

طبقه‌بندی خود کار فاز فولاد در تصاویر

میکروسکوپ الکترونی روبشی

زهرا فیروز مهجن آبادی^۱، پوریا جعفری^{*۲}، مهدی رضائی^۳

کارشناس ارشد گروه مهندسی مخابرات، دانشکده مهندسی برق و کامپیوتر، دانشگاه سیستان و بلوچستان، زاهدان، ایران^۱

استادیار گروه مهندسی برق و الکترونیک، دانشکده مهندسی برق و کامپیوتر، دانشگاه سیستان و بلوچستان، زاهدان، ایران^{*۲}

دانشیار گروه مهندسی برق و الکترونیک، دانشکده مهندسی برق و کامپیوتر، دانشگاه سیستان و بلوچستان، زاهدان، ایران^۳

چکیده

خواص فولادها وابسته به اجزای ریزساختاری به نام فاز است که در فرایند تولید آن شکل می‌گیرد. فازهای مختلف فولاد در تصاویر میکروسکوپی سطح فولاد قابل مشاهده‌اند. تشخیص و طبقه‌بندی خودکار انواع فازها از روی تصاویر منجر به درک بهتری از خواص فولاد با سرعت و دقت بالاتر می‌شود. در این مقاله برای نخستین بار، روشی برای طبقه‌بندی خودکار و هوشمند فازهای فولاد از روی تصاویر میکروسکوپی ارائه می‌شود. این کار نیازمند تعریف و استخراج ویژگی‌های مناسب بافت منحصر به فرد این تصاویر و بخش‌بندی تصاویر به مناطقی با اشکال بسیار نامنظم بر اساس ویژگی‌های استخراج شده است؛ بدین منظور ابتدا تصویر ورودی بلوک‌بندی شده و برای هر بلوک به صورت مستقل یک سری از ویژگی‌های بافت تصویر استخراج می‌شوند. تعداد این ویژگی‌ها به وسیله روش تحلیل مؤلفه‌های اصلی کاهش یافته و سپس به شبکه عصبی پیشینه‌هموار برای طبقه‌بندی هر بلوک از تصویر داده می‌شوند. نتایج پیاده‌سازی نشان می‌دهد که دقت روش پیشنهادی در طبقه‌بندی دو فاز سوزنی و مرزدانه‌ای بالای ۹۹ درصد و همچنین در طبقه‌بندی سه فاز مرزدانه‌ای، سوزنی و ویدمن اشتاتن بالای ۸۶ درصد است.

واژگان کلیدی: تصاویر میکروسکوپی الکترونی روبشی، فازهای فولاد، طبقه‌بندی خودکار، شبکه عصبی مصنوعی پیشینه‌هموار، الگوریتم کی-میانگین.

Automated Classification of Steel Phases in Scanning Electron Microscope Images

Zahra Firuz Mahjanabadi¹, Pouria Jafari^{*2} and Mehdi Rezaei¹

M-Eng Department of Telecommunications, Faculty of Electrical and Computer Engineering, University of Sistan and Baluchestan, Zahedan, Iran¹

Assistant Professor of Department of Electrical and Electronics Engineering, Faculty of Electrical and Computer Engineering, University of Sistan and Baluchestan, Zahedan, Iran^{*2}

Associate Professor of Department of Electrical and Electronics Engineering, Faculty of Electrical and Computer Engineering, University of Sistan and Baluchestan, Zahedan, Iran³

Abstract

The properties of steels are intrinsically dependent on their microstructural components, known as phases, which form during the manufacturing process. Different steel phases can be observed in microscopic images of steel surfaces. Automatic detection and classification of these phases from images can significantly enhance the understanding of steel properties with improved speed and accuracy. This paper introduces, for the first time, an intelligent and automated method for classifying steel phases from microscopic images. This process requires defining and extracting suitable texture features unique to these images and segmenting the images into highly irregular regions based on the extracted features. To achieve this, the input image is initially divided into blocks, and texture features are extracted

* Corresponding author

* نویسنده عهده‌دار مکاتبات

independently for each block. The dimensionality of these features is then reduced using Principal Component Analysis, and the refined features are subsequently fed into a Softmax neural network for classification.

The implementation results indicate that the proposed method achieves an accuracy of over 99% in distinguishing between two phases: acicular ferrite and granular ferrite. Furthermore, it attains an accuracy exceeding 86% when classifying three phases: granular ferrite, acicular ferrite, and Widmanstätten ferrite. This suggests that the widely used and conventional k-means clustering method, as a traditional machine learning approach, is incapable of effectively distinguishing microscopic steel phase blocks using extracted texture features. Notably, as of the writing of this paper, no prior research has been conducted on the automatic classification of different ferrite phases, making this study a novel contribution to the field.

In this research, an automated classification algorithm for ferrite phase structures in SEM images of steel is proposed using texture feature extraction methods and machine learning models. The dataset comprises images of 1024×768 resolution, which were divided into 128×128 blocks, with classification performed independently for each block. Due to the limited number of blocks available for training machine learning models, data augmentation techniques such as rotation and scaling were applied to increase the dataset size. Various image processing methods were used to extract 128 texture features. These extracted features were then used to classify different ferrite phases using two machine learning models: k-means clustering and the Softmax neural network. Additionally, PCA was employed to reduce feature dimensionality, which positively impacted the classification of granular and acicular ferrite. While k-means clustering, as a conventional and widely used machine learning method, failed to achieve satisfactory classification accuracy, the proposed approach using a smooth maximum neural network demonstrated exceptional performance. Despite the complex and irregular nature of ferrite shapes, the selected features and the proposed algorithm successfully achieved over 99% accuracy for two-phase classification and over 86% accuracy for three-phase classification.

Keywords: Scanning Electron Microscope, Automated Classification, Steel Phases, Neural Networks, K-Means Algorithm.

۱- مقدمه

فولاد با داشتن تنوع بالا، وجود خواص مکانیکی مفید و مقرون به صرفه بودن یکی از مهم‌ترین و پرمصرف‌ترین مصالح در کاربردهای مختلف صنعتی و ساختمانی است [۱]. به‌طور عمده خصوصیات مکانیکی، عملکرد فیزیکی و توانایی مکانیکی انواع مختلف فولاد به توزیع، شکل و اندازه فازها در ریزساختارها وابسته است که در فرایند تولید آن شکل می‌گیرد؛ به این ترتیب، شناسایی و طبقه‌بندی صحیح این ریزساختارها می‌تواند بسیار حائز اهمیت باشد [۲].

ریزساختارهای مختلف فولاد دارای ظاهر متفاوتی بوده و تحت تأثیر پارامترهایی چون عناصر آلیاژی، سرعت خنک‌سازی و عملیات حرارتی قرار دارند [۳]. با توجه به نحوه تولید فولاد و بسته به این پارامترها، ریزساختارها از فازهای مختلفی مانند فریت^۱، سمنتیت^۲، آستنیت^۳، پرلیت^۴، بینیتیک^۵ و مارتنزیت^۶ تشکیل شده‌اند که هرکدام از آن‌ها شکل‌های متفاوتی دارند. مهندسين مواد برای شناسایی فازهای فولاد از تصویربرداری با

میکروسکوپ‌های الکترونی استفاده می‌کنند؛ برای مثال در شکل (۱)، سه شکل مختلف فاز فریت به نام‌های فریت سوزنی^۷، ویدمن اشتاتن^۸ و مرزدانه‌ای^۹ نشان داده شده است [۴].

