

مدلسازی عملکرد دروازه منطقی OR انحصاری سه ورودی به کمک شبکه عصبی

سمانه حامدی^{۱*} و حامد دهدشتی جهرمی^۲

اطلاعات مقاله	چکیده
<p>نوع مقاله:</p> <p>دریافت مقاله: ۱۴۰۰/۰۶/۰۶</p> <p>بازنگری مقاله: ۱۴۰۰/۱۲/۲۹</p> <p>پذیرش مقاله: ۱۴۰۱/۰۱/۲۷</p>	<p>دروازه‌های منطقی تمام نوری اصلی‌ترین و مهمترین واحد برای دستیابی به سیستم‌های پردازشی تمام نوری هستند. ارائه یک روش سریع و کارآمد برای مطالعه رفتار دروازه‌های منطقی تمام نوری بسیار با اهمیت بوده و همواره مورد توجه محققان قرار داشته است. در این مقاله از شبکه‌های عصبی رگرسیون کلی (GRNN) و روش پیش‌بینی خطی (Lin) برای پیش‌بینی خروجی دروازه منطقی تمام نوری XOR سه ورودی استفاده شده است. نتایج بدست آمده نشان می‌دهند هر دو روش به خوبی می‌توانند رفتار قطعه را مدل‌سازی کنند اما مدت زمان آموزش شبکه عصبی در روش پیش‌بینی خطی با ساختار بهینه حدود ۹۳ ثانیه است که بسیار بیشتر از روش GRNN با مدت زمان آموزش ۸ ثانیه می‌باشد. هر دو شبکه پس از آموزش می‌توانند خروجی دروازه مورد نظر را در مدت زمانی کمتر از ۱ ثانیه پیش‌بینی نمایند. این زمان در مقایسه با زمان مورد نیاز برای محاسبه خروجی دروازه منطقی XOR که برابر با ۱۲ ثانیه می‌باشد کاهش چشمگیری را در مدل‌سازی این افزاره نشان می‌دهد. در روش GRNN به ازای مقدار گستردگی ۰.۰۱، بهترین پاسخ با مقادیر خطاهای MAE, RSE, MSE به ترتیب $1/97 \times 10^{-7}$، $5/95 \times 10^{-6}$ و $1/6 \times 10^{-4}$ به دست آمده است. در روش پیش‌بینی خطی با مقدار آموزش اولیه ۲۰۰ داده کمترین مقادیر خطاهای MAE, RSE, MSE به ترتیب $1/11 \times 10^{-22}$، $2/14 \times 10^{-16}$ و $2/11 \times 10^{-11}$ و بهترین خروجی برای مدل‌سازی حاصل شده است. مقدار ضریب همبستگی (R^2) بین مقادیر مدل‌سازی شده و مقادیر مطلوب خروجی دروازه منطقی مذکور برای هر دو روش شبکه عصبی برابر با یک می‌باشد که نشان دهنده پیش‌بینی بسیار خوب در این روش است.</p>
<p>واژگان کلیدی:</p> <p>شبکه عصبی پیش‌بینی خطی، شبکه عصبی رگرسیون کلی، دروازه منطقی تمام نوری.</p>	

۱- مقدمه^۱

شبکه‌های عصبی مصنوعی از جمله روش‌های محاسبه‌ای انعطاف پذیر هستند که قادر به تخمین دامنه وسیعی از داده‌های غیرخطی می‌باشند. یکی از مزیت‌های این روش نسبت به مدل‌های دیگر غیرخطی، این است که شبکه‌های عصبی مصنوعی می‌توانند هر نوع تابعی را با دقت بسیار خوبی تقریب بزنند. شبکه‌ها بدون استفاده از روابط پیچیده ریاضی و صرفاً با اتکاء بر داده‌های در دسترس، قابلیت پیش‌بینی روابط حاکم بر داده‌های ورودی و خروجی یک سیستم را دارند. این گونه از شبکه‌ها نیازمند هیچ‌گونه

پیش‌فرضی در مورد شکل و ساختار مدل در فرآیند مدل‌سازی خود نیستند و به طور کلی یک مدل کاملاً مبتنی بر داده هستند. شبکه‌های عصبی اخیراً تبدیل به ابزار قدرتمندی برای مطالعه پدیده‌های فیزیکی و مدل‌سازی سیستم‌های مهندسی در طیف وسیعی از علوم از قبیل رشته‌های مهندسی [۱-۳]، راهسازی و صنعت ساختمان‌سازی [۴، ۵]، امنیت سایبری و فضای مجازی [۶]، صنعت نفت و گاز [۷] شده‌اند. استفاده از این ابزار در مدل‌سازی ادوات الکترونیکی و اپتوالکترونیکی باعث کاهش زمان محاسبات و افزایش سرعت شده است. در مقاله‌ای که

* پست الکترونیک نویسنده مسئول: hamed@ sutech.ac.ir.

۱. استادیار، دانشکده مهندسی برق - دانشگاه صنعتی شیراز - شیراز - ایران

۲. دانشیار، دانشکده فنی و مهندسی - دانشگاه جهرم - جهرم - ایران

مدارهای مجتمع نوری و الکترونیکی با روابط پیچیده ریاضی استفاده کرد. الگوریتم‌های زیادی برای آموزش شبکه‌های عصبی ارائه شده است مانند روش پیش‌بینی خطی (Lin)^۳، پرسپترون چند لایه (MLP)^۴، توابع شعاع پایه (RBF)^۵، رگرسیون عمومی (GRNN)^۶، ترکیب خبره‌ها^۷ و ترکیبی آموزش پذیر و ... است. هر کدام از روش‌ها مزایا و معایب خود را دارند که با توجه به پیچیدگی و نوع داده‌های موجود می‌توان از یک روش استفاده کرد. در این مقاله از روش شبکه‌های عصبی مصنوعی برای تحلیل عملکرد یک دروازه منطقی XOR سه ورودی تمام نوری و محاسبه خروجی آن استفاده شده است. برای این منظور دو شبکه عصبی مختلف برای مدل‌سازی دروازه منطقی مذکور طراحی و تحلیل شده است. خروجی‌های این دو مدل که مبتنی بر شبکه‌های عصبی پیش‌بینی خطی و شبکه‌های عصبی رگرسیون کلی (GRNN) هستند با یکدیگر مقایسه شده و توانایی هر یک از مدل‌ها را بر اساس خطاهای تولیدی سنجیده و گزارش شده است.

شبکه‌های عصبی مصنوعی با پردازش داده‌های تجربی، دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کنند. به این عمل یادگیری می‌گویند. اصولاً توانایی یادگیری مهمترین ویژگی یک سیستم هوشمند است. سیستمی که بتواند یاد بگیرد، منعطف‌تر است و ساده‌تر برنامه‌ریزی می‌شود؛ بنابراین، دربارهٔ مسائل و معادلات جدید بهتر پاسخگو است. با توجه به رویکرد دنیای فناوری، آینده همه سیستم‌ها به سمت هوشمند شدن و استفاده از هوش مصنوعی پیش می‌رود. امروزه جامعه بشری به وضعیتی رسیده است که شاید زندگی بدون حضور کارگزارهای هوشمند، غیرممکن باشد. بنابراین همه در علوم ناگزیر به استفاده از هوش مصنوعی و جایگزین کردن روش‌های محاسباتی سنتی با روش‌های هوش مصنوعی هستیم. پژوهش حاضر در راستای استفاده از هوش مصنوعی در شبیه‌سازی ادوات فوتونیک و تمام نوری می‌باشد. از نتایج این تحقیق می‌توان برای طراحی و تحلیل مدارات دیجیتال در مقیاس‌های بسیار بزرگ استفاده نموده و آن را جایگزین روش‌های محاسباتی سنگین و پیچیده کنونی کرد. علاوه بر این، استفاده از شبکه عصبی باعث

در سال ۲۰۱۸ منتشر شد، پژوهشگران دانشگاه تگزاس از روش شبکه عصبی برای بهینه‌سازی طراحی سلول خورشیدی استفاده کردند [۸]. همچنین از این روش برای ردیابی اطلاعات و تخمین مشخصات کانال در سیستم‌های مخابراتی استفاده شده است [۹، ۱۰]. توانمندی شبکه‌های عصبی مصنوعی برای طراحی ادوات فوتونیک مبتنی بر سیلیکون بررسی و گزارش شده است [۱۱]. بعنوان مثال از این روش برای طراحی تزویجگر نوری^۱ و فرستنده نوری نامتقارن سیلیکونی استفاده گردیده است [۱۲].

