

# کاربرد شبکه‌های عصبی عمیق در طبقه‌بندی تصاویر آسیب‌های شبکه فاضلاب و مشخص کردن مسیرهای بحرانی آنها

مسلم سردشتی بیرجندی<sup>۱</sup>، حسین رحمانی<sup>۲\*</sup> و سعید فراحت<sup>۳</sup>

اطلاعات مقاله	چکیده
<p>نوع مقاله: پژوهشی دریافت مقاله: ۱۴۰۰/۰۸/۰۹ بازنگری مقاله: ۱۴۰۰/۱۲/۰۳ پذیرش مقاله: ۱۴۰۱/۰۱/۲۷</p>	<p>فاضلاب‌روها جزء اصلی تأسیسات زیربنایی شبکه فاضلاب شهری به حساب می‌آیند. آسیب‌های فاضلاب‌روها به دلیل غیرقابل رویت بودن کمتر توجه شده و این عدم رسیدگی به آسیب‌ها، موجب وضعیت‌های اضطراری و هزینه‌های غیر منطقی می‌گردد. این شریان‌های حیاتی در طول سرویس‌دهی، نیازمند نگهداری و بازسازی جهت عملکرد بهینه در تمام ابعاد می‌باشند. امروزه روش‌های پردازش و طبقه‌بندی عکس و فیلم‌های گرفته شده توسط ربات‌های ویدئومتری متحرک برای انجام بازرسی شبکه فاضلاب بسیار مورد استفاده قرار می‌گیرند. یکی از الگوریتم‌های موفق در زمینه پردازش تصویر، الگوریتم شبکه عصبی کانولوشن است که از زیر مجموعه‌های الگوریتم یادگیری عمیق به شمار می‌رود. در این مقاله از یک الگوریتم شبکه عصبی کانولوشن جهت طبقه‌بندی تصاویر آسیب‌های شبکه فاضلاب و موارد مؤثر در بهبود و دقت و عملکرد این الگوریتم، پرداخته شده است. تصاویر توسط ربات ویدئومتری از شبکه فاضلاب بدست آمده است. نتایج حاصل از استفاده از الگوریتم پیشنهادی در شبکه فاضلاب، دستیابی به دقت ۹۸ درصدی در طبقه‌بندی آسیب‌های شبکه و در مقایسه با سایر روش‌ها و نیز کاهش زمان اجرای نسبتاً کم معماری پیشنهادی (۹۱ دقیقه) در مقایسه با سایر معماری‌های معتبر در یادگیری عمیق در یک بستر سخت‌افزاری یکسان می‌باشد. همچنین، در آینده، الگوریتم پیشنهادی جهت تحلیل شبکه‌های فاضلاب بدون نیاز به نیروهای متخصص و همچنین کنترل یک ربات هدایت خودکار ویدئومتری شبکه فاضلاب مورد استفاده قرار خواهد گرفت.</p>
<p><b>واژگان کلیدی:</b> الگوریتم یادگیری عمیق، شبکه عصبی کانولوشن، ویدئومتری شبکه فاضلاب، پردازش تصویر.</p>	

## ۱- مقدمه

فاضلاب‌روها در طول سرویس‌دهی، نیازمند نگهداری و بازسازی جهت عملکرد بهینه در تمام ابعاد می‌باشند. با این وجود، به آسیب‌های فاضلاب‌روها به دلیل غیرقابل رویت بودن کمتر توجه شده و این عدم رسیدگی به آسیب‌ها، موجب وضعیت‌های اضطراری خواهد شد که علاوه بر اضافه نمودن هزینه‌های غیرمنطقی در طول سال‌های بهره‌برداری، عمر مفید شبکه را کاهش می‌دهد. با توجه به اینکه قطر لوله‌ها در بسیاری از شبکه‌های

فاضلاب کم می‌باشد، حضور انسان برای انجام بازرسی شبکه عملاً غیرممکن است. در اندازه‌های بزرگتر نیز وجود گازهای خطرناک، غیرقابل پیش‌بینی بودن شبکه و وجود خطر ریزش، حضور انسان برای انجام بازرسی را غیر منطقی می‌کند. لذا استفاده از ربات‌های متحرک برای انجام بازرسی شبکه فاضلاب بسیار رایج گردیده است. عکس و فیلم‌های گرفته شده توسط ربات ویدئومتری شبکه فاضلاب، توسط نیروهای متخصص بررسی شده، آسیب‌های شبکه فاضلاب شناسایی می‌شوند و مسیرهای بحرانی

\*پست الکترونیک نویسنده مسئول: h\_rahmani@eng.usb.ac.ir

۱. دانشجوی دکتری گرایش مکانرونیک، گروه مهندسی مکانیک، دانشکده مهندسی شهید نیکبخت، دانشگاه سیستان و بلوچستان، زاهدان، ایران.

۲. دانشیار، گروه مهندسی مکانیک، دانشکده مهندسی شهید نیکبخت، دانشگاه سیستان و بلوچستان، زاهدان، ایران.

۳. استاد، گروه مهندسی مکانیک، دانشکده مهندسی شهید نیکبخت، دانشگاه سیستان و بلوچستان، زاهدان، ایران.

مشخص می‌گردند تا در اختیار شرکت‌های پیمانکار مربوطه قرار گیرند و به ترتیب از مسیر بحرانی‌تر، آسیب‌ها رفع گردد [۱].

بدون شک وجود یک استاندارد و رویکرد یکپارچه نسبت به مسئله ارزیابی درونی شبکه‌های فاضلاب، اولین و مهمترین قدم در راه رسیدن به روش‌های مناسب جهت مدیریت هر چه بهتر شبکه‌های فاضلاب می‌باشد. تدوین و گسترش این استانداردها در کشورهای پیشرفته نظیر انگلستان، کانادا و استرالیا موجب انجام اقدامات لازم و مناسب جهت بهبود وضعیت شبکه‌های فاضلاب در این کشورها و در نتیجه مدیریت آسان‌تر در این شبکه‌ها و رسیدن به شرایط مطلوب شده است. در سال‌های اخیر، در ایران نیز عملیات بازرسی شبکه‌های فاضلاب در مراحل تحویل موقت و بهره‌برداری از اهمیت ویژه‌ای برخوردار شده است. شرکت‌های دولتی و خصوصی در یک دهه گذشته با استفاده از دوربین‌های بازرسی (ویدئومتری) داخلی و خارجی در این زمینه مشغول فعالیت می‌باشند.

از این رو، آسیب‌پذیری فاضلاب‌روها باید مورد توجه بهره‌برداران قرار گیرد و طبق برنامه‌ریزی و زمان‌بندی مناسب بررسی و ارزیابی شوند. اما در عمل به علت گستردگی فاضلاب‌روهای آسیب دیده و محدودیت زمان و هزینه، امکان رسیدگی و برطرف کردن تمام آسیب‌های فاضلاب‌روها در یک زمان وجود ندارد و این امر نیازمند فعالیت‌های مدیریتی در قالب رتبه‌بندی آسیب‌پذیری جهت تدوین برنامه نگهداری و بازسازی فاضلاب‌روها می‌باشد. برای تعیین و رتبه‌بندی آسیب‌پذیری فاضلاب‌روها شناسایی عوامل مؤثر ضروری می‌باشد. در این زمینه پژوهش‌هایی در سراسر دنیا و ایران پیرامون تعیین عوامل مؤثر بر آسیب‌پذیری و ارزیابی آسیب‌پذیری فاضلاب‌روها انجام شده است. رینا و همکاران [۲] در سال ۱۹۹۴، ریوارد و همکاران [۳] در سال ۲۰۰۰، بنیس و همکاران [۴] در سال ۲۰۰۳ و کاردوسو و همکاران [۵] در سال ۲۰۰۵، شاخص‌های هیدرولیکی را برای ارزیابی فاضلاب‌روها تعریف کردند.

