

## حذف نویزهای نقطه‌ای تصاویر فازی با استفاده از شبکه عصبی کانولوشنی

محمد یعقوبی<sup>۱</sup>، بابک زارع<sup>۱</sup>، محمدرضا جعفر فرد<sup>۱</sup>

<sup>۱</sup>\*گروه فیزیک، دانشکده فیزیک، دانشگاه علم و صنعت ایران، تهران

### چکیده

تصاویر فازی حاصل از هولوگرام‌ها و الگوهای تداخلی در میکروسکوپ‌های فاز کمی معمولاً با مشکلاتی همچون اعوجاج، پیچش فاز و نویزهای فازی همراه هستند. با وجود تلاش‌های گسترده در دهه‌های اخیر و ارائه‌ی روش‌های متنوع برای حذف نویز، این چالش‌ها همچنان به‌طور کامل برطرف نشده‌اند. استفاده از فیلترهای کلاسیک کاهش نویز اغلب موجب آسیب به جزئیات تصویر، افت کیفیت و ضعف در تشخیص مرزها و لبه‌ها شده و در نتیجه اطلاعات مفید تصویر از بین می‌رود. یکی از رویکردهای نوین در این زمینه، بهره‌گیری از الگوریتم‌های یادگیری ماشین است. نتایج حاصل از معیارهای ارزیابی کیفیت تصویر نشان می‌دهند که شبکه‌های عصبی کانولوشنی، نسبت به روش‌های مرسوم حذف نویز تصاویر فازی، عملکرد برتری دارند. در این روش، داده‌های آموزشی به شبکه ارائه می‌شوند تا پس از چندین مرحله آموزش، شبکه توانایی کاهش نویز تصویر را با دقت بالا به دست آورد.

**واژگان کلیدی:** نویز نقطه‌ای، یادگیری ماشین، شبکه عصبی کانولوشنی.

### اطلاعات مقاله

تاریخ دریافت: ۱۴۰۴/۰۹/۲۶

تاریخ پذیرش: ۱۴۰۴/۱۱/۲۰

تاریخ چاپ: ۱۴۰۴/۱۲/۲

شاپای چاپی: 2588-493x

شاپای الکترونیکی: 2588-4921

\* نویسنده مسئول

mrjafarfard@iust.ac.ir

bzarer@iust.ac.ir



### مقدمه

با وجود تحقیقات گسترده در دهه‌های اخیر و ارائه‌ی روش‌های متنوع برای حذف نویز از تصاویر میکروسکوپ‌های فازی، مشکل حذف نویزها از این گونه تصاویر، هنوز به‌طور کامل حل نشده است. بسیاری از روش‌های موجود اگرچه تا حدی نویز را کاهش می‌دهند، اما در برخی موارد موجب افت کیفیت، کاهش وضوح سیگنال و در نتیجه از بین رفتن اطلاعات مفید تصویر می‌شوند. از جمله‌ی این روش‌ها می‌توان به

توابع از پیش تعریف شده در زبان‌های برنامه‌نویسی مختلف نظیر پایتون و نرم‌افزار متلب اشاره کرد؛ مانند فیلترهای گاوسی<sup>۱</sup>، میانگین‌گیری، میانه<sup>۲</sup>، فیلترهای خطی<sup>۳</sup>، متعادل ترکیبی<sup>۴</sup>، دو طرفه<sup>۵</sup> و میانگین غیر محلی<sup>۶</sup>. با این حال، این دسته از توابع محدودیت‌های یادشده را دارند و همین امر موجب شده است که محققان تلاش‌های گسترده‌ای برای یافتن روش‌هایی کارآمدتر در شرایط مختلف انجام دهند.

در سال‌های اخیر، یادگیری عمیق، به دلیل معرفی معماری‌های نوین شبکه و همچنین توسعه سخت‌افزارهای محاسباتی پرسرعت، در

