

Thickness Measurement of Metals Using Neural Network and Radioisotope Measurement-Modelling

Amir Mohammad Beigzadeh  | Shahryar Badiei

Nuclear Science and Technology Research Institute (NSTRI), Radiation Applications Research School, AEOI, Tehran, Iran. E-mail: abeigzadeh@aeoi.org.ir

ABSTRACT

Article Information:

Research Article

Received 15 January 2023

Revised 01 February 2023

Accepted 14 Feb. 2023

Keywords:

Radioisotope Thickness Measurement, Artificial Neural Network, Modelling, Monte Carlo, Gamma Ray

The nuclear industry has undergone a significant technological revolution in recent years, with neural networks playing an increasingly important role. These advanced machine learning algorithms are now widely used to analyze nuclear data obtained from various sources, such as calculations, modeling, simulation, and nuclear sensors including gamma ray-based gauges, experimental tests, and non-destructive tests like radiography. Non-destructive measurement methods based on gamma rays passing through materials or processes have gained popularity due to their effectiveness and safety in the nuclear industry. These methods typically use radioactive radioisotope sources like cesium-137 and cobalt-60, along with scintillation detection units, to capture data related to fluid thickness, density, and flow. By applying neural networks, these measurements can be made even more accurate and reliable, ensuring optimal safety and efficiency in the nuclear sector. To investigate this further, a study was conducted to design the geometry of the transmission mode for radioisotope thickness measurement through simulation using the MCNPX Monte Carlo code. The model included three commonly used metals in industries: copper, iron, and aluminum, to determine their thickness. To create the dataset, the thickness of the samples was varied from 0.5 to 50 mm, with a step size of 0.5 mm, and the results of Monte Carlo calculations were recorded as pulse height in the detector. Artificial neural networks were trained based on radial basis functions (RBF) and multilayer perceptron (MLP) techniques using all the results obtained from different energies. After training, the networks were tested to predict the thickness of different metals. The results obtained from the two networks were compared for the output of the model. The study showed that the response of the MLP network was more satisfactory than that of the RBF network in this application. Overall, the study highlights the potential of neural networks in enhancing the accuracy and reliability of non-destructive measurements in the nuclear industry, particularly in predicting the thickness of different materials.

Cite this article: Beigzadeh, A. & Badiei, S. (2023). Thickness Measurement of Metals Using Neural Network and Radioisotope Measurement-Modelling. *Journal of Nondestructive Testing Technology*, 3 (2), 1-15. <http://doi.org/10.30494/JNDT.2023.401311.1121>

ضخامت‌سنجی فلزات با بهره‌گیری از روش رادیوایزوتوپی و شبکه عصبی-مدل‌سازی

امیرمحمد بیگ زاده | شهریار بدیعی

پژوهشکده کاربرد پرتوها، سازمان انرژی اتمی، پژوهشگاه علوم و فنون هسته‌ای، تهران، ایران، رایانامه: abeigzadeh@aeoi.org.ir

چکیده:

صنعت هسته‌ای حوزه‌ای است که استفاده از شبکه‌های عصبی در سال‌های اخیر در آن اهمیت فزاینده‌ای پیدا کرده است. یکی از کاربردهای مهم و کلیدی شبکه‌های عصبی در صنعت هسته‌ای در تحلیل داده‌های هسته‌ای به دست آمده از محاسبات، سنجشگرهای هسته‌ای از قبیل سنجشگرهای مبتنی بر پرتوی گاما برای اندازه‌گیری ضخامت، چگالی، فلوی سیالات، آزمایش‌های تجربی و آزمون‌های غیرمخرب نظیر پرتونگاری و ... است. روش‌های اندازه‌گیری هسته‌ای مبتنی بر پرتوی گامای عبوری از یک ماده و یا فرایند، یک روش غیرمخرب است که در شکل کلی از یک چشمه رادیوایزوتوپی پرتوزا مانند چشمه سزیم-۱۳۷ و کبالت-۶۰ و یک واحد آشکارسازی سوسوزن تشکیل شده است. در این مطالعه از طریق مدل‌سازی با کد مونت کارلوی MCNPX، هندسه‌ی مد عبوری برای ضخامت‌سنجی رادیوایزوتوپی طراحی گردید و در این مدل سه نمونه فلز پر کاربرد در صنایع (مس، آهن و آلومینیوم) با هدف تعیین ضخامت آنها استفاده شد. برای ایجاد مجموعه داده با تعداد بالا ضخامت نمونه‌ها از ۰/۵ تا ۵۰ میلی‌متر با گام ۰/۵ میلی‌متر تغییر داده شد و نتایج محاسبات مونت کارلو به صورت ارتفاع پالس در آشکارساز ثبت شد. در ادامه تمامی نتایج حاصل از انرژی‌های مختلف به صورت مجموع برای آموزش شبکه‌ی عصبی مصنوعی بر پایه توابع شعاعی (RBF) و پرسپترون چندلایه (MLP) استفاده شد تا پس از آموزش این شبکه‌ها قادر به پیش‌بینی ضخامت فلزات مختلف باشند. نتایج به دست آمده از دو شبکه برای خروجی مدل با یکدیگر مقایسه شدند. نتایج نشان داد که پاسخ شبکه MLP نسبت به RBF در این کاربرد رضایت بخش‌تر است.

اطلاعات مقاله:

مقاله پژوهشی

تاریخ دریافت:

۱۴۰۱/۱۰/۲۵

تاریخ بازنگری:

۱۴۰۱/۱۱/۱۲

تاریخ پذیرش:

۱۴۰۱/۱۱/۲۵

کلیدواژگان:

ضخامت‌سنجی

رادیوایزوتوپی،

شبکه عصبی مصنوعی،

مدل‌سازی،

مونت کارلو،

پرتوی گاما

استناد: بیگ زاده، امیرمحمد و بدیعی، شهریار. (۱۴۰۱). ضخامت‌سنجی فلزات با بهره‌گیری از روش رادیوایزوتوپی و شبکه عصبی-مدل‌سازی.

مجله فناوری آزمون‌های غیرمخرب، ۳ (۲)، ۱۵-۱. <http://doi.org/10.30494/JNDT.2023.401311.1121>

۱- مقدمه

شبکه‌های عصبی نوعی الگوریتم یادگیری ماشینی هستند که از ساختار و عملکرد مغز انسان الهام گرفته شده‌اند. شبکه‌های عصبی از لایه‌هایی از نورون‌های مصنوعی تشکیل شده‌اند که به هم متصل شده و در شبکه‌هایی سازمان‌دهی شده‌اند [۱]. صنعت هسته‌ای حوزه‌ای است که استفاده از شبکه‌های عصبی در سال‌های اخیر در آن اهمیت فزاینده‌ای پیدا کرده است [۲]. یکی از کاربردهای کلیدی شبکه‌های عصبی در صنعت هسته‌ای در آنالیز داده‌های هسته‌ای است [۳]. داده‌های هسته‌ای توسط منابع مختلفی مانند راکتورهای هسته‌ای، شتاب‌دهنده‌های ذرات و آشکارسازهای پرتوی مستقل و بکار گرفته شده در سنجشگرهای هسته‌ای تولید می‌شوند [۴]. این داده‌ها پیچیده و حجیم هستند که استخراج اطلاعات مفید از آن‌ها با استفاده از روش‌های تحلیلی سنتی را دشوار می‌کند. با این حال، شبکه‌های عصبی برای آنالیز این نوع داده‌ها مناسب هستند، زیرا می‌توانند الگوها و روابطی را در داده‌ها تشخیص دهند که ممکن است برای اپراتورهای انسانی آشکار نباشد.