چوختای و زاید در سال ۲۰۰۷، مطالعاتی را در مورد پیش‌بینی شرایط بهره‌برداری در قالب عوامل هیدرولیکی و غیرهیدرولیکی فاضلاب‌روها با استفاده از رگرسیون چند متغیره انجام دادند [۶]. همچنین، بن قاسم و بنیس در سال ۲۰۰۰، در تحقیقی تحت عنوان سیستم خبره برای عیب‌یابی فاضلاب‌روهای شبکه فاضلاب، شاخص‌هایی را در

نظر گرفتند و عملکرد سیستم فاضلاب را، در دو عنوان ساختاری و هیدرولیکی تحت سیستم استنتاج فازی مورد بررسی قرار دادند [۷].

مدنی تنکابنی و تابش در سال ۱۳۸۴ روشی برای ارزیابی عملکرد هیدرولیکی شبکه‌های جمع‌آوری فاضلاب شهری پیشنهاد دادند [۸]. حسینی و قاسمی در سال ۲۰۱۲ در تحقیقی به ارزیابی عملکرد هیدرولیکی فاضلاب‌روها با تجزیه و تحلیل عدم قطعیت جریان بر پایه منطق فازی پرداختند [۹].

بازرسی بصری متداول‌ترین روش استفاده شده برای به دست آوردن اطلاعات انواع آسیب‌های شبکه فاضلاب به منظور تهیه برنامه‌های نگهداری شبکه و رفع آسیب‌های شبکه می‌باشد. اگرچه می‌توان اطلاعات آسیب‌های شبکه را از یک بازرسی بصری توسط ربات ویدئومتری به دست آورد، اما این روش وقت‌گیر و معمولاً غیرقابل اطمینان است، چرا که نتایج به تجربه و مهارت نیروی متخصص مربوطه بستگی دارد. برای غلبه بر معایب بازرسی بصری، الگوریتم‌های پردازش تصویر به عنوان یک روش جایگزین امیدوارکننده برای بررسی و نظارت بر آسیب‌های شبکه فاضلاب معرفی شده‌اند [۱۰]. به طور کلی، در این الگوریتم‌ها، از تصاویر حاصل از ویدئومتری شبکه فاضلاب توسط ربات ویدئومتری برای پردازش و آنالیز آسیب‌های شبکه فاضلاب استفاده می‌شود که منجر به حصول اطلاعاتی نظیر وجود آسیب‌ها در شبکه، نوع آسیب و موقعیت آنها می‌گردد. اگر چه کارایی این الگوریتم‌ها منجر به کاربرد زیاد آنها در زمینه شناسایی آسیب‌های شبکه فاضلاب خواهد شد، اما وجود موانع مختلف در شبکه فاضلاب، وجود لجن‌های فاضلابی و کیفیت تصاویر گرفته شده توسط ربات ویدئومتری می‌تواند منجر به تشخیص نادرست آسیب‌های شبکه فاضلاب گردد. بنابراین، تشخیص آسیب‌های واقعی از تصاویر به دست آمده از ویدئومتری شبکه فاضلاب فرآیندی مهم در تشخیص و طبقه‌بندی آسیب‌ها محسوب می‌شود. امروزه، یادگیری ماشین به عنوان ابزاری ترکیبی و نوآورانه در برنامه‌های مهندسی شناخته شده است [۱۱-۱۲].

روش‌های یادگیری ماشین به طور معمول شامل شناسایی ویژگی‌های متمایزکننده از تصاویر آموزش است که منجر به ایجاد یک مدل طبقه‌بندی می‌شود. سپس مدل طبقه‌بندی آموزش‌دیده روی تصاویر جدید (تصاویر آزمایش) اعمال می‌شود تا در آنها آسیب‌های شبکه

۱. استفاده از الگوریتم شبکه‌های عصبی عمیق برای اولین بار، جهت شناسایی و طبقه‌بندی آسیب‌های شبکه فاضلاب

۲. معماری پیشنهادی این مقاله ترکیبی از لایه‌های عمیق مختلف است که منجر به یک ساختار منحصر به فرد شده است.

۳. با وجود اینکه برخی از پژوهش‌های پیشین به بررسی، تشخیص و طبقه‌بندی آسیب‌های شبکه فاضلاب پرداخته‌اند [۱۵]، اما تعیین مسیرهای بحرانی شبکه فاضلاب از طریق تشخیص آسیب‌های شبکه فاضلاب و امتیازدهی به آن‌ها، مورد توجه کمتری قرار گرفته است. لذا در این پژوهش به طور مشخص و در یک سیستم طبقه‌بندی، تعیین مسیرهای بحرانی شبکه فاضلاب برای در اولویت قرار دادن آن‌ها جهت نگهداری و تعمیرات شبکه فاضلاب، بدون نیاز به استفاده از نیروهای متخصص، انجام می‌گردد.

## ۲- مواد و روش‌ها

همان‌طور که اشاره گردید جهت شناسایی و طبقه‌بندی آسیب‌های شبکه فاضلاب در این مقاله نیازمند استفاده از الگوریتم شبکه‌های عصبی می‌باشد. الگوریتم یادگیری عمیق یکی از الگوریتم‌های یادگیری ماشین است، که هدف آن کشف سطوح مختلف از ویژگی‌های ورودی مورد نظر است [۱۶-۱۸]. به‌تازگی، الگوریتم‌های یادگیری عمیق متعددی برای حل مشکلات قدیمی هوش مصنوعی پیشنهاد شده است. این الگوریتم‌ها در بسیاری از حوزه‌های هوش مصنوعی مانند بینایی ماشین، تشخیص گفتار و تشخیص جسم موفق عمل کرده‌اند [۱۸]. به طور کلی روش‌های الگوریتم یادگیری عمیق را می‌توان به چهار دسته تقسیم کرد [۱۴]:

۱- شبکه عصبی کانولوشن<sup>۳</sup>

۲- شبکه باور عمیق

۳- شبکه رمزگشای اتوماتیک

۴- روش کد پراکنده

با توجه به بررسی مقالات و مطالعات پیشین در زمینه شناسایی و طبقه‌بندی آسیب‌های شبکه فاضلاب، این نکته دریافت می‌شود که اگرچه شناسایی آسیب‌های شبکه فاضلاب از لحاظ مهندسی و نگهداری زیرساخت‌ها از

فاضلاب شناسایی شوند. برای طبقه‌بندی مؤثر و به منظور تولید یک مدل طبقه‌بندی قوی نیاز به استخراج ویژگی‌های پیشرفته از تصاویر آسیب‌ها در شبکه فاضلاب است. در دهه اخیر، یادگیری عمیق<sup>۱</sup> که دسته‌ای از الگوریتم‌های یادگیری یادگیری ماشین و هوش مصنوعی است و تلاش می‌کند مفاهیم انتزاعی سطح بالا را با استفاده از یادگیری در سطوح و لایه‌های مختلف مدل کند، به عنوان روشی قدرتمند در موضوعات تشخیص و طبقه‌بندی معرفی شده است [۱۳]. ایده یادگیری عمیق با الهام از ساختار طبیعی مغز انسان و به کمک امکانات و فن‌آوری‌های جدید توانسته است در بسیاری از حوزه‌های مربوط به هوش مصنوعی و یادگیری ماشین موفقیت‌های چشم‌گیری را کسب کند. از جمله مزایای یادگیری عمیق می‌توان به یادگیری خودکار و چند لایه ویژگی‌ها، دقت زیاد در نتایج، قدرت تعمیم و شناسایی داده‌های جدید و پشتیبانی گسترده سخت‌افزاری و نرم‌افزاری اشاره کرد [۱۴].

