



## *Applications of Artificial Neural Network and Deep Learning in Damage Detection and Structural Health Monitoring - a review study*

### **Abstract**

In recent years, Structural Health Monitoring (SHM) systems have been widely installed in various civil infrastructures to monitor the health status of structures and detect structural damage or abnormalities through long-term monitoring of structures. Conventional data analysis methods face challenges such as environmental noise, large amount of measurement data, computational complexity, etc., which severely limit the widespread application of SHM technology. In recent years, with the rapid development of computing hardware and image acquisition equipment, deep learning-based data processing methods provide a new channel for mining the huge data of a SHM system, towards autonomous, accurate and robust processing of monitoring information. This paper provides an overview of deep learning-based SHM, including a brief summary of the history of deep learning development, applications of deep learning-based data processing methods in SHM.

Keywords: Artificial neural network, deep learning, damage detection, structural health monitoring.



## کاربردهای شبکه عصبی مصنوعی و یادگیری عمیق در شناسایی آسیب و پایش سلامت سترکچرها - مطالعه مروری

عباس محبی<sup>۱</sup>، سید مهدی موسوی<sup>۲</sup>

### چکیده

در سال‌های اخیر، سیستم‌های پایش سلامت سترکچرها<sup>۳</sup> (SHM) بصورت گسترده در زیربناهای مختلف مدنی برای بررسی وضعیت صحت سترکچرها و تشخیص آسیب سترکچری یا غیرطبیعی بودن آنها از طریق نظارت طولانی مدت بر روی سترکچرها نصب شده‌اند. شیوه‌های مرسوم تحلیل معلومات با چالش‌های سروصدای محیطی، حجم معلومات اندازه‌گیری، پیچیدگی محاسبه، و غیره روبرو هستند و آنها کاربرد فراگیر تکنالوژی SHM را به شدت محدود می‌سازد. در سال‌های اخیر، با پیشرفت سریع سخت افزار محاسباتی و تجهیزات اکتساب تصویر، شیوه پروسس معلومات مبتنی بر یادگیری عمیق یک کانال جدیدی را برای حفر معلومات عظیم از یک سیستم SHM، به سمت پروسس خودمختار، دقیق و قوی معلومات نظارت فراهم می‌سازد. این مقاله یک مرور را در مورد SHM مبتنی بر یادگیری عمیق از جمله یک خلاصه مختصر از تاریخچه توسعه یادگیری عمیق، کاربردهای شیوه‌های پروسس داده‌های مبتنی بر یادگیری عمیق در SHM از انواع مختلف ارائه می‌دهد  
واژگان کلیدی: شبکه عصبی مصنوعی، یادگیری عمیق، شناسایی آسیب، پایش سلامت سترکچرها.

<sup>۱</sup>. استاد پوهنچی کامپیوتر ساینس دانشگاه خاتم النبیین؛ ab.mohebbi@knu.edu.af

<sup>۲</sup>. استاد پوهنچی انجنیری دانشگاه کاتب؛ s.m.mousavi@kateb.edu.af

<sup>۳</sup>. Structural Health Monitoring

انجینیری سترکچر شامل تجزیه و تحلیل سترکچر و دیزاین آن در برابر بارهای وارده می‌باشد. برای سیستم‌های سترکچری پیچیده تحت بارهای شدید که در آن سترکچر رفتار بسیار غیرخطی از خود نشان می‌دهند، استفاده از روش‌های تحلیل و دیزاین سترکچری نیازمند یک فرآیند زمان‌بر است و به نوعی در عمل بسیار پیچیده و دوشوار خواهد بود. در این مورد، شبکه‌های عصبی و یادگیری عمیق می‌توانند یک جایگزین امیدوارکننده برای صرفه جویی در زمان انجام تحلیل، ارائه دهد. یکی از اولین کاربردهای شبکه عصبی مصنوعی در انجینیری سترکچر توسط عادل‌ی و یه [۱] در سال ۱۹۸۹ برای دیزاین گادرهای فولادی انجام شد [۲]. از آن زمان، الگوریتم شبکه عصبی مصنوعی و یادگیری عمیق با موفقیت در بسیاری از کارهای پیشگام در انجینیری سترکچر از جمله تحلیل و دیزاین سترکچر [۳]، شناسایی آسیب سترکچرها [۴]، پایش سلامت سترکچرها (SHM) [۵]، منحنی‌های شکنندگی [۶-۹] استفاده شده است. هدف از این مقاله، بررسی برخی از ویژگی‌های شبکه‌های عصبی و یادگیری عمیق و کاربرد آن در در شناسایی آسیب و پایش سلامت سترکچرها است.


