختلال‌های ناخواسته انواع نویزها جزء چالش‌های ضروری محسوب می‌شود. نویز ضربه که در آن اختلاف شدت پیکسل نویزی با پیکسل‌های اطراف زیاد است، یکی از عوامل تضعیف کیفیت در تصاویر دیجیتال می‌باشد. یکی از مسایل در زمینه حذف نویز ضربه، نگهداری جزئیات تصویر مانند لبه‌ها و بافت تصویر به همراه کاهش نویز است. این نویز با پالس مثبت و منفی در فرایند اکتساب تصویر، ذخیره تصویر در حافظه، رمزگذاری و انتقال تصویر از خطوط انتقالی موجب تخریب تصویر می‌شود [۱] تا [۴]. وجود نویز ضربه در تصاویر اثر مخربی در طبقه‌بندی تصاویر توسط شبکه کانولوشنال دارد. CNN از روش‌های مؤثر برای طبقه‌بندی تصاویر است که یادگیری را با استفاده از لایه‌های کانولوشن، ادغام و لایه تماماً متصل انجام می‌دهد. این شبکه از نورون‌هایی که دارای وزن‌ها و بایاس‌های آموزش‌پذیر


این مقاله در تاریخ ۲۳ بهمن ماه ۱۳۹۷ دریافت و در تاریخ ۲۰ مرداد ماه ۱۳۹۸ بازنگری شد.

محمد مؤمنی، دانشکده مهندسی کامپیوتر، پردیس فنی و مهندسی، دانشگاه یزد، یزد، ایران، (email: mohamad.momeny@stu.yazd.ac.ir).


مهدی آقا صرام، دانشکده مهندسی کامپیوتر، پردیس فنی و مهندسی، دانشگاه یزد، یزد، ایران، (email: mehdi.sarram@yazd.ac.ir).

علی محمد لطیف (نویسنده مسئول)، دانشکده مهندسی کامپیوتر، پردیس فنی و مهندسی، دانشگاه یزد، یزد، ایران، (email: alatif@yazd.ac.ir).

راضیه شیخ‌پور، گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه اردکان، اردکان، ایران، (email: rsheikhpour@ardakan.ac.ir).



شکل ۱: روندنمای کلی رهیافت پیشنهادی.



شکل ۳: شبکه عصبی پیشنهادی برای تشخیص نویز ضربه مبتنی بر بهبود الگوریتم معرفی شده در [۴].

### ۲-۱ لایه تشخیص نویز ضربه

شناسایی صحیح نویز ضربه در فرایند مقاوم‌سازی CNN دارای اهمیت است. لایه تشخیص نویز ضربه با روش پیشنهادی مبتنی بر بهبود روش Liang و همکاران [۴] در ابتدای شبکه CNN تعبیه می‌شود. نویز ضربه به طور کلی به صورت مقادیر حدی (سفید یا سیاه) در تصویر وجود دارد و اختلاف شدت پیکسل نویزی با پیکسل‌های همسایه زیاد است. بنابراین میزان شباهت مقدار یک پیکسل با مقادیر پیکسل‌های همسایه به شناسایی نویز ضربه کمک می‌کند. محاسبه اختلاف شدت پیکسل جاری و پیکسل‌های همسایه در همسایگی ۵×۵ طبق شکل ۲ انجام می‌شود. شکل ۳ نشان‌دهنده معماری روش پیشنهادی مبتنی بر شبکه عصبی برای تشخیص نویز ضربه است. لایه تشخیص نویز ضربه، شامل آموزش شبکه عصبی مبتنی بر محاسبه فاصله مقادیر پیکسل‌های همسایه و پیکسل جاری طبق معیارهای زیر است:

- فاصله کسینوسی<sup>۱</sup> (رابطه (۱))
- فاصله زاویه‌ای<sup>۲</sup> [۲۳] (رابطه (۲))
- فاصله برداری بر پایه زاویه<sup>۳</sup> [۲۳] (رابطه (۳))
- فاصله اقلیدوسی<sup>۴</sup> (رابطه (۴))
- اختلاف شدت<sup>۵</sup> [۴] (رابطه (۵))
- میانگین اختلاف زمینه<sup>۶</sup> [۴] (رابطه (۶))
- اختلاف پیچیدگی انباشتی<sup>۷</sup> [۴] (رابطه (۷))

$$CD(i, j, k) = \frac{\sum_{m=i-\tau}^{i+\tau} \sum_{n=j-\tau}^{j+\tau} \sum_{l=1}^{\tau} I(i, j, k) \times I(m, n, l)}{\sqrt{\sum_{m=i-\tau}^{i+\tau} \sum_{n=j-\tau}^{j+\tau} \sum_{l=1}^{\tau} I_{(i, j, k)}^{\tau} \times \sum_{m=i-\tau}^{i+\tau} \sum_{n=j-\tau}^{j+\tau} \sum_{l=1}^{\tau} I_{(m, n, l)}^{\tau}}} \quad (1)$$

1. Cosine Distance
2. Angular Distance
3. Vector Angular-Based Distance
4. Euclidean Distance
5. Gray-Level Difference
6. Average Background Difference
7. Accumulation Complexity Difference

I(i-2,j-2)	I(i-1,j-2)	I(i,j-2)	I(i+1,j-2)	I(i+2,j-2)
I(i-2,j-1)	I(i-1,j-1)	I(i,j-1)	I(i+1,j-1)	I(i+2,j-1)
I(i-2,j)	I(i-1,j)	I(i,j)	I(i+1,j)	I(i+2,j)
I(i-2,j+1)	I(i-1,j+1)	I(i,j+1)	I(i+1,j+1)	I(i+2,j+1)
I(i-2,j+2)	I(i-1,j+2)	I(i,j+2)	I(i+1,j+2)	I(i+2,j+2)

شکل ۲: پنجره ۵×۵ تصویر.

اشاره کرد.

Esakkirajan و همکارانش برای بازیابی تصاویر با نویز ضربه، فیلتر MDBTMF را ارائه دادند. در این روش ابتدا یک پنجره دوبعدی ۳×۳ در مرکز هر پیکسل ایجاد می‌شود. اگر مقدار پیکسل چیزی به غیر از صفر یا ۲۵۵ بود، مقدار واقعی پیکسل شناخته شده و پردازش نمی‌شود. اگر کلیه مقادیر پنجره صفر یا ۲۵۵ بود میانگین مقادیر پنجره جایگزین مقدار فعلی پیکسل می‌شود و در غیر این صورت مقادیر صفر و ۲۵۵ از پنجره حذف شده و میانه مقادیر باقیمانده در پیکسل جاری قرار می‌گیرد. عملیات فوق تا پیمایش کل تصویر ادامه می‌یابد [۱۸].

Yu و همکارانش طیف گرادیان ترکیبی را مبتنی بر یک روش دومرحله‌ای برای حذف نویز ضربه ارائه دادند [۱۹]. Shanmugavadivu و همکارانش در [۲۰] فیلتر میانه دومرحله‌ای تطبیقی ATSM را برای رفع نویز ارائه دادند.

الگوریتم‌های مبتنی بر فیلتر میانه دارای ساختاری ساده و در عین حال زمان اجرای سریع هستند. از معایب روش‌های مبتنی بر فیلتر میانه این است که اگر تصویر دارای نویز با چگالی بالا باشد این فیلترها کارایی خوبی ندارند و نمی‌توانند پیکسل‌های بدون نویز را از پیکسل‌های نویزی تشخیص دهند و این منجر به حذف اطلاعات مهم تصویر از جمله لبه‌ها می‌شود [۱۵]، [۱۷] و [۲۱].