سنجشگرهای هسته‌ای دستگاه‌هایی هستند که برای اندازه‌گیری ضخامت، چگالی و ترکیب مواد استفاده می‌شوند [۵]. آنها با استفاده از اصول فیزیک هسته‌ای برای اندازه‌گیری خواص مواد با استفاده از یک چشمه رادیواکتیو و یک آشکارساز کار می‌کنند. سنجشگر از یک چشمه یا مولد پرتوی یون‌ساز رادیواکتیو تشکیل شده است که پرتوها را به سوی ماده موردنظر برای اندازه‌گیری گسیل می‌کند. سپس این پرتو از ماده عبور می‌کند یا از آن پس پراکنش می‌شود و توسط یک آشکارساز، پرتوهای عبوری یا پس پراکنش شده اندازه‌گیری می‌شوند. مقدار پرتوی که در آشکارساز ثبت می‌شود متناسب با ضخامت و چگالی ماده است. انواع مختلفی از سنجشگرهای هسته‌ای وجود دارد، از جمله سنجشگرهای ثابت و سنجشگرهای قابل حمل [۶، ۷].

سنجشگرهای ثابت به طور دائم در یک خط فرایند نصب می‌شوند و برای اندازه‌گیری ضخامت و چگالی مواد در حین حرکت در خط استفاده می‌شوند. از سوی دیگر سنجشگرهای قابل حمل دستگاه‌های دستی هستند که می‌توانند برای اندازه‌گیری ضخامت و چگالی مواد در میدان مورد استفاده

قرار گیرند. استفاده از سنجشگرهای هسته‌ای به دلیل توانایی آنها در اندازه‌گیری سریع، دقیق و غیر مخرب مواد، اهمیت فزاینده‌ای در صنعت پیدا کرده است. سنجشگرهای هسته‌ای در صنایعی مانند تولید فولاد، تولید کاغذ و تولید پلاستیک و نورد فلزات استفاده می‌شود تا اطمینان حاصل شود که مواد با مشخصات ضخامت و چگالی مورد نیاز تولید می‌شوند. این امر برای حصول اطمینان از اینکه محصولات مطابق با استانداردهای کیفیت هستند و مطابق با آنچه در نظر گرفته شده است، بسیار مهم است. این ابزار در بسیاری از صنایع برای نظارت و کنترل فرآیندهای تولید استفاده می‌شوند. داده‌های موجود در صنعت هسته‌ای از دو منبع داده‌های تجربی و آزمایشگاهی و داده‌های به دست آمده از مدل‌سازی و شبیه‌سازی تشکیل شده است. در صنایع قبل از راه‌اندازی یک سامانه واقعی و انجام آزمایش‌های تجربی، مدل‌سازی فرایند یک امر مقرون‌به‌صرفه می‌باشد و این امر در صنعت هسته‌ای به سبب بهره‌گیری از چشمه‌های رادیواکتیو و مولدهای پرتوهای یون‌ساز اهمیتی دو چندان می‌یابد. شبیه‌سازی یک مرحله حیاتی در صنعت هسته‌ای قبل از انجام هر کار آزمایشی است. این به اپراتورها اجازه می‌دهد تا سناریوهای مختلف را آزمایش کنند، محققان می‌توانند تجربیات ارزشمندی را در کار با مواد و ابزارهای هسته‌ای مختلف از قبیل چشمه‌های پرتوزا و آشکارسازهای مختلف بدون خطر پرتوگیری، به دست آورند. علاوه بر این، شبیه‌سازی‌ها را می‌توان برای آزمایش فناوری‌ها و طرح‌های جدید قبل از پیاده‌سازی در کارخانه واقعی استفاده کرد. شبکه‌های عصبی نیز می‌توانند در ارتقای کارآمدی این نوع از ابزارهای اندازه‌گیری در جهت بهبود دقت و کاهش خطاهای اندازه‌گیری مؤثر باشند [۸]. برخی از موارد کلیدی استفاده از شبکه‌های عصبی در ابزار اندازه‌گیری شامل پردازش تصویر، پردازش سیگنال، کالیبراسیون، تشخیص خطا و تصمیم‌گیری در زمان واقعی بر اساس داده‌های اندازه‌گیری می‌باشد [۹].

استفاده از شبکه عصبی مصنوعی در تحلیل داده‌های سنجشگرهای رادیواکتیو تجربی و مدل‌سازی شده توسط محققان در حوزه‌های سنجشگرهای چگالی، تعیین کسر حباب، طیف‌نگاری‌های گاما، سیالات تک فازی و دو فازی، ردیاب‌های هسته‌ای گزارش شده است که در ادامه به برخی

از آنها اشاره می‌شود.

ستاری و همکارانش برای تعیین درصد حجمی و نوع رژیم جریان در سیالات دوفازی، ساختاری متشکل از یک چشمه Cs-137 و یک آشکارساز یدید سدیم (NaI) با کد مونت‌کارلوی MCNP-X¹ شبیه‌سازی کردند و در این هندسه سه رژیم جریان معمول شامل: حلقوی، طبقه‌بندی شده و همگن در کسر خالی ۰.۵٪ تا ۹۰٪ شبیه‌سازی شده است تا مجموعه داده مورد نیاز برای استخراج ویژگی‌ها و استفاده از آنها در شبکه عصبی مصنوعی (ANN)^۲ فراهم شود [۱۰]. مقایسه شبکه‌های عصبی چندلایه پرسپترون و رگرسیون عمومی برای پیش‌بینی کسر حجمی با استفاده از کد MCNPX توسط سالگادو و همکارانش مورد بررسی قرار گرفت. در این مدل‌سازی هندسه اندازه‌گیری متشکل از یک منبع پرتو گاما ۶۶۲ کیلوکترن ولت و دو آشکارساز NaI(Tl) بود، یکی برای اندازه‌گیری پرتو ارسالی و دیگری برای اندازه‌گیری پرتو پراکنده [۱۱]. روس و همکارانش روشی مبتنی بر اصول تکنیک ردیابی ذرات رادیواکتیو برای پیش‌بینی موقعیت لحظه‌ای یک ذره رادیواکتیو برای نظارت بر مخلوط بتن در داخل یک واحد صنعتی با استفاده از روش مونت‌کارلو و شبکه عصبی مصنوعی ارائه کردند. این شبیه‌سازی شامل یک هندسه تشخیص هشت آشکارساز سوسوزن (NaI(Tl))، یک منبع نقطه‌ای Cs-137 با انرژی ۶۶۲ کیلوکترن ولت با گسیل همسانگرد پرتوهای گاما و یک مخزن پلی‌وینیل کلرید بود. مدل‌سازی سیستم تشخیص با استفاده از کد MCNPX انجام شد. برای هر دو محیط، ضریب همبستگی برای همه مختصات ۰/۹۹ بود که نشان داد این روش می‌تواند ابزار خوبی برای ارزیابی مخلوط‌کن‌های صنعتی باشد [۱۲]. در مطالعه دیگر مدل‌سازی سنجشگر اندازه‌گیری چگالی و سرعت سیالات مورد بررسی قرار گرفت. داده‌های مورد نیاز برای آموزش و آزمایش مدل ANN با شبیه‌سازی کد MCNPX به دست آمد. قبل از استفاده از نتایج شبیه‌سازی برای آموزش ANN، هندسه شبیه‌سازی با یک راه‌اندازی آزمایشی اعتبارسنجی شد. راه‌اندازی آزمایشی شامل دو آشکارساز NaI(Tl) ۲ اینچی (۵/۰۸ سانتیمتر) است که در فاصله ۱۲۰ میلی‌متری از یکدیگر و یک منبع

