Computational Intelligence in Electrical Engineering
Vol. 15, No. 1, 2024
pp. 17-24
Research Paper

Extracting the Sensing Characteristic of a Multimode Optical Fiber Speckle-Gram Refractive Index Sensor with Tapered Sensing Area Based on Deep Learning

Mostafa Al-Zain[1], Mojtaba Akbari[2], Hamidreza Karimi Alavijeh[*3], Payman Moallem[4]

Ph.D. student, Dept. of Electrical Engineering, University of Isfahan, Isfahan, Iran
Ph.D. student, Dept. of Electrical Engineering, University of Isfahan, Isfahan, Iran
Assistant Professor, Dept. of Electrical Engineering, University of Isfahan, Isfahan, Iran
Professor, Dept. of Electrical Engineering, University of Isfahan, Isfahan, Iran

Abstract:
In this paper, using a deep learning technique, the sensing characteristic of a refractive index (RI) sensor based on a multimode optical fiber speckle-gram has been extracted. The investigated sensor structure consists of a tapered optical fiber or microfiber (MF) induced on a standard multimode optical fiber (MMF). Due to the presence of evanescent waves around the MF, the guiding status of the end MMF is dependent on the external RI around the taper. Thereby, the propagating modes and resulting interference pattern or speckle-gram become sensitive to the changes in the taper environment. Herein, by analyzing and quantifying the speckle-gram modulation, the RI changes around the taper are characterized. To extract the sensing characteristic and improve its measurement accuracy, deep learning algorithms and specifically the ResNet deep neural network are used in the processing of the output speckle-grams. Using this algorithm, while the tapered fiber is immersed in different refractive index solutions in the range of 1.33 to 1.368, a set of output speckle images is captured for learning and then a number of them are used for measurement, and finally the accuracy of detecting the refractive index of the solutions RI has been achieved up to 95%.

Keywords: Tapered optical fiber, fiber speckle-gram, deep learning, RestNet.

This is an open access article under the CC BY-NC-ND/4.0/ License (https://creativecommons.org/licenses/by-nc-nd/4.0/).

https://doi.org/10.22108/ISEE.2023.138136.1635

مقاله پژوهشی

استخراج مشخصهٔ یک حسگر ضریب شکست مبتنی بر لکهٔ خروجی فیبر نوری چند مد با ناحیهٔ حساس باریک‌شده با استفاده از یادگیری عمیق

مصطفی الزین[۱]، مجتبی اکبری[۲]، حمیدرضاکریمی علویجه[۳*]، پیمان معلم[٤]

۱- دانشجوی دکتری گروه مهندسی برق، دانشکده فنی و مهندسی، دانشگاه اصفهان، اصفهان، ایران
m.alzein@eng.ui.ac.ir

۲- دانشجوی دکتری گروه مهندسی برق، دانشکده فنی و مهندسی، دانشگاه اصفهان، اصفهان، ایران
m.akbari@eng.ui.ac.ir

۳- استادیار گروه مهندسی برق، دانشکده فنی و مهندسی، دانشگاه اصفهان، اصفهان، ایران
h.karimi@eng.ui.ac.ir

٤- استاد گروه مهندسی برق، دانشکده فنی و مهندسی، دانشگاه اصفهان، اصفهان، ایران
P_moallem@eng.ui.ac.ir

چکیده: در این مقاله، مشخصات حسگری ضریب شکست مبتنی بر تصویر لکهٔ خروجی تار نوری چند مد با استفاده از ساختار تار باریک‌شده همراه با یک روش نرم‌افزاری یادگیری عمیق استخراج داده شده است. این ساختار حسگری از یک تار نوری چند مد باریک‌شده متصل به دو تار نوری چند مد استاندارد تشکیل شده است. با وجود امواج میراشونده پیرامون بخش باریک‌شده، شرایط موجبری ساختار در بخش خروجی به ضریب شکست محیط، وابسته و از این رو، مدهای انتشاری و تصویر حاصل از تداخل آنها حساس به تغییرات محیط می‌شوند. بر این اساس، پردازش تصویر حاصل از تداخل مدهای انتشاری ساختار چند مدی و آنالیز کمی تغییرات آنها مبنای حسگری است. به‌منظور بهبود دقت سنجش، از الگوریتم‌های یادگیری عمیق و به‌طور مشخص از شبکه عصبی عمیق ResNet در پردازش تصاویر لکه خروجی تار نوری استفاده شده است. با استفاده از این الگوریتم، مجموعه‌ای از تصاویر لکهٔ خروجی تار با قرارگیری بخش تار باریک‌شده در ۹ محلول سنجش مختلف در بازهٔ ضریب شکستی ۱,۳۳ تا ۱,۳٦۸ برای یادگیری و سپس تعدادی از تصاویر ثبت‌شده برای سنجش تعریف شده‌اند و درنهایت، دقت تشخیص ضریب شکست محلول‌ها تا ۹۵٪ به دست آمده است.

واژه‌های کلیدی: تار نوری باریک‌شده، لکهٔ خروجی تار نوری، یادگیری عمیق، ResNet.