## ۱. پیشینه تحقیق

### ۱-۱. شبکه عصبی مصنوعی

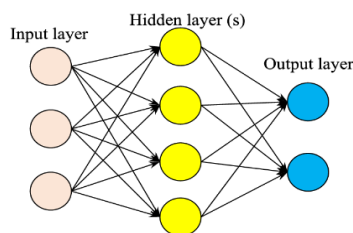
یک ANN که ساختاری شبیه به مغز انسان دارد از نورون‌های مصنوعی که به عنوان واحدها یا گره‌ها نیز شناخته می‌شوند، تشکیل شده است. این گره‌ها به طور کامل به هم متصل شده و در سه لایه مختلف چیده شده‌اند که در شکل ۱ نشان داده شده است. لایه ورودی داده‌های ورودی  $x$  را دریافت می‌کند، در حالی که لایه خروجی نتایج پیش بینی شده  $y$  شبکه را نشان می‌دهد. ساندویچ بین لایه‌های ورودی و خروجی یک یا چند لایه پنهان از واحدهای محاسباتی است (شکل ۲) که محاسبات اصلی ریاضی را روی داده‌های ورودی انجام می‌دهد. هنگامی که یک ANN با دو یا چند لایه پنهان طراحی می‌شود، به آن پرسپترون چندلایه یا یادگیری عمیق (DL) می‌گویند [۱۰، ۱۱]. رفتار هر واحد نورون با وزن‌هایی که به آن اختصاص داده می‌شود، تعریف می‌شود. هنگامی که داده‌های  $x_i$  به لایه ورودی وارد می‌شوند، در وزن‌های مربوطه  $w_i$  ضرب می‌شوند. سپس، از یک تابع انتقال برای محاسبه مجموع وزنی ورودی به اضافه یک بایاس  $b$  استفاده می‌شود که به تدریج تنظیم می‌شود تا اختلاف بین خروجی‌های پیش بینی شده و واقعی را به حداقل برساند. در نهایت مقدار تابع انتقال از طریق تابع فعال سازی  $f$  ارسال می‌شود تا بررسی شود که آیا گره باید داده‌ها را به لایه خروجی ارسال کند یا خیر. هنگامی که یک ANN آموزش داده می‌شود، مقادیر تصادفی وزن‌ها به همه گره‌ها اختصاص داده می‌شود. هنگامی که تابع فعال سازی مقدار پیش بینی شده  $y$  را به لایه خروجی منتقل می‌کند، از یک تابع خطا برای محاسبه تفاوت بین خروجی‌های پیش بینی شده و واقعی استفاده می‌شود. بر اساس نتیجه، مدل



ANN وزن تمام گره‌های خود را برای به حداقل رساندن خطا تنظیم می‌کند. چنین فرآیند آموزشی که به عنوان پس انتشار [۱۱] شناخته می‌شود تا زمانی که شرط همگرایی برآورده شود، تکرار می‌شود. تعدادی هایپر پارامتر وجود دارد که باید هنگام آموزش یک مدل ANN بهینه شوند زیرا فرآیند یادگیری و آموزش شبکه را کنترل می‌کنند. آن‌ها شامل انتخاب‌های معماری یک شبکه عصبی مصنوعی (یعنی تعداد لایه‌های پنهان استفاده‌شده، تعداد گره‌ها در هر لایه پنهان، و نوع توابع فعال‌سازی) و متغیرهای آموزشی (یعنی نرخ انحراف، تعداد دوره‌ها، تکانه، و اندازه دسته) می‌باشند. افزایش تعداد لایه‌های پنهان و گره‌های پنهان می‌تواند دقت شبکه را افزایش دهد، اما باعث هزینه محاسباتی می‌شود. تابع فعال‌سازی برای محاسبه غیر خطی بودن مدل‌ها استفاده می‌شود. نرخ یادگیری تعیین می‌کند که مدل ANN با چه سرعتی پارامترهای خود را به روز می‌کند. استفاده از نرخ بالای یادگیری باعث سرعت بخشیدن به یادگیری می‌شود، اما ممکن است نتواند همگرا شود. Epoch تعداد تکرارها را برای مجموعه داده آموزشی کنترل می‌کند، در حالی که حرکت برای انتخاب جهت مرحله بعدی از مرحله قبل استفاده می‌شود که می‌تواند به جلوگیری از نوسانات کمک کند. چنین پارامترهای فوق در طول مراحل آزمایش و اعتبار سنجی تنظیم می‌شوند.



شکل ۲: واحد محاسبات شبکه عصبی

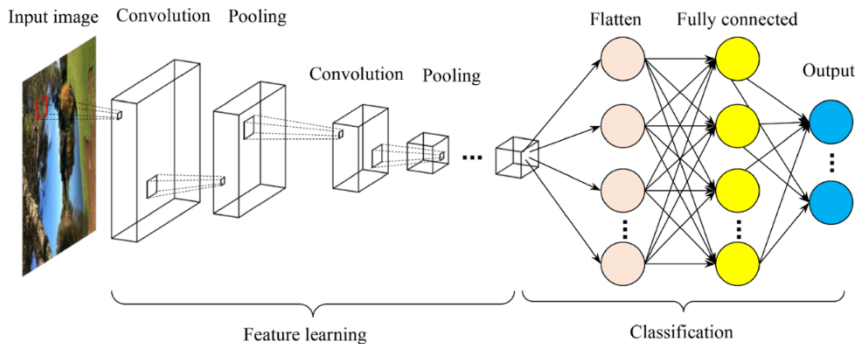


شکل ۱: معماری شبکه عصبی

## ۲-۱. شبکه عصبی عمیق

الگوریتم‌های زیادی در شبکه عصبی عمیق وجود دارد که در اینجا به پر کاربردترین آن‌ها یعنی CNN یا همان شبکه عصبی کانولوشنی می‌باشد؛ پرداخته خواهد شد. این الگوریتم برای اولین بار در دهه ۱۹۸۰ توسط یان لیکون، یک محقق علوم کامپیوتر فرانسوی که یکی از نسخه‌های اولیه معماری‌های CNN را برای تشخیص دیجیتلی دست نویس به نام LeNet [۱۲] ساخت، معرفی گردید. نظریه اساسی CNN ایجاد یک شبکه است که در آن هر لایه می‌تواند معلومات را از لایه‌های قبلی به معلومات پیچیده‌تر تبدیل و به لایه‌های بعدی منتقل کند. طوری که در شکل ۳ نشان داده شده است، یک CNN بر اساس دو بلاک اساسی ساخته شده است: بلاک یادگیری ویژگی و بلاک طبقه بندی. یادگیری ویژگی که از تعدادی از لایه‌های