با توجه به رشد روزافزون شبکه‌های فاضلاب در ایران، کنترل کیفی و کمی نحوه عملکرد شرکت‌های فعال در زمینه بازرسی شبکه فاضلاب از اهمیت بسیار بالایی برخوردار است. در غیر این صورت، گزارش‌های به‌دست آمده از عملیات بازرسی شبکه‌های فاضلاب از کیفیت و دقت لازم برخوردار نخواهند بود و در نتیجه مدیریت این شبکه‌ها امری بسیار مشکل خواهد بود. بی‌شک، یکی از مهمترین راه‌های کنترل نحوه عملکرد شرکت‌های فعال در این زمینه، تدوین یک استاندارد ملی مطابق با وضعیت شبکه‌های فاضلاب کشور جهت کدگذاری عیوب شبکه است. از آنجایی که شرکت‌های فاضلاب در ایران استاندارد WRC<sup>۲</sup> را به رسمیت می‌شناسند باید این استاندارد برای شرکت‌های ایرانی تطبیق داده شود. مسلماً این امر نیازمند انجام تحقیقات گسترده با همکاری شرکت‌ها و مؤسسات داخلی و خارجی و همچنین تدوین و اجرای برنامه‌ای جامع در این زمینه است.

در این مقاله، با بهره‌گیری از اطلاعات مربوط به استاندارد WRC و با استفاده از یک الگوریتم یادگیری ماشین به دنبال روشی برای طبقه‌بندی و امتیازدهی آسیب‌های شبکه فاضلاب بدون نیاز به استفاده از نیروهای متخصص، هستیم. بنابراین نوآوری این مقاله را می‌توان در سه مورد ذکر کرد:


<sup>3</sup> Convolutional Neural Networks

<sup>1</sup> Deep Learning

<sup>2</sup> Water Research Center

در شکل (۱) چند نمونه از آسیب‌های شبکه فاضلاب مشاهده می‌شود.

اهمیت زیادی برخوردار است، اما تشخیص نوع آسیب نیز به نوبه خود می‌تواند مهم و ضروری باشد. این امر بدون درک از آسیب‌های شبکه فاضلاب امکانپذیر نیست.



شکل ۱- تصاویر مربوط به آسیب‌های شبکه فاضلاب

هفت دسته تصاویر ترک، شکاف، شکستگی، سوراخ، تغییر شکل، فروریزش و جابجایی در محل اتصال طبقه‌بندی می‌شوند.

### ۱-۳- جمع آوری داده‌ها

همان‌گونه که پیش تر ذکر شد، یکی از راه‌های مدرن برای تشخیص آسیب‌های شبکه فاضلاب، استفاده از پردازش تصاویر دیجیتالی است که نسبت به سایر روش‌ها دارای دقت بیشتر است. برای این منظور، در این مقاله، از تصاویر و فیلم‌های به‌دست آمده توسط ربات‌های ویدئومتری در سطح کشور، جهت آموزش و تست الگوریتم پیشنهادی استفاده شده است.

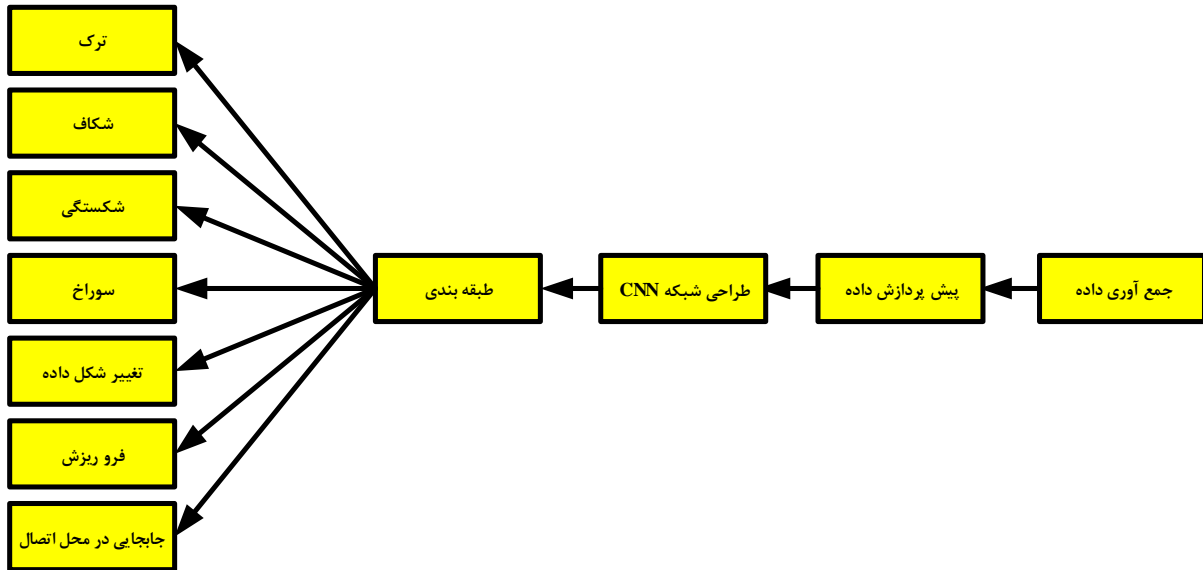
### ۲-۳- پیش‌پردازش

تصاویر حاصل از مرحله قبل، رنگی و دارای نویز است که در اثر تغییرات شدت نور محیط داخل شبکه فاضلاب و لرزش‌های احتمالی به وجود آمده‌اند. این نویزها موجب تغییر رنگ و محو شدن بعضی از قسمت‌های سطح لوله‌های شبکه فاضلاب می‌شوند. در این مرحله، ابتدا تصاویر رنگی به تصاویر خاکستری تبدیل می‌شوند و سپس با استفاده از متعادل‌سازی هیستوگرام، تصاویر بهبود می‌یابند [۱۹].

بنابراین، شناسایی آسیب‌های موجود در شبکه فاضلاب به دلیل اینکه می‌تواند صدمات زیادی به شبکه فاضلاب بزند، از اهمیت به‌سزایی برخوردار است. به همین منظور، در این پژوهش، یک روش هوشمند براساس یادگیری عمیق برای شناسایی و طبقه‌بندی آسیب‌های شبکه فاضلاب ارائه شده است. این روش هوشمند که مبنای آن شبکه‌های عصبی کانولوشنی است، منجر به طبقه‌بندی آسیب‌های شبکه فاضلاب به هفت دسته ترک، شکاف، شکستگی، جابجایی در محل اتصال، فروریزش، تغییر شکل و سوراخ می‌شود.

### ۳- ساختار پیشنهادی

روش پیشنهادی این مقاله برای شناسایی و طبقه‌بندی آسیب‌های شبکه فاضلاب مطابق دیاگرام جعبه‌ای شکل (۲) به این صورت است که ابتدا در مرحله جمع‌آوری داده، عکس‌هایی از آسیب‌های شبکه‌های فاضلاب کشور که توسط ربات‌های ویدئومتری شبکه فاضلاب موجود تهیه شده‌اند، جمع‌آوری می‌شوند. پس از مرحله جمع‌آوری داده، پیش‌پردازشی جهت نویزهای احتمالی و تنظیم شدت نور تصاویر صورت می‌گیرد. در انتها، با طراحی یک شبکه یادگیری عمیق، تصاویر مستخرج از آسیب‌های شبکه فاضلاب به



شکل ۲- دیاگرام جعبه‌ای روش پیشنهادی برای طبقه‌بندی تصاویر آسیب‌های شبکه فاضلاب

### ۳-۱- جمع آوری داده‌ها

همان‌گونه که پیش‌تر ذکر شد، یکی از راه‌های مدرن برای تشخیص آسیب‌های شبکه فاضلاب، استفاده از پردازش تصاویر دیجیتال است که نسبت به سایر روش‌ها دارای دقت بیشتر است. برای این منظور، در این مقاله، از تصاویر و فیلم‌های به‌دست آمده توسط ربات‌های ویدئومتری در سطح کشور، جهت آموزش و تست الگوریتم پیشنهادی استفاده شده است.