<sup>۴</sup> Combined Balanced

<sup>۵</sup> Bilateral

<sup>۶</sup> Non local mean

<sup>۱</sup> Gaussian

<sup>۲</sup> Median

<sup>۳</sup> Linear

حوزه های گوناگونی مانند افزایش رزولوشن بیشینه<sup>۷</sup> [۱]–[۴]،  
توموگرافی کامپیوتری<sup>۸</sup> [۵]، تصویربرداری تشدید مغناطیسی<sup>۹</sup> [۶]،  
توموگرافی فتوآکوستیک<sup>۱۰</sup> [۷] و هولوگرافی<sup>۱۱</sup> [۸]–[۱۳] به کار گرفته  
شده است و نتایج چشمگیری نیز در کاهش نویز تصاویر ارائه داده است.  
برای نمونه، یانگ<sup>۱۲</sup> و یان<sup>۱۳</sup>، یک روش نوین مبتنی بر شبکه مولد  
متخاصم<sup>۱۴</sup> (GAN) با استفاده از فاصله Wasserstein و شباهت  
ادراکی پیشنهاد کردند [۱۴]. فاصله Wasserstein که ریشه در  
نظریه جابه جایی بهینه دارد، به بهبود عملکرد GAN کمک می کند.  
این روش نه تنها سطح نویز تصویر را کاهش می دهد، بلکه اطلاعات  
حیاتی موجود در داده را نیز حفظ می نماید. از سوی دیگر، سینگ<sup>۱۵</sup> و  
شانکار<sup>۱۶</sup> با ترکیب شبکه ی عصبی کانولوشنال<sup>۱۷</sup> (CNN) و انتشار  
ناهمسانگرد<sup>۱۸</sup> (AD)، یک روش ترکیبی چند سطحی برای حذف نویز  
تصاویر دیجیتال ارائه کردند [۱۵]. در این روش، ابتدا CNN بر روی  
تصاویر نویزدار اعمال می شود و نتیجه ی حاصل برای حفظ لبه ها و مرز  
اشیاء به الگوریتم AD داده می شود. این ترکیب موجب حذف مؤثر نویز  
و در عین حال حفظ جزئیات ظریف تصویر می گردد. روش دیگری که  
توسط لفکیمیاتیس<sup>۱۹</sup> معرفی شده است، با هدف مقابله با مشکل مقیاس  
خاکستری<sup>۲۰</sup> و حذف نویز تصاویر رنگی طراحی گردیده [۱۶]. ساختار  
شبکه ی پیشنهادی شامل دو بخش است: شبکه ی اول مبتنی بر لایه های  
کانولوشنی و شبکه ی دوم متکی بر فیلترهای غیرمحلی<sup>۲۱</sup>. ویژگی  
برجسته ی این روش در مقایسه با بسیاری از مدل های موجود آن است  
که نیاز به آموزش مجدد برای هر سطح نویز ندارد و می تواند طیف  
گسترده ای از شرایط نویزی را با استفاده از مجموعه ای از پارامترهای

آموخته شده پوشش دهد. علاوه بر این، ژانگ<sup>۲۲</sup> و وانگمنگ<sup>۲۳</sup> مدلی  
دیگر از CNN را معرفی کردند که در آن از یادگیری باقیمانده<sup>۲۴</sup> و  
نرمال سازی دسته ای<sup>۲۵</sup> برای افزایش سرعت آموزش و بهبود عملکرد  
حذف نویز بهره گرفته می شود [۱۷]. این مدل که با نام شبکه ی عصبی  
کانولوشنال حذف نویز<sup>۲۶</sup> پیش رونده (DnCNN) شناخته می شود،  
قادر به حذف نویز گاوسی حتی با سطح نویز ناشناخته است. ادغام  
یادگیری باقیمانده و نرمال سازی دسته ای، نقش بسزایی در بهبود کارایی  
این مدل ایفا می کند.

در پژوهش حاضر، یک رویکرد مبتنی بر یادگیری ماشین با استفاده از  
شبکه ی عصبی کانولوشنی<sup>۲۸</sup> (CNN) برای حذف نویزهای پیسه ای  
تصاویر فازی بازسازی شده از هولوگرام ارائه شده است. در این روش،  
ابتدا داده های آموزشی در اختیار شبکه قرار می گیرند و شبکه طی چند  
مرحله آموزش، الگوی مناسبی برای مسئله ی مورد نظر فرا می گیرد.  
سپس، بر اساس این یادگیری، قادر به کاهش نویز تصاویر خواهد بود.  
نتایج بدست آمده نشان می دهد که روش پیشنهادی در مقایسه با توابع  
رایج حذف نویز نظیر فیلترهای گاوسی، میانگین گیری و میانه عملکرد  
بهتری داشته و خطای کمتری در حذف نویزهای فازی ایجاد می کند.  
ساختار مقاله به شرح زیر است: در بخش ۱، معیارهای ارزیابی کیفیت  
تصاویر معرفی می شوند. بخش ۲ به تشریح شبکه ی عصبی مورد استفاده  
و بخش ۳ به معرفی مجموعه داده اختصاص دارد. نتایج حاصل در بخش  
۴ ارائه می شوند و نهایتاً در بخش ۵، جمع بندی و نتیجه گیری بیان  
خواهد شد.

## ۱- معیارهای ارزیابی کیفیت تصاویر

<sup>18</sup> Anisotropic Diffusion (AD)

<sup>19</sup> Lefkimmiatis

<sup>20</sup> Grayscale

<sup>21</sup> Non-local filter

<sup>22</sup> Kai Zhang

<sup>23</sup> Wangmeng

<sup>24</sup> Residual learning

<sup>25</sup> Batch normalization

<sup>26</sup> Denoising convolutional neural networks (DnCNN)

<sup>27</sup> Feed-forward

<sup>28</sup> Convulsive neural networks (CNN)

<sup>7</sup> Super resolution

<sup>8</sup> Computed tomography (CT)

<sup>9</sup> Magnetic resonance imaging

<sup>10</sup> Photoacoustic tomography

<sup>11</sup> Holography

<sup>12</sup> Yang

<sup>13</sup> Yan

<sup>14</sup> Generative adversarial network (GAN)

<sup>15</sup> Singh

<sup>16</sup> Shankar

<sup>17</sup> Convolutional neural Network (CNN)

هستند. عبارت  $[X'(x, y) - X(x, y)]^2$  بیانگر مربع خطا در هر پیکسل است.