متناوب پیچیدگی و استخراج تشکیل شده است برای استخراج و یادگیری ویژگی از تصویر ورودی استفاده می‌شود. ویژگی استخراج شده یا یاد گرفته شده بعد از طریق بلاک طبقه بندی طبقه بندی می‌شود. معماری‌های مختلف CNN همچنان برای بهبود عملکرد CNN در کاربردهای مختلف بوجود آمده‌اند. قابل توجه در میان آنها AlexNet، LeNet، VGG و ResNet می‌باشد [۱۴، ۱۳]. در متن SHM، CNN بصورت گسترده برای تشخیص ترک در سترکچرها بر اساس شیوه‌های طبقه بندی تصویر یا تخنیک‌های بخش بندی استفاده شده است. میتود طبقه بندی تصویر به عوض سطح پیکسل که در میتود تقسیم بندی استفاده می‌شود، می‌تواند ترک را در سطح تصویر تشخیص دهد.



شکل ۳: معماری CNN معمولی

## ۲. کاربردهای شبکه عصبی و یادگیری عمیق در انجیر سترکچر

### ۲-۱. شناسایی آسیب و پایش سلامت سترکچرها

بازرسی خسارت سترکچری برای ایمنی سترکچرهای در حال خدمت ضروری است و از این رو بسیاری از گروه‌های تحقیقاتی از روش‌های مبتنی بر یادگیری عمیق برای انجام تشخیص خسارت در سترکچرهای مختلف استفاده کرده‌اند. کاربردهای مطالعات مبتنی بر یادگیری عمیق جمع آوری و در جدول ۱ لیست شده است. مطالعات مبتنی بر تصویر و CNN متعدد وجود داشته است زیرا انواع زیادی از آسیب‌های سازه‌ای قابل مشاهده است. برای غلبه بر کمبود مجموعه معلومات تصویر حاشیه‌نویسی شده برای مقاصد مشخص بازرسی، یادگیری انتقال توسط آموزش قبلی با تعداد زیادی از مجموعه معلومات تصویر منبع باز و تنظیم دقیق با تعداد کمی از تصاویر جمع آوری شده تطبیق شده است. همچنان، تخنیک‌های مرسوم افزایش معلومات و همچنان شیوه‌های مبتنی بر یادگیری عمیق مانند GAN برای بزرگ کردن ست‌های معلومات استفاده شده است. برای تشخیص، بومی سازی و کمیت کردن آسیب‌های سترکچری مانند شکستن و ترک‌ها، شیوه‌های Faster R-CNN و FCN برای موقعیت‌یابی دقیق آسیب‌ها روی دست گرفته شدند و تخنیک‌های پروسس تصویر (IPTs) برای بدست آوردن پارامترهای


آسیب بکار برده شده‌اند. بر علاوه تصاویر، معلومات سلسله زمانی مانند شتاب و جابجایی برای تشخیص تخریب در آن مطالعات استفاده شده است. برای پروسس کردن معلومات سلسله زمانی، شبکه‌های رمزگذار خودکار و D-CNN توسط چندین گروه تحقیقاتی بوجود آمدند. علاوه بر این، تبدیل کردن معلومات خام سلسله زمانی به طیف‌های فرکانس یا طیف‌های فرکانس زمانی فضایی برای پروسس بیشتر نیز در حال بررسی است.

جدول ۱: کاربرد یادگیری عمیق در پایش سلامت سترکچرها و شناسایی آسیب

Structure type	Application	Reference	Technology
Bridge	Crack detection	Alipour <i>et al.</i> (2019)	FCN
		Dung <i>et al.</i> (2019)	VGG-16+Transfer learning
	Damage detection	Kim <i>et al.</i> (2018)	UAV+R-CNN+Transfer learning+IPT
		Sajedi and Liang (2019)	SegNet
		Bao <i>et al.</i> (2019)	Auto-encoder+Unsupervised learning
Loosened bolt detection	Duan <i>et al.</i> (2019)	CNN	
	Huynh <i>et al.</i> (2019)	R-CNN	
Concrete building	Damage state classification	Khodabandehlou <i>et al.</i> (2019)	CNN
	Crack detection	Li <i>et al.</i> (2019)	Faster R-CNN
Tunnel	Multiple damage detection	Song <i>et al.</i> (2019)	ResNet+MobileNet+CrossNet
		Huang <i>et al.</i> (2018)	FCN
	Crack detection	Gao <i>et al.</i> (2019)	Faster R-CNN+FCN
		Xue and Li (2018)	FCN+Faster R-CNN
		Cha <i>et al.</i> (2017)	CNN
Steel building	Crack detection	Dorafshan <i>et al.</i> (2018)	AlexNet+Transfer learning
		Dung and Anh (2019)	FCN+Transfer learning
		Kang and Cha (2018)	UAV+CNN
		Kim and Cho (2018)	UAV+AlexNet+Transfer learning
		Kim and Cho (2019)	Mask R-CNN
	Multiple damage detection	Ni <i>et al.</i> (2019)	GoogLeNet+ResNet
		Ni <i>et al.</i> (2019)	GoogLeNet+Transfer learning
		Yang <i>et al.</i> (2018)	VGG-19+FCN
		Ye <i>et al.</i> (2019)	FCN
		Zhang <i>et al.</i> (2019)	SegNet
Steel building	Spalling detection	Zhang <i>et al.</i> (2019)	ResNet+FCN
		Beckman <i>et al.</i> (2019)	Faster R-CNN
	Damage dataset generation	Gao <i>et al.</i> (2019)	GAN
		Gulgec <i>et al.</i> (2019)	CNN
	Damage detection	Liu and Zhang (2019)	CNN
		Pathirage <i>et al.</i> (2018)	Auto-encoder
		Yu <i>et al.</i> (2019)	CNN
	Multiple damage detection	Zhao <i>et al.</i> (2019)	VGG-16+MobileNet
		Chen and Jahanshahi (2018)	CNN+Naive Bayes
		Wu <i>et al.</i> (2019)	VGG-16+ResNet-18
Zhou <i>et al.</i> (2019)		Auto-encoder	
Abdeljaber <i>et al.</i> (2017)		1D-CNN	
Crack detection	Atha and Jahanshahi (2018)	CNN	
	Cha <i>et al.</i> (2018)	Faster R-CNN	