خواص گوناگون انواع مختلف فولاد کامل وابسته به فازهای و اشکال متفاوت آن‌ها هستند و شناسایی و طبقه‌بندی فازهای گوناگون در تصاویر میکروسکوپی منجر به درک عمیق‌تر و پیش‌بینی بهتر خواص فولاد می‌شود. امروزه وظیفه طبقه‌بندی اشکال مختلف فازهای فولاد از روی تصاویر میکروسکوپی برعهده یک متخصص علم مواد است؛ به‌طوری که در یک روند زمان‌بر با مشاهده دقیق قسمت‌های مختلف تصویر گرفته‌شده از فولاد و بر اساس تجربه و مشخصات ظاهری شکل آن یکی از طبقه‌های فاز را به آن اختصاص می‌دهد؛ علاوه بر این که چنین عملی زمان زیادی می‌گیرد، همواره با خطاهای انسانی و تصمیمات غیر یکتا همراه خواهد بود [۵]. با ارائه راه‌کاری برای طبقه‌بندی خودکار تصاویر میکروسکوپی فازهای مختلف فولاد بر اساس استانداردهای متالوگرافی هم در سرعت و هم در دقت می‌تواند بسیار چشم‌گیر، قابل توجه و کاربردی باشد.

¹ Ferrite

² Cementite

³ Austenite

⁴ Pearlite

⁵ Bainitic

⁶ Martensite

⁷ Acicular ferrite

⁸ Widmanstätten ferrite

⁹ Granular ferrite

تا به امروز پژوهش‌های زیادی روی تصاویر SEM انجام شده‌است، اما مطالعات نشان می‌دهد که هیچ کدام در راستای استخراج ویژگی شکل‌های مختلف فازهای فولاد نبوده‌است. تصاویر خاکستری SEM به جای نور مرئی با الکترون‌ها تشکیل می‌شوند و فقط حاوی اطلاعات دوبعدی‌اند؛ از آنجا که تصاویر رنگی از اهمیت بالاتری برخوردارند، در [۶] روشی ارائه داده‌اند که در آن با استفاده از یک جدول جست‌وجو بر اساس شدت روشنایی هر پیکسل یک رنگ به آن اختصاص داده می‌شود تا یک تصویر رنگی به دست بیاید. این روش به‌عنوان شبه‌رنگ یا رنگ کاذب شناخته می‌شود.


در مرجع [۷] یکی دیگر از روش‌های اضافه کردن رنگ به تصاویر SEM ارائه شده‌است. در این روش دو تصویر SEM از یک ماده در دو زاویه مختلف گرفته شده‌است؛ سپس اطلاعات ارتفاع به صورت غیرمستقیم محاسبه می‌شود. از آنجا که گرفتن عکس از نانو ساختارها از زوایای مختلف بسیار دشوار است؛ بنابراین بازسازی سه‌بعدی به‌سختی امکان‌پذیر است. در پژوهش دیگری از پردازش تصاویر بر روی تصاویر SEM گرفته‌شده از نمونه‌های نیمه‌هادی برای توصیف آن‌ها استفاده شده‌است. با برخورد الکترون‌های شلیک‌شده از میکروسکوپ با الکترون‌های موجود در نمونه سیگنال‌های مختلفی تولید می‌شود که با تجزیه و تحلیل آن‌ها می‌توان به توصیف نمونه‌ها پرداخت [۸]. در [۹] اطلاعات شدت روشنایی^۴ موجود در تصویر دو بعدی SEM برای بازسازی یک تصویر سه‌بعدی تصاویر از سطح نمونه استفاده شده‌است. در [۱۰] با استفاده از روش‌های پردازش تصویر روی تصاویر SEM سطوح ترک‌دار پارامترهایی از جمله مساحت، زاویه، و طول ترک را محاسبه می‌کند.

مطالعه پژوهش‌های پیشین و روش‌های معرفی شده بر روی تصاویر SEM نشان می‌دهند که تاکنون پژوهش خاصی بر روی جداسازی خودکار و هوشمند شکل فازهای میکروسکوپی فولاد انجام نشده‌است. در این مقاله روش هوشمندی ارائه می‌شود که با وجود تعداد کم تصاویر در دسترس SEM می‌تواند طبقه‌بندی فازهای مختلف فولاد را روی تصاویر SEM انجام دهد.

طبقه‌بندی با استفاده از مدل‌های یادگیری ماشین نیاز به استخراج ویژگی از تصاویر ورودی دارد. ویژگی‌ها انواع مختلفی دارند که مهم‌ترین آن‌ها ویژگی بافتی است. در این بخش تعدادی از روش‌هایی که برای استخراج ویژگی بافتی معرفی شده‌اند، بیان می‌شوند؛ برای نمونه در تشخیص سرطان سینه از روی تصاویر ماموگرافی از

در این مقاله هدف ارائه روشی برای طبقه‌بندی هوشمند و خودکار شکل‌های مختلف فاز فریت در تصاویر میکروسکوپ الکترونی است. بر اساس پژوهش‌ها چنین روش خودکاری تا کنون ارائه نشده‌است. در طراحی روش مورد نظر، به دلیل محدودیت در تعداد تصاویر در دسترس، نمی‌توان از روش‌های هوش مصنوعی که برای استخراج ویژگی خودکار نیازمند تعداد زیادی داده برای آموزش هستند استفاده کرد؛ به همین دلیل در این پژوهش ابتدا بر اساس روش‌های متداول پردازش تصویر، ویژگی‌های متناسب با طبقه‌های مختلف فاز فریت از دسته‌های تصویر استخراج می‌شوند؛ پس از به‌دست آوردن تعداد کافی از ویژگی‌های لازم برای طبقه‌بندی، با کمک روش‌های یادگیری ماشین کی-متوسط^۱ و شبکه عصبی مصنوعی^۲ طبقه‌بندی انجام می‌شود. برای افزایش تعداد نمونه تصاویر و تشکیل پایگاه داده مورد نیاز از روش‌های داده‌افزایی استفاده شده‌است.

ادامه این مقاله در پنج بخش تنظیم شده‌است. در بخش دوم مروری بر برخی پژوهش‌های پیشین روش‌های استخراج انجام می‌شود. در بخش سوم روش پیشنهادی و در بخش چهارم تحلیل نتایج به‌دست‌آمده از پیاده‌سازی روش پیشنهادی بیان می‌شود؛ در نهایت نتیجه‌گیری در بخش پنجم ارائه خواهد شد.



(شکل-۱): تصویر میکروسکوپ الکترونی از فولاد و فازهای فریت

مرزانه‌ای (A)، فریت ویدمن اشتاتن (C)، فریت سوزنی (D)
(Figure-1): Electron microscope image of steel and the phases of Granular ferrite (A), Widmanstätten ferrite (C), Acicular ferrite (D)

۲- پیشینه پژوهش

برای طبقه‌بندی فازهای مختلف فولاد از روی تصاویر میکروسکوپ الکترونی روبشی (SEM)^۳ نیاز به پیاده‌سازی روش‌های استخراج ویژگی مختص بافت تصویر است. این بخش مروری بر پیشینه پردازش تصویر در تصاویر SEM و مروری بر پیشینه استخراج ویژگی‌های بافتی خواهد داشت.