بیشینه نسبت سیگنال به نویز یک معیار لگاریتمی است که نسبت بین بیشینه توان سیگنال و توان نویز را بیان می‌کند و برحسب دسی بل<sup>۳۲</sup> (Db) محاسبه می‌شود. هرچه مقدار PSNR بزرگ‌تر باشد، تصویر بازسازی شده کیفیت بالاتری داشته و به تصویر اصلی نزدیک‌تر است. در مقابل، مقادیر پایین PSNR بیانگر افت کیفیت و از دست رفتن اطلاعات است. رابطه‌ی محاسبه‌ی PSNR به صورت زیر است

$$PSNR = 20 \log_{10} \left( \frac{MAX}{\sqrt{MSE}} \right) \quad (2)$$

در این رابطه، MAX بیانگر حداکثر بیشترین مقدار ممکن برای پیکسل است. به عنوان مثال، در تصاویر ۸ بیتی این مقدار برابر با ۲۵۵ است.

ضریب شباهت ساختاری سیگنال بر اساس سه مؤلفه‌ی اصلی روشنایی، کنتراست<sup>۳۳</sup> و ساختار طراحی شده تا با سامانه بینایی انسان تطابق بیشتری داشته باشد. این معیار عددی بین صفر تا یک است که هرچه به یک نزدیک‌تر باشد، شباهت تصویر بازسازی شده با تصویر اصلی بیشتر خواهد بود. رابطه‌ی عمومی SSIM به صورت زیر تعریف می‌شود؛


$$SSIM(X', X) = \frac{(2\mu_x' \mu_x + c_1)(2\sigma_x' \sigma_x + c_2)}{(\mu_x'^2 + \mu_x^2 + c_1)(\sigma_x'^2 + \sigma_x^2 + c_2)} \quad (3)$$

که در آن  $\mu_x$  و  $\mu_x'$  به ترتیب میانگین‌های موضعی  $X$  و  $X'$ ،  $\sigma_x^2$  و  $\sigma_x'^2$  واریانس تصاویر و  $\sigma_{xx'}$  کوواریانس تصاویر است. ضرایب  $C_1$  و  $C_2$  ضرایب ثابتی هستند که برای جلوگیری از صفر شدن مخرج استفاده می‌شوند.

## ۲- ساختار شبکه‌ی عصبی

شبکه‌های CNN امروزه به عنوان یکی از رایج‌ترین روش‌های یادگیری عمیق در حل مسائل یادگیری ماشین شناخته می‌شوند و

ارزیابی کیفیت تصویر و تعیین میزان افت آن از موضوعات اساسی در بسیاری از الگوریتم‌های پردازش تصویر به شمار می‌رود. برای سنجش عملکرد این الگوریتم‌ها، معیارها و شاخص‌های متعددی معرفی شده‌اند که در ادامه به مهم‌ترین آن‌ها پرداخته می‌شود. هرچند چشم انسان قادر است به صورت کیفی عملکرد این روش‌ها را با یکدیگر مقایسه کند، اما این مقایسه همواره دقیق نبوده و می‌تواند با خطا همراه باشد و به همین دلیل، استفاده از معیارهای کمی برای ارزیابی و مقایسه عددی روش‌ها ضروری است تا دقت هر الگوریتم مشخص گردد. از جمله پرکاربردترین



شکل ۱ ساختار مفهومی از شبکه‌ی CNN

معیارهای ارزیابی کیفیت تصاویر می‌توان به خطای میانگین مربعات<sup>۲۹</sup> (MSE) [۱۸]، بیشینه نسبت سیگنال به نویز<sup>۳۰</sup> (PSNR) [۱۹] و ضریب شباهت ساختاری سیگنال<sup>۳۱</sup> (SSIM) [۲۰] اشاره کرد. خطای میانگین مربعات معیاری برای برآورد میزان خطاست که اختلاف بین مقادیر اصلی و مقادیر تخمینی را اندازه‌گیری می‌کند. این شاخص همواره نامنفی است و هرچه مقدار آن به صفر نزدیک‌تر باشد، نشان دهنده‌ی خطای کمتر و در نتیجه کیفیت بهتر تصویر است. رابطه‌ی محاسبه‌ی MSE به صورت زیر تعریف می‌شود؛

$$MSE = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} [X'(x, y) - X(x, y)]^2 \quad (1)$$

که در آن،  $M$  و  $N$  ابعاد تصویر،  $X(x, y)$  مقدار پیکسل تصویر مرجع، و  $X'(x, y)$  مقدار پیکسل تصویر بازسازی شده (پس از حذف نویز)

<sup>31</sup> Structural similarity index measure (SSIM)

<sup>32</sup> Decibel (Db)

<sup>33</sup> Contrast

<sup>29</sup> Mean squared error (MSE)

