



استفاده از شبکه عصبی عمیق برای تحلیل خرابای دو بعدی

سبحان براتی^(۱) جواد علامتیان^{(۲)*}

(۱) گروه مهندسی عمران، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

(۲) گروه مهندسی عمران، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران*

تاریخ دریافت: ۱۴۰۳/۰۶/۲۲ تاریخ پذیرش: ۱۴۰۳/۱۰/۱۲

چکیده

برای سازه‌ها با درجه‌های آزادی زیاد، نرم‌افزارهای سنتی اجزا محدود، که مبتنی بر تقسیم‌بندی دامنه مسئله به جزءهای کوچک‌تر هستند، به دلیل صرف زمان زیاد، کارایی کمتری دارند. به همین دلیل، مهندسين به استفاده از الگوریتم‌های هوش مصنوعی مبتنی بر طبیعت روی آورده‌اند که توانایی یادگیری الگوهای پیچیده از داده‌ها را دارند. یکی از این روش‌ها، استفاده از شبکه‌های عصبی عمیق است. این شبکه‌ها با داشتن ساختار لایه‌ای و قابلیت یادگیری از داده‌های ورودی، می‌توانند رفتار سیستم‌ها را مدل‌سازی کنند. ابتدا شبکه عصبی عمیق با استفاده از داده‌های تجربی آموزش داده می‌شود و پس از آن به پیش‌بینی داده‌های جدید می‌پردازد. با این حال، چالش‌هایی همچون نیاز به داده‌های آموزشی گسترده و مناسب، تضمین دقت مدل و تفسیرپذیری نتایج همچنان وجود دارند. برای غلبه بر این چالش‌ها، باید تحقیقات بیشتری در زمینه بهینه‌سازی ساختار شبکه‌ها، تکنیک‌های پیش‌پردازش داده‌ها و توسعه روش‌های ترکیبی در هوش مصنوعی صورت گیرد. در این مقاله، از شبکه عصبی عمیق برای تخمین تغییر مکان‌های یک خرابای دو عضوی بر اساس داده‌های گذشته استفاده می‌شود، تا بتوان این شبکه را جایگزین روابط طولانی اجزا محدودی کرد. نتایج حاصل از این مقاله، نشان دهنده تاثیر بسیار زیاد معماری شبکه و تعداد نمونه‌ها در مورد این مسئله هست.

کلمات کلیدی: هوش مصنوعی، خرابای دو بعدی، شبکه عصبی عمیق

*عهده‌دار مکاتبات:

جواد علامتیان

نشانی: گروه مهندسی عمران، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

پست الکترونیکی: alamatian@yahoo.com

شبکه‌های عصبی عمیق و روش اجزاء محدود دو رویکرد قدرتمند در حوزه تحلیل‌های عددی و مدل‌سازی مسائل پیچیده مهندسی هستند. شبکه عصبی عمیق یکی از روش‌های مبتنی بر طبیعت به عنوان یکی از زیرمجموعه‌های یادگیری ماشین، به طور گسترده در مهندسی عمران به کار گرفته می‌شود. این تکنیک‌ها توانایی پردازش و تحلیل داده‌های پیچیده و بزرگ را دارند و می‌توانند در بهبود کارایی، دقت و هوشمندی سیستم‌های مهندسی عمران نقش بسزایی ایفا کنند. روش اجزاء محدود که به طور گسترده در تحلیل سازه‌ها، دینامیک سیالات و دیگر زمینه‌های مهندسی استفاده می‌شود، مبتنی بر تقسیم‌بندی دامنه مسئله به اجزاء کوچک‌تر و حل معادلات دیفرانسیل جزئی در هر جزء است. این روش اگرچه دقت بالایی دارد، اما محاسبات پیچیده و زمان‌بر است. در مقابل، شبکه‌های عصبی عمیق به عنوان یک رویکرد مبتنی بر یادگیری ماشین، با توانایی یادگیری الگوهای پیچیده از داده‌ها، به عنوان یک جایگزین کارآمد و سریع برای روش‌های سنتی نظیر اجزاء محدود مطرح شده‌اند. با آموزش یک شبکه عصبی عمیق بر اساس داده‌های حاصل از شبیه‌سازی‌های اجزاء محدود یا داده‌های تجربی، می‌توان به مدل‌هایی دست یافت که قادر به پیش‌بینی رفتار سیستم‌های پیچیده با دقت بالا و در زمان کوتاه‌تر، بدون استفاده دوباره از روابط طولانی اجزاء محدود هستند. این جایگزینی نه تنها می‌تواند زمان محاسبات را کاهش دهد، بلکه امکان تحلیل مسائل بزرگ‌تر و پیچیده‌تر را نیز فراهم می‌آورد. با این حال، چالش‌هایی همچون نیاز به داده‌های آموزشی گسترده و مناسب، تضمین دقت مدل و تفسیرپذیری نتایج همچنان وجود دارند که نیازمند تحقیقات و توسعه‌های بیشتر در این زمینه هستند. کاربردهای مختلف شبکه‌های عصبی عمیق در مهندسی عمران شامل تحلیل سازه‌ها، پیش‌بینی رفتار سازه‌ای، بهینه‌سازی طراحی‌ها، و تشخیص خرابی‌ها است. مطالعات متعددی به بررسی این کاربردها پرداخته‌اند. برای مثال، پژوهشگران در مقاله‌ای مدل اجزاء محدود را با استفاده از یک الگوریتم هیبریدی بروزرسانی کرده‌اند تا پاسخ عددی را با رفتار تجربی مشاهده شده در سازه هماهنگ کنند [1]. در مطالعه‌ای، محققان از الگوریتم کلونی زنبورها برای بهینه‌سازی شکل و اندازه خرپا بهره برده‌اند [2]. همچنین، با استفاده از روش برآورد در لحظه تابع چگالی احتمال و روش واگرایی باقیمانده کولبک-لیبلر، عیب‌های موجود در یک سازه خرپای تطبیقی با طراحی مدولار و بهره‌گیری از مدل‌های محلی و داده‌های حسگرها و محرک‌های هیدرولیکی شناسایی شده‌اند. در این مقاله، عیوب در حسگرها و محرک‌ها تشخیص داده می‌شود، اما به دلیل محدودیت دسترسی مدل‌های محلی به اطلاعات بین اتصالات ماژول‌ها، ممکن است عیوب در ماژول‌های دیگر باقی‌مانده‌های محلی را تحت تأثیر قرار دهند که این مشکل نیز با روش مذکور مرتفع شده است [3]. در کار دیگری، محققان با استفاده از الگوریتم تکامل مشترک، به بهینه‌سازی شکل و اندازه

خرپای فضایی پرداخته‌اند [4]. همچنین، نتایج حاصل از هشت الگوریتم مختلف از جمله الگوریتم کرکس‌های آفریقایی و الگوریتم ساختار کریستالی برای بهینه‌سازی خرپا مقایسه شده است [5]. علاوه بر این، الگوریتم خفاش اصلاح شده برای بهینه‌سازی وزن خرپا مورد استفاده قرار گرفته است [6]. در حوزه استفاده از هوش مصنوعی، در پژوهشی از این فناوری برای ارزیابی مقاومت یک سازه چوبی در برابر آتش استفاده شده است [7]. همچنین، با بهره‌گیری از شبکه عصبی مصنوعی، مدلی برای پیش‌بینی مقاومت کماتش جانبی-پیش‌بینی تیرهای فولادی با بازشو دایره‌ای توسعه داده شده است [8]. در مطالعه دیگری، از شبکه عصبی مصنوعی برای پیش‌بینی خیز حداکثر تیر فولادی با بازشوه‌های شش‌ضلعی تحت بار ضربه‌ای استفاده شده است [9]. همچنین، محققان با استفاده از شبکه عصبی مصنوعی، رفتار خمشی یک تیر فولادی تقویت‌شده با ورق FRP را پیش‌بینی کرده‌اند [10].

هدف این مقاله، بررسی و تحلیل خرپاهای دوبعدی با بهره‌گیری از شبکه‌های عصبی عمیق است. این مطالعه تلاش دارد تا با بهبود دقت و سرعت تحلیل خرپاها، کارایی و قابلیت اطمینان فرآیندهای مهندسی سازه را افزایش دهد. در این راستا، شبکه‌های عصبی عمیق به دلیل توانایی بالا در یادگیری الگوهای پیچیده و مدل‌سازی رفتارهای غیرخطی سیستم‌ها، به عنوان یک ابزار موثر مورد استفاده قرار می‌گیرند. این مقاله به دنبال ارائه یک روش نوین و کارآمد برای تحلیل خرپاهای دوبعدی است که نتایج حاصله از آن می‌تواند در طراحی و ارزیابی سازه‌های عمرانی کاربرد گسترده‌ای داشته باشد.

از جمله محدودیت‌هایی که در مقاله‌های ذکر شده می‌توان به آن اشاره کرد، ترکیب دو روش اجزا محدود و معادلات آن با چنین روش‌های بهینه‌سازی است اما در رابطه با نوآوری این مقاله می‌توان اشاره کرد که معادلات اجزا محدود پس از ساخت نمونه‌های آموزش دیگر استفاده نمی‌شوند و عملاً یک شبکه عصبی جایگزین این معادلات می‌شود و همین امر باعث می‌شود تا در مسائلی مانند حداقل کردن تابع جرم یک خرپا که نیاز است حالات بسیار زیادی از یک خرپا بررسی شود در زمان کمتری جواب مسئله حاصل شود.