¹ K-means

² Artificial Neural Network

³ Scanning Electron Microscope

⁴ Contrast

ماتریس هم‌وقوعی سطح خاکستری (GLCM) که توصیف‌کننده بافت تصویر است، استفاده شده است [۱۱].

در پژوهش دیگری برای طبقه‌بندی تصاویر بادام زمینی روش‌های تبدیل موجک^۲، پالایه گابور^۳، الگوی باینری محلی^۴ (LBP)، ماتریس تفاوت سطح خاکستری^۵ (GLDM) و ماتریس هم‌وقوعی سطح خاکستری (GLCM) برای استخراج ویژگی‌های مختلف بافت پیشنهاد شده‌اند [۱۲]. در [۱۳] از تفاوت پالایه‌های گاوسی^۶ (DoG) برای تشخیص در تصاویر ماموگرافی استفاده کرده‌اند. برای اجرای این روش دو نسخه مات شده از تصویر اصلی با درجه تار متفاوت از هم کم می‌شوند. با استفاده از ویژگی‌های استخراج‌شده از پالایه‌های گاوسی و شبکه عصبی خودسازمانده^۷ تصاویر مربوط به ماموگرافی ناحیه‌بندی می‌شوند.

در [۱۴] یک الگوی سرآمد^۸ و جهتی محلی^۹ (LDEP) برای طبقه‌بندی بافت استفاده می‌شود. این روش الگوی شمارش اختلاف محلی جهت‌دار^{۱۰} (DLDCP)، به‌عنوان یک توصیف‌کننده محلی قوی اطلاعات مؤثر جهت و پیکسل بافت را ارائه و برای پیکسل‌های فرد و زوج استخراج می‌کند؛ سپس با استفاده از روش الگوی محلی مرتبط اکسترمم همسایه‌ها^{۱۱} (NERLP) اطلاعات مربوط به شدت روشنایی را نیز به‌دست می‌آورد. نتایج نشان می‌دهد که روش پیشنهادی نسبت به شرایط مختلف از جمله چرخش، تغییر اندازه، نوفه و روشنایی مقاوم عمل می‌کند.

۳- روش پیشنهادی

در این پژوهش یک الگوریتم طبقه‌بندی برای تشخیص سه شکل فریت به نام‌های فریت‌های سوزنی، ویدمن اشتاتن و مرزانه‌ای در تصاویر SEM فولاد پیشنهاد می‌شود؛ به این ترتیب که ابتدا هر تصویر میکروسکوپی الکترونی به بلوک‌های ۱۲۸ در ۱۲۸ تقسیم شده‌است تا طبقه‌بندی روی هر بلوک به‌صورت مجزا انجام پذیرد. با توجه به تعداد کم تصاویر موجود، داده‌افزایی مناسب با دو روش تغییر مقیاس و چرخش انجام شده‌است تا تصاویر بیشتری برای آموزش مدل طبقه‌بندی تولید شود. از روی تصاویر به‌دست‌آمده

ویژگی‌های مختلف بافت محاسبه، سپس ویژگی‌های مازاد حذف شده و مدل طبقه‌بند کی-میانگین و شبکه عصبی بیشینه‌هموار بر روی ویژگی‌ها اعمال می‌شود. در ادامه مراحل مختلف کار با جزئیات بیشتری تشریح می‌شود.

۳-۱- استخراج ویژگی

در ابتدا گفتنی است که به‌دلیل کم‌بودن تعداد تصاویر SEM از شکل‌های مختلف فریت، روش‌های یادگیری عمیق برای استخراج ویژگی و طبقه‌بندی قابل پیاده‌سازی نیستند؛ به همین دلیل ابتدا ویژگی‌های مورد نیاز برای طبقه‌بندی بافت فریت به‌وسیله الگوریتم‌های غیرهوشمند استخراج، سپس برای ویژگی‌های به‌دست‌آمده مدل یادگیری ماشین و هوشمند پیشنهاد می‌شود؛ همان‌طور که در قسمت شبیه‌سازی نشان داده می‌شود، این ویژگی‌ها کفایت لازم برای تشخیص طبقه هر بلوک از تصویر SEM فریت را دارا هستند.

با بررسی دقیق تصاویر SEM مشخص می‌شود که ویژگی‌های مناسب برای طبقه‌بندی این‌گونه تصاویر ویژگی‌های بافتی است؛ به همین دلیل ویژگی‌های بافتی تصاویر میکروسکوپی ارزیابی شده‌اند و از بین آن‌ها ویژگی‌هایی که برای تفکیک مناطق فریت مناسب‌ترند، انتخاب شده‌اند. در ادامه روش‌های استخراج ویژگی متناسب با بافت تصاویر SEM معرفی می‌شوند.

۳-۱-۱- ماتریس هم‌وقوعی سطح خاکستری (GLCM)

ماتریس هم‌وقوعی سطح خاکستری یک روش استخراج ویژگی بافت است که برای به‌دست‌آوردن ارتباط بین پیکسل‌ها مورد استفاده قرار می‌گیرد. ماتریس GLCM برای بلوک‌های تولیدشده در چهار زاویه صفر، ۹۰، ۴۵ و ۱۳۵ درجه با فاصله یک پیکسل بین پیکسل‌ها ($d=1$) تشکیل شده‌است و از این چهار ماتریس GLCM، چهار ویژگی آماری از جمله انرژی، شدت نور، هم‌بستگی و هم‌گونی استخراج می‌شود؛ در نتیجه شانزده ویژگی از هر بلوک تصویر به‌دست می‌آید [۱۱].

۳-۱-۲- تفاوت سطح خاکستری (GLDM)

در این روش خواص هر منطقه بر اساس تفاوت‌های سطح خاکستری دو پیکسل در نظر گرفته می‌شوند. ماتریس GLDM تصاویر در چهار موقعیت مختلف (0,d)، (d,d)، (d,0) و (d,d) به‌دست می‌آید که d، فاصله بین پیکسل‌ها بوده و در این پژوهش مقدار d یک پیکسل در نظر گرفته می‌شود؛ سپس دو ویژگی آماری، آنترپی^{۱۲} و میانگین از هر ماتریس GLDM استخراج می‌شود؛ در نتیجه هشت ویژگی از هر بلوک تصویر به‌دست می‌آید [۱۲].

¹ Gray Level Co-Occurrence Matrix

² Wavelet Transformation

³ Gabor Filter

⁴ Local Binary Pattern

⁵ Gray Level Difference Matrix

⁶ Difference of Gaussian filters

⁷ Self-organizing map

⁸ External

⁹ Locally Directional and Extremal Pattern

¹⁰ Directional local difference count pattern

¹¹ Neighbors extremum related local pattern

¹² Entropy

۳-۱-۳- الگوی شمارش اختلاف محلی جهت‌دار

اطلاعات جهت‌دار برای بافت بسیار حائز اهمیت است. روش الگوی شمارش اختلاف محلی جهت‌دار^۱ (DLDCP) برای دریافت اطلاعات جهت پیشنهاد می‌شود؛ زیرا در این روش تفاوت محلی بین همسایه در موقعیت‌های فرد و پیکسل مرکزی و همسایه در موقعیت‌های زوج و پیکسل مرکزی به‌عنوان اختلافات محلی به‌دست‌آمده و به‌عنوان ویژگی جهتی از بافت ذخیره می‌شود.