۱- مقدمه

فناوری حسگری بر پایه تارهای نوری به دلیل ویژگی‌های جذابی مانند اندازه کوچک، امکان سنجش از راه دور، سنجش به‌صورت نقطه‌ای یا توزیع‌شده، مقاومت در برابر تداخلات الکترومغناطیسی و قابلیت اطمینان بالا در محیط‌هایی با شرایط فیزیکی و شیمیایی سخت توجهات بسیاری را به خود جلب کرده است [۱-۵]. تاکنون انواع حسگرها مبتنی بر ساختارهای تار نوری شامل تداخل سنج [٦]، توری براگ [۷] و تارهای نوری باریک‌شده همراه با نانوذرات پلاسمونیکی [۸] برای اندازه‌گیری ضریب شکست[۱] (RI) مایعات ارائه شده‌اند؛ با این حال، این حسگرها در فرآیند سنجش نیاز به تجهیزات پیچیده‌ای

[۱] تاریخ ارسال مقاله: ۱۴۰۲/۰٤/۰۲
تاریخ پذیرش مقاله: ۱۴۰۲/۰۵/۲۲
نام نویسندهٔ مسئول: حمیدرضاکریمی علویجه
نشانی نویسندهٔ مسئول: ایران، اصفهان، دانشگاه اصفهان، دانشکده فنی و مهندسی، گروه مهندسی برق

دارنـد. نـوع خروجـی تولیدشـده در ایـن سـاختارها بـا محـدودیت اسـتفاده از روش‌هـای پـردازش دیجیتـال و نـرم‌افـزاری بـه جـای روش‌هـای کنتـرل مـوجبری و سخت‌افزاری برای بهبود مشخصات سنجش مانند دقـت و سرعت پاسخ‌دهی مواجه است.

همچنین، حسگرهای نوری مبتنی بر لکه خروجـی تـار نوری[۲] (FSS) با یک چیدمان ساده‌تر و خروجـی تصـویری قابل پردازش که حاوی اطلاعات زیادی‌انـد، گزینـه جـذابی برای حسگری‌های محیطـی هسـتند [۹, ۱۰]. یـک سـاختار FSS براسـاس تجزیـه‌وتحلیـل تغییـرات طـرح تـداخلی تولیدشده در سطح مقطع عرضی یک تـار نـوری چنـد مـد[۳] (MMF) عمل سنجش کمیت‌های شیمیایی و فیزیکی محیط پیرامون را انجام می‌دهد؛ تحریک هم‌زمان مـدهای انتشـاری در یک MMF که با سرعت‌های فاز متفاوت سیر می‌کنند و در طی یک مسـیر مشـخص اخـتلاف فازهـای متفـاوتی را تجربه می‌کنند. این پدیده شکل‌گیری یک طرح تـداخلی در دهانه خروجی تار نوری را نتیجه می‌دهد که معمولاً متشکل از تعداد بسیار زیـادی نقـاط روشـن و تاریـک اسـت [۱۱]. توزیع این نقاط در تصویر تشکیل‌شده در خروجـی MMF اطلاعات شرایط موجبری در سرتاسر مسیر تار نـوری را در خود دارد؛ به نحوی که دامنه هر کمیت فیزیکی یا شـیمیایی که باعث تغییـر در مشخصـات مـدهای انتشـاری در مسـیر موجبری شود، با پردازش تغییرات این طرح تـداخلی قابـل سنجش اسـت. تـاکنون از FSS بـرای انـدازه‌گیـری دمـا و سـنجش کمیـت‌هـای شـیمیایی و فیزیکـی ماننـد ضـریب شکست، جابجـایی، کـرنش، خمـش و لـرزش کاربردهـای متعددی گزارش شـده اسـت [۱۶]؛ بـا ایـن حـال، افـزایش حساسیت و سرعت پاسخ‌دهی حسگرها به استفاده بهینـه از آنها در کاربردهای گوناگون منجر می‌شـود. در ایـن راسـتا، استفاده از هوش مصنوعی به‌عنوان یک راه‌حـل نـرم‌افـزاری مؤثر برای بهبود عملکرد FSSها مطـرح شـده اسـت [۱۲–۱۷]. با استفاده از الگوریتم‌های هوش مصنوعی تغییـرات در لکهٔ خروجی تار نوری با دقت بیشـتری، کمّـی و همچنـین، اغتشاشات ناشی از شرایط نوری مختلف برطرف می‌شـوند. از دیگر مزایای استفاده از هـوش مصـنوعی در حسـگرهای تاری نوری مبتنی بـر لکـهٔ خروجـی، کـاهش زمـان تحلیـل داده‌ها و کاهش هزینهٔ انجام آزمـایش‌هـا و زمـان اسـت. در مرجع [۱۵] یـک مـدل شـبکه عصـبی کانولوشـن[۴] (CNN) آموزش داده شد تا رابطه بین پارامتر تغییر شکل تار نوری و تغییرات در مشخصات لکه‌ای خروجـی یـادگیری شـود. در این تحقیق نشـان داده شـد لکـه‌هـای خروجـی تـار نـوری می‌توانند به دقت برای انحراف نوک تار را اندازه‌گیری کنند و انحراف را تشخیص دهند. طبقه‌بنـدی براسـاس یـادگیری عمیـق در مرجـع [۱۶] افـزایش دامنـه انـدازه‌گیـری بهبـود حساسیت حسگر را نتیجه داده است. الگوریتم‌های CNN و SVM[۵] برای طبقه‌بندی لکه‌ها در شرایط خمشـی مختلـف، استفاده و فاصله‌های خمشـی ۱۵، ۱۰ و ۵ درجـه بـا دقـت ۹۹,۲، ۹۶,۱ و ۹۳,۵ درصد به‌ترتیب اندازه‌گیری شدند [۱۷]؛ بـا ایـن حـال، انـدازه‌گیـری ضـریب شکسـت و حسـگری شیمیایی مبتنی بر ساختار FSS، زمـانی کـه تارهـای نـوری معمول با ساختار هسته – غلاف استفاده می‌شوند، با چـالش حساسیت روبـه‌رو هسـتند. در ایـن سـاختارها از آنجـا کـه محصورشدگی نور در مرز هسته – غلاف انجام می‌شود، این ناحیه در عمق لایهٔ غلاف قرار دارد و بنابراین، نور انتشـاری در فیبر در معرض برهمکنش مستقیم بـا محـیط و تغییـرات شیمیایی آن قرار نمی‌گیرد؛ بنابراین، حساسیتی بـه تغییـرات ضریب شکست محیط پیرامون وجود ندارد [۱۹]. در جهت رفع این چالش، پیـاده‌سـازی FSS بـا اسـتفاده از فیبرهـای نوری خاص مانند تار بدون هسته[۶]، بـه‌کـارگیری اتصـالات ناهمگون تارهای نوری[۷] چند مد و تک مد یا تارهای نـوری تغییر شکل یافتـه بررسـی شـده‌انـد کـه در آنهـا در بخـش حسگری نور انتشاری دارای برهمکنش مسـتقیم بـا محـیط پیرامون قرار دارد [۱۸].