در روش مرکب برای بهبود اثر نویز ضربه‌ای تصویر با استفاده از اتوماتای سلولی، ابتدا نقاط نویزی تشخیص داده می‌شود و در ادامه با اطلاع از نقاط نویزی، نقطه مورد نظر را تغییر می‌دهند [۲۲]. الگوریتم‌های مبتنی بر اتوماتای سلولی اغلب دارای ساختار ساده هستند ولی اجرای الگوریتم نسبت به فیلترهای میانه کندتر است. از اتوماتای سلولی برای سیستم‌هایی که از اجزای ساده‌ای تشکیل شده‌اند و رفتار هر جزء بر اساس رفتار همسایگان و متناسب با تجربیاتش تعیین و اصلاح می‌شود، استفاده می‌گردد [۲۲].

هدف این مقاله، افزایش دقت طبقه‌بندی تصاویر آغشته به نویز ضربه توسط CNN همراه با کاهش پیچیدگی زمانی است. روش پیشنهادی به حذف مرحله پیش‌پردازش برای حذف نویز و اصلاح معماری شبکه CNN جهت مقاوم‌سازی در برابر نویز ضربه می‌پردازد.

روش پیشنهادی در بخش دوم معرفی می‌شود. نتایج آزمایش‌ها در بخش سوم ارائه می‌گردد و بخش چهارم شامل نتیجه‌گیری است.

### ۲- روش پیشنهادی

معماری روش پیشنهادی در شکل ۱ نشان داده شده است. در ادامه به تشریح بخش‌های مختلف معماری CNN پیشنهادی پرداخته می‌شود.



شکل ۴: دو سطح آستانه  $Th_{top}$  و  $Th_{down}$  برای جداسازی پیکسل‌های سالم، قطعاً نویزی و احتمالاً نویزی.

اگر  $z \leq Th_{down}$  سپس  $p = 1$  بنابراین مقدار پیکسل قطعاً نویزی است.

در جایی که  $p$  نشان‌دهنده احتمال نویزی بودن مقدار پیکسل است (شکل ۴). از احتمال نویزی بودن یک پیکسل، در بخش مقاوم‌سازی CNN در برابر نویز استفاده خواهد شد.

وظیفه لایه تشخیص نویز، تهیه نقشه نویز است تا پیکسل‌های سالم و نویزی تصویر از هم تفکیک شوند. نقشه نویز در این مقاله، بیانگر دسته‌بندی مقادیر پیکسل‌های تصویر به سه دسته سالم، قطعاً نویزی و احتمالاً نویزی است. در روش پیشنهادی برای مقاوم‌سازی CNN در برابر نویز، برای هر تصویر یک نقشه نویز تولید می‌شود. با توجه به شکل ۵، هر تصویر شامل چهار کانال خواهد بود: نقشه نویز، کانال قرمز، کانال آبی و کانال سبز. بنابراین تصاویر با چهار کانال به CNN داده می‌شود. در فرایند آموزش مبتنی بر نقشه نویز، روش پیشنهادی نحوه برخورد با پیکسل‌های نویزی را یاد می‌گیرد.

### ۲-۲ لایه کانولوشن تطبیقی در برابر نویز

پیکسل‌های همسایه نقش مهمی در بازیابی مقادیر پیکسل‌های نویزی دارند. در کارهای اخیر از پیکسل‌های همسایه برای بازیابی مقادیر پیکسل‌های نویزی استفاده شده است [۴]. در الگوریتم پیشنهادی برای بهبود طبقه‌بندی در تصاویر آغشته به نویز، پیکسل‌های همسایه به صورت انطباقی به کارگیری می‌شود به طوری که بر اساس سالم یا نویزی بودن مقادیر پیکسل‌های تصویر، اندازه ابعاد کرنل کانولوشن جهت فیلترگذاری به صورت تطبیقی تنظیم می‌گردد.

اندازه هسته کانولوشن در CNN پایه  $3 \times 3$  بود. در [۲۷] روشی ارائه شد تا هسته کانولوشن بتواند هم‌زمان ابعاد  $3 \times 3$ ،  $1 \times 1$  و  $5 \times 5$  داشته باشد و اثبات شد که این روش کارایی بهتری نسبت به CNN پایه دارد. همچنین با اضافه کردن چندین هسته کانولوشن در ابعاد مختلف، این روش بهبود داده شد. در این مقاله، ایده به کارگیری از هسته کانولوشن در ابعاد مختلف برای ارتقای طبقه‌بندی تصاویر نویزی استفاده می‌شود. نحوه تنظیم اندازه ابعاد کرنل کانولوشن به صورت تطبیقی جهت فیلترگذاری به شرح زیر است:

- فیلتر کانولوشن  $(n-2) \times (n-2)$  برای پیکسل‌های با مقدار سالم
  - فیلتر کانولوشن  $n \times n$  برای همه پیکسل‌های تصویر
  - فیلتر کانولوشن  $(n+2) \times (n+2)$  برای پیکسل‌های نویزی
- در روش پیشنهادی برای حذف نویز همراه با حفظ لبه‌ها و بافت تصویر، فیلترگذاری تطبیقی بر اساس مقادیر پیکسل‌ها در CNN جهت افزایش دقت طبقه‌بندی انجام می‌شود. در پیکسل آغشته به نویز، برای بازیابی مقدار پیکسل به همسایه‌های بیشتری نیاز است و بنابراین افزایش ابعاد کرنل کانولوشن بر اساس نویزی بودن پیکسل انجام می‌شود. افزایش

$$AD(i, j, k) = 1 - \left[ 1 - \frac{z}{\pi} \times \cos^{-1} \frac{\sum_{m=i-z}^{i+z} \sum_{n=j-z}^{j+z} \sum_{l=1}^r I(i, j, k) \times I(m, n, l)}{\sqrt{\sum_{m=i-z}^{i+z} \sum_{n=j-z}^{j+z} \sum_{l=1}^r I^2(i, j, k)} \times \sqrt{\sum_{m=i-z}^{i+z} \sum_{n=j-z}^{j+z} \sum_{l=1}^r I^2(m, n, l)}} \right] \quad (2)$$

$$VAD(i, j, k) = 1 - AD(i, j, k) \times \frac{\sum_{m=i-z}^{i+z} \sum_{n=j-z}^{j+z} \sum_{l=1}^r I(i, j, k) - I(m, n, l)}{\sqrt{3 \times 255^2}} \quad (3)$$

$$ED(i, j, k) = \sqrt{\sum_{m=i-z}^{i+z} \sum_{n=j-z}^{j+z} (I(i, j, k) - I(m, n, k))^2} \quad (4)$$

$$GD(i, j, k) = \sum_{m=i-1}^{i+1} \sum_{n=j-1}^{j+1} |I(i, j, k) - I(m, n, k)| \quad (i, j) \neq (m, n) \quad (5)$$

$$ABD(i, j, k) = I(i, j, k) - \text{Mean} \left( \sum_{m=i-1}^{i+1} \sum_{n=j-1}^{j+1} I(m, n, k) \right) \quad (i, j) \neq (m, n) \quad (6)$$


$$ACD(i, j, k) = \sum_{m=i-1}^{i+1} \sum_{n=j-1}^{j+1} |4 \times I(m, n, k) - I(m-1, n, k) - I(m+1, n, k) - I(m, n-1, k) - I(m, n+1, k)| \quad (7)$$

در روش پیشنهادی برای محاسبه فاصله برداری از کانال‌های قرمز، سبز و آبی تصویر استفاده می‌شود. مقادیر موجود در کانال‌های همسایه هر پیکسل، یک بردار در نظر گرفته می‌شود. میزان اختلاف بین مقادیر پیکسل مرکزی و پیکسل‌های همسایه به صورت برداری توسط فاصله‌های کسینوسی، زاویه‌ای و برداری بر پایه زاویه محاسبه می‌گردد. رابطه (۷) طبق پیکسل‌های موجود در همسایگی وان نیومن<sup>۱</sup> تعریف شده است زیرا مقادیر این همسایگی تأثیر مهمی در تشخیص نویز دارند [۲۴]. همه فاصله‌های محاسبه‌شده به عنوان ورودی به شبکه عصبی داده می‌شود. در هر یک از روابط فوق اگر تقسیم بر صفر اتفاق بیفتد، صفر جایگزین خواهد شد.