## ۲-۲. پل‌ها

کیم و همکاران یک شیوه مبتنی بر UAV و R-CNN را برای تشخیص ترک‌ها در پل‌های کانکریتی قدیمی پیشنهاد کرد [15]. یک R-CNN از قبل آموزش دیده توسط تصاویر ترک برای تشخیص ترک تنظیم شده بود و IPTs برای سنجش ترک‌های تشخیص شده بکار برده شد. لیانگ یک میتود مبتنی بر یادگیری عمیق سه سطحی را برای بازرسی پل‌های پس از فاجعه پیشنهاد کرد. VGG-16 برای تشخیص خرابی سطح سیستم بکار برده شد، و Faster R-



CNN و SegNet برای تشخیص آسیب سطح جزء و سطح محلی به ترتیب بکار برده شدند [16]. یک CNN کم عمق که از ابتدا آموزش دیده بود، یک VGG-16 از قبل آموزش دیده با یک طبقه بندی کننده دقیق، و یک VGG-16 از قبل آموزش دیده با یک لایه پیچشی و طبقه بندی کننده دقیق با استفاده از میزان دقت، میزان

دقت و میزان یادآوری. تصاویر خام از آزمایش‌ها و بازرسی‌های روزانه برای ایجاد مجموعه معلومات جمع آوری شد و افزایش معلومات برای کاهش تناسب بیش از حد روی دست گرفته شد. هون و همکاران یک شیوه مبتنی بر تبدیل خط R-CNN و Hough را برای تشخیص پیچ‌های شل شده اتصالات فولادی پیشنهاد کرد. یک R-CNN پانزده لایه بدون تصاویر پیچ از قبل آموزش دیده و با تصاویر پیچ تنظیم شده بود [17]. الگوریتم تبدیل خط هوف برای ارزیابی وضعیت شل شدن پیچ‌های تشخیص شده روی دست گرفته شد. علیپور و همکاران یک شیوه مبتنی بر FCN را برای تشخیص ترک‌ها برای ارزیابی ترک بازدید شده پیشنهاد کرد [18]. پنج مدل با میزان‌های مختلف نمونه‌گیری بر اساس حالت از قبل آموزش دیده آزمایش شدند. مجموعه معلومات تصویر توسط تصاویر شکاف جمع‌آوری شده در محل با حاشیه‌نویسی محتاطانه ایجاد شد و تاثیر اندازه مجموعه معلومات تحلیل شد.

## ۲-۳. تونل‌ها

ژو و لی یک چارچوب سه مرحله‌ای مبتنی بر یادگیری عمیق را برای طبقه بندی و محلی سازی آسیب‌های پوشش تونل توسعه دادند [19]. یک FCN برای استخراج نقشه‌های ویژگی تصاویر ورودی بوجود آمد، یک شبکه پیشنهاد سایت برای انتخاب ساحات مشکوک در نقشه های ویژگی بکار برده شد، و یک میتود استخراج حساس به موقعیت برای یافتن دقیق خسارات نیز بکار برده شد. هوانگ و همکاران یک شیوه دو جریان مبتنی بر FCN را برای تطبیق بخش بندی معنایی برای درزها و نشت‌ها در تونل‌ها بکار برد [20]. مقایسه عملکرد در بین شیوه پیشنهادی، یک الگوریتم رشد ساحه، و یک الگوریتم آستانه سازی تطبیقی انجام گردید. سونگ و دیگران عملکرد سه نوع مختلف DNNs را برای بخش بندی معنایی درزهای تونل مقایسه نمودند [21].

برای آموزش شبکه‌های آزمایش شده، تصاویر تونل از موقعیت‌های دنیای واقعی جمع آوری شد و یک مجموعه معلومات درز تونل با حاشیه نویسی بخش بندی معنایی ایجاد شد. گو و همکاران یک چارچوب مبتنی بر Faster R-CNN و FCN را برای تشخیص سریع و دقیق نقص‌های تونل متعدد ایجاد نمودند [22]. لی و همکاران (۲۰۱۹) یک پردازش تصویر و چارچوب مبتنی بر R-CNN را برای تشخیص ترک‌های تونل پیشنهاد نمودند که بر اساس آن یک مجموعه معلومات حاوی سه نوع ترک برای آموزش سریعتر R-CNN ساخته شد [23].



