

# A Review and Application of Deep Learning Method for Classification of Concrete Aggregates and Soil

*Pourlak, Mahyar*

*PhD Candidate, Department of Civil Engineering, Qom University, Qom, Iran.*

***Ghotbi Siabil, S.M. Amin\****

*Corresponding Author, PhD, Department of Civil Engineering, K.N. Toosi University of Technology, Tehran, Iran  
ghotbi@mail.kntu.ac.ir*

*Morteza Esmaeili*

*Professor of Railway Engineering, Iran University of Science and Technology*

## ***Abstract***

*Mechanical sieve analysis is a common method for size Classification concrete aggregates and soil. For facilitation and acceleration of this method, this paper reviews image processing and deep learning methods used in geotechnical and civil engineering applications. Combination of deep learning with image processing can result in a robust, human-independent approach (in terms of experience and recognition power), resulting in faster and accurate results. To better understand the performance of such methods, two convolutional neural network (CNN) architectures (e.g. AlexNet or GoogleNet) were evaluated for their capability in automatic feature extraction and image classification. It was observed that the accuracy of these networks in prediction of aggregate class is dependent on ratio of the number of training samples to the whole dataset size, epoch number and mini batch size. The number of training images between 80-90% of the total dataset was found to be suitable and a minimum of 10 epoch is required to obtain the maximum validation accuracy. Using this model, a validation accuracy of up to 100% was reachable. Furthermore, the model was capable to predict about 85% of new images correctly. The future improvement of this method can be associated to increasing its efficiency in training process by using optimization approaches.*

***Keywords:*** *Soil and Aggregate Classification, Image Processing, Deep Learning*

# مرور و کاربرد روش یادگیری عمیق در طبقه‌بندی مصالح دانه‌ای بتن و خاک

دریافت مقاله ۳۰-۰۱-۱۴۰۰

پذیرش مقاله ۲۷-۱۲-۱۳۹۹

مهیار پورلک

دانشجوی دکتری مهندسی سازه‌های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه قم، قم، ایران

سید محمدامین قطبی\*

دکتری مهندسی خاک و پی، دانشکده مهندسی عمران، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران

ghotbi@mail.kntu.ac.ir

مرتضی اسماعیلی

استاد دانشکده مهندسی راه آهن، دانشگاه علم و صنعت ایران

## چکیده

روش پایه برای تعیین خصوصیات مهندسی خاک و سنگ‌دانه‌های بتن، طبقه‌بندی آن‌ها به روش مکانیکی آنالیز الک است که روندی زمان‌بر و گاهی پرهزینه دارد. در این مقاله با کاربرد روش پردازش تصویر مبتنی بر یادگیری عمیق، عملاً نیاز به دخالت کاربر برای پردازش تصاویر به حداقل و سرعت و دقت طبقه‌بندی مصالح افزایش یافته است که این موضوع می‌تواند به افزایش بهره‌وری در پروژه‌ها کمک نماید. بدین منظور نمونه‌های مصالح از پروژه‌های مختلف در سطح شهر تهران جمع‌آوری شده و از آن‌ها عکس‌هایی در شرایط مشخص تهیه گردید. برای تعیین دقیق طبقه‌بندی مصالح، نمونه‌ها به روش آنالیز الک دانه‌بندی شدند. با این اطلاعات، شبکه‌های یادگیری عمیق AlexNet و GoogleNet بررسی، تنظیم و آموزش داده شده‌اند. برای تعیین پارامترهای مدل از حساسیت‌سنجی استفاده شد. بر این اساس استفاده از حدود ۸۰-۹۰ درصد تصاویر گرفته شده برای آموزش مدل و سایر تصاویر برای بررسی دقت آن مناسب تشخیص داده شد. نتایج آنالیز نشان داد که با استفاده از این روش دقت صحت‌سنجی به حدود ۱۰۰٪ می‌رسد. همچنین درصد توانایی مدل برای شناسایی طبقه‌بندی تصاویر نمونه‌های جدید در حدود ۸۵٪ است. با افزایش داده‌های ورودی برای آموزش مدل می‌توان به دقتی به مراتب بالاتر نیز دست یافت.

کلید واژگان: طبقه‌بندی مصالح، خاک و سنگ‌دانه بتن، پردازش تصویر، یادگیری عمیق

۱-مقدمه

مصالح بتنی و خاکی از جمله مصالح پر کاربرد در صنعت ساخت هستند که تعیین خصوصیات و دانه بندی آنها اهمیت بسیار زیادی دارد. شن و ماسه در مجموع حدود ۶۰ تا ۷۵ درصد از حجم بتن را تشکیل می‌دهند که ۶۰ تا ۷۰ درصد از کل دانه‌ها شن و ۳۰ الی ۴۰ درصد دانه‌ها را ماسه تشکیل می‌دهد. از طرف دیگر برآورد خصوصیات مهندسی خاک مانند تراکم‌پذیری، مقاومت برشی و هدایت هیدرولیکی از جمله اقدامات ضروری حین طراحی و اجرای پروژه‌های عمرانی است. بنابراین انجام دانه‌بندی مصالح سنگی بتن با توجه به طرح اختلاط و نوع کاربرد و در خاک برای تعیین خصوصیات پایه آن باید انجام شود.

تحلیل اندازه دانه‌های خاک و بتن<sup>۱</sup> (دانه‌بندی) یکی از آزمایش‌های پایه و مهم برای انجام طبقه‌بندی مصالح بتنی و خاک است. مرز اندازه شن و ماسه الک استاندارد نمره ۴ با اندازه ۴/۷۶ میلی‌متر است. دانه‌های ریزتر از ۴/۷۶ میلی‌متر را ماسه و بزرگتر از ۴/۷۶ میلی‌متر را شن می‌نامند. حداقل اندازه دانه‌های ماسه ۰/۰۷۵ میلی‌متر و حداکثر اندازه دانه‌های شن ۶۰ میلی‌متر می‌باشد. دانه‌بندی مصالح خاکی و سنگی اصولاً به روش مکانیکی الک انجام می‌شود که انجام هر آزمایش آن بسته به وسعت پروژه‌ها می‌تواند تا حدود ۱۴ ساعت زمان ببرد [۱]. در نتیجه انجام تعداد بسیار زیاد از آزمایش‌های طبقه‌بندی مصالح خاکی و بتنی در پروژه‌های بزرگ می‌تواند زمان و هزینه زیادی را تحمیل نماید.

امروزه به کمک روش پردازش تصویر<sup>۲</sup> می‌توان عملیات طبقه‌بندی مختلف (از جمله طبقه‌بندی مصالح خاکی و سنگی) را با سرعت و دقت نسبتاً مناسب به انجام رساند. به عنوان نمونه، Mora et al. (1998) [۲] با استفاده از روش پردازش تصاویر دیجیتال (DIP) روشی را برای تحلیل توزیع اندازه ذرات درشت‌دانه بتن ارائه دادند. در تحقیقات مشابه دانه‌بندی تنها بر اساس مساحت صورت گرفته بود، اما در روش پیشنهادی جدید تبدیل توزیع بر اساس مساحت به توزیع بر اساس جرم از طریق تعریف یک پارامتر شکل برای در نظر گرفتن ضخامت دانه‌ها ارائه شد. بر این اساس نمودارهای به دست آمده به منظور تطابق با نمودارهای واقعی جابجا شدند. در این روش، دانه‌ها باید کاملاً گسترانده شده و بدون همپوشانی باشند تا دقت مناسبی حاصل شود. همچنین دانه‌ها نباید خیلی کوچک باشند تا پیکسل متناظر با آن بتواند نماینده آن باشد.

Han et al. (2016) [۳] روش تحلیل تصاویر دوبعدی برای ارزیابی توزیع و خصوصیات دانه‌های درشت بتن بر اساس عکس‌های گرفته شده از مقاطع بتنی ارائه دادند. بر مبنای اصل Cavalieri [۴ و ۵]، درصد یک مساحت در مقطع عرضی یک نمونه با درصد حجمی در حالت سه بعدی برابر فرض می‌شود. با مقایسه نتایج حاصل از این روش با روش‌های سه بعدی مانند دانه‌بندی و نسبت حجم دوغاب به دانه‌ها، روش دوبعدی به کار گرفته شده از دقت مطلوب برخوردار بود. علاوه بر آن، روش دو بعدی اثر خطاهای تصادفی مانند لرزش بتن و نمونه‌گیری غیریکنواخت را آشکار می‌کند.