در سال‌های اخیر تلاش‌های فراوانی برای افزایش سرعت سیستم‌های دیجیتال و طراحی پردازنده‌های سرعت بالا جهت پاسخگویی به نیاز بازار شده است. با توجه به سرعت انتشار بسیار زیاد نور، استفاده از فوتون بجای الکترون می‌تواند گزینه مناسبی برای غلبه بر محدودیت‌های ذاتی سیستم‌های الکترونیکی و افزایش چشمگیر سرعت سیستم‌های محاسباتی باشد. بنابراین تحقیقات فراوانی به منظور طراحی سیستم‌های پردازشی و شبکه‌های رایانه‌ای تمام نوری صورت گرفته است [۱۳-۱۵]. دروازه‌های منطقی کوچکترین اجزاء سیستم‌های پردازش دیجیتال و شبکه‌های کامپیوتری می‌باشند. بنابراین برای طراحی و دستیابی به سیستم‌های تمام نوری ابتدا باید دروازه‌های منطقی تمام نوری با عملکرد صحیح و دقیق طراحی و ساخته شوند. تلاش‌های فراوانی برای طراحی و توسعه دروازه‌های منطقی تمام نوری صورت گرفته که منجر به ساختارهای استاندارد برای ساخت این دروازه‌های تمام نوری شده است [۱۶-۲۰]. دروازه منطقی OR انحصاری (XOR)^۲ به عنوان یکی از دروازه‌های منطقی پایه‌ای و کلیدی در پردازش سیگنال بوده که نقشی اساسی در کاربردهایی مانند شناسایی الگوی بیت، تولید توالی بیت، بررسی و تولید بیت توازن، فرآیندهای رمزگذاری داده‌ها و محاسبات نوری دارد [۲۱، ۲۲]. روش‌های مختلفی برای طراحی، مدل‌سازی و آنالیز دروازه‌های منطقی (XOR) تمام نوری وجود دارد که همگی مبتنی بر ساختار فیزیکی و بسط معادلات ریاضی می‌باشند.

با توجه به توانمندی‌ها و قابلیت‌های شبکه‌های عصبی، می‌توان از آنها به عنوان یک ابزار توانمند در مدل‌سازی

⁵ Radial-Base Function

⁶ Generalized Regression Neural Networks

⁷ Mixture of experts

¹ Optical couplers

² Exclusive OR

³ Linear prediction

⁴ Multi-Layer Perceptron

جهت کنترل فاز سیگنال‌های پروب و ایجاد پدیده XPM به SOAها اعمال می‌شوند.

سیگنال‌های خروجی ماخ-زندرها (۱) و (۲) بعنوان ورودی ساختار ماخ-زندر (۳) عمل کرده و خروجی نهایی توسط ماخ-زندر (۳) تولید می‌شود. با توجه به ساختار ارائه شده، خروجی نهایی از حاصل جمع دو خروجی (۱) و (۲) (OR سیمی) بدست می‌آید.

بنابراین خروجی نهایی عبارت است از: $Po = Po_1 + Po_2$. شایان ذکر است در این ساختار متمم منطقی سیگنال‌ها با علامت (') نشان داده شده‌اند. توضیحات بیشتر در خصوص نحوه محاسبات خروجی‌ها در مرجع [۲۳] ارائه شده است. در این طرح از یک منبع لیزر با توان ۵۰ میلی وات و با پروفایل گوسی بعنوان منبع ورودی برای تحریک ساختار استفاده شده است. به کمک روش ارائه شده در این مرجع، خروجی این دروازه برای حالت‌های مختلف ورودی و همچنین تاثیر توان نوری سیگنال‌های ورودی بر خروجی محاسبه شده و از این داده‌ها برای آموزش و تست شبکه عصبی استفاده شده است. تعداد مجموعه داده‌های ورودی ۸۱۹۲ است که ۱۵٪ آن به داده تست و ۸۵٪ برای آموزش در نظر گرفته شده است. منظور از ۸۱۹۲ تعداد کل مجموعه داده‌های^۴ لازم برای شبکه عصبی است. به این صورت که هر مجموعه داده شامل بردار داده‌های ورودی و خروجی است که در رابطه (۱) نشان داده شده است. با توجه به رابطه (۱) ورودی شامل سه سیگنال منطقی (A, B) و متمم آنها (A', B') است که در مجموع دارای ۵ بعد می‌شود. داده خروجی نیز مقدار منطقی دروازه XOR به ورودی مرتبط با خود و دارای یک بعد است.

$$P = [A, A', B, B', C] \quad (1)$$

$$T = [\text{XOR Output}]$$

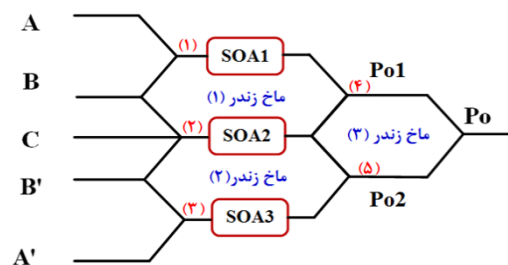
۳- ساختار شبکه‌های عصبی استفاده شده

انواع مختلفی از شبکه‌های عصبی مصنوعی وجود دارند که برای پیش‌بینی استفاده می‌شوند. از آن جمله می‌توان به شبکه‌های عصبی پیش‌بینی خطی (Lin) و شبکه‌های عصبی رگرسیون کلی (GRNN) اشاره کرد. هر یک از مدل‌های مذکور دارای مزایا و معایبی بوده و عملکردهای متفاوتی نیز در حل مسائل مختلف داشته‌اند، اما در حالت

کاهش زمان محاسبات و تحلیل خروجی دروازه منطقی مورد مطالعه شده است. شبکه عصبی GRNN نیاز به ۸ ثانیه و شبکه عصبی LIN نیاز به ۹۳ ثانیه در فاز آموزش داشته و پس از آموزش می‌توانند خروجی دروازه مورد نظر را در مدت زمانی کمتر از ۱ ثانیه پیش‌بینی نمایند. این زمان در مقایسه با زمان مورد نیاز برای محاسبه خروجی دروازه منطقی XOR که برابر با ۱۲ ثانیه می‌باشد کاهش چشمگیری داشته و مزیت بارز استفاده از شبکه عصبی و هوش مصنوعی را در مدل‌سازی این افزاره نشان می‌دهد. ساختار مقاله حاضر به این صورت می‌باشد: در فصل دوم به معرفی ساختار دروازه منطقی تمام نوری مورد نظر و نحوه استخراج داده‌های لازم برای مدل‌سازی آن توسط شبکه عصبی پرداخته شده است. فصل سوم به معرفی ساختار شبکه‌های عصبی طراحی شده می‌پردازد. نتایج مدل‌سازی و بحث‌های مربوطه در فصل چهارم ارائه شده است. فصل پنجم ضمن ارائه نتیجه‌گیری، مقاله را خاتمه می‌دهد.

۲- داده مورد نیاز شبکه عصبی

شکل (۱) ساختار داخلی دروازه منطقی XOR تمام نوری سه ورودی را نشان می‌دهد.



شکل ۱- شماتیک ساختار یک دروازه منطقی XOR تمام نوری سه ورودی

در شکل (۱) ساختار داخلی این دروازه رسم شده است. این ساختار شامل یک تداخل‌سنج سه بازویی ماخ-زندر^۱ است که در هر بازوی آن یک تقویت‌کننده نوری نیمه‌هادی (SOA)^۲ قرار گرفته است. اساس عملکرد این ساختار، پدیده مدولاسیون فاز متقابل (XPM)^۳ در هر SOA می‌باشد. سیگنال B بعنوان سیگنال پروب به دو بازوی ماخ‌زندر (۱) و سیگنال B' (متمم منطقی سیگنال B) بعنوان سیگنال پروب به دو بازوی ماخ-زندر (۲) اعمال می‌شود. سیگنال‌های A, C و A' (متمم منطقی سیگنال A)

³ Cross Phase Modulation

⁴ Dataset

¹ Mach-Zehnder

² Semiconductor Optical Amplifier

ساختار شامل یک لایه توابع شعاع پایه و یک لایه خطی ویژه می‌باشد. همانطور که در شکل (۲) نشان داده شده است ساختار شبکه GRNN چهار لایه دارد:

لایه ورودی: اولین لایه، لایه ورودی است که وابسته به پارامترهای ورودی شبکه عصبی است. به ازای هر متغیر ورودی یک نرون در لایه ورودی وجود دارد بنابراین تعداد نرون‌های ورودی وابسته به تعداد متغیرهای ورودی است. سپس نرون‌های ورودی مقادیر را به هر یک از نرون‌ها در لایه مخفی اول وارد می‌کنند.

