



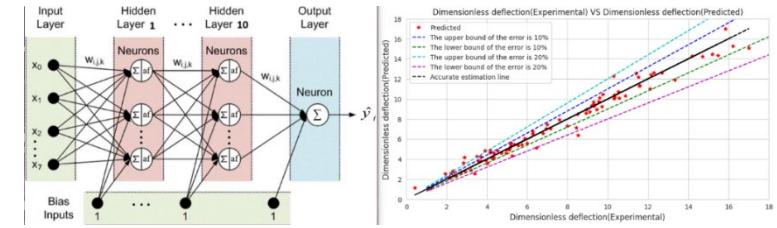
پیش‌بینی پاسخ پلاستیک ورق‌های فلزی دایره‌ای تحت بار دینامیکی یکنواخت با استفاده از شبکه عصبی عمیق

سعید سرآبادان^{۱*}, امیرحسین باقریان^۱, توحید میرزاپایی مستوفی^۲^۱ استادیار، دانشکده علوم پایه، دانشگاه امام حسین^(ع)، تهران، ایران^۲ کارشناسی ارشد، دانشکده علوم پایه، دانشگاه امام حسین^(ع)، تهران، ایران^۳ استادیار، دانشکده مهندسی مکانیک، دانشگاه آیون‌کی، آیون‌کی، ایران

برجسته‌ها

- استفاده از یادگیری عمیق جهت پیش‌بینی خیز دائمی ورق‌های فلزی
- استفاده از الگوریتم بهینه‌ساز آدام در معماری مدل شبکه عصبی عمیق
- تعیین فراپارامترهای بهینه بر اساس جستجو گرهای ارزیاب

چکیده گرافیکی



مشخصات مقاله

تاریخچه مقاله:

نوع مقاله: علمی پژوهشی
دریافت: ۱۴۰۲/۱۱/۱۹

بازنگری: ۱۴۰۲/۱۲/۲۷

پذیرش: ۱۴۰۳/۰۲/۰۱

ارائه برخط: ۱۴۰۳/۰۳/۲۹

*نویسنده مسئول:

ssarabandan@ihu.ac.ir

کلیدواژه‌ها:
بارگذاری دینامیکی یکنواخت
ورق‌های فلزی دایره‌ای شکل
شبکه عصبی عمیق
هوش مصنوعی
خیز دائمی
ورق‌های فلزی

چکیده

در تحقیق پیش رو با استفاده از شبکه‌های عصبی عمیق به پیش‌بینی میزان بیشترین خیر ورق‌های فلزی دایره‌ای شکل تحت بار شدید دینامیکی یکنواخت پرداخته می‌شود. شبکه عصبی ارائه شده در این تحقیق در محیط زبان برنامه‌نویسی پایتون و با استفاده از کتابخانه‌های موجود در آن از جمله تنسورفلو طراحی گردید. مدل طراحی شبکه مبتنی بر مسئله رگرسیون و از نوع سکوتنشال و شامل ۱۰ لایه می‌باشد که تابع فعال ساز موجود در نورون‌ها از نوع لیکی رلو (Leaky RELU) هستند. الگوریتم بهینه‌ساز مدل روى آدام و تابع هدف مسئله میانگین مربعات خطأ و تعداد تکرار شبکه روی ۷۰۰ مرتبه تنظیم شد. مجموعه داده مورد استفاده در این مقاله مشکل از ۵۸۱ نمونه حاصل از ۱۶ سری آزمایش در طی چهل سال گذشته می‌باشد که به وسیله کتابخانه سایکیت-لرن استانداردسازی شدند. ورق‌های فلزی از چهار جنس فولادی، آلومنیوم، مس و تیتانیوم می‌باشند و هیچ‌گونه تغییرات میان فلزات مختلف صورت نگرفته است. تعداد داده‌های آموزشی در مدل ۴۴۳ عدد معادل ۷۷٪ از مجموعه داده تعیین شد. همچنین تعداد داده‌های آزمایشی و ارزیاب به ترتیب ۸۸ عدد معادل ۱۵٪ و ۵۰ عدد معادل ۱۰٪ از کل مجموعه داده انتخاب شد. هر نمونه دارای ۸ ویژگی به عنوان ورودی‌های شبکه عصبی و یک برجسب به عنوان خروجی می‌باشد. مدل هوشمند ارائه شده از میان ۸۸ داده آزمایشی که به صورت کاملاً تصادفی از مجموعه داده انتخاب شده بود، توانست ۷۶٪ از داده‌ها تقریباً معادل ۶۷ عدد را در محدوده خطای کمتر از ۱۰٪ و ۸۸٪ از داده‌ها یا به عبارت دیگر معادل تقریباً ۷۸ عدد را در محدوده خطای کمتر از ۲۰٪ پیش‌بینی کند. میزان شاخص ریشه میانگین مربعات خطأ ۱۰^۲ برابر نسبت به روابط پیش‌بینی کننده تحلیلی و سنتی موجود در سوابق تحقیق کاهش پیدا کرد. همچنین معیار ضریب تعیین که شاخصی مهم جهت ارزیابی عملکرد شبکه‌های عصبی مبتنی بر مسائل رگرسیون می‌باشد مقدار ۰/۹۶ را در بر گرفته است.