در روش Ozen and Guler (2014) [۶]، تصاویر دو بعدی از مقاطع عرضی نمونه‌های بتنی تهیه شد و توزیع اندازه دانه‌ها بر اساس آن انجام گرفت. یک الگوریتم برای مشخص کردن آستانه بهینه در تحلیل تصویر مقطع عرضی و همچنین یک پارامتر شکل دانه برای استفاده در تحلیل توزیع اندازه دانه‌ها پیشنهاد شد. استفاده از این روش می‌تواند ارزش عملی برای ارزیابی بتن شامل درجه جدایش و مرزهای دانه‌بندی مخلوط در حین ساخت داشته باشد.

در تحقیق Yang et al. (2018) [۶]، یک سیستم ریخته‌گری و پراکنده‌سازی ماسه مبتنی بر خصوصیات کانتور ذرات ماسه (تعیین شده توسط دریافت تصاویر با پس‌زمینه روشن) و یک مکانیزم استخراج تهیه شد. الگوریتم‌هایی

<sup>1</sup> Particle Size Distribution (PSD)

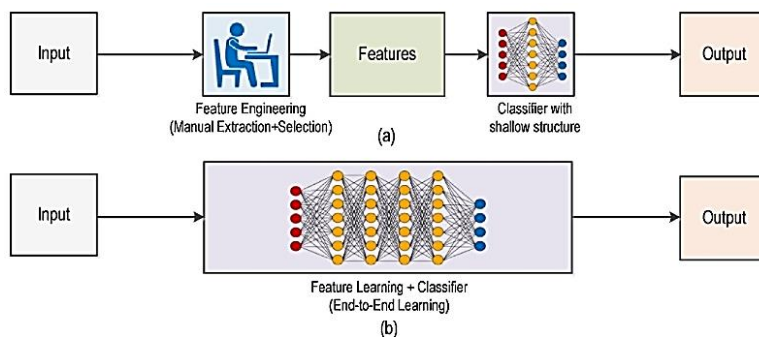
<sup>2</sup> Image Processing

برای حذف ذرات تکراری، تعیین ذرات ناقص در مرزهای تصویر، خوشه‌بندی کانتور ذرات و تعیین اندازه ذره معادل مطالعه شدند. نتایج آزمایشگاهی حداکثر خطای تکرار بر روی نمونه‌ها کمتر از ۰.۴٪ است که برای کاربردهای واقعی بسیار مناسب است.

تحلیل بافت مبتنی بر تصاویر برای طبقه‌بندی بافت خاک با استفاده از روش SVM و تابع هسته مرکزی توسط Barman and Choudhury (2019) [۸] ارائه شد. پیش از انجام تحلیل تصاویر، بافت خاک با روش معمولی هیدرومتری و مثلث USDA تعیین گردید که کاری بسیار وقت‌گیر و طاقت فرسا است. یک آزمایش ساده هیدرومتری برای تعیین درصد لای، رس و ماسه حداقل ۲۴ ساعت طول می‌کشد، اما طبق این تحقیق با استفاده از پردازش تصویر مدت زمان تحلیل کاهش می‌یابد.

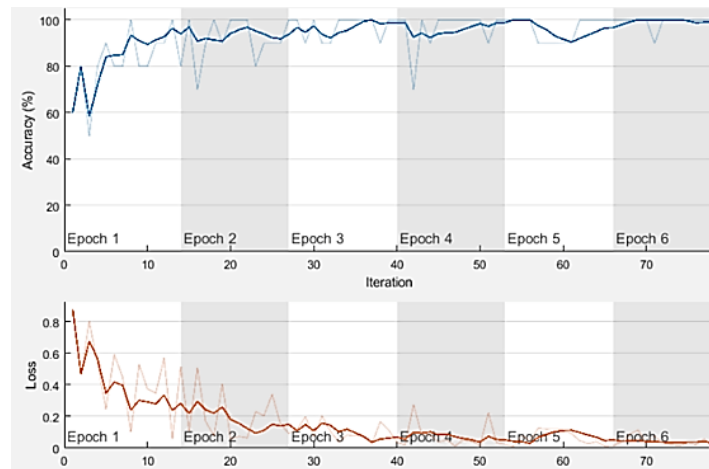
در پژوهش‌های فوق‌الذکر، با وجود استفاده از روش پردازش تصاویر، لازم است یک فرد متخصص تصاویر را پردازش نموده و نتایج مورد نیاز را استخراج نماید که خود مستلزم صرف وقت و هزینه جداگانه است. با بکارگیری روش یادگیری عمیق<sup>۱</sup> (به عنوان یک شاخه پیشرفته از علم هوش مصنوعی) در چهارچوب پردازش تصویر، می‌توان نیاز به عامل انسانی در طبقه‌بندی را به حداقل رساند (شکل ۱-۱). در حوزه‌های ساخت با کمک پردازش تصویر و هوش مصنوعی می‌توان هزینه‌ها را کاهش داد که میزان این کاهش به نوع پروژه بستگی دارد. به عنوان نمونه Gui et al. (2011) [۹] با استفاده از الگوریتم ژنتیک کاهش ۱۰ تا ۲۰ درصد در هزینه ساخت شمع برای پروژه‌های بندرگاهی را پیش‌بینی کردند. همچنین Alqedra et al. (2011) [۱۰] به کمک الگوریتم ژنتیک کاهش ۳۰ درصدی در هزینه تیرهای سازه را پیش‌بینی کردند.

تاکنون تحقیقات مختلفی در مورد استفاده از روش پردازش تصویر مبتنی بر یادگیری عمیق در طبقه‌بندی سنگ‌دانه بتنی، خاک و سایر امور مربوط به طبقه‌بندی در مهندسی عمران انجام شده است. استفاده از یادگیری عمیق (به عنوان نمونه شبکه AlexNet [۱۱]) به طور مؤثری در زمینه‌های مختلف مهندسی عمران به کار گرفته شده است. یکی از نمونه‌های موفق مربوط به مسائل پایش سلامت روسازی‌ها می‌باشد (Meziane et al. (2018) [۱۲] که در شکل ۱-۲ مقادیر دقت و خطا حین آموزش شبکه توسط آن‌ها نشان داده شده است.



شکل ۱- مقایسه شماتیک پردازش تصویر کلاسیک و پردازش تصویر در چهارچوب یادگیری عمیق


<sup>۱</sup> Deep Learning (DL)



شکل ۲- مقادیر دقت و تابع خطا حین آموزش شبکه AlexNet [۱۳]

در خصوص طبقه‌بندی سنگ‌دانه‌ها و خاک، (2003) de Oliveira Morais et al. [۱۳] مقادیر ذرات در بخش‌های رس و ماسه به داده‌های تصاویر را با استفاده از رگرسیون چند متغیره PLS2 مرتبط نمودند. با این روش رویکرد بینایی کامپیوتر انتخاب شده برای تشخیص بافت خاک بر مبنای تصاویر دقتی تا ۱۰۰٪ داشت. این روش کم‌هزینه، مناسب محیط زیست، غیرمخرب و سریع‌تر از روش استاندارد بود. در تحقیق (2011) Cortina-Jauchs et al. [۱۴] ترکیب پردازش تصویر، روش‌های خوشه‌بندی و شبکه عصبی مصنوعی برای طبقه‌بندی بافت خاک ارائه گردید. این روش برای طبقه‌بندی تصاویر خاک به دو گروه فضاهای خالی و ذرات خاک است که در تشخیص فضاهای خالی و ذرات خاک در تصاویر CT<sup>۱</sup> بسیار موثر است. به کمک این روش درصد طبقه‌بندی صحیح فضاهای خالی در نمونه‌های مورد بررسی به بیش از ۹۶٪ رسید.