### ۳-۲- پیش‌پردازش

تصاویر حاصل از مرحله قبل، رنگی و دارای نویز است که در اثر تغییرات شدت نور محیط داخل شبکه فاضلاب و لرزش‌های احتمالی به وجود آمده‌اند. این نویزها موجب تغییر رنگ و محو شدن بعضی از قسمت‌های سطح لوله‌های شبکه فاضلاب می‌شوند. در این مرحله، ابتدا تصاویر رنگی به تصاویر خاکستری تبدیل می‌شوند و سپس با استفاده از متعادل‌سازی هیستوگرام، تصاویر بهبود می‌یابند [۱۹].

### ۳-۳- طراحی شبکه عصبی کانولوشنی

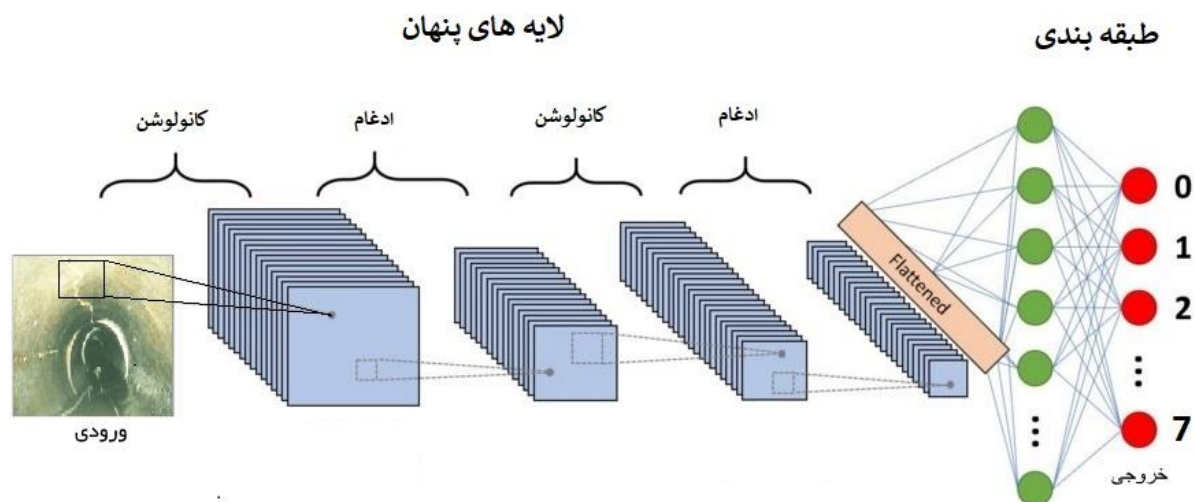
#### ۳-۳-۱- اصول عملکرد شبکه‌های عصبی کانولوشنی

شبکه‌های عصبی مصنوعی که از شیوه عملکرد سیستم عصبی زیستی الهام گرفته‌اند، نوع خاصی از مدل‌های یادگیری برای پردازش اطلاعات هستند. ساده‌ترین نوع شبکه‌های عصبی مصنوعی، شبکه‌های عصبی پیشخور هستند که جهت حرکت اطلاعات در آنها فقط رو به جلو است [۲۰]. مجموعه‌ای از شبکه‌های عصبی مصنوعی پیشخور که حداقل شامل سه لایه (لایه ورودی، لایه پنهان

و لایه خروجی) باشند و از الگوریتم پس‌انتشار برای آموزش لایه‌ها استفاده کنند، تشکیل شبکه‌های پرسپترون چندلایه می‌دهند [۲۰]. در این مقاله به منظور طبقه‌بندی آسیب‌های شبکه فاضلاب، از شبکه‌های عصبی عمیق استفاده می‌شود. شبکه‌های عصبی کانولوشنی (CNN) نوع خاصی از شبکه‌های عصبی عمیق پیشخور هستند که با اعمال تغییراتی بر شبکه‌های کلاسیک پرسپترون چندلایه طراحی شده‌اند و انتخابی مناسب برای پردازش داده‌های دوبعدی مانند تصاویر هستند [۲۱]. ساختار کلی طبقه‌بندی آسیب در تصاویر شبکه‌های فاضلاب با استفاده از شبکه‌های عصبی کانولوشنی که از سه بخش کلی تصاویر ورودی، لایه‌های پنهان و طبقه‌بندی تشکیل می‌شود، در شکل (۳) نشان داده شده است [۲۲]. طبق این شکل تصاویر شبکه فاضلاب به عنوان تصاویر ورودی در نظر گرفته و به لایه‌های پنهان فرستاده می‌شوند. خروجی این لایه‌ها به عنوان ورودی قسمت طبقه‌بندی که حاوی لایه‌های تماماً متصل هستند، در نظر گرفته می‌شود و خروجی نهایی شبکه منجر به طبقه‌بندی تصاویر شبکه فاضلاب به هفت دسته ترک، شکاف، شکستگی، جابجایی در محل اتصال، فروریزش، تغییر شکل و سوراخ می‌شود. لایه‌های پنهان از دو نوع لایه اصلی کانولوشن و ادغام تشکیل می‌شوند که وظیفه انتخاب و استخراج خودکار ویژگی‌ها را بر عهده دارند. در لایه‌های کانولوشن، فیلترهایی که عمقی برابر با عمق تصویر ورودی دارند، با تصویر ورودی کانولوشن می‌شوند. هر کدام از این فیلترها همانند وزن‌های ماتریسی قابل آموزش هستند و

استخراج ویژگی‌ها از ورودی شبکه را به عهده دارند و ویژگی اصلی آنها استخراج ویژگی‌های محلی و پیوستگی بین این ویژگی‌هاست [۱۴].

در طول آموزش شبکه مدام به‌روزرسانی می‌شوند. کانولوشن ایجادشده به ازای هر فیلتر در یک صفحه با نام نگاشت ویژگی ذخیره می‌شود. لایه‌های کانولوشن وظیفه



شکل ۳- یک نمونه از ساختار شبکه‌های عصبی کانولوشن

زیادی از پارامترهای یک شبکه کانولوشنی هستند، همانند شبکه‌های عصبی مصنوعی سنتی عمل می‌کنند. به این صورت که این لایه‌ها نتیجه شبکه را در قالب یک بردار با اندازه مشخص ارائه می‌دهند [۲۰]. بنابراین در حالت کلی در هر شبکه عصبی کانولوشنی تعدادی از لایه‌های ادغام و کانولوشن به همراه توابع غیرخطی موسوم به تابع فعال‌سازی نظیر واحد خطی اصلاح‌کننده<sup>۴</sup> ( $Relu$ )، در کنار تعدادی لایه تماماً متصل، کار استخراج ویژگی و طبقه‌بندی را انجام می‌دهند. تابع  $Relu$  بر اساس معادله (۱) به‌دست می‌آید [۲۱]:

$$Relu(x) = \max(0, x) \quad (1)$$

در شبکه‌های عصبی کانولوشنی دو مرحله آموزش وجود دارد: مرحله رو به جلو<sup>۳</sup> و مرحله پس انتشار<sup>۴</sup> یا رو به عقب. در مرحله اول، پس از اعمال تصویر ورودی به شبکه، ضرب نقطه‌ای بین ورودی و پارامترهای هر نورون و نهایتاً اعمال عملیات کانولوشن در هر لایه صورت می‌گیرد و خروجی شبکه محاسبه می‌شود. به منظور تنظیم وزن‌ها و پارامترهای شبکه (آموزش شبکه) از نتیجه خروجی با