لایه مخفی اول (لایه الگو): لایه دوم در ساختار شبکه عصبی به عنوان اولین لایه مخفی یا لایه الگو شناخته می‌شود. این لایه N نرون دارد و تعداد آنها وابسته به تعداد نمونه‌های ورودی است که برای هر نمونه در مجموعه داده آموزشی یک نرون دارد. نرون مقادیر پیش‌بینی کننده برای نمونه مربوط به مقدار هدف را ذخیره می‌کند. مقادیر ورودی از لایه ورودی با بردار X نشان داده می‌شود. سپس یک نرون مخفی فاصله اقلیدسی نمونه را از نقطه مرکزی نرون (Di) و سپس تابع کرنل RBF را با استفاده از مقادیر سیگما به کار می‌برد. بدین صورت که در هر نرون هر بردار ورودی از بردار وابسته به نرون X جزئی تقریق می‌شود و نتیجه آن به توان ۲ رسیده و به تابع کرنل غیرخطی که معمولاً تابع نمایی است اعمال می‌شود. مقدار بدست آمده به نرون‌های لایه مخفی دوم (جمع) فرستاده می‌شود.

لایه مخفی دوم (لایه جمع): برای شبکه‌های GRNN تنها دو نرون در لایه جمع وجود دارد. ورودی اولین نرون جمع مقادیر خروجی‌های وزن‌دار که از هر نرون لایه مخفی اول می‌آید است و ورودی دومین نرون جمع مقادیر وزن‌دار ضرب شده با مقدار هدف برای هر نرون لایه مخفی اول است که به ترتیب به عنوان واحد جمع مخرج (D) و دیگری واحد جمع صورت (N) می‌باشند.

لایه خروجی (تصمیم): لایه تصمیم، مقدار واحد جمع صورت کسر را بر مقدار جمع شده در واحد جمع مخرج تقسیم می‌کند و نتیجه را بعنوان تخمین یا پیش‌بینی مقدار خروجی به کار می‌برد. همانطور که در شکل (۲) نشان داده شده است ($Y=N/D$)

روش GRNN برخلاف روش‌های انتشار بازگشتی (BP)^۳ پارامترهای یادگیری مانند نرخ یادگیری ندارد اما یک

کلی برتری هیچ کدام بر دیگری ثابت نشده است. با توجه به ساختار دروازه منطقی XOR سه ورودی تمام نوری نشان داده شده در شکل (۱)، داده ورودی شبکه عصبی B، A، B'، A' و C است و خروجی پاسخ دروازه منطقی XOR است. بنابراین ساختار شبکه‌های عصبی باید دارای ۵ نرون ورودی و یک نرون خروجی باشد.

۳-۱- شبکه‌های عصبی رگرسیون کلی (GRNN)

شبکه عصبی رگرسیون کلی یکی از روش‌های شبکه عصبی رایج پیشرو^۱ تحت نظارت^۲ است. شبکه‌های عصبی GRNN جزء دسته روش‌های شبکه عصبی توابع شعاع پایه RBF است که اغلب برای تخمین توابع استفاده می‌شوند. یکی از قابلیت‌های مهم این روش پاسخ سریع در فاز آموزش حتی برای داده‌های پراکنده است. زیرا فقط یکبار در مسیر پیشرو انتشار می‌یابد درحالیکه اغلب روش‌های شبکه عصبی مشابه در مسیر پیشرو و پسرو باید انتشار یابند تا به خطای قابل پذیرش و مطلوب برسند [۲۴]. رگرسیون در روش GRNN برای تابع اسکالر Y شامل ماتریس بردار ورودی X تصادفی است و $f(x,y)$ تابع چگالی احتمال است.

$$E[Y/x] = \int_{-\infty}^{\infty} Y f(Y/x) dy = \frac{\int_{-\infty}^{\infty} Y f(x,Y) dy}{\int_{-\infty}^{\infty} f(x,Y) dy} \quad (۲)$$

اگر رابطه بین مقدار وابسته Y و غیر وابسته X تخمین غیر پارامتری $f(x,y)$ باشد یکی از روش‌های تخمین گوسین مانند رابطه (۳) قابل استفاده است.

$$\hat{f}(x,y) = \frac{1}{(2\pi)^{(p+1)/2\sigma^{p+1}}} \times \left\{ \frac{1}{n} \sum_{i=1}^n \exp \left[-\frac{(X-X_i)^T (X-X_i)}{2\sigma^2} \right] \times \exp \left[-\frac{(Y-Y_i)^2}{2\sigma^2} \right] \right\} \quad (۳)$$


در روابط ذکر شده n تعداد نمونه‌های آزمایش، Y_i خروجی مطلوب وابسته به مقدار ورودی X، σ پارامتر نرم‌کنندگی یا یکدست‌کنندگی هنگام یادگیری شبکه عصبی و p اندازه بردار ورودی است. ساختار شبکه عصبی GRNN که در شکل (۲) نشان داده شده است شبیه به شبکه‌های RBF بوده ولی دارای تفاوت‌هایی در لایه‌های میانی هستند. این

^۳ Back propagation

^۱ Feed-forward neural networks

^۲ Supervised

پیش‌بینی خطی، به حداقل رساندن اختلاف بین این دو روش پیش‌بینی خطی شبیه پرسپترون ۳ لایه است که تابع فعال‌سازی خروجی آن خطی است. در این روش درصد کمی از داده‌های ورودی به عنوان حالت تاخیر ورودی اولیه و بقیه داده‌ها به عنوان داده ورودی برای گام بعدی در نظر گرفته می‌شود [۲۶، ۲۵]. ساده‌ترین نوع پیش‌بینی خطی، در شکل (۳) نشان داده شده است. در این روش یک لایه خطی با یک نرون برای ساختار انتخاب می‌شود که با توجه به درصد کمی از مقادیر اولیه ورودی بقیه مقادیر پیش‌بینی می‌شوند. با تغییر تعداد داده‌های اولیه و با توجه به حداقل شدن خطای خروجی بهترین ساختار برای مدل‌سازی انتخاب می‌شود. در این شکل، b بایاس نام دارد و دارای مقدار ثابت است.



شکل ۳: نمایش اختصاری شبکه عصبی پیش‌بینی خطی

در این روش بردار X ، مجموعه ورودی‌ها است که می‌توان با بردار زیر (رابطه ۴) نشان داد.

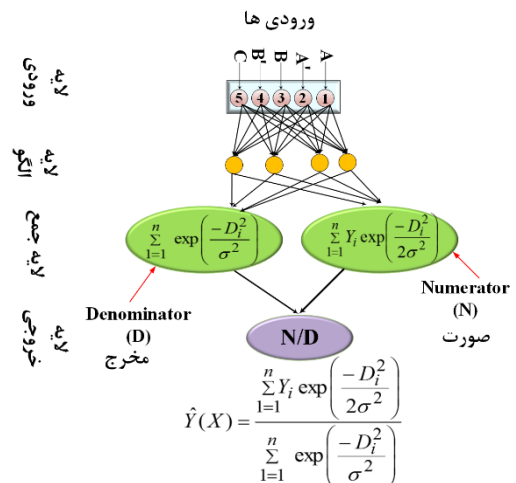
$$X(n) = \begin{bmatrix} x_1(n) \\ x_2(n) \\ \vdots \\ x_i(n) \\ \vdots \\ x_m(n) \end{bmatrix} \quad (4)$$

w وزن‌های ورودی شبکه عصبی است که با بردار $w(n)$ نمایش داده می‌شوند:

$$W(n) = \begin{bmatrix} w_1(n) \\ w_2(n) \\ \vdots \\ w_i(n) \\ \vdots \\ w_m(n) \end{bmatrix} \quad (5)$$

با توجه به شکل (۳) فرض می‌شود:

فاکتور بنام فاکتور نرم‌کنندگی (σ) دارد که بعد از فاز آموزش شبکه به آن اعمال می‌شود. انتخاب فاکتور نرم‌کنندگی یا کرنل بسیار مهم است. انتخاب مقدار کم باعث می‌شود نمونه‌های آموزش متمایز شوند و مقدار زیاد آن منجر به درجه درونیایی بزرگتر بین نمونه‌های آموزش می‌شود. یکی از روش‌های انتخاب مناسب σ بصورت سعی و خطا بر اساس مقایسه مقادیر خطا بین خروجی مدل‌سازی شده و مقدار هدف برای داده تست به ازای مقادیر متفاوت فاکتور نرم‌کنندگی به دست می‌آید. مقدار فاکتور نرم‌کنندگی معمولاً بین ۰ و ۱ انتخاب می‌شود. در این مقاله با توجه به مجموعه داده‌های آموزش، تعداد نرون‌های لایه ورودی و خروجی به ترتیب ۵ و ۱ عدد انتخاب شده است. طبق توضیحات بیان شده در لایه مخفی اول نیز تعداد نرون‌ها به اندازه نرون‌های ورودی ۵ عدد انتخاب می‌شود. لایه مخفی دوم شامل ۲ نرون برای محاسبه صورت (N) و مخرج (D) است که در لایه خروجی به تابع پیش‌بینی خروجی اعمال می‌شود.