در این مقاله، یک FSS مبتنی بر تار نـوری چنـد مـدی شامل یک ناحیـهٔ باریـک‌شـده تـار نـوری باریـک‌شـده[۸] یـا میکروتار (MF) همراه با به‌کارگیری الگوریتم‌های یادگیـری عمیق در پردازش لکهٔ خروجی با هدف حسـگری تغییـرات شیمیایی محیط پیرامون MF پیشنهاد و ازنظـر آزمایشـگاهی

نتایج آن بررسی شد. به دلیل امواج میراشونده، مدهای انتشاری درون MF تحت تأثیر ضریب شکست محیط پیرامون قرار می‌گیرند؛ بنابراین، می‌توان از این FSS با ساختار MMF-MF-MMF مشخصات شیمیایی و تغییرات آنها را در یک محلول که بخش MF ساختار را در بر گرفته است، ازطریق پردازش لکه نوری خروجی ساختار به دست آورد. محلول‌های سنجش‌شده دارای ضریب‌های شکست مختلف هستند که بخش MF را در بر می‌گیرند و برای هر محلول، مجموعه‌ای از تصاویر لکهٔ خروجی مرتبط به آن ثبت می‌شود و درنهایت، با استفاده از الگوریتم‌های یادگیری عمیق غلظت محلول براساس مشخصات تصویر یک لکهٔ خروجی مشخص می‌شود.

۲- مبانی و اصول حسگری ساختار

تداخل مدهای هدایت‌شده با ثابت‌های انتشار متفاوت در یک تار نوری چند مدی لکهٔ خروجی تار نوری را تشکیل می‌دهد که از تعداد زیادی نقاط روشن و تاریک تشکیل شده است. ماکزیمم تعداد مدهایی که در یک فیبر MMF با ضریب شکست پله‌ای می‌توانند محصور و هدایت شوند، طبق رابطه زیر محاسبه می‌شود.

$$M = \frac{V^2}{2} \qquad (۱)$$

در این رابطه، v فرکانس بهنجارشده مربوط به تار است و با استفاده از رابطه (۲) بیان می‌شود: [۲۱]

$$V = \frac{2a\pi\sqrt{(n_1{}^2 - n_2{}^2)}}{\lambda} \qquad (۲)$$

که a قطر هسته، λ طول موج نور، n_1 و n_2 ضریب شکست لایه هسته و لایه غلاف هستند. با توجه به جهت انتشار z، توزیع شدت در یک الگوی تداخلی در صفحه xy براساس رابطه (۳) به دست می‌آید:

$$I(x,y) = \sum_{m=1}^{M}\sum_{n=1}^{M} a_m a_n \exp j(\varphi_m - \varphi_n) \qquad (۳)$$

در این رابطه M تعداد مدها، a_m و φ_m دامنه و فاز مد مرتبه mام است [۲۲]. بر این اساس، الگوی تداخلی ایجادشده به کمیت‌های نوری مانند طول تار، قطر هسته، ضرایب شکست هسته و غلاف، توان لیزر، طول موج و شرایط تزویج نیز بستگی دارد. هر گونه عامل خارجی مانند تغییرات فیزیکی یا شیمیایی که مشخصات انتشاری مدها را در امتداد طولی تار نوری بتواند تحت تأثیر قرار دهد، باعث تغییر در طرح تداخلی خروجی از تار می‌شود و بنابراین، ازطریق پردازش تصاویر لکه می‌توان دامنهٔ عامل تغییر را آشکارسازی و استخراج کرد. ساختار کلی این حسگرها شامل منبع نوری، تار نوری و یک دوربین با توان تفکیک مناسب به همراه امکانات پردازش تصویر است. شکل (۱) تجهیزات مورد نیاز و چیدمان این حسگر را نمایش می‌دهد.