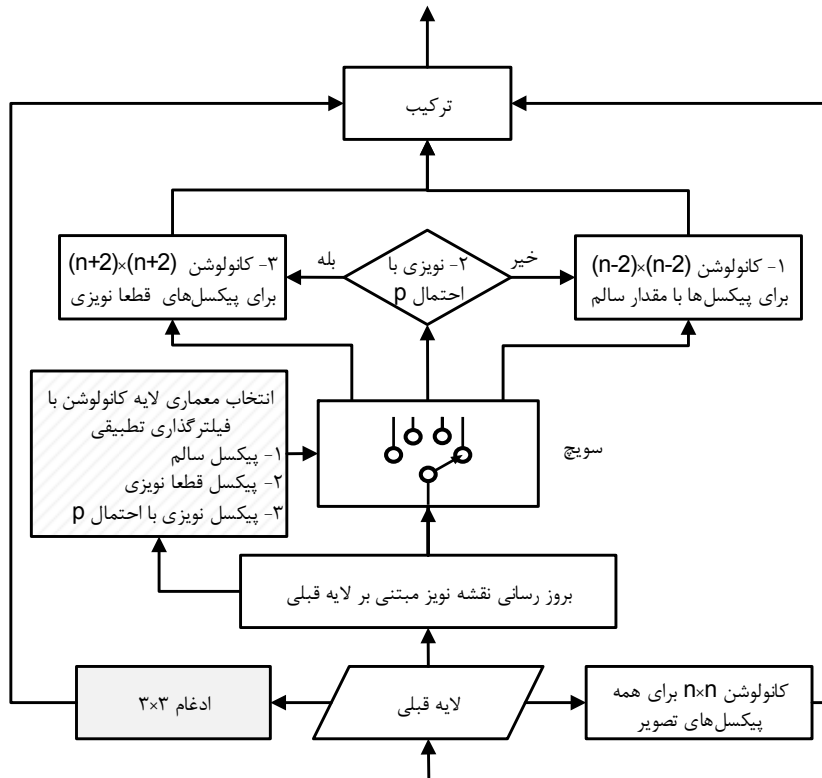
در شبکه عصبی پیشنهادی،  $X$  نشان‌دهنده ورودی شبکه است و خروجی شبکه با  $Z$  نمایش داده می‌شود. وزن‌های لایه‌های شبکه با  $\bar{W}$  و مشخص گردیده است.

برای آموزش شبکه عصبی از روش پس‌انتشار خطا استفاده می‌شود. در بیشتر مقالات اخیر، مقادیر پیکسل‌ها به دو دسته سالم و نویزی طبقه‌بندی می‌شوند [۱۹] تا [۲۲]، [۲۵] و [۲۶]. در روش Liang و همکاران نیز خروجی شبکه از یک سطح آستانه عبور داده می‌شود تا مقادیر پیکسل‌ها به دو دسته سالم و نویزی تقسیم گردد. ولی خروجی شبکه عصبی پیشنهادی از دو سطح آستانه  $Th_{top}$  و  $Th_{down}$  برای دسته‌بندی پیکسل‌ها به سالم، قطعاً نویزی و احتمالاً نویزی عبور داده می‌شود. خروجی شبکه عصبی پیشنهادی با نرمال‌سازی Max/Min به عددی در بازه [۰،۱] نگاشت شده و با  $z$  نمایش داده می‌شود. با توجه به مقدار  $z$ ، برای هر یک از مقادیر پیکسل‌های تصویر شرایط زیر محتمل است:

- اگر  $z \geq Th_{down}$  سپس  $p = 0$  بنابراین مقدار پیکسل سالم است.
- اگر  $Th_{down} < z < Th_{top}$  سپس  $p = 1 - z$  بنابراین مقدار پیکسل احتمالاً نویزی است.




شکل ۵: چهار کانال برای هر تصویر.



شکل ۶: معماری لایه کانولوشن پیشنهادی جهت مقاوم سازی شبکه برای تصاویر نویزی.

ادغام دارد. برای مثال، نویز ضربه باعث اختلال در عملگر ادغام کننده بیشینه می‌شود. نویز ضربه با مقدار صفر و ۲۵۵ ظاهر می‌شود بنابراین ادغام بیشینه همواره پیکسل نویزی حاوی ۲۵۵ را انتخاب می‌کند. از طرف دیگر مقدار نویزی صفر همواره به عنوان کمترین مقدار در لایه ادغام کمینه انتخاب می‌شود. در این پژوهش یک روش جدید برای اصلاح عملگر ادغام جهت افزایش دقت شبکه عصبی کانولوشنال در طبقه بندی تصاویر نویزی ارائه می‌گردد. شکل ۷ یک مثال عددی از عملگر ادغام بیشینه را نشان می‌دهد. برای حذف نویز در لایه ادغام، کافی است که از پردازش پیکسل نویزی توسط عملگر ادغام جلوگیری شود. شکل ۸ روش پیشنهادی برای بهبود عملگر ادغام کننده بیشینه جهت حذف نویز با چگالی پایین را نشان می‌دهد. پیکسل نویزی با مربع مشکی مشخص شده است. همان طور که در تصویر مشاهده می‌شود، با پیش‌گیری از پردازش پیکسل نویزی در عملگر ادغام، از انتخاب مقدار نویزی برای به کارگیری در لایه‌های بعدی CNN جلوگیری می‌شود. این عمل باعث افزایش دقت طبقه بندی می‌گردد.



شکل ۷: عملگر ادغام ۲×۲ با روش بیشینه با گام ۲ برای پیکسل‌های با مقدار سالم.

کرنل کانولوشن برای پیکسل‌های نویزی، کاهش تأثیر نویز در CNN را در بر دارد. شکل ۶ معماری لایه کانولوشن پیشنهادی جهت مقاوم سازی شبکه برای تصاویر نویزی را نشان می‌دهد. شایان ذکر است که نقشه نویز در هر لایه به روز رسانی می‌شود.