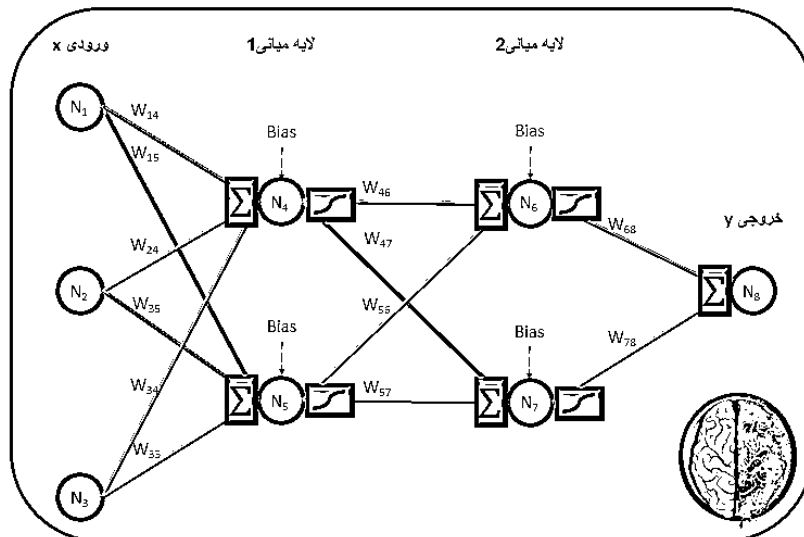
۲- مبانی شبکه عصبی عمیق

یادگیری عمیق یک شاخه مهم از فناوری اطلاعات بوده که روی ساخت سیستم‌های هوشمند تمرکز دارد. ارتباط تنگاتنگی با یادگیری ماشین و هوش مصنوعی دارد تا در نهایت مبتنی بر شبکه‌های عصبی مصنوعی، یادگیری ماشین را جلو ببرد. یادگیری ماشینی تمرین استفاده از الگوریتم‌ها برای یادگیری از داده‌ها و پیش‌بینی است. سه دسته اصلی یادگیری ماشین به شرح زیر وجود دارد:

- تحت نظارت
- بدون نظارت
- تقویتی

یادگیری نظارت شده برای زمانی که خروجی صحیح مشخص شده و مدل با داده‌های برچسب‌دار، آموزش داده می‌شود. در این دسته، مدل یاد می‌گیرد تا ورودی‌ها را بر اساس داده‌های برچسب‌گذاری شده نگاشت و به خروجی‌ها تبدیل کند. یادگیری بدون نظارت برای زمانی است که مدل با داده‌های بدون برچسب آموزش داده می‌شود تا خودش الگوها و ساختارها را در داده‌ها پیدا کند. یادگیری تقویتی نیز برای شرایطی است که مدل یاد می‌گیرد بر اساس بازخورد از محیط، تصمیم بگیرد. مدل‌های یادگیری عمیق می‌توانند به‌طور خودکار ویژگی‌ها را از داده‌ها استخراج کنند. مدل‌های یادگیری عمیق به ویژه برای کارهایی مانند تشخیص تصویر و گفتار کارآمد و موثر خواهند بود [11]. شبکه‌های عصبی مصنوعی با الهام از ساختار و عملکرد مغز انسان طراحی شده‌اند. این شبکه‌ها از واحدهای پردازشی ساده‌ای به نام نورون یا گره تشکیل شده‌اند که به صورت لایه‌هایی سازمان‌دهی می‌شوند. به‌طور کلی، یک شبکه عصبی شامل سه نوع لایه اصلی است: لایه ورودی که داده‌های خام ورودی را دریافت کرده و آنها را به نورون‌های لایه‌های بعدی منتقل می‌کند. هر نورون در این لایه نمایانگر یک ویژگی یا بعد از داده‌های ورودی است. همچنین، هر نورون لایه ورودی می‌تواند از چند ویژگی تشکیل شده باشد که هر ویژگی دارای پارامترهای مخصوص خود باشد. لایه‌های میانی یا پنهان وظیفه پردازش داده‌ها و استخراج ویژگی‌های پیچیده‌تر را برعهده دارند. تعداد و اندازه این لایه‌ها تعیین‌کننده عمق و پیچیدگی شبکه عصبی است. هنگامی که یک شبکه عصبی دارای تعدادی لایه پنهان باشد، به آن شبکه عصبی عمیق می‌گویند. در نهایت، لایه خروجی نتایج نهایی پردازش را ارائه می‌دهد و تعداد نورون‌های این لایه بستگی به نوع مسئله و تعداد کلاس‌ها یا خروجی‌های ممکن دارد. نحوه عملکرد شبکه‌های عصبی به این صورت است که در هر نورون، ورودی‌ها با وزن‌های مشخصی ضرب می‌شوند که این وزن‌ها نشان‌دهنده اهمیت هر ورودی در فرآیند تصمیم‌گیری نورون هستند. سپس مجموع این ورودی‌های وزن‌دار شده و یک مقدار بایاس که به عنوان یک عدد ثابت شناخته می‌شود، محاسبه می‌شود. نتیجه این محاسبات از یک تابع فعال‌سازی عبور می‌کند که تصمیم می‌گیرد آیا نورون فعال یا غیر فعال شود. تابع فعال‌سازی نقش کلیدی در اعمال غیرخطی بودن به شبکه ایفا می‌کند، که این غیرخطی بودن برای یادگیری الگوهای پیچیده ضروری است. آموزش شبکه عصبی فرآیندی است که طی آن وزن‌ها و بایاس‌ها با استفاده از مجموعه‌ای از داده‌های آموزشی بهینه می‌شوند. این فرآیند معمولاً شامل مراحل انتشار پیشرو، محاسبه خطا، و انتشار معکوس است. در انتشار پیشرو، داده‌های ورودی از طریق شبکه عبور می‌کنند تا خروجی نهایی تولید شود. سپس اختلاف بین خروجی پیش‌بینی شده و خروجی واقعی (داده‌های هدف) محاسبه می‌شود. این اختلاف با استفاده از تابع

هزینه به یک عدد تبدیل می‌شود. در نهایت، انتشار معکوس شامل محاسبه گرادیان‌های تابع هزینه نسبت به وزن‌ها و بایاس‌ها است. سپس این گرادیان‌ها برای به‌روزرسانی وزن‌ها و بایاس‌ها استفاده می‌شوند به طوری که خطا کاهش یابد. این به‌روزرسانی معمولاً با استفاده از الگوریتم بهینه‌سازی مانند ¹Adam انجام می‌شود. شبکه‌های عصبی عمیق به دلیل توانایی بالای خود در مدل‌سازی الگوهای پیچیده و غیرخطی، در حوزه‌های مختلفی از جمله تشخیص تصویر، پردازش زبان طبیعی، پیش‌بینی سری‌های زمانی، و بسیاری دیگر کاربرد دارند. این شبکه‌ها به دلیل قدرت یادگیری و تطبیق‌پذیری بالا، ابزار بسیار مهمی در زمینه هوش مصنوعی و یادگیری ماشین به شمار می‌آیند [11]. فرایند بالا در شکل ۱ خلاصه گردیده است.



شکل ۱: فرایند یک مدل شبکه عصبی عمیق

عملاً فرمولی که برای بدست آوردن هر نورون استفاده می‌شود در رابطه زیر بیان می‌شود.

$$N = \sum_{i=1}^n N_i w_i + Bias \quad n = \text{تعداد نورون لایه قبل} \quad (1)$$

که در آن N نورون، N_i نورون i ام لایه‌ی قبل، w_i وزن نورون i ام وارد شده به نورون N ، و بایاس یک مقدار ورودی برای نورون N هست.


¹ Adaptive Moment Estimation

۳- مراحل طراحی شبکه

برای ایجاد و آموزش یک شبکه عصبی، چندین مرحله کلیدی باید طی شوند. ابتدا باید معماری شبکه، شامل تعداد لایه‌های پنهان و تعداد نورون‌ها در هر لایه، مشخص شود. این پارامترها تعیین‌کننده قدرت محاسباتی شبکه و توانایی آن در یادگیری الگوهای پیچیده هستند و باید به صورت تجربی و بر اساس ویژگی‌های مسئله و داده‌های موجود تنظیم شوند.

سپس تعداد نورون‌های لایه ورودی تعیین می‌شود که برابر با تعداد ویژگی‌های داده‌های ورودی است. این ویژگی‌ها همان خصوصیات یا متغیرهایی هستند که به عنوان ورودی به شبکه داده می‌شوند.