شکل ۲: ساختار شبکه GRNN برای پیش‌بینی مقادیر خروجی دروازه منطقی XOR سه ورودی تمام نوری

به دست آوردن مقدار بهینه فاکتور نرم‌کنندگی به روش سعی و خطا و با هدف کاهش خطاهای مدل‌سازی خروجی در بخش ۴ توضیح داده می‌شود.

۳-۲- روش پیش‌بینی خطی

روش پیش‌بینی خطی یک رویکرد برای مدل‌سازی رابطه حاکم بر یک متغیر وابسته و یک یا چند متغیر مستقل ورودی است. هدف از انجام پیش‌بینی خطی شناسایی مدل خطی این رابطه است بطوریکه پیش‌بینی‌ها به مقادیر مطلوب داده‌ها نزدیک باشند و یکی از مهم‌ترین مسائل در

$$MAE = \frac{1}{N} \sum_{i=1}^N |T_i - Y_i| \quad (9)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (Y_i - T_i)^2}{\sum_{i=1}^N (T_i - \bar{T})^2} \quad (10)$$

در روابط فوق، T مقدار خروجی مطلوب، \bar{T} متوسط خروجی مطلوب، Y خروجی ناشی از آموزش شبکه عصبی و n تعداد داده‌های تست است. پارامتر MSE ، روشی برای برآورد میزان خطاست که در واقع تفاوت بین مقادیر واقعی و آنچه توسط شبکه عصبی تخمین زده شده است. MSE ، تقریباً همه جا مثبت است (منفی نیست) به این دلیل که تخمین‌گر اطلاعاتی که قابلیت تولید تخمین دقیق‌تری دارد را حساب نمی‌کند. پس این شاخص که مقداری همواره نامنفی دارد، هرچقدر مقدار آن به صفر نزدیکتر باشد، نشان دهنده میزان کمتر خطاست. RSE ، خطا نسبت به مقدار مطلوب است. به عبارتی خطا نسبت به آنچه باید پیش‌بینی می‌شده (مقدار مطلوب) است. بنابراین، خطای مربع نسبی خطای مربع کل را گرفته و با تقسیم بر خطای مربع کل و میانگین مقادیر واقعی آن را نرمالیزه می‌کند. MAE ، تفاوت مطلق بین مقادیر مطلوب و مقادیر مدل‌سازی شده است که در واقع مقایسه مقادیر پیش‌بینی شده با مقادیر مطلوب است. R^2 ، یکی از معیارهای مورد استفاده در تعیین همبستگی دو متغیر است. در واقع ضریب همبستگی ابزاری برای تعیین نوع و درجه رابطه بین داده‌های مدل‌سازی شده توسط شبکه عصبی و داده مطلوب است. ضریب همبستگی، شدت رابطه و همچنین نوع رابطه (مستقیم یا معکوس) را نشان می‌دهد. این ضریب بین -1 تا 1 است و در صورت عدم وجود رابطه بین دو متغیر، برابر صفر است. در این مقاله با توجه به نوع داده‌ها و رابطه‌ای که برای ضریب همبستگی استفاده شده مقدار ضریب همبستگی بین 0 و 1 به دست می‌آید. صفر بودن ضریب همبستگی به این معناست که مقدار مدل‌سازی شده و مقدار مطلوب مستقل از یکدیگر هستند. هر چقدر مقدار R^2 به 1 نزدیکتر باشد نشان‌دهنده همبستگی بیشتر مقادیر پیش‌بینی شده به مقدار مطلوب است و بیانگر مدل‌سازی بهتر شبکه عصبی است.

$$v(n) = \sum_{i=0}^m x_i(n)w_i(n)$$

کند. $y(n)$ از رابطه ۶ تبعیت می

$$y(n) = \phi(v(n)) = \begin{cases} 1 & v(n) \geq 0 \\ 0 & v(n) < 0 \end{cases} \quad (6)$$

Φ تابع فعال‌سازی نام دارد که در این روش خطی است. این روش برای داده‌هایی قابل اعمال است که با یک خط راست قابل تفکیک باشند. مقادیر وزن‌ها و بایاس طوری انتخاب می‌شوند که جمع مربع خطای مقادیر پیش‌بینی شده به حداقل یا مقدار خطای مشخص شده برسد. ساختار شبکه عصبی طراحی شده در روش پیش‌بینی خطی مطابق مجموعه داده آموزش دارای ۵ نرون ورودی شامل A, A', B, B' و C و دارای یک نرون در لایه میانی است. لایه خروجی دارای ۱ نرون است که شامل منطق دیجیتال خروجی XOR و تابع فعال‌سازی خطی است.

۴- نتایج مدل‌سازی

برای طراحی و ارزیابی شبکه عصبی رگرسیون کلی $GRNN$ ، داده‌های ورودی به دو بخش آموزش و تست تقسیم می‌شوند. در بخش آموزش، داده‌های آموزش به شبکه عصبی ارائه می‌شود و شبکه عصبی رابطه بین ورودی و خروجی‌های مطلوب را به دست می‌آورد. مابقی داده‌ها که توسط شبکه عصبی دیده نشده‌اند به عنوان داده تست در نظر گرفته می‌شود. برای ارزیابی شبکه عصبی طراحی شده، تعدادی از داده‌های ورودی که توسط شبکه دیده نشده (داده تست)، به شبکه عصبی داده می‌شود که با توجه به آنچه از داده‌های آموزش یاد گرفته است خروجی را پیش‌بینی کند. خطاهای متوسط مربع خطا (MSE)^۱، مربع نسبی خطا (RSE)^۲، متوسط خطای مطلق (MAE)^۳ و ضریب همبستگی (R^2) بین داده‌های مدل شده و داده مطلوب برای ارزیابی شبکه عصبی از روابط زیر محاسبه شده‌اند.

$$MSE = \frac{1}{N} \sum_{i=1}^N (Y_i - T_i)^2 \quad (7)$$

$$RSE = \frac{\sum_{i=1}^N (Y_i - T_i)^2}{\sum_{i=1}^N (\bar{T} - Y_i)^2} \quad (8)$$

³ Mean Absolute Error


¹ Mean Square Error

² Root Square Error

۴-۱- شبکه عصبی GRNN

در این مقاله، ۸۵٪ از داده‌های ورودی برای آموزش و ۱۵٪ آن برای تست در نظر گرفته شده است. خروجی مطلوب داده تست مربوط به دروازه منطقی XOR سه ورودی نوری به ازای منبع نور لیزر ورودی با توان ۵۰ میلی وات در شکل (۴-الف) نشان داده شده است. نتیجه مدل سازی دروازه منطقی XOR سه ورودی تمام نوری با روش شبکه عصبی رگرسیون کلی GRNN در شکل (۴-ب) نشان داده شده است. با توجه به مقایسه نتایج مدل سازی و داده مطلوب، شبکه عصبی GRNN به خوبی توانسته است نمودار خروجی دروازه منطقی XOR را پیش بینی کند. در شکل (۴-ج) تفاوت بین مقادیر خروجی مدل سازی شده و مقادیر مطلوب خروجی دوازه منطقی رسم شده است. با توجه نمودار رسم شده حدکثر مقدار خطا در مرتبه 10^{-4} است. در این روش تعداد نرون‌ها در لایه‌های ورودی، میانی اول، میانی دوم، و خروجی به ترتیب (۵، ۲، ۱) است. انتخاب فاکتور نرم‌کنندگی بسیار مهم است. یکی از روش‌های انتخاب مناسب σ ، روش سعی و خطا می‌باشد. در جدول (۱) مقادیر پارامترهای ارزیابی شبکه عصبی به ازای تغییرات مقادیر تفاوت فاکتور نرم‌کنندگی (σ) لیست شده است. فاکتور نرم‌کنندگی از مقدار ۰/۹ تا ۰/۰۰۰۸ کاهش

داده شده و به ازای هر کدام شبکه عصبی GRNN آموزش دیده است و سپس پارامترهای ارزیابی متفاوت مانند MAE, RSE, MSE و R^2 برای داده تست محاسبه شده است.