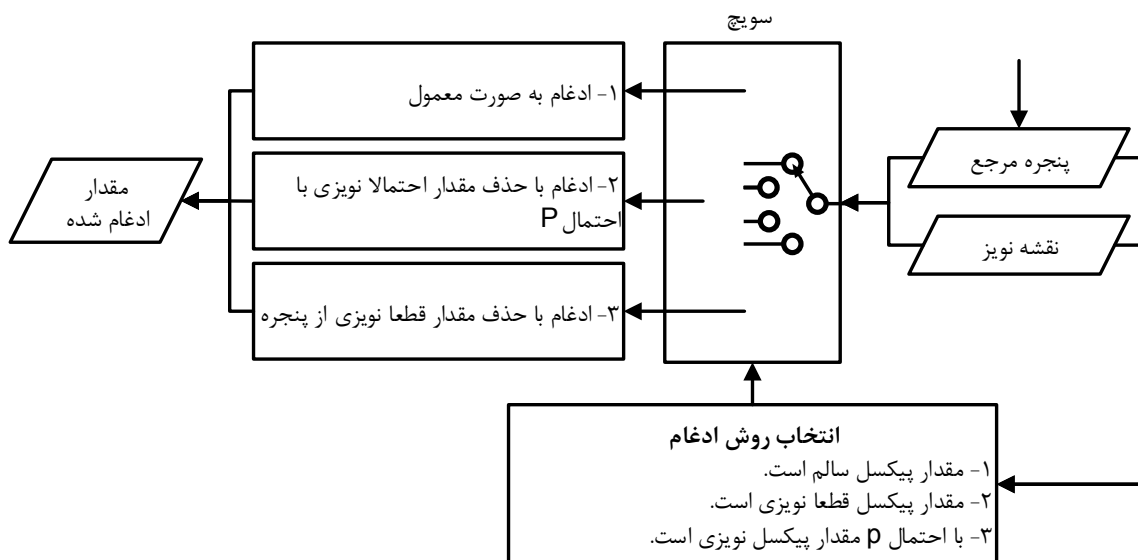
### ۳-۲ ادغام تطبیقی

یک تابع ادغام کننده، خروجی شبکه در یک مکان خاص را با خلاصه آماری خروجی‌های همسایه جایگزین می‌کند. نویز تأثیر مستقیم در لایه



شکل ۸: روش پیشنهادی برای بهبود عملکرد ادغام‌کننده بیشینه ۲×۲ با گام ۲ جهت حذف نویز با چگالی پایین (پیکسل نویزی با مربع مشکی مشخص شده است).

شکل ۹: رهیافت معرفی شده برای بهبود عملکرد ادغام‌کننده بیشینه جهت حذف نویز با چگالی بالا (پیکسل‌های نویزی با مربع مشکی مشخص شده است).



شکل ۱۰: روندنمای روش پیشنهادی برای بهبود عملکرد ادغام‌کننده بیشینه جهت حذف نویز.

از موارد زیر خواهد بود:

- میزان چگالی نویز تصویر ورودی
- نتیجه خروجی CNN

با اصلاح تابع هزینه بر اساس میزان تخریب تصویر ورودی و چگالی نویز، CNN یاد می‌گیرد که از نقشه نویز برای تعیین وزن‌های نرون‌ها در لایه کانولوشن استفاده کند. برای محاسبه میزان چگالی نویز، رابطه زیر استفاده می‌گردد [۲۸]

$$ND_r = \frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N (P_{r_{ij}}) \quad (8)$$

که  $P_r$  مشخص‌کننده نقشه نویز و  $ND_r$  نشان‌دهنده چگالی نویز در  $r$  امین تصویر ورودی است. پارامترهای CNN بر اساس نتیجه خروجی CNN و چگالی نویز تصویر ورودی در هر مرحله از آموزش تنظیم می‌گردند. یعنی هرچه چگالی نویز در تصویر ورودی بالاتر باشد، پارامترهای CNN تغییر کمتری نسبت به مقدار قبلی خود در فرایند آموزش خواهند داشت. این امر باعث می‌شود که تصاویر با چگالی نویز بالا تأثیر کمتری در آموزش داشته باشند. با فرض این که  $L_{soft\ max}$  خروجی تابع هزینه  $Soft\ max$  باشد آن گاه اصلاح تابع هزینه تطبیقی در برابر نویز با رابطه زیر میسر می‌گردد

$$Loss\ function = (L_{soft\ max} \times \lambda_1) + (\overline{ND} \times \lambda_2) \quad (9)$$

$\lambda_1 \in \mathbb{R}, \lambda_2 \in \mathbb{R}$

که  $\overline{ND}$  میانگین چگالی نویز همه تصاویری است که در محاسبه خروجی تابع هزینه  $L_{soft\ max}$  مؤثر بوده‌اند.  $\lambda_1$  و  $\lambda_2$  به ترتیب نشان‌دهنده ضریب تأثیرگذاری  $L_{soft\ max}$  و چگالی نویز بر تابع خطا می‌باشد. روش پیشنهادی برای اصلاح تابع هزینه بر اساس میزان تخریب

با افزایش چگالی نویز، احتمال تخریب پیکسل‌های کل پنجره در تصویر وجود دارد. با توجه به این که عملکرد ادغام چندین بار در لایه‌های شبکه عصبی کانولوشنال تکرار می‌شود، می‌توان روش پیشنهادی برای ادغام پیکسل‌های نویزی را بارها استفاده کرد. در شکل ۹ روش پیشنهادی در بهبود عملکرد ادغام‌کننده بیشینه جهت برخورد با پیکسل‌های نویزی با چگالی بالا نشان داده شده است. پیکسل‌های نویزی با مربع مشکی مشخص گردیده است. شکل ۱۰ نشان‌دهنده روندنمای روش پیشنهادی برای بهبود عملکرد ادغام‌کننده بیشینه جهت حذف نویز است. در این روندنمای یک سوئیچ تعبیه شده که انتخاب روش ادغام بر اساس مقادیر پیکسل‌ها در CNN را کنترل می‌کند. در لایه ادغام پیشنهادی، پیکسل‌هایی که با احتمال  $p$  توسط نویز تخریب شده باشند، با همان احتمال در عملیات ادغام شرکت داده نمی‌شوند. به عبارت دیگر، مشارکت یک پیکسل در لایه ادغام منوط به سالم بودن مقدار آن پیکسل است. اگر یک پیکسل احتمالاً نویزی است، در لایه ادغام پیشنهادی با همان احتمال پردازش نمی‌گردد.

## ۲-۴ تابع هزینه مبتنی بر چگالی نویز تصویر ورودی

به منظور آموزش و تنظیم پارامترهای CNN، از نتیجه خروجی جهت محاسبه میزان خطای شبکه استفاده می‌شود [۲۸]. برای این کار خروجی شبکه را با استفاده از یک تابع خطا<sup>۱</sup> با پاسخ صحیح مقایسه کرده و میزان خطا محاسبه می‌شود. پارامترهای CNN با توجه به تأثیری که بر خطای ایجادشده در شبکه دارند اصلاح می‌گردند. در روش پیشنهادی، برای کاهش میزان آسیب‌پذیری CNN به نویز، محاسبه تابع خطا ترکیبی

VGG-Net ضروری است که روش پیشنهادی یک بار بر پایه معماری medium و یک بار بر پایه معماری slow پیکربندی<sup>۱</sup> شود. در جدول ۱، پیکربندی روش پیشنهادی بر پایه مدل VGG-Net-Medium قابل مشاهده است. جدول ۲ نشان‌دهنده پیکربندی روش پیشنهادی بر پایه مدل VGG-Net-Slow می‌باشد.