لایه‌های ادغام یا جمع‌آوری نیز با هدف کاهش تعداد پارامترها (کاهش ابعاد مسئله) و تجمیع ویژگی‌های مشترک در لایه‌های پنهان استفاده می‌شوند. ادغام بیشینه و میانگین از مهمترین روش‌های ادغام هستند که به ترتیب با انتخاب بیشینه و میانگین مقادیر در یک همسایگی، منجر به کاهش اندازه نگاشت‌های ویژگی و درعین حال ثابت ماندن تعداد آنها می‌شود [۱۵]. ذکر این نکته ضروری است که در لایه‌های کانولوشن و ادغام، اندازه و گام فیلتر و همچنین نوع لایه‌سازی در اندازه نگاشت ویژگی تأثیرگذار است. لایه‌سازی به معنای اضافه کردن لایه‌های اضافی با مقدار صفر دور تصویر ورودی جهت کانولوشن با فیلتر است که می‌تواند به سه روش لایه‌سازی صحیح<sup>۱</sup>، لایه‌سازی یکسان<sup>۲</sup> و لایه‌سازی کامل<sup>۳</sup> انجام شود [۱۹]. در بخش انتهایی لایه‌های پنهان در شبکه‌های کانولوشن، تعداد زیادی از صفحات ویژگی با ابعاد بسیار کوچک وجود دارند که به عنوان ورودی‌های لایه‌های تماماً متصل در قسمت طبقه‌بندی به کار می‌روند. خروجی این لایه‌ها برداری یک بعدی است، در صورتیکه ورودی آنها نگاشت‌های ویژگی دوبعدی است. لایه‌های تماماً متصل که حاوی بخش

<sup>3</sup> Same Padding

<sup>4</sup> Rectified Linear Unit

<sup>1</sup> Padding

<sup>2</sup> Valid Padding

میان محققان وجود دارد. در حالت کلی ادغام بیشینه به دلیل حفظ بهتر ویژگی‌های شناسایی شده در لایه‌های ابتدایی نسبت به ادغام میانگین، می‌تواند باعث همگرایی سریع‌تر و تعمیم بهتر گردد. در این میان نیز الگوریتم‌های مختلف منظم‌سازی<sup>۲</sup> مانند حذف تصادفی<sup>۳</sup> و افزایش داده<sup>۴</sup> می‌توانند از بروز بیش‌برازش<sup>۵</sup> جلوگیری کنند. این الگوریتم‌ها در معماری‌هایی نظیر *AlexNet* و *ZF* مشاهده می‌شوند. با این وجود، رسیدن به یک معماری مطلوب بر مبنای یک فرمول واحد امکان‌پذیر نیست و معماری‌های *CNN* بر اساس یک سری از اصول اولیه و مبتنی بر سعی و خطا به دست می‌آیند.

شکل (۴) معماری پیشنهادی این پژوهش را نشان می‌دهد. در این معماری، در سراسر شبکه برای نگهداری بهترین ویژگی‌ها از ادغام بیشینه استفاده شد. همچنین در بلوک‌های اول و دوم پس از لایه کانولوشن، نرمال‌سازی بسته‌ها قرار گرفته است. در سه بلوک ابتدایی معماری پیشنهادی، تابع فعال‌ساز غیرخطی *PReLU* وجود دارد. این تابع در کنار تسریع فرآیند همگرایی، به دلیل محاسبات ساده‌تر در مقایسه با توابعی مثل سیگموئید، حجم محاسبات لازم را نیز کاهش می‌دهد. این تابع مشکل از بین رفتن گرادینان و داده‌های منفی که در تابع فعال‌ساز *Relu* وجود دارد را برطرف کرده است. در این تابع، به جای صفر در نظر گرفتن داده‌های کوچکتر از صفر، ناحیه منفی کوچکتری در نظر گرفته می‌شود. در انتهای شبکه و در بلوک چهارم نیز از دو لایه تماماً متصل استفاده شده است. از آنجا که تعداد زیادی از پارامترها در دو لایه انتهایی تماماً متصل قرار دارند، در حین آموزش احتمال پیش‌پردازش زیادت‌تر می‌شود. به همین دلیل و برای جلوگیری از آن، در بین لایه‌های تماماً متصل از لایه حذف تصادفی برای کاهش پارامترها استفاده می‌شود. حذف تصادفی از جمله روش‌های منظم‌سازی است که در هر تکرار از آموزش، تعدادی از نورونها را به صورت تصادفی از شبکه حذف می‌کند و در مرحله بعد، با وزن قبلی به شبکه بازمی‌گرداند. همچنین در لایه آخر نیز تابع *Softmax* به منظور طبقه‌بندی در نظر گرفته شده است.

استفاده از یک تابع خطا جهت محاسبه میزان خطای شبکه استفاده می‌گردد. در این مقاله از تابع *Softmax* به عنوان تابع هزینه استفاده شده است و وزن‌ها و پارامترهای شبکه طوری انتخاب می‌شوند که این تابع کمینه گردد [۲۲]. این تابع هزینه توسط معادله (۲) محاسبه می‌گردد [۲۲]:

$$L_i = -\log\left(\frac{e^{S y_i}}{\sum_j e^{S_j}}\right) \quad (2)$$

با توجه به فرمول (۲) اگر به تصویر  $x_i$  برچسب  $y_i$  داده شود و تابع  $S = f(x_i, w)$  امتیازهای هر طبقه را با وزن  $w$  محاسبه کند، آن‌گاه  $S_j = f(x_i, W)_j$  امتیاز طبقه  $j$  را نشان می‌دهد. در نهایت  $L_i$  مقدار تابع هزینه مربوط به  $i$ امین تصویر است. سپس، بر اساس میزان خطای محاسبه شده، مرحله پس انتشار شروع می‌شود. در این مرحله، گرادینان هر وزن و پارامتر با توجه به قاعده زنجیری<sup>۱</sup> محاسبه می‌شود و تمامی وزن‌ها و پارامترها با توجه به تأثیری که بر خطای ایجادشده در شبکه دارند، تغییر پیدا می‌کنند و به روزرسانی می‌شوند. بعد از به روزرسانی وزن‌ها و پارامترها، مرحله رو به جلو شروع می‌شود. بعد از تکرار تعداد مناسبی از این مراحل، آموزش شبکه پایان می‌یابد.

### ۲-۳-۳- ساختار CNN پیشنهادی

عملیات کانولوشن ایده اصلی تشکیل‌دهنده شبکه‌های *CNN* است و شیوه استفاده از آن یک عامل تعیین‌کننده بزرگ برای عملکرد شبکه است. اینکه ابعاد لایه‌های کانولوشن چه اندازه باشد بستگی به نوع داده، محدودیت‌های سخت‌افزاری و برخط بودن یا نبودن عملیات دارد. با این حال، چند کانولوشن  $3 \times 3$  که به طور متوالی پشت سر هم قرار می‌گیرند، می‌توانند به همان میدان تأثیر<sup>۱</sup> که کانولوشن‌های بزرگتر ارائه می‌دهند، دست یابند، ساختاری که در معماری‌های مشتق شده *CNN* مانند *VGGNet* و *ResNet* دیده می‌شود. هر چند که ممکن است این ساختار نیاز به سخت‌افزار قوی و زمان زیاد محاسبات داشته باشد. بعد از هر لایه کانولوشن و به منظور جمع‌بندی ویژگی، هنگام نمونه‌برداری کاهش از لایه‌های ادغام استفاده می‌شود. در مورد بهتر بودن هر کدام از تکنیک‌های ادغام بیشینه و میانگین نیز بحث زیادی در