* این مقاله یک مقاله با دسترسی آزاد است که تحت شرایط و ضوابط مجوز (CC BY) Creative Commons Attribution توزیع شده است.

© نویسنده‌گان

ناشر: دانشگاه جامع امام حسین^(ع)

گردید. همچنین یکی دیگر از مشکلات موجود در مراجع قبلی [۱۴، ۱۵] عدم بیان دلیل برای معرفی اعداد بی‌بعد بود که برای حل این مشکل، اعداد بی‌بعد پیشنهادی، از بعدسازی معادلات تعادل دینامیکی حاکم بر ورق استخراج شدند [۳]. همچنین، کمیت‌های مهمی نظیر هندسه ورق، توانایی مقاومت دینامیکی ماده در برابر بار وارد، حساسیت ماده به نرخ کرنش و همچنین اینترسی بار دفعی واردشده به موارد فوق اضافه گردید. درنهایت معادلات ساختاری تجربی بر اساس نتایج تجربی موجود و همچنین روش تجزیه مقادیر منفرد بهینه‌شده، به دست آمد.

در مقاله حاضر، علاوه بر افزایش دقت، به افزایش شاخص سرعت در محاسبات نیز پرداخته شد تا مدل بتواند به صورت هوشمند، داده‌های ورودی را در سریع‌ترین زمان ممکن با حداقل خطای پردازش و خروجی نهایی را در اختیار کاربر قرار دهد. همچنین این مدل با داشتن تقریباً ۶۰ هزار پارامتر، در صورت استفاده از منابع محاسباتی کارآمد قادر خواهد بود حجم عظیمی از داده‌های دریافتی را پردازش و مورد پیش‌بینی قرار دهد. در روابط تحلیلی پیشین، هدف تعیین بهترین منحنی گذرنده از داده‌ها با حل دستگاه معادلات و تعیین مجھولات موجود در رابطه بود که نیاز به حل روابط و معادلات پیچیده ریاضیاتی داشت و به صورت آزمون و خطای جهت رسیدن به کمترین میزان شاخص ارزیابی خطای که عموماً میانگین مربعات خطای بود صورت می‌گرفت. روش ارائه شده در این تحقیق مبتنی بر روش‌های تکراری و استفاده از روابط ساده ریاضیاتی که پیچیدگی محاسباتی بسیار کمتری نسبت به روابط تحلیلی دارند صورت می‌پذیرد. این پیچیدگی محاسباتی کمتر این امکان را می‌دهد تا بتوان روش تکراری را تا مراتب بسیار بالاتر اجرا کنیم و مدل روابط موجود میان داده‌ها را با دقت بیشتری جستجو و برآورد می‌کند. همچنین، ضعف مدل‌های کلاسیک تأخیر در پردازش داده‌های با حجم بالا می‌باشد. درواقع با افزایش میزان داده‌های ورودی مدل مجبور به حل معادلات سنگین خواهد شد که نیاز به منابع محاسباتی گران و زمان طولانی خواهد داشت. همچنین در مدل‌های مبتنی بر یادگیری ماشین ارائه شده، شبکه هیچ‌گاه داده‌های آموزشی را در ارزیابی و محاسبه خطای لحاظ نکرده و عملکرد شبکه بر اساس داده‌های

۱- مقدمه

با پیشرفت تکنولوژی و لزوم کسب دانش دقیق جهت ارزیابی پاسخ سازه‌ها تحت بارگذاری دینامیکی شدید، روش‌های تجربی جای خود را به روش‌های مبتنی بر یادگیری ماشین و یادگیری عمیق داده‌اند که نقش به سزاوی در پویایی ارزیابی‌ها، کاهش زمان، هزینه‌ها و آسیب‌های احتمالی خواهند داشت. در جدیدترین تحقیقات در این حوزه ساکاریدس [۱] با استفاده از نتایج آزمایش‌های منتشرشده در سالیان گذشته در زمینه پاسخ کمانش سازه‌های لوله‌ای و استفاده از مفاهیم یادگیری ماشین نسبت به فروپاشی سازه‌ها پیش‌بینی‌های دقیق‌تری انجام داده است. شایان توجه است که در زمینه ارائه مدل‌های تحلیلی و تجربی جهت پیش‌بینی پاسخ دینامیکی ورق‌های دایره‌ای و مستطیلی تحت بارگذاری دینامیکی تحقیقات گسترده‌ای صورت گرفته که به برخی از آن‌ها در ادامه اشاره می‌شود. [۱۲-۲].