رادیواکتیو Ba-۱۳۳ به عنوان ردیاب قرار گرفته‌اند. نتایج نشان داد که میانگین خطای نسبی تخمینی (MRE)^۳ تعیین چگالی در سیستم ارائه شده کمتر از ۰/۹ درصد بوده است. عدم قطعیت استاندارد ترکیبی نسبی اندازه‌گیری سرعت سیال از ۰/۵٪ تجاوز نکرد [۱۳]. شناسایی فصل مشترک در انتقال مشتقات نفتی در چند مسیر جریان با استفاده از شبکه عصبی مصنوعی و چگالی سنجی گاما با کد MCNPX توسط افتخاری زاده و همکارانش انجام شد [۱۴]. با هدف پیش‌بینی دقیق کسر حجمی در جریان‌های سه فاز که نقش مهمی در صنایع نفت و فرآیند دارد مدل‌سازی بر مبنای تضعیف پرتوهای گامای (تک پرتو مدادی) و شبکه‌های عصبی پرسپترون چند لایه برای پیش‌بینی دقیق درصد کسر حجمی در جریان‌های سه فاز آب-گازوئیل-هوا توسط اسلامی راد و همکارانش انجام گردید. سنجشگر متشکل از یک سیستم ساده از یک چشمه Cs-137 و یک آشکارساز NaI(Tl) برای شمارش پرتوهای عبوری بود. راه‌اندازی آزمایشی با استفاده از کد MCNPX برای ارائه داده‌های مورد نیاز برای شبکه عصبی شبیه‌سازی انجام شد. نویسندگان این کار راه‌اندازی پیشنهادی را بهترین و ساده‌ترین طرح برای کاهش خطرات پرتوی، زمان و هزینه معرفی نمودند [۱۵].

در تحقیق دیگری برای بررسی پارامترهای اثرگذار در صحت اندازه‌گیری چگالی سنج گاما از خروجی‌های به دست آمده از مدل‌سازی با کد MCNP4C برای آموزش شبکه عصبی بهره برده شد [۱۶]. بکارگیری روش هسته‌ای در اندازه‌گیری خواص فیزیکی مواد از قبیل چگالی و ضخامت به دو روش صورت می‌پذیرد: روش عبوری و روش پس‌پراکنشی، که در شکل ۱ طرحی از این دو روش برای اندازه‌گیری نشان داده شده است.

³ Mean Relative Error

¹ Monte Carlo N-Particle Transport Code-X

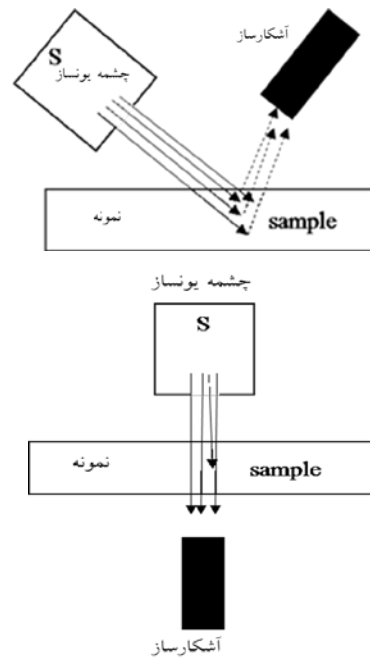
² Artificial Neural Network

مدل‌سازی با بهره‌گیری از کد مونت کارلوی MCNPX انجام شده است.

۲- روش کار

۲-۱ شبیه‌سازی:

از کد MCNPX برای شبیه‌سازی عبور و برهمکنش پرتو گاما با ماده استفاده شد [۱۸]. از هندسه پرتوی عبوری در این مطالعه استفاده شد که در آن آشکارساز و چشمه یون‌ساز در دو جهت مخالف نمونه مستقر می‌شوند.



شکل ۱) دو چیدمان اصلی برای ضخامت سنجی توسط پرتوی گاما، الف) پس پراکنشی و ب) عبوری

جدول ۱) نام و مشخصات رادیونوکلئیدهای گاما زای مورد استفاده در مدل‌سازی

نیمه عمر (سال)	انرژی (keV)	نماد	نام رادیونوکلئید
۳۰	۶۶۱/۷	Cs-137	سزیوم-۱۳۷
۵/۲۷	۱۳۳۲ و ۱۱۷۳	Co-60	کبالت-۶۰
۴۷۰	۵۹/۵۴	Am-241	امرسیوم-۲۴۱
۱۳/۵	۱۲۱/۷۸۲ و ۱۷۶۹/۰۹	Eu-152	یورورپیوم-۱۵۲

برای یک‌سوسازی^۱ و ایجاد باریکه در یک جهت خاص از چشمه‌ای که تابش همسانگرد در فضای 4π دارد، چشمه یون‌ساز در داخل حفاظ سربی قرار داده شد. از رادیونوکلئیدهای Cs-137، Am-241، Co-60 و Eu-152 برای دستیابی به مجموعه داده شبکه استفاده شد [۱۹]. نام و انرژی چشمه‌های گسیلنده گامای مورد استفاده در شبیه‌سازی در جدول ۱ آمده است. ابعاد آشکارساز NaI(Tl) 2×2 اینچ (5.08×5.08 سانتیمتر) است. ابعاد نمونه جهت آنالیز ۲۵ در ۲۵ سانتیمتر و ضخامت‌های مختلف از ۰/۵ تا ۵۰ میلی‌متر با گام ۰/۵ میلی‌متر در نظر گرفته شد که امکان شبیه‌سازی ۱۰۰ مقدار مختلف را فراهم نمود. شماتیکی از هندسه مدل‌سازی شده در شکل ۲ نشان داده شده است.

روش پس پراکنشی برای اندازه‌گیری ضخامت پوشش‌ها، چاه پیمایی و غیره استفاده می‌شود. در این روش آشکارساز و چشمه یون‌ساز در یک طرف ماده قرار دارند (شکل ۱. الف). پرتو وارد ماده می‌شود، با آن اندرکنش کرده و به بیرون پراکنده می‌شود.

روش عبوری برای اندازه‌گیری چگالی، ضخامت و غیره استفاده می‌شود (شکل ۱. ب) که در این سنجشگرها مولد پرتوی یون‌ساز و آشکارساز در طرفین مخالف ماده قرار دارند و شار تابشی با عبور از مواد کاهش می‌یابد.

