



رده‌بندی عیوب سطح ورق فولاد با استفاده از شبکه‌های عصبی

و شاخص‌های ساده محاسباتی

منصوره نویدپناه^۱، رسول امیرفتاحی^۲

(تاریخ دریافت: ۸۹/۶/۱، تاریخ پذیرش: ۹۱/۱۲/۴)

چکیده

امروزه بررسی اتوماتیک سطح ورق فولاد، یکی از مراحل اساسی در تولید فولاد با کیفیت به شمار می‌رود و اکثر فولاد سازهای جهان بازرسی چشمی توسط اپراتور را با این روش نوین جایگزین نموده‌اند. در این مقاله تلاش شده است که با ارائه روشی جدید، رده‌بندی و تشخیص عیوب سطحی ورق فولاد با استفاده از شاخص‌های ساده محاسباتی و شبکه عصبی مصنوعی پرسپترون چند لایه بطور اتوماتیک انجام گیرد. نتایج شبیه‌سازی‌های انجام شده حاکی از آن است که روش پیشنهادی به طور متوسط قابلیت تشخیص انواع خرابی‌های رایج را تا ۹۳/۳ درصد دارا بوده و به دلیل سرعت قابل قبول اجرای الگوریتم محاسباتی، برای پیاده‌سازی بلادرنگ نیز مناسب می‌باشد.

کلمات کلیدی

شبکه‌های عصبی، رده‌بندی، عیوب سطحی، ورق فولاد

Steel Surface Defect Categorization Using Artificial Neural Networks and Uncomplicated Computational Indicators

Mansoureh Navidpanah¹, Rasoul Amirfattahi²

ABSTRACT

Automatic inspection of steel surfaces is one of the basic processes in steel production. Most of steel producers have replaced the traditional human-based inspection methods with these new automatic and machine-based Methods. In this paper, a new approach has been proposed for detection and categorization of cold-rolled surface defects. The proposed algorithm is mainly based on artificial MLP neural networks and uncomplicated computational indicators. Experimental results show that the proposed method could detect up to 93.3% of prevalent defects. In addition, this method is appropriate for real-time implementation because of its satisfactory execution time on a modern computer.

Keywords

Artificial Neural Networks, Categorization, Surface Defects, Steel Sheet

۱. کارشناسی ارشد، دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی اصفهان mimnavidpanah2005@gmail.com

۲. دانشیار دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی اصفهان fattahi@cc.iut.ac.ir



فصل سوم روش پیشنهادی برای رده‌بندی عیوب سطح ورق فولاد بیان شده است. نتایج شبیه سازی ها در بخش چهارم و نتیجه گیری نهایی در بخش پنجم ارائه شده اند.

۲. روشهای متداول در تشخیص عیوب ورق فولاد

ساریدیس و برندين در ۱۹۷۶ نشان دادند که اتوماسیون سیستمهای بازرسی سطح فلزات برای ورق فولاد سرد قابل انجام است [۲]. تحقیقات انجام شده در مورد بازرسی سطح اجسام از سال ۱۹۸۳ تا سال ۲۰۰۳ نشان می دهد که تشخیص و رده‌بندی عیوب ورق فولاد به ندرت انجام گرفته است [۳]. واله و همکارانش در ۱۹۹۶ اولین رده‌بندی خرابی سطح ورق فولاد را روی تصاویر به دست آمده از دو پایگاه داده متفاوت با استفاده از شبکه‌های عصبی مصنوعی انجام دادند که هدف آن مقایسه بین ساختار درختی شبکه عصبی پرسپترون چند لایه و ساختار معمولی آن بود [۴]. آنها پس از قطعه‌بندی تصویر و تشخیص ناحیه خرابی، خرابیها را بر اساس شاخصهای هندسی به چهار دسته عمودی، افقی، دایره‌ای (حلقوی) و اشکال پیچیده تقسیم کرده و سپس عیوب موجود در هر کدام از این چهار دسته را با استفاده از شاخصهای متفاوت مربوط به سطوح روشنایی تصویر، به دسته‌های نهایی تقسیم نمودند. واله و همکارانش دو روش برای رده‌بندی عیوب در نظر گرفتند. در هر دو روش نیمی از تصاویر از هر پایگاه داده برای آموزش و نیمی برای تست استفاده شدند. کارایی روش با استفاده از شبکه MLP و MLP درختی (Tree- MLP (TMLP) در جدول (۱) داده شده است. اونسلان و ارسیل در ۱۹۹۹ مقاله ای منتشر کردند که در آن تحقیقی وسیع اما محدود به درجه بندی فقط سه نوع ورق زنگ‌زده و سه نوع ورق شن زده (Sandblasted) متناظر با ورقهای زنگ‌زده انجام شده بود [۵]. در آن تحقیق به جز زنگ‌زدگی هیچ نوع خرابی دیگری از سطح ورق شناسایی نشده بود.