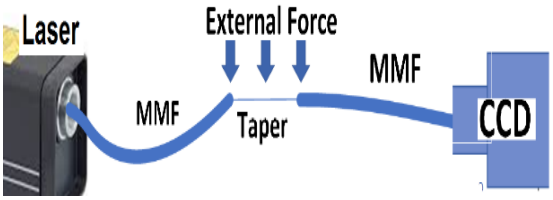

شکل (۱): ساختار یک حسگر مبتنی بر لکهٔ خروجی تار نوری متشکل از تار نوری چند مدی، منبع نور لیزر، دوربین و پردازش تصویر

تا کنون به‌منظور استخراج اطلاعات حسگری از لکهٔ خروجی تار و الگوی تصویری حاصل از آن، برای نمونه، از کمیت‌هایی مانند NIPC[۹] یا ZNCC[۱۰] استفاده شده است [۲۲-۲۳].

۲-۱- ساخت و مشخصه‌یابی حسگر

شکل (۲) یک FSS مبتنی بر ساختار MMF-MF-MMF را نشان می‌دهد. ناحیهٔ حساس ساختار متشکل از تار باریک‌شده است که با استفاده از روش گرمایش و کشش تار نوری چند مد (قطر هسته و غلاف به‌ترتیب ۵۰ و ۱۲۵ میکرومتر) ایجاد شده و جزئیات این فرایند ساخت در [۲۴] ارائه شده است. به‌منظور کاهش اثرات عوامل بیرونی نامطلوب مانند اغتشاشات مکانیکی، چیدمان حسگری روی یک میز نوری استاندارد پیاده برپا شده است. برای تزویج

نور خروجی یک لیزر هلیوم – نئون در طول موج nm ۶۳۲٫۸ به ورودی حسگر از یک لنز میکروسکوپ با بزرگنمایی ۱۰ استفاده شده است. رشتهٔ MMF استفاده‌شده در این آزمایش ۲ متر طول دارد که در وسط آن به طول یک سانتی‌متر یک ناحیهٔ باریک‌شده یا MF ایجاد شده است. نور عبوری از MF ازطریق امواج میراشونده مدها با محلول‌های ضریب شکستی که در پیرامون ساختار تزریق می‌شوند، دارای برهمکنش مستقیم است و این ویژگی تغییر مدهای انتشاری و تغییر طرح تداخلی حاصل از آنها را در بخش MMF پایانی نتیجه می‌دهد. در این ساختار پیشنهادی حساسیت FSS به سبب تأثیرپذیری مستقیم امواج میراشونده از محیط نسبت به یک فیبر نوری استاندارد باید افزایش یابد. با قراردادن ناحیه حساس در معرض محلول‌های ضریب شکست تهیه‌شده از محلول نمک *NaCl* در آب خالص با غلظت‌های مختلف نمک از ۰ تا ۲۰ درصد وزنی، تصاویر مربوطه از لکه خروجی دریافتی از MMF دوم، ثبت و پردازش می‌شوند. پس از هر اندازه‌گیری MF و محیط پیرامون آن باید با آب مقطر شستشو شود تا اثر محلول‌های مختلف تداخل نداشته باشد. با توجه به اینکه ساختار به ارتعاشات خارجی حساس است، این فرایند با دقت بالا و بدون هیچ‌گونه اغتشاش مکانیکی اضافی انجام شده است.

در مرحله بعدی با استفاده از الگوریتم شبکه‌های عصبی عمیق تصاویر لکهٔ خروجی کلاس‌بندی، یادگیری (آموزش) و برای استخراج مشخصهٔ حسگری تحلیل می‌شوند.

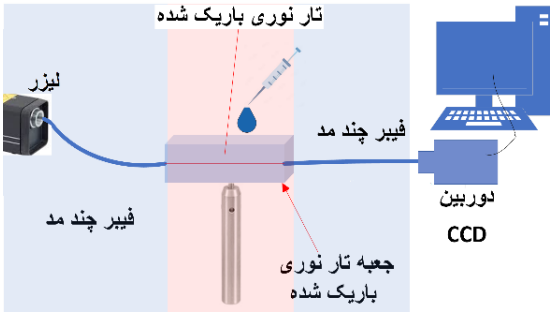

شکل (۲): ساختار FSS که در آن یک MF بین دو تا MMF قرار گرفته شده است.