هدف از این مطالعه پیش‌بینی مقادیر ضخامت صفحات فلزی آهن، آلومینیوم و مس با استفاده از شبکه‌های عصبی مصنوعی است. سیستم اندازه‌گیری شبیه‌سازی شده یک سیستم اندازه‌گیری ضخامت با پرتوی گاما است که متشکل از یک آشکارساز کریستال یدور سدیم می‌باشد و بخش چشمه آن چهار چشمه گاما زای پرکاربرد در صنعت هسته‌ای [۱۷]: Am-241، Cs-137، Co-60 و Eu-152 در نظر گرفته شد که جهت اندازه‌گیری ضخامت نمونه‌هایی از فلزات آلومینیوم، مس و آهن به کار رفته است. شبیه‌سازی و

¹ collimation

مورد استفاده برای شبیه‌سازی ۲ میلیارد ذره در نظر گرفته شد که برای به دست آوردن آمار قابل قبول، با مقادیر خطای نسبی زیر ۱ درصد برای همه زیربخش‌های توزیع ارتفاع پالس کافی بود. تالی F8 توزیع ارتفاع پالسی را می‌دهد که معادل با $\frac{I_0}{I}$ در معادله (۱) برای کل PHD^۱ است.

$$\frac{I}{I_0} = e^{-\mu x} \quad (1)$$

هنگامی که یک پرتوی گاما از ماده عبور می‌کند، بخشی از آن پراکنده می‌شود، بخشی از طریق فرآیندهای اندرکنش تابش با ماده جذب می‌شود و بخشی بدون برهمکنش از ماده عبور می‌کند (پرتو عبوری). ضریب انباشت در ارتباط با گامای پراکنده‌شده در جاذب یا در یکسوسازها یا سایر بخش‌ها که توسط آشکارساز ثبت می‌شود، تعریف می‌شود که سهم بیشتری از پرتوهای گامای ثبت‌شده را فراهم می‌کند. ضریب تضعیف خطی احتمال تضعیفی است که این فوتون ممکن است به دلیل پراکندگی کامپتون، جذب فوتوالکتریک یا تولید زوج-یون داشته باشد. در نتیجه شدت پرتو عبوری با استفاده از معادله (۲) توضیح داده می‌شود.

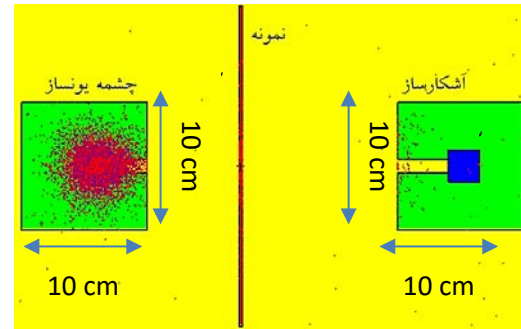
$$I = B(x, E_x) I_0 \exp(-\mu x) \quad (2)$$

که در رابطه‌ی (۲) I شدت باریکه عبوری، I_0 شدت باریکه فرودی، $B(x, E_x)$ ضریب انباشت، μ ضریب تضعیف خطی (cm^{-1}) و x ضخامت نمونه جاذب است. بنابراین ضخامت با استفاده از رابطه (۳) قابل محاسبه است:

$$x = \frac{\ln \frac{I_0}{I} B(x, E_x)}{\mu} \quad (3)$$


۲-۲ شبکه عصبی مصنوعی:

شبکه‌های عصبی مصنوعی (ANN) که معمولاً جهت سادگی شبکه‌های عصبی (NN) نامیده می‌شوند، سیستم‌های محاسباتی الهام گرفته‌شده از شبکه‌های عصبی بیولوژیکی هستند که در آن به شکل ساده شده‌ای نرون‌های عصبی انسان و حیوانات به شکل ریاضی مدل‌سازی شده است [۲۰].



شکل ۲) هندسه شبیه‌سازی شده با کد مونت کارلو

هر دو واحد آشکارسازی و گسیل پرتوی یون‌ساز در داخل محفظه استوانه‌ای قرار داده شدند که نمایی شفاف از آن در شکل ۳ نشان داده شده است.



شکل ۳) چیدمان اندازه‌گیری مورد استفاده

عدد اتمی و چگالی فلزات مورد استفاده در شبیه‌سازی در جدول ۲ آورده شده است.

جدول ۲) نام و چگالی فلزات مورد استفاده در شبیه‌سازی

نام فلز	عدد اتمی	چگالی (گرم بر سانتیمتر مکعب)
آلومینیوم	۱۳	۲/۶۹۸۹
آهن	۲۶	۷/۸۷۴
مس	۲۹	۸/۶۹


شبیه‌سازی بدون حضور نمونه نیز انجام شد تا در ابتدا میزان کارایی شمارش اولیه در آشکارساز محاسبه گردد. از تالی F8 قبل دسترس در کد مونت‌کارلوی MCNPX برای محاسبه توزیع ارتفاع پالس در آشکارساز در پاسخ به باریکه گاما پس از اندرکنش درون نمونه‌های فلزی، استفاده شد. سپس توزیع‌های ارتفاع پالس برای آموزش شبکه‌های عصبی برای پیش‌بینی ضخامت فلزات استفاده شدند. تعداد تاریخچه

¹ Pulse Height Distribution

گرفته شده است. از انواع مختلف شبکه‌های عصبی می‌توان شبکه عصبی پرسپترون چندلایه (MLP)، شبکه‌های عصبی بر پایه توابع شعاعی (RBF^۱)، ماشین‌های بردار پشتیبان (SVM^۲)، نگاشت‌های خودسازمان‌ده (SOM^۳)، یادگیرنده رقمی‌ساز بردار (LVQ^۴) و شبکه عصبی هاپفیلد را نام برد. در این مطالعه شبکه‌های عصبی MLP و RBF مورد استفاده قرار گرفته‌اند. شبکه عصبی MLP یکی از پایه‌ای‌ترین مدل‌های عصبی موجود است که عملکرد انتقالی مغز انسان را شبیه‌سازی می‌کند و در برخی موارد شبکه‌ی پیش‌خورد^۵ نیز نامیده می‌شود. در شکل ۴ ساختار این شبکه قابل مشاهده است. شبکه عصبی RBF، یک شبکه‌ی سه لایه است که از نرون‌های میانی با توابع انتقال گوسی تشکیل شده و اتصالات لایه اول وزن ندارند. در نتیجه، شبکه‌های RBF غالباً دارای فرایند یادگیری و آماده‌سازی سریع‌تری هستند [۲۱]. در شکل ۵ ساختار این شبکه ترسیم شده است.

۲-۲-۱ آموزش شبکه عصبی

یک پرسپترون پیش‌خور چند لایه (MLP^۶) برای ارتباط تعداد ذرات ثبت‌شده در آشکارساز سوسوزن با ضخامت نمونه‌های فلزی استفاده شد. برای جلوگیری از آموزش بیش از حد، از روش اعتبارسنجی متقابل^۷ به عنوان معیار توقف فرایند یادگیری استفاده شد. مدل پیشنهادی MLP در شکل ۶ نشان داده شده است.



شکل ۴) ساختار شبکه‌ی MLP.

بر این اساس، یک ANN بر پایه‌ی مجموعه‌ای از واحدها یا گره‌های متصل به نام نرون‌های مصنوعی ایجاد می‌شود که نرون‌ها را در یک سیستم عصبی بیولوژیکی مدل‌سازی می‌کنند. هر اتصال، مانند سیناپس‌های یک مغز بیولوژیکی، می‌تواند سیگنالی را به نرون‌های دیگر منتقل کند. یک نرون مصنوعی سیگنال‌ها را دریافت می‌کند، آن‌ها را جمع کرده و سپس پردازش می‌کند و می‌تواند به نرون‌های متصل به آن، سیگنال دهد. "سیگنال" در یک اتصال یک عدد واقعی است و خروجی هر نرون با اعمال یک تابع خطی یا غیرخطی بر مجموع ورودی‌های آن محاسبه می‌شود. تمام اتصالات نرونی وزنی دارند که طی فرایند یادگیری تنظیم می‌شود. وزن باعث افزایش یا کاهش قدرت سیگنال در یک اتصال می‌شود. نرون‌ها ممکن است آستانه‌ای داشته باشند که سیگنال تنها در صورتی ارسال شود که سیگنال مجموع از آن آستانه عبور کند.