اطلاعات جهت‌دار با استفاده از اختلاف محلی بین پیکسل مرکزی و پیکسل‌های همسایه آن در موقعیت‌های زوج و فرد نشان داده می‌شود. با توجه به اطلاعات استخراج‌شده مشاهده می‌شود که اختلافات محلی بین پیکسل مرکزی و پیکسل‌های همسایه آن در موقعیت‌های زوج و فرد، چهار تفاوت جهت‌دار مختلف را در آن موقعیت‌ها ایجاد می‌کند. ابتدا با استفاده از روش DLDCP برای پیکسل مرکزی اطلاعات جهت استخراج می‌شود. با در نظر گرفتن یک پنجره به شعاع R در اطراف پیکسل، یک بار برای موقعیت‌های فرد اطراف پیکسل و بار دیگر برای موقعیت‌های زوج اطراف پیکسل و سپس برای مرکز، اطلاعات استخراج می‌شود. از هر کدام از ماتریس‌های اطلاعات نماد در موقعیت‌های زوج و فرد، ویژگی‌های آماری واریانس، میانگین، آنتروپی، انرژي، کورتوسیس^۲ و چولگی^۳ استخراج می‌شود؛ در نتیجه از هر ماتریس شش ویژگی و در مجموع دوازده ویژگی از هر بلوک تصویر به‌دست می‌آید؛ در ضمن اطلاعات بین پیکسل مرکزی و همسایه‌ها نیز به این دوازده ویژگی اضافه می‌شود [۱۴].

۳-۱-۴- الگوی موقعیت اکسترمم (ELP)

یک ویژگی مهم دیگر برای طبقه‌بندی تصاویر موقعیت مکانی پیکسل‌هایی است که در همسایگی یک پیکسل دارای بیشترین و کمترین شدت روشنایی هستند. در این روش با در نظر گرفتن یک همسایگی برای هر پیکسل، موقعیت پیکسل‌هایی که دارای بیشترین و کمترین شدت روشنایی هستند و همچنین شدت روشنایی آن‌ها استخراج می‌شود و به این ترتیب برای هر بلوک تصویر (۴) ماتریس به‌دست خواهد آمد که با محاسبه ویژگی‌های آماری واریانس، میانگین، آنتروپی، انرژي، کورتوسیس و چولگی، ۲۴ ویژگی از هر بلوک تصویر استخراج خواهد شد [۱۴].

۳-۱-۵- الگوی اختلاف اکسترمم (EDP)

در این روش در همسایگی هر پیکسل میانگین بیشترین و کمترین شدت روشنایی پیکسل‌های محاسبه می‌شوند و به

این ترتیب برای هر بلوک تصویر یک ماتریس به‌دست خواهد آمد که ویژگی‌های آماری واریانس، میانگین، آنتروپی، انرژي، کورتوسیس و چولگی روی آن محاسبه شده و در نتیجه شش ویژگی از هر بلوک تصویر استخراج می‌شود [۱۴].

۳-۱-۶- الگوی فشرده‌سازی اکسترمم (ECP)

در این روش برای هر پیکسل یک همسایگی در نظر گرفته و با استفاده از مقادیر اکسترمم در این همسایگی عددی محاسبه، که مانده تقسیم شدت روشنایی پیکسل مرکزی بر این عدد محاسبه می‌شود و به این ترتیب برای هر بلوک یک ماتریس به‌دست می‌آید. برای این ماتریس ویژگی‌های آماری همچون واریانس، میانگین، آنتروپی، انرژي، کورتوسیس و چولگی محاسبه و در نتیجه از هر بلوک تصویر شش ویژگی استخراج می‌شود [۱۴].

۳-۱-۷- اختلاف گاوسین (DoG)

DoG یک پالایه خطی است که از تفاضل پالایه گاوسی به‌دست می‌آید. در این پالایه فرکانس‌های عبوری مرتبط با لبه‌های موجود در تصاویر هستند. پالایه DoG دوبعدی به‌صورت همسان‌گرد تعریف می‌شود و کاربرهای متنوعی دارد. در اینجا به‌منظور استخراج ویژگی، تعداد پنج پالایه DoG دوبعدی با ابعاد ۸، ۱۶، ۲۴، ۳۲ و ۴۰ محاسبه شده و به هر بلوک تصویر اعمال می‌شود. در بلوک‌های حاصل از هر پالایه، شش ویژگی آماری شامل واریانس، میانگین، آنتروپی، انرژي، کورتوسیس و چولگی استخراج شده و در نتیجه سی ویژگی از هر بلوک تصویر به‌دست می‌آید [۱۳].

۳-۱-۸- تبدیل موجک گسسته (DWT)

از تبدیل موجک گسسته چهار زیرتصویر استخراج می‌شود، که عبارت‌اند از:

- ✓ I_{LL} که حاوی کلیات تصویر اولیه است،
- ✓ I_{LH} ، دربرگیرنده جزئیات افقی تصویر است،
- ✓ I_{HL} ، شامل جزئیات عمودی تصویر است،
- ✓ I_{HH} ، حاوی جزئیات قطری تصویر است [۱۵].

در نهایت شش ویژگی آماری میانگین، واریانس، چولگی، کورتوسیس، انرژي و آنتروپی از ضرایب موجک زیرتصویرها محاسبه می‌شود؛ در نتیجه ۲۴ ویژگی از هر بلوک تصویر به‌دست می‌آید. در کل با کنار هم قراردادن ویژگی‌های محاسبه‌شده ۱۲۸ ویژگی حاصل خواهد شد. این احتمال وجود دارد که بین این ویژگی‌ها همبستگی وجود داشته باشد؛ به همین دلیل برای رفع این مشکل و کاهش تعداد ویژگی‌های به‌دست‌آمده از روش تحلیل مؤلفه‌های اصلی^۶ (PCA) استفاده خواهد شد.

^۴ Difference of Gaussian (DoG)

^۵ Discrete Wavelet Transform (DWT)

^۶ Principal Component Analysis

^۱ Directional Local Difference Count Pattern

^۲ Kurtosis

^۳ Skewness

تصاویر میکروسکوپ الکترونیکی نوری مختلفی که در این مقاله مورد استفاده قرار گرفته‌اند از آزمایشگاه گروه مهندسی مواد دانشگاه سیستان و بلوچستان با دقت قابل قبولی به‌دست آمده‌اند. با توجه به اینکه در مجموعه تصاویر به‌دست‌آمده از SEM برای آموزش مدل‌های هوشمند داده زیادی وجود ندارد، ابتدا به‌ناچار با استفاده از روش‌های مختلف به داده‌افزایی پرداخته می‌شود. در این پژوهش از روش‌های بلوک‌بندی، چرخش و مقیاس‌دهی برای داده‌افزایی استفاده می‌شود.