۲-۲- پردازش ازطریق شبکه عصبی پیچشی

شبکه عصبی پیچشی یک الگوریتم یادگیری عمیق است که تصویر ورودی را دریافت می‌کند و به هر یک از اشیا و جنبه‌های موجود در تصویر میزان اهمیت (وزن‌های قابل یادگیری و بایاس) تخصیص می‌دهد و قادر به متمایزسازی آنها از یکدیگر است. این الگوریتم در مقایسه با دیگر الگوریتم‌های دسته‌بندی به پیش‌پردازش کمتری نیاز است؛ در حالی که فیلترهای روش‌های اولیه به‌صورت دستی مهندسی شده‌اند، شبکه عصبی پیچشی، با آموزش‌دیدن به اندازه کافی، توانایی فراگیری این فیلترها را کسب می‌کند.

در این تحقیق، از شبکه عصبی پیچشی رزنت ۵۰ (*Residual Network*) که یک شبکه عصبی عمیق از پیش آموزش دیده برای تشخیص تصاویر است، استفاده شده و ساختار شبکه آن در شکل (۳) نشان داده شده است [۲۰]. محققین شرکت مایکروسافت، این شبکه را در سال ۲۰۱۵ طراحی کردند و از ۵۰ لایه پیچشی که اساس یادگیری در آنها باقیمانده‌ها هستند، تشکیل شده است. در شبکه‌های عصبی عمیق معمولی اغلب لایه‌های پیچشی و سپس لایه‌های کاملاً متصل برای طبقه‌بندی دارند. وقتی این شبکه‌ها عمیق‌تر شوند (یعنی لایه‌ها افزایش یابند)، مشکل محوشدگی گرادیان یا انفجار گرادیان رخ می‌دهد. این معماری با ارائه لایه‌های خاصی که بلوک‌های باقی‌مانده (Residual) شناخته می‌شوند، به‌عنوان راهکاری برای حل مشکل کاهش نرخ یادگیری در شبکه‌های عمیق ایجاد شده است. ایده اصلی این معماری این است که با استفاده از اسکیپ کانکشن‌ها (skip connections)، اطلاعات از لایه‌های قبلی به لایه‌های بعدی به‌صورت مستقیم یا شرطی منتقل می‌شوند که باعث کاهش مشکل کاهش نرخ یادگیری می‌شود و شبکه‌ها را قادر به آموزش با عمق بالا می‌کند [۲۰]

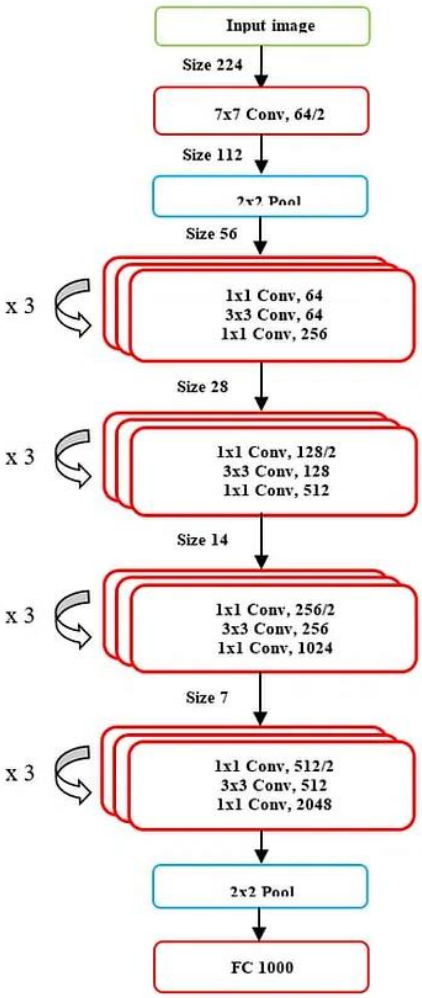

شکل (۳): معماری شبکه ResNet50

در شکل (۳) لایه ورودی (Input Layer) تصویر ورودی را به شبکه می‌دهد. ابعاد ورودی برای شبکه ResNet-50 عموماً ۲۲٤×۲۲٤×۳ برای تصاویر رنگی است. لایهٔ بعدی لایه کانولوشنی اول است که با استفاده از ٦٤ فیلتر کانولو، تصویر ورودی را کانولوشن می‌کند و نتیجه را به لایه بعدی ارسال می‌کند. بعد از این لایه یک جمع‌کننده هست که به‌منظور کاهش ابعاد تصاویر و استخراج ویژگی‌های مهم استفاده می‌شوند. در مرحله بعدی که مهم‌ترین قسمت ResNet-50 است از چندین بلوک تکراری از لایه‌های کانولوشنی تشکیل شده است. اسکیپ کانکشن‌ها نقطهٔ قوت اصلی این معماری هستند که امکان جریان‌دادن مستقیم یا شرطی اطلاعات از لایه‌های قبلی به لایه‌های بعدی را فراهم می‌کنند. این امر به شبکه اجازه می‌دهد در تمام فرآیند آموزش به‌عنوان یک شبکه کم‌عمق با قسمت‌های کمتر و معماری ساده‌تر عمل کند؛ در حالی که بتواند از خطاهای بلندمدت که در شبکه‌های عمیق قدیمی ممکن است به وجود آید، جلوگیری کند. پس از بلوک‌های باقی‌مانده لایه میانگین‌گیری (average pooling) را روی کل نواحی تصویر انجام می‌دهد و خروجی را به لایه بعدی منتقل می‌کند. این عمل به کاهش تعداد پارامترها و پیچیدگی شبکه کمک می‌کند و درنهایت، لایه آخر با ابعاد خروجی مناسب برای مسئله دسته‌بندی (به تعداد دسته‌ها) ارائه می‌شود و نتیجهٔ نهایی را تولید می‌کند.