<sup>30</sup> Peak signal-to-noise ratio (PSNR)

### ۳- مجموعه داده ها

با توجه به اینکه تصاویر میکروسکوپ های فازی بیشتر سلولها و یا میکروذرات تقریباً کروی هستند از یک تابع گاوسی برای مدل سازی تصاویر استفاده شده است. داده های مورد استفاده در این پژوهش شامل دو مجموعه ی متفاوت از تصاویر با ابعاد  $128 \times 128$  پیکسل هستند. داده های نوع اول، شامل یک تابع گاوسی  $(A \exp[-\frac{(x-x_0)^2+(y-y_0)^2}{2\sigma^2}])$  با زمینه ی سفید است که مرکز آن  $(x_0, y_0)$  به صورت تصادفی انتخاب شده است. با مقدار بیشینه فاز و با  $\sigma$  پهنای تابع را می توان کنترل کرد. داده های نوع دوم شامل یک تصویر با زمینه ی سفید که درون آن یک بیضی سیاه قرار دارد. این بیضی ها با استفاده از رابطه ی  $\text{sgn}[(x-x_0)^2 + (a/b)^2(y-y_0)^2 - a]$  رسم شده است که در آن  $a$  و  $b$  محورهای بیضی هستند. مرکز این بیضی  $(x_0, y_0)$  نیز بصورت تصادفی تعیین می شود. انتخاب این دو نوع داده موجب تنوع ویژگی های آموزشی شده و توانایی شبکه در یادگیری و پیش بینی داده های جدید را بهبود می بخشد. داده های تولید شده به دو بخش آموزشی و اعتبارسنجی تقسیم می شوند. داده های آموزشی برای یادگیری و به روزرسانی پارامترهای شبکه به کار می روند، در حالی که داده های اعتبارسنجی جهت ارزیابی عملکرد شبکه ی طراحی شده مورد استفاده قرار می گیرند. سهم داده های اعتبارسنجی معادل ۱۰٪ از کل مجموعه داده های آموزشی در نظر گرفته شده است.

به طور گسترده در پردازش تصویر بکار گرفته شده اند. در این پژوهش نیز برای حذف نویز، از تصاویر فازی بازسازی شده از شبکه های CNN استفاده شده است. از نظر ساختاری CNN مشابه شبکه های پرسپترون چندلایه<sup>۳۴</sup> (MLP) است، با این تفاوت که در ابتدای شبکه، چند لایه ی کانولوشن قرار دارند که امکان استخراج ویژگی های خاص از تصویر را فراهم می کنند. به طور کلی، یک CNN از سه بخش اصلی تشکیل می شود: لایه ی کانولوشن، لایه ی تجمیع<sup>۳۵</sup> و لایه ی طبقه بندی. لایه ی کانولوشن شامل مجموعه ای از فیلترها است که هر کدام به صورت ماتریسی از مقادیر عددی تعریف می شوند و با تصویر ورودی کانولوشن داده می شوند تا ویژگی های مختلف استخراج شوند. لایه ی تجمیع ابعاد ماتریس های بدست آمده از لایه ی کانولوشن را کاهش می دهد و در نتیجه پیچیدگی محاسباتی را کاهش می بخشد. لایه ی طبقه بندی به عنوان لایه ی خروجی عمل کرده و مشابه شبکه ی پرسپترون چندلایه، مسئول تصمیم گیری نهایی است. شبکه ی طراحی شده شامل دو لایه ی کانولوشنی و دو لایه ی تجمیع (شکل ۱) است. در لایه های کانولوشنی، از ۳۲ فیلتر با ابعاد  $5 \times 5$  استفاده شده و توابع فعال ساز  $\text{ReLU}^{36}$  و Sigmoid به کار گرفته شده اند. از آنجا که افزایش بیش از حد پارامترهای آموزشی (مانند تعداد لایه ها، تعداد فیلترها یا حجم داده های آموزشی) می تواند منجر به بیش برآزش<sup>۳۷</sup> شود، شبکه ی CNN در صورت آموزش بیش از حد توانایی تعمیم دهی به داده های جدید را از دست داده و هنگام اعمال بر تصاویر نویزدار جدید، با خطای قابل توجهی همراه بود. در الگوریتم پیشنهادی، برای آموزش شبکه از دو تابع خطا استفاده شده است: تابع MSE و تابع آنتروپی متقاطع دوتایی<sup>۳۸</sup>. انتخاب تابع خطا بر اساس نوع داده ی تولید شده انجام می شود. همچنین، برای بهینه سازی شبکه از الگوریتم آدام<sup>۳۹</sup> استفاده شده است.