شکل ۴: مدل سازی گیت XOR سه ورودی تمام نوری با شبکه عصبی رگرسیون کلی GRNN به ازای منبع نور لیزر ورودی با توان ۵۰ میلی وات. الف) خروجی مطلوب به دست آمده از روش شبیه سازی، ب) داده مدل سازی شده به روش GRNN، ج) اختلاف بین مقادیر مدل سازی شده و داده هدف (خطا)

جدول ۱- خطاهای R^2 , MSE, RSE, MAE برای مدل سازی خروجی گیت XOR سه ورودی تمام نوری به ازای منبع لیزر ورودی با توان ۵۰ میلی وات با استفاده از شبکه عصبی GRNN به ازای تغییرات مقدار فاکتور نرم‌کنندگی

خطا	فاکتور نرم‌کنندگی (σ)									
	۰/۰۰۰۸	۰/۰۰۱	۰/۰۰۲	۰/۰۰۳	۰/۰۰۴	۰/۰۰۵	۰/۰۰۷	۰/۰۰۹	۰/۰۰۱	۰/۰۰۳
MSE	$1/34 \times 10^{-7}$	$1/97 \times 10^{-7}$	$8/5 \times 10^{-7}$	2×10^{-6}	$3/7 \times 10^{-6}$	$5/97 \times 10^{-6}$	$1/23 \times 10^{-5}$	$2/6 \times 10^{-5}$	$2/12 \times 10^{-5}$	$3/11 \times 10^{-4}$
RSE	$3/74 \times 10^{-6}$	$5/95 \times 10^{-6}$	$2/5 \times 10^{-5}$	$6/4 \times 10^{-5}$	$1/11 \times 10^{-4}$	$1/79 \times 10^{-4}$	$3/7 \times 10^{-4}$	$6/4 \times 10^{-4}$	$3/11 \times 10^{-4}$	$3/11 \times 10^{-4}$
MAE	$1/27 \times 10^{-4}$	$1/6 \times 10^{-4}$	$3/4 \times 10^{-4}$	$5/4 \times 10^{-4}$	$7/5 \times 10^{-4}$	$9/6 \times 10^{-4}$	$1/0 \times 10^{-3}$	$1/0 \times 10^{-3}$	$1/0 \times 10^{-3}$	$1/0 \times 10^{-3}$
R^2	۱	۱	۱	۰/۹۹۹۹	۰/۹۹۹۹	۰/۹۹۹۸	۰/۹۹۹۶	۰/۹۹۹۴	۰/۹۹۹۲	۰/۹۹۹۰


تعداد کل داده‌های در دسترس که شامل مجموع کل داده آموزش و تست بوده ۸۱۹۲ داده است. همانطور که در جدول ۲ مشخص است به ازای مقادیر بسیار کم اولیه شبکه عصبی دارای خطای بسیار زیادی است بنابراین مقادیر خروجی گیت منطقی را به درستی پیش‌بینی نمی‌کند. نمودار رسم شده در شکل (۶) به ازای ۲۰ داده اولیه نشان دهنده این است که منطق دیجیتال مقادیر خروجی دارای خطای زیادی است و دامنه خروجی مدل‌سازی شده بسیار کمتر از مقدار مطلوب واقعی است. بنابراین مقادیر اولیه ورودی تا جایی افزایش داده می‌شود که نمودار خروجی مدل‌سازی شده به خروجی مطلوب بسیار شبیه باشد و همچنین دارای خطای کمی باشد. چون پیش‌بینی مقدار دقیق منطقی خروجی دروازه XOR بسیار مهم است. با توجه به خطاهای محاسبه شده برای شبکه عصبی پیش‌بینی خطی لیست شده در جدول ۲ با افزایش مقادیر اولیه ورودی، نرخ کاهش خطا کم شده است و زمان آموزش شبکه عصبی افزایش می‌یابد. با توجه نتایج مدل‌سازی شبکه عصبی پیش‌بینی خطی به ازای ۲۰۰ داده ورودی تاخیر اولیه کمترین مقدار خطا دارد. در این حالت، پارامترهای ارزیابی MSE, RSE, MAE, R² و به ترتیب دارای مقادیر $۱۰^{-۲۲} \times ۱/۱۱$ ، $۱۰^{-۱۶} \times ۲/۱۴$ ، $۱۰^{-۱۱} \times ۲/۱۱$ و ۱ هستند.

جدول ۲- خطاهای MSE, RSE, MAE, R² برای مدل‌سازی خروجی گیت XOR به ازای منبع لیزر ورودی با توان ۵۰ میلی وات با استفاده از شبکه عصبی پیش‌بینی خطی به ازای مقادیر متفاوت تاخیر اولیه ورودی

ردیف	مقادیر اولیه ورودی (A _i)					
	۲۰	۴۰	۶۰	۸۰	۱۰۰	۱۲۰
Xi	۲۰	۴۰	۶۰	۸۰	۱۰۰	۱۲۰
MSE	$۷/۹ \times ۱۰^{-۶}$	$۷/۶ \times ۱۰^{-۶}$	$۷/۵ \times ۱۰^{-۶}$	۷×۱۰^{-۶}	$۷/۹ \times ۱۰^{-۶}$	$۷/۵ \times ۱۰^{-۶}$
RSE	$۱/۳۳$	$۰/۹۹۷۱$	$۰/۷۶۶۷$	$۰/۵۶۶۷$	$۰/۵۵۴$	$۰/۳۸۰$
MAE	$۸/۵ \times ۱۰^{-۴}$	$۹/۱ \times ۱۰^{-۴}$	$۷/۴ \times ۱۰^{-۴}$	$۶/۴ \times ۱۰^{-۴}$	$۶/۷ \times ۱۰^{-۴}$	$۴/۸ \times ۱۰^{-۴}$
R ²	$۴/۳۹$	$۴/۴۱$	$۵/۱۴۴$	$۰/۶۳۴۴$	$۰/۶۳۴۴$	$۷/۱-۸$
Time(s)	۴۹۸/۸۸	۶۷۷/۶	۶۶۷/۱۳	۶۵۳/۲۳	۶۵۱/۸۵	۵۹۸/۳۶

با توجه به مقادیر به دست آمده در مقادیر بیشتر از ۰/۰۰۱، نرخ کاهش خطا زیاد است اما به ازای ۰/۰۰۱، نرخ کاهش خطا بسیار کم شده و ضریب همبستگی به مقدار بیشینه می‌رسد. در این مقدار گستردگی، MSE دارای مقدار $۱۰^{-۷} \times ۱/۹۷$ و RSE دارای مقدار $۵/۹۵ \times ۱۰^{-۶}$ ، MAE مقدار $۱۰^{-۴} \times ۱/۶$ و R² برابر ۱ است. مطابق جدول ۱، کاهش بیش از حد فاکتور نرم‌کنندگی نرخ کاهش خطا را چندان تغییر نداده و منجر به پاسخ بهتر شبکه عصبی نخواهد شد. بنابراین در این مقاله مقدار ۰/۰۰۱ به عنوان مقدار بهینه فرض شده است.

نمودار میله‌ای خطای MSE برحسب مقادیر متفاوت فاکتور نرم‌کنندگی (σ) برای شبکه عصبی GRNN در شکل (۵) رسم شده است. با توجه به نمودار رسم شده، با کاهش مقدار فاکتور نرم‌کنندگی خطای MSE کاهش یافته است.




شکل ۵- نمودار میله‌ای MSE برحسب مقادیر متفاوت فاکتور نرم‌کنندگی (σ) برای محاسبه خروجی دروازه منطقی XOR سه ورودی تمام نوری با استفاده از شبکه عصبی GRNN

۴-۲- شبکه عصبی پیش‌بینی خطی

در روش شبکه عصبی پیش‌بینی خطی، تعدادی از داده‌های ورودی آموزش به عنوان حالت تاخیر اولیه ورودی استفاده شده و بقیه به عنوان ورودی آموزش به شبکه عصبی داده می‌شود. تعداد نرون‌ها در ۳ لایه این روش (۵ و ۱ و ۱) است. تعداد مقادیر اولیه درصد کمی از داده‌های ورودی انتخاب می‌شود که با استفاده از روش سعی و خطا به شبکه داده می‌شود. در این الگوریتم از دستور newlind در نرم افزار متلب برای آموزش شبکه عصبی پیش‌بینی خطی استفاده شده است. پارامترهای خطای محاسبه شده پس از آموزش شبکه عصبی، به ازای مقادیر متفاوت تاخیر اولیه در روش پیش‌بینی خطی در جدول ۲ لیست شده است.