در سال ۱۹۸۹ نوریک و مارتین [۱۳] اصلاحاتی را روی عدد بی‌بعد جانسون که در سال ۱۹۵۱ ارائه داده بود انجام دادند و عدد بی‌بعد ایمپالس ϕ_{cs} را برای پیش‌بینی رفتار دینامیکی ورق‌های دایره‌ای تحت بارگذاری دینامیکی یکنواخت به صورت رابطه (۱) پیشنهاد کردند:

$$(1) \quad \phi_{cs} = \frac{I}{\pi R H^2 \sqrt{\rho \sigma_0}}$$

سپس در سال ۲۰۰۷ ژاکوب و همکاران [۱۴] عدد بی‌بعد ایمپالس ϕ_{cs} را با اعمال فاصله استخراج خرج از سطح ورق که با نماد ۵ نمایش داده می‌شود، برای بارگذاری دینامیکی به صورت رابطه (۲) ارائه دادند:

$$(2) \quad \phi_{cs} = \frac{I(1 + \ln(R/R_0))}{(1 + \ln(S/R_0))\pi R H^2 \sqrt{\rho \sigma_0}}$$

همچنین نوریک [۸] در سال ۲۰۱۷ رابطه تجربی خود را بر حسب عدد بی‌بعد ایمپالس ϕ_{cs} برای پیش‌بینی بیشترین خیز دائمی ورق‌های دایره‌ای تحت بار دینامیکی یکنواخت (W_0) نسبت به ضخامت به صورت رابطه (۳) ارائه کرده است.

$$(3) \quad \frac{W_0}{H} = 425\phi_{cs} + 0.277$$

در مقاله ارائه شده توسط مستوفی و همکاران [۳] با استفاده از بی‌بعدسازی روابط حاکم بر ورق، این اثر به تحلیل اضافه

میزان پارامترهای اضافی کاست و مدلی سبک‌تر به لحاظ پردازش محاسباتی داشت.

۲- یادگیری عمیق

یادگیری عمیق یکی از الگوریتم‌های حوزه یادگیری ماشین و نوین‌ترین دستاوردهای حوزه هوش مصنوعی است که به جهت کاربردهای متفاوت آن در مدل بندی مسائل علم و فناوری، موردن توجه قرار گرفته و گرایش‌های متفاوتی از علوم را به خود وابسته نموده است. در یادگیری عمیق طراح شبکه عصبی با عمیق کردن شبکه یا به عبارت بهتر، اضافه کردن لایه‌های پنهان به شبکه آن را قادر به یادگیری الگوریتم‌های پیچیده‌تر و دریافت حجم عظیمی از داده‌ها می‌کند.

هر مدل یادگیری عمیق به صورت کلی مشکل از لایه ورودی، لایه پنهان و لایه خروجی می‌باشد. در هر لایه، بسته به نوع مسئله تعدادی نورون قرار می‌گیرد که در هسته هر نورون توابع پله‌ای و یا تابع فعال‌ساز قرار داده می‌شود [۱۶]. در مدل یادگیری عمیق با رفتمن از هر لایه به لایه دیگر جمع وزن دار مجموعه نورون‌های لایه قبل محاسبه و با اعمال یک تابع فعال‌ساز غیرخطی به لایه دیگر منتقل می‌شوند؛ اما اینکه چگونه هر وزن باید تغییر کند کمی دشوار است، این بدان معنی است که خطای به دست آمده در خروجی لایه نهایی می‌تواند ناشی از نورون‌های لایه آخر و همچنین نورون‌های لایه‌های قبلی باشد که توسط الگوریتم پس انتشار سهم خطای هر نورون در هر لایه مشخص و فرآیند به روزرسانی وزن‌ها تا رسیدن به بهترین ضرایب ادامه می‌یابد [۱۷]. از مفاهیم اصلی در فرآیند یادگیری در شبکه‌های عمیق، بهینه‌سازی الگوریتم‌های تابع خطای می‌باشد که توسط فرآیندی به نام گرادیان کاوشی انجام می‌پذیرد [۱۸]. پیش‌شرطی سازی مؤثر با گرادیان کاوشی به معنای انتخاب نرخ یادگیری متفاوت برای هر متغیر است، این امر سبب می‌گردد تا بهینه‌سازها با روش‌های بهتری با توجه به نوع مسئله در نظر گرفته شوند که می‌توان به بهینه‌سازهای تصادفی، پویا و تطبیقی اشاره کرد [۱۹]. شایان توجه است که جهت مدل‌سازی از داده‌های موجود در ادبیات تحقیق که در جدول ۱ ارائه شده، استفاده گردیده است.