مدل پیشنهادی از پنج لایه کانولوشن و سه لایه تماماً متصل تشکیل شده است. اندازه فیلتر، فقط در اولین لایه کانولوشن، تطبیقی در برابر نویز است به طوری که اندازه فیلتر در نواحی با پیکسل‌های سالم ثابت است و بر اساس معماری VGG-Net تنظیم می‌شود. اندازه فیلتر در نواحی با پیکسل‌های نویزی افزایش می‌یابد (شکل ۶). جهت نرمال‌سازی از LRN<sup>۲</sup> استفاده شده است [۳۰]. عملکرد لایه ادغام به روش تطبیقی وزن‌دار است. در هر لایه، نقشه نویز به روز رسانی می‌شود. از تابع فعال‌ساز RELU<sup>۳</sup> در همه لایه‌ها به غیر از آخرین لایه استفاده شده است [۳۰]. در آخرین لایه از تابع هزینه تطبیقی در برابر نویز مبتنی بر  $soft - max$  به کارگیری شده است. برای آموزش مدل پیشنهادی از پایگاه داده ۲۰۱۲-ILSVRC استفاده شده [۳۱] که شامل ۱۰۰۰ کلاس است. در این مجموعه داده از ۱/۳ میلیون تصویر برای آموزش و ۵۰ هزار تصویر برای اعتبارسنجی استفاده شده است. میزان خطا در طبقه‌بندی، معیار ارزیابی برای آزمون مدل می‌باشد.

### ۳-۳ نتایج طبقه‌بندی

افزایش و کاهش ابعاد کرنل کانولوشن، بر اساس نویزی و سالم بودن پیکسل‌ها باعث بهبود دقت طبقه‌بندی می‌شود زیرا افزایش اندازه کرنل در ناحیه‌های نویزی باعث کاهش تأثیر نویز می‌شود. پیکربندی روش پیشنهادی با استفاده از لایه ادغام تطبیقی، از پردازش پیکسل‌های نویزی توسط عملگر ادغام جلوگیری می‌کند. در جدول ۳ VGG-Net-Medium و روش پیشنهادی برای طبقه‌بندی تصاویر نویزی مقایسه شده‌اند. همان گونه که نتایج نشان می‌دهد، روش پیشنهادی در همه موارد کمترین خطا در طبقه‌بندی را دارد. جدول ۴ مقایسه طبقه‌بندی روش پیشنهادی و VGG-Net-Slow برای تصاویر نویزی با چگالی ۱۰٪ تا ۵۰٪ را نشان می‌دهد. نتایج حاکی از برتری روش پیشنهادی در طبقه‌بندی تصاویر نویزی است.

برای مقایسه مدل پیشنهادی از پایگاه داده MNIST استفاده شده که شامل ۱۰ کلاس است [۳۲]. این مجموعه داده از ۷۰۰۰۰ تصویر تشکیل شده که ۶۰۰۰۰ نمونه سالم برای آموزش و ۱۰۰۰۰ نمونه نویزی برای تست اختصاص یافته است. میزان خطا (Top ۱) در طبقه‌بندی، معیار ارزیابی برای آزمون مدل می‌باشد. در جدول ۵ پیکربندی شماره ۱ مدل پیشنهادی شامل سه لایه کانولوشن، دو لایه ادغام، یک لایه ReLU و یک لایه تماماً متصل نشان داده شده است. پیکربندی شماره ۲ مدل پیشنهادی شامل پنج لایه کانولوشن، سه لایه ادغام، دو لایه ReLU و یک لایه تماماً متصل است (جدول ۶).

مطابق با شکل ۶، فقط در اولین لایه کانولوشن، اندازه فیلتر  $n \times n$  به صورت تطبیقی در برابر نویز است به طوری که اندازه فیلتر در نواحی با پیکسل‌های سالم ثابت است ولی اندازه فیلتر در نواحی با پیکسل‌های نویزی افزایش می‌یابد. نقشه نویز در هر لایه به روز رسانی می‌شود.



شکل ۱۱: شناسایی نویز ضربه.

تصویر ورودی قابل تعمیم به توابع هزینه دیگر نیز می‌باشد. اگر چگالی نویزهای گوسی، پواسون، اسپیکل و سایر نویزهای پایه‌ای در هر تصویر ورودی قابل محاسبه باشد، تابع هزینه مبتنی بر چگالی نویز به روش پیشنهادی قابل پیاده‌سازی است.

### ۲-۵ زمان اجرا

مدت زمان اجرای الگوریتم‌های بهبود کیفیت تصاویر نویزی دارای اهمیت است. معمولاً تصاویر آغشته به نویز ضربه در دو مرحله بازیابی می‌شوند. در مرحله اول، سالم یا نویزی بودن مقدار پیکسل تشخیص داده می‌شود. اصلاح مقدار پیکسل آغشته به نویز و بهبود کیفیت تصویر در مرحله دوم انجام می‌گردد [۲] تا [۴] و [۱۴]. در این مقاله، مرحله اول یا شناسایی نویز با تهیه نقشه نویز بر پایه روش‌های اخیر انجام می‌شود. مرحله دوم، مقاوم‌سازی CNN در برابر نویز بدون هیچ گونه پیش‌پردازش است. روش پیشنهادی در تمام مراحل زیر تنها از سوئیچینگ با پیچیدگی زمانی  $O(1)$  برای کنترل پیکسل‌های نویزی استفاده می‌کند:

- لایه کانولوشن CNN با فیلترگذاری تطبیقی در برابر نویز
- پرش تطبیقی در برابر نویز
- لایه ادغام تطبیقی در برابر نویز

### ۳- شیب‌سازی

#### ۱-۳ شناسایی نویز

شناسایی نویز ضربه به روش پیشنهادی با روش‌های [۴] و [۲۹] با استفاده از تصویر بابون در شکل ۱۱ مقایسه گردید. نتایج شیب‌سازی نشان‌دهنده برتری روش پیشنهادی نسبت به سایر روش‌های مورد مقایسه است.

#### ۲-۳ تنظیم پارامترهای CNN

برای آموزش مدل پیشنهادی از ۱۰۰ هزار تصویر آغشته به نویز با چگالی ۲۰٪ به عنوان مرجع الگوی نویز با توزیع یکنواخت استفاده شده است. نقشه نویز برای یادگیری باناظر در مدل پیشنهادی به کار گرفته شده است. تصاویر ورودی به اندازه  $224 \times 224$  تغییر اندازه داده شده‌اند. روش پیشنهادی با مدل VGG-Net آموزش‌دیده [۳۰] با معماری medium و slow مقایسه شده و بنابراین برای مقایسه با مدل‌های

1. Configuration
2. Local Response Normalization
3. Rectification Linear Unit

جدول ۱: پیکربندی روش پیشنهادی بر پایه VGG-NET-MEDIUM.