بازرسی سطح ورق فولاد یکی از فرآیندهای اجتناب ناپذیر در تولید فولاد مرغوب و باکیفیت به شمار می رود. وجود عیب در سطح ورق فولاد تولید شده علاوه بر این که می تواند سبب بروز مشکلات فنی در فرآیند نورد شود، گاهی ممکن است به کاهش تولید و از دست دادن بازار نیز منجر گردد [۱]. بر اساس گزارشات شرکت فولاد مبارکه، که یکی از بزرگ ترین شرکت های تولید ورق فولاد در ایران و خاور میانه به شمار می رود، عیوب عمده ورق فولاد عبارتند از: حفره^۱، خراش^۲، چین های عرضی^۳ و زنگ زدگی^۴. تشخیص این عیوب به صورت چشمی و توسط نیروی انسانی علاوه بر این که باعث خستگی، اتلاف وقت و نیروی انسانی، ... می‌گردد، به دلیل سرعت بالای ورق در ناحیه نورد سرد تقریباً غیر ممکن است. هدف از بازرسی اتوماتیک سطح ورق، طبقه‌بندی ورق های تولید شده از نظر کیفیت و جمع آوری اطلاعات آماری کامل از انواع خرابی ها می باشد [۱]. با توجه به سرعت بالای ورق فولاد در حال حرکت، استخراج و سپس بررسی حجم وسیعی از اطلاعات در یک زمان کوتاه کار بسیار مشکلی است. علاوه بر آن بدلیل شباهت بین خرابیهای مربوط به طبقات مختلف، تنوع خرابی در داخل طبقات و همچنین امکان بوجود آمدن نوع جدیدی از خرابی، سیستم بررسی سطح باید به اندازه کافی هوشمند باشد تا بتواند خود را با تغییرات خرابیها وفق دهد [۱]. به منظور دست یابی به سرعت بالای محاسبات و قابلیت تطبیق بالا که برای یک سیستم بلادرنگ مورد نیاز است، در این مقاله روشی بر مبنای استفاده از رده‌بندهای عصبی و شاخصهای ساده محاسباتی پیشنهاد شده است. در بخش دوم مقاله برخی از روشهای متداول در بررسی سطح ورق فولاد مرور شده اند. در

¹ Hole

² Scratch

³ Scrape

⁴ Rust



جدول (۱): نتایج رده‌بندی عیوب سطح ورق فولاد در حالتی که نیمی از تصاویر برای آموزش شبکه و نیمی دیگر برای تست آن در نظر گرفته شده اند [برگرفته از مرجع ۴]

شبکه عصبی مورد استفاده		پایگاه تصویر اول	پایگاه تصویر دوم
MLP	مجموعه آموزش	٪۶۳/۵	٪۷۸/۳
	مجموعه تست	٪۶۰/۲	٪۶۸/۶
TMLP	مجموعه آموزش	٪۹۲/۹	٪۹۱/۹
	مجموعه تست	٪۶۰/۵	٪۶۵/۱

حفره معرفی شد. برای تشخیص دو نوع خرابی Anneal Black Patch, Color و ورق سالم از شبکه عصبی RBF با شاخصهای واریانس و عدم تقارن هیستوگرام نسبت به مرکز آن^۳ مربوط به کانالهای قرمز، آبی، سبز و خاکستری مربوط به بلوک استفاده شده است [۱]. تشخیص خرابی حفره با استفاده از آستانه‌گذاری و تشخیص فرورفتگی و برآمدگی تصویر با مدل‌کردن سطح ورق با یک سطح درجه دو انجام شد [۱]. از کارهای دیگر که در زمینه تشخیص عیوب ورق انجام گرفته، استفاده از روشهای پردازش تصویر مانند آستانه‌گذاری سطح روشنی، تبدیل هاف و آستانه‌گذاری از تعداد پیکسلهای خرابی و گردایان چند حالتی است [۹].

روبرتو مدینا به همراه همکارانش در سال ۲۰۱۱ با استفاده از الگوریتمهای بینایی ماشین، شش دسته خرابی را با عناوین جوش، زنگ زدگی سفید^۴، علامت انتقال دهنده^۵، خوردگی حفره ای^۶، لکه های روی^۷ و آثار رول شدن ورق^۸ با دقت ۸۷ درصد تشخیص و طبقه بندی کردند [۱۴] که در مقایسه با روش پیشنهادی ما کارایی کمتری داشته است.

در مقاله دیگری نیز تعدادی از روشهای تشخیص و طبقه‌بندی با یکدیگر مقایسه شده است [۱۵]. نظر به اینکه روش پیشنهادی ما به مراتب ساده تر و نتایج حاصل از آن در حد روشهای پیچیده پیشنهادی است، می توان از آن به عنوان روشی قابل قبول و کارا در امر تشخیص و طبقه بندی خرابی های سطح ورق استفاده کرد.