<sup>4</sup> Data Augmentation

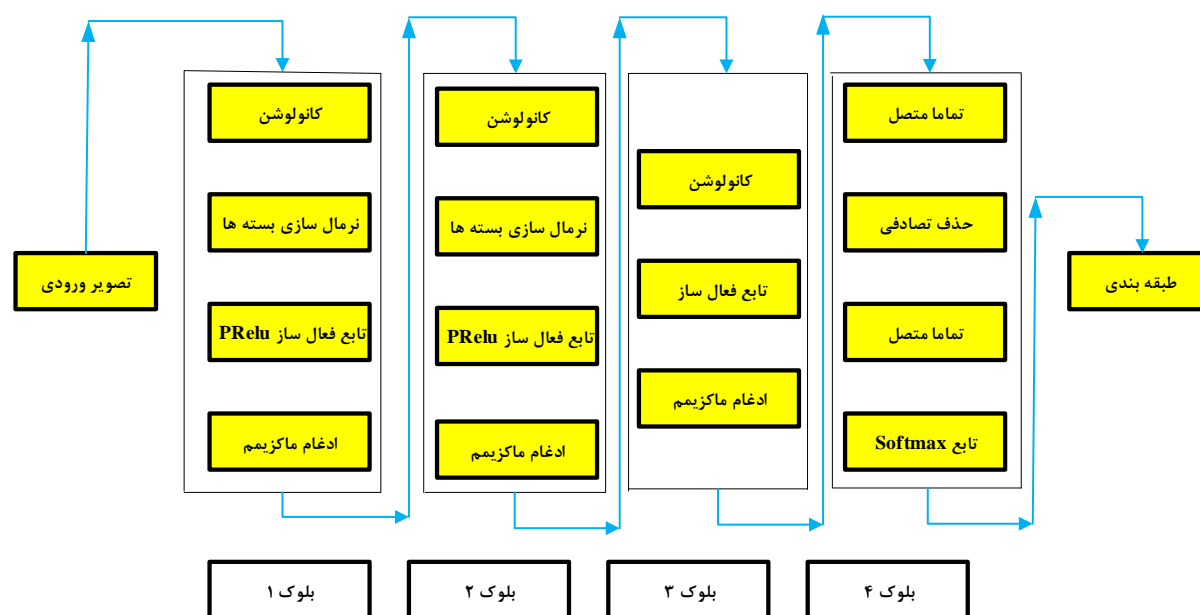
<sup>5</sup> Overfitting

<sup>1</sup> Receptive Field

<sup>2</sup> Regularization

<sup>3</sup> Drop Out





شکل ۴- معماری الگوریتم پیشنهادی شبکه‌های کانولوشنی مورد استفاده در این پژوهش

را هم افزایش می‌دهد. به علاوه، باید توجه داشت که اگر تعداد دوره‌ها بیش از حد باشد، ممکن است منجر به بیش برآزش شود. لازم به ذکر است که در این پژوهش از ۲۰ دوره استفاده شده است. در نهایت و پس از مرحله اعتبارسنجی یک مدل یادگیری عمیق، کارایی آن روی مجموعه داده‌های آزمایش ارزیابی می‌شود. در واقع هنگامی که یک شبکه عمیق آموزش می‌بیند و برآزش می‌شود، این شبکه سعی می‌کند خروجی را روی داده‌های آزمایش هرچه دقیق‌تر پیش‌بینی کند که میزان درستی پیش‌بینی به‌دست آمده روی داده‌های آزمایش، درصد صحت<sup>۵</sup> (دقت الگوریتم) را تشکیل می‌دهد. شکل (۵) تغییرات درصد اعتبارسنجی و تغییرات مقدار تابع هزینه را نشان می‌دهد که اعمال این شبکه روی داده‌های آزمایش درصد صحت ۹۸ را به دنبال داشت که نشان از عملکرد مناسب معماری پیشنهادی است. همچنین در جدول ۱، مقایسه صحت و زمان اجرای شبکه کانولوشنی پیشنهادی با برخی از مهم‌ترین شبکه‌های کانولوشنی معتبر و مرسوم انجام گرفته است.

#### ۴- نتایج و بحث

همان‌گونه که پیش‌تر بیان شد، هدف از این مطالعه طبقه‌بندی تصاویر آسیب‌های موجود در شبکه فاضلاب است. به همین منظور، ابتدا پس از تهیه تصاویر آسیب‌های شبکه فاضلاب به‌دست آمده از ویدئومتری شبکه‌های فاضلاب در سطح کشور و متعادل‌سازی هیستوگرام آن‌ها، تعداد ۷۰۰۰ تصویر شامل هفت دسته تصاویر ترک، شکاف، شکستگی، جابجایی در محل اتصال، فروریزش، تغییر شکل و سوراخ (هردسته ۱۰۰۰ تصویر) ایجاد شدند. از این تعداد تصویر، تعداد ۵۲۵۰ تصویر (۷۵ درصد مجموعه داده) برای آموزش<sup>۱</sup> و ۱۷۵۰ تصویر (۲۵ درصد مجموعه داده) برای آزمایش<sup>۲</sup> به صورت تصادفی انتخاب شدند. همچنین ۲۰ درصد از مجموعه داده‌های آموزش (۱۰۵۰ تصویر) برای اعتبارسنجی<sup>۳</sup> در نظر گرفته شده است. طی کردن ورودی در کل شبکه در یک مسیر رفت و برگشت به یک دوره<sup>۴</sup> اشاره دارد. تعداد دوره‌هایی که برای یادگیری شبکه استفاده می‌شود در هر شبکه متفاوت است. درست است که داشتن دوره‌های بیشتر منجر به صحت بیشتر در شبکه می‌شود، ولی زمان یادگیری شبکه

<sup>۴</sup> Epoch

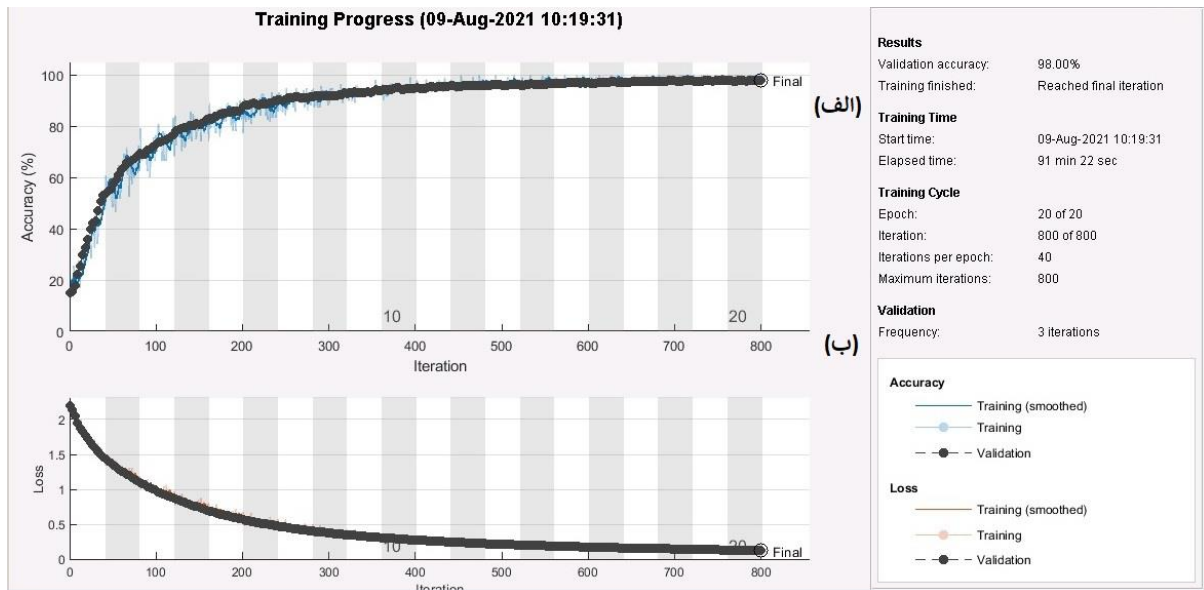
<sup>۵</sup> Accuracy

<sup>۱</sup> Train

<sup>۲</sup> Test

<sup>۳</sup> Validation





شکل ۵- نتیجه اعمال معماری پیشنهادی روی مجموعه تصاویر آموزش، (الف) تغییرات درصد اعتبارسنجی و (ب) تغییرات مقدار تابع هزینه