در مرحله بعد، انتخاب تابع فعال‌ساز مناسب برای نورون‌ها ضروری است. برای این منظور، تابع 1 ReLU، معمولاً به عنوان تابع فعال‌ساز انتخاب می‌شود. این تابع به شبکه اجازه می‌دهد تا غیرخطی بودن را یاد بگیرد. اگر از توابع فعال‌ساز استفاده نکنیم، وزن‌ها و مقدار بایاس فقط یک معادله‌ی خطی را ایجاد می‌کنند. درست است که معادله‌ی خطی خیلی راحت تر حل‌شدنی است، اما برای حل مسائل پیچیده نمی‌تواند کمکی به ما کند. در واقع معادلات خطی در یادگیری الگوهای پیچیده‌ی داده‌ی خیلی محدود هستند. تابع فعال‌ساز ReLU در زمینه‌ی یادگیری عمیق بسیار مشهور است و در بیشتر مواقع استفاده می‌شود. این تابع همان‌طور که در شکل ۲ نمایان است، به این صورت عمل می‌کند که مقدارهای منفی را صفر و مقدارهای مثبت و مقدارهای برابر با صفر را همان مقدار خودش در نظر می‌گیرد. به‌طور کلی، شبکه‌های عصبی از توابع فعال‌ساز استفاده می‌کنند تا بتوانند به شبکه در یادگیری داده‌های پیچیده کمک و پیش‌بینی قابل‌قبولی را در خروجی ارائه کنند [11].

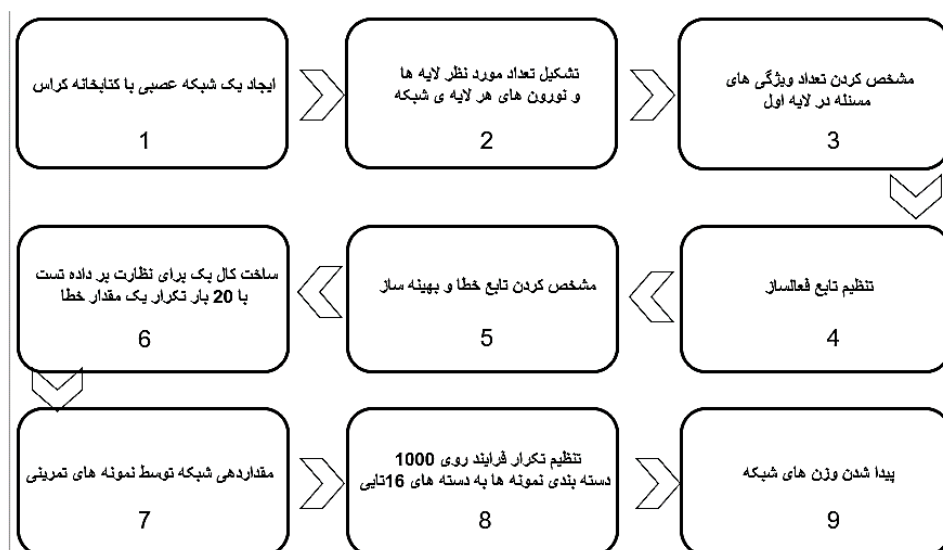


شکل ۲: تابع فعال‌ساز ReLU [1]

¹ Rectified Linear Unit

سپس تابع خطا تعریف می‌شود که معیاری برای اندازه‌گیری عملکرد شبکه است. این تابع بر اساس تفاوت بین خروجی پیش‌بینی شده توسط شبکه و خروجی واقعی داده‌ها محاسبه می‌شود و هدف فرآیند آموزش، کمینه کردن مقدار این خطا است. برای بروزرسانی وزن‌های شبکه و کاهش مقدار تابع خطا، بهینه‌سازها به کار می‌روند. بهینه‌سازها با محاسبه نرخ تغییر تابع خطا و به‌روزرسانی وزن‌ها، براساس یک الگوی خاص تابع خطا را به سمت صفر میل می‌دهند. همچنین در این فرآیند، **call back** نیز مورد استفاده قرار می‌گیرند. این ابزارها برای کنترل فرآیند آموزش استفاده می‌شوند؛ برای مثال، **Early Stopping** اگر بهبود قابل توجهی در تابع خطا پس از تعداد مشخصی تکرار مشاهده نشود، فرآیند آموزش را متوقف می‌کند که این کار به صرفه‌جویی در زمان کمک می‌کند.

شبکه سپس با داده‌های تمرینی آموزش داده می‌شود که این شامل تنظیم وزن‌ها بر اساس ورودی‌ها و خروجی‌های داده شده و به‌روزرسانی آنها با استفاده از بهینه‌ساز است. در نهایت، پارامترهای آموزش نظیر تعداد تکرارها و اندازه بسته‌های داده تنظیم می‌شوند. تعداد تکرارها به تعداد دفعاتی اشاره دارد که کل مجموعه داده‌های تمرینی از شبکه عبور می‌کند و بسته‌های داده به تقسیم داده‌ها به قسمت‌های کوچکتر برای بهبود مدیریت حافظه و افزایش کارایی محاسبات اشاره دارد. در این مقاله، ۱۰۰۰ تکرار با بسته‌های ۱۶ تایی استفاده شده است. با دنبال کردن این مراحل و تنظیم دقیق پارامترها، می‌توان یک شبکه عصبی کارا و دقیق ایجاد کرد که قادر به یادگیری الگوها و پیش‌بینی‌های مناسب باشد. تمامی این مراحل را می‌توان در شکل ۳ مشاهده نمود [11].



شکل ۳. مراحل ایجاد یک شبکه

مشکلات کم‌برازش^۱ و بیش‌برازش^۲ نیز در طراحی شبکه‌های عصبی باید مورد توجه قرار گیرند. کم‌برازش زمانی رخ می‌دهد که شبکه به اندازه کافی پیچیده نیست و نمی‌تواند الگوهای داده‌ها را به خوبی یاد بگیرد. برای جلوگیری از این مشکل، می‌توان تعداد لایه‌ها و نورون‌ها را افزایش داد یا از توابع فعال‌ساز پیچیده‌تری استفاده کرد. از طرف دیگر، بیش‌برازش زمانی رخ می‌دهد که شبکه داده‌ها را بیش از حد به خاطر می‌سپارد. برای جلوگیری از بیش‌برازش، تکنیک‌های مانند Dropout و منظم‌سازی L2 به کار می‌روند. در روش Dropout، به صورت تصادفی برخی از نورون‌ها در طول فرآیند آموزش غیرفعال می‌شوند تا از وابستگی شبکه به یک تعداد محدود از نورون‌ها جلوگیری شود. در منظم‌سازی L2، یک جریمه به مجموع مربعات وزن‌ها اضافه می‌شود تا از رشد بیش از حد وزن‌ها و پیچیدگی شبکه جلوگیری شود. در نهایت، با ترکیب مراحل طراحی معماری شبکه، پیش‌پردازش داده‌ها و استفاده از روش‌های منظم‌سازی، می‌توان یک شبکه عصبی کارآمد ایجاد کرد که قادر به یادگیری الگوهای پیچیده و ارائه پیش‌بینی‌های دقیق باشد. این مراحل به شبکه کمک می‌کنند تا داده‌های ورودی را به صورت بهینه پردازش کرده و نتایج قابل قبولی تولید کند [11].


۴- استفاده از شبکه عصبی عمیق در تحلیل خرابی دو بعدی

سازه خرابی نوعی ساختار مهندسی است که از ترکیب اعضای مثلثی شکل تشکیل می‌شود. این سازه‌ها معمولاً از اعضای راست ساخته شده‌اند که در محل‌های اتصال به یکدیگر به صورت مفصل متصل می‌شوند. ویژگی اصلی سازه‌های خرابی این است که بارها به صورت محوری (فقط کششی یا فشاری) به اعضای خرپا وارد می‌شوند. این موضوع باعث می‌شود که اعضا تنها تحت نیروهای محوری قرار بگیرند و نیروی برشی و خمشی در آنها ایجاد نشود. از آنجایی که نیروها به صورت محوری به اعضای خرپا وارد می‌شوند، تمامی مقطع هر عضو درگیر نیرو می‌شود و به حالت تسلیم می‌رسد، به این معنی که تمامی ظرفیت عضو برای تحمل بار به طور کامل به کار گرفته می‌شود. به همین دلیل، سازه‌های خرابی از مصالح به صورت بهینه استفاده می‌کنند، زیرا هیچ بخشی از مصالح به صورت غیرفعال باقی نمی‌ماند. سازه‌های خرابی غالباً در ساخت پل با دهانه‌های بزرگ، ساخت سقف‌های سبک و بزرگ مانند سقف‌های سالن‌های ورزشی، انبارها و دکل‌های مخابراتی به دلیل سبکی و استحکام بالا استفاده می‌شود. هدف از این مقاله، به کارگیری شبکه عصبی عمیق برای تحلیل سازه‌های خرابی دو بعدی است. همانطور که در ابتدا گفته شد خرپا از

^۱ Underfitting

^۲ Overfitting

مجموعه اعضای محوری تشکیل شده است، که در این مقاله اعضا به صورت دوبعدی هستند و این اعضا در مختصات محلی در شکل ۴ به نمایش در آمده است.




شکل ۴: المان یک بعدی در مختصات محلی

در این مرحله باید ابتدا معادلات تعادل محلی در هر گره را نوشت و ماتریس سختی محلی المان را استخراج کرد.

$$K^e = \frac{A^e E^e}{L^e} \begin{bmatrix} 1 & 0 & -1 & 0 \\ 0 & 0 & 0 & 0 \\ -1 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \quad (۲)$$

که در آن u_1^e و u_2^e و v_1^e و v_2^e عامل‌های مجهول گرهی در مختصات محلی هستند و A^e مساحت المان و E^e مدول الاستیسیته المان و L^e طول المان و K^e ماتریس سختی محلی المان هستند.