Layer	VGG-Net-Medium	Proposed	Size	Number	Number	Padding
۱	-	Noise detection	-	-	-	-
۲	Input	Input	-	-	-	-
۳	Convolution	Adaptive convolution	۷×۷	۹۶	۹۶	۰
۴,۵	ReLU, LRN	ReLU, LRN	-	-	-	-
۶	Max pooling	Adaptive max pooling	۳×۳	-	-	۰
۷	Convolution	Convolution	۵×۵	۲۵۶	۲۵۶	۱
۸,۹	ReLU, LRN	ReLU, LRN	-	-	-	-
۱۰	Max pooling	Adaptive max pooling	۳×۳	-	-	۰
۱۱	Convolution	Convolution	۳×۳	۵۱۲	۵۱۲	۱
۱۲	ReLU	ReLU	-	-	-	-
۱۳	Convolution	Convolution	۳×۳	۵۱۲	۵۱۲	۱
۱۴	ReLU	ReLU	-	-	-	-
۱۵	Convolution	Convolution	۳×۳	۵۱۲	۵۱۲	۱
۱۶	ReLU	ReLU	-	-	-	-
۱۷	Max pooling	Adaptive max pooling	۳×۳	-	-	۰
۱۸	Fully connected	Fully connected	-	۴۰۹۶	۴۰۹۶	۰
۱۹	ReLU	ReLU	-	-	-	-
۲۰	Fully connected	Fully connected	-	۴۰۹۶	۴۰۹۶	۰
۲۱	ReLU	R3-3eLU	-	-	-	-
۲۲	Fully connected	Fully connected	-	۱۰۰۰	۱۰۰۰	۰
۲۳	Loss function	Adaptive loss function	-	-	-	-

جدول ۲: پیکربندی روش پیشنهادی بر پایه VGG-NET-SLOW.


Layer	VGG-Net-Slow	Proposed	Size	Number	Stride	Padding
۱	-	Noise detection	-	-	-	-
۲	Input	Input	-	-	-	-
۳	Convolution	Adaptive convolution	۷×۷	۹۶	۲	۰
۴,۵	ReLU, LRN	ReLU, LRN	-	-	-	-
۶	Max pooling	Adaptive max pooling	۳×۳	-	۳	۰
۷	Convolution	Convolution	۵×۵	۲۵۶	۱	۰
۸	ReLU	ReLU	-	-	-	-
۹	Max pooling	Adaptive max pooling	۲×۲	-	۲	۰
۱۰	Convolution	Convolution	۳×۳	۵۱۲	۱	۱
۱۱	ReLU	ReLU	-	-	-	-
۱۲	Convolution	Convolution	۳×۳	۵۱۲	۱	۱
۱۳	ReLU	ReLU	-	-	-	-
۱۴	Convolution	Convolution	۳×۳	۵۱۲	۱	۱
۱۵	ReLU	ReLU	-	-	-	-
۱۶	Max pooling	Adaptive max pooling	۳×۳	-	۳	۰
۱۷	Fully connected	Fully connected	-	۴۰۹۶	۱	۰
۱۸	ReLU	ReLU	-	-	-	-
۱۹	Fully connected	Fully connected	-	۴۰۹۶	۱	۰
۲۰	ReLU	ReLU	-	-	-	-
۲۱	Fully connected	Fully connected	-	۱۰۰۰	۱	۰
۲۲	Loss function	Adaptive loss function	-	-	۱	۰

در شکل‌های ۱۲ و ۱۳ مقایسه Baseline CNN (BL-CNN) و  $n = 5$  می‌باشد.

### ۳-۴ پیچیدگی زمانی

زمان بازیابی تصویر آغشته به نویز ضربه توسط الگوریتم‌های MF

در شکل‌های ۱۲ و ۱۳ مقایسه Baseline CNN (BL-CNN) و  $n = 5$  می‌باشد. برای  $n = 7$  و  $n = 5$  پارامترهای ۱ و ۲ با پارامترهای  $n = 7$  و  $n = 5$  برای طبقه‌بندی تصاویر نویزی نمایش داده شده است. همان گونه که مشاهده می‌شود، کمترین خطا در شکل ۱۲ با پیکربندی شماره دو با ابعاد



شکل ۱۲: مقایسه Baseline CNN با پیکربندی شماره یک و دو روش پیشنهادی ( $n = 5$ ) و برای طبقه‌بندی تصاویر آغشته به نویز ضربه.

جدول ۴: مقایسه روش پیشنهادی و VGG-NET-SLOW برای طبقه‌بندی تصاویر نویزی با چگالی ۱۰٪ تا ۵۰٪.

روش‌ها	خطا در طبقه‌بندی (Top 5)				
	۱۰٪	۲۰٪	۳۰٪	۴۰٪	۵۰٪
VGG-Net-M	۰٫۴۷	۰٫۷۲	۰٫۸۷	۰٫۹۴	۰٫۹۸
روش پیشنهادی	۰٫۲۵	۰٫۳۳	۰٫۳۸	۰٫۴۱	۰٫۴۳

جدول ۳: مقایسه روش پیشنهادی و VGG-NET-MEDIUM برای طبقه‌بندی تصاویر نویزی با چگالی ۱۰٪ تا ۵۰٪.

روش‌ها	خطا در طبقه‌بندی (Top 5)				
	۱۰٪	۲۰٪	۳۰٪	۴۰٪	۵۰٪
VGG-Net-M	۰٫۴۵	۰٫۶۹	۰٫۸۵	۰٫۹۳	۰٫۹۶
روش پیشنهادی	۰٫۲۴	۰٫۳۱	۰٫۳۷	۰٫۴۰	۰٫۴۲


جدول ۵: پیکربندی شماره یک شبکه پیشنهادی.

Layer	BL-CNN	NR-CNN	Size	Number	Stride	Padding $n = 5$	Padding $n = 7$
۰	-	Noise detection	-	-	-	-	-
۱	Input	Input	-	-	-	-	-
۲	Convolution	Adaptive Convolution	$n \times n$	۲۰	۱	۰	۱
۳	Max pooling	Adaptive Max pooling	$2 \times 2$	-	۲	۰	۰
۴	Convolution	Convolution	$5 \times 5$	۵۰	۱	۰	۰
۵	Max pooling	Max pooling	$2 \times 2$	-	۲	۰	۰
۶	Convolution	Convolution	$4 \times 4$	۵۰۰	۱	۰	۰
۷	ReLU	ReLU	-	-	۱	۰	۰
۸	Fully connected	Fully connected	$1 \times 1$	۱۰	۱	۰	۰
۹	Loss function	Adaptive loss function	-	-	-	-	-

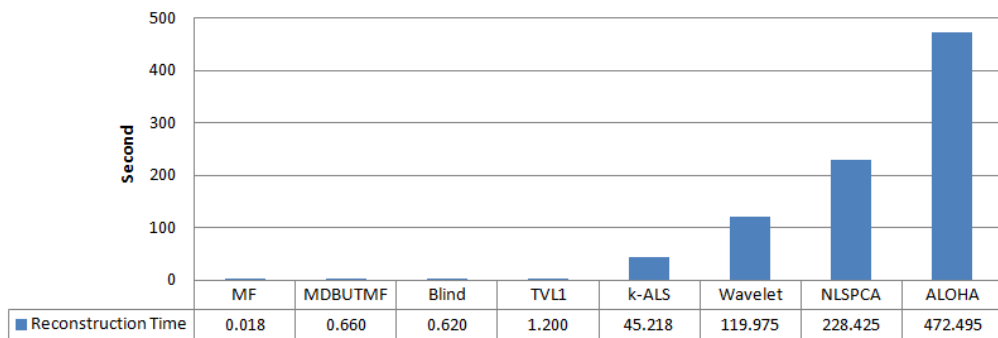
جدول ۶: پیکربندی شماره دو شبکه پیشنهادی.