جدول ۱- مقایسه صحت و زمان اجرای شبکه کانولوشنی پیشنهادی با برخی از مهم‌ترین شبکه‌های کانولوشنی معتبر و مرسوم

نوع	دقت الگوریتم (درصد)	زمان تقریبی (دقیقه)
[17] Alex Net	۷۹	۱۷۳۰
[18] VGG Net	۸۶/۴	۱۵۵۱
[19] Google Net	۹۴/۲	۴۵۷
شبکه کانولوشن پیشنهادی	۹۸	۹۱

همچنین، در شکل (۷)، منحنی  $ROC^3$  مربوط به داده‌های اعتبارسنجی و تست قابل مشاهده می‌باشد. سطح زیر این منحنی را  $AUC$  می‌گویند. مقدار عددی  $AUC^3$  به وضوح عددی بین صفر تا یک است و نشان می‌دهد قدرت تشخیص یک تست چقدر است.

اگر این عدد به یک نزدیک باشد به معنای آن است که داده‌ها عموماً در بالای خط نیمساز قرار گرفته‌اند و میزان نرخ مثبت صحیح بالا است. اعداد  $AUC$  نزدیک به ۰/۵ همان برابری نرخ مثبت صحیح و نرخ مثبت کاذب را نشان می‌دهد و اعداد کمتر از ۰/۵ بیانگر بیشتر بودن نرخ مثبت کاذب در مقایسه با نرخ مثبت صحیح است. در جدول ۲ مشاهده می‌شود که تمام مقدار  $AUC$  به‌دست آمده برای داده‌های اعتبارسنجی و تست مربوط به همه‌ی هفت کلاس، مقدار یک و مقادیر بسیار نزدیک به یک هستند.

یکی از معیارهای ارزیابی کیفیت یک الگوریتم طبقه‌بندی، ماتریس اغتشاش<sup>۱</sup> می‌باشد. این ماتریس، یک ماتریس  $N \times N$  می‌باشد که  $N$  همان تعداد کلاس‌ها در نظر گرفته شده در الگوریتم طبقه‌بندی می‌باشد. همانطور که در شکل (۶) مشاهده می‌شود، این ماتریس برای این تحقیق با توجه به کلاس‌بندی آسیب‌های شبکه فاضلاب به هفت کلاس، یک ماتریس  $7 \times 7$  در  $7$  می‌باشد. عناصر روی قطر اصلی ماتریس، نمونه‌های صحیح تشخیص داده شده توسط الگوریتم را نشان می‌دهند و مجموع عناصر روی قطر اصلی، برابر تعداد کل نمونه‌های صحیح تشخیص داده شده می‌باشند. همچنین، برای به‌دست آوردن بازده یک الگوریتم طبقه‌بندی کافی است مجموع عناصر اصلی را بر مجموع کل عناصر ماتریس تقسیم کنیم، که در شکل (۶) راندمان و صحت برای داده‌های اعتبارسنجی و تست مشاهده می‌شود.

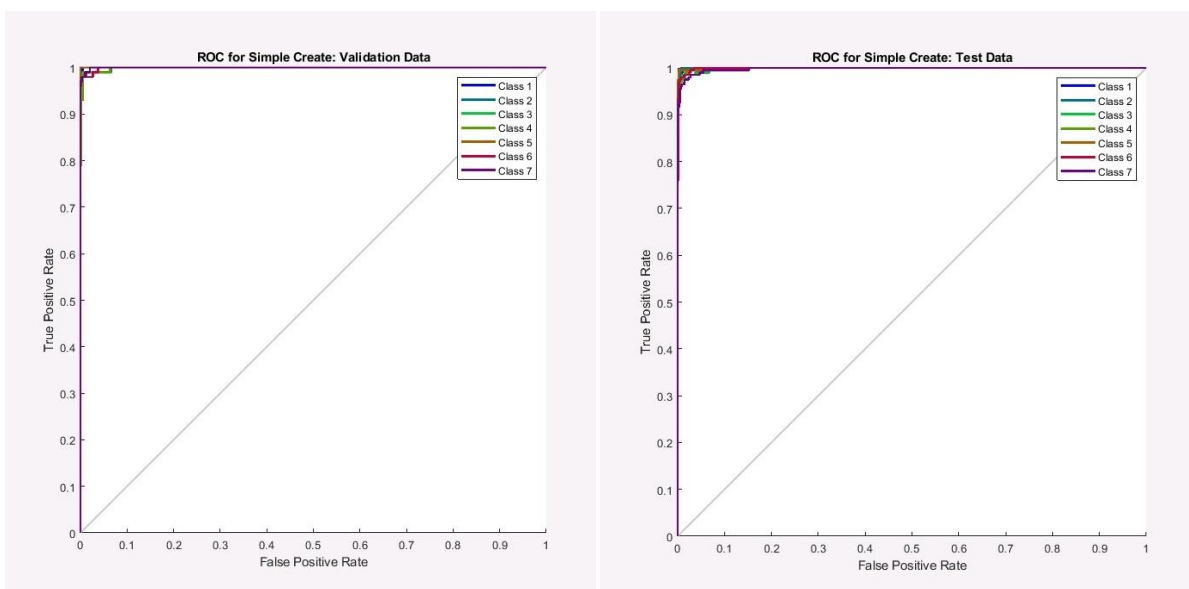
<sup>3</sup> Area under the ROC curve

<sup>1</sup> Confusion Matrix

<sup>2</sup> Receiver Operating Characteristics



شکل ۶- ماتریس اغتشاش مربوط به داده‌های اعتبارسنجی و تست



شکل ۷- نمودار ROC مربوط به داده‌های اعتبارسنجی و تست

جدول ۲- مقادیر AUC مربوط به داده‌های اعتبارسنجی و تست

	داده‌ها	کلاس ۱	کلاس ۲	کلاس ۳	کلاس ۴	کلاس ۵	کلاس ۶	کلاس ۷
AUC	تست	۱/۰۰۰۰	۰/۹۹۹۹	۰/۹۹۹۴	۰/۹۹۸۸	۰/۹۹۹۹	۰/۹۹۹۵	۰/۹۹۹۷
	اعتبارسنجی	۱/۰۰۰۰	۰/۹۹۹۹	۰/۹۹۹۱	۰/۹۹۸۴	۰/۹۹۸۴	۱/۰۰۰۰	۱/۰۰۰۰

### ۵- نتیجه‌گیری

تشخیص آسیب‌های شبکه فاضلاب می‌تواند نقش به‌سزایی در طول عمر و نظارت بر شبکه‌های فاضلاب ایفا کند. به همین دلیل، در این مقاله یک روش هوشمند برای شناسایی آن‌ها براساس شبکه‌های عصبی کانولوشن ارائه شد. بر طبق

این روش هوشمند، تصاویر مستخرج از آسیب‌های شبکه فاضلاب در سطح کشور که توسط ربات‌های ویدئومتری شبکه فاضلاب تهیه شده بود، توسط یک معماری عمیق پیشنهادی طبقه‌بندی شدند. این طبقه‌بندی شامل دسته‌های تصاویر ترک، شکاف، شکستگی، جابجایی در

توجه به زمان اجرا، روش پیشنهادی نمی‌تواند برای برخط بودن مناسب باشد، اما انتظار می‌رود که استفاده از سیستم سخت افزاری قوی می‌تواند به تحقق آن کمک کند تا بتوان به همراه یک سیستم کنترل مقاوم، جهت هدایت خودکار یک ربات ویدئومتری شبکه فاضلاب و مشخص کردن مسیرهای بحرانی شبکه فاضلاب از آن استفاده نمود.

