

در این مقاله استفاده از تصویرنمایی کامپیوتری (CV) و روش‌های یادگیری ماشین برای دسته‌بندی آخال‌های غیر فلزی در فولاد بر اساس تصاویر الکترون برگشتی (BSE) میکروسکوپ الکترونی روبشی (SEM) بدست آمده در طی آنالیز خودکار آخال تشریح می‌شود. استفاده از آنالیز خودکار آخال سهم عمده‌ای در کنترل آخال‌ها در طی فرآوری فولاد و درک مکانیزمی سیر تحول آخال ایجاد کرده است [۱-۳]. آنالیز خودکار از یک SEM مجهز به آشکارساز BSE و طیف‌سنجی پراکنش انرژی اشعه ایکس (EDS) استفاده می‌کند. هزاران ویژگی را می‌توان در دامنه ساعت‌ها مشاهده کرد که نمایه‌هایی از توزیع متغیر را ارائه می‌دهند. تصاویر BSE اطلاعات کمی (اندازه‌ای) در مورد مقدار، اندازه، شکل و محل فراهم می‌سازند، در حالی که طیف‌های EDS اطلاعاتی در مورد ترکیب شیمیایی ارائه می‌دهند. تصاویر BSE همچنین حاوی اطلاعاتی در مورد ترکیب آخال است، زیرا تولید الکترون‌های برگشتی با عدد اتمی افزایش می‌یابد. هدف از این مطالعه ایجاد سیستمی بود که تصاویر BSE را به اندازه‌گیری‌های ترکیب EDS مرتبط کند. این کار مستلزم تبدیل تصاویر BSE به نمایش عددی است تا بتواند توسط رایانه تفسیر شود.

وقتی انسان به یک تصویر نگاه می‌کند، اطلاعات را بر اساس کل صحنه شناسایی می‌کند. حیطه تصویرنمایی کامپیوتری با استخراج ویژگی‌های مفید تصاویر با استفاده از مدل‌های ریاضی و آماری برای توصیف اطلاعات تصویری مانند لبه‌ها، گوشه‌ها و حباب‌های موجود در تصاویر سروکار دارد [۴]. سپس این ویژگی‌ها را می‌توان برای نمایش عددی تصویر با هم ترکیب کرد. یک رویکرد دیگر تصویرنمایی کامپیوتری از شبکه‌های عصبی پیچیده (CNN<sup>۲</sup>) استفاده می‌نماید، که نوعی الگوریتم یادگیری عمیق ماشین است که در انجام وظایف تشخیص تصویر بسیار خوب عمل می‌کند [۵، ۶]. یک CNN تصویر اولیه را از چند مجموعه دسته‌بندی‌کننده (کلاسیفایر) استفاده می‌نماید که احتمال اینکه یک تصویر به یک دسته معین تعلق داشته باشد را مشخص می‌کند. هم فیلترها و هم دسته‌بندی‌کننده از داده‌های آموزشی آموخته (یادگیری) می‌شوند. پس از آموزش، می‌توان از این مدل برای دسته‌بندی تصاویر اضافی استفاده کرد. یک مزیت رویکرد CNN این است که برای شناسایی انواع ویژگی‌های مورد نظر به انسان احتیاج ندارد؛ در عوض، آنها را از داده‌ها می‌آموزد.