Layer	BL-CNN	NR-CNN	Size	Number	Stride	Padding $n = 5$	Padding $n = 7$
۰	-	Noise detection	-	-	-	-	-
۱	Input	Input	-	-	-	-	-
۲	Convolution	Adaptive Convolution	$n \times n$	۲۰	۱	۰	۱
۳	Max pooling	Adaptive Max pooling	$2 \times 2$	-	۲	۱	۱
۴	Convolution	Convolution	$5 \times 5$	۵۰	۱	۰	۰
۵	Max pooling	Max pooling	$2 \times 2$	-	۱	۰	۰
۶	ReLU	ReLU	-	-	۱	۰	۰
۷	Convolution	Convolution	$4 \times 4$	۶۰	۱	۰	۰
۸	Max pooling	Max pooling	$2 \times 2$	-	۱	۰	۰
۹	Convolution	Convolution	$3 \times 3$	۵۰۰	۱	۰	۰
۱۰	Max pooling	Max pooling	$2 \times 2$	-	۱	۰	۰
۱۱	ReLU	ReLU	-	-	۱	۰	۰
۱۲	Fully connected	Fully connected	$1 \times 1$	۱۰	۱	۰	۰
۱۳	Loss function	Adaptive loss function	-	-	-	-	-





شکل ۱۳: مقایسه Baseline CNN با پیکربندی شماره یک و دو روش پیشنهادی ( $n=7$ ) و برای طبقه‌بندی تصاویر آغشته به نویز ضربه.



شکل ۱۴: زمان بازیابی و بهبود تصاویر آغشته به نویز ضربه توسط الگوریتم‌های مختلف [۲].

VGG-Net-Medium مقایسه گردید. در برابر نویز ضربه پیشنهاد گردید. مقایسه VGG-Net-Slow و با روش پیشنهادی نشان‌دهنده کاهش خطا در طبقه‌بندی تصاویر نویزی از طریق مقاوم‌سازی CNN است. زمان اجرای کمتر به جهت عدم نیاز به پیش‌پردازش جهت حذف نویز، از مزایای روش پیشنهادی برای طبقه‌بندی تصاویر نویزی می‌باشد.

### مراجع

[1] Z. Zhang, D. Han, J. Dezert, and Y. Yang, "A new adaptive switching median filter for impulse noise reduction with pre-detection based on evidential reasoning," *Signal Processing*, vol. 147, pp. 173-189, Jun. 2018.

[2] K. H. Jin and J. C. Ye, "Sparse and low-rank decomposition of a hankel structured matrix for impulse noise removal," *IEEE Trans. Image Process.*, vol. 27, no. 3, pp. 1448-1461, Nov. 2018.

[3] I. Turkmen, "The ANN based detector to remove random-valued impulse noise in images," *J. Vis. Commun. Image Represent.*, vol. 34, pp. 28-36, Jan. 2016.

[4] S. Liang, S. Lu, J. Chang, and C. C. T. Lin, "A novel two-stage impulse noise removal technique based on neural networks and fuzzy decision," *IEEE Trans. on Fuzzy Systems*, vol. 16, no. 4, pp. 863-873, Aug. 2008.

[5] Y. Hou, Z. Li, P. Wang, and W. Li, "Skeleton optical spectra-based action recognition using convolutional neural networks," *IEEE Trans. Circuits Syst. Video Technol.*, vol. 28, no. 3, pp. 807-811, Nov. 2018.

[6] C. Ding and D. Tao, "Trunk-branch ensemble convolutional neural networks for video-based face recognition," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 40, no. 4, pp. 1002-1014, May 2018.

[7] L. C. Chen, G. Papandreou, I. Kokkinos, K. Murphy, and A. L. Yuille, "DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 40, no. 4, pp. 834-848, Apr. 2018.

[8] G. Lin, Q. Wu, L. Qiu, and X. Huang, "Image super-resolution using a dilated convolutional neural network," *Neurocomputing*, vol. 275, pp. 1219-1230, Jan. 2018.

TVL1 [۱۸]، MDBUTMF [۱۸]، k-ALS [۳۳]، Wavelet [۳۴]، ALOHA [۲] و NLSPCA [۳۶] در شکل ۱۴ نشان داده شده است.

با توجه به شکل ۱۴، سریع‌ترین روش اصلاح مقدار پیکسل آغشته به نویز ضربه، استفاده از فیلتر میانه است [۲]. کمترین پیچیدگی زمانی برای محاسبه مقدار میانه با مرتب‌سازی سریع،  $O(n \log(n))$  است. مقایسه پیچیدگی زمانی روش پیشنهادی با مرتبه زمانی  $O(1)$  و سریع‌ترین روش حذف نویز ضربه مبتنی بر فیلتر میانه، نشان‌دهنده برتری روش پیشنهادی است.

### ۴- نتیجه‌گیری

در این مقاله رویکرد جدیدی برای طبقه‌بندی تصاویر آغشته به نویز ضربه، بدون نیاز به پیش‌پردازش و مبتنی بر شبکه عصبی کانولوشنال ارائه گردید. افزایش و کاهش ابعاد کرنل کانولوشن، بر اساس نویزی و سالم بودن پیکسل‌ها باعث بهبود دقت طبقه‌بندی می‌شود. پیکربندی روش پیشنهادی با استفاده از لایه ادغام تطبیقی، از پردازش پیکسل‌های نویزی توسط عملگر ادغام جلوگیری می‌کند. مجموعه داده‌های ILSVRC-۲۰۱۲ و MNIST برای آموزش مدل استفاده گردید. طبقه‌بندی روش پیشنهادی و VGG-Net-Slow برای تصاویر نویزی با چگالی ۱۰ تا ۵۰٪ حاکی از برتری روش پیشنهادی با خطای کمتر از ۰/۴ در طبقه‌بندی تصاویر نویزی است. لایه ادغام تطبیقی در CNN جهت مقاومت در برابر نویز، اصلاح گردید. لایه ادغام تطبیقی برای جلوگیری از پردازش مقادیر نویزی معرفی شد. تابع هزینه تطبیقی برای مقاوم‌سازی