به طور معمول، نرون‌ها در لایه‌هایی قرار می‌گیرند به طوری که لایه‌های مختلف ممکن است تبدیل‌های متفاوتی را روی ورودی‌های خود انجام دهند. سیگنال‌ها از اولین لایه (لایه ورودی)، به آخرین لایه (لایه خروجی)، احتمالاً پس از چندین بار عبور از لایه‌های میانی (لایه‌های مخفی) منتقل می‌شوند.

استفاده از ANN در دو مرحله انجام می‌شود:

۱) آموزش: که مرحله یادگیری نیز نامیده می‌شود، جایی است که شبکه ویژگی‌ها و رفتارهای مجموعه داده‌های ارائه شده را می‌آموزد. در این مرحله، فرایند تنظیم پارامترهای شبکه صورت می‌گیرد و ظرفیت تعمیم‌دهی آن به منظور ارزیابی کارایی تأیید می‌شود.

۲) آزمون: مرحله‌ای است که پاسخ شبکه به موارد جدیدی که در مرحله قبلی ارائه نشده است مورد ارزیابی قرار می‌گیرد که این ارزیابی نهایی شبکه است.

انواع مختلفی از مدل‌های محاسباتی تحت عنوان کلی شبکه‌های عصبی مصنوعی معرفی شده‌اند که هر یک برای دسته‌ای از کاربردها قابل استفاده هستند و در هر کدام، از وجه مشخصی از قابلیت‌ها و خصوصیات مغز انسان الهام

^۵ Feedforward

^۶ Multi-Layer Perceptron

^۷ Validation data

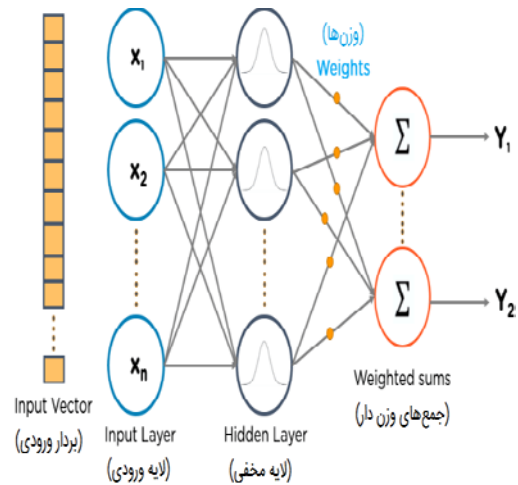
^۱ Radial Basis Function

^۲ Support Vector Machine


^۳ Self-organizing map

^۴ Learning vector quantization

Spread همان انحراف معیار توابع گوسی لایه میانی در معماری شبکه RBF است. الگوریتم‌های مختلفی شبکه‌های RBF را پیاده‌سازی کرده و آموزش می‌دهند. در الگوریتم newrb که در این پژوهش از آن بهره جستیم، این پارامتر به عنوان ورودی از کاربر پرسیده می‌شود. در نتیجه مقدار بهینه‌ی آن با سعی و خطا بدست آمده است. در سایر الگوریتم‌ها با استفاده از روش‌های با نظارت یا بدون نظارت مقدار آن تعیین می‌شود. برای تهیه‌ی داده‌های ورودی در مجموع ۱۲۰۰ شبیه‌سازی با ضخامت مختلف نمونه‌ها و چشمه‌های مختلف انجام شد. برخی از طیف‌ها که مربوط به ضخامت‌های زیاد بودند نزدیک به صفر ثبت گردیدند و از مجموعه‌ی داده‌ها حذف شدند و در نهایت ۷۳۹ جفت داده حاصل گردید و دو ماتریس 150×739 و 1×739 (ترانهاده‌ی آنها) به عنوان داده‌های ورودی و هدف مورد استفاده قرار گرفتند. ۱۰٪ از داده‌های به‌دست آمده برای تست (۷۴ جفت داده) و مابقی برای آموزش شبکه‌ها مورد استفاده قرار گرفتند (۵۹۹ جفت داده).



شکل ۵) ساختار شبکه‌ی RBF.



شکل ۶) معماری MLP برای پیش‌بینی ضخامت فلزات.

۳- نتایج

۳-۱ شبیه‌سازی


بدیهی است که فلزهایی با چگالی بالاتر در برابر پرتوهای گامای کم انرژی به عنوان محافظ عمل می‌کنند و مقادیر بسیار نزدیک به صفر را در توزیع ارتفاع پالس ارائه می‌دهند. در شکل ۷ شمارش کل سطح زیر طیف به ازای ضخامت‌های مختلف فلزات برای طیف‌های ثبت شده از چشمه‌های آمرسیوم-۲۴۱، یورونیوم-۱۵۲، سزیوم-۱۳۷ و کبالت-۶۰ به ازای یک ذره مشاهده می‌شود. همان‌طور که از نمودارهای شکل ۷ انتظار می‌رود با افزایش ضخامت، ذرات ثبت شده کاهش می‌یابند. در شکل‌های ۸ و ۹ به ترتیب طیف‌های ثبت‌شده برای نمونه‌های آلومینیوم و مس در چهار انرژی مختلف، به ازای ضخامت‌های ۲، ۲۵ و ۵۰ میلی‌متر ملاحظه می‌شود.

همان‌طور که در شکل ۶ مشخص است این شبکه شامل دو لایه‌ی مخفی به ترتیب با ۱۰ و ۵ نورون با توابع تبدیل تانژانت هیپربولیک است و از آنجایی که خروجی شبکه ضخامت پیش‌بینی شده برای فلزات است یک نرون خروجی با تابع خطی این وظیفه را انجام می‌دهد.


چهار چشمه‌ی موجود در مسئله با کدگذاری از ۱ تا ۴، سه نمونه فلز مورد اندازه‌گیری با کدگذاری از ۱ تا ۳ و طیف ثبت شده در آشکارساز در ۱۴۸ کانال به عنوان ورودی شبکه‌ها مورد استفاده قرار گرفتند. در نتیجه هر داده شامل ۱۵۰ ورودی است.

توزیع ارتفاع پالس‌ها از ۲۰ کیلوکلوکرون ولت تا حداکثر انرژی شبیه‌سازی شده در فواصل ۱۰ کیلوکلوکرون ولت در هر کانال ثبت گردید. برای شبکه‌ی RBF از ساختار مطابق شکل ۵ با ۲۰۰ نرون در لایه‌ی مخفی استفاده شد.