دستاوردهای این پژوهش نیز عبارتند از:

۱. دستیابی به دقت ۹۸ درصد که در طبقه‌بندی آسیب‌های شبکه و در مقایسه با سایر روش‌ها، دقت خوبی به شمار می‌رود.
۲. زمان اجرای نسبتاً کم معماری پیشنهادی (۹۱ دقیقه) در مقایسه با سایر معماری‌های معتبر در یادگیری عمیق در یک بستر سخت‌افزاری یکسان.

محل اتصال، فروریزش، تغییرشکل و سوراخ در شبکه فاضلاب بود که صحت ۹۸ درصد را به همراه داشت. نقاط قوت این مقاله را می‌توان در پنج مورد برشمرد: اول اینکه این روش برای اولین بار برای طبقه‌بندی تصاویر آسیب‌های شبکه فاضلاب به کار گرفته شده است که نیاز به حضور نیروی متخصص جهت ویدئومتری شبکه فاضلاب را مرتفع می‌کند. مورد دوم معماری عمیق پیشنهادی در مقایسه با سایر معماری‌های عمیق از پیچیدگی بسیار کمتری برخوردار است. سوم در عین سادگی منجر به صحت بیشتری نسبت به سایر روش‌های معرفی شده در مطالعات پیشین و سایر معماری‌های عمیق معتبر شده است. مورد چهارم، به زمان اجرای کمتر نسبت به سایر روش‌ها مربوط می‌شود. پنجمین و آخرین نقطه قوت این مقاله، اگرچه با

## مراجع

- [۱] جواد لشکری زاده و سید محمود حسینی، "رتبه بندی آسیب پذیری فاضلاب‌ها جهت تدوین برنامه نگهداری و بازسازی شبکه فاضلاب شهری با استفاده از روش SAW"، نهمین کنگره مهندسی عمران، ۲۱ و ۲۲ اردیبهشت ماه ۱۳۹۵ دانشگاه فردوسی مشهد، مشهد، ایران.
- [2] S. Reyna, M. Delleur, W. Jacques, J.A. Vanegas, "Multi Attribute Rehabilitation of Storm or Combined Sewer System", Urban Drainage Rehabilitation Programs and Techniques, Macaitis, New York, 1994, pp 55-72.
- [3] G. Rivard, P. Depuis, "Evaluation du Comportement Hydraulique d'un Re'seaud'e'Goutexistant: Parametres et Criteres'Analyse Pour la Re'habilitation," Proc., INFRA, 2000.
- [4] S. Bennis, J. Bengassem, P. Lamarre, "Hydraulic Performance Index of a Sewer Network", Journal of Hydraulic Engineering, Vol. 129, 2003, pp. 504-510.
- [5] A. Cardoso, V. Prigiobbe, M. Giulianelli, E. Baer, J. Benedittis, S.T. Coelho, "Assessing the Impact of Infiltration and Exfiltration in Sewer Systems Using Performance Indicators: Case Studies of the APUSS Project", Proceeding of International Conference on Urban Drainage, Copenhagen, Denmark, August 21-26, 2005.
- [6] F. Chughtai, T. Zayed, "Sewer Pipeline Operational Condition Prediction Using Multiple Regression", Journal of Pipeline Engineering, ASCE, Vol. 1, 2007, pp. 1-11.
- [7] J. Bengassem, S. Bennis, "Fuzzy Expert System for Sewer Networks Diagnosis", Proc. of International Conference on Decision Making in Urban and Civil Engineering, Lyon, France, 2000.
- [۸] سپیده سادات مدنی تنکابنی، و مسعود تابش، "بررسی شاخص عملکرد هیدرولیکی شبکه‌های جمع‌آوری فاضلاب شهری"، پنجمین کنفرانس هیدرولیک ایران، کرمان، ۷ تا ۱۹ آبان، ۱۳۸۴.
- [9] S.M. Hosseini, A. Ghasemi, "Hydraulic Performance Analysis of Sewer Systems with Uncertain Parameters", Journal of Hydroinformatics, Vol. 14, 2012, pp. 682-696.
- [10] A. Mohan, S. Poobal, "Crack Detection Using Image Processing: A Critical Review and Analysis", Alexandria Engineering Journal, Vol. 57, 2018, pp. 787-798.
- [11] J.K. Oh, G. Jang, S. Oh, J.H. Lee, B.J. Yi, Y.S. Moon, J.S. Lee, Y. Choi, "Bridge Inspection Robot System with Machine ision", Automation in Construction, Vol. 18, 2009, pp. 929-941.
- [12] N.D. Hoang, Q.L. Nguyen, "A Novel Method for Asphalt Pavement Crack Classification Based on Image Processing and Machine Learning, Engineering with Computers", Vol. 35, 2019, pp. 487-498.
- [13] I. Goodfellow, Y. Bengio, A. Courville, "Deep Learning", MIT Press, 2016.
- [14] N. Dwivedi, D.K. Singh, "Review of Deep Learning Techniques for Gender Classification in Images", Harmony Search and Nature Inspired Optimization Algorithms, Springer, 2019, pp. 1089-1099.

[15] V. Podvezko, "The Comparative Analysis of MCDM Methods SAW and COPRAS", Journal of Engineering Economics, Vol. 22, 2011, pp. 134-146.

[۱۶] راضیه راستگو، کورش کیانی، "شناسایی چهره با استفاده از تنظیم دقیق شبکه های کانولوشنی عمیق و رویکرد یادگیری انتقالی"، مجله مدل سازی در مهندسی، دوره ۱۷، شماره ۵۸، پاییز ۱۳۹۸، صفحه ۱۰۳-۱۱۱.

[۱۷] علی سلیمانی ایوری، محمد رضا فدوی امیری، حسین مروی، "تولید سیگنال مصنوعی زلزله به کمک مدلی جدید در فشرده سازی و آموزش شبکه هایعصبی مصنوعی"، مجله مدل سازی در مهندسی، سال ۱۴، شماره ۴۶، پاییز ۱۳۹۵، صفحه ۷۵-۸۵.

[۱۸] علی نظری، "مدلسازی انرژی ضربه ی فولادهای مرتبه ای با استفاده از شبکه های عصبی مصنوعی"، مجله مدل سازی در مهندسی، دوره ۱۴، شماره ۴۵، تابستان ۱۳۹۵، صفحه ۱۴۵-۱۶۲.

[19] Y. Xie, L. Ning, M. Wang, C. Li, "Image Enhancement Based on Histogram Equalization", Journal of Physics Conference Series, IOP Publishing, Vol. 1314, 2019, pp. 012161.

[20] W. Nawaz, S. Ahmed, A. Tahir, H.A. Khan, "Classification of Breast Cancer Histology Images Using Alexnet", International Conference Image Analysis and Recognition, Springer, 2018, pp. 869-876.

[21] M.K. Kim, "Contactless Palmprint Identification Using the Pretrained VGGNet Model", Journal of Korea Multimedia Society, Vol. 21, 2018, 1439-1447.

[22] M. Al-Qizwini, I. Barjasteh, H. Al-Qassab, H. Radha, "Deep Learning Algorithm for Autonomous Driving Using Googlenet", IEEE Intelligent Vehicles Symposium (IV), IEEE, 2017, pp. 89-96.