استفاده از روش از یادگیری عمیق برای طبقه‌بندی اندازه دانه‌های خاک و ارزیابی کیفیت عملیات خاک‌ورزی برای کاهش هزینه و نیروی انسانی دخیل توسط (2020) Azizi et al. [۱۵] مورد استفاده قرار گرفت. بدین منظور تعدادی جفت عکس استریو برای تغذیه شبکه مورد استفاده قرار گرفت که یک نمونه از هر اندازه در شکل ۳ نشان داده شده است. از آنجایی که سیستم عکس‌برداری استریو وابسته به نور محیطی نیست، عکس‌برداری در شرایط صحرائی و بدون سیستم نورپردازی انجام گرفت. به منظور آموزش مدل‌های عمیق، تصاویر هر لنز از یکدیگر جدا شدند و به شبکه داده شدند. بدون نیاز به استخراج ویژگی‌های تصاویر که به طور دستی در بیشتر الگوریتم‌های پردازش تصویر و بینایی مورد استفاده قرار می‌گیرند، مدل عمیق مورد استفاده در این تحقیق مشاهده و استخراج خصوصیات مورد نیاز از پایین‌ترین تا بالاترین سطح را به صورت خودکار فرا گرفت.



شکل ۳- دانه‌های خاک پس از عملیات خاک‌ورزی. اندازه دانه‌ها از شماره ۱ تا ۶ افزایش می‌یابد [۱۵].

<sup>1</sup> Computed tomography

در بین الگوریتم‌های مختلف یادگیری عمیق موجود، شبکه عصبی پیچشی (CNN) به دلیل قابلیت بسیار خوب آن در کار با تصاویر در تحقیق بالا مورد استفاده قرار گرفت. شبکه‌های VggNet16، ResNet50 و Inception-v4 مورد استفاده قرار گرفتند. دقت طبقه‌بندی این شبکه به بالای ۹۵٪ می‌رسد، اما بالاترین دقت با ResNet50 (98.72%) به دست آمد. این دقت بسیار خوب که به طور قابل ملاحظه‌ای متفاوت از تحقیقات قبلی است، نشان دهنده توانایی روش یادگیری عمیق در طبقه‌بندی دانه‌ها خاک است. نتایج این تحقیق نشان داد که تخمین قطر وزنی متوسط (MWD) دانه‌ها بدون محدودیت اندازه و با دقت بسیار خوب کاملاً عملی و دست‌یافتنی است. در شکل ۴ یک نمونه از روند تغییرات دقت و تابع خطا در یادگیری برای شبکه Inception-v4 نشان داده شده است.



شکل-۱- دقت و نرخ خطا طبقه‌بندی دانه‌های خاک به دست آمده از آموزش داده‌ها در شبکه Inception-v4 [۱۵]

با توجه به پیشینه تحقیقات، رویکرد یادگیری عمیق برای طبقه‌بندی و تعیین خصوصیات مصالح خاکی و سنگ‌دانه‌های بتن در این تحقیق مورد توجه قرار گرفت. این کار از روی تصاویر گرفته شده از نمونه‌های مصالح و به صورت تقریباً خودکار و با دقت و سرعت نسبتاً مناسبی قابل انجام خواهد بود. به این منظور نمونه‌های مختلف مصالح خاکی از پروژه‌های مختلف در شهر تهران تهیه شده و پس از تهیه عکس‌ها، عمل دانه‌بندی بر روی آن‌ها انجام شده است. سپس با تعلیم دادن دو شبکه یادگیری عمیق از روی این داده‌ها، چارچوبی نسبتاً سریع و دقیق برای تعیین طبقه‌بندی مصالح خاک و سنگ‌دانه بتن ارائه گردیده است. در این تحقیق از مصالح خاکی عمدتاً درشت‌دانه استفاده شده است که قابل قیاس با سنگ‌دانه‌های بتنی بوده و اقدامات لازم برای استفاده مستقیم در سنگ‌دانه‌های بتن در انتهای مقاله مورد اشاره قرار می‌گیرد. با توجه به وسعت پروژه‌ها در کشور، نتایج این تحقیق می‌تواند به کاهش هزینه‌ها، بهره‌وری و افزایش سرعت اجرا کمک شایانی نماید.

## ۲- روش تحقیق

با توجه به مشابه بودن مصالح بتنی و خاکی از نظر مشابهت اندازه دانه‌ها و روش طبقه‌بندی و با توجه به تعدد گروه‌های دانه‌بندی خاک نسبت به سنگ‌دانه‌های بتنی، در این تحقیق مصالح خاکی برای آموزش شبکه مورد استفاده قرار گرفته است و نتایج آن به راحتی قابل تعمیم به مصالح بتنی نیز است. نمونه‌های مصالح خاکی از پروژه‌های مختلف تهیه شده و دانه‌بندی آن‌ها با روش الک مکانیکی تعیین شدند. تصاویر نمونه‌های مصالح تحت شرایط مشخصی ثبت می‌گردد و این تصاویر به همراه برچسب طبقه‌بندی آن به صورت یک دسته داده آموزشی به کد آموزش عمیق که از قبل آماده و تنظیم شده داده می‌شود. شبکه با این تصاویر تحت آموزش قرار گرفته و وزن‌دهی بهینه لایه‌های آن تعیین می‌گردد. در نهایت با دادن تصویر یک نمونه مصالح با شرایط فوق‌الذکر به شبکه آموزش دیده، دانه‌بندی (طبقه‌بندی) با دقت مطلوبی قابل ارزیابی است. تجزیه و تحلیل اطلاعات توسط نرم‌افزارهای موجود در این زمینه مانند Matlab و شبکه‌های یادگیری عمیق منطبق بر انجام شده است. تصاویر ثبت شده از نمونه‌ها برای تعلیم شبکه به آن داده شده و شبکه با استخراج خصوصیات آن‌ها و رفت و برگشت روی شبکه، مقادیر


مناسب پارامترها را تعیین نموده و بدین ترتیب آموزش داده می‌شود. در نهایت این شبکه آموزش دیده بسته به تعداد و گوناگونی داده‌های آموزشی می‌تواند دقت مناسبی در تعیین دانه‌بندی و طبقه‌بندی مصالح داشته باشد.

### ۱-۲ نمونه‌گیری و دانه‌بندی خاک

نمونه‌های مصالح به وزن تقریبی ۱ تا ۲ کیلوگرم از پروژه‌های مختلف تهیه و پس از برچسب‌گذاری، به آزمایشگاه منتقل شده و مقدمات انجام دانه‌بندی برای آن‌ها انجام شد. سپس دانه‌بندی خاک‌ها بر اساس روش ال‌ک مکانیکی مطابق استاندارد ASTM D6913 [۱۶] انجام شد. در مجموع ۲۶ نمونه مصالح خاکی از ۷ پروژه تهیه شد که با توجه به آزمایش دانه‌بندی در ۱۳ دسته مختلف قرار می‌گیرند.

### ۲-۲ ثبت تصاویر

نمونه‌های ذکر شده با وزن تقریبی ۱ تا ۲ کیلوگرم از پروژه‌های ذکر شده جمع‌آوری شده و بر روی یک صفحه مسطح گسترانده شدند. این کار در یک محیط مسقف بدون نور خورشید و با نور ثابت غیرطبیعی انجام شد تا شرایط از نظر نوری کاملاً ثابت باشد. به منظور ثبت تصاویر نمونه‌ها، از یک دوربین ۸ مگاپیکسل گوشی همراه استفاده شد. به منظور برقرار شرایط ثابت در عکس‌برداری‌ها و حذف خطاهایی نظیر لرزش دست، یک پایه برای قرار دادن دوربین ساخته شد که شکل شماتیک و تصویر آن در شکل ۵ نشان داده شده است. لنز دوربین در ارتفاع ۸۰ سانتی‌متر از مرکز نمونه‌های ذکر شده قرار گرفتند. در شکل ۶ (الف) و (ب) به ترتیب تصویر دو نمونه خاک GW و SM در شرایط ذکر شده نشان داده شده است.