۳- نتایج

در این مقاله، ناحیهٔ حساس ساختار FSS ایجادشده برای سنجش در معرض ۹ محلول با ضریب‌های شکست مختلف از ۱,۳۳۳ تا ۱,۳٦۸ قرار می‌گیرد. در مرحلهٔ یادگیری (آموزش)، برای سنجش هر محلول ٤٥۰ تصویر با اندازه که به ۹ کلاس مختلف بسته‌بندی شده‌اند، ثبت شده است. به‌منظور آموزش بهتر و جلوگیری از بیش‌برازش تصاویر ورودی در معرض تغییراتی چون چرخش، نویز تصادفی و تغییرات کنتراست و روشنایی قرار گرفته‌اند. شکل (٤) لکهٔ خروجی تار نوری برای ضریب شکست‌های ۱,۳٤۱۸ (الف)، ۱,۳٥۲۳ (ب)، ۱,۳٦۳۰ (پ) و ۱,۳٦۸٤ (ت) را نشان می‌دهد. برای مرحله آزمایشی، حدود ۱۲٥ تصویر برای هر کلاس به کار برده شده است. تصاویر به‌دست‌آمده با استفاده از دوربین CMOS با دقت مؤثر ۱,۲ مگاپیکسل و لنز Azure 60.40 DL ثبت شده‌اند. شبکه ResNet50 بیش از ۲۳ میلیون پارامتر قابل آموزش دارد و سخت‌افزار استفاده‌شده برای ترین این شبکه Nvidia GTX 960M است که دارای ۱۰۲٤ هسته کودا است.

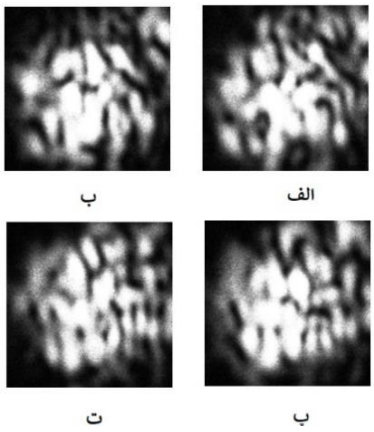

شکل (٤): لکهٔ خروجی تار نوری برای ضریب شکست‌های ۱,۳٤۱۸ (الف)، ۱,۳۵۲۳ (ب)، ۱,۳٦۳۰ (پ) و ۱,۳٦۸٤ (ت) هستند.

استفاده از شبکه‌های عصبی عمیق در FSS برای تشخیص تغییرات لکه نور خروجی و بنابراین، حسگری در محیط‌های شیمیایی می‌تواند افزایش دقت، توانایی تشخیص الگوهای پیچیده و آموزش پذیری بالا را به همراه داشته باشد. یکی از مهم‌ترین مشارکت‌های رزنت، معرفی مفهوم شبکه‌های عصبی پیچشی عمیق برای وظایف شناسایی تصویر است. در شکل (۵)، ماتریس درهم‌ریختگی (confusion matrix) برای الگوریتم پیشنهادی، با دقت ۹۵٪ برای نتایج مدنظر نشان داده شده است. همان‌طور که مشخص است الگوریتم پیشنهادی دارای دقت زیادی در تشخیص ضریب شکست محلول دربرگیرنده MF است.