<sup>37</sup> Overfitting

<sup>38</sup> Binary cross entropy

<sup>39</sup> Adam

<sup>34</sup> Multilayer Perceptron (MLP)

<sup>35</sup> Pooling layer

<sup>36</sup> Rectified Linear Unit

## ۴- ارائه نتایج

از آنجا که عملکرد شبکه‌ی CNN باید در شرایط مختلف آزمایش شود تا صحت فرآیند حذف نویز تأیید گردد، آزمون‌های متعددی برای ارزیابی شبکه در نظر گرفته شد و این فرآیند به دفعات تکرار گردید. برای بررسی تأثیر چگالی نویز، ابتدا شبکه تعداد ۲۰۰۰۰ داده تولید کرد و به آنها نویز نقطه‌ای با شدت‌های متفاوت افزود، به گونه‌ای که با افزایش پارامتر چگالی، تعداد نویزهای موجود در هر پیکسل بیشتر شد. سپس تصاویر نویزی با استفاده از یک فیلتر  $5 \times 5$  پردازش شده و فرآیند حذف نویز انجام گردید. همچنین برای بررسی تأثیر تعداد داده‌های آموزشی، مجموعه داده‌هایی با حجم‌های ۱۵۰۰۰، ۲۰۰۰۰ و ۲۳۰۰۰ به‌طور مجزا تولید و استفاده شدند. این تنوع در داده‌ها علاوه بر افزایش قدرت تعمیم شبکه، فرآیند حذف نویز را به شرایط واقعی نزدیکتر کرد. در نهایت، جهت اطمینان از عملکرد شبکه‌ی CNN، مقادیر مختلفی برای نرخ یادگیری در نظر گرفته شد. نتایج هر بخش در ادامه آمده است.

## ۴-۱ تأثیر چگالی نویز بر داده‌ها

پارامتر چگالی نویز با مقادیر نویز ۱، ۲ و ۵ برای داده‌های نوع اول و دوم مورد بررسی قرار گرفت. نتایج مربوط به این بخش در شکل ۲ و شکل ۳ ارائه شده‌اند.

## ۴-۲ تغییر تعداد داده‌های آموزشی




برای ارزیابی تأثیر حجم داده‌ها، سه مجموعه‌ی آموزشی شامل ۱۵۰۰۰، ۲۰۰۰۰ و ۲۳۰۰۰ تصویر مورد استفاده قرار گرفتند. در هر مرحله، ۱۰٪ از داده‌ها به‌عنوان داده‌های اعتبارسنجی در نظر گرفته شد. نتایج در شکل ۴ و شکل ۵ نشان داده شده‌اند.

## ۴-۳ تغییر نرخ یادگیری




در این بخش، مقادیر نرخ یادگیری به ترتیب ۰/۰۰۱، ۰/۰۰۱ و ۰/۰۰۱ در نظر گرفته شدند. نتایج حاصل در شکل ۶ و شکل ۷ ارائه شده‌اند. بر اساس نتایج جدول و با در نظر گرفتن شرایط یکسان برای پارامترهای دیگر (تعداد داده‌های آموزشی، داده‌های اعتبارسنجی، ابعاد فیلتر و چگالی نویز)، مشاهده می‌شود که مقادیر MSE، PSNR و SSIM، در تمام مراحل تقریباً مشابه‌اند. با این حال، نرخ‌های یادگیری ۰/۰۰۱ و ۰/۰۰۱ تصاویری با وضوح بالاتر نسبت به نرخ یادگیری ۰/۰۰۱ ایجاد کردند. بنابراین، این دو مقدار می‌توانند به عنوان نرخ‌های یادگیری بهینه برای شبکه‌ی CNN در نظر گرفته شوند.

جدول ۱: مقایسه معیارهای ارزیابی تصاویر مربوط به شکل ۲ و شکل ۳

| داده‌های نوع اول      |  |  | داده‌های نوع دوم     |         |         |                       |
|-----------------------|--|--|----------------------|---------|---------|-----------------------|
| تعداد داده‌ها         |  |  | ۲۰۰۰۰                |         |         | تعداد داده‌ها         |
| تعداد مراحل آموزش     |  |  | ۱۰۰                  |         |         | تعداد مراحل آموزش     |
| تعداد داده‌های آموزشی |  |  | ۲۰۰۰۰                |         |         | تعداد داده‌های آموزشی |
| ابعاد فیلتر           |  |  | ۵*۵                  |         |         | ابعاد فیلتر           |
| تابع بهینه ساز        |  |  | Adam                 |         |         | تابع بهینه ساز        |
| تابع خطا              |  |  | Binary cross entropy |         |         | تابع خطا              |
| پارامتر نویز          |  |  | ۵                    | ۲       | ۱       | پارامتر نویز          |
| MSE                   |  |  | ۸/۳۵۳۱               | ۱/۳۳۰۲  | ۰/۳۳۱۷  | MSE                   |
| PSNR                  |  |  | ۳۸/۹۱۲۲              | ۴۶/۸۹۱۳ | ۵۲/۹۲۳۲ | PSNR                  |
| SSIM                  |  |  | ۰/۸۴۵۱               | ۰/۹۷۱۷  | ۰/۹۹۲۷  | SSIM                  |



شکل ۲ نمونه‌ایی از داده‌های نوع اول همراه با نویز و نسخه رفع نویز شده، به‌همراه مقایسه‌ی برش عرضی داده‌ها و خطای حاصل از فرآیند حذف نویز. نتایج از بالا به پایین به‌ترتیب مربوط به چگالی‌های نویز ۱، ۲ و ۵ هستند.