- [28] J. Gu, et al., "Recent advances in convolutional neural networks," *Pattern Recognit.*, vol. 77, pp. 354-377, May 2018.
- [29] A. K. Samantary, P. Kanungo, and B. Mohanty, "Neighbourhood decision based impulse noise filter," *IET Image Process.*, vol. 12, no. 7, pp. 1222-1227, Jul. 2018.
- [30] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," Sept. 2014.
- [31] O. Russakovsky, et al., "ImageNet large scale visual recognition challenge," *Int. J. Comput. Vis.*, vol. 115, no. 3, pp. 211-252, Dec. 2015.
- [32] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, Nov. 1998.
- [33] Y. Wang, A. Szlam, and G. Lerman, "Robust locally linear analysis with applications to image denoising and blind inpainting," *SIAM J. Imaging Sci.*, vol. 6, no. 1, pp. 526-562, Jan. 2013.
- [34] B. Dong, H. Ji, J. Li, Z. Shen, and Y. Xu, "Wavelet frame based blind image inpainting," *Appl. Comput. Harmon. Anal.*, vol. 32, no. 2, pp. 268-279, May 2012.
- [35] M. Yan, "Restoration of images corrupted by impulse noise and mixed gaussian impulse noise using blind inpainting," *SIAM J. Imaging Sci.*, vol. 6, no. 3, pp. 1227-1245, Jan. 2013.
- [36] J. Salmon, Z. Harmany, C. A. Deledalle, and R. Willett, "Poisson noise reduction with non-local PCA," *J. Math. Imaging Vis.*, vol. 48, no. 2, pp. 279-294, Feb. 2014.
- [9] S. Yu, S. Jia, C. Xu, "Convolutional neural networks for hyperspectral image classification," *Neurocomputing*, vol. 219, pp. 88-98, Jan. 2016.
- [10] K. Audhkhasi, O. Osoba, B. Kosko, "Noise-enhanced convolutional neural networks," *Neural Networks*, vol. 78, pp. 15-23, Jun. 2016.
- [11] W. Zhang, L. Jin, E. Song, and X. Xu, "Removal of impulse noise in color images based on convolutional neural network," *Applied Soft Computing*, vol. 82, Article No. 105558, Sept. 2019.
- [12] L. Jin, W. Zhang, G. Ma, and N. Song, "Learning deep CNNs for impulse noise removal in images," *Journal of Visual Communication and Image Representation*, vol. 62, pp. 193-205, Jul. 2019.
- [13] J. Yim and K. A. Sohn, "Enhancing the performance of convolutional neural networks on quality degraded datasets," in *Int. Conf. Digit. Image Comput. Tech. Appl., DICTA'17*, 8 pp., Sydney, NSW, Australia, 29 Nov.-1 Dec. 2017.
- [14] I. F. Jafar, R. A. Alna'mneh, and K. A. Darabkh, "Efficient improvements on the BDND filtering algorithm for the removal of high-density impulse noise," *IEEE Trans. Image Process.*, vol. 22, no. 3, pp. 1223-1232, Nov. 2013.
- [15] S. Q. Yuan and Y. H. Tan, "Impulse noise removal by a global-local noise detector and adaptive median filter," *Signal Processing*, vol. 86, no. 8, pp. 2123-2128, Aug. 2006.
- [16] D. Ze-Feng, Y. Zhou-Ping, and X. You-Lun, "High probability impulse noise-removing algorithm based on mathematical morphology," *IEEE Signal Process. Lett.*, vol. 14, no. 1, pp. 31-34, Jan. 2007.
- [17] K. S. Srinivasan and D. Ebenezer, "A new fast and efficient decision-based algorithm for removal of high-density impulse noises," *IEEE Signal Process. Lett.*, vol. 14, no. 3, pp. 189-192, Mar. 2007.
- [18] S. Esakkirajan, T. Veerakumar, A. N. Subramanyam, and C. H. Premchand, "Removal of high density salt and pepper noise through modified decision based unsymmetric trimmed median filter," *IEEE Signal Process. Lett.*, vol. 18, no. 5, pp. 287-290, Mar. 2011.
- [19] G. Yu, S. Niu, and J. Ma, "A hybrid spectral gradient method for removing salt-and-pepper impulse noise," in *Proc. 4th Int. Congress on Image and Signal Processing*, pp. 765-768, Shanghai, China, 15-17 Oct. 2011.
- [20] P. Shanmugavadivu and P. S. Eliahim Jeevaraj, "Fixed-value impulse noise suppression for images using PDE based adaptive two-stage median filter," in *Proc. Int. Conf. on Computer, Communication and Electrical Technology, ICCET'11*, pp. 290-295, Tamilnadu, India, 18-19 Mar. 2011.
- [21] X. Zhang and Y. Xiong, "Impulse noise removal using directional difference based noise detector and adaptive weighted mean filter," *IEEE Signal Process. Lett.*, vol. 16, no. 4, pp. 295-298, Apr. 2009.
- [22] S. Sadeghi, A. Rezvanian, and E. Kamrani, "An efficient method for impulse noise reduction from images using fuzzy cellular automata," *AEU-Int. J. Electron. Commun.*, vol. 66, no. 9, pp. 772-779, Sept. 2012.
- [23] D. Androustos, K. N. Plataniotis, and A. N. Venetsanopoulos, "Novel vector-based approach to color image retrieval using a vector angular-based distance measure," *Comput. Vis. Image Underst.*, vol. 75, no. 1, pp. 46-58, Jul. 1999.
- [24] T. Toffoli and N. Margolus, *Cellular Automata Machines: A New Environment for Modeling*, 1987.
- [25] S. S. Wang and C. H. Wu, "A new impulse detection and filtering method for removal of wide range impulse noises," *Pattern Recognit.*, vol. 42, no. 9, pp. 2194-2202, Sep. 2009.
- [26] P. Y. Chen and C. Y. Lien, "An efficient edge-preserving algorithm for removal of salt-and-pepper noise," *IEEE Signal Process. Lett.*, vol. 15, pp. 833-836, Dec. 2008.
- [27] C. Szegedy, et al., "Going deeper with convolutions," in *Proc. of the IEEE Computer Society Conf. on Computer Vision and Pattern Recognition, CVPR'15*, 9 pp., Boston, MA, USA, 7-12 Jun. 2015.

**محمد مومنی** تحصیلات خود را در مقطع کارشناسی ارشد در سال ۱۳۹۲ در رشته مهندسی کامپیوتر از دانشگاه محقق اردبیلی به پایان رساند و هم‌اکنون به عنوان دانشجوی دکتری در رشته مهندسی کامپیوتر در دانشگاه یزد فعالیت دارد. زمینه‌های مورد علاقه نام‌برده یادگیری عمیق، یادگیری ماشین و پردازش تصویر می‌باشد.

**مهدی آقا صرام** تحصیلات خود را در مقطع دکتری از دانشگاه ولز بریتانیا در سال ۱۳۵۸ به پایان رساند. ایشان عضو مؤسسه کنترل و ابزار دقیق استرالیا و همچنین عضو کمیته راهبری استانداردهای فناوری اطلاعات استرالیا بود. نام‌برده در سال‌های ۱۳۷۹ تا ۱۳۸۲ به عنوان مدرس در دانشگاه‌های استرالیا مشغول به تدریس بود و هم‌اکنون دانشیار بازنشسته دانشکده مهندسی کامپیوتر دانشگاه یزد می‌باشد. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: یادگیری ماشین، داده کاوی و کدگذاری شبکه.

**علی محمد لطیف** در سال ۱۳۷۲ مدرک کارشناسی مهندسی برق خود را از دانشگاه صنعتی اصفهان و در سال ۱۳۷۵ مدرک کارشناسی ارشد مهندسی برق خود را از دانشگاه امیرکبیر دریافت نمود. در سال ۱۳۸۰ نام‌برده به عضویت هیأت علمی گروه مهندسی برق دانشگاه یزد در آمد و پس از آن به دوره دکترای مهندسی کامپیوتر در دانشگاه اصفهان وارد گردید و در سال ۱۳۹۰ موفق به اخذ درجه دکترا در مهندسی کامپیوتر از دانشگاه مذکور گردید. دکتر لطیف از سال ۱۳۹۰ به عضویت هیأت علمی دانشکده مهندسی کامپیوتر دانشگاه یزد در آمد و اینک نیز دانشیار این دانشکده می‌باشد. زمینه‌های علمی مورد علاقه ایشان متنوع بوده و شامل موضوعاتی مانند پردازش تصویر، یادگیری ماشین و یادگیری عمیق می‌باشد.

**راضیه شیخ‌پور** تحصیلات خود را در مقطع دکتری مهندسی کامپیوتر در سال ۱۳۹۶ از دانشگاه یزد به پایان رساند و سپس به عنوان پژوهشگر پسا دکتری در دانشگاه یزد مشغول به فعالیت بود. نام‌برده هم‌اکنون عضو هیأت علمی و استادیار گروه مهندسی کامپیوتر دانشگاه اردکان می‌باشد. زمینه‌های تحقیقاتی مورد علاقه ایشان یادگیری ماشین، داده کاوی، انتخاب ویژگی و یادگیری نیمه‌نظارتی می‌باشد.