مقایسه نمودار خروجی مطلوب دروازه منطقی XOR رسم شده در شکل (۸-الف) و نمودار خروجی مدل سازی رسم شده در شکل (۸-ب)، روش پیش‌بینی خطی با ۲۰۰ داده ورودی به خوبی خروجی را پیش‌بینی کرده است. با محاسبه تفاوت نقطه به نقطه خروجی مطلوب و خروجی مدل سازی شده (شکل (۸-ج))، خطا در مرتبه 10^{-10} بدست می‌آید. پارامتر ضریب همبستگی (R^2) برآوردی از نزدیک بودن داده‌های مدل سازی شده با مقادیر مطلوب است. همانطور که در مقادیر جدول خطاها برای هر دو روش شبکه عصبی مشخص است مقدار (R^2) یک به دست آمده است.




شکل ۸- مدل سازی گیت XOR، سه ورودی تمام نوری با روش شبکه عصبی پیش‌بینی خطی به ازای منبع نور لیزر ورودی توان ۵۰ میلی وات و تعداد ۲۰۰ داده تاخیر اولیه ورود. (الف) خروجی مطلوب به دست آمده از روش شبیه‌سازی، (ب) داده مدل سازی شده به روش پیش‌بینی خطی و (ج) اختلاف بین مقادیر مدل سازی شده و داده هدف (خطا)



در شکل‌های (۹-الف) و (۹-ب) مقادیر خروجی مدل سازی شده با استفاده از شبکه‌های عصبی GRNN و پیش‌بینی خطی برحسب خروجی مطلوب رسم شده است. همانطور که دیده می‌شود در هر دو روش یک خط با شیب یک به داده‌ها تطبیق داده شده است. تجمع داده‌ها بر روی خط با شیب یک برآورد همبستگی خطی و بسیار خوب دو روش شبکه عصبی در پیش‌بینی خروجی دروازه منطقی XOR سه ورودی تمام نوری است.

جدول ۳ مقدار خطا را برای توان‌های مختلف سیگنال‌های ورودی در بازه ۲۰ تا ۸۰ میلی وات در هر دو مدل شبکه عصبی نشان می‌دهد. با توجه به نتایج گزارش شده در این جدول، هر دو روش شبکه عصبی، به ازای توان‌های مختلف خروجی XOR را با مقدار خطای قابل قبول مدل سازی

در شکل (۷) نمودار خطای MSE و RSE برحسب مقادیر متفاوت داده تاخیر ورودی برای شبکه عصبی پیش‌بینی خطی رسم شده است. با توجه به منحنی رسم شده، با افزایش مقدار داده ورودی اولیه، خطای MSE و RSE کاهش می‌یابد و در مقادیر بیشتر از ۲۰۰ داده اولیه نرخ کاهش خطا تقریباً ثابت شده است. البته افزایش بیش از حد ورودی اولیه منجر به افزایش زمان آموزش شبکه عصبی خواهد شد و در پاسخ مدل سازی خروجی نیز بهبود چشمگیری حاصل نمی‌شود.



شکل ۶- مدل سازی گیت XOR، سه ورودی تمام نوری با روش شبکه عصبی پیش‌بینی خطی به ازای منبع نور لیزر ورودی توان ۵۰ میلی وات و تعداد ۲۰۰ داده اولیه ورودی. (الف) خروجی مطلوب شبکه عصبی به دست آمده از روش شبیه‌سازی، (ب) داده مدل سازی شده به روش پیش‌بینی خطی و (ج) اختلاف بین مقادیر مدل سازی شده و داده هدف (خطا)



شکل ۷- نمودار خطای (الف) MSE و (ب) RSE برحسب مقادیر متفاوت داده ورودی تاخیر اولیه برای پیش‌بینی خروجی دروازه منطقی XOR سه ورودی تمام نوری با استفاده از شبکه عصبی پیش‌بینی خطی

نمودار خروجی مدل سازی شده با روش پیش‌بینی خطی به ازای ۲۰۰ داده ورودی در شکل (۸) رسم شده است. با

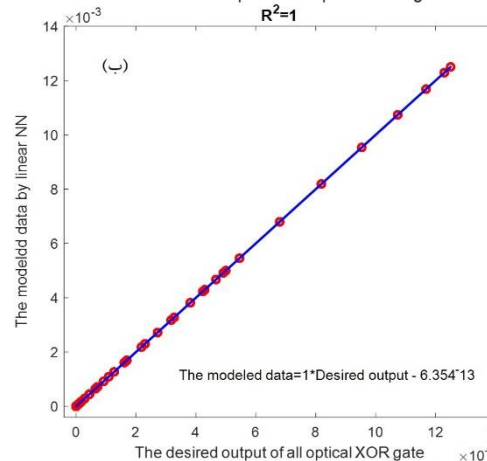
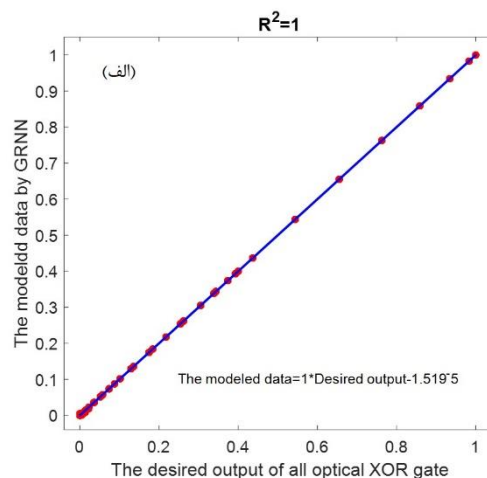
همچنین توان منبع نور لیزر ورودی نیز محدودیتی برای مدل سازی ایجاد نمی کند.

جدول ۳- خطای ناشی از مدل سازی خروجی گیت XOR سه ورودی تمام نوری با استفاده از شبکه های عصبی GRNN و پیش بینی خطی برای توان های مختلف منبع نور لیزر ورودی

توان ورودی (mW)	پیش بینی خطی				شبکه عصبی GRNN				
	MAE	MSE	RSE	R ²	time	MAE	MSE	RSE	R ²
	۲۰	۱/۰۸×۱۰ ^{-۱۱}	۳/۰۲×۱۰ ^{-۳۳}	۳/۵×۱۰ ^{-۱۶}	۱	۹۳/۶	۳/۰۶×۱۰ ^{-۳}	۶/۹×۱۰ ^{-۷}	۳/۰۹×۱۰ ^{-۵}
۴۰	۱/۶۳×۱۰ ^{-۱۱}	۶/۵۷×۱۰ ^{-۳۳}	۳/۵۵×۱۰ ^{-۱۶}	۱	۹۴/۶	۳/۳۹×۱۰ ^{-۳}	۷/۷۷×۱۰ ^{-۷}	۳/۳۹×۱۰ ^{-۵}	۱
۴۰	۱/۷۵×۱۰ ^{-۱۱}	۷/۳۹×۱۰ ^{-۳۳}	۳/۳۵×۱۰ ^{-۱۶}	۱	۹۵/۳۶	۳/۳۴×۱۰ ^{-۳}	۸/۱۶×۱۰ ^{-۷}	۳/۴۷×۱۰ ^{-۵}	۱
۵۰	۳/۱۱×۱۰ ^{-۱۱}	۱/۱۱×۱۰ ^{-۳۳}	۳/۱۴×۱۰ ^{-۱۶}	۱	۹۴/۰۶	۳/۰۶×۱۰ ^{-۳}	۸/۵۴×۱۰ ^{-۷}	۳/۵۵×۱۰ ^{-۵}	۱
۶۰	۱/۹۶×۱۰ ^{-۱۱}	۹/۹×۱۰ ^{-۳۳}	۱/۳۶×۱۰ ^{-۱۶}	۱	۹۳/۶۵۵	۳/۳۳×۱۰ ^{-۳}	۸/۱۱×۱۰ ^{-۷}	۳/۵×۱۰ ^{-۵}	۱
۷۰	۱/۹×۱۰ ^{-۱۱}	۹/۳×۱۰ ^{-۳۳}	۹/۵۴×۱۰ ^{-۱۷}	۱	۹۵/۳۷	۳/۲×۱۰ ^{-۳}	۷/۵۵×۱۰ ^{-۷}	۳/۴۴×۱۰ ^{-۵}	۱
۱۰	۱/۵۶×۱۰ ^{-۱۱}	۹/۳۱×۱۰ ^{-۳۳}	۷/۳۶×۱۰ ^{-۱۷}	۱	۹۴/۶	۳/۰۴×۱۰ ^{-۳}	۷/۲۳×۱۰ ^{-۷}	۳/۳۱×۱۰ ^{-۵}	۱