۳. روش پیشنهادی

با توجه به اینکه برخی از روشهای مذکور در بخش قبل مانند مراجع [۴] و [۹] نتایج رده‌بندی خوبی ندادند و برخی از آنها نیز در فرایند تشخیص خرابی بطور ترتیبی

چالاسانی در سال ۲۰۰۰ با استفاده از الگوریتم قطعه‌بندی آب پخشان^۱ ناحیه خرابی روی سطح ورق فولاد را برای خرابیهای

Rust Marks, Black Patch, hole, Pinch mark

مشخص نمود، اما نوع خرابی را مشخص نکرد [۶].

در [۷] برای رده‌بندی عیوب Black, Coil Break, Roll Mark, Scratch, Pinch, Patch و ورق بدون عیب،

سیستم بلادرنگ نرم‌افزاری و سخت‌افزاری مبتنی بر مقایسه شاخصهای تصاویر طراحی شده است که در آن فقط از شاخصهای هیستوگرام استفاده شده است. با اعمال تبدیل موجک سه سطحی بر بردار هیستوگرام، از چهار بردار حاصل، میانگین و واریانس استخراج شده و سپس فاصله RMS شاخصهای تصویر ورودی از میانگین شاخصهای هر کلاس بدست می آید. به این ترتیب کلاس خروجی انتخاب می‌شود [۷]. بدلیل همپوشانی اجتناب‌ناپذیر هیستوگرام و در نتیجه همپوشانی شاخصها، استفاده از هیستوگرام و محاسبه فاصله از مرکز کلاسها کارایی لازم را نخواهد داشت. [۱] و [۸].

در [۱] ماژول نرم‌افزاری پردازش تصویر برای رده‌بندی پنج نوع ورق شامل فولاد بدون عیب، فولادی با تغییر رنگ بعد از حرارت، فولاد دارای لکه‌های سیاه، فولاد دارای سطحی برآمده یا فرورفته و فولاد دارای عیب

³ Skewness

⁴ White Rust

⁵ Transporter Mark

⁶ Pitting Corrosion

⁷ Zinc Protuberance

⁸ Rolled Mark

¹ Watershed

² این خرابیها در بین کارشناسان فولاد با نام لاتین شناخته شده است



عمل می‌کنند [۱] و [۹] در این مقاله سعی شده است تا با استفاده از روشهای استخراج شاخص سریع، کارا، دارای محاسبات کم و پیاده‌سازی راحت، رده‌بندی خرابیها انجام شود.

شاخصها باید بگونه‌ای باشد که علاوه بر سرعت، قابلیت انجام محاسبات بطور موازی و عدم وابستگی زمان پردازش به نوع خرابی، کارایی رده‌بندی نیز بالا باشد. در [۱] و [۹] با اضافه شدن نوعی خرابی جدید که ظاهراً مشابه با یکی از انواع خرابی قبلیست، یکی از الگوریتمها بلااستفاده شده و نیاز به طراحی الگوریتمی جدید برای کلاس خرابی قبلی و جدید باشد. شاخصهایی که ما از آنها استفاده کرده‌ایم، هیستوگرام، تبدیل فوریه و ماتریسهای هم رخداد هستند که از لحاظ محاسباتی سریع و از لحاظ پیاده‌سازی آسانتر از دیگر روشهای تحلیل بافت هستند. همچنین این شاخصها برای بلادرنگ کردن سیستم تشخیص عیوب نیز مناسب‌تر می‌باشند. در ادامه به بررسی مختصر هریک از این روشها می‌پردازیم.

هیستوگرام: هیستوگرام یک تصویر، احتمال وقوع سطوح روشنایی مختلف در تصویر است. بدلیل بعد بالای بردار هیستوگرام برای تصویری با ۲۵۶ سطح، ویژگیهای مذکور در روابط (۳-۱) تا (۳-۴) را از آن استخراج و در رده‌بندی استفاده می‌کنیم. این ویژگیها بترتیب میانگین هیستوگرام، واریانس هیستوگرام، عدم تقارن هیستوگرام نسبت به حالت نرمال (تمایل به چپ یا راست) و درجه قله‌دار بودن هیستوگرام را نشان می‌دهد [۵] و [۱۰]. در این روابط L تعداد سطوح روشنایی (مثلاً ۲۵۶) و $h(l)$ احتمال وجود سطح روشنایی l در تصویر است.

$$\mu = \sum_{l=0}^{L-1} l * h(l) \quad \text{میانگین} \quad (1-3)$$

$$\sigma^2 = \sum_{l=0}^{L-1} (l - \mu)^2 * h(l) \quad \text{واریانس} \quad (2-3)$$

$$s = \sum_{l=0}^{L-1} (l - \mu)^3 * h(l) / \sigma^{3/2} \quad \text{انحراف از مرکز} \quad (3-3)$$

$$k = \sum_{l=0}^{L-1} (l - \mu)^4 * h(l) / \sigma^2 \quad \text{درجه قله دار بودن} \quad (4-3)$$