حال باید ماتریس سختی در مختصات محلی به مختصات کلی برده شود. برای این فرایند از شکل ۵ کمک گرفته می‌شود.



شکل ۵: المان یک بعدی در مختصات کلی

در این مرحله ماتریس دوران به شکل زیر است.

$$R^e = \begin{bmatrix} \cos \theta^e & \sin \theta^e & 0 & 0 \\ -\sin \theta^e & \cos \theta^e & 0 & 0 \\ 0 & 0 & \cos \theta^e & \sin \theta^e \\ 0 & 0 & -\sin \theta^e & \cos \theta^e \end{bmatrix} \quad (3)$$

که در آن u_1^e و u_2^e و v_1^e و v_2^e عامل‌های مجهول گره‌ی در مختصات کلی هستند و R^e ماتریس دوران المان هستند.

پس از بدست آوردن ماتریس دوران می توان از طریق رابطه $kd=f$ در مختصات محلی به رابطه‌ی مختصات کلی دست پیدا کرد و ماتریس سختی کل المان را بدست آورد.

$$R^{eT} K^e R^e = K^e \Rightarrow K^e = \frac{AE}{L} \begin{bmatrix} C^2 & CS & -C^2 & -CS \\ CS & S^2 & -CS & -S^2 \\ -C^2 & -CS & C^2 & CS \\ -CS & -S^2 & CS & S^2 \end{bmatrix} \quad (4)$$

در این رابطه K^e ماتریس سختی المان در مختصات کلی و C کسینوس تتا و S سینوس تتا است. بعد از بدست آوردن ماتریس سختی هر المان در مختصات کلی از سوار کردن ماتریس‌ها به روش پارتیشن‌بندی ماتریس سختی کل بدست می‌آید. در نهایت با توجه به این مسئله که در ماتریس سختی ابتدا گره‌های مقید قرار داشته باشند از طریق فرمول‌های زیر تغییر مکان‌های گره‌ی بدست می‌آید.

$$K = \begin{bmatrix} E & F \\ K_{EE} & K_{EF} \\ K_{FE} & K_{FF} \end{bmatrix} \begin{matrix} E \\ F \end{matrix}, \quad d = \begin{bmatrix} d_E \\ d_F \end{bmatrix}, \quad f = \begin{bmatrix} f_E \\ f_F \end{bmatrix}, \quad f_E = 0, \quad r = \begin{bmatrix} r_E \\ r_F \end{bmatrix}, \quad r_F = 0$$

$$\begin{bmatrix} K_{EE} & K_{EF} \\ K_{FE} & K_{FF} \end{bmatrix} \begin{bmatrix} d_E \\ d_F \end{bmatrix} = \begin{bmatrix} 0 \\ f_F \end{bmatrix} + \begin{bmatrix} r_E \\ 0 \end{bmatrix} \rightarrow K_{FF} d_F = f_F - K_{FE} d_E \quad (5)$$

که در آن d_E بردار جابه‌جایی گره‌های مقید و d_F بردار جابه‌جایی گره‌های آزاد و r_E بردار واکنش‌های تکیه‌گاهی و f_F بردار نیرو در گره‌های آزاد هستند.

و در نهایت روند اجرای تحلیل به صورت زیر خلاصه می‌شود:

۱- یک مجموعه داده‌ی اکسلی شامل تمامی ویژگی‌های مرتبط با مسئله (ورودی‌ها) و جواب‌های مورد نظر (خروجی‌ها) که توسط روش اجزا محدود به دست آمده است، تهیه می‌شود. این داده‌ها به دو دسته تقسیم می‌شوند:

ورودی‌ها که شامل متغیرهایی هستند که به شبکه داده می‌شوند، و خروجی‌ها که نتایج مورد انتظار پیش‌بینی توسط شبکه هستند. بخشی از داده‌ها به صورت تصادفی به عنوان داده‌های تست کنار گذاشته می‌شوند که تنها برای ارزیابی مدل مورد استفاده قرار می‌گیرند و در فرآیند آموزش به کار نمی‌روند.

۲- داده‌های موجود قبل از ورود به شبکه عصبی **normalize** می‌شوند. این به معنای مقیاس‌بندی داده‌ها به محدوده‌ای مشخص (معمولاً بین ۰ و ۱) است که به بهبود عملکرد و پایداری شبکه عصبی کمک می‌کند.

۳- ساختار شبکه عصبی شامل لایه‌های مختلف با نورون‌های متعدد است که به یادگیری و شناسایی الگوهای پیچیده در داده‌ها کمک می‌کند. فرآیند آموزش شبکه عصبی شامل تنظیم وزن‌های شبکه است به گونه‌ای که خروجی‌های شبکه با جواب‌های واقعی تطابق داشته باشند. یکی از بهینه‌سازهای محبوب، **Adam** است که معمولاً سرعت همگرایی خوبی دارد.

۴- پس از آموزش شبکه، مدل با داده‌های تست ارزیابی می‌شود. هدف این است که تابع خطا در داده‌های تست حداقل شود تا اطمینان حاصل شود که مدل به خوبی توانسته است الگوهای موجود در داده‌ها را بیاموزد و تعمیم‌پذیری مناسبی دارد. این ارزیابی‌ها معمولاً شامل محاسبه معیارهایی مانند دقت، حساسیت، غیره هستند تا اطمینان حاصل شود که مدل به درستی عمل می‌کند و می‌تواند در شرایط واقعی استفاده شود.

در این مقاله از تابع خطا میانگین مربعات^۱ **MSE** استفاده شده است. رابطه‌ی زیر بیانگر این شکل از تابع خطا هست.

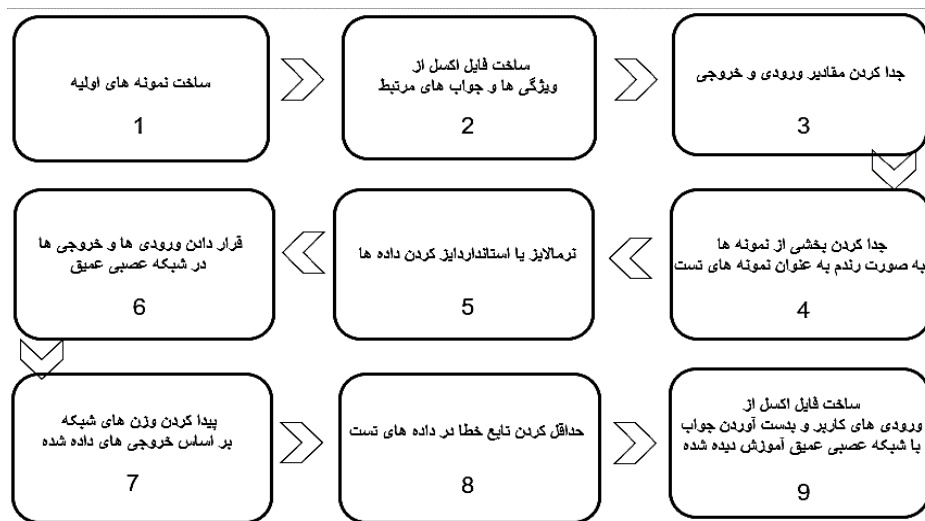
$$MSE = \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n} \quad (۶)$$

که در آن **n** تعداد نمونه‌ها و **Y_i** مقدارهای واقعی نمونه‌های تست و **\hat{Y}_i** مقدارهای پیش‌بینی شده برای نمونه‌های تست است.

۵- پس از آموزش و ارزیابی مدل، شبکه عصبی آماده استفاده برای پیش‌بینی‌های جدید است. ورودی‌های جدید کاربر در قالب یک مجموعه داده‌ی اکسلی تهیه می‌شود و با استفاده از شبکه عصبی آموزش دیده شده، جواب‌های مرتبط به دست می‌آیند. این نتایج می‌توانند در یک مجموعه داده‌ی اکسلی جدید ذخیره شوند تا به صورت مستند و قابل ارائه باشند. این مجموعه می‌تواند شامل تمامی ویژگی‌های ورودی و خروجی‌های پیش‌بینی شده باشد، به طوری که کاربر بتواند به راحتی نتایج را بررسی و تحلیل کند. این فرآیند به طور مداوم می‌تواند تکرار شود؛ به طوری که با

^۱ mean_ square error

ورود داده‌های جدید و به‌روزرسانی مدل، شبکه عصبی قادر به ارائه پیش‌بینی‌های دقیق‌تر و بهینه‌تر باشد. با این کار، سیستم به مرور زمان بهبود یافته و قادر خواهد بود تا با تغییرات و الگوهای جدید سازگار شود. به این ترتیب، استفاده از شبکه عصبی برای پیش‌بینی و تحلیل داده‌ها می‌تواند به تصمیم‌گیری‌های بهتر و بهینه‌تر در مسائل مختلف کمک کند. این مراحل به‌طور خلاصه فرآیند کامل ایجاد، آموزش و ارزیابی یک شبکه عصبی عمیق را تشریح می‌کنند و نشان می‌دهند که چگونه از داده‌های اولیه تا نتایج نهایی را می‌توان پیش برد. خلاصه‌ای از نحوه اجرای تحلیل در شکل ۶ موجود است.