لازم به ذکر است که از پارامترهای شبکه، Spread برابر 0.02 و MaxNeuron برابر ۲۰۰ تعیین گردید. پارامتر




الف




الف




ب




ب




ج



ج



د



د

شکل ۸) ارتفاع‌های پالس ثبت شده برای ضخامت‌های مختلف آلومینیوم به ازای محاسبات چشمه‌های الف) آمرسیوم-۲۴۱ (ب) یورویوم-۱۵۲ (ج) سزیوم-۱۳۷ (د) کبالت-۶۰

شکل ۷) شمارش سطح زیر طیف به ازای ضخامت‌های مختلف فلزات در انرژی الف) چشمه‌های سزیوم-۱۳۷ (ب) یورویوم-۱۵۲ (ج) آمرسیوم-۲۴۱ (د) کبالت-۶۰

$$\frac{I_1}{I_2} = e^{-\mu x_1 + \mu x_2} \quad (10)$$

که در نهایت μ برای هر ماده به ازای انرژی یک چشمه به صورت زیر محاسبه می شود.

$$\mu = \frac{\ln \frac{I_1}{I_2}}{x_2 - x_1} \quad (11)$$

جدول ۳ ضریب تضعیف استخراج شده از نمودارهای ضخامت - شمارش و مقایسه آن با نتایج کارهای دیگر

مراجع [۲۲-۲۵]	$\mu(\frac{1}{cm})$ (مطالعه حاضر)	چشمه	نوع ماده
۰/۷۵	۰/۷۵۲	آمرسیوم	
۰/۱۹	۰/۱۸۷	سزیوم	آلومینیوم
۰/۱۴	۰/۱۳۲	کبالت	
۹/۴۵	۱۰/۲۸	آمرسیوم	
۰/۶۱	۰/۵۷۵	سزیوم	مس
۰/۴۲	۰/۳۹	کبالت	
۰/۵۸	۰/۵۲	سزیوم	آهن
۰/۳۳	۰/۳۶	کبالت	

همان‌طور که در نمودارهای شکل‌های ۸ و ۹ مشخص است، شکل کلی طیف‌های به‌دست آمده تابع چشمه‌ی شبیه‌سازی شده است و با افزایش ضخامت فلزات ارتفاع طیف‌ها کاهش یافته است. از آنجایی که مس عدد اتمی بالاتری نسبت به آلومینیوم دارد کاهش ارتفاع طیف‌ها با افزایش ضخامت در آن شدیدتر رخ می‌دهد.

از آنجاییکه ضریب تضعیف خطی تابعی از چگالی و انرژی پرتوی فرودی به ماده است. لذا داریم:

$$\mu = \mu(\rho, E) \quad (4)$$

از آنجاییکه در هر ضخامت سنجی با چشمه یکسان، انرژی ذره فرودی یکسان است. لذا رابطه (۴) به صورت زیر نوشته می‌شود.

$$\mu = \mu(\rho) \quad (5)$$

با توجه به اینکه نمودارهای نشان داده شده در شکل‌های ۷ الف تا ج، تغییرات شمارش در آشکارساز به ازای ضخامت‌های مختلف نمونه‌های آلومینیوم، آهن و مس را نشان می‌دهد، لذا ضریب تضعیف خطی به دست آمده از این نمودارها باید مقداری نزدیک به مقادیر ضریب تضعیف خطی محاسبه شده و اندازه‌گیری شده در سایر مطالعات را داشته باشد. برای محاسبه ضریب تضعیف خطی از روی نمودارها، دو نقطه دلخواه برای یک چشمه و یک ماده جاذب برای برخی از نمودارهای نشان داده شده در متن در نظر می‌گیریم:

معادلات حاکم بر روی هر کدام از نقاط به صورت معادلات (۶) و (۷) بیان می‌شود:

$$I_1 = I_0 e^{-\mu x_1} \quad (6)$$


و

$$I_2 = I_0 e^{-\mu x_2} \quad (7)$$


که x_1 و x_2 ضخامت به دست آمده از روی نمودار در نقطه اول و دوم است. برای محاسبه μ میتوان از تقسیم دو رابطه بالا استفاده نمود:

$$\frac{I_1}{I_2} = \frac{I_0 e^{-\mu x_1}}{I_0 e^{-\mu x_2}} \quad (8)$$


$$\frac{I_1}{I_2} = \frac{e^{-\mu x_1}}{e^{-\mu x_2}} \quad (9)$$




الف




الف




ب




ب




ج



ج



د

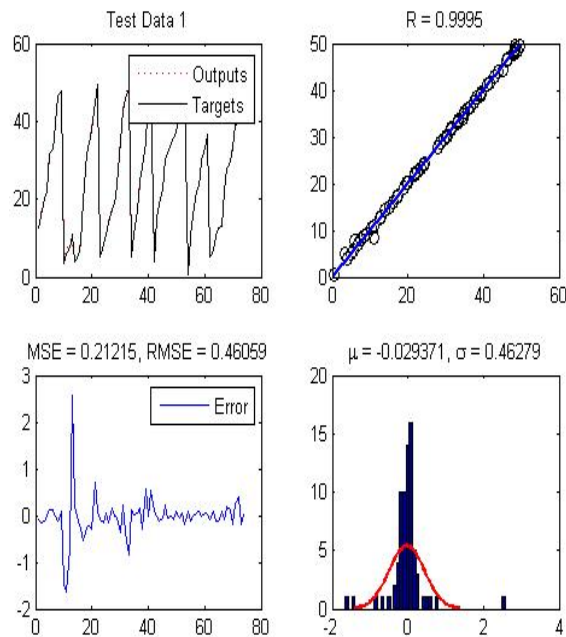


د

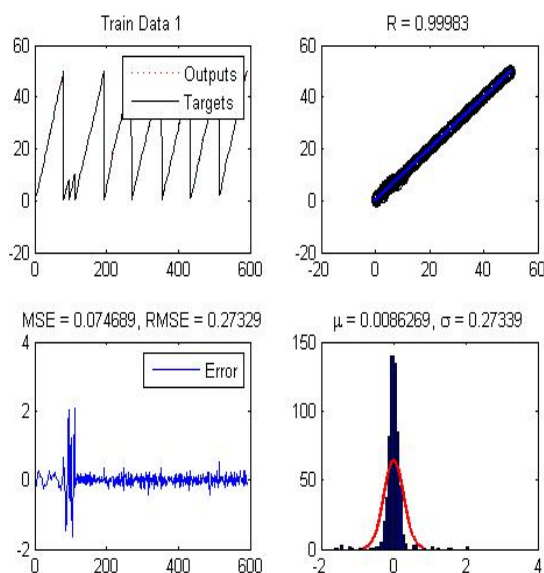
شکل ۱۰) ارتفاع‌های پالس ثبت شده برای ضخامت‌های مختلف آهن برای محاسبات با الف) آمرسیوم-۲۴۱، ب) چشمه‌های یورانیوم-۱۵۲، ج) سزیوم-۱۳۷ و د) کبالت-۶۰.

شکل ۹) ارتفاع‌های پالس ثبت شده برای ضخامت‌های مختلف مس به ازای محاسبات با الف) آمرسیوم-۲۴۱، ب) چشمه‌های یورانیوم-۱۵۲، ج) سزیوم-۱۳۷ و د) کبالت-۶۰.

بود که خطای کمی است و می‌تواند در کاربردهایی که این سطح از خطا در آن مورد قبول است به کار رود. همچنین با توجه به شکل ۱۲ مشخص می‌شود که خطای داده‌های آزمون حول صفر تمرکز یافته‌اند. همان‌طور که انتظار می‌رود این مقادیر برای داده‌های آموزش کمتر هستند (شکل ۱۳).



شکل ۱۲) نتایج شبکه پرسپترون برای داده‌های آزمون.

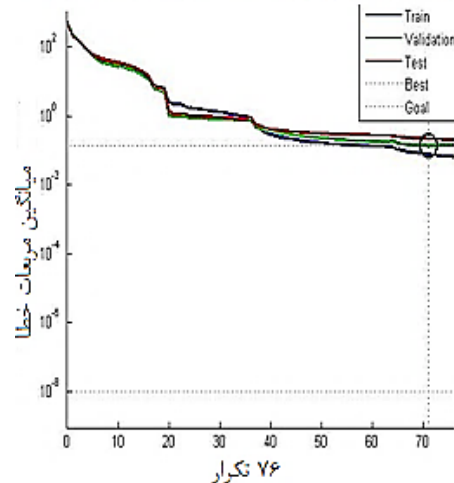


شکل ۱۳) نتایج شبکه پرسپترون برای داده‌های آموزش.