ماتریسهای هم رخداد: این ماتریسها که اولین بار توسط Haralick و همکارانش در سال ۱۹۷۳ معرفی شد، اطلاعات آماری مرتبه دو از تصویر را استخراج می‌کنند و دارای قدرت بالاتری نسبت به هیستوگرام تصویر هستند. محاسبه آسان این ماتریسها و قدرت بالای شاخصهای استخراجی، آنها را در بین روشهای دیگر متمایز کرده است [۵] و [۱۱]. با این روش روابط بین سطح روشنایی مربوط به پیکسلهای تصویر بدست می‌آید. در تحقیق حاضر ماتریسهای GLCM^۱ برای چهارجهت صفر، ۴۵، ۹۰ و ۱۳۵ درجه و همسایگی یک پیکسل محاسبه و میانگین آنها برای استخراج شاخص استفاده شد تا این شاخصها مستقل از جهت خرابی باشند.

عبارت محاسباتی ذیل برای فواصل مختلف در جهات محور x, y است که به ازای x, y های متفاوت زاویه و فاصله متفاوت محاسبه خواهد شد. (M, N) برابر است با ابعاد تصویر)

$$P(i, j | \Delta x, \Delta y) = W Q(i, j | \Delta x, \Delta y)$$


$$W = \frac{1}{(M - \Delta x)(N - \Delta y)}$$

$$Q(i, j | \Delta x, \Delta y) = \sum_{n=1}^{N-\Delta y} \sum_{m=1}^{M-\Delta x} A$$

$$A = \begin{cases} 1 & \text{if } f(m, n) = i \text{ and } f(m + \Delta x, n + \Delta y) = j \\ 0 & \text{elsewhere} \end{cases}$$

با محاسبه میانگین P در چهار جهت با فاصله مکانی یک پیکسل مقدار $P(i, j)$ مورد استفاده در روابط ذیل به دست می‌آید [۱۱].

در یک تصویر یکنواخت بدلیل یکسان بودن تقریبی تمام سطوح روشنایی موجود در تصویر، اطلاعات عمده ماتریسها که مقادیر بزرگتر را شامل می‌شود، نزدیک به قطراصلی است. با توجه به سطح روشنایی متوسط تصویر، محل قله به سمت نیمه بالای قطر (در تصویر



شکل (۱) باندهای فرکانسی تبدیل فوریه

شبکه‌های عصبی مصنوعی: قدرت محاسباتی بالای این شبکه‌ها ابتدا از ساختار توزیع شده موازی و سپس از قدرت بالای یادگیری و تعمیم آنها ناشی می‌شود. این دو قابلیت مهم آنها را در حل مسائل پیچیده نسبت به سایر روشها ممتاز کرده است. شبکه‌های عصبی مصنوعی بدلیل امکان استفاده از نرونها با تابع فعالیت غیرخطی و همچنین یادگیری نمونه‌های آموزشی با ایجاد نگاشت (بویژه غیر خطی) بین نمونه‌های ورودی و خروجی در بیشتر کاربردهای رده‌بندی استفاده می‌شوند. زیرا برخلاف روشهای آماری نیاز به مدل توزیع از پیش تعیین شده برای نمونه‌های ورودی ندارند. از طرفی با توجه به اینکه شبکه‌های عصبی مصنوعی وزنه‌های سیناپتیک خود را با تغییرات محیط وفق می‌دهند، با اضافه شدن گروه جدیدی از خرابیها، می‌توانند براحتی مجدداً آموزش داده شوند تا تغییرات را منعکس کنند [۱۲]. استفاده از شبکه‌های عصبی مصنوعی بدلیل ماهیت توزیع‌شدگی اطلاعات ذخیره شده امکان پیاده‌سازی یک سخت‌افزار تحمل‌پذیر خطا را فراهم می‌کند.

همچنین ماهیت موازی شبکه‌های عصبی مصنوعی، محاسبات را در یک کاربرد خاص سرعت بخشیده و پیاده‌سازی VLSI آنها را عملی و مفید می‌سازد. در این مقاله از شبکه عصبی MLP با دو لایه مخفی و الگوریتم انتشار به عقب‌گردان مزدوج استفاده شده است. در ضمن نرخ یادگیری شبکه برابر ۰/۰۱ و تابع فعالیت استفاده شده سیگموئید تانژانت است که این تابع بدلیل تقارن شکلی نسبت به سیگموئید لگاریتمی کارایی بهتری بدست می‌دهد. این شبکه نسبت به دیگر شبکه‌های عصبی مصنوعی که قدرت رده‌بندی چند کلاسی غیر خطی دارند، دارای پیاده‌سازی راحت‌تری می‌باشد و نتایج بهتری

تاریک) و یا پایین قطر (در تصویر روشن) جابجا خواهد شد.