برای انجام عملیات چرخش ابتدا تصویر به بلوک‌های ۱۲۸ در ۱۲۸ تقسیم می‌شود؛ سپس هر بلوک را با زاویه‌های ۴۵، ۹۰، ۱۲۰، ۱۳۵، ۱۵۰، ۱۸۰، ۲۲۵ و ۲۷۰ درجه چرخانده و تصاویر جدید به‌عنوان داده جدید ذخیره می‌شوند؛ همچنین برای انجام عملیات مقیاس‌دهی ابتدا تصویر به بلوک‌های بزرگ‌تر با هم‌پوشانی تقسیم‌بندی می‌شود؛ سپس هر کدام از بلوک‌ها با مقیاس‌های چهار و بیست درصد اندازه اصلی کاهش پیدا می‌کند و تصاویر جدید ساخته می‌شوند. برای افزایش تعداد تصاویر، بلوک‌های مقیاس‌بندی‌شده نیز با زوایای ۹۰، ۱۸۰ و ۲۷۰ درجه چرخانده شده و تصاویر جدید تشکیل می‌شوند.

۳-۳- روش‌های طبقه‌بندی

در این مقاله برای طبقه‌بندی از روش‌های کی-میانگین و شبکه عصبی مصنوعی به‌طور جداگانه استفاده شده‌است؛ به این صورت که پس از استخراج ویژگی‌های توضیح داده شده در بخش پیشین، تعداد آن‌ها با استفاده از روش PCA کاهش یافته و برای طبقه‌بندی فاز فریت تصویر ورودی به طبقه‌بندی کی-میانگین و یا طبقه‌بندی شبکه عصبی داده می‌شوند. جزئیات بیشتر در مورد روش‌های طبقه‌بندی در ادامه آمده‌است.

۳-۳-۱- خوشه‌بندی کی-میانگین^۱

الگوریتم کی-میانگین یکی از روش‌های خوشه‌بندی ساده و سریع است. این الگوریتم دارای یک پارامتر به نام k است که تعداد خوشه‌هایی را که باید به دست آید، مشخص می‌کند. الگوریتم کی-میانگین به این صورت عمل می‌کند که k داده به‌عنوان مرکز خوشه انتخاب می‌شوند؛ سپس فواصل سایر داده‌ها با مراکز خوشه‌ها محاسبه شده و داده‌ها به هر کدام از مراکز خوشه که نزدیک‌تر بودند در همان خوشه جای می‌گیرند. میانگین هر خوشه به‌عنوان مرکز جدید خوشه در

نظر گرفته می‌شود. این مراحل تا جایی ادامه پیدا می‌کند که خوشه‌ها بدون تغییر باقی بمانند. در تنظیم مراکز هر خوشه از برچسب داده‌ها استفاده نمی‌شود و به همین دلیل به روش کی-میانگین روش خوشه‌بندی بدون ناظر گفته می‌شود [۱۶] و [۱۷]. در این مقاله از روش کی-میانگین برای مقایسه با روش پیشنهادی استفاده شده‌است؛ زیرا یک الگوریتم خوشه‌بندی متداول در یادگیری ماشین به حساب می‌آید؛ برای این منظور ابتدا بدون در نظر گرفتن برچسب داده‌ها، خوشه‌بندی انجام می‌پذیرد؛ سپس با توجه به برچسب داده و بیشترین میزان فراوانی داده‌ها در هر خوشه، به آن خوشه یک برچسب زده می‌شود؛ به این ترتیب از این الگوریتم برای طبقه‌بندی بلوک‌های تصویر استفاده خواهد شد.

۳-۳-۲- شبکه عصبی مصنوعی

ساختار پایه شبکه‌های عصبی نورون‌ها هستند. هنگامی که به نورون‌های یک شبکه عصبی داده‌های ورودی اعمال می‌شود، ورودی‌ها در بردار وزن ضرب شده و از تابع فعال‌ساز^۲ (خطی یا غیرخطی) درون نورون عبور داده می‌شوند. خروجی شبکه عصبی از خروجی نورون‌ها حاصل خواهد شد. با مقایسه خروجی شبکه عصبی با خروجی مطلوب خطای عملکرد شبکه عصبی به‌دست می‌آید. در مواردی که هدف طبقه‌بندی است، تابع فعال‌سازی خروجی شبکه عصبی بیشینه‌هموار^۳ در نظر گرفته خواهد شد.

شکل (۲) نمودار جعبه‌ای شبکه عصبی استفاده شده در این مقاله با تابع فعال‌ساز بیشینه‌هموار (Softmax) را نشان می‌دهد. در این شبکه عصبی ورودی‌ها همان ویژگی‌های به‌دست‌آمده از بلوک‌های تصویرند که با x_i (امین ویژگی) مشخص شده‌اند. یک ورودی ثابت با مقدار یک نیز به‌عنوان بایاس در ورودی هر نورون در نظر گرفته می‌شود. ورودی‌ها از طریق وزن‌ها به نورون‌های لایه بعد متصل شده‌اند. W_{ji} وزن میان نورون j -ام در لایه دوم و ورودی i -ام است. مقدار متغیر ورودی هر نورون که با net معرفی شده از مجموع وزن‌دار ورودی‌ها ساخته خواهد شد. در اینجا فرض شده‌است که تعداد کل ویژگی‌ها برابر با m و n نیز اندیس شمارش تعداد نورون لایه دوم است. در شکل (۲) تعداد نورون‌های لایه دوم، که همان لایه خروجی است، سه در نظر گرفته شده‌است. هر یک از این خروجی‌ها به صورت زیر محاسبه می‌شود:

$$net_j = w_{j0} + x_1 w_{j1} + x_2 w_{j2} + \dots + x_m w_{jm} \quad (1)$$

تابع بیشینه‌هموار نیز با رابطه زیر قابل محاسبه است:


$$y_j = \frac{e^{net_j}}{\sum_{j=1}^n e^{net_j}} \quad (2)$$

² Activation Function

³ Softmax

¹ K-means clustering

بیان شده ساختار کلی روش پیشنهادی مطابق با شکل (۳) خواهد بود.