۳-۲ نتایج شبکه‌های عصبی

۳-۲-۱ نتایج پرسپترون: همان‌طور که در شکل ۱۱ مشخص است، داده‌های اعتبار‌سنجی پس از ۷۱ بار تکرار موجب خاتمه‌ی فرآیند آموزش شده‌اند.

بهترین خطای اعتبار‌سنجی برابر ۰/۱۳۶۵۴ در تکرار ۷۱ حاصل شد



شکل ۱۱) میانگین مربع خطا برای داده‌های تست، آموزش و اعتبار‌سنجی.

خطای داده‌های آزمون و آموزش به ترتیب در شکل‌های ۱۲ و ۱۳ قابل مشاهده است. با توجه به شکل ۱۲ برای داده‌های آزمون خطا حدود ۰/۴ میلی‌متر (نمودار پایین سمت راست) و میانگین مربعات خطا (MSE^1) ۰/۲۱ است (نمودار پایین سمت چپ). این دو مقدار، انحراف معیار و میانگین مربعات خطا (MSE) برای خطای بازیابی ۷۴ داده تست هستند. منظور از خطا اختلاف بین ضخامت واقعی و ضخامت پیش‌بینی شده فلز می‌باشد. به بیان دقیق‌تر میانگین مربعات خطا برای داده‌های آزمون از رابطه (۱۲) محاسبه شده است:

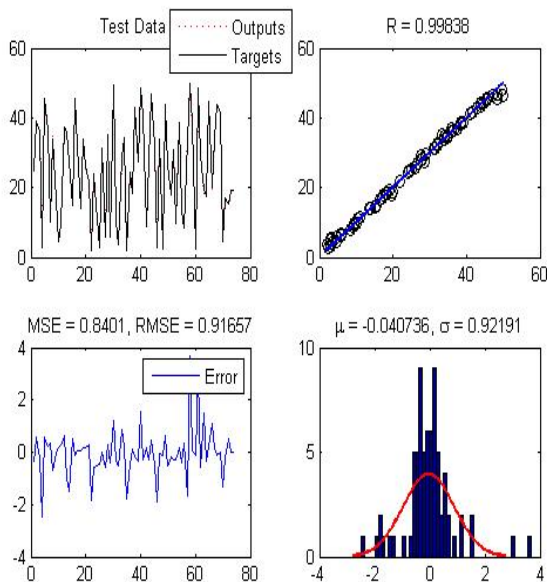
$$MSE = \frac{1}{74} \sum_{i=1}^{74} (Th_{Target}(i) - Th_{Predicted}(i))^2 \quad (12)$$

در رابطه (۱۲) $Th_{Predicted}$ و Th_{Target} به ترتیب ضخامت واقعی و ضخامت پیش‌بینی شده فلز هستند. اگر ضخامت میانگین ۲۵ میلی‌متر در نظر گرفته شود خطای ۰/۴ میلی‌متر معادل خطای نسبی ۱/۶ درصد خواهد

¹ Mean Square Error

خطای داده‌های آزمون در شکل ۱۶ قابل مشاهده است. با توجه به شکل ۱۶ برای داده‌های آزمون، خطا حدود ۰/۹ میلی‌متر و میانگین مربعات خطا در حدود ۰/۸ است. در این شکل در نمودار بالا سمت چپ ضخامت‌های پیش‌بینی شده (نقطه‌چین قرمز) و ضخامت هدف (مشکی) برای ۷۴ داده آزمون بر حسب شماره نمونه رسم شده است و از آنجایی که مقادیر بسیار به هم نزدیک هستند این دو نمودار بر روی هم منطبق شده‌اند. در نمودار مجاور (بالا سمت راست) ضخامت‌های پیش‌بینی شده بر حسب ضخامت هدف رسم شده است و از آنجایی که مقادیر بسیار به هم نزدیک هستند نمودار تقریباً به فرم تابع همانی خطی درآمده و ضریب همبستگی برابر ۰/۹۹۸ بدست آمده است. در نمودار پایین سمت چپ نمودار خطا (اختلاف بین ضخامت واقعی و ضخامت پیش‌بینی شده) برای ۷۴ داده آزمون بر حسب شماره نمونه رسم شده است و میانگین مربعات خطا (۰/۸) و جذر آن (۰/۹) بر بالای نمودار نوشته شده است. در نمودار پایین سمت راست هیستوگرام خطا به همراه میانگین (حدود صفر) و انحراف معیار (۰/۹) مشاهده می‌شود.

همچنین با توجه به شکل مشخص می‌شود که خطای داده‌های آزمون حول صفر تمرکز یافته‌اند و ضریب همبستگی نزدیک به یک می‌باشد.

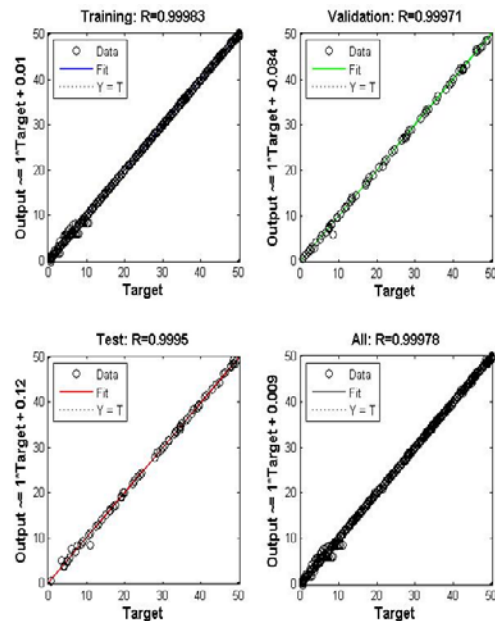


شکل ۱۶) نتایج شبکه RBF برای داده‌های آزمون.

۴- نتیجه‌گیری

در این تحقیق از روش‌های هوشمند جهت یافتن


نتایج آنالیز رگرسیون بین خروجی‌ها و هدف برای داده‌های آموزش، اعتبارسنجی، آزمون و کل داده‌ها در شکل ۱۴ منعکس شده است.



شکل ۱۴) نتایج آنالیز رگرسیون بین خروجی‌ها و هدف برای داده‌های آموزش، اعتبارسنجی، آزمون و کل داده‌ها.

با بررسی در نمودارهای شکل ۱۴ مشاهده می‌شود که مقدار ضریب همبستگی بین خروجی و هدف برای کلیه داده‌ها بسیار نزدیک به یک به‌دست آمده است که نشان‌دهنده دقت و صحت عملکرد شبکه در این کاربرد است.

۲-۲-۳ نتایج شبکه RBF: در شکل ۱۵ نمودار مربوط به کاهش خطای شبکه تا ۲۰۰ تکرار نشان داده شده است. همان‌طور که در این نمودار مشخص است خطای شبکه پس از ۱۰۰ تکرار کاهش ملموسی ندارد.



شکل ۱۵) نمودار مربوط به کاهش خطای شبکه RBF تا ۲۰۰ تکرار.