آزمایشی که مدل بر اساس آن‌ها تعلیم ندیده و کاملاً برای شبکه جدید هستند ارزیابی می‌گردد که منجر به ارزیابی واقعی و دقیق‌تر مدل خواهد شد [۱۶-۱۹]. در این مقاله، تلاش گردیده تا با استفاده از یادگیری عمیق و ایجاد یک مدل شبکه عصبی در راستای بهبود میزان دقت و شاخص‌های ارزیابی خطأ، پاسخ ورق‌های تک لایه فلزی دایره‌ای تحت بارگذاری شدید دینامیکی یکنواخت مورد پیش‌بینی قرار گرفته و با روش‌های سنتی و تحلیلی موجود در سوابق تحقیق مقایسه گردد [۲۰-۴۵]. داده‌های موجود در ادبیات تحقیق از ۴ نوع فلز فولاد، آلومینیوم، تیتانیوم و مس که سهم هر کدام به ترتیب ۵۸۱ عدد از ۱۳، ۷۰، ۴۸۶ و ۸۴ مداده موجود در مجموعه داده می‌باشد، تشکیل شده است. هر داده دارای ۸ ویژگی شامل میزان نیروی واردشده بر ورق، ضخامت ورق، شعاع ورق، مقاومت استاتیکی ورق، چگالی ورق، کمیت‌های مربوط به حساسیت ماده به نرخ کرنش و همچنین یک برچسب تحت عنوان میزان خیز دائمی ورق می‌باشد.

۲- هوش مصنوعی و استفاده از داده‌های تجربی

کار با داده‌ها پس از گسترش مدل‌های هوشمند در میان محققان و تحلیلگران دچار تغییرات زیادی شد. دیگر منابع ذخیره‌سازی اطلاعات، گنجایش داده‌های تولیدی روزافزون را نداشتند و مدل‌های مبتنی بر ریاضیات کلاسیک توانایی پردازش و کار با حجم عظیم داده‌ها را از دست دادند. در اینجا نقش‌آفرینی پدیده نوظهور حوزه تکنولوژی و کامپیوتر یعنی هوش مصنوعی در کنار پردازنده‌های گرافیکی در پردازش داده‌ها آشکار می‌شود. جایی که روابط تحلیلی سنتی در تخمین و پردازش داده‌هایی که نیاز به هزاران پارامتر در معادلات خود را دارند قادر به پاسخگویی نخواهند بود. حتی در خوش‌بینانه‌ترین حالت اگر رابطه‌ای تحلیلی برای تخمین و پردازش داده‌های خود بیابیم، زمان عملکرد الگوریتم وجه تمایز اصلی میان روش‌های هوشمند امروزی با مدل‌های کلاسیک گذشته خواهد بود. اگرچه امروزه با افزایش داده‌های ورودی در طراحی مدل‌های مبتنی بر هوش مصنوعی با مشکلاتی از قبیل افزایش بیش از حد پارامترها، اشباع شبکه و افزایش پیچیدگی محاسباتی مواجه خواهیم شد اما می‌توان با استفاده از شبکه‌های عصبی کانولوشنی تا حد بسیار زیادی از

جدول (۱): جمع‌آوری نتایج تجربی موجود در ادبیات تحقیق.

| محدوده ایمپالس (N·s) | محدوده بیشترین خیز (mm) | تنشی تسلیم (Mpa) | ضخامت ورق (mm) | قطر ورق (mm) | تعداد آزمایش | سال تحقیق | مرجع |
|----------------------------|-------------------------------|---------------------|-------------------|-----------------|-----------------|--------------|------|
| ۱۱۳/۰-۲۴/۲ | ۴۲/۷-۲/۴ | ۲۹۰ و ۵۴۵ | ۶/۴ و ۶/۱ | ۲۰۰ | ۴۲ | ۱۹۶۶ | [۲۰] |
| ۱۳۷/۶-۳۲/۲ | ۲۸/۳-۳/۸ | ۲۹۰ و ۲۸۳ | ۶/۴ و ۶/۲ | ۲۰۳ | ۳۰ | ۱۹۷۰ | [۲۱] |
| ۷/۲-۰/۹۱ | ۱۲/۷-۰/۸ | ۲۵۱ و ۲۲۳ | ۲/۳ و ۱/۹ | ۶۴ | ۲۰ | ۱۹۷۹ | [۲۲] |
| ۱۵/۶-۵/۶ | ۱۹/۸-۶/۱ | ۲۸۲ | ۱/۶ | ۱۰۰ | ۲۱ | ۱۹۸۹ | [۱۵] |
| ۲۹/۲-۴/۸ | ۳۰/۱-۳/۷ | ۲۶۴ | ۱/۶ | ۱۰۰ | ۹ | ۱۹۹۱ | [۲۳] |
| ۲۲/۰-۴/۶ | ۲۷/۹-۴/۶ | ۲۷۰ | ۱/۶ | ۱۰۰ | ۱۴۲ | ۱۹۹۴ | [۲۴] |
| ۱۶/۳-۴/۶ | ۲۰/۹-۵/۶ | ۲۶۲ | ۲/۰-۱/۵ | ۱۰۰ | ۲۰ | ۱۹۹۵ | [۲۵] |
| ۳۰/۹-۱/۴ | ۳۴/۳-۲/۷ | ۲۹۰ | ۱/۶ و ۱۰۰، ۸۰، ۶۰ | ۱۲۰ | ۱۱۴ | ۱۹۹۶ | [۲۶] |
| ۱۶/۵-۵/۲ | ۲۰/۴-۷/۳ | ۲۵۵ | ۱/۶ | ۱۰۰ | ۷ | ۱۹۹۶ | [۲۷] |
| ۳۳/۵-۹/۶ | ۱۹/۰-۵/۴ | ۲۴۰ | ۱/۹ | ۱۰۶ | ۴۸ | ۲۰۰۷ | [۱۴] |
| ۲۹/۰-۵/۴ | ۱۸/۶-۰/۵ | ۲۶۱ | ۲/۰ | ۱۰۶ | ۲۵ | ۲۰۰۷ | [۴۵] |
| ۳۴/۶-۵/۲ | ۲۶/۳-۳/۲ | ۲۷۷، ۲۰۱، ۱۰۲ و ۳۱۸ | ۲/۰، ۱/۶ و ۳/۰ | ۱۰۰ | ۴۲ | ۲۰۱۰ | [۲۸] |
| ۲۴/۳-۱۷/۴ | ۳۳/۸-۱۲/۷ | ۲۱۵ | ۳/۰ | ۱۷۰ | ۷ | ۲۰۱۱ | [۲۹] |
| ۵۹/۸-۱۱/۹ | ۱۷/۷-۱/۳ | ۷۵۰ | ۳/۰ و ۲/۰ | ۱۰۶ | ۱۳ | ۲۰۱۴ | [۳۰] |
| ۵۱/۶-۴/۱ | ۳۵/۸-۶/۱ | ۲۸۹ | ۲/۰ و ۱/۰ | ۱۲۰ | ۱۵ | ۲۰۱۵ | [۳۱] |
| ۲۱/۷-۶/۵ | ۱۶/۱-۶/۶ | ۳۵۰ و ۱۱۰ | ۳/۰ و ۲/۰ و ۶/۰ | ۱۰۰ | ۲۶ | ۲۰۲۰ | [۳۲] |