(شکل-۲): نمودار جعبه‌ای شبکه عصبی با تابع فال ساز پیشینه هموار
(Figure-2): Block diagram of the softmax neural network

که در آن y_j خروجی تابع پیشینه هموار برای نورون j -ام است. هدف از آموزش شبکه عصبی تنظیم وزن‌های آن است به نحوی که خطای خروجی‌اش کمترین حد شود.

$$E = \frac{1}{2} \sum_{j=1}^{n=3} (y_{dj} - y_j)^2 \quad (3)$$

به طوری که E مجموع مربعات خطای خروجی‌های شبکه و y_{dj} مقدار مطلوب خروجی j -ام شبکه است، با کمک خطای به دست آمده می‌توان با الگوریتم‌های آموزشی، وزن‌های درون شبکه عصبی را تنظیم کرد به نحوی که خطای شبکه برای اطلاعات داده شده کاهش پیدا کند؛ به این ترتیب با به روزرسانی متناوب وزن‌ها در مرحله آموزش خطا به کمینه مقدار خود خواهد رسید [۱۸]. با توجه به مطالب




(شکل-۳): نمودار جعبه‌ای روش پیشنهادی
(Figure-3): Propose Block diagram

DoG بر روی هر بلوک از تصویر در مجموع ۱۲۸ ویژگی به دست خواهد آمد. با توجه به آنکه تعداد ۱۲۸ ویژگی به دست آمده از نظر آماری دارای وابستگی هستند، می‌توان با الگوریتم PCA تعداد ویژگی‌ها را کاهش داد. برای

۴- نتایج شبیه سازی

۴-۱- نتایج استخراج ویژگی

طبق جدول (۱) با اعمال روش‌های استخراج ویژگی و GLCM, GLDM, DLDCP, ELP, EDP, ECP, DWT و



(شکل-۵): خروجی شبکه عصبی برای کلاس بندی دوفريت با ۸۰ ویژگی (بلوک رنگ آبی فريت سوزنی و بلوک رنگ زرد فريت مرزدانه‌ای)
(Figure-5): Neural network output for two ferrite classification with 80 features (The blue color represents Acicular ferrite, and the yellow color represents Granular)

پس از آموزش شبکه عصبی بیشینه‌هموار می‌توان خروجی آن را بر روی بخشی از تصویر نمونه مشاهده کرد. شکل (۵) خروجی شبکه عصبی برای طبقه‌بندی دو فريت با هشتاد ویژگی را نشان می‌دهد؛ همان‌طور که مشخص است، بلوک‌های با رنگ آبی به فريت سوزنی و بلوک‌های با رنگ زرد به فريت مرزدانه‌ای اختصاص دارند. یک بلوک تصویر که با حاشیه قرمز رنگ نشان داده شده نیز به‌اشتباه مرزدانه‌ای تشخیص داده شد؛ درحالی‌که فريت سوزنی است.

در جدول (۲) نتایج شبیه‌سازی برای کی-میانگین و بیشینه‌هموار برای طبقه‌بندی دو فريت مشاهده می‌شود؛ همان‌طور که مشخص است، روش کی-میانگین دقتی نزدیک به ۶۰ درصد دارد، اما شبکه عصبی بیشینه‌هموار به‌خوبی توانسته است، با دقت بسیار بالا طبقه‌بندی بلوک‌ها را انجام دهد. ردیف‌های این جدول نمایانگر تعداد ویژگی‌هایی هستند که به مدل طبقه‌بند ارائه شده‌اند.

کاهش تعداد ویژگی‌ها به هشتاد ویژگی، معادل حذف ۴۸ ویژگی از ۱۲۸ ویژگی اولیه است؛ درحالی‌که استفاده از ۱۲۸ ویژگی نشان‌دهنده عدم اعمال الگوریتم PCA است. نتایج نشان می‌دهند که با کاهش تعداد ویژگی‌ها به هشتاد با استفاده از الگوریتم PCA، دقت مدل پیشنهادی افزایش می‌یابد. این موضوع نشان‌دهنده آن است که روش PCA نگاشت داده‌ها را در فضای ورودی به‌نحوی انجام می‌دهد که استفاده از ویژگی‌های مؤثر در طبقه‌بندی، دقت مدل را بهبود می‌بخشد؛ بنابراین، می‌توان از مدلی ساده‌تر با تعداد کمتری از ویژگی‌های ورودی استفاده کرد و همچنان دقت مطلوبی را به‌دست آورد.

۴-۱-۲- نتایج طبقه‌بندی برای سه فريت


در تصاویر SEM فولاد، فريت‌های مختلفی وجود دارد که در قسمت پیش تلاش شد دو فريت سوزنی و مرزدانه‌ای از هم جدا شوند. در این بخش سعی خواهد شد که علاوه‌بر آن دو

به‌دست‌آوردن تعداد مناسب ویژگی از خطای بازسازی به ازای تعداد ویژگی‌های مختلف استفاده می‌شود. شکل (۴) چگونگی کاهش خطای بازسازی را به ازای افزایش تعداد ویژگی‌های خروجی PCA نشان می‌دهد؛ هر چه تعداد ویژگی‌های خروجی PCA به ۱۲۸ نزدیک‌تر شود، میزان خطای بازسازی کاهش پیدا می‌کند. مطابق شکل (۴) می‌توان تعداد ویژگی‌های لازم برای مدل طبقه‌بندی را هشتاد که به‌طور تقریبی خطای بازسازی در آن قابل صرفه نظر کردن است در نظر گرفت؛ به این ترتیب علاوه‌بر حذف ویژگی‌های وابسته و اضافی، از مدل طبقه‌بند ساده‌تر با تعداد متغیر کمتری نیز استفاده می‌شود؛ همچنین تأثیر کاهش تعداد ویژگی در بخش نتایج بر روی دقت داده‌های آزمایش نیز قابل توجه است.

(جدول-۱): ویژگی‌های بافت استخراج‌شده

(Table-1): Extracted Features

نام روش	تعداد ویژگی‌های استخراج‌شده	نام روش	تعداد ویژگی‌های استخراج‌شده
GLCM	۱۶	EDP	۶
GLDM	۸	ECP	۶
DLDCP	۱۴	DWT	۲۴
ELP	۲۴	DoG	۳۰
تعداد کل ویژگی‌ها		۱۲۸	



(شکل-۴): نتایج الگوریتم PCA با ۱۲۸ ویژگی
(Figure-4): PCA Result for the 128 features

۴-۱-۱- نتایج طبقه‌بندی برای دو فريت

در ابتدا فقط دو فريت سوزنی و مرزدانه‌ای انتخاب و طبقه‌بندی با توجه به این دو طبقه انجام شده‌است. در ابتدا پانزده درصد از داده‌ها برای آزمایش نهایی جدا می‌شوند؛ سپس پس از اعمال داده‌افزایی بر روی بلوک‌های به‌دست‌آمده، تعداد ۱۵۲۲ داده ورودی برای این دو فريت به‌دست می‌آید. از این بین پانزده درصد از داده‌ها برای ارزیابی و ۸۵ درصد آن‌ها برای آموزش استفاده شده‌است. برای اینکه بتوان جواب معنادارتر و معتبرتری به‌دست آورد، هر کدام از مدل‌های طبقه‌بندی استفاده شده (بیشینه‌هموار و کی-میانگین) را پنجاه بار آموزش داده و میانگین دقت و انحراف معیار دقت ثبت شده‌است.