شکل ۵- (الف) شکل شماتیک پایه قرارگیری دوربین، (ب) تصویر پایه قرارگیری دوربین در آزمایشگاه



شکل ۶- تصویر نمونه‌های (الف) GW و (ب) SM در شرایط نور ثابت

### ۳-۲ روش پردازش تصویر بر پایه یادگیری عمیق

الگوریتم‌های مختلفی برای شناسایی و طبقه‌بندی تصاویر بر پایه یادگیری عمیق پیشنهاد شده‌اند. این الگوریتم‌ها عموماً از یک نسخه خاص یادگیری عمیق به نام شبکه عصبی کانولوشن یا پیچشی تبعیت می‌کنند که در ادامه کلیاتی از آن ارائه شده است. در این پروژه از دو الگوریتم AlexNet (Krizhevsky et al., 2012 [۱۱]) و GoogleNet (Szegedy et al., 2014 [۱۷]) به عنوان دو ماژول جداگانه در متلب استفاده شده است. شبکه آموزش یافته در یک فایل ذخیره شده و برای استفاده‌های بعدی بارگذاری می‌شوند. همچنین به منظور شناسایی تصاویر بر پایه شبکه آموزش دیده، یک ماژول جداگانه با قابلیت بارگذاری هر کدام از معماری‌های یادگیری عمیق ارائه شده است. برای حصول عملکرد منطقی این الگوریتم‌ها ابتدا لازم است عملیات پیش‌آموزش<sup>۱</sup> و تنظیم دقیق<sup>۲</sup> در کدهای مربوطه انجام و حساسیت‌سنجی گردد. همچنین تصاویر حاصل از دوربین‌هایی با مشخصات متفاوت لازم است مقیاس گردند که در ادامه به آن‌ها اشاره می‌شود.

### ۳-۱-۲ پیش‌پردازش و کاهش بیش‌برازش<sup>۳</sup>

بیش‌برازش به معنی آموختن کل تصویر به جای آموختن ویژگی‌های تصویر است. این موضوع وقتی اتفاق می‌افتد که تعداد نمونه‌های لازم برای آموزش شبکه بسیار کمتر از تعداد وزن‌ها و پارامترهای آموزش شبکه باشد. در این شرایط عملکرد مدل هنگام آزمایش بر روی تصاویر نمونه‌ها کاهش می‌یابد. به لحاظ تئوری برای جلوگیری از این موضوع تعداد نمونه‌ها باید ۱۰ برابر تعداد پارامترها باشد [۱۸]. به این منظور یک روش افزایش تعداد نمونه‌های آموزشی است. در شبکه AlexNet تعداد پارامترها ۶۰ میلیون است که تهیه عکس به تعداد ۶۰۰ میلیون برای جلوگیری از بیش‌برازش عملاً امری بسیار مشکل و گاهی نشدنی است. روش بعدی کاهش پیچیدگی مدل از طریق کاهش تعداد پارامترهای آن است. در مورد شبکه‌های مورد استفاده به علت لزوم وجود تمامی لایه‌ها برای عملکرد صحیح مدل، این روش نیز امری ناممکن است.

یکی از بهترین روش‌ها برای جلوگیری و کاهش چشمگیر بیش‌برازش استفاده از روش تقویت داده‌ها<sup>۴</sup> است، هر چند به منظور بهبود عملکرد مدل باید به صورت دقیق تنظیم گردد [۱۹]. در این روش تعداد داده‌های آموزشی به طور مصنوعی (و البته به روش منطقی) افزایش داده می‌شوند. روش‌های متداول برای این منظور شامل سر و ته کردن، جابجایی، چرخاندن، تغییر اندازه، تغییر شفافیت، اضافه کردن نویز و ... به تصاویر است.

### ۳-۲-۲ مقیاس کردن تصاویر

با توجه به اینکه شبکه آموزش یافته کنونی بر پایه عکس‌های گرفته شده با یک دوربین خاص است، لازم است عکس‌هایی که در آینده برای آموزش و یا شناسایی گرفته می‌شوند به نحوی مقیاس شوند. به این منظور با دانستن وضوح تصویر دوربین حاضر (72 dpi) و تعداد پیکسل‌ها، ابعاد تصویر به دست می‌آید. برای عکس‌های دیگر نیز مقادیر فوق با دستورات مشخص در نرم‌افزار متلب استخراج می‌شوند. سپس با تقسیم ابعاد تصاویر و به دست آوردن نسبت آن‌ها، ابعاد تصاویر جدید با این نسبت مقیاس شده و به ماژول مربوط به یادگیری و یا شناسایی تصویر وارد می‌شوند. لازم به ذکر است در صورت استفاده از تصاویر با وضوح بالاتر، دقت آموزش و پیش‌بینی صحیح شبکه افزایش خواهد یافت. عرض تصاویر مورد استفاده بهتر است بزرگ‌تر از ۹۰ اینچ و نسبت عرض به طول تصاویر 16:9 باشد تا عمل مقیاس کردن سبب افت کیفیت و همچنین تغییر نسبت عرض به ارتفاع تصاویر نگردد.

<sup>1</sup> Pre-training

<sup>2</sup> Fine-tuning

<sup>3</sup> Over-fitting

<sup>4</sup> Data Augmentation



### ۳- نتایج و تحلیل آزمایشات

برای آموزش شبکه و اعتبارسنجی اولیه مدل‌ها، نتایج آزمایش دانه‌بندی مکانیکی پروژه‌های مختلف به منظور آموزش شبکه‌ها مورد استفاده قرار گرفت. عکس‌های تهیه شده از نمونه‌ها مطابق مطالب گفته شده در بخش قبل تهیه شدند. برای هر کدام از فاصله‌های لنز دوربین از نمونه‌ها (۴۰، ۶۰ و ۸۰ سانتی‌متر)، تعداد ۸ عکس تهیه شده بودند که با احتساب تعداد پروژه‌های مورد استفاده، حدود ۲۷۰ عکس برای آموزش در هر فاصله لنز از نمونه به شبکه داده شدند. مطابق آزمایش‌های الک مکانیکی، نمونه‌ها مشتمل بر ۱۳ طبقه‌بندی مختلف مصالح خاکی می‌باشند.

به منظور حساسیت‌سنجی اثر عوامل مختلف بر دقت شبکه، در ابتدا مفاهیم پایه مربوطه به شرح زیر بیان می‌گردد:

#### الف) نسبت یادگیری

میزان کاهش تابع هزینه (خطای یادگیری) در هر تکرار را نسبت یادگیری می‌گویند. به عبارت ساده‌تر، سرعت کاهش هزینه‌ها همان نسبت یادگیری است. نسبت یادگیری باید با دقت زیادی انتخاب گردد تا موجب عبور از حالت بهینه و یا افزایش بسیار زیاد زمان یادگیری شبکه نگردد. در صورت انتخاب عدد بزرگ برای نسبت یادگیری، تابع هزینه در ابتدا با سرعت زیادی کاهش می‌یابد، اما از مقدار مشخصی کمتر نخواهد شد. با انتخاب نسبت یادگیری بسیار بزرگ، تابع خطا حتی ممکن است افزایش یابد. اگر نسبت یادگیری عدد کوچکی انتخاب شود، کاهش تابع خطا به صورت تدریجی و با شیب بسیار کمی اتفاق می‌افتد که به معنی زمان طولانی برای آموزش شبکه خواهد بود.

#### ب) اندازه بسته‌ها

در تعلیم یک شبکه عصبی به جای ارسال کل ورودی، آن را به بسته‌های کوچک با اندازه‌ی یکسان تقسیم می‌کنند. با ارسال داده‌ها به صورت بسته (Batch)، مدل نسبت به مدلی که تمام اطلاعات را یکجا دریافت کرده است، جامع‌تر باشد.

#### پ) دوره

یک دوره (Epoch) به معنی یک تکثیر رفت و برگشت در شبکه و برابر با یک رفت و برگشت ورودی در کل شبکه است. تعداد دوره‌های یادگیری شبکه به نظر کاربر بستگی دارد. با وجود افزایش دقت نتایج با افزایش تعداد دوره‌های شبکه، زمان یادگیری شبکه افزایش می‌یابد. به علاوه، باید توجه داشته باشید که اگر تعداد دوره‌ها بیش از حد زیاد باشد، ممکن است هضم آن برای شبکه سنگین باشد، یا اصطلاحاً شبکه «over-fit» شود. در حالت پایه، حداقل BatchSize برابر ۱۰، تعداد نسبت جامعه آماری آموزش به کل نمونه برابر ۰/۸ و نرخ یادگیری اولیه  $1e-4$  هستند.