CNN ها نوعی الگوریتم یادگیری ماشین هستند. روش‌های یادگیری ماشین سعی در آنالیز خودکار داده‌ها یا انجام پیش‌بینی از داده‌ها بدون دخالت انسان دارند. دو دسته کلی روش یادگیری ماشین وجود دارد: تحت نظارت و بدون نظارت. تفاوت اصلی بین آنها این است که آیا انسان برچسب‌هایی را به داده‌ها اختصاص می‌دهد یا خیر. برای یادگیری تحت نظارت، داده‌ها با حقیقت پایه برچسب‌گذاری می‌شوند (برای مثال، برای یک عکس، برچسب حقیقت پایه ممکن است "گربه" یا "سگ" باشد). توابع برای نقشه‌برداری از رابطه بین داده‌ها و حقیقت پایه ساخته می‌شوند. دسته‌بندی و رگرسیون دو نمونه متداول یادگیری ماشین از نوع تحت نظارت هستند. روش‌های یادگیری بدون نظارت استنتاج را از مجموعه داده‌هایی که فاقد برچسب هستند، استخراج می‌کنند. متداول‌ترین روش یادگیری بدون نظارت، آنالیز خوشه‌ای است که برای آنالیز داده‌های اکتشافی برای یافتن الگوها یا گروه‌بندی‌های پنهان در داده‌ها مورد استفاده قرار می‌گیرد.

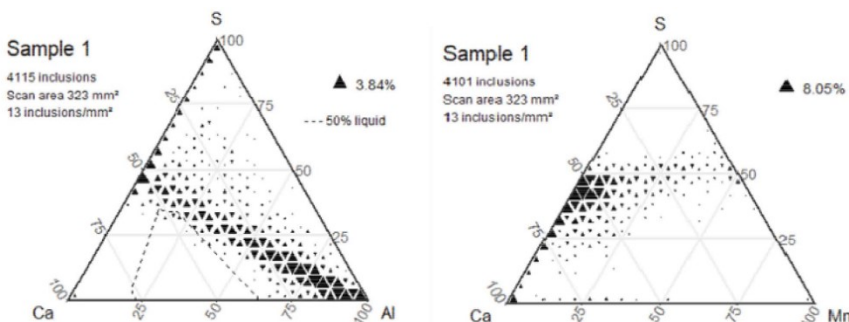
<sup>۱</sup> - Inclusion Classification by Computer Vision and Machine Learning, IRON & STEEL TECHNOLOGY, OCT 2020.

<sup>۲</sup> - convolutional neural networks

در این مطالعه، یک CNN برای تشخیص ویژگی‌های تصویر، ایجاد نمایش عددی این ویژگی‌ها و سپس استفاده از این نمایش‌ها برای دسته‌بندی بکار گرفته شد. مجموعه‌ای از داده‌های آنالیز خودکار آخال مورد استفاده قرار گرفت برای:

- آموزش - از تصاویر و دسته‌بندی آنها به عنوان ورودی استفاده می‌شود. الگوریتم‌های CNN پارامترهای مدل را بهینه می‌کنند بطوری که پیش‌بینی مدل با دسته‌بندی حقیقت پایه مطابقت داشته باشد.
- اعتبارسنجی - زیرمجموعه‌ای از داده‌های آموزشی به عنوان بررسی بهینه‌سازی پارامتر و همچنین برای تنظیم دستی پارامتر مورد استفاده قرار گرفت.
- آزمایش - مجموعه‌ای از تصاویر (متمايز از مواردی که برای آموزش و اعتبارسنجی استفاده می‌شوند) توسط CNN دسته‌بندی شده و دسته‌بندی‌ها با حقیقت پایه مقایسه می‌شوند.

این رویه نمونه‌ای از یادگیری ماشین از نوع تحت نظارت است. در این کار، مشاهدات یا به عنوان "آخال" یا "غیرآخال" دسته‌بندی شدند، یعنی، یک دسته‌بندی‌کننده دوتائی ایجاد شد. در آینده، دسته‌های دیگری می‌توانند اضافه شوند بطوری که روابط بهتری بین تصویر BSE و ترکیب شیمیایی بتوانند ایجاد شوند. این رویکرد می‌تواند نیاز به آنالیز EDS در طی آنالیز خودکار آخال را کاهش دهد.