به عنوان جمع بندی در این بخش مقایسه بین این پژوهش با کارهای دیگران انجام شده است. با توجه به پیشرفت تکنولوژی و افزایش سرعت پردازش داده، توسعه مدارهای مجتمع نوری شامل ادوات نوری دیجیتال، موجبرهای نوری و گیت های منطقی دیجیتال مانند AND, OR, XOR و ... رو به رشد است. یکی از روش های معمول برای مدل سازی ساختارهای نوری استفاده از روش های عددی می (FDTD) باشد [۱۳-۲۰ و ۲۳] که معمولا برای به دست آوردن هر خروجی در یک ساختار بسیار زمانبر و طولانی می باشد. از آنجاییکه شبکه های عصبی قابلیت مدل سازی

کرده اند. البته خطای MSE ناشی از روش پیش بینی خطی با ۲۰۰ داده ورودی اولیه حدود ۱۰^{-۵} برابر کمتر از روش GRNN است.



شکل ۹- الف) (*) مقادیر خروجی مدل سازی گیت XOR سه ورودی تمام نوری بر حسب داده های مطلوب با روش شبکه عصبی GRNN، (-) تابع خط تطبیق داده شده به داده ها، ب) (*) مقادیر خروجی مدل سازی گیت XOR سه ورودی تمام نوری بر حسب داده های مطلوب با روش شبکه عصبی پیش بینی خطی، (-) تابع خط تطبیق داده شده به داده ها.

زمان آموزش شبکه عصبی برای هر دو روش نیز در جدول آمده است. با توجه به نتایج حاصل شده شبکه عصبی GRNN در مدت زمان متوسط ۸ ثانیه به طول می انجامد اما روش پیش بینی خطی در متوسط زمانی حدود ۹۳ ثانیه آموزش می بیند. بنابراین روش شبکه عصبی GRNN در مدت زمان کمتری آموزش می بیند. با توجه به نتایج حاصل شده با استفاده از الگوریتم های GRNN و پیش بینی خطی می توان خروجی دروازه منطقی XOR سه ورودی تمام نوری را سریعتر از روش عددی محاسبه و پیش بینی کرد.

همچنین اغلب روشهای استفاده شده در موجبرهای نوری از الگوریتم‌های پیچیده شبکه عصبی استفاده شده است. در این پژوهش دو روش خطی و گوسی برای مدل‌سازی استفاده شده که هر دو روشهای سریع و ساده‌ای هستند. با توجه به نتایج به دست آمده، هر دو روش با وجود تعداد داده کم (حدود ۲۰۰ داده) به خوبی خروجی را مدل‌سازی کردند. اما روش رگرسیون کلی (GRNN) عملکرد بهتر و سرعت بهتری در پیش‌بینی خروجی گیت منطقی دارد.

۵- نتیجه‌گیری

در این مقاله یک روش جدید، سریع و کارآمد مبتنی بر شبکه‌های عصبی برای پیش‌بینی مقدار دقیق خروجی دروازه منطقی XOR سه ورودی تمام نوری ارائه شد. از آنجاییکه خروجی دقیق منطقی دروازه XOR دارای اهمیت است ارائه یک روش مناسب در مقایسه با روش‌های عددی که نیاز به زمان محاسبات زیاد دارند بسیار مهم است. در این پژوهش از دو الگوریتم شبکه‌های عصبی رگرسیون کلی GRNN و روش پیش‌بینی خطی (Lin) استفاده شده است. نتایج شبیه‌سازی نشان داد که شبکه عصبی GRNN با مقدار فاکتور نرم‌کنندگی ۰/۰۰۱، و روش پیش‌بینی خطی با ۲۰۰ داده ورودی اولیه با کمترین مقدار خطا توانستند خروجی را مدل‌سازی کنند. اما مدت زمان آموزش شبکه عصبی در روش خطی با ساختار بهینه حدود ۹۳ ثانیه است که بسیار بیشتر از روش GRNN با مدت زمان آموزش ۸ ثانیه می‌باشد. هر دو شبکه می‌توانند پس از آموزش، خروجی را در کمتر از ۱ ثانیه پیش‌بینی کنند که بسیار سریعتر از روشهای سنتی با زمان ۱۲ ثانیه می‌باشد. همچنین در این پژوهش نشان داده شد که هر دو الگوریتم شبکه عصبی توانایی مدل‌سازی خروجی دروازه منطقی XOR سه ورودی تمام نوری به ازای توان‌های متفاوت منبع نور لیزر ورودی (بازه ۲۰ تا ۸۰ میلی وات) دارند.

داده‌های با تعداد زیاد در مدت زمان کم دارد از این روش اخیراً در شبیه‌سازی و مدل‌سازی ساختارهای نوری استفاده شده است. در روش شبکه عصبی یکبار که الگوریتم آموزش می‌بیند، پیش‌بینی داده‌های جدید بسیار سریعتر از روشهای کلاسیک نوری انجام می‌شود. در سال ۲۰۱۷ با استفاده از شبکه‌های عصبی ساختار یک دی‌مالتی پلکسر ۸ کاناله مدل‌سازی و بهینه‌سازی شد. در این مقاله بهینه ابعاد حفره‌های استفاده شده در بلور فوتونی با استفاده از شبکه عصبی به دست آمده است [۲۷]. در سال ۲۰۱۸ با استفاده از داده‌های آزمایشگاهی موجبرهای استریپ و گریتینگ از شبکه عصبی برای پیش‌بینی پروفایل توان نور خروجی مدار مجتمع نوری استفاده شد [۲۸]. تخمین پاشندگی نور در نانو ذرات فوتونویکی با استفاده از شبکه‌های عصبی مصنوعی در سال ۲۰۱۸ انجام شده است. در این پژوهش نشان داده شد که با تعداد داده کم نیز شبکه‌های عصبی با دقت بالا آموزش می‌بینند [۲۹]. مودهای خروجی موجبرهای دی‌الکتریک نوری با استفاده از شبکه عصبی در سال ۲۰۱۹ و ۲۰۲۱ مدل‌سازی، پیش‌بینی و آنالیز شده است [۳۰، ۳۱]. در کار دیگری در سال ۲۰۱۹ ویژگی‌های نوری ساختارهای پلاسمونیک با استفاده از روش ترکیبی شبکه‌های عصبی به کار برده شد [۳۲]. در پژوهش دیگری برای پیش‌بینی ضریب شکست موثر موجبرهای نوری کانالی از شبکه عصبی استفاده شده است [۳۳]. در سال ۲۰۲۱ نمایه میدان الکترومغناطیسی در موجبرهای نوری با استفاده از شبکه‌های عصبی پیش‌بینی شده است [۳۴]. در این سال بهینه ابعاد یک ساختار چند لایه با استفاده از طیف جذب خروجی ساختار به روش شبکه‌های عصبی مصنوعی به دست آمده است [۳۵]. با توجه به بررسی انجام شده در پژوهش‌های چاپ شده، مدل‌سازی گیت‌های منطقی نوری مانند OR انحصاری سه ورودی توسط شبکه‌های عصبی تاکنون انجام نشده است.

مراجع

- [1] E. Nasernia, M. Noori, and M. Rezaie, "Milling Tool Wear Prediction by Feed Motor Current Signal using MLPs and ANFIS," *Aerospace Mechanics Journal*, Vol. 15, No. 1, 2019, pp. 51-62.
- [۲] حمیدرضا میرشاهولد، رامین قاسمی اصل، ناهید رئوفی، مهرداد ملک زاده دیرین، "مدل سازی و پیش بینی نقطه اشتعال ترکیبات هیدرو کربنی با استفاده از شبکه عصبی". مدل سازی در مهندسی، دوره ۶۴، شماره ۱۹، اردیبهشت ۱۴۰۰، صفحه ۱۰۹-۱۱۶.
- [3] H. Dehdashti Jahromi and S. Hamed, "Artificial intelligence approach for calculating electronic and optical properties of nanocomposites," *Materials Research Bulletin*, Vol. 141, 2021, p. 111371.