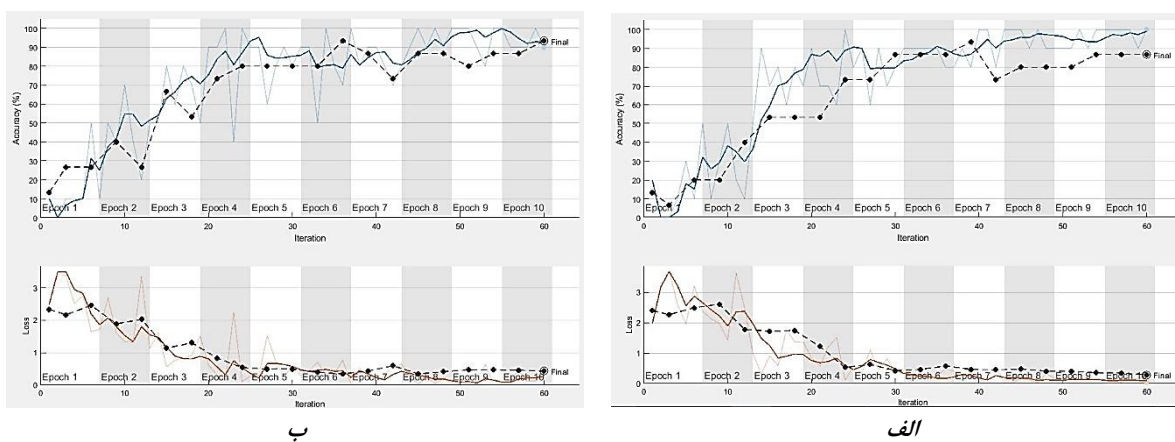
### ۳-۱- پیش‌آموزش و تنظیم دقیق شبکه

پیش از آموزش شبکه، لازم است مقادیر مناسب برای پارامترهای مختلف آن تعیین گردند. عموماً قانون مشخصی برای تعیین دقیق این پارامترهای وجود ندارد و بهترین راه برای این منظور انجام حساسیت‌سنجی است. از جمله مهم‌ترین پارامترهای مورد بررسی در این بخش اثر تعداد دوره‌های آموزش (Epoch)، اندازه بسته‌های آموزش (Mini Batch Size)، نسبت تعداد داده‌های صحت‌سنجی و آزمایشی به داده‌های کل و اثر نرخ یادگیری است. پس از مشخص شدن این مقادیر آموزش نهایی شبکه یادگیری عمیق انجام می‌شود.

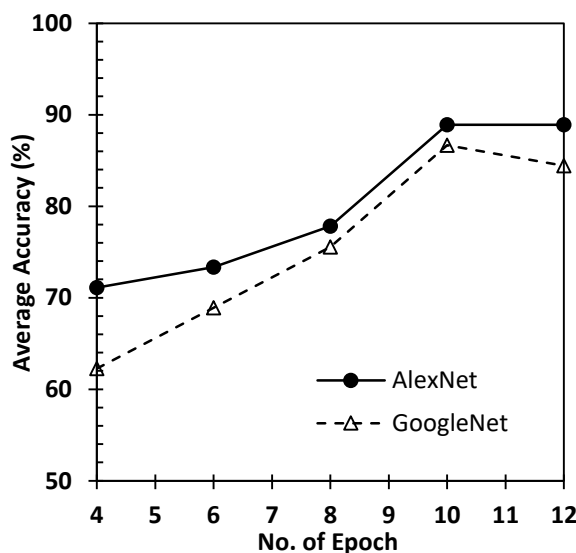
#### ۳-۱-۱- اثر تعداد دوره‌های آموزش (Epoch)

در حالت کلی با افزایش تعداد دوره‌ها دقت یادگیری شبکه افزایش یافته و تابع هزینه کاهش می‌یابد. اما باید در نظر داشت در صورتی که تعداد دوره‌ها و یا epoch بیش از یک مقدار مشخص افزایش یابد، شبکه دچار بیش‌برازش شده و دقت آن کاهش می‌یابد. این تعداد بهینه دوره‌ها به میزان پیچیدگی داده‌های ورودی، تعداد آن‌ها و تعداد طبقات خروجی مورد نظر دارد. شکل ۷ شکل روند آموزش شبکه یادگیری عمیق AlexNet برای تعداد ۱۰ دوره یا epoch

آموزش نشان می‌دهد. در این شکل‌ها نمودار بالای درصد دقت آموزش نسبت به دوره و نمودار پایینی نمودار تابع هزینه نسبت به دوره را نشان می‌دهد. به طور کلی با افزایش تعداد دوره‌ها و رفت و برگشت داده‌ها در شبکه، دقت افزایش یافته و تابع هزینه یا خطا کاهش یافته است. در شکل ۸ اثر تغییرات تعداد epoch بر دقت یادگیری شبکه‌های AlexNet و GoogleNet نشان داده شده است. لازم به ذکر است دقت هر تعداد epoch از متوسط‌گیری حداقل ۳ بار آنالیز همان تعداد epoch محاسبه شده است. این نمودار نشان می‌دهد که به طور کلی دقت شبکه AlexNet برای این داده‌ها اندکی بیشتر دقت شبکه GoogleNet است. همچنین با افزایش تعداد دوره‌ها از ۴ تا ۱۰ شاهد افزایش دقت یادگیری شبکه هستیم و با افزایش بیشتر دوره‌ها، دقت شبکه ثابت مانده و یا کاهش می‌یابد. بنابراین تعداد ۱۰ دوره را می‌توان به عنوان مقدار بهینه در آموزش در نظر گرفت.



شکل ۷- اثر تعداد Epoch بر روند آموزش شبکه AlexNet

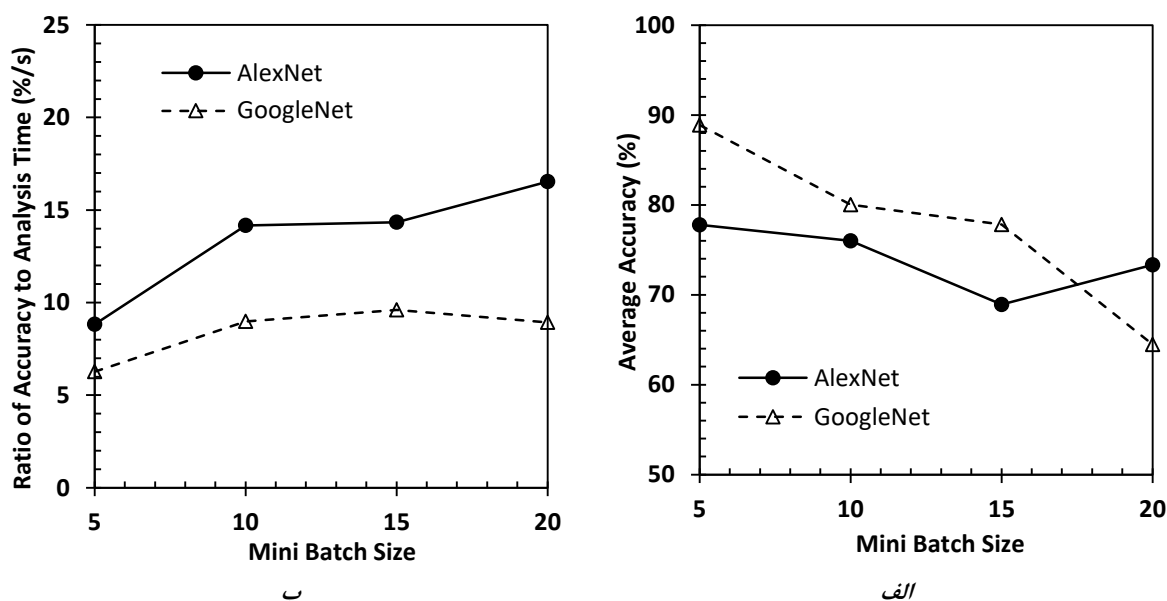


شکل ۸- اثر تعداد Epoch بر دقت شبکه

### ۲-۱-۳- اثر اندازه بسته یا MiniBatch

همانند تعداد epoch، هیچ قانون مستقیمی برای تعیین اندازه بسته‌های داده در آموزش وجود ندارد و اندازه بهینه بسته برای هر نوع داده باید با آزمون و خطا تعیین گردد. در شکل ۹ (الف) تغییرات دقت به دست آمده از آموزش شبکه‌های AlexNet و GoogleNet برای اندازه‌های مختلف بسته نشان داده شده است. به طور کلی هر چه اندازه