## مواد و روش‌ها

### جزئیات آنالیز نمونه و تعیین

#### خودکار آخال - داده‌های آنالیز

خودکار آخال از چهار نمونه فراهم شد. داده‌ها از سیستم ابزار آنالیز خودکار تمیزی فولاد (ASCAT) گردآوری شد. هر نمونه از ذوب‌های مختلف محصول صفحه

شکل 1 - نمودارهای سه‌تایی نشان‌دهنده ترکیبات آخال نماینده برای چهار نمونه مورد بررسی در این مطالعه است.


محورها بر حسب کسر مولی S, Mn, Ca یا S, Mn, Ca می‌باشند. اندازه نماد متناسب با تراکم تعداد آخال‌های ترکیب خاصی است.

(پلیت) برداشته شد. هم تصاویر BSE (وضوح ۱۲۸ \* ۱۲۸) و هم داده‌های EDS فراهم شد. در مجموع ۴۹۳۷۲ مشاهده برای چهار نمونه انجام شد. از این مجموعه داده‌ها، ۱۵۹۲۴ مشاهده دسته‌بندی شده به عنوان "آخال" و ۳۱۲۸ مشاهده دسته‌بندی شده به عنوان "غیرآخال" توسط قواعد داخلی ASCAT انتخاب شدند. مشاهدات باقیمانده نیز طبق قواعد به عنوان "غیرآخال" دسته‌بندی شدند اما برای این آنالیز انتخاب نشدند زیرا آنها از میدان‌های دید خالی یا ذرات بسیار کوچک با تعداد EDS کم تشکیل شده بودند. دسته‌بندی‌های ASCAT به عنوان حقیقت پایه برای آنالیز تصویرنمایی کامپیوتری در نظر گرفته شدند.


### روش‌های تصویرنمایی کامپیوتری - مجموعه داده‌ها ابتدا متوازن شدند، یعنی شامل تعداد مساوی مشاهدات "آخال" و "غیرآخال" شدند.

این کار با نمونه‌گیری تصادفی ۳۱۲۸ مشاهده از دسته "آخال" انجام شد. بنابراین کل اندازه مجموعه داده‌ها ۶۲۵۶ تصویر بود. از این مجموعه داده‌ها، ۴۰۰۳ مشاهده برای آموزش مدل، ۱۰۰۱ مشاهده برای اعتبارسنجی مدل در طی آموزش و ۱۲۰۰۲ مشاهده برای آزمایش مدل پس از اتمام آموزش مورد استفاده قرار گرفتند.

در این مطالعه، از یک CNN در دسترس عموم، VGG16 استفاده شد. این CNN برای کارهای دسته‌بندی تصویر در طیف گسترده‌ای از تصاویر ایجاد شده است. پارامترهای اولیه مدل برای VGG16 CNN از قبل آموزش دیده در پایگاه داده ImageNet بکار گرفته شدند. ImageNet یک پایگاه داده با بیش از ۱ میلیون تصویر طبیعی از اشیاء مختلف روزمره است (اما بدون میکروگراف). با وجود داشتن ارتباط اندکی با آخال‌ها، ویژگی‌های تولید شده از فرآیند انتقال یادگیری، نمایانگر اطلاعات مفهومی سطح بالایی است که می‌تواند برای مشکلات خارج از محدوده پایگاه داده آموزش اصلی به خوبی مورد استفاده قرار گیرد.



شکل ۲- تصاویر اسکن الکترون برگشتی (BSE) میکروسکوپ الکترونی روبشی (SEM) از ویژگی‌های دسته‌بندی شده به عنوان (a) "آخال" و (b) "غیرآخال" توسط قواعد داخلی ASCAT. این تصاویر نمونه‌هایی از آنهایی است که برای آنالیز CV استفاده شده است.



شکل ۳- دقت داده‌های آموزش و اعتبارسنجی در طی فرآیند آموزش مدل VGG16. بالاترین دقت آموزش بدست آمده تقریباً ۹۶ درصد بود.