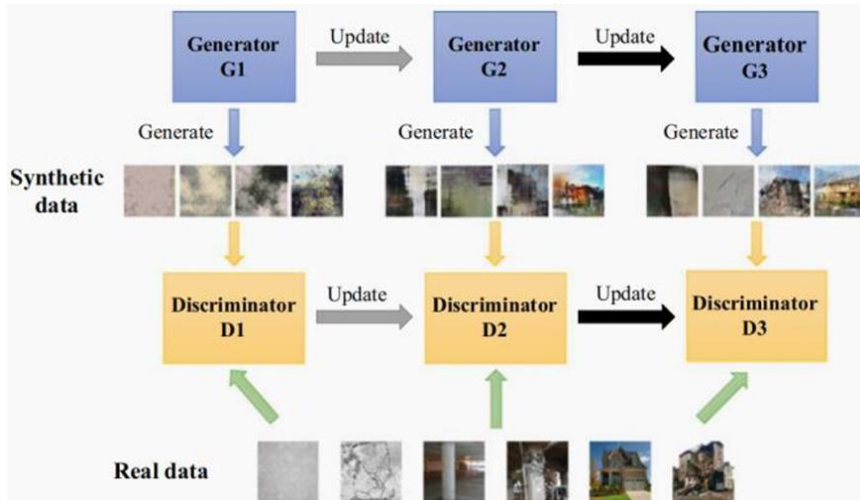
## ۲-۴. ساختمان آهن کانکرتی

ژانگ و همکاران یک FCN مبتنی بر بلاک باقیمانده را با پیچیدگی اتساع یافته برای تشخیص ترک‌های کانکرت پیشنهاد کرد. بلاک‌های باقی مانده برای استخراج ویژگی‌ها استفاده شدند و پیچیدگی‌های اتساع شده با میزان‌های مختلف اتساع برای ساحات مختلف پذیرنده انجام شدند [24]. دونگ و ان یک میتود مبتنی بر FCN را برای تشخیص ترک‌ها در سطوح کانکرتی پیشنهاد کردند. یک مدل مبتنی بر VGG-16، یک مدل مبتنی بر InceptionV3 و یک مدل مبتنی بر ResNet برای عملکردهای استخراج ویژگی برای انتخاب بهترین رمزگذار برای FCN پیشنهادی مقایسه شدند [25]. نی و همکاران یک میتود مبتنی بر GoogLeNet و ResNet را برای تشخیص ترک‌ها پیشنهاد کرد [25]. اپریتور مومنت زرنیک برای پردازش کردن تصاویر ترک که توسط میتود پیشنهادی برای سنجش ترک‌های نازک تشخیص شده بود استفاده شد. لی و همکاران یک FCN مبتنی بر DenseNet-121 را برای تشخیص نواقص کانکرت از جمله پوسته شدن، ترک‌ها و سوراخ‌ها پیشنهاد کرد [27]. یادگیری انتقال مبتنی بر مدل برای اختصاص دادن پارامترهای اولیه FCN در پروسه آموزشی روی دست گرفته شد. ژانگ و همکاران یک مدل مبتنی بر SegNet را با آگاهی از متن برای تشخیص ترک‌ها در تصاویر با اندازه‌های دلخواه پیشنهاد کرد [28]. نی و همکاران یک میتود دو مرحله‌ی مبتنی بر CNN را برای تشخیص ترک‌های سترکچری پیشنهاد کرد. گوگل نت از قبل آموزش دیده و خوب تنظیم شده برای تشخیص ترک‌ها استفاده شد و یک شبکه ترسیم ترک برای انجام ترکیب نقشه و ویژگی برای ترسیم ترک‌های پیکسل وار روی دست گرفته شد [29]. شو و همکاران یک مدل مبتنی بر R-CNN سریعتر را برای تشخیص و محلی سازی انواع مختلف آسیب‌های لرزه‌ای مانند ترک‌ها و شکاف‌ها پیشنهاد کرد. یک شبکه پیشنهادی منطقه‌ای با به اشتراک گذاشتن نقشه‌های ویژگی-های اولیه به یک Fast R-CNN ادغام شد. مجموعه معلومات تصویر توسط تصویر برداری در محل ایجاد شد و افزایش معلومات برای بزرگ کردن مجموعه معلومات روی دست گرفته شد [30].

کیم و چو یک چارچوب مبتنی بر Mask R-CNN را برای تشخیص و سنجش ترک‌های کانکرت پیشنهاد کردند. تصاویر آموزشی ترک‌های کانکرت از یک دیوار کانکرتی در محل جمع آوری شده بود و دارای ترک‌های با عرض‌های مختلف بود [31]. یی و همکاران یک FCN مبتنی بر U-Net را توسعه داد تا به طور خودکار ترک‌ها را در سطوح کانکرتی تشخیص دهد. یک مجموعه معلومات آنلاین تصاویر ترک با لیبیل‌های پیکسل وار جمع آوری شد [32]. گو و همکاران (۲۰۱۹) یک معماری مبتنی بر GAN را برای تولید تصاویر تخریب سترکچری کانکرتی برای ایجاد یک مجموعه معلومات آموزشی پیشنهاد کرد، طوریکه در شکل ۴ نشان داده شده است. یک میتود بوت استرپ کردن برای بهبود ظرفیت تولید مدل پیشنهادی روی دست گرفته شد. تصاویر مصنوعی تولید شده توسط یک نمره خود-آغاز و شاخص‌های توانایی



تعمیم ارزیابی شدند [33]. بیکمن و همکاران یک شیوه مبتنی بر کمره سریع R-CNN و عمق را برای تشخیص و سنجش پراکندگی اجزای سترکچری پیشنهاد کرد. R-CNN سریعتر توسط تصاویر پراکنده شدن در محل آموزش دیده و برای تشخیص ساحات پراکنده شدن در تصاویر بکار برده شد، و عمق پوشش توسط یک کمره عمق برای ارزیابی حجمی پوشش تشخیص شده اندازه‌گیری شد [34].