شکل ۶: نحوه اجرای تحلیل با شبکه عصبی عمیق

۵- راستی آزمایی شبکه عصبی عمیق

برای صحت سنجی ابتدا باید مجموعه داده‌ها و خروجی‌های مربوطه جمع‌آوری شود. برای این آزمون دو تابع سه متغیره زیر را تعریف می‌شود.

$$y_1 = x_1^2 + x_2 + x_3 + 4 \quad (v)$$

$$y_2 = x_1^2 + x_2^2 + x_3 - 5$$

که در آن y_1 تابع اول و y_2 تابع دوم و x_1 و x_2 و x_3 ویژگی‌های مسئله هستند. حال برای جمع‌آوری داده، ۳۸۰ عدد مجموعه ویژگی مطابق جدول ۱ تعریف شده است. برای این مجموعه‌ها


مقدارهای توابع بدست آمده است و ۴۰٪ از داده‌ها را به عنوان داده تست در این شبکه در نظر گرفته می‌شود. پس از ساخت مجموعه داده‌ی اکسلی تمام مراحل که در روند اجرا مقاله گفته شده است طی می‌شود، تا بتوان نتایج را بررسی کرد.

جدول ۱: بازه‌ی نمونه‌های راستی آزمایی انتخابی

مشخصات نمونه‌ها برای صحت سنجی	
X_1	58 , 61 , 64 , 1195
X_2	79 , 83 , 87 , 1595
X_3	44 , 46 , 48 , 802

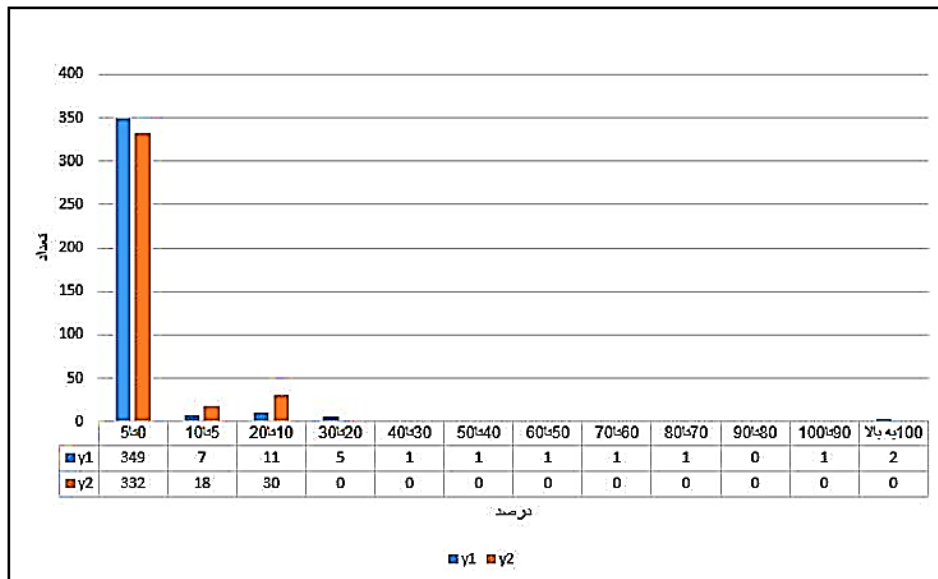
در رابطه با معماری شبکه که به صورت تجربی بدست آمده، شبکه دارای یک لایه ورودی و چهار لایه میانی با هر یک چهارده نورون و یک لایه خروجی با دو نورون است. در این صحت سنجی نمونه‌ها به بسته‌های شانزده تایی تقسیم می‌شوند تا سرعت شبکه و دقت آن بیشتر شود.

همانطور که در شکل ۷ نمایان است، تابع خطا در ۱۳۷ تکرار به مقدار $1,5 \times 10^{-5}$ رسیده است.



شکل ۷: نمودار تابع خطا برحسب تعداد تکرار

بعد از آموزش شبکه عصبی نوبت به تست شبکه و بررسی عملکرد آن می رسد. برای بررسی عملکرد آن تمامی نمونه هارا که قبلا ساخته شده است، به شبکه داده می شود تا پیش بینی کند و با مقایسه این مقادارها با مقادارهای اصلی بتوان صحت سنجی شبکه را بررسی کرد.




شکل ۸: راستی آزمایی شبکه

با توجه به شکل ۸ این شبکه عصبی عمیق با معماری ارائه شده در بالا، که حاصل آزمون خطا در معماری شبکه است، برای چنین مسئله ای ۹۰٪ از مقادارها را توانسته است، بین صفر تا ۵٪ خطا پیش بینی کند و این نشان دهنده عملکرد صحیح این شبکه بر مبنای کد نوشته شده و بر اساس زبان برنامه نویسی پایتون و عملکرد صحیح در رابطه با میل دادن تابع خطا به سمت صفر در این مسئله است.

۵- تحلیل خرابی دو بعدی با شبکه عصبی عمیق

مطابق شکل ۹ مدل اجزاء محدودی سازه مورد نظر در این مقاله دارای دو جزء دو گرهی با دو عامل مجهول و دو گره مقید و یک گره آزاد در مختصات کلی است. هر دو جزء در این سازه از تمامی جهات شبیه به هم هستند. در روش های متداول این گونه سازه ها با استفاده از معادلات تعادل، روش سختی و روش اجزاء محدود تحلیل می شوند. در

این مقاله قرار است تا الگوریتم شبکه عصبی عمیق جایگزین این چنین روابطی که به دلیل وجود بار مفهومی فیزیکی بعضاً خیلی از مسائل پیچیده و زمان برمی شوند، شود. به عبارتی دیگر هدف از این چنین مقاله ها، بدست آوردن تغییر مکان‌ها و تنش‌های درون اعضا و یا هر مقصود دیگری که بستگی به خود مسئله دارد، بدون استفاده از معادلات تعادل یا الگوریتم اجزاء محدود و با استفاده از روش‌های مبتنی بر طبیعت است.



شکل ۹: سازه خرابایی مسئله

۵-۱- تحلیل حساسیت براساس هر یک از ویژگی‌ها

قبل از پرداختن به اصل مسئله، باید براساس هر یک از ویژگی‌های مسئله، شبکه عصبی عمیق را مورد بررسی قرار داد تا نحوه عملکرد آن بر روی هر یک از ویژگی‌ها نمایان شود. این بررسی به عنوان نوعی تحلیل حساسیت، به ما کمک می‌کند تا بفهمیم کدام ویژگی‌ها بیشترین تأثیر را بر خروجی مدل دارند و چطور تغییرات در این ویژگی‌ها می‌تواند عملکرد نهایی شبکه را تحت تأثیر قرار دهد. در گام اول، لازم است ویژگی‌های کلیدی مسئله شناسایی شوند. این ویژگی‌ها می‌توانند شامل ورودی‌های مختلفی مانند داده‌های عددی، تصاویر، یا اطلاعات متنی مرتبط با مسئله مورد بررسی باشند. پس از شناسایی این ویژگی‌ها، یک مدل شبکه عصبی عمیق باید ایجاد و آموزش داده شود تا بتواند بر اساس این ورودی‌ها تصمیم‌گیری کند. سپس، برای هر یک از ویژگی‌ها، به صورت جداگانه تحلیل حساسیت انجام می‌شود. در این تحلیل، تغییرات جزئی در مقدارهای هر ویژگی به مدل اعمال می‌شود و تأثیر این تغییرات بر خروجی نهایی مدل مورد ارزیابی قرار می‌گیرد. این فرآیند به ما اجازه می‌دهد تا درک کنیم که کدام ویژگی‌ها برای عملکرد مدل حیاتی‌تر هستند و تغییر در آن‌ها می‌تواند به طور قابل توجهی نتایج را تغییر دهد.

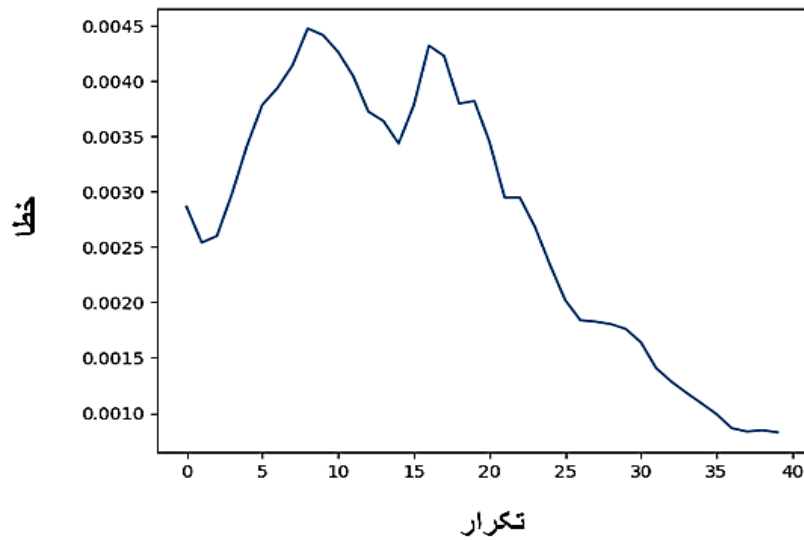
حال برای شروع، فقط مساحت متغیر می‌باشد و در نتیجه فقط ویژگی یک بروی مساحت به عنوان ویژگی است.