خرابیهایی که در تصویر با تغییر واضح سطح روشنایی بین پیکسلهای مجاور مشخص شده‌اند، در مکانهایی از ماتریسهای هم رخداد و بدور از قطر اصلی قله‌هایی را ایجاد می‌کند. هرچه کنتراست خرابی بیشتر باشد (خرابی در تصویر واضح تر باشد)، این قله‌ها دورتر از قطر اصلی خواهند بود و هرچه خرابی ناحیه بزرگتری از سطح را بپوشاند قله‌ها بزرگتر خواهند بود. ویژگیهایی که از ماتریس GLCM بدست می‌آید در روابط (۳-۵) تا (۳-۱۰) ذکر شده است.

$$\sum_i \sum_j \frac{p(i, j)}{1 + (i - j)^2} \quad \text{IDM} \quad (5-3)$$

$$\text{Max } p(i, j) \quad \text{بیشترین احتمال} \quad (6-3)$$

$$\sum_i \sum_j p(i, j)^2 \quad \text{انرژی} \quad (7-3)$$

$$-\sum_i \sum_j p(i, j) \log(p(i, j)) \quad \text{آنتروپی} \quad (8-3)$$

$$\sum_i \sum_j p(i, j) * (i - j)^2 \quad \text{کنتراست} \quad (9-3)$$

$$\sum_i \sum_j (i - \mu)^2 * p(i, j) \quad \text{واریانس} \quad (10-3)$$

تبدیل فوریه: از روشهای ساده استخراج اطلاعات طیفی تصویر است که شاخصهای آن مقدار حضور هارمونیکهای فرکانس پایین، متوسط و بالا، همچنین متوسط فرکانس تصویر و میزان پراکندگی فرکانسی در تصویر را بدست می‌دهد [۵] و [۱۰]. در این مقاله ابتدا طیف فرکانسی مانند شکل (۱) به سه باند فرکانسی تقریباً مساوی تقسیم شده و سپس پنج شاخص انرژی باند پایین، انرژی باند متوسط، انرژی باند بالا، میانگین تبدیل و واریانس از آن استخراج می‌گردد.



نیز در رده‌بندی خرابیهای سطح ورق فولاد بدست داده است.

۴. نتایج شبیه سازی ها

پایگاه تصاویر ما شامل ۳۹۱ تصویر واقعی و سنتز شده خاکستری از سطح ورق فولاد است که از مجتمع فولاد مبارکه اصفهان و پایگاه اینترنتی فولاد هندوستان [۱۳] بدست آمده تعداد تصاویر آموزش ۱۹۴ و تعداد تصاویر مجموعه تست برابر با ۱۹۷ عدد می باشد.

اندازه تصاویر ۲۵۶ در ۲۵۶ پیکسل است. تصاویر از نمونه خرابی های تشخیص داده شده چشمی به دست آمده است. تعداد تصاویر از هر کلاس خرابی در جدول (۲) نشان داده شده است. لازم به ذکر است که فرایند تصویر برداری در کارخانه فولاد مبارکه اصفهان با مشکلات زیادی همراه بوده است و به همین دلیل تعداد تصاویر کمتر از حد انتظار ما بود. چه بسا با تعداد بالای تصاویر نتایج بهتری بدست آید.

جدول (۲) تعداد موجود از هر کلاس، در مراحل آموزش و

تست

کلاس خرابی	تعداد نمونه های آموزش	تعداد نمونه های تست
حفره	۳۴	۳۵
چین های عرضی	۳۲	۳۲
خراش	۴۰	۴۱
زنگ زدگی	۵۵	۵۶
ورق سالم	۳۳	۳۳

نمونه‌هایی از خرابیهای مورد بحث در این مقاله به همراه هیستوگرام آنها در شکل (۲) مشاهده می شود که البته تنوع کامل خرابیها را پوشش نمی دهد. در این مقاله کارایی روشهای استخراج شاخص مذکور در بخش قبل در تشخیص این خرابیها تست شد و مشاهده شد که در هر کلاس برخی از شاخصها بهتر از بقیه عمل کرده و نتایج بهتری بدست می دهند. عیوب مورد بحث در این تحقیق و


نحوه دسته‌بندی آنها با شاخصهای مختلف بصورت زیر خلاصه می شود.

الف- حفره: این عیب که کلاس اول خرابیها را در تحقیق ما تشکیل می دهد با استفاده از شاخصهای هیستوگرام و ماتریسهای هم رخداد بهتر شناسایی شده است.


ب- چینهای عرضی: یکی دیگر از انواع خرابیهای سطح ورق فولاد است که ماتریسهای هم رخداد در تشخیص آن بهتر از بقیه شاخصها عمل کرده اند.

ج- خراش: این عیب که از عیوب رایج ورق فولاد می باشد با استفاده از شاخصهای تبدیل فوریه بخوبی تشخیص داده می شود.