می‌گیرد. از شاخص‌های ارزیابی خطأ در مسائل مبتنی بر رگرسیون که بیانگر کیفیت عملکرد برآوردگر است (شکل ۱)، میانگین مربعات خطأ و ضریب تعیین می‌باشد که نحوه محاسبه آن به ترتیب به صورت روابط (۴) و (۵) است [۳۴].

$$MSE(y, \hat{y}) = \frac{1}{n} \left(\sum_{i=1}^n (y_i - \hat{y}_i) \right)^2 \quad (4)$$

$$R^2 = 1 - \frac{SSR}{SST} = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$

در رابطه (۵) همان‌طور که در ادامه رابطه بسط داده شده است، منظور از SSR مجموع مربعات خطأ به ترتیب بین مقدار

۲-۲- رگرسیون در یادگیری عمیق

رگرسیون یک فرآیند آماری است که رابطه‌ی معناداری بین متغیرهای وابسته و مستقل پیدا می‌کند [۳۳]. الگوریتم‌های رگرسیون برای پیش‌بینی مقادیر پیوسته استفاده می‌شوند و هدف در این مدل بندی جستجوی ضرایب بهینه جهت رسیدن به بهترین پیش‌بینی کننده می‌باشد که نماینده خوبی برای داده‌ها است. در مسائل مربوط به شبکه‌های عصبی عمیق، ابعاد بسیار بالاتر برای متغیرهای مستقل و نیاز به محاسبات پیچیده جهت تعیین ضرایب بهینه مورد توجه قرار

$$\rho_{X,Y} = \frac{\text{cov}(X, Y)}{\sqrt{\text{var}(X)}\sqrt{\text{var}(Y)}} = \frac{E[(X - \mu_X)(Y - \mu_Y)]}{\sigma_X \sigma_Y} \quad (6)$$

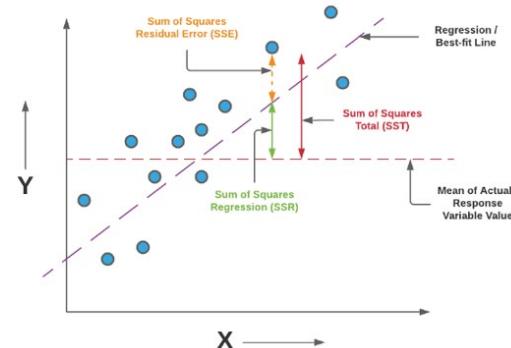
که در رابطه بالا منظور از E اميد رياضي، μ ميانگين دادهها به ازاي هر متغير تصادفي و σ انحراف معيار به ازاي هر متغير تصادفي است.

ضرير همبستگي، شاخصی در بازه ۱-۱ میباشد. هرگاه ميزان شاخص به ۱ یا ۱- نزديکتر شود همبستگي ميان دو متغير بيشتر است. علامت مثبت و منفي بيانگر جهت رابطه و همبستگي ميان دو متغير است به گونه‌ای که اگر علامت ضرير همبستگي منفي باشد بيانگر آن است که رابطه بين دو متغير معكوس يكديگر است و هرگاه مثبت باشد آن دو متغير باهم همبستگي مستقييم دارند يعني با افزایش مقدار يك متغير، ميزان متغير ديگر نيز با همان نسبت افزایش خواهد يافت. اين شاخص به صورت درصد هم بيان میشود.