(جدول ۲): نتایج شبیه‌سازی برای تمام مدل‌های پیشنهاد شده به ازای ویژگی‌های مختلف برای دو فریت


(Table-2): Simulation results for all proposed models for different features for two ferrites

تعداد ویژگی	کی-میانگین				بیشینه‌هموار			
	دقت آموزش	انحراف معیار دقت آموزش	بهترین دقت آموزش	دقت آزمایش	میانگین دقت آموزش	واریانس دقت آموزش	بهترین دقت آموزش	دقت آزمایش
۸۰	۴۹,۸۹٪	۶,۱۳	۵۸,۱۲٪	۵۹,۵۱٪	۹۹,۹۸٪	۰,۰۴	۱۰۰٪	۹۹,۷۸٪
۹۰	۴۸,۸۵٪	۵,۸۲	۵۷,۶۵٪	۶۰,۸۳٪	۹۹,۹۷٪	۰,۰۵	۱۰۰٪	۹۹,۵۶٪
۱۲۸	۵۰,۵۸٪	۶,۰۷	۵۷,۲۷٪	۵۹,۷۳٪	۹۹,۹۷٪	۰,۰۵	۱۰۰٪	۹۹,۳۴٪

(جدول ۳): نتایج شبیه‌سازی برای طبقه‌بندی سه فریت

(Table-3): Simulation results for all proposed models for different features for three ferrites

تعداد ویژگی	کی-میانگین				بیشینه‌هموار			
	دقت آموزش	انحراف معیار دقت آموزش	بهترین دقت آموزش	دقت آزمایش	میانگین دقت آموزش	واریانس دقت آموزش	بهترین دقت آموزش	دقت آزمایش
۸۰	۳۲,۶۴٪	۶,۲	۵۴,۱۸٪	۵۲,۸۲٪	۸۶,۷۴٪	۰,۷۵	۸۸,۴۵٪	۸۵,۸۶٪
۹۰	۳۲,۹۶٪	۶,۳۲	۵۳,۸۰٪	۵۱,۶۰٪	۸۶,۸۶٪	۰,۸۳	۸۸,۹۹٪	۸۸,۹۹٪
۱۲۸	۳۱,۷۶٪	۷,۰۳	۵۴,۲۶٪	۵۱,۶۰٪	۸۶,۹۱٪	۰,۸۹	۸۸,۸۱٪	۸۸,۸۱٪



(شکل ۶): بازنمایی سه بعدی داده‌ها برای سه کلاس فریت

مرزدانه‌ای (رنگ آبی)، فریت سوزنی (رنگ سبز) و فریت

ویدمن اشتاتن (رنگ زرد) با روش کاهش بعد t-SNE

(Figure-6): 3D representation of data for three classes: Granular Ferrite (blue), Acicular Ferrite (green), and Widmanstatten Ferrite (yellow), using the t-SNE dimensionality reduction method.

با بهره‌گیری از این روش، نمودار شکل (۶) برای سه طبقه فریت مرزدانه‌ای (رنگ آبی)، فریت سوزنی (رنگ سبز) و فریت ویدمن اشتاتن (رنگ زرد) در فضای سه‌بعدی (با کاهش ابعاد از ۱۲۸ به سه بعد) ترسیم شده‌است؛ این نمودار نشان می‌دهد که تفکیک طبقه‌ها با روش‌های خطی، مانند الگوریتم کی-میانگین امکان‌پذیر نیست؛ از این رو، استفاده از روش شبکه عصبی بیشینه‌هموار، دقت بالاتری را در تفکیک طبقه‌ها به دست آورده‌است.

به این معنی که روش معتبر و پرکاربرد کی-میانگین (به عنوان یک روش سنتی یادگیری ماشین) قادر به تفکیک بلوک‌های تصویر میکروسکوپی فولاد با استفاده از ویژگی‌های استخراج شده نیست. به این نکته توجه شود که با توجه به اینکه تا زمان نگارش مقاله هیچ پژوهشی برای تشخیص خودکار فازهای مختلف فریت ارائه

فریت، فریت ویدمن اشتاتن نیز تشخیص داده شود. در این وضعیت تعداد ۱۵۵۸ بلوک ورودی تهیه شده‌است. در جدول (۳) نتایج شبیه‌سازی دو مدل طبقه‌بند کی-میانگین و بیشینه‌هموار به ازای تعداد ویژگی‌های مختلف برای طبقه‌بندی سه فریت مشاهده می‌شود؛ همانند بخش پیشین، ابتدا پانزده درصد از داده‌های اصلی که بدون داده‌افزایی هستند برای آزمایش جدا می‌شوند؛ بعد از انجام عملیات مختلف داده‌افزایی پانزده درصد داده‌ها برای ارزیابی و ۸۵ درصد برای آموزش استفاده شده‌است. برای افزایش اعتبار نتایج، پنجاه بار شبیه‌سازی‌ها تکرار شده و میانگین و واریانس دقت به دست آمده به همراه بهترین دقت گزارش شده‌است.

همان‌طور که مشخص است روش پیشنهادی با شبکه عصبی بیشینه‌هموار می‌تواند با دقت ۸۸,۹۹ درصد در داده آزمایش به خوبی طبقه‌های مختلف فریت را تشخیص دهد. در این جدول نیز تأثیر اضافه کردن روش PCA برای کاهش تعداد ویژگی‌ها به نود ویژگی جهت ساده‌تر شدن مدل طبقه‌بند و بهبود خطای آزمایش مشهود است. در این وضعیت نیز روش کی-میانگین همچنان نتوانسته‌است به خوبی عمل کند و فقط به عنوان داشتن یک روش مقایسه در کنار شبکه عصبی بیشینه‌هموار آمده‌است.

یکی از روش‌های محبوب برای تجسم داده‌های با ابعاد بالا، استفاده از الگوریتم ^۱t-SNE است. این الگوریتم به ویژه برای بازنمایی و تجسم داده‌هایی که دارای کلاس‌های مختلف‌اند، بسیار کارآمد است. در فرایند t-SNE ضمن حفظ ساختار محلی داده‌ها، نقاطی را که در فضای با ابعاد بالا به هم نزدیک‌اند، در فضای با ابعاد پایین نیز نزدیک به هم نمایش می‌دهد.

^۱ t-Distributed Stochastic Neighbor Embedding

نشده‌است، امکان مقایسه روش پیشنهادی با نتایج مقاله‌های گذشته نبود و از این نظر روش پیشنهادی در این زمینه یکتا به نظر می‌رسد.

۵- نتیجه‌گیری و پیشنهاد

در این پژوهش یک الگوریتم طبقه‌بندی خودکار برای شکل‌های فازفریت فولاد در تصاویر SEM با استفاده از روش‌های استخراج ویژگی‌های بافت تصویر و مدل‌های یادگیری ماشین در طبقه‌بندی ارائه شده‌است. مجموعه داده در این پژوهش تصاویر با ابعاد ۱۰۲۴ در ۷۶۸ هستند. تصاویر به بلوک‌های ۱۲۸ در ۱۲۸ تقسیم شده و طبقه‌بندی بر روی هر بلوک به صورت جداگانه انجام شد. با توجه به اینکه تعداد بلوک‌های به دست آمده برای آموزش مدل‌های یادگیری ماشین کافی نبود، ابتدا با روش‌های مختلف مانند چرخش و مقیاس‌بندی تعداد ورودی‌ها افزایش داده شدند. از روش‌های مختلف پردازش تصویر در استخراج ویژگی برای به دست آوردن تعداد ۱۲۸ ویژگی بافت استفاده شد؛ سپس طبقه‌های مختلف فاز فریت با اعمال ویژگی‌های به دست آمده به دو مدل طبقه‌بند یادگیری ماشین کی-میانگین و شبکه عصبی تابع فعال‌ساز بیشینه‌هموار تشخیص داده شدند؛ همچنین به منظور کاهش ابعاد فضای ویژگی ورودی از روش PCA استفاده شد که تأثیر مثبتی در طبقه‌بندی دو فریت مرزدانه‌ای و سوزنی داشت. روش خوشه‌بندی کی-میانگین به عنوان یک روش یادگیری ماشین سنتی و پرکاربرد به دقت مناسبی در تفکیک طبقه‌ها دست نیافت و نتوانست به خوبی بلوک‌های تصویر را جدا کند، اما با وجود پیچیده بودن شکل فریت‌ها نبود الگویی خاص در آن‌ها، نتایج به دست آمده نشان داد که ویژگی‌های انتخاب شده و الگوریتم پیشنهادی با شبکه عصبی بیشینه‌هموار در تشخیص خودکار طبقه‌های مختلف فریت بسیار موفق بوده و دقتی بالای ۹۹ درصد برای دو طبقه و دقت بالای ۸۶ درصد برای سه طبقه کسب کرده‌است.