- [۴] میثم عفتی، رحمت مدندوست، زینب فلاح زرگو بازکیایی، "ارزیابی عملکرد مدل های شبکه عصبی مصنوعی، نروفازی و رگرسیون چند متغیره در پیش بینی مقاومت فشاری بتن به کمک روش بارنقطه ای"، مدل سازی در مهندسی، دوره ۱۸، شماره ۶۲، آبان ۱۳۹۹، صفحه ۹۹-۱۱۳.
- [۵] فاضل فصیحی، محمودرضا کی منش، سیدعلی صحاف، سهیل قره، "تعیین ضریب بار هم‌ارز مبتنی بر الگوریتم شبکه عصبی مصنوعی"، مدل سازی در مهندسی، دوره ۱۹، شماره ۶۵، تیر ۱۴۰۰، صفحه ۱۴۹-۱۶۰.
- [6] A. Maroosi, E. Zabbah, and H. Ataei Khabbaz, "Network Intrusion Detection using a combination of artificial neural networks in a hierarchical manner," *Electronic and Cyber Defense*, Vol. 8, No. 1, 2020, pp. 89-99.
- [۷] احسان برنجکار، "ارزیابی عملکرد شبکه‌های عصبی مصنوعی تلفیق شده با الگوریتم های فراابتکاری وال و مورچگان در تخمین نرخ نفوذ حفاری و مقایسه با شبکه های عصبی ساده و مدل های ریاضی مرسوم"، مدل سازی در مهندسی، دوره ۱۹، شماره ۶۵، تیر ۱۴۰۰، صفحه ۱۱۵-۱۳۵.
- [8] M. Kaya and S. Hajimirza, "Application of artificial neural network for accelerated optimization of ultra-thin organic solar cells," *Solar Energy*, Vol. 165, 2018, pp. 159-166.
- [9] S. Arya and Y. Ho Chung, "Artificial neural network estimation of data and channel characteristics in free-space ultraviolet communications," *Applied Optics*, Vol. 59, No. 13, 2020, pp. 386-3818.
- [10] N. Farsad and A. Goldsmith, "Neural network detection of data sequences in communication systems," *IEEE Transactions on Signal Processing*, Vol. 66, No. 21, 2018, pp. 5663-5678.
- [11] A. M. Hammond and R. M. Camacho, "Designing integrated photonic devices using artificial neural networks," *Optics Express*, Vol. 27, No. 21, 2019, pp. 29620-29638.
- [12] E. Bor et al., "Integrated silicon photonic device design by attractor selection mechanism based on artificial neural networks: optical coupler and asymmetric light transmitter," *Optics Express*, Vol. 26, No. 22, 2018, pp. 29032-29044.
- [13] Y. Ji, H. Wang, J. Cui, M. Yu, Z. Yang, and L. Bai, "All-optical signal processing technologies in flexible optical networks," *Photonic Network Communications*, Vol. 38, No. 1, 2019, pp. 14-36.
- [14] A. Surendar, M. Asghari, and F. Mehdizadeh, "A novel proposal for all-optical 1-bit comparator using nonlinear PhCRRs," *Photonic Network Communications*, Vol. 38, No. 2, 2019, pp. 244-249.
- [15] S. Serajmohammadi, H. Alipour-Banaei, and F. Mehdizadeh, "A novel proposal for all optical 1-bit comparator using nonlinear PhCRRs," *Photonics and Nanostructures - Fundamentals and Applications*, Vol. 34, 2019, pp. 19-23.
- [16] A. Salimzadeh and H. Alipour-Banaei, "An all optical 8 to 3 encoder based on photonic crystal OR-gate ring resonators," *Optics communications*, Vol. 410, 2018, pp. 793-798.
- [17] Q. Liu, N. Li, and C. Tan, "All-optical logic gate based on manipulation of surface polaritons solitons via external gradient magnetic fields," *Physical Review A*, Vol. 101, No. 2, 2020, p. 023818.
- [18] K. Safari-Anzabi, A. Habibzadeh-Sharif, M. J. Connelly, and A. Rostami, "Performance enhancement of an all-optical XOR gate using quantum-dot based reflective semiconductor optical amplifiers in a folded Mach-Zehnder interferometer," *Optics & Laser Technology*, Vol. 135, 2021, p. 106628.
- [19] F. Parandin, "Realization of Ultra-compact All-optical Universal NOR Gate on Photonic Crystal Platform," *Journal of Electrical and Computer Engineering Innovations (JECEI)*, Vol. 9, No. 2, 2021, pp. 185-192.
- [20] D. G. S. Rao, S. Swarnakar, V. Palacharla, K. S. R. Raju, and S. Kumar, "Design of all-optical AND, OR, and XOR logic gates using photonic crystals for switching applications," *Photonic Network Communications*, Vol. 41, No. 1, 2021, pp. 109-118.
- [21] Y. Mao, B. Liu, R. Ullah, T. Sun, and L. Zhao, "All-optical XOR function accompanied with OOK/PSK format conversion with multicast functionality based on cascaded SOA configuration," *Optics Communications*, Vol. 466, 2020, p. 125421.
- [22] V. Agarwal, R. Anurag, H. S. Ganesh, and Y. S. Ramaiah, "An Ultrafast all optical Encryption Decryption Scheme based on XOR logic for secure transmission in Optical Networks," in *Journal of Physics: Conference Series*, Vol. 1804, No. 1, 2021, p. 012187.
- [23] H. D. Jahromi, A. Binaie, A. Zarifkar, and M. H. Shekhi, "a new structure for all-optical three-input XOR logic gate based on semiconductor optical amplifier mach-zehnder interferometer," *International Journal of Modern Physics B*, Vol. 28, No. 07, 2014, p. 1450052.

- [24] M. del Rosario Martinez-Blanco et al., Generalized regression neural networks with application in neutron spectrometry. InTech Croatia, 2016.
- [25] M. Hariharan, L. S. Chee, and S. Yaacob, "Analysis of infant cry through weighted linear prediction cepstral coefficients and probabilistic neural network," Journal of medical systems, Vol. 36, No. 3, 2012, pp. 1309-1315.
- [26] P. F. Baldi and K. Hornik, "Learning in linear neural networks: A survey," IEEE Transactions on neural networks, Vol. 6, No. 4, 1995, pp. 837-858.
- [27] V. R. Balaji, M. Murugan, S. Robinson, R. J. O. Nakkeeran, and Q. Electronics, "Design and optimization of photonic crystal based eight channel dense wavelength division multiplexing demultiplexer using conjugate radiant neural network," Vol. 49, No. 5, 2017, pp. 1-15.
- [28] D. Liu, Y. Tan, E. Khoram, and Z. J. A. P. Yu, "Training deep neural networks for the inverse design of nanophotonic structures," Vol. 5, No. 4, 2018, pp. 1365-1369.
- [29] J. Peurifoy et al., "Nanophotonic particle simulation and inverse design using artificial neural networks," Vol. 4, No. 6, 2018, p. eaar4206.
- [30] G. Alagappan and C. E. J. J. o. M. O. Png, "Modal classification in optical waveguides using deep learning," Vol. 66, No. 5, 2019, pp. 557-56.
- [31] N. J. Anika and M. B. J. O. Mia, "Design and analysis of guided modes in photonic waveguides using optical neural network," Vol. 228, 2021, p. 165785.
- [32] I. Sajedian, J. Kim, J. J. M. Rho, and nanoengineering, "Finding the optical properties of plasmonic structures by image processing using a combination of convolutional neural networks and recurrent neural networks," Vol. 5, No. 1, 2019, pp. 1-8.
- [33] G. Alagappan and C. E. J. J. B. Png, "Universal deep learning representation of effective refractive index for photonics channel waveguides," Vol. 36, No. 10, 2019, pp. 2636-2642.
- [34] G. Alagappan, C. E. J. N. C. Png, and Applications, "Prediction of electromagnetic field patterns of optical waveguide using neural network," Vol. 33, No. 7, 2021, pp. 2195-2206.
- [35] M. Chen, D. Pang, X. Chen, H. Yan, and P. J. P. Zhou, "Optimized Design of Multi-layer Nano-photonic Structures for Selective Absorption Applications by Artificial Neural Networks," Vol. 16, No. 3, 2021, pp. 653-659.