ضرير همبستگي در يادگيري ماشین شاخص و معياری ارزشمند جهت تشخيص ميزان همبستگي ميان ويزگي‌هاي موجود در مجموعه داده میباشد. بر اساس اين شاخص طراح شبکه میتواند رفتار داده‌هاي خود را بررسی و بر اساس ميزان تأثير هر کدام از ويزگي‌ها بر متغير خروجي شبکه يا برچسب آن‌ها را تغيير دهد و يا گاهی حذف کند و همچنین چگونگی عملکرد شبکه را بر اساس ميزان اين شاخص تفسير کند. شایان ذكر است هر چه ميزان همبستگي ميان ويزگي‌ها به صورت دوبهدو و بهخصوص ميان هر ويزگي با برچسب بيشتر باشد عملکرد شبکه بهتر و تأثير ويزگي‌ها در پيش‌بياني مقدار دقيق‌تر برچسب خروجي از شبکه بيشتر است. در تحقيق پيش رو ميزان ضرير همبستگي ميان ويزگي‌هاي موجود در مجموعه داده به صورت دوبهدو محاسبه و به صورت شكل ۲ گزارش میشود. همان‌گونه که پيداست قطر اصلی اين ماتريس ۱ میباشد زيرا هر ويزگي با خودش داراي ضرير همبستگي حداکثری با مقدار ۱ است.

پيش‌بياني شده هر داده توسط مدل و مقدار ميانگين مقادير واقعی داده‌ها میباشد. همچنین منظور از SST مجموع مربعات خطأ به ترتيب بین مقدار واقعی هر داده و ميانگين داده‌هاي واقعی میباشد.

يکي از مباحث مهم و مرسوم در تعليم مدل‌های مبتنی بر شبکه‌ی عصبی، استفاده از شبکه‌های بزرگ آموزش‌دیده و ارائه‌شده توسط شرکت‌های بزرگ فعال در حوزه‌ی صنعت ديجيتال جهت شخصی‌سازی آن‌ها با داده‌های مورد‌نظر کاربر است. يکي از چالش‌های موجود در مدل‌سازی شبکه‌ی عصبی ارائه‌شده در اين تحقيق على رغم تلاش‌های صورت گرفته، عدم دسترسی به شبکه‌ای مناسب از نوع رگرسیون و سازگار با داده‌های موجود در مجموعه‌ی داده جهت افزایش کارایی مدل در برخورد با طيف وسیعی از فلزات دیگر بود. ازین‌رو ایجاد يك معماری جديد مبتنی بر مسئله رگرسیون و سازگار با داده‌های محدود موجود از پایه انجام شد.



شکل (۱): شاخص‌های ارزیابی خط رگرسیون.

۳-۲- ضرير همبستگي

اغلب بيان همبستگي ميان دو متغير تصادفي بر اساس شاخص کوواریانس مشهور میباشد اما مشکل اين شاخص وابستگي به واحد اندازه‌گيری متغيرها است، همين دليل مبنائي بر استفاده از شاخص ارزیابی ديگري به نام ضرير همبستگي شد که واحدی نداشته و ببعد میباشد. ضرير همبستگي ميان دو متغير تصادفي X و Y به شكل زير محاسبه میشود:



شکل (۲): میزان همبستگی میان ویژگی‌های ورق

افتادن در کمینه‌های محلی یا موضعی است. این تهدید سبب پیدایش و ارائه الگوریتم‌های بهینه‌ساز پیشرفته و جدید همچون آدادلتا، آداگراد، آرم اس پرایپ و آدام شد. در واقع آنچه وجه تمایز میان این الگوریتم‌ها می‌باشد، تفاوت در تعیین نرخهای یادگیری و فراپارامترهای درون روابط بوده است. در واقع دانشمندان الگوریتم‌ها را به سوبی هدایت کرده‌اند که با هر گام و هر مرتبه اعمال الگوریتم گرادیان کاهشی مدل اندازه گام خود را به صورت یکسان انتخاب نکند و در هر مرحله با توجه به سوابق گرادیان در گام‌های قبل و تابع هدف مسئله گام خود را تغییر دهد تا در حداقل‌های موضعی به دام نیفتند (شکل ۳). عبارت ساده (۷) تابع خطرا به صورت یک معادله نشان می‌دهد.

$$Loss = y - \hat{y} \quad (7)$$

که در آن به ترتیب y و \hat{y} مقادیر واقعی و پیش‌بینی شده توسط شبکه هستند. رابطه (۸) عملکرد الگوریتم گرادیان کاهشی روی تابع خطرا، در به روزرسانی ضرایب شبکه را نمایش می‌دهد. در این رابطه، منظور از m تعداد داده‌ها، $(x^{(i)}, h_w(x^{(i)}))$ مقدار واقعی یا تابع مدل برآورد کننده به ازای ورودی i ، $y^{(i)}$ مقدار واقعی یا تجربی داده و η نرخ یادگیری الگوریتم می‌باشد.