د- زنگ زدگی: از عیوب بسیار رایج ورق می باشد که در [۵] کارهای زیادی برای تشخیص آن انجام شده است. در تحقیق حاضر بترتیب شاخصهای هیستوگرام، ماتریسهای هم رخداد و فوریه در تشخیص آن نتایج بسیار خوبی بدست داده اند. در تشخیص ورق سالم نیز که یکی از کلاسهای مورد بحث در این تحقیق بشمار می آید، بترتیب تبدیل فوریه، ماتریسهای هم رخداد و هیستوگرام نتایج خوبی بدست داده اند.



(ب)





(الف)



رده‌بندی بدست دهد. بنابراین ترکیب شاخصها برای بهبود نتایج ضروریست. با مشاهده شکل (۳) براحتی می‌توان این نتایج را با یکدیگر مقایسه کرد. خاطر نشان می‌گردد که اطلاعات دقیق در مورد شاخص های هیستوگرام در [۱۶] آمده است.

با توجه به اینکه در شبکه عصبی MLP مقدار اولیه وزنها تأثیر زیادی در نتیجه نهایی و زمان همگراشدن شبکه به خروجیهای موردنظر دارد، برای یافتن بهترین نتیجه باید چندین بار شبکه را با وزنها تصادفی اولیه متفاوت آموزش داد [۱۲]. اما نکته مهم اینکه میزان تنوع در نمونه‌های یک کلاس و شباهت بین نمونه های کلاسهای مختلف باعث پایین آمدن کارایی شبکه خواهد شد زیرا باعث می‌شود تنظیم وزنها بصورت کارا انجام نگیرد. [۱۲].

در تحقیق حاضر زمانیکه ما از ۵ نرون خروجی متناظر با ۵ کلاس مربوط به ورق استفاده کردیم شبکه MLP در رده‌بندی انواع ورقهای معیوب و سالم بطور متوسط ۸۶/۴ درصد کارایی بدست داد که بسیار مناسب بود. اما به علت اینکه در تصاویر مربوط به خرابیها تنوع داشتیم بنظر می‌رسید با در نظر گرفتن این تنوع کارایی بهبود یابد. به همین جهت ما مجموعه تصاویر خرابی حفره را به سه دسته و مجموعه تصاویر خرابی زنگ زدگی را نیز به سه دسته تقسیم کردیم.



شکل (۲) انواع خرابیهای سطح ورق فولاد و هیستوگرام مربوط، الف) چینهای عرضی، ب) و ج) حفره، دوه) زنگ زدگی، و) خراش، ی) ورق سالم

همانطور که در شکل (۲) مشاهده می‌شود، خرابیهای مختلف با استفاده از هیستوگرام از یکدیگر قابل تفکیک هستند. اما با توجه به اینکه این نمونه‌ها تنوع تصاویر در کلاسهای مختلف را پوشش نمی‌دهد، نمی‌توان شباهت بین کلاسهای مختلف و تنوع داخل برخی از کلاسها را در این اشکال بخوبی مشاهده کرد. اگر ماتریسهای هم رخداد و یا طیف فوریه این تصاویر بدست آید، تشابه در کلاسهای مختلف و تنوع در داخل یک کلاس بطور نسبی در آنها نیز مشاهده خواهد شد که خود اثباتی بر این موضوع می‌باشد که هر یک از روشهای استخراج شاخص مذکور به تنهایی نخواهد توانست کارایی بالایی در




۹-۳۰-۲۶-۱۵ می باشد که ۱۵ متناظر با تعداد ورودیها یا تعداد شاخصهای مورد استفاده، ۲۶ و ۳۰ بترتیب تعداد نرونها در لایه مخفی اول و دوم و ۹ تعداد نرونهای خروجیست. نتایج این شبکه در رده بندی انواع ورقهای معیوب و ورق سالم به ازای استفاده از شاخصهای جداگانه و ترکیبی برای خرابیهای مختلف در شکل (۳) مشاهده شد. در جدول (۳) نیز ماتریس رده بندی کلاسهای مختلف و در شکل (۴) نمودار مجموع مربعات خطای شبکه در فرایند آموزش نسبت به تعداد دفعات آموزش شبکه مشاهده می گردد.

جدول (۳) ماتریس دسته بندی تعداد درست نمونه های


تست

کلاس انتسابی کلاس واقعی	حفره	چین های عرضی	خراش	زنگ زدگی	سالم
حفره	۳۴	۰	۱	۰	۰
چین های عرضی	۲	۲۸	۲	۰	۰
خراش	۱	۳	۳۵	۲	۰
زنگ زدگی	۰	۰	۲	۵۴	۰
سالم	۰	۰	۰	۰	۳۳

اگر در جدول (۳) دقت شود ورق سالم بدون هیچ خطایی شناسایی شده و علاوه بر آن هیچ ورق معیوبی به کلاس ورق سالم اختصاص داده نشده است. این موضوع تشخیص معیوب و یا سالم بودن ورق به طور کامل را نشان می دهد.