شکل ۳ نمونه‌ایی از داده‌های نوع دوم همراه با نویز و نسخه‌ی رفع نویز شده، همراه با مقایسه‌ی برش عرضی داده‌ها و خطای حاصل از فرآیند حذف نویز. نتایج از بالا به پایین به‌ترتیب مربوط به چگالی‌های نویز ۱، ۲ و ۵ هستند.


## ۴-۴ مقایسه فیلترهای حذف نویز و روش یادگیری

## ماشین


همان‌طور که در بخش ۱ اشاره شد، فرآیند حذف نویز می‌تواند با استفاده از فیلترهای مختلف نیز انجام گیرد. از رایج‌ترین فیلترهای حذف نویز می‌توان به MEDIAN, GAUSSIAN و AVERAGE اشاره کرد. مقایسه‌ی نتایج حاصل از این فیلترها با روش یادگیری ماشین در شکل ۹ و شکل ۹ ارائه شده است. در این بخش، برای ارزیابی عملکرد فیلترها، داده‌های آزمایشی با کمترین سطح نویز ممکن در نظر گرفته شدند تا کارایی فیلترها در شرایط نویزی حداقلی بررسی شود. در حالی که روش یادگیری ماشین در بخش‌های قبل حتی در شرایط نویز با بیشترین چگالی نیز بررسی شده و عملکرد موفقیت‌آمیز آن به‌طور کامل مشهود بود. مطابق نتایج جدول ۴ و شکل‌های ۸ و ۹، معیارهای PSNR و SSIM نشان می‌دهند که روش یادگیری ماشین نسبت به فیلترهای کلاسیک برتری قابل توجهی دارد و از دقت بسیار بالاتری برخوردار است.

## ۵- بحث و نتیجه‌گیری

در این پژوهش، از شبکه‌های CNN برای کاهش نویز تصاویر استفاده شد. نتایج نشان داد که با تغییر پارامترهایی نظیر چگالی نویز، تعداد داده‌های آموزشی و نرخ یادگیری، شبکه‌ی طراحی شده قادر است به‌طور مؤثر، نویز تصاویر را کاهش دهد. در بخش پایانی، عملکرد شبکه با چند فیلتر رایج حذف نویز مقایسه شد. نتایج نشان داد که روش مبتنی بر یادگیری ماشین، بدون آسیب رساندن به جزئیات تصویر، توانایی بالاتری در حذف نویز داشته و می‌تواند جایگزین مناسبی برای روش‌های کلاسیک باشد. علاوه بر این، با توسعه و گسترش شبکه‌های عصبی و بهره‌گیری از مفاهیم یادگیری عمیق، می‌توان ساختارهای پیچیده‌تری از CNN طراحی کرد و آن‌ها را در حوزه‌های متنوعی نظیر تصویربرداری پزشکی، میکروسکوپی، بیولوژیکی، نظامی و ماهواره‌ای به کار گرفت. این امر می‌تواند تحولی چشمگیر در کیفیت پردازش و تحلیل تصاویر ایجاد کند.




شکل ۴ نمونه‌ای از داده‌های نوع اول همراه با نویز و نسخه‌ی رفع نویز شده، همراه با مقایسه‌ی برش عرضی داده‌ها و خطای حاصل از فرآیند حذف نویز. نتایج از بالا به پایین به ترتیب مربوط به تعداد داده‌های آموزشی ۱۵۰۰۰، ۲۰۰۰۰ و ۲۳۰۰۰ هستند.




شکل ۵ نمونه‌ای از داده‌های نوع دوم همراه با نویز و نسخه‌ی رفع نویز شده، همراه با مقایسه‌ی برش عرضی و خطای حاصل از فرآیند حذف نویز. نتایج از بالا به پایین به ترتیب مربوط به تعداد داده‌های آموزشی ۱۵۰۰۰، ۲۰۰۰۰ و ۲۳۰۰۰ هستند.

جدول ۲: مقایسه معیارهای ارزیابی تصاویر مربوط به شکل ۴ و شکل ۵

| داده‌های نوع اول     |         |         | داده‌های نوع دوم |         |         |                       |
|----------------------|---------|---------|------------------|---------|---------|-----------------------|
| ۲                    |         |         | ۲                |         |         | پارامتر نویز          |
| ۱۰۰                  |         |         | ۱۰۰              |         |         | تعداد مراحل آموزش     |
| ۵*۵                  |         |         | ۵*۵              |         |         | ابعاد فیلتر           |
| Adam                 |         |         | Adam             |         |         | تابع بهینه ساز        |
| Binary cross entropy |         |         | MSE              |         |         | تابع خطا              |
| ۱۵۰۰۰                | ۲۰۰۰۰   | ۲۳۰۰۰   | ۱۵۰۰۰            | ۲۰۰۰۰   | ۲۳۰۰۰   | تعداد داده‌های آموزشی |
| ۱۵۰۰                 | ۲۰۰۰    | ۲۳۰۰    | ۱۵۰۰             | ۲۰۰۰    | ۲۳۰۰    | تعداد داده‌های تست    |
| ۱/۳۳۷۵               | ۱/۳۱۷۷  | ۱/۳۳۳۵  | ۱/۴۶۵۷           | ۱/۴۷۱۶  | ۱/۴۵۵۴  | MSE                   |
| ۴۶/۸۶۷۷              | ۴۶/۹۳۲۴ | ۴۶/۸۸۰۸ | ۴۶/۴۷۰۲          | ۴۶/۴۵۲۸ | ۴۶/۵۰۰۶ | PSNR                  |
| ۰/۹۷۱۴               | ۰/۹۷۱۹  | ۰/۹۷۱۷  | ۰/۹۵۵۷           | ۰/۹۵۴۰  | ۰/۹۵۵۳  | SSIM                  |