6-References

۶-مراجع

- [4] E. Pereloma and D. V. Edmonds, "Phase transformations in steels: Diffusionless transformations, high strength steels", *modelling and advanced analytical techniques*, Elsevier, 2012.
- [5] Muñoz-Rodenas, Jorge, et al, "Effectiveness of machine-learning and deep-learning strategies for the classification of heat treatments applied to low-carbon steels based on microstructural analysis", *Applied Sciences*, vol. 13, no. 6, p. 3479, 2023.
- [6] J. I. Goldstein, D. E. Newbury, J. R. Michael, N. W. Ritchie, J. H. J. Scott, and D. C. Joy, "Scanning electron microscopy and X-ray microanalysis", Springer, 2017.
- [7] C. Mignot, "Color (and 3D) for scanning electron microscopy", ed: Oxford University Press, 2018.
- [8] Hadjipanayis, George C., and Richard W. Siegel, eds. *Nanophase materials: Synthesis-properties-applications*, Vol. 260. Springer Science & Business Media, 2012.
- [9] F.-Y. Zhu, Q.-Q. Wang, X.-S. Zhang, W. Hu, X. Zhao, and H.-X. Zhang, "3D nanostructure reconstruction based on the SEM imaging principle, and applications", *Nanotechnology*, vol. 25, no. 18, p. 185705, 2014.
- [10] D. Saladra and M. Kopernik, "Qualitative and quantitative interpretation of SEM image using digital image processing", *Journal of microscopy*, vol. 264, no. 1, p. 102-124, 2016.
- [11] Y. Pourasad, "Detection and classification of breast masses using mammographically image processing," *Razi Journal of Medical Sciences*, vol. 27, no. 4, pp. 60-73, 2020.
- [12] S. Siddesha, S. Niranjana, and V. M. Aradhya, "Texture based classification of arecanut," in 2015 International Conference on Applied and Theoretical Computing and Communication Technology (iCATccT), *IEEE*, pp. 688-692, 2015.
- [13] J. F. Ramirez-Villegas, E. Lam-Espinosa, and D. F. Ramirez-Moreno, "Microcalcification detection in mammograms using difference of Gaussians filters and a hybrid feedforward-Kohonen neural network," in 2009 XXII Brazilian Symposium on Computer Graphics and Image Processing, *IEEE*, pp. 186-193, 2009.
- [14] Y. Dong et al., "Locally directional and extremal pattern for texture classification," *IEEE Access*, vol. 7, pp. 87931-87942, 2019.
- [15] M. Akbar, A. R. Ahmadian, M. J. Abolhasani and M. Giti, "Tissue classification of ultrasound images of diffuse liver diseases using wavelet transform", vol. 2, no. 7, pp. 67-76, 2006.
- [16] R. Xu and D. Wunsch, *Clustering*, John Wiley & Sons, 2008.

[۱۵] ا. مصطفی، ع. احمدیان، م. ج. ابولحسنی و م. گیتی، «کلاسه‌بندی بافت تصاویر سونوگرافی بیماری‌های منتشر کبدی با استفاده از تبدیل موجک»، *مجله فیزیک پزشکی ایران*، ۱۳۸۵، ۷ (۲)، ۶۷-۷۶.

- [1] Kwok, T. W. J., and D. Dye, "A review of the processing, microstructure and property relationships in medium Mn steels", *International Materials Reviews*, vol. 68, no.8, p. 1098-1134, 2023.
- [2] Uehata, Nao, et al, "Optical microscopy-based damage quantification: an example of cryogenic deformation of a dual-phase steel", *isij international*, vol. 58, no.1, p. 179-185, 2018.
- [3] G. Krauss, "Steels: processing, structure, and performance", Asm International, 2015.

[۱۷] وحیدی فردوسی صدیقه، امیرخانی حسین، «ترکیب وزن‌دار خوشه‌بندی‌ها با هدف افزایش صحت خوشه‌بندی نهایی»،

پردازش علائم و داده‌ها، ۱۳۹۹؛ ۱۷ (۲): ۸۵-۱۰۰.

[17] Vahidi Ferdosi S, Amirkhani H. "Weighted Ensemble Clustering for Increasing the Accuracy of the Final Clustering", *JSDP*; 17 (2):100-85, 2020.

[18] I. Goodfellow, Y. Bengio, and A. Courville, *Deep learning*, MIT press, 2016. .



زهرا فیروز دانش‌آموخته رشته

مهندسی مخابرات- گرایش سیستم از

دانشگاه سیستان و بلوچستان، دانشکده

مهندسی برق و کامپیوتر در مقطع

ارشد است. زمینه پژوهشی مورد علاقه

ایشان پردازش تصویر، پردازش ویدئو و هوش مصنوعی است.

نشانی رایانامه ایشان عبارت است از:

zahra.firooz2020@gmail.com



پوریا جعفری دانش‌آموخته رشته

الکترونیک در مقطع کارشناسی و

کنترل در مقطع کارشناسی‌ارشد و

دکتر است. در حال حاضر عضو هیئت

علمی دانشگاه سیستان و بلوچستان

بوده و زمینه‌های پژوهشی مورد علاقه ایشان یادگیری

عمیق، هوش مصنوعی و کنترل هوشمند است.

نشانی رایانامه ایشان عبارت است از:

pjafari@ece.usb.ac.ir



مهدی رضائی مدارک کارشناسی و

کارشناسی‌ارشد خود را در رشته

مهندسی الکترونیک به‌ترتیب از

دانشگاه صنعتی امیرکبیر پلی‌تکنیک

تهران و دانشگاه تربیت مدرس تهران

در سال‌های ۱۳۷۱ و ۱۳۷۵ دریافت کردند. ایشان دکترای

خود را در سال ۱۳۸۷ در رشته پردازش سیگنال در

دانشگاه صنعتی تامپر فنلاند به پایان رساندند و در حال

حاضر دانشیار دانشکده مهندسی برق و کامپیوتر در

دانشگاه سیستان و بلوچستان هستند. زمینه‌های پژوهشی

مورد علاقه ایشان مخابرات و پردازش سیگنال‌های

چندرسانه‌ای است.

نشانی رایانامه ایشان عبارت است از:

mehdi.rezaei@ece.usb.ac.ir