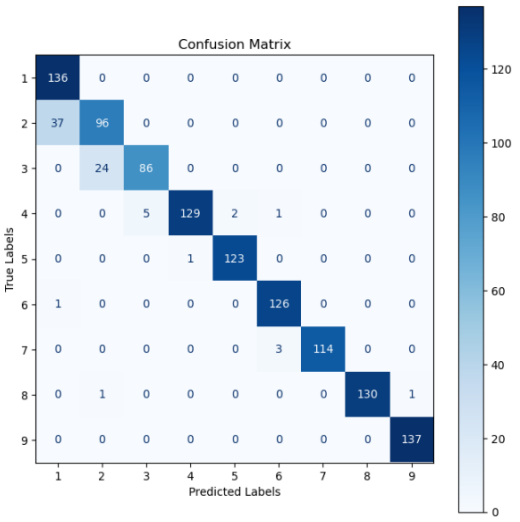

شکل (۵): confusion matrix برای ۹ محلول

هر کلاسِ لکهٔ خروجی دارای اثر انگشت خود است؛ بنابراین، هر تصویر متعلق به محلولی مشخص ویژگی‌های خاص خود را دارد که آن را از تصاویر محلول‌های دیگر متمایز می‌کند. بیان اینکه دقت‌ها ۹۵ درصد است، زمانی که تصاویر آزمایشی بارگذاری شوند، به این معنی است که الگوریتم یا روشی که برای تحلیل لکه‌های خروجی یک محلول استفاده می‌شود، قادر است به‌درستی و با خطای بسیار کم، هر تصویر را تشخیص دهد و طبقه‌بندی کند. این یک نتیجه مطلوب است؛ زیرا نشان می‌دهد روش در تحلیل خود قابل اعتماد است؛ با این حال، باید توجه داشت این سطح دقت همیشه دردسترس نیست و نتایج ممکن است به دلیل مجموعهٔ داده یا شرایط خاص تحلیل متفاوت باشد. به عبارت دیگر، این دقت می‌تواند بالا باشد؛ به شرط اینکه در حین آزمایشات اندازه‌گیری هیچ اغتشاش اضافه‌ای خروجی حسگر را تغییر ندهد. درمقابل، دقت به قطر تار نوری باریک‌شده وابسته است و یک نقطه بهینه برای قطر تاری نوری وجود دارد. در این نقطه مدهای منتشرشده در تار نوری کافی و همچنین، تأثیر محیط بر امواج میراشونده زیاد است. فرآیند آموزش این شبکه ۱۰ بار تکرار شده است. دقت پس از تکرار اول به محدوده ٦۰ درصد، در تکرار دوم محدوده ۸۵ درصد و از تکرار سوم به بعد در محدوده ۹۵ درصد ثابت می‌ماند و با تکرارهای بیشتر پیشرفتی در بهبود دقت حاصل نشده است.

نتایج حاصل از اجرای روش پیشنهادی روی بعضی از داده‌های تست در شکل‌های (٦) آورده شده‌اند. در فرآیند ارزیابی مدل آموزش داده شده از ۱۱۵۲ تصویر استفاده شده است. همان‌طور که در شکل (۵) هم مشخص است مدل پیشنهادی در تعیین ضریب شکست صحیح همه محلول‌ها به‌خوبی عمل کرده است. فقط در محلول‌های شماره ۲ و ۳ به دلیل نزدیک‌بودن ضریب شکست‌ها دارای چندین خطا است. از بین ۱۱۵۲ تصویر ارزیابی‌شده به‌طور تصادفی تعداد ۹ عدد از آنها را در شکل (٦) نمایش داده شده است. همان‌طور که مشخص است یک محلول با ضریب شکست کلاس ۲ به دلیل نزدیکی بسیار زیاد ضرایب شکست به یکدیگر به‌طور اشتباه کلاس ۳ تعیین شده است. همین اتفاق برای محلول با کلاس ۳ افتاده است که به اشتباه برای کلاس

۳ پیش‌بینی شده است. مابقی تصاویر به‌درستی تخمین زده شده‌اند.

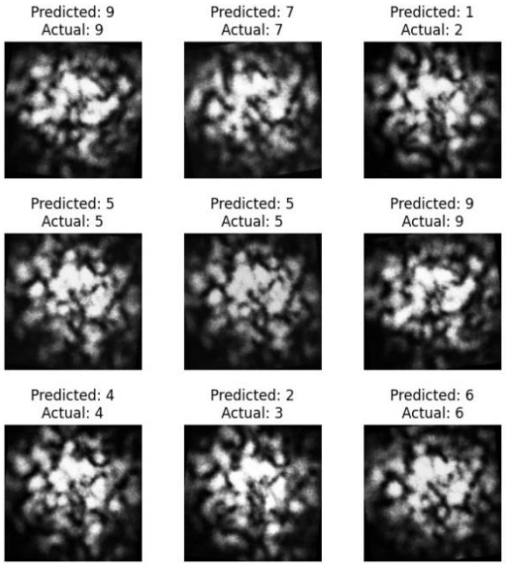

شکل (٦): برخی ازنتایج طبقه بندی داده‌های تست

٤- نتیجه گیری

در این مقاله، برای تشخیص غلظت محلول، یک حسگر مبتنی بر لکهٔ خروجی تار نوری با کمک هوش مصنوعی ارائه شده است. برای افزایش حساسیت شیمیایی، ساختار حسگر مبتنی بر یک تار نوری چند مد شامل یک بخش باریک‌شده استفاده شده است. براساس نتایج به‌دست‌آمده، یادگیری عمیق و به‌طور مشخص، شبکه‌های عصبی عمیق ResNet50 می‌تواند دقت مناسبی را از این ساختار حسگر ارائه دهد. تار باریک‌شده محلول‌های مورد سنجش غوطه‌ور شده است که در این فرآیند تغییر ضریب شکست بیرونی تغییر مشخصات انتشاری مدها و درنهایت، تغییر لکه خروجی را به دنبال دارد. هر محلول با غلظت مشخص یک مجموعه از تصاویر یا کلاس را تشکیل می‌دهد. با استفاده از الگوریتم‌های یادگیری عمیق کلاس‌بندی و تست برای تصاویر انجام‌شده، دقت سنجش برابر با ۹۵٪ ثبت شده است که نسبتاً یک دقت بالا محسوب می‌شود. به دلیل دقت بالای این حسگر، می‌توان در زمینه‌های مختلف مانند حوزه پزشکی، آزمایشگاهی و صنعتی استفاده شود.

مراجع

[1] Joe, H.-E., et al., A review on optical fiber sensors for environmental monitoring. International journal of precision engineering and manufacturing-green technology, 2018. 5(1): p. 173-191.