برای جمع آوری داده از ۱۴۳ مساحت موجود در جدول اشتال کمک گرفته شده است و ۲۰٪ از داده‌ها به عنوان داده تست در نظر گرفته شده است. نمونه‌های ساخته شده از داخل جدول ۲ می‌باشد. پس از ساخت مجموعه داده‌ی اکسلی تمام مراحل که در روند اجرا مقاله گفته شده است طی می‌شود، تا بتوان نتایج را بررسی کرد.

جدول ۲: بازه‌ی نمونه‌های انتخابی


مشخصات نمونه ها	
A	$(mm)^2$ تمامی نیمرخ های لوله در جدول اشتال
P	$= 25 \times 10^6 N$
β	$= 30D$
α	$= 30D$
L	$= 4000mm$
$E=2 \times 10^5 Mpa$	

در این مطالعه، معماری شبکه عصبی به صورت تجربی انتخاب و تنظیم شده است تا عملکرد بهینه‌تری داشته باشد. این شبکه دارای یک لایه ورودی، یک لایه میانی (پنهان)، و یک لایه خروجی است. لایه ورودی شبکه مسئول دریافت داده‌های ورودی است و اطلاعات اولیه را به شبکه انتقال می‌دهد. سپس داده‌ها به لایه میانی که شامل هفت نورون است، منتقل می‌شوند. این لایه پنهان نقش حیاتی در پردازش داده‌ها و استخراج ویژگی‌های پیچیده‌تر ایفا می‌کند. لایه خروجی شبکه شامل دو نورون است که نتیجه‌نهایی شبکه را تولید می‌کند. در این تحلیل حساسیت، نمونه‌ها به بسته‌های شانزده‌تایی تقسیم شده‌اند تا فرآیند آموزش شبکه به صورت بهینه‌تری انجام شود. این تکنیک، روشی برای افزایش سرعت آموزش شبکه و همچنین بهبود دقت آن است. همانطور که در شکل ۱۰ نمایان است، تابع خطا در ۴۰ تکرار به مقدار $10^{-4} \times 8.26$ رسیده است.



شکل ۱۰: نمودار تابع خطا بر حسب تعداد تکرار

پس از اتمام فرآیند آموزش شبکه عصبی، مرحله بعدی تست و ارزیابی عملکرد شبکه است. این مرحله بسیار دارای اهمیت است، زیرا نشان می‌دهد که آیا شبکه توانسته است به درستی الگوها و روابط موجود در داده‌ها را یاد بگیرد و قادر به تعمیم آنها به داده‌های جدید و دیده نشده است یا قادر به چنین کاری نیست. در این مرحله، تمامی نمونه‌هایی که قبلاً برای تست و ارزیابی آماده شده‌اند، به شبکه داده می‌شوند. این داده‌ها به شبکه ارائه می‌شوند تا شبکه بتواند براساس یادگیری‌های قبلی، خروجی یا همان پیش‌بینی‌های خود را تولید کند. در تمامی نمودارها عملکرد شبکه، X نشان دهنده ی تعداد تغییر مکان افقی نمونه‌ها و Y نشان دهنده ی تعداد تغییر مکان عمودی نمونه‌ها در بازه مشخص شده می‌باشد.



شکل ۱۱: عملکرد شبکه

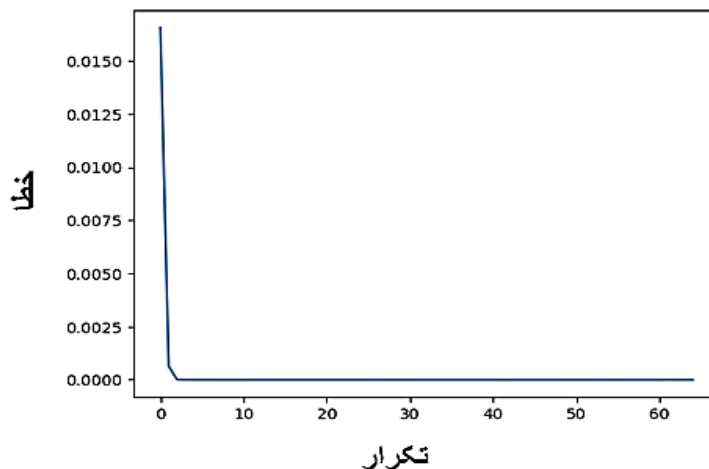
با توجه به شکل ۱۱ به دلیل محدودیت‌های موجود در ساخت نمونه‌ها که تنها بر اساس متغیر مساحت یا به عبارت بهتر ویژگی یک به روی مساحت طراحی شده‌اند، به وضوح مشخص است که شبکه عصبی نتوانسته است عملکرد قابل قبولی از خود نشان دهد. این محدودیت به طور مستقیم بر فرآیند یادگیری شبکه تاثیر گذاشته و باعث شده است که شبکه قادر به شناسایی و استخراج ویژگی‌های مورد نیاز از داده‌ها نباشد. در چنین شرایطی، عملکرد شبکه به طور قابل توجهی کاهش پیدا کرده و شبکه نتوانسته است به خوبی الگوهای موجود در داده‌ها را بیاموزد و تعمیم دهد. با توجه به عملکرد نا صحیح شبکه نسبت به متغیر مساحت، نمی توان نمودار خروجی های شبکه عصبی عمیق و متغیر مساحت را رسم کرد.

حال نوبت به بررسی متغیر طول المان میرسد و برای این امر از ۸۰۰ نمونه براساس جدول ۳ کمک گرفته شده است و ۲۰٪ از داده ها به عنوان داده تست در نظر گرفته می شود. پس از ساخت مجموعه داده‌ی اکسلی تمام مراحل که در روند اجرا مقاله گفته شده است طی می‌شود، تا بتوان نتایج را بررسی کرد.

جدول ۳: بازه‌ی نمونه‌های انتخابی


مشخصات نمونه ها	
A	$=22000(mm)^2$
P	$= 25 \times 10^6 N$
β	$= 30D$
α	$= 30D$
L	$\geq 500mm$ $\leq 160300mm$ با گام های 200 تایی
$E=2 \times 10^5 Mpa$	

در رابطه با معماری شبکه که به صورت تجربی بدست آمده، شبکه یک لایه ورودی و چهار لایه میانی با هر یک چهار نورون و یک لایه خروجی با دو نورون دارد. در این تحلیل حساسیت نمونه‌ها به بسته‌های شانزده تایی تقسیم می‌شوند تا سرعت شبکه و دقت آن بیشتر شود. همانطور که در شکل ۱۲ نمایان است، تابع خطا در ۶۵ تکرار به مقدار $10^{-7} \times 5.48$ رسیده است.



شکل ۱۲: نمودار تابع خطا برحسب تعداد تکرار


بعد از آموزش شبکه عصبی نوبت به تست شبکه و بررسی عملکرد آن می‌رسد. برای بررسی عملکرد آن تمامی نمونه‌ها را که قبلاً ساخته شده است، به شبکه داده می‌شود تا پیش‌بینی کند و با مقایسه این مقادارها با مقادارهای اصلی می‌توان عملکرد آن را بررسی کرد.



شکل ۱۳: عملکرد شبکه

همان‌طور که در شکل ۱۳ نمایان است نسبت به ویژگی طول المان تقریباً عملکرد شبکه به ۱۰۰٪ می‌رسد. حال که عملکرد شبکه عصبی نسبت به این ویژگی عالی است می‌توان نمودار خروجی‌ها را نسبت به این متغیر در شکل

۱۴ دید. در شکل ۱۴ مقدارهای تغییر مکان پیش بینی شده در جهت افق و PDy مقدارهای پیش بینی شده در جهت قائم و L محور طول المانها و D محور جابه جایی می باشد.



شکل ۱۴: خروجی های شبکه براساس متغیر طول

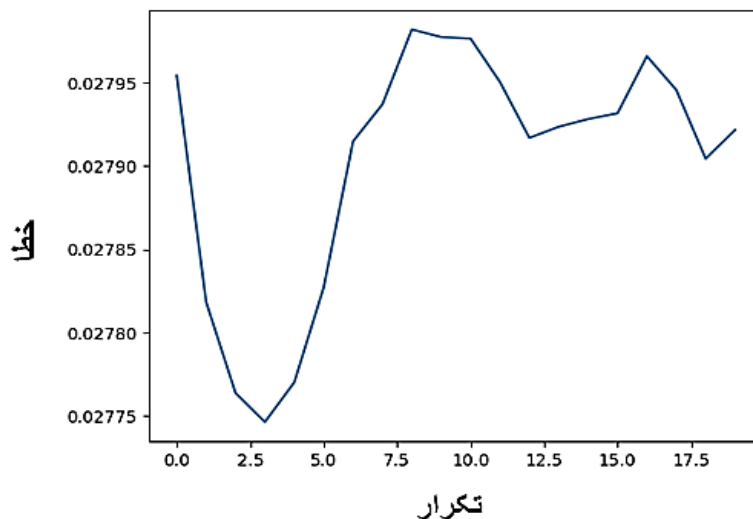
همان طور که از شکل ۱۴ پیدا است، یک رابطه خطی بین متغیر طول در شبکه عصبی عمیق و خروجی های شبکه عصبی عمیق، به همان شکل که از معادلات تعادل این رابطه خطی استخراج می شود، دیده می شود. در نهایت نوبت به متغیر زاویه پای خرابی می رسد که در ویژگی کسینوس به توان دو خود را نشان می دهد از همین ابتدا می توان حدس زد که نتایج خوبی نسبت به این ویژگی بدست نیاید چون تعداد نمونه آموزش بسیار کم است. با این حال با توجه به جدول ۴، ۸۹ نمونه ساخته شده است که ۲۰٪ از آن برای داده تست لحاظ شده است. پس از ساخت مجموعه داده ی اکسلی تمام مراحل که در روند اجرا مقاله گفته شده است طی می شود، تا بتوان نتایج را بررسی کرد.