(ب)



(ج)

شکل (۳) در صد موفقیت شاخصهای مختلف در تشخیص الف) حفره، ب) چینهای عرضی ج) خراش


این کار باعث تشکیل ۹ کلاس جدید شد. با توجه به اینکه میانگین کارایی سیستم با ترکیب شاخصها و با استفاده از ۹ کلاس جدید ۹۳/۳ در صد (میانگین در صد موفقیت برای ستون آخر از نمودارهای بالا که مربوط به ترکیب شاخصهاست) بدست آمد، این بهبود ۶/۹ درصدی در میزان موفقیت شبکه در عمل رده بندی اهمیت در نظر گرفتن تنوع نمونه های داخل کلاسها را برایمان آشکار کرد. البته باید ذکر شود که شبکه بدون هیچ خطایی عمل رده بندی نمونه های آموزشی را انجام می دهد. این موضوع از اهمیت بالایی برخوردار است و نشانگر دقت بسیار بالای روش پیشنهادی در تشخیص معیوب و یا سالم بودن ورق فولاد می باشد.

معماری شبکه عصبی MLP که با استفاده از ترکیب شاخصها عمل رده بندی را انجام داده است بصورت

در این مقاله با استفاده از شاخصهای ساده محاسباتی و شبکه عصبی مصنوعی MLP که اغلب محققان با آن آشنا هستند رده‌بندی عیوب سطح ورق فولاد انجام شده است. علاوه بر آن از تصاویر خاکستری استفاده شده است که نیاز به پردازش کانالهای رنگ و در نتیجه حجم بالای محاسبات را از بین می‌برد. در [۱] از اطلاعات کانال رنگ استفاده شده است که پردازش را کند می‌کند. مزیت روش پیشنهادی ما بر روشهایی مانند [۱] و [۹] اینست که با ورود تصویر تست علاوه بر اینکه هر کدام از شاخصها می‌تواند مستقل از شاخصهای دیگر محاسبه شود، مدت زمان لازم برای تشخیص نوع ورق برای تمام خرابیها یکسان است. اما در [۱] و [۹] زمانیکه تصویر وارد می‌شود تک تک الگوریتمها بر روی سطح ورق تست می‌شود تا بالاخره نوع خرابی مشخص شود. این عمل ترتیبی باعث نامناسب بودن روشهای مذکور برای پیاده‌سازی بلادرنگ می‌شود. علاوه بر آن در [۱] و [۹] زمان مورد نیاز برای تشخیص خرابی تصویر به نوع خرابی وابسته است.

در روش پیشنهادی این مقاله، علاوه بر اینکه امکان موازی‌سازی محاسبات بین روشهای مختلف استخراج شاخص وجود دارد، در محاسبه تک تک شاخصها نیز می‌توان از محاسبات موازی استفاده کرد. این امر باعث می‌شود که روش پیشنهادی قابلیت اجرای سریعتر را نیز داشته باشد. علاوه بر آن استفاده از ویژگیهای تصویر که تا کنون امتحان خود را در کاربردهای رده‌بندی بافت پس داده‌اند و اطلاعات منطقی مهمی را از تصویر بیرون می‌کشند، قابل اعتمادتر است تا استفاده از الگوریتمهایی مانند آستانه‌گذاری سطح روشنایی و یا آستانه‌گذاری تعداد پیکسلهای خرابی مورد استفاده در [۱] و [۹]. زیرا با تغییر مقدار خرابی بر روی سطح ورق و تغییر سطح روشنایی تصویر به این الگوریتمها نمی‌توان اعتماد کرد.

در [۱] و [۷] کارایی روش پیشنهادی برای رده‌بندی بیان نشده است و در [۶] نیز اصلاً تشخیص نوع خرابی انجام نگرفته است. اما در تحقیق حاضر نوع تصاویر، اندازه آنها، تعداد نمونه‌های تست و آموزش و کارایی روش پیشنهادی



شکل (۴) نمودار مقدار خطا بر حسب تعداد تکرار آموزش

همانطور که انتظار داشتیم و در شکل (۳) نیز مشاهده می‌شود، با استفاده از شاخصهای ترکیبی نتایج بهتری نسبت به حالت استفاده از شاخصهای جداگانه، بدست آمده است.