[2] Wright, R.F., et al., Corrosion sensors for structural health monitoring of oil and natural gas infrastructure: A review. Sensors, 2019. 19(18): p. 3964.

[3] Gupta, B.D., A. Pathak, and A.M. Shrivastav. Optical Biomedical Diagnostics Using Lab-on-Fiber Technology: A Review. in Photonics. 2022. MDPI.

[4] Hegde, G., S. Asokan, and G. Hegde, Fiber Bragg grating sensors for aerospace applications: a review. ISSS Journal of Micro and Smart Systems, 2022: p. 1-19.

[5] Deng, Y. and J. Jiang, Optical Fiber Sensors in Extreme Temperature and Radiation Environments: A Review. IEEE Sensors Journal, 2022.

[6] Yaghobi, O. and H. Karimi-Alavijeh, Fabrication and characterization of single-step optical microfiber Mach–Zehnder interferometer refractive index sensors. IEEE Sensors Journal, 2018. 19(5): p. 1788-1793.

[7] Maghsoudian, M.H. and H. Karimi-Alavijeh, A very fast single-step process for optical microfiber long period gratings fabrication. Journal of Lightwave Technology, 2022.

[8] Zhan, Y., et al., Surface plasmon resonance-based microfiber sensor with enhanced sensitivity by gold nanowires. Optical Materials Express, 2018. 8(12): p. 3927-3940.

[9] Fujiwara, E., T.D. Cabral, and C.M. Cordeiro. Optical Fiber Specklegram Sensors for Measurement of Liquids. in 2019 SBFoton International Optics and Photonics Conference (SBFoton IOPC). 2019. IEEE.

[10] Fujiwara, E., M.F.M. Dos Santos, and C.K. Suzuki, Optical fiber specklegram sensor analysis by speckle pattern division. Applied optics, 2017. 56(6): p. 1585-1590.

[11] Yin, S., P.B. Ruffin, and T. Francis, Fiber optic sensors. 2017: CRC press.

[12] Efendioglu, H.S., T. Yildirim, and O. Toker. Advanced image processing and artificial intelligence based approaches to fiber optic statistical mode sensor design. in Smart Sensor Phenomena, Technology, Networks, and Systems, 2011. International Society for Optics and Photonics.

[13] Fontana, M., Using Machine Learning to Turn Optical Fiber Specklegram Sensor into a Spatially Resolved Sensing System. 2018.

[14] Liu, Y., et al., Bending recognition based on the analysis of fiber specklegrams using deep learning. Optics & Laser Technology, 2020. 131: p. 106424.

[15] Razmyar, S. and M.T. Mostafavi, Deep Learning for Estimating Deflection Direction of a Multimode Fiber From Specklegram. Journal of

Z. Jianyu, “Research on the measurement of heart rate based on LD laser and multimode /ber,” in Proceedings of the 2020 IEEE 5th Optoelectronics Global Conference, pp. 200–203, Shenzhen, China, September 2020.

[22] F. T. S. Yu, M. Wen, S. Yin, and C.-M. Uang, “Submicrometer displacement sensing using inner-product multimode fiber specklefields,” Appl. Opt. 32, 4685–4689 (1993).

[23] M. A. Zain, H. Karimi-Alavijeh, P. Moallem, A. Khorsandi and K. Ahmadi, "A High-Sensitive Fiber Specklegram Refractive Index Sensor With Microfiber Adjustable Sensing Area," in IEEE Sensors Journal, vol. 23, no. 14, pp. 15570-15577, 2023.

[24] H. Karimi-Alavijeh, A. Taslimi, M. H. Maghsoudian, M. H. Poorghadiri, and M. Kazemzadeh. "Fabrication of low-loss adiabatic optical microfibers using an attainable arc-discharge fiber tapering setup." Optics Communications 522 (2022): 128669.

Lightwave Technology, 2020. 39(6): p. 1850-1857.

[16] Arango, J., et al. Deep learning classification and regression models for temperature values on a simulated fibre specklegram sensor. in Journal of Physics: Conference Series. 2021. IOP Publishing.

[17] Lu, S., et al., A Sensitized Plastic Fiber Sensor for Multi-Point Bending Measurement Based on Deep Learning. IEEE Photonics Journal, 2021. 13(5): p. 1-7.

[18] Wu, Q., et al., High sensitivity SMS fiber structure based refractometer–analysis and experiment. Optics express, 2011. 19(9): p. 7937-7944.

[19] Mu, G., et al., Refractive index sensing based on the analysis of D-shaped multimode fiber specklegrams. IEEE Photonics Technology Letters, 2020. 32(8): p. 485-488.

[20] Kaiming He et al., Deep Residual Learning for Image Recognition,2015 ,Computer Vision and Pattern Recognition

[21] Z. Xiaomin, S. Yunxu, X. Fucheng, M. Yan, and

[1] Refractive Index
[2] Fiber Specklegram Sensor
[3] Multimode optical Fiber
[4] Convolution Neural Network
[5] Support Vector Machine
[6] No-core Fiber
[7] Hetero-core Splicing
[8] Micro Fiber
[9] Normalized Intensity Inner Product
[10] Zero-mean Normalized Cross-correlation Coefficient