جدول ۴: بازه‌ی نمونه‌های انتخابی

مشخصات نمونه‌ها	
A	$= 22000(mm)^2$
P	$= 25 \times 10^6 N$
β	$= 30D$
α	$\geq 1D$ $\leq 89D$ با گام‌های یک درجه
L	$= 4000mm$
$E=2 \times 10^5 Mpa$	


در رابطه با معماری شبکه که به صورت تجربی بدست آمده، شبکه یک لایه ورودی و پنج لایه میانی با هر یک چهار نورون و یک لایه خروجی با دو نورون دارد. در این تحلیل حساسیت نمونه‌ها به بسته‌های شانزده تایی تقسیم می‌شوند تا سرعت شبکه و دقت آن بیشتر شود.

همانطور که در شکل ۱۵ نمایان است، تابع خطا در ۲۰ تکرار به مقدار ۰,۰۲۸ رسیده است.



شکل ۱۵: نمودار تابع خطا برحسب تعداد تکرار

بعد از آموزش شبکه عصبی نوبت به تست شبکه و بررسی عملکرد آن می‌رسد. برای بررسی عملکرد آن تمامی نمونه‌ها را که قبلاً ساخته‌ایم، به شبکه داده می‌شود تا پیش‌بینی کند و با مقایسه این مقادارها با مقادارهای اصلی می‌توان عملکرد آن را بررسی کرد.



شکل ۱۶: عملکرد شبکه

همان‌طور که در ابتدای بحث ذکر شد و در شکل ۱۶ نمایان است، یکی از مشکلات اصلی که شبکه عصبی با آن مواجه شده است، کمبود نمونه‌های کافی برای آموزش است. این کمبود داده به طور قابل ملاحظه‌ای بر عملکرد شبکه تأثیر منفی گذاشته و باعث شده است که شبکه نتواند به درستی الگوهای موجود در داده‌ها را شناسایی و یاد بگیرد. یکی از نتایج این محدودیت، عملکرد ناصحیح شبکه نسبت به متغیر زاویه است. این متغیر به دلیل عدم وجود داده‌های کافی و متنوع، نتوانسته است به شبکه اطلاعات کافی برای یادگیری و تعمیم ارائه دهد. به دلیل این عملکرد ناصحیح، شبکه قادر نبوده است که رابطه معناداری بین متغیر زاویه و خروجی‌های خود برقرار کند. نتیجه این ضعف این است که رسم نمودار خروجی شبکه نسبت به متغیر زاویه عملاً غیرممکن شده است، چرا که داده‌ها و پیش‌بینی‌های شبکه برای این متغیر به اندازه کافی دقیق و قابل اعتماد نیستند. به عبارت دیگر، خروجی‌های شبکه برای متغیر زاویه نه تنها دارای نوسانات و خطاهای زیادی هستند، بلکه فاقد الگویی منسجم می‌باشند که بتواند به طور صحیح نمایش داده شود. از دیگر مشکلاتی که نسبت به این ویژگی مطرح است می‌توان به این مطلب اشاره کرد که در تغییر مکان افقی با زیاد شدن \cos^2 تغییر مکان افقی کم می‌شود ولی در تغییر مکان قائم باعث زیاد شدن آن می‌شود و این اثر دوگانه باعث پیچیدگی در عملکرد شبکه می‌شود و همین امر باعث کارایی کمتر نسبت به این ویژگی هست.

۵-۲- تحلیل اصل مسئله

در این مسئله، ورودی‌های هر نورون در لایه‌ی اول به تعداد ویژگی‌های مسئله است، یعنی به ازای هر ویژگی، یک وزن اختصاصی در نظر گرفته می‌شود که نقش مهمی در عملکرد شبکه ایفا می‌کند. به عبارت دیگر، به ازای هر ویژگی،

وزنی مشخص تعیین می‌شود که تأثیر آن ویژگی بر خروجی شبکه را معین می‌کند. ویژگی‌های مورد استفاده در این مسئله به شرح زیر هستند:

یک به روی مساحت المان‌ها که نقش مهمی در تحلیل المان‌های مختلف دارد و با استفاده از آن، شبکه می‌تواند تأثیر تغییرات در مساحت المان‌ها را بررسی کند. هرچه مساحت یک المان کوچک‌تر باشد، مقدار این ویژگی بزرگتر خواهد شد.

کسینوس به توان دو در زوایای پای اتصال مفصلی به زمین ویژگی دیگری است که به تحلیل زوایای اجزا، مربوط می‌شود. استفاده از کسینوس به توان دو این امکان را فراهم می‌کند تا تأثیر این زوایا بر سازه بررسی شود و شبکه بتواند تغییرات کوچک در زاویه‌ها را که ممکن است بر رفتار سازه تأثیرگذار باشد، شناسایی کند.


طول المان‌ها نیز ویژگی کلیدی دیگری است که به تعیین رفتار سازه کمک می‌کند. تغییرات در طول المان‌ها می‌تواند به طور مستقیم بر سازه تأثیرگذار باشد. در شکل ۵، این ویژگی‌ها به صورت واضح تعریف شده و برای تجزیه و تحلیل رفتار سازه‌ها اهمیت زیادی دارند. نمونه‌های ساخته شده در این مقاله به صورت تصادفی و از مقدارهای جدول ۵ برداشت شده است.

جدول ۵: بازه‌ی نمونه‌های انتخابی

مشخصات نمونه‌ها	
A	$(mm)^2$ تمامی نیمرخ‌های لوله در جدول اشتال
P	$= 25 \times 10^6 N$
β	$= 30D$
α	$\geq 30D$ $\leq 70D$ تمامی زوایای مضرب پنج در بازه بالا
L	$\geq 500mm$ $\leq 5000mm$ تمامی مقادیر مضرب ده در بازه بالا
$E=2 \times 10^5 Mpa$	


در این مقاله ابتدا به صورت تصادفی ۶۰۰۰ مدل نمونه تولید شده و ۴۰٪ از آن را به عنوان داده تست استفاده کرده ایم. از معماری شبکه می‌توان به وجود یک لایه ورودی و سه لایه میانی و یک لایه خروجی که تمامی لایه‌ها به جز لایه آخر ۲۲۵ نورون و لایه آخر به تعداد خروجی‌های مسئله یعنی دو نورون دارند، اشاره کرد. همانطور که در شکل ۱۷

نمایان است، تابع خطا در ۳۲ تکرار به مقدار $4,07 \times 10^{-5}$ رسیده است.



شکل ۱۷: نمودار تابع خطا بر حسب تعداد تکرار

بعد از آموزش شبکه عصبی نوبت به تست شبکه و بررسی عملکرد آن می‌رسد. برای بررسی عملکرد آن تمامی نمونه‌ها را که قبلاً ساخته شده است، به شبکه داده می‌شود تا پیش‌بینی کند و با مقایسه این مقادارها با مقادارهای اصلی بتوان عملکرد آن را بررسی کرد.



شکل ۱۸: عملکرد شبکه


با توجه به شکل ۱۸ این شبکه عصبی عمیق با معماری ارائه شده در بالا، که حاصل آزمون خطا در معماری شبکه

است، برای چنین مسئله‌ای فقط ۲۴٪ از مقدارها را توانسته است، بین صفر تا ۵٪ خطا پیش‌بینی کند و این نشان دهنده عملکرد ضعیف شبکه عصبی عمیق در این مسئله هست. حال برای درک بهتر نتایج می‌توان از جدول ۶ باتوجه به نیروی متمرکز $N_{25} \times 10^{-6}$ و زاویه نیرو با محور ایکس 30° کمک گرفت.

جدول ۶: مقدارهای درست پیش‌بینی شده در مقابل مقدارهای نادرست


پیش‌بینی های درست					پیش‌بینی های نادرست				
A(mm ²)	5000	1890	325	1890	A(mm ²)	53900	19500	325	57900
1/A(1/mm ²)	2E-4	53E-5	31E-4	53E-5	1/A(1/mm ²)	1.8E-5	5.1E-5	31E-4	1.7E-5
L(mm)	2460	1860	4790	1410	L(mm)	3030	3030	4790	650
α (d)	50	50	40	60	α (d)	30	55	40	30
COS^2	0.41	0.41	0.58	0.25	COS^2	0.75	0.33	0.58	0.75
D_x (mm)	64.45	128.9	1359.42	162	D_x (mm)	4.06	25.56	---	0.81
D_y (mm)	26.2	52.41	---	---	D_y (mm)	7.03	7.24	1114.72	1.4
$P D_x$ (mm)	62.46	126.19	1320.5	155.71	$P D_x$ (mm)	8.02	17.17	---	-5.6
$P D_y$ (mm)	25.07	51.16	---	---	$P D_y$ (mm)	17.49	4.71	1173.86	2.88
%x	3.07	2.12	2.85	3.59	%x	97.72	32.8	---	791.6
%y	4.31	2.38	---	---	%y	148.91	34.8	5.3	105.4

حال برای پی بردن به تاثیر افزایش نمونه‌ها، ابتدا ۱۹۰۰۰ نمونه از جدول ۵ انتخاب می‌شود و با معماری شبکه تجربی بدست آمده برای این مقدار نمونه و با بسته بندی ۶۴ تایی، شبکه دوباره آموزش داده می‌شود و شبکه، تابع خطا را به سمت صفر میل می‌دهد. سپس داده‌ها را برای پیش‌بینی به شبکه داده می‌شود و عملکرد شبکه در شکل ۱۹ بررسی می‌شود.