۴-۲- گرادیان کاهشی

نحوه اصلاح وزن‌ها در یک شبکه عصبی مصنوعی تا رسیدن به بهترین برآورد کننده داده‌ها بر اساس فرآیند بهینه‌سازی صورت می‌پذیرد. در واقع یک شبکه عصبی مصنوعی با تعیین تابع خطا به عنوان تابع هدف آن را تا یافتن حداقل مطلق کمینه می‌کند. این کمینه‌سازی به وسیله الگوریتم گرادیان کاهشی که در برابر روش‌های مشابه دیگر همچون معادله نرمال هزینه محاسباتی کمتر و در برابر داده‌های با حجم بالا سرعت و دقت بالاتری دارد انتخاب می‌شود. در یادگیری ماشین الگوریتم گرادیان کاهشی با داده‌ها با سه رویکرد برخوردار می‌کند. رویکرد متداول گرادیان کاهشی تصادفی ریز دسته‌ای می‌باشد، در این شیوه داده‌ها به دسته‌بندی‌های متعدد تقسیم‌بندی می‌شود و با دریافت هر دسته فرآیند به روزرسانی انجام می‌پذیرد که تا حد امکان مشکلات اشاره‌شده در شیوه‌های قبلی را بطرف می‌کند. این رویکرد در کتابخانه‌های زبان پایتون به عنوان پیش‌فرض تنظیم و عمل می‌کند که در این شبکه نیز از آن استفاده شده است. در الگوریتم گرادیان کاهشی همان‌گونه که به صورت گذرا به آن اشاره شد، مشکل و خطری که مدل ما را تهدید می‌کند، گیر

۶-۲-تابع فعال‌ساز لیکی رلو

تابع فعال‌ساز در هر نورون مصنوعی اگر سیگنال‌های دریافتی اصطلاحاً به حد آستانه رسیده باشند، سیگنال‌های خروجی را برای نورون بعدی ارسال می‌کند. درواقع تابع فعال‌ساز تصمیم می‌گیرد که یک نورون باید فعال شود یا خیر. یک شبکه عصبی مصنوعی در یادگیری عمیق بدون وجود تابع فعال‌ساز یک مدل رگرسیون خطی ساده است به این دلیل که این توابع محاسبات غیرخطی را در ورودی یک شبکه عصبی مصنوعی انجام می‌دهند و آن را قادر به یادگیری و انجام وظایف پیچیده‌تر می‌کنند؛ بنابراین انتخاب تابع فعال‌ساز مناسب که بتواند غیرخطی بودن و دقت را یک مدل شبکه عصبی ارائه دهد حائز اهمیت می‌باشد. استفاده از توابع فعال‌ساز خانواده رلو مشکل محو گرادیان را تا حد زیادی بهبود می‌دهد اما دونقطه ضعف این توابع، عدم مشتق‌پذیری در نقطه صفر و همچنین تولید مقدار صفر یا ایجاد نورون مرده به ازای مقادیر منفی است. برای حل این مشکل در مقاله‌ای در سال ۲۰۱۰ تابع جدیدتری از جمله لیکی رلو ارائه شدند که مشکلات تابع رلو را برطرف کرد.

تابع فعال‌ساز سیگموید و تانژانت هایپربولیک را به دلیل مشکل محو گرادیان نمی‌توان در شبکه‌هایی با لایه‌های زیاد به کار برد. تابع فعال‌ساز لیکی رلو که محبوب‌ترین انتخاب در یادگیری عمیق (در لایه پنهان) است بر مشکل محو گرادیان غلبه می‌کند و به شبکه اجازه می‌دهد سریع‌تر یادگیرید و عملکرد بهتری داشته باشد. ضابطه تابع لیکی رلو به صورت $\text{ReLU}(x) = \max(0.1x, x)$ تعریف می‌گردد (شکل ۴). همچنین در این تابع به سبب در نظر گرفتن ضربی به عنوان a ، مشکل ایجاد نورون مرده به ازای ورود اعداد منفی برای تابع رفع گردید.

۸-۲-مدل‌سازی مسئله با شبکه عصبی

مسئله پیش رو در این مقاله از نوع یادگیری با ناظر و رگرسیون می‌باشد. جهت طراحی شبکه عصبی عمیق این مقاله، ابتدا بانک اطلاعاتی شامل مجموعه داده با ۵۸۱ نمونه که حاصل از ۱۶ سری آزمایش بین سال‌های ۱۹۶۶ تا ۲۰۲۰ بوده و شامل ۸ ویژگی می‌باشد را به عنوان داده اصلی در نظر

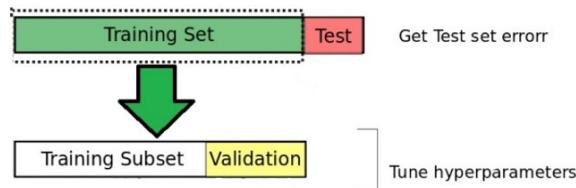
$$\begin{aligned} J(W) &= \frac{1}{2m} \sum_{i=1}^m (h_w(x^{(i)}) - y^{(i)})^2 \\ w_{\text{new}} &= w - \eta \frac{\partial J(W)}{\partial w} \\ &= w - \eta \\ &\cdot [2x(wx + b - y)] \end{aligned} \quad (8)$$

شکل (۳): طرح‌واره شبکه عصبی عمیق.