بسته افزایش یابد، دقت در شبکه GoogleNet کاهش می‌یابد. اما در مورد شبکه AlexNet تغییرات دقت با تغییر اندازه بسته چندان محسوس نیست و در اندازه بسته ۱۵ شاید کاهش دقت آموزش هستیم. از طرف دیگر با افزایش اندازه بسته‌ها مدت زمان مورد نیاز آنالیز کاهش نسبتاً چشمگیری می‌یابد. برای یافتن اندازه نمونه بهینه با کمترین زمان آنالیز، دقت آموزش نسبت به مدت زمان آموزش شبکه نرمال گردید و در شکل ۹ (ب) نشان داده شده است. این نمودار نشان می‌دهد که به طور کلی زمان بیشتر برای آموزش شبکه GoogleNet مورد نیاز است. این موضوع با افزایش تعداد داده‌های آموزشی و محدودیت قدرت پردازشی اهمیت زیادی دارد. شبکه AlexNet حساسیت چندانی به تغییرات اندازه بسته ورودی ندارد و نسبت دقت به مدت زمان آموزش برای اندازه بسته‌های ۵ الی ۲۰ بین حدود ۶ تا ۹ درصد متغیر است. از طرف دیگر با افزایش اندازه بسته‌ها شبکه AlexNet رفتار بهینه‌تری از خود نشان داده است. در این حالت نسبت دقت به زمان آموزش با افزایش اندازه بسته‌ها از ۵ تا ۲۰ از حدود ۹ به ۱۵ درصد افزایش می‌یابد.



شکل ۹- اثر تعداد 10 Epoch بر روند آموزش شبکه AlexNet

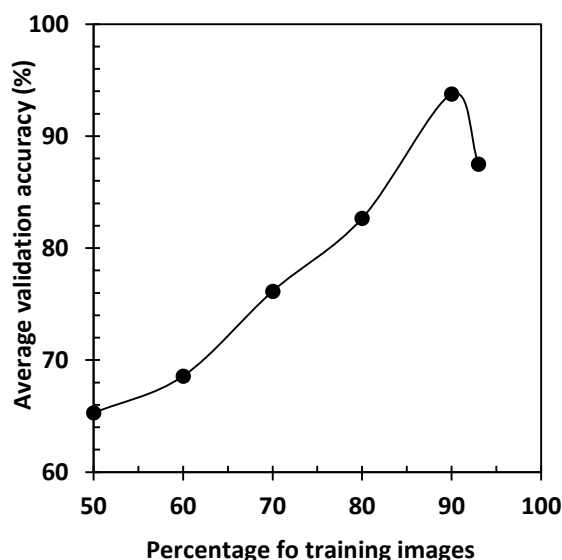
### ۳-۱-۳- اثر نسبت تعداد داده‌های آموزش و صحت‌سنجی

به طور کلی بخشی از داده‌ها برای آموزش شبکه، بخش دیگر برای صحت‌سنجی و بخش دیگری برای آزمایش مدل به کار می‌روند. داده‌های به کار رفته برای آموزش و صحت‌سنجی مدل به طور مستقیم بر پارامترهای آن تاثیر گذار هستند. دسته دیگری از داده‌ها که برای آزمایش مدل به کار می‌روند به طور غیر مستقیم برای سنجش عملکرد مدل مورد استفاده قرار می‌گیرند و بهتر است حدود ۱۰ الی ۱۵ درصد از داده‌های کل باشند که در این پروژه نیز به طور متوسط همین نسبت مورد استفاده قرار گرفته است. داده‌های آزمایشی از آن جهت اهمیت دارند که در هنگام آموزش مدل به آن داده نمی‌شوند، بلکه پس از اتمام هر دور آموزش جهت بررسی کیفیت عملکرد مدل برای اولین بار به آن داده می‌شوند.

عدد مشخصی به عنوان نسبت تعداد داده‌های آموزش و صحت‌سنجی وجود ندارد و به نوع و تعداد تصاویر ورودی وابسته است. برای یافتن نسبت مناسب باید با آزمون و خطا عدد مناسب به دست آید. اما به عنوان یک تخمین

اولیه نسبت‌های ۷۰:۳۰ و ۸۰:۲۰ توسط پژوهشگران مختلف (به عنوان مثال Alqahtani and Whyte, 2016 [۲۰]) معرفی شده‌اند. نسبت ۸۰:۲۰ در اصل پرتو<sup>۱</sup> [۲۱] نیز بیان شده است.

در این تحقیق ۱۰ درصد داده‌ها برای آزمایش شبکه پس از آموزش در نظر گرفته شدند و سایر داده‌ها برای آموزش و صحت‌سنجی مورد استفاده قرار گرفتند که لازم است نسبت بهینه داده‌ها صحت‌سنجی و آموزشی برای آن تعیین گردد. برای به دست آوردن نسبت بهینه، دقت صحت‌سنجی برای نسبت‌های ۵۰٪ تا ۹۵٪ داده‌های آموزشی به داده‌های کل مورد بررسی قرار گرفتند که نتایج آن در نمودار شکل ۹ نشان داده شده است. به طور کلی با افزایش نسبت داده‌های آموزشی (کاهش داده‌های صحت‌سنجی) از ۵۰٪ تا ۹۰٪، دقت صحت‌سنجی مدل از حدود ۶۵٪ تا ۹۵٪ افزایش می‌یابد که افزایش قابل توجهی است. با افزایش بیشتر نسبت داده‌های آموزشی نسبت به داده‌های صحت‌سنجی، نمودار افت شدیدی پیدا می‌کند. بنابراین می‌توان گفت با انتخاب نسبت داده‌های آموزشی در حدود ۹۰٪ از داده‌های کل و انتخاب تنها ۱۰٪ از داده‌ها برای صحت‌سنجی، دقت صحت‌سنجی مدل به حدود ۹۵٪ می‌رسد که به معنی دقت بسیار مناسب مدل می‌باشد.