داده‌های آموزش از مدل عبور می‌کنند و پارامترهای آن تنظیم می‌شود) آموزش دیده است. دقت‌ها، بیان شده به صورت درصد مشاهدات صحیح دسته‌بندی شده نسبت به تعداد کل مشاهدات، برای داده‌های آموزش و اعتبارسنجی در طی فرآیند آموزش در شکل ۳ نشان داده شده است.

|            |               |     |     |
|------------|---------------|-----|-----|
| True Label | Non-Inclusion | 608 | 18  |
|            | Inclusion     | 7   | 619 |

شکل ۴- ماتریس سردرگمی پیش‌بینی‌های مدل CV از مجموعه داده‌های آزمایش. مسیرهای مورب پیش‌بینی‌های صحیحی برای دسته "آخال" و "غیرآخال" را نشان می‌دهد.

[۸،۷]. این یک مثال از انتقال یادگیری، یک روش در یادگیری ماشین است که توسط آن دانش یک مسئله را می‌توان برای مسئله دیگری به کار برد. منطق انتقال یادگیری این است که همه اشیا در واقع دارای برخی ویژگی‌های مشترک هستند. از ویژگی‌های یادگیری شده از یک پایگاه داده می‌توان برای استخراج ویژگی‌ها از پایگاه داده مشابه دیگر استفاده کرد حتی اگر برخی از تصاویر قبلاً هرگز توسط مدل دیده نشده باشند. در این مسئله، محققان می‌خواستند ببینند که آیا پارامترها یا ویژگی‌های یادگیری شده از تعداد زیادی از تصاویر طبیعی (مجموعه داده ImageNet) همچنان در مورد ویژگی‌های یادگیری شده از داده‌های آخال بکار می‌روند یا نه [۱۰،۹]. برای انجام این کار، اول VGG16 با پارامترهایی که در پایگاه داده ImageNet یادگیری شده‌اند، مورد استفاده قرار می‌گیرد، اما دسته‌بندی کننده بازآموزی می‌شود. یعنی، سیستم بجای شناسایی تصاویر متعلق به یکی از دسته‌های ImageNet (گربه، هواپیما و غیره)، آنها را به عنوان "آخال" یا "غیرآخال" دسته‌بندی می‌کند.

## نتایج و بحث

نمودارهای سه تایی نشان‌دهنده ترکیبات آخال اندازه‌گیری شده توسط EDS در شکل ۱ آورده شده‌اند (فقط برای نمونه ۱ نشان داده شده است، اما ترکیبات آخال در نمونه‌های دیگر بسیار مشابه بود) تصاویر نماینده BSE مشاهدات دسته‌بندی شده توسط قواعد ASCAT به عنوان "آخال" و "غیرآخال" در شکل ۲ نشان داده شده است. دسته‌بندی کننده VGG16 برای ۱۵ دوره (یعنی تعداد دفعاتی که

نتایج حاصل از مجموعه داده‌های آزمایش به صورت یک ماتریس سردرگمی در شکل ۴ نشان داده شده است. در این نمودار مسیرهای مورب پیش‌بینی‌های صحیح برای دسته "آخال" و "غیر-آخال" را نشان می‌دهند. دقت کلی پیش‌بینی‌های مدل برای داده‌های آزمایش ۹۸ درصد بود.


فرآیند آموزش CNN برای ۴۰۰۳ تصویر به ۲۸۰ ثانیه زمان نیاز داشت (تقریباً ۷۰ میلی‌ثانیه برای هر مشاهده). میانگین زمان صرف شده آنالیز تصاویر آزمایش ۶۹ میلی‌ثانیه برای هر تصویر بود. بر اساس شیوه راه‌اندازی آنالیز، اسکن‌های EDS برای هر ویژگی به

۱۰۰۰ میلی‌ثانیه نیاز داشتند.