- [3] D. Neudecker, M. Grosskopf, M. Herman, W. Haeck, P. Grechanuk, S. Vander Wiel, et al., "Enhancing nuclear data validation analysis by using machine learning," *Nuclear Data Sheets*, vol. 167, pp. 36-60, 2020.
- [4] P. Vicente-Valdez, L. Bernstein, and M. Fratoni, "Nuclear data evaluation augmented by machine learning," *Annals of Nuclear Energy*, vol. 163, p. 108596, 2021.
- [5] W. Troxler, "Development and industry acceptance of nuclear gauges," in *Constructing and controlling compaction of earth fills*, ed: ASTM International, 2000.
- [6] D. R. Carlson, "Level and density measurement using non-contact nuclear gauges," *Measurement and Control*, vol. 10, pp. 83-87, 1977.
- [7] B. A. C. d. Castro, "Application of portable nuclear gauge to the control of soil, asphalt and concrete compaction."
- [8] P. Daponte and D. Grimaldi, "Artificial neural networks in measurements," *Measurement*, vol. 23, pp. 93-115, 1998.
- [9] G. W. Irwin, G. W. Irwin, K. Warwick, and K. J. Hunt, *Neural network applications in control: let*, 1995.
- [10] M. A. Sattari, G. H. Roshani, and R. Hanus, "Improving the structure of two-phase flow meter using feature extraction and GMDH neural network," *Radiation Physics and Chemistry*, vol. 171, p. 108725, 2020.
- [11] C. Salgado, R. Dam, W. Salgado, R. Werneck, C. Pereira, and R. Schirru, "The comparison of different multilayer perceptron and General Regression Neural Networks for volume fraction prediction using MCNPX code," *Applied Radiation and Isotopes*, vol. 162, p. 109170, 2020.
- [12] R. S. d. F. Dam, T. P. Teixeira, W. L. Salgado, and C. M. Salgado, "A new application of radioactive particle tracking using MCNPX code and artificial neural network," *Applied Radiation and Isotopes*, vol. 149, pp. 38-47, 2019.
- [13] G. Roshani, R. Hanus, A. Khazaei, M. Zych, E. Nazemi, and V. Mosorov, "Density and velocity determination for single-phase flow based on radiotracer technique and neural networks," *Flow Measurement and Instrumentation*, vol. 61, pp. 9-14, 2018.
- [14] E. Eftekhari Zadeh, S. Fegghi, G. Roshani, and A. Rezaei, "Application of artificial neural network in precise prediction of cement elements percentages based on the neutron activation analysis," *The European Physical Journal Plus*, vol. 131, pp. 1-8, 2016.
- خروجی (که ضخامت فلز است) بر حسب طیف دریافتی و نوع چشمه و نوع فلز به عنوان ورودی‌ها استفاده شده است. بدین منظور بایستی از روش‌هایی استفاده کرد که ارتباط بین ورودی‌ها و خروجی‌ها را می‌یابد که این امر در واقع عمل تقریب تابع^۱ است. شبکه‌های مختلفی نظیر MLP، RBF و یا ANFIS و غیره به این جهت می‌تواند به کار گرفته شود که در این تحقیق از MLP و RBF استفاده شده است. در پژوهش حاضر، روشی مبتنی بر گامای عبوری و شبکه‌های عصبی برای پیش‌بینی ضخامت در فلزات مختلف از ۰/۵ تا ۵۰ میلی‌متر ارائه شد. تمامی شبیه‌سازی‌ها با استفاده از کد مونت کارلوی MCNPX انجام شد. داده‌ها به صورت توزیع ارتفاع پالس برای هر فلز در ضخامت‌های مختلف برای ۴ انرژی محاسبه شد. تاریخچه ذرات ترابرد در شبیه‌سازی‌ها به‌قدری ادامه یافت تا انحراف معیار محاسبات مونت کارلو به حدود ۰/۳ درصد کاهش یابد. در بخش بعد دو شبکه عصبی مصنوعی بر پایه توابع شعاعی (RBF) و پرسپترون چند لایه (MLP) مورد استفاده قرار گرفت. طیف‌های توزیع ارتفاع پالس به دست آمده مستقیماً برای آموزش شبکه‌های عصبی استفاده شدند. با ارزیابی MLP، برای داده‌های آزمون، خطا حدود ۰/۴ میلی‌متر و میانگین مربعات خطا (MSE) ۰/۲۱ به دست آمد. برای شبکه‌ی RBF برای داده‌های آزمون، خطا حدود ۰/۹ میلی‌متر و میانگین مربعات خطا (MSE) در حدود ۰/۸ محاسبه شد. مشاهده شد نتایج شبکه‌ی MLP نسبت به RBF در این کاربرد رضایت‌بخش‌تر است. از آنجاییکه خطا در حالت استفاده از MLP نسبت به RBF کمتر از نصف به دست آمده است، پیش‌بینی می‌شود که MLP در تشخیص ضخامت فلزات دقیق‌تر عمل کرده و از این رو استفاده از آن نسبت به RBF ارجحیت دارد.

۲- منابع

- [1] S. Shanmuganathan, *Artificial neural network modelling: An introduction*: Springer, 2016.
- [2] K. Moshkbar-Bakhshayesh and M. B. Ghofrani, "Transient identification in nuclear power plants: A review," *Progress in Nuclear Energy*, vol. 67, pp. 23-32, 2013.

¹ Function approximation

- [15] S. Islami rad, R. Gholipour Peyvandi, and S. Sadrzadeh, "Determination of the volume fraction in (water-gasoil-air) multiphase flows using a simple and low-cost technique: Artificial neural networks," *Physics of Fluids*, vol. 31, p. 093301, 2019.
- [16] M. Khorsandi, S. Fegghi, A. Salehizadeh, and G. Roshani, "Developing a gamma ray fluid densitometer in petroleum products monitoring applications using Artificial Neural Network," *Radiation measurements*, vol. 59, pp. 183-187, 2013.
- [17] A. Belicic-Kolsek and T. Sutej, "Safety of radiation sources in Slovenia," 2001.
- [18] D. B. Pelowitz, "MCNPXTM user's manual," *Los Alamos National Laboratory, Los Alamos*, vol. 5, p. 369, 2005.
- [19] M.-M. Bé, V. Chisté, C. Dulieu, E. Browne, V. Chechev, N. Kuzmenko, et al., Table of radionuclides (Vol. 2-A= 151 to 242) vol. 2, 2004.
- [20] J. E. Dayhoff, *Neural network architectures: an introduction*: Van Nostrand Reinhold Co., 1990.
- [21] R. M. Snyder, "Neural Networks for the Beginner," 1996.
- [22] R. Thoraeus, "Attenuation of Gamma Radiation from ^{60}Co , ^{137}Cs , ^{192}Ir , and ^{226}Ra in Various Materials Used in Radiotherapy." *Acta Radiologica: Therapy, Physics, Biology*, vol. 3, no. 2, 1965, pp. 81-86.
- [23] O. Adedoyin and A. Ayodeji. "Measurement of Shielding Effectiveness of Building Blocks against 662 KeV Photons." *Journal of Physical Science*, vol. 27, no. 2, 2016, pp. 55.
- [24] OSHA. "Shielding Layer Examples." OSHA, n.d., <https://www.osha.gov/ionizing-radiation/introduction/shielding-layer-examples>
- [25] NIST. "X-Ray Mass Attenuation Coefficients." NIST, n.d., <https://physics.nist.gov/cgi-bin/Xcom>.