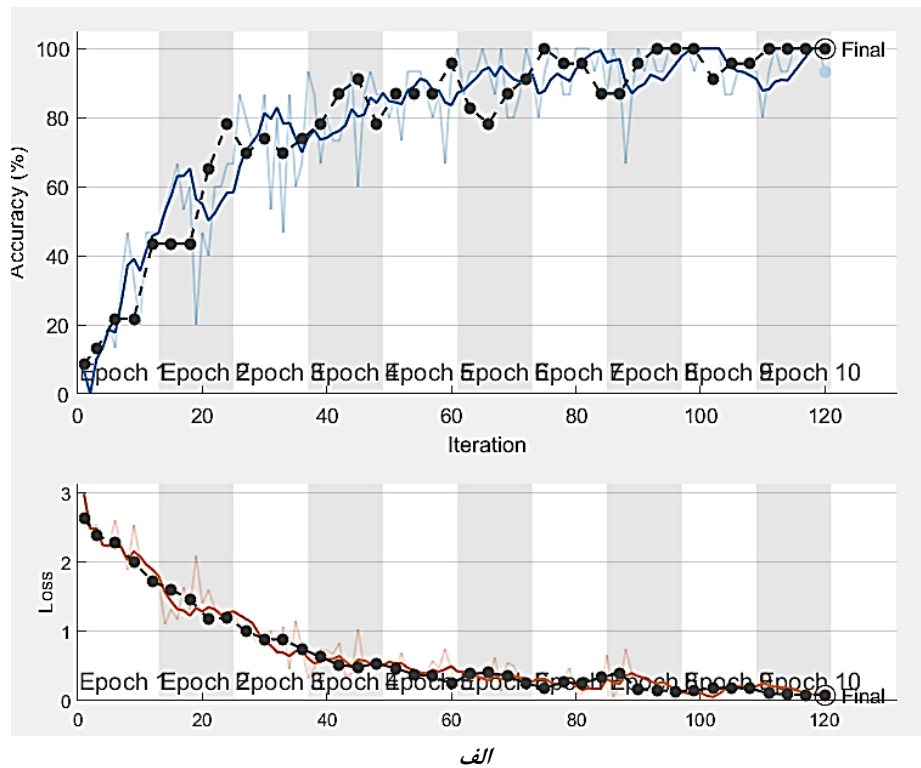


شکل ۱۰- نمودار تغییرات دقت صحت‌سنجی آموزش شبکه در مقابل درصد داده‌های صحت‌سنجی

## ۲-۳- آموزش شبکه یادگیری عمیق

با مشخص شدن مقادیر بهینه پارامترهای اساسی شبکه در بخش قبل، آموزش و صحت‌سنجی شبکه مورد بررسی قرار گرفت. آموزش شبکه دو بار به صورت مستقل انجام شد و نتایج آن در شکل ۱۱ (الف) نشان داده شده است. دقت صحت‌سنجی مورد اول ۱۰۰٪ و برای مورد دوم ۹۵٪ است که به معنی آموزش مناسب شبکه است. در بخش (ب) این شکل‌ها چند نمونه از تشخیص دانه‌بندی‌ها حین صحت‌سنجی نشان داده شده که در تطابق با درصدهای صحت‌سنجی به دست آمده است.

<sup>۱</sup> Pareto Principle


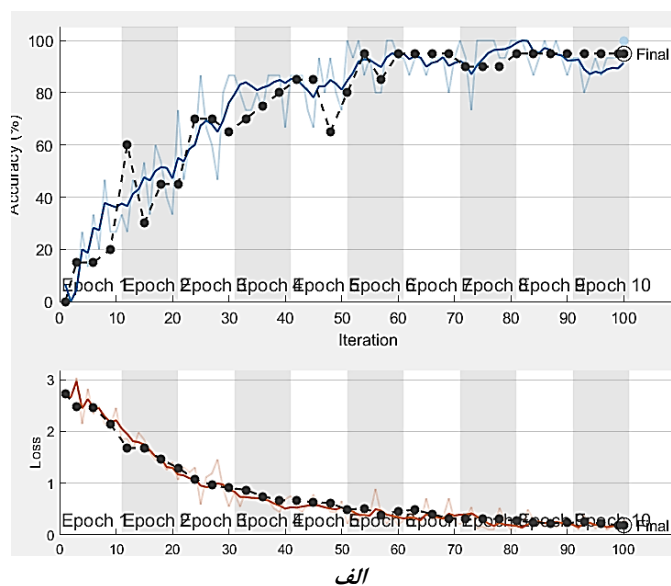


ب

شکل ۱۱- (الف) روند دقت صحت سنجی و تابع خطا در آموزش شماره ۱، (ب) چند نمونه نتایج پیش‌بینی شده و درصد دقت آن‌ها

### ۳-۳- آزمایش شبکه تعلیم یافته


در این مرحله ابتدا شبکه یادگیری عمیق با دادن ۹۰٪ داده‌ها (تصاویر) موجود مورد تعلیم قرار گرفت که نتایج آن در شکل ۱۲ نشان داده شده است. سپس شبکه آموزش یافته بر روی ۱۰٪ داده‌های آزمایشی امتحان گردیده است. لازم به یادآوری است که داده‌های آزمایشی در مرحله آموزش شبکه به آن داده نشده‌اند و در حقیقت شبکه برای اولین بار در این مرحله عکس‌ها را مشاهده می‌کند.



ب

شکل ۱۲- (الف) روند دقت صحت سنجی و تابع خطا در آموزش روی ۹۰٪ داده، (ب) چند نمونه نتایج پیش‌بینی شده و درصد دقت آن‌ها

نتایج چند پیش‌بینی صحیح شبکه بر روی تصاویر جدید در شکل ۱۳ نشان داده شده است. شبکه آموزش دیده می‌تواند با دقت بالاتر از ۸۰٪ درصد طبقه‌بندی خاک در تصاویر جدید را به صورت کاملاً دقیق پیش‌بینی نماید. در شکل ۱۴ یک نمونه پیش‌بینی شده با کمی انحراف از طبقه‌بندی دقیق نشان داده شده است. این نمونه در حقیقت شن لای‌دار (GM) بوده است که توسط شبکه شن با دانه‌بندی خوب (GW) تشخیص داده شده است. مطابق مطالب ارائه شده در بخش‌های قبل، شن لای‌دار در حقیقت شنی است که درصد لای آن بیش از ۱۵٪ است که در این مورد به نظر می‌رسد درصد لای در همین حدود قرار دارد. به عبارت دیگر می‌توان گفت که با وجود عدم تطابق دقیق دانه‌بندی واقعی و پیش‌بینی شبکه، طبقه‌بندی خاک در گروه‌های اصلی چهارگانه (شن، ماسه، لای و رس) به درستی صورت گرفته است. این موضوع نشان می‌دهد که شبکه یادگیری عمیق حتی در صورت عدم انطباق دقیق پیش‌بینی با طبقه‌بندی واقعی، این قابلیت را دارد که نزدیک‌ترین طبقه ممکن خاک را اعلام نماید. در این حالت با توجه به نزدیک بودن رفتار گروه‌های مختلف موجود در هر کدام از گروه‌های اصلی چهارگانه خاک، حدود پارامترهای پیش‌بینی شده طبق آن مقادیر نسبتاً منطقی خواهند داشت.



شکل ۱۳- چند نمونه پیش‌بینی کاملاً صحیح شبکه روی داده‌های آزمایشی (داده‌های استفاده نشده در آموزش)



شکل ۱۴- پیش‌بینی نزدیک به صحیح شبکه بر روی داده‌های آزمایشی (طبقه‌بندی کاملاً صحیح: GM)

کارایی و دقت روش مورد استفاده را می‌توان با تحقیقات قبلی مقایسه نمود. به عنوان مثال، (Azizi et al. (2020) [۱۵] با استفاده از روش مشابه این تحقیق (شبکه‌های پیچشی عمیق) و معماری‌های مختلف برای تعیین اندازه دانه‌های حاصل از عملیات خاک‌ورزی به دقت بین ۹۵ تا ۹۸ درصد رسیدند. لازم به ذکر است در تحقیق آن‌ها دانه‌ها به صورت کاملاً مجزا از یک دیگر قرار گرفته و سپس عکس‌برداری انجام شد که می‌تواند دلیل دقت بالاتر نتایج آن‌ها در مقایسه با تحقیق حاضر باشد. در تحقیق (Sitton et al. (2017) [۲۲] از شبکه عصبی معمولی برای طبقه‌بندی خاک استفاده نمودند که دقت آن بستگی به روش و مقدار نویز اعمالی دارد و با افزایش تعداد نمونه‌های خاک دقت آن افزایش یافت. با وجود استفاده از ۶۲۴ نمونه خاک، حداکثر دقت روش آن‌ها به ۸۹٪ درصد رسید که نسبت به یادگیری عمیق با تعداد نمونه‌های بسیار کمتر، دقت قابل توجهی نمی‌باشد. علاوه بر این موارد، (Srivastava et al. (2021) [۲۳] با مرور روش‌های مختلف بینایی کامپیوتر و یادگیری عمیق دریافتند که برای طبقه‌بندی خاک، شبکه‌های عصبی مصنوعی معمولی، الگوریتم جنگل تصادفی، روش بردار پشتیبان و روش رگرسیون چند جمله‌ای به ترتیب دقتی در حدود ۹۰، ۷۷، ۹۵ و ۸۶ درصد دارند، در حالی که روش شبکه عصبی

پیچشی می‌تواند به دقتی تا بیش از ۹۹٪ دست یابد. این موضوع بیانگر قابلیت بسیار بالای روش یادگیری عمیق پیچشی برای استفاده در طبقه‌بندی خاک و مصالح دانه‌ای است که در این تحقیق نیز مورد استفاده قرار گرفته است.