شکل ۴: تولید مجموعه معلومات مبتنی بر GAN (گو و همکارانش ۲۰۱۹)

## ۲-۵. ساختمان‌های فولادی

عبدالجابر و همکاران یک CNN یک بعدی را برای تشخیص آسیب سترکچری مبتنی بر لرزش یک سترکچر فولادی با معلومات شتاب توسعه داد [35]. ااتا و جهانشاهی دو معماری مبتنی بر CNN به نام‌های خوردگی-۵ و خوردگی-۷ را برای تشخیص خوردگی در سطوح فلزی پیشنهاد کردند [36]. عملکرد معماری‌های پیشنهادی با ZF Net، VGG-15، و VGG-16 توسط میزان دقت، میزان یادآوری و نمره F1 مقایسه شد. چن و جهانشاهی یک شیوه مبتنی بر CNN را با یک میتود ادغام معلومات نایف بایس ترکیب کردند تا درزها را در چارچوب‌های ویدیویی نیروگاه‌های هسته‌ای تشخیص دهند [37]. یک CNN برای تشخیص ترک‌ها در هر فریم ویدیویی بکار برده شد، و یک طرح تصمیم‌گیری ساده بایس برای از بین بردن وصله‌های بدون ترک استفاده شد. چا و همکاران یک میتود سریعتر مبتنی بر R-CNN را برای بازرسی بصری نواقص سترکچری بشمول ترک‌های کانکریت، خوردگی پیچ، خوردگی فولاد، و لایه برداری فولاد پیشنهاد کرد [38]. پاتیراج و دیگران یک معماری مبتنی بر رمزگذار خودکار را برای شناسایی آسیب سترکچری توسط پاسخ‌های لرزش پیشنهاد کرد. مطالعات عددی و تجربی برای تولید مجموعه معلومات برای آموزش، اعتبار سنجی و آزمایش معماری پیشنهادی انجام شد [39]. گلجک و همکاران یک شیوه مبتنی بر CNN را برای طبقه بندی



اجزای سترکچر فولادی آسیب دیده و آسیب ندیده تولید شده توسط شبیه‌سازی‌های عددی پیشنهاد کرد. برای انتخاب یک استخراج کننده ویژگی، ۵۰ CNN با میزان‌های یادگیری مختلف، لایه‌های پیچیده و کاملاً متصل آموزش دیده و مقایسه شدند. برای ساختن یک آشکارساز بومی‌سازی، یک مطالعه مقایسه‌ای مشابه بر اساس ۷۰ تنظیمات انجام شد [40]. لایو و ژانگ یک میتود مبتنی بر CNN را برای ارزیابی شرایط تخریب برای ارزیابی پس از خطر اعضای فیوز فولادی سترکچری توسعه دادند. تصاویر کانتورهای فشار پلاستیکی تجمعی که توسط تحلیل عددی و مطالعه تجربی تولید شده اند برای آموزش و اعتبار سنجی میتود پیشنهادی روی دست گرفته شده‌اند [41]. ژو و همکاران یک شبکه مبتنی بر رمزگذاری خودکار را توسط هیستوگرام سختی آموزش داد تا شناسایی آسیب را از طریق تخریب سختی تطبیق کند [42].

یو و همکاران یک چارچوب عمیق مبتنی بر CNN را برای تشخیص آسیب یک سترکچر فولادی هوشمند با جدا کننده‌ها پیشنهاد کرد. مجموعه معلومات آموزشی توسط شبیه‌سازی عددی مدل‌های سترکچری فولادی بوجود آمد [43]. وو و همکاران یک میتود مبتنی بر الگوریتم هرس کردن DNN و برای تشخیص آسیب‌های سترکچری پیشنهاد کرد. VGG-16 و ResNet-18 توسط یک سرور با عملکرد بالا آموزش دیده بودند و مجموعه معلومات آسیب حاوی تصاویر ترک و خوردگی بود که با دقت از زیرساخت‌های ساحوی جمع آوری شده بودند [44]. ژائو و همکاران (۲۰۱۹) یک میتود مبتنی بر VGG-16 را برای تشخیص وضعیت شل شدن پیچ برای سترکچرهای فولادی پیشنهاد کرد. بعد از آموزش، اعتبار سنجی و آزمایش، از یک MobileNet برای تطبیق پروسه تشخیص با یک موبایل هوشمند استفاده شد [45].

### نتیجه‌گیری

این مقاله مروری بر تحقیقات اخیر و توسعه یادگیری عمیق برای SHM سترکچرها ارائه می‌کند. بر اساس بررسی جامع رویکردهای مبتنی بر یادگیری عمیق، موارد کاربرد، مسائل چالش برانگیز، می‌توان نتیجه‌گیری‌های زیر را انجام داد:


- توسعه یادگیری عمیق شامل معماری‌های جدید، آموزش کارآمد و الگوریتم‌های اعتبارسنجی، چارچوب‌های جدید و غیره، رویکردهای پردازش داده‌های آسان‌تر و قدرتمندتری را برای محققان و انجمنیان فراهم می‌کند تا با مسائل حرفه‌ای مقابله کنند.
- کاربردهای اصلی رویکردهای مبتنی بر یادگیری عمیق برای SHM سترکچرها، تشخیص آسیب سترکچری و ارزیابی وضعیت سترکچر است. در میان آنها، کاربردهای مبتنی بر چشم انداز توجه زیادی را از سوی جامعه پژوهشی جلب می‌کند.
- غلبه بر چالش‌ها در کاربردهای رویکردهای مبتنی بر یادگیری عمیق برای SHM مستلزم مجموعه‌ای از مجموعه داده‌های خاص، توسعه معماری‌های جدید برای

عملکرد بهتر، و استراتژی‌های آموزشی جدید برای رفع مسائلی مانند برازش بیش از حد و ناپدید شدن گرادیان است.