شکل ۱۹: عملکرد شبکه

همان‌طور که در شکل ۱۹ دیده می‌شود عملکرد شبکه با این معماری مختصص ۱۹۶۵۲ عدد نمونه بسیار ضعیف است و با وجود افزایش نمونه تقریباً ۷٪ از نمونه‌ها را زیر ۵٪ خطا پیش‌بینی کرده است. در نهایت برای پیدا کردن تاثیر نمونه‌ها یک مدل شبکه هم با ۵۰۹۶۴ تا نمونه و دسته‌بندی ۶۴ تایی ساخته می‌شود و نتایج آن در شکل ۲۰ مورد بررسی قرار می‌گیرد.



شکل ۲۰: عملکرد شبکه

حال با بررسی نتایج این معماری شبکه عصبی و تحلیل عملکرد آن، مشاهده شد که با افزایش تعداد نمونه‌های آموزشی از ۱۹،۶۵۲ به ۵۰،۹۶۴، عملکرد شبکه بهبود یافته است. این افزایش تعداد نمونه‌ها منجر به دقت بیشتر در پیش‌بینی‌ها شده و شبکه توانست ۴۳٪ از نمونه‌ها را به درستی پیش‌بینی کند. با این حال کماکان ۵۳٪ از نمونه‌ها درست پیش‌بینی نشده‌اند. این نتیجه نشان می‌دهد که با افزایش حجم داده‌های آموزشی، شبکه توانایی بیشتری در یادگیری و تعمیم الگوهای پیچیده پیدا می‌کند و دقت آن در پیش‌بینی نتایج بهبود می‌یابد. به عبارت دیگر، افزایش تعداد نمونه‌های آموزشی نقش کلیدی در بهبود عملکرد شبکه عصبی داشته و کارایی شبکه در حل مسائل بزرگتر و پیچیده‌تر بیشتر شده است. این بهبود ۴۳ درصدی دقت، بیانگر این است که تعداد نمونه‌های بزرگتر از ۶،۰۰۰ توانایی شبکه را در انجام پیش‌بینی‌های دقیق‌تر به میزان قابل توجهی افزایش داده است و نشان می‌دهد که برای رسیدن به دقت بهینه، نیاز به حجم مناسبی از داده‌های آموزشی وجود دارد. از سوی دیگر، نتایج جالب توجهی نیز در تحلیل تعداد نمونه‌های ۱۹،۶۵۲ مشاهده شد. با وجود اینکه تعداد نمونه‌ها از ۶،۰۰۰ به ۱۹،۶۵۲ افزایش یافته بود، عملکرد شبکه در این حالت به‌طور غیرمنتظره‌ای بسیار بدتر شد. این کاهش دقت نشان‌دهنده این است که افزایش تعداد نمونه‌ها به دلیل تغییر معماری شبکه همیشه منجر به بهبود عملکرد نمی‌شود.

۶- نتیجه گیری

این مقاله به بررسی استفاده از شبکه‌های عصبی عمیق برای تحلیل و مدل‌سازی سازه‌های خرپای دو بعدی پرداخته است. هدف اصلی آن، بررسی توانایی این شبکه‌ها در جایگزینی روش‌های سنتی تحلیل سازه، نظیر روش اجزاء محدود، و بهبود کارایی و سرعت محاسبات در تحلیل‌های پیچیده مهندسی می‌باشد. این روش، با ارائه یک فرآیند کامل از جمع‌آوری داده‌ها، آموزش شبکه عصبی، ارزیابی مدل و استفاده عملی از آن، نشان داد که استفاده از شبکه‌های عصبی عمیق می‌تواند جایگزین مؤثری برای روش‌های سنتی مانند اجزاء محدود باشد، به شرطی که تنظیمات شبکه به درستی انجام شوند و داده‌های آموزشی زیادی در دسترس باشد. در نتیجه‌گیری این مقاله می‌توان بیان کرد که مسئله مورد بررسی به دلیل وجود تعداد زیادی از حالات ممکن و ویژگی‌های مختلف به‌طور ذاتی پیچیده است. یکی از چالش‌های اصلی در این مسئله، استفاده از شبکه عصبی عمیق برای پیش‌بینی دو مقدار خروجی متفاوت برای هر مجموعه ویژگی است. این پیچیدگی خود به‌تنهایی مدل‌سازی مسئله را دشوار می‌کند و همچنین آموزش را برای شبکه عصبی پیچیده تر می‌کند. علاوه بر این، یکی از ویژگی‌های خاص، یعنی $\cos 2$ ، به دلیل رابطه مستقیم آن با یکی از خروجی‌ها و کاهش مقدارهای یکی از خروجی‌ها در اثر افزایش این ویژگی، منجر به ایجاد اختلال در یادگیری شبکه شده است. این رابطه نامتوازن بین ویژگی‌ها و خروجی‌ها، دلیل اصلی عدم دستیابی به نتایج قابل قبول است. با این حال، یکی از راه‌حل‌های قابل پیشنهاد برای بهبود نتایج، ادامه دادن به افزایش تعداد نمونه‌های آموزشی است. همان‌طور که دیده شد، با افزایش نمونه‌ها، عملکرد شبکه بهبود یافته است، بنابراین، با افزودن داده‌های بیشتر می‌توان به نتایج بهتری در تحلیل این مسئله پیچیده دست یافت و دقت پیش‌بینی‌ها را ارتقا داد.

منابع

- [1] J. Naranjo-Pérez, M. Infantes, JF. Jiménez-Alonso, A. Sáez, "A collaborative machine learning-optimization algorithm to improve the finite element model updating of civil engineering structures," *Engineering Structures*, vol. 225, doi:10.1016/j.engstruct.2020.111327.
- [2] FKJ. Jawad, C. Ozturk, W. Dansheng, M. Mahmood, O. Al-Azzawi, A Al-Jemely, "Sizing and layout optimization of truss structures with artificial bee colony algorithm," *Structures*, vol. 30, pp.546-559, doi:10.1016/j.istruc.2021.01.016.
- [3] A. Gienger, S. Schaut, O. Sawodny, C. Tarin, "Modular Distributed Fault Diagnosis for Adaptive Structures using Local Models," *IFAC-PapersOnLine*, vol. 53, pp. 13631-13637,

doi:10.1016/j.ifacol.2020.12.862.

- [4] B. Etaati , M. Neshat, A. Abdollahi Dehkordi , N. Salami Pargoo ,M. El-Abd , A. Sadollah , A H. Gandomi, "Shape and sizing optimisation of space truss structures using a new cooperative coevolutionary-based algorithm," Results in Engineering, vol. 21, doi:10.1016/j.rineng.2024.101859.
- [5] N. Khodadadi , A Ö. Çiftçioğlu , S. Mirjalili , A. Nanni, "A comparison performance analysis of eight meta-heuristic algorithms for optimal design of truss structures with static constraints," Decision Analytics Journal, vol. 8, doi:10.1016/j.dajour.2023.100266.
- [6] T. Huu, S. Van, Q. Pham, T. Le, "An improved bat algorithms for optimization design of truss structures," Structures, vol. 47, pp. 2240-2258, doi:10.1016/j.istruc.2022.12.033.
- [7] MZ. Naser, "Fire resistance evaluation through artificial intelligence - A case for timber structures," Fire Safety Journal, vol. 105, pp. 1-18, doi:10.1016/j.firesaf.2019.02.002.
- [8] F. Ferreira, R. Shamass, V. Limbachiya, KD. Tsavdaridis, CH. Martins, "Lateral-torsional buckling resistance prediction model for steel cellular beams generated by Artificial Neural Networks (ANN)," Thin-Walled Structures, vol. 170, doi:10.1016/j.tws.2021.108592.
- [9] H. Chen, Y. Liu, Y. Huang, J. Huang, L. Caisong, Z. Guo, "Maximum displacement prediction model for steel beams with hexagonal web openings under impact loading based on artificial neural networks," Engineering Applications of Artificial Intelligence, vol. 136, doi:10.1016/j.engappai.2024.108932.
- [10] SK Kamane, NK Patil, BR Patagundi, "Use of artificial neural network to predict the bending behavior of steel I beam externally attached with FRP sheets," Materials Today: Proceedings, vol. 39, pp.17-21, doi:10.1016/j.matpr.2020.04.893.

[11] اسماعیلی، م. باد پی، ا. "مرجع کاربردی یادگیری ژرف با Tensor Flow و Keras"، انتشارات آتی نگر، ۱۴۰۲.