#### ۴- جمع‌بندی و نتیجه‌گیری

به منظور افزایش بهره‌وری در پروژه‌های ساخت ابنیه، در تحقیق حاضر یک رویکرد جدید برای انجام طبقه‌بندی خاک و مصالح دانه‌ای معرفی شده است. در این رویکرد نمونه‌های مختلف خاک و دانه‌های سنگی پس از جمع‌آوری و تهیه تصاویر مناسب از آن‌ها، دانه‌بندی می‌شوند. سپس این تصاویر و طبقه‌بندی‌های مربوطه به عنوان یک پایگاه داده برای آموزش یک شبکه یادگیری عمیق مورد استفاده قرار می‌گیرند. شبکه ذکر شده پس از آموزش قادر خواهد بود نتایج طبقه‌بندی نمونه‌های جدید را با دقت نسبتاً مناسبی پیش‌بینی نماید. لازم به ذکر است هر چقدر تعداد نمونه‌ها و عکس‌ها بیشتر باشد، پایگاه داده غنی‌تر و شبکه آموزش یافته دقت بالاتری در تشخیص تصاویر جدید خواهد داشت. خلاصه نتایج حاصل شده از این پروژه به صورت زیر قابل بیان است:

- در فرآیند آموزش شبکه لازم است ۱۰ الی ۱۵ درصد داده‌ها از داده‌ها (تصاویر) از داده‌های آموزشی جدا شده و در مرحله آزمایش مدل مورد استفاده قرار گیرند.

- در صورت استفاده از تصاویر اخذ شده با دوربین‌های متفاوت، ابعاد تصاویر باید با ابعاد تصاویر مورد استفاده برای آموزش شبکه منطبق گردند. برای این کار ابعاد بسته به وضوح و تعداد پیکسل‌ها مقیاس می‌شوند که در کد مربوطه گنجانده شده است.

- برای رسیدن به بالاترین دقت در صحت‌سنجی، لازم است در مرحله آموزش داده‌ها حدود ۹۰٪ تصاویر برای آموزش و مابقی برای صحت‌سنجی مورد استفاده قرار گیرند.

- در این پروژه شبکه یادگیری عمیق آموزش دیده می‌تواند با دقت بیش از ۸۰٪ درصد طبقه‌بندی تصاویر جدید را پیش‌بینی نمود.

- حتی در مواردی که طبقه‌بندی پیش‌بینی شده کاملاً منطبق بر دانه‌بندی خاک نبود، تشخیص گروه‌بندی‌های اصلی چهارگانه خاک (شن، ماسه، لای و رس) توسط شبکه به درستی صورت گرفت.

- برای تهیه تصاویر حتماً لازم است نمونه خاک جدا شوند و در محل بدون نور مستقیم خورشید عکس تهیه گردد. با تهیه تصاویر جدید از نمونه‌های خاک و ادامه آموزش شبکه حاضر می‌توان وسعت تشخیص شبکه آموزش دیده کنونی را ارتقاء بخشید و به دقت‌های بالاتر دست یافت.

در خصوص کاربرد این روش برای تشخیص درصد شن و ماسه در بتن، می‌توان نمونه‌هایی با درصد‌های مختلف شن و ماسه تهیه نمود و تعلیم شبکه را بر اساس آن‌ها انجام داد. در این حالت شبکه آموزش یافته قادر خواهد بود درصد شن و ماسه نمونه‌های جدید را با دقت مناسبی انجام دهد. این روش در آینده می‌تواند به منظور افزایش سرعت اجرای پروژه‌های ساخت ابنیه و کاهش هزینه‌های مرتبط به عنوان جایگزین مناسب روش دانه‌بندی الک مد نظر قرار گیرد.

#### ۵- تقدیر و تشکر

نویسندگان مقاله از پرسنل و کارشناسان محترم آزمایشگاه شرکت پی‌سازان لیدوما به جهت همکاری در انجام دانه‌بندی نمونه‌های خاک و فراهم نمودن فضای لازم برای آماده‌سازی و عکس‌برداری از نمونه‌ها کمال تشکر و قدردانی را می‌نمایند.

#### ۶- مراجع

[1] Withee, J. (2016). *FHWA Highway Materials Engineering Course, Federal Highway Administration, Washington, DC.*

[2] Mora, C. F., Kwan, A. K. H., Chan, H. C. (1998). *Particle size distribution analysis of coarse aggregate using digital image processing. Cement and Concrete Research, 28(6), 921-932.*



- [3] Han, J., Wang, K., Wang, X., Monteiro, P. J. (2016). 2D image analysis method for evaluating coarse aggregate characteristic and distribution in concrete. *Construction and Building Materials*, 127, 30-42.
- [4] Mouret, M., Ringot, E., & Bascoul, A. (2001). Image analysis: a tool for the characterisation of hydration of cement in concrete—metrological aspects of magnification on measurement. *Cement and Concrete Composites*, 23(2-3), 201-206.
- [5] Baddeley, A., Jensen, E. B. V. (2004). *Stereology for statisticians*. CRC Press.
- [6] Ozen, M., Guler, M. (2014). Assessment of optimum threshold and particle shape parameter for the image analysis of aggregate size distribution of concrete sections. *Optics and Lasers in Engineering*, 53, 122-132.
- [7] Yang, J., Yu, W., Fang, H. Y., Huang, X. Y., & Chen, S. J. (2018). Detection of size of manufactured sand particles based on digital image processing. *PloS one*, 13(12).
- [8] Barman, U., & Choudhury, R. D. (2019). Soil texture classification using multi class support vector machine. *Information Processing in Agriculture*.
- [9] Gui, X., Zheng, X. Y., Song, J. W., & Peng, X. (2011). Automation bridge design and structural optimization. In *Applied Mechanics and Materials (Vol. 63, pp. 457-460)*. Trans Tech Publications Ltd.
- [10] Alqedra, M., Arafa, M., & Ismail, M. (2011). Optimum cost of prestressed and reinforced concrete beams using genetic algorithms. *Journal of artificial intelligence*, 4(1).
- [11] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems (pp. 1097-1105)*.
- [12] Meziane, S., Bahi, L., & Ouadif, L. (2018, November). Automatic Recognition of Pavement Degradation: Case of Rif Chain. In *International Congress and Exhibition " Sustainable Civil Infrastructures: Innovative Infrastructure Geotechnology"* (pp. 135-144). Springer, Cham.
- [13] de Oliveira Morais, P. A., de Souza, D. M., de Melo Carvalho, M. T., Madari, B. E., & de Oliveira, A. E. (2019). Predicting soil texture using image analysis. *Microchemical Journal*, 146, 455-463.
- [14] Cortina-Januchs, M. G., Quintanilla-Dominguez, J., Vega-Corona, A., Tarquis, A. M., & Andina, D. (2011). Detection of pore space in CT soil images using artificial neural networks. *Biogeosciences*, 8(2), 279-288.
- [15] Azizi, A., Gilandeh, Y. A., Mesri-Gundoshmian, T., Saleh-Bigdeli, A. A., & Moghaddam, H. A. (2020). Classification of soil aggregates: A novel approach based on deep learning. *Soil and Tillage Research*, 199, 104586.
- [16] ASTM D6913-04, "standard test methods for particle size distribution of soils," American Society for Testing of Materials, Pennsylvania, PA, USA
- [17] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1-9)*.
- [18] Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- [19] Shu, M. (2019). Deep learning for image classification on very small datasets using transfer learning.
- [20] Alqahtani, A., & Whyte, A. (2016). Estimation of life-cycle costs of buildings: regression vs artificial neural network. *Built Environment Project and Asset Management*.
- [21] Newman, M. E. (2005). Power laws, Pareto distributions and Zipf's law. *Contemporary physics*, 46(5), 323-351.
- [22] Sitton, J. D., Zeinali, Y., & Story, B. A. (2017). Rapid soil classification using artificial neural networks for use in constructing compressed earth blocks. *Construction and Building Materials*, 138, 214-221.
- [23] Srivastava, P., Shukla, A., & Bansal, A. (2021). A comprehensive review on soil classification using deep learning and computer vision techniques. *Multimedia Tools and Applications*, 1-28.