ثابت شده است که رویکردهای مبتنی بر یادگیری عمیق ارزش قابل توجهی برای مقابله با انواع مختلف مشکلات SHM دارند. با توسعه الگوریتم‌ها و چارچوب‌های جدید، ایجاد مجموعه داده‌های کافی و بهبود قدرت محاسباتی، رویکردهای مبتنی بر یادگیری عمیق به طور قابل توجهی پیشرفت‌ها را در تحقیقات و کاربردهای SHM ارتقا می‌دهند.




- [1] Adeli H, Yeh C. Perceptron learning in engineering design. *Comput-Aided Civ Infrastruct Eng* 1989;4:247–56.
- [2] Adeli H. Neural networks in civil engineering: 1989–2000. *Comput Aided Civ Infrastruct Eng* 2001;16:126–42.
- [3] Hajela P, Berke L. Neurobiological computational models in structural analysis and design. *Comput Struct* 1991;41:657–67.
- [4] Wu X, Ghaboussi J, Garrett JH. Use of neural networks in detection of structural damage. *Comput Struct* 1992;42:649–59.
- [5] Stephens JE, VanLuchene RD. Integrated assessment of seismic damage in structures. *Comput Aided Civ Infrastruct Eng* 1994;9:119–28.
- [6] Berke L, Patnaik SN, Murthy PLN. Optimum design of aerospace structural components using neural networks. *Comput Struct* 1993;48:1001–10.
- [7] Iranmanesh A, Kaveh A. Structural optimization by gradient-based neural networks. *Int J Numer Meth Eng* 1999;46:297–311.
- [8] Kaveh A, Gholipour Y, Rahami H. Optimal design of transmission towers using genetic algorithm and neural networks. *Int J Space Struct* 2008;23:1–19.
- [9] Goh ATC. Prediction of ultimate shear strength of deep beams using neural networks. *ACI Struct J* 1995;92:28–32.
- [10] Schmidhuber J. Deep learning in neural networks: an overview. *Neural Netw* 2015;61:85–117.
- [11] LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature* 2015;521:436–44.
- [12] Le Cun Y, Bottou L, Bengio Y, Haffner P. Gradient-based learning applied to document recognition. *Proc IEEE* 1998;86:1–46.
- [13] Khan A, Sohail A, Zahoora U, Qureshi AS. A survey of the recent architectures of deep convolutional neural networks. *Artif Intell Rev* 2020;53:5455–516.
- [14] Alzubaidi L, Zhang J, Humaidi AJ, Al-Dujaili A, Duan Y, Al-Shamma O, et al. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data* 2021;8:53.
- [15] Kim, I.H., Jeon, H., Baek, S.C., Hong, W.H. and Jung, H.J. (2018), “Application of crack identification techniques for an aging concrete bridge inspection using an unmanned aerial vehicle”, *Sensors*, 18(6), 1881. DOI: 10.3390/S18061881.
- [16] Liang, X. (2019), “Image-based post-disaster inspection of reinforced concrete bridge systems using deep learning with Bayesian optimization”, *Comput.-Aided Civil Infrastruct. Eng.*, 34(5), 415-430. DOI: 10.1111/mice.12425.
- [17] Huynh, T.C., Park, J.H., Jung, H.J. and Kim, J.T. (2019), “Quasi autonomous bolt-loosening detection method using vision based deep learning and image processing”, *Automat. Constr.*, 105, UNSP 102844. DOI: 10.1016/J.Autcon.2019.102844.



- [18] Alipour, M., Harris, D.K. and Miller, G.R. (2019), "Robust pixel level crack detection using deep fully convolutional neural networks", *J. Comput. Civil. Eng.*, 33(6), 04019040. DOI: 10.1061/(Asce)Cp.1943-5487.0000854.
- [19] Xu, Y., Wei, S.Y., Bao, Y.Q. and Li, H. (2019), "Automatic seismic damage identification of reinforced concrete columns from images by a region-based deep convolutional neural network", *Struct. Control. Health Monit.*, 26(3), e2313. DOI: 10.1002/Stc.2313.
- [20] Huang, H.W., Li, Q.T. and Zhang, D.M. (2018), "Deep learning based image recognition for crack and leakage defects of metro shield tunnel", *Tunn. Undergr. Sp. Tech.*, 77, 166-176. DOI: 10.1016/j.tust.2018.04.002.
- [21] Song, Q., Wu, Y.Q., Xin, X.S., Yang, L., Yang, M., Chen, H.M., Liu, C., Hu, M.J., Chai, X.S. and Li, J.C. (2019), [21] "Real-time tunnel crack analysis system via deep learning", *IEEE Access*, 7, 64186-64197. DOI: 10.1109/Access.2019.2916330.
- [22] Gao, Y.Q., Kong, B.Y. and Mosalam, K.M. (2019), "Deep leaf bootstrapping generative adversarial network for structural image data augmentation", *Comput.-Aided Civil Infrastruct. Eng.*, 34(9), 755-773. DOI: 10.1111/mice.12458.
- [23] Li, S.Y., Zhao, X.F. and Zhou, G.Y. (2019), "Automatic pixel-level multiple damage detection of concrete structure using fully convolutional network", *Comput.-Aided Civil Infrastruct. Eng.*, 34(7), 616-634. DOI: 10.1111/mice.12433.
- [24] Zhang, X.X., Rajan, D. and Story, B. (2019), "Concrete crack detection using context-aware deep semantic segmentation network", *Comput.-Aided Civil Infrastruct. Eng.*, DOI: 10.1111/mice.12477.
- [25] Dung, C.V. and Anh, L.D. (2019), "Autonomous concrete crack A review on deep learning-based structural health monitoring of civil infrastructures detection using deep fully convolutional neural network", *Automat. Constr.*, 10.1016/j.autcon.2018.11.028. 99, 52-58. DOI: 10.1016/j.autcon.2018.11.028.
- [26] Ni, F.T., Zhang, J. and Chen, Z.Q. (2019), "Zernike-moment measurement of thin-crack width in images enabled by dual scale deep learning", *Comput.-Aided Civil Infrastruct. Eng.*, 34(5), 367-384. DOI: 10.1111/mice.12421.
- [27] Li, S.Y., Zhao, X.F. and Zhou, G.Y. (2019), "Automatic pixel-level multiple damage detection of concrete structure using fully convolutional network", *Comput.-Aided Civil Infrastruct. Eng.*, 34(7), 616-634. DOI: 10.1111/mice.12433.
- [28] Zhang, K.G., Cheng, H.D. and Zhang, B.Y. (2018), "Unified approach to pavement crack and sealed crack detection using preclassification based on transfer learning", *J. Comput. Civil. Eng.*, 32(2), 5487.0000736.
- [29] Ni, F.T., Zhang, J. and Chen, Z.Q. (2019), "Pixel-level crack delineation in images with convolutional feature fusion", *Struct. Control. Health Monit.*, 26(1), e2286. DOI: 10.1002/Stc.2286.
- [30] Xu, Y., Wei, S.Y., Bao, Y.Q. and Li, H. (2019), "Automatic seismic damage identification of reinforced concrete columns from