شبیه‌سازی‌های انجام گرفته در تحقیق حاضر بر روی سیستم پنتیوم چهار که دارای پردازنده اینتل با فرکانس کاری ۳/۲۱ گیگا هرتز و مقدار حافظه ۱ گیگابایت می‌باشد اجرا شده است. مقدار زمانی که در مرحله آموزش برای رده‌بندی با استفاده از شبکه عصبی MLP و شاخصهای ترکیبی لازم است برابر با ۷۲/۳۵ ثانیه می‌باشد. مدت زمان انجام عملیات رده‌بندی در مرحله تست برای اجرای اول برابر با ۴۶ میلی‌ثانیه و برای اجرای دوم برابر با ۱۶ میلی‌ثانیه می‌باشد (زمان اجرای دوم بدلیل اینکه کد عملیات در حافظه نهان سیستم ذخیره شده است، کمتر از زمان اجرا در اولین بار است). با توجه به اینکه زمان انجام محاسبات مربوط به استخراج شاخصها (محاسبه ترتیبی شاخصهای هیستوگرام، ماتریسهای کوکرنس و تبدیل فوریه) برابر با ۲۶۵ میلی‌ثانیه می‌باشد، زمان تعیین کلاس تصویر ورودی با احتساب زمان استخراج شاخص برابر با ۲۸۱ میلی‌ثانیه می‌باشد که با انجام موازی محاسبات این مقدار زمان بسیار کم خواهد شد.

۵. نتیجه‌گیری

در همه حالات بیان شده است. همچنین کارایی بسیار خوبی نسبت به [۴] و [۹] بدست آمده است. بنظر می‌رسد طراحی سخت افزار خط لوله برای ادامه کار و پیاده‌سازی بلادرنگ سیستم رده‌بندی خرابیهای سطح ورق مناسب باشد که به عنوان پیشنهادی برای ادامه کار بیان می‌شود.

منابع

1. Guha P., "Automated Visual Inspection of Steel Surface, Texture Segmentation and Development of a Perceptual Similarity Measure", MS Thesis, Department of Electrical Engineering, Indian Institute of Technology, Kanpur, April 2001.
 2. Saridis G.N., Brandin D.M., "An Automatic Surface Inspection System for Flat Rolled Steel", Purdue Laboratory for Applied Industrial Control Schools of Engineering, Purdue University West Lafayette, Indiana, December 1976.
 3. Niskanen M., "A Visual Training Based Approaches to Surface Inspection", MS Thesis, Department of Electrical and Information Engineering, University of Oulu 2003.
 4. Valle M., Baratta D., Caviglia D.D., "Application of Hierarchical Neural Network to Pattern recognition for Quality Control Analysis In Steel industry plant", *IEEE International Workshop on Neural Networks for Identification, Control, Robotics and Signal/Image Processing*, Italy, 1996.
 5. Mery D., Berti M.A., "Automatic detection of welding defects using texture features", *International Symposium on Computerized Tomography and Image Processing for Industrial Applications in Radiology*, Berlin, 2003.
 6. Chalasani S.K., "Segmentation and Performance Evaluation of Steel Defect Images", MS Thesis, Department of Mechanical Engineering, Indian Institute of Technology, Kanpur, March, 2000.
 7. Kumar A., Gupta S., "Real Time DSP Based Identification of Surface Defects Using Content-Based Imaging Technique", *IEEE International Conference on Industrial Technology*, 2000.
 8. Monadjemi A.H., "Towards Efficient Texture Classification and Abnormality Detection", Ph.D. Dissertation, Department of Computer Science, University of Bristol, October 2004.
۹. شریف‌زاده م.، پردازش دیجیتال تصاویر ورق فولاد به منظور تشخیص انواع خرابیهای سطحی، پایان‌نامه کارشناسی ارشد، دانشکده برق و کامپیوتر، دانشگاه صنعتی اصفهان، اصفهان، ۱۳۸۴.
10. Rafael C. Gonzalez., Richard E. Woods., Digital Image Processing (3rd Edition), published in 2007, ISBN-10: 013168728X | ISBN-13: 978-0131687288 | Edition: 3
11. Fritz Albertson., "Statistical Texture Measures Computed From Gray Level Co-Occurrence Matrices", Image Processing Laboratory Department of Informatics University of Oslo ,2008.
12. Haykin S., "Neural Network: A Comprehensive Foundation", Prentice Hall, 1998.
13. http://www.iitk.ac.in/robotics/project_lists/sail/atlas.html
14. Roberto Medina, Fernando Gayubo, Luis M. Gonzalez-Rodrigo, David Olmedo, Jaime Bermejo, Eduardo Zalama, Jose R. Peran., Automated visual classification of frequent defects in flat steel coils, Springer-Verlag London Limited 2011.
15. Ali Javed , Mirza Ahsan Ullah , Aziz-ur-Rehman., "Comparative Analysis of Different Fabric Defects Detection Techniques ", Image, Graphics and Signal Processing, 2013.
۱۶. نویدپناه م.، رده بندی عیوب سطح ورق فولاد با استفاده از شبکه های عصبی مصنوعی، پایان‌نامه کارشناسی ارشد، دانشکده برق و کامپیوتر، دانشگاه صنعتی اصفهان، اصفهان، ۱۳۸۴.