شکل ۶ نمونه‌ای از داده‌های نوع اول همراه با نویز و نسخه‌ی رفع نویز شده، همراه با مقایسه‌ی برش عرضی داده‌ها و خطای حاصل از فرآیند حذف نویز. نتایج از بالا به پایین به ترتیب مربوط به نرخ‌های یادگیری ۰/۰۰۱، ۰/۰۰۱ و ۰/۰۰۱ هستند.




شکل ۷ نمونه‌ای از داده‌های نوع دوم همراه با نویز و نسخه‌ی رفع نویز شده، همراه با مقایسه‌ی برش عرضی داده‌ها و خطای حاصل از فرآیند حذف نویز. نتایج از بالا به پایین به ترتیب مربوط به نرخ‌های یادگیری ۰/۰۰۱، ۰/۰۰۱ و ۰/۰۰۱ هستند.

جدول ۳: مقایسه معیارهای ارزیابی تصاویر مربوط به شکل ۶ و شکل ۷

| داده های نوع دوم |         |         | داده های نوع اول     |         |        | پارامتر نویز          |
|------------------|---------|---------|----------------------|---------|--------|-----------------------|
| ۲                |         |         | ۲                    |         |        | تعداد مراحل آموزش     |
| ۱۰۰              |         |         | ۱۰۰                  |         |        | تعداد داده های آموزشی |
| ۲۰۰۰             |         |         | ۲۰۰۰                 |         |        | ابعاد فیلتر           |
| ۵*۵              |         |         | ۵*۵                  |         |        | تابع بهینه ساز        |
| Adam             |         |         | Adam                 |         |        | تابع خطا              |
| MSE              |         |         | Binary cross entropy |         |        | نرخ یادگیری           |
| ۰/۰۰۰۱           | ۰/۰۰۱   | ۰/۰۱    | ۰/۰۰۰۱               | ۰/۰۰۱   | ۰/۰۱   | MSE                   |
| ۱/۴۴۷۵           | ۱/۴۷۹۵  | ۱/۴۱۵۵  | ۱/۳۳۰۹               | ۱/۳۲۴۳  | ۱/۳۲۷۴ | PSNR                  |
| ۴۶/۵۲۴۳          | ۴۶/۴۲۹۴ | ۴۶/۶۲۱۶ | ۴۶/۸۸۹۱              | ۴۶/۹۱۰۶ | ۴۶/۹۰  | SSIM                  |
| ۰/۹۵۷۸           | ۰/۹۵۶۰  | ۰/۹۶۳۴  | ۰/۹۷۱۹               | ۰/۹۷۱۹  | ۰/۹۷۲۱ |                       |



شکل ۹ (الف) داده ی نوع اول بدون نویز و (ب) داده ی نویزدار. تصاویر (ج) تا (و)، داده هایی را نشان می دهند که نویز آنها به ترتیب با استفاده از فیلترهای AVERAGE، MEDIAN، GAUSSIAN و شبکه کانولوشنی حذف شده است.



شکل ۱۰ (الف) داده ی نوع دوم بدون نویز و (ب) داده ی نویزدار. تصاویر (ج) تا (و) داده هایی را نشان می دهند که نویز آنها به ترتیب با استفاده از فیلترهای AVERAGE، MEDIAN، GAUSSIAN و شبکه کانولوشنی حذف شده است.

جدول ۴: مقایسه معیارهای PSNR و SSIM برای فیلترهای AVERAGE، MEDIAN و GAUSSIAN در متلب و روش یادگیری ماشین (شبکه کانولوشنی)

| داده های شکل ۹ |       | داده های شکل ۹ |       | فیلتر             |
|----------------|-------|----------------|-------|-------------------|
| SSIM           | PSNR  | SSIM           | PSNR  |                   |
| ۰/۴۵           | ۲۴/۴۸ | ۰/۳۰           | ۱۵/۴۴ | فیلتر AVERAGE     |
| ۰/۴۸           | ۳۲/۶۴ | ۰/۲۹           | ۱۵/۴۵ | فیلتر MEDIAN      |
| ۰/۵۳           | ۲۶/۹۴ | ۰/۳۴           | ۱۵/۴۷ | فیلتر GAUSSIAN    |
| ۰/۹۷           | ۵۷/۳۶ | ۰/۹۸           | ۶۸/۷۷ | روش یادگیری ماشین |