- images by a region-based deep convolutional neural network”, *Struct. Control. Health Monit.*, 26(3), e2313. DOI: 10.1002/Stc.2313.
- [31] Kim, B. and Cho, S. (2019), “Image-based concrete crack assessment using mask and region-based convolutional neural network”, *Struct. Control. Health Monit.*, 26(8), e2381. DOI: 10.1002/Stc.2381.
- [32] Ye, X.W., Jin, T. and Chen, P.Y. (2019). “Structural crack detection using deep learning-based fully convolutional networks”, *Adv. Struct. Eng.*, DOI: 10.1177/1369433219836292.
- [33] Gao, Y.Q., Kong, B.Y. and Mosalam, K.M. (2019), “Deep leaf bootstrapping generative adversarial network for structural image data augmentation”, *Comput.-Aided Civil Infrastruct. Eng.*, 34(9), 755-773. DOI: 10.1111/mice.12458.
- [34] Beckman, G.H., Polyzois, D. and Cha, Y.J. (2019), “Deep learning-based automatic volumetric damage quantification using depth camera”, *Automat. Constr.*, 99, 114-124. DOI: 10.1016/j.autcon.2018.12.006.
- [35] Abdeljaber, O., Avci, O., Kiranyaz, S., Gabbouj, M. and Inman, D.J. (2017), “Real-time vibration-based structural damage detection using networks”, *J. one-dimensional convolutional neural Sound. Vib.*, 388, 154-170. DOI: 10.1016/j.jsv.2016.10.043.
- [36] Atha, D.J. and Jahanshahi, M.R. (2018), “Evaluation of deep learning approaches based on convolutional neural networks for corrosion detection”, *Struct. Health. Monit.*, 17(5), 1110-1128. DOI: 10.1177/1475921717737051.
- [37] Chen, F.C. and Jahanshahi, M.R. (2018), “NB-CNN: deep learning-based crack detection using convolutional neural network and naive bayes data fusion”, *IEEE T. Ind. Electron.*, 65(5), 4392-4400. DOI: 10.1109/Tie.2017.2764844.
- [38] Cha, Y.J., Choi, W., Suh, G., Mahmoudkhani, S. and Buyukozturk, O. (2018), “Autonomous structural visual inspection using region-based deep learning for detecting multiple damage types”, *Comput.-Aided Civil Infrastruct. Eng.*, 33, 731-747. DOI: 10.1111/mice.12334.
- [39] Pathirage, C.S.N., Li, J., Li, L., Hao, H., Liu, W.Q. and Ni, P.H. (2018), “Structural damage identification based on autoencoder neural networks and deep learning”, *Eng. Struct.*, 172, 13-28. DOI: 10.1016/j.engstruct.2018.05.109.
- [40] Gulgec, N.S., Takac, M. and Pakzad, S.N. (2019), “Convolutional neural network approach for robust structural damage detection and localization”, *J. Comput. Civil. Eng.*, 33(3), 04019005. DOI: 10.1061/(Asce)Cp.1943-5487.0000820.
- [41] Liu, H. and Zhang, Y.F. (2019), “Image-driven structural steel damage condition assessment method using deep learning algorithm”, *Measurement*, 133, 168-181. DOI: 10.1016/j.measurement.2018.09.081.
- [42] Zhou, C., Chase, J.G. and Rodgers, G.W. (2019), “Degradation evaluation of lateral story stiffness using HLA-based deep learning networks”, *Adv. Eng. Inform.*, 39, 259-268. DOI: 10.1016/j.aei.2019.01.007.



- [43] Yu, Y., Wang, C.Y., Gu, X.Y. and Li, J.C. (2019), "A novel deep learning-based method for damage identification of smart building structures", *Struct. Health Monit.*, 18(1), 143-163. DOI: 10.1177/1475921718804132.
- [44] Wu, R.T. and Jahanshahi, M.R. (2019), "Deep convolutional neural network for structural dynamic response estimation and system identification", *J. Eng. Mech.*, 145(1), 04018125. DOI: 10.1061/(Asce)Em.1943-7889.0001556.
- [45] Zhao, X.F., Zhang, Y. and Wang, N.N. (2019), "Bolt loosening angle detection technology using deep learning", *Struct. Control. Health Monit.*, 26(1), e2292. DOI: 10.1002/Stc.2292.