یک مطالعه قبلی [۱۱] از رویکرد مشابه CNN در مجموعه داده‌های مختلف آخال که در یک SEM دیگری گردآوری شده بود، استفاده کرد. در آن مطالعه دقت داده‌های آزمایش ۷۲ درصد بود. **شکل ۵** تصاویر نماینده نشان‌دهنده تفاوت بین دو مجموعه داده را ارائه می‌دهد. به نظر می‌رسد تصاویر با کنتراست بالاتر از مجموعه داده‌های فعلی، دقت رویکرد CNN را بهبود می‌بخشند.

### نتیجه‌گیری

این مطالعه نشان داد که می‌توان از یک رویکرد تصویرنمایی کامپیوتری برای پیش‌بینی اینکه آیا یک مشاهده آخال هست یا نه با دقت بالا استفاده کرد. این پیش‌بینی فقط بر اساس تصاویر BSE انجام شده است. مرحله بعدی در این مطالعه دسته‌بندی آخال‌ها بر حسب ترکیب شیمیایی فقط بر اساس تصاویر BSE است. تأثیر پارامترهای تنظیم SEM و تصاویر BSE حاصل نیز مهم نشان داده شد. روش‌هایی برای انطباق با تغییرپذیری در تصاویر BSE باید توسعه یابد. اما، با کنترل مناسب تنظیم میکروسکوپ و با داده‌های کافی برای آموزش مدل، رویکرد CNN قابلیت کمک به فیلتر کردن (یعنی، شناسایی مشاهداتی که قبل از اندازه‌گیری EDS آخال نیستند) و همچنین برای کاهش نیاز به اندازه‌گیری EDS در طی آنالیز خودکار آخال را دارد.



شکل ۵- تصاویر نماینده BSE از دو مجموعه داده آنالیز خودکار آخال، از [x]، دسته‌بندی شده به عنوان "آخال" (a)، از [x]، دسته‌بندی شده به عنوان "غیرآخال" (b)، از این مطالعه، دسته‌بندی شده به عنوان "آخال" (c)، و از این مطالعه، دسته‌بندی شده به عنوان "غیرآخال" (d).

### منابع

1. S.R. Story, S.M. Smith, R.J. Fruehan, G.S. Casuccio, M.S. Potter and T.L. Lersch, "Application of Rapid Inclusion Identification and Analysis," *Iron & Steel Technology*, September 2005, pp. 41–49.
2. E.B. Pretorius, H.G. Oltmann and B.T. Schart, "An Overview of Steel Cleanliness From an Industry Perspective," *AISTech 2013 Conference Proceedings*, Vol. I, 2013, pp. 993–1026.
3. P. Kaushik, J. Lehmann and M. Nadif, "State of the Art in Control of Inclusions, Their Characterization, and Future Requirements," *Metall. Mater. Trans. B*, Vol. 43, No. 4, 2012, pp. 710–725.
4. R. Szeliski, *Computer Vision*, Springer, London, U.K., 2011.
5. Y. Guo, Y. Liu, A. Oerlemans, S. Lao, S. Wu and M.S. Lew, "Deep Learning for Visual Understanding: A Review," *Neurocomputing*, Vol. 187, 2016, pp. 27–48.
6. Y. LeCun, Y. Bengio and G. Hinton, "Deep Learning," *Nature*, Vol. 521, No. 7553, 2015, pp. 436–444.
7. K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," September 2014.
8. T. Mueller, A.G. Kusne and R. Ramprasad, *Machine Learning in Materials Science*, John Wiley & Sons Ltd., 2016, pp. 186–273.
9. K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," September 2014.
10. O. Russakovsky et al., "ImageNet Large-Scale Visual Recognition Challenge," *Int. J. Comput. Vis.*, Vol. 115, No. 3, 2015, pp. 211–252.
11. M. Abdulsalam, N. Gao, E.A. Holm and B.A. Webler, "Classification of Non-Metallic Inclusions Via Computer Vision and Machine Learning," *Clean Steel 9 Proceedings*, Budapest, Hungary, September 2018.