## منابع

- [1] Y. Rivenson, Z. Göröcs, H. Günaydin, Y. Zhang, H. Wang, and A. Ozcan, "Deep learning microscopy," *Optica*, (2017).
- [2] W. Shi et al., "Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network," *Proc. IEEE Comput.*, (2016).
- [3] C. Dong, C. C. Loy, K. He, and X. Tang, "Image super-resolution using deep convolutional networks," *IEEE Trans.* (2016).
- [4] M. Hara and K. Tanaka, "Accurate image super-resolution using very deep convolutional networks," *Nihon. Koshu Eisei Zasshi*, (2013).
- [5] K. H. Jin, M. T. McCann, E. Froustey, and M. Unser, "Deep convolutional neural network for inverse problems in imaging," *IEEE Trans. Image Process* (2017).
- [6] H. Zhao, L. Gao, B. Qiao, and J. Gao, "Accelerating magnetic resonance imaging via deep learning", *Journal Beijing Univ* (2009).
- [7] S. Antholzer, M. Haltmeier, and J. Schwab, "Deep learning for photoacoustic tomography from sparse data," *Inverse Probl. Sci. Eng.*, (2019)
- [8] T. Pitkäaho, A. Manninen, and T. J. Naughton, "Focus classification in digital holographic microscopy using deep convolutional neural networks," *Opt. InfoBase Conf. Pap.*, (2017).
- [9] A. Sinha, J. Lee, S. Li, and G. Barbastathis, "Lensless computational imaging through deep learning," *Optica*, (2017).
- [10] H. Wang, M. Lyu, and G. Situ, "eHoloNet: a learning-based end-to-end approach for in-line digital holographic reconstruction," *Opt. Express*, (2018).
- [11] Y. Rivenson, Y. Zhang, H. Günaydin, D. Teng, and A. Ozcan, "Phase recovery and holographic image reconstruction using deep learning in neural networks," *Light Sci. Appl.*, (2018).
- [12] Z. Ren, Z. Xu, and E. Y. Lam, "Learning-based nonparametric autofocusing for digital holography," *Optica*, (2018).
- [13] T. Shimobaba et al., "Digital holographic particle volume reconstruction using a deep neural network," *Appl. Opt.*, (2019).
- [14] Q. Yang et al., "Low-dose CT image denoising using a generative adversarial network with wasserstein distance and perceptual loss," *IEEE Trans. Med. Imaging*, (2018).
- [15] P. Singh and A. Shankar, "A novel optical image denoising technique using convolutional neural network and anisotropic diffusion for real-time surveillance applications," *J. Real-Time Image Process.*, (2021).
- [16] S. Lefkimmatis, "Universal Denoising Networks: A Novel CNN Architecture for Image Denoising," *Proc. IEEE Comput. Soc. Conf. Comput.* (2018).
- [17] K. Zhang, W. Zuo, Y. Chen, D. Meng, and L. Zhang, "Beyond a gaussian denoiser: residual learning of deep cnn for image denoising," *IEEE Trans. Image Process.*, (2017).
- [18] H. A. Jalab and R. W. Ibrahim, "enoising algorithm based on generalized fractional integral operator with two parameters," *Discret. Dyn. Nat. Soc.*, (2012).
- [19] A. Shukla and R. Pandey, "Generalized fractional derivative based adaptive algorithm for image denoising," *Multimed. Tools Appl.*, (2020).
- [20] A. K. Shukla, R. K. Pandey, S. Yadav, and R. B. Pachori, "Generalized Fractional Filter-Based Algorithm for Image Denoising," *Circuits Syst. Signal Process*, (2020).

## neural convolution Speckle noise elimination of phase images using networks

<sup>1</sup> Mohammad Yaghoobi, <sup>1</sup> Babak Zare, <sup>1</sup> Mohammad Reza JafarFard

<sup>1\*</sup> Faculty of Physics, Iran University of Science and Technology, Tehran

### Article details

Received: 2025/12/17

Accepted: 2026/02/9

Published: 2026/02/21

ISSN: 2588-493X

eISSN: 2588-4921

Correspondence email:

mrjafarfard@iust.ac.ir

bzarer@iust.ac.ir



### Abstract

Phase images obtained from holograms and interference patterns in quantitative phase microscopy often suffer from distortions, phase wrapping, and phase noise. Despite extensive efforts over the past decades and the development of various denoising methods, these challenges have not yet been completely resolved. Classical noise reduction filters typically damage image details, reduce overall quality, and weaken boundary and edge detection, thereby eliminating useful image information. A promising modern approach involves the use of machine learning algorithms. Results from image quality assessment metrics show that convolutional neural networks outperform conventional phase image denoising methods. In this approach, training data are fed into the network, and after several training stages, the network acquires the ability to reduce noise in phase images with high accuracy.

**Keywords:** Phase microscopy, speckle Noise, Machine learning, convolution neural networks