۲-۵-الگوریتم بهینه‌ساز مدل (آدام)

بر اساس آنچه تابه‌حال بررسی کردیم دریافتیم که گرادیان کاهشی تصادفی در حل مسائل بهینه‌سازی از گرادیان کاهشی مؤثرتر است، به عنوان مثال، به دلیل انعطاف‌پذیری ذاتی آن در برابر داده‌های اضافی. همچنین گرادیان کاهشی ریز دسته‌ای با استفاده از مجموعه‌های بزرگ‌تری از مشاهدات در یک ریز دسته، کارایی اضافی قابل توجهی را نسبت به گرادیان کاهشی تصادفی ارائه می‌دهد. رویکرد پیشرفت عملکرد الگوریتم‌های بهینه‌ساز، وابسته به گرادیان‌های طی کرده در گام‌های گذشته و میزان اهمیت آن‌ها برای برداشتن گام بعدی در جهت همگرایی سریع و دقیق‌تر است. آدام ارائه شده در سال ۲۰۱۴ توسط کینگما [۳۵] تمام ایده‌های مطرح شده در سیر تکامل الگوریتم‌های بهینه‌ساز برای تجمیع تاریخچه گرادیان‌های گذشته و اعمال مربع گرادیان برای تسريع همگرایی و مقیاس بندی هر مختصات جهت ایجاد یک پیش‌شرط محاسباتی کارآمد را در نظر گرفت. اگرچه الگوریتم آدام عاری از مشکل نیست و بهبودهایی بر آن ارائه شد اما تا به امروز محبویت خود را در میان طراحان شبکه‌های عصبی از دست نداده و همچنان کلید حل مسائل دشوار یادگیری ماشین است که در مدل ارائه شده در این تحقیق نیز به عنوان الگوریتم بهینه‌ساز شبکه تعریف گردید.

داده‌ها، بررسی داده‌های پرت و همبستگی میان ویژگی‌های داده، جلوگیری از ایجاد بیش برآذش، تغییر در تعداد لایه‌های مخفی، نورون‌ها و تعداد تکرار شبکه است که در مجموع بر اساس جمع‌بندی نتایج مدل ارائه شده شامل مشخصات جدول ۲ می‌باشد.



شکل (۵): شبیه‌سازی نحوه تقسیم‌بندی داده‌ها.

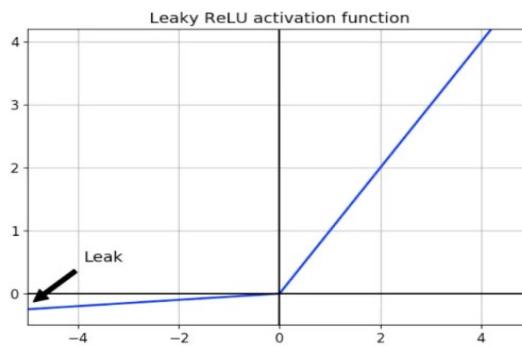
جدول (۲): معماری مدل شبکه‌ی عصبی.

| تعداد یا نوع | نوع فرایانتر |
|---|--------------------------------|
| ۱۰ | تعداد لایه‌های مخفی |
| تعداد نورون‌های مورداستفاده در ۱۰۰، ۵۰، ۲۰ و ۱۰ | لایه‌های مخفی |
| لیکی رلو | نوع تابع فعال‌ساز |
| ۰/۱ | ضریب لیک در تابع فعال‌ساز |
| میانگین مربعات خطا | تابع هدف یا خطای مدل |
| خطای جذر میانگین مربعات، ضریب تعیین و زمان حل | شاخص‌های ارزیابی مدل |
| ۷۰۰ | تعداد تکرار |
| آدام | الگوریتم بهینه‌ساز |
| ۰/۰۰۰۱ | نرخ یادگیری الگوریتم بهینه‌ساز |

۲-۳- فرآیند آموزش و ارزیابی مدل

عموماً در شبکه‌های عصبی عمیق فرآیند آموزش و ارزیابی به صورتی به کار می‌رود که به ما اجازه دهد در هر مرحله از فرآیند آموزش، میزان تمایز بین مقدار پیش‌بینی مدل با مقدار واقعی را مشخص کرد. یکی از متداول‌ترین روش‌ها به این صورت است که قسمتی از داده را به عنوان داده تست در نظر گرفته می‌شود و مدل تا انتهای آموزش به آن دسترسی ندارد. داده‌های آموزشی در هر مرحله به چند قسمت تقسیم می‌شوند و یک قسمت آن به عنوان داده‌ی ارزیابی و مابقی

گرفته شد. تمام ویژگی‌ها از نوع عددی و عاری از داده‌های نول می‌باشند. مجموعه داده به صورت فایل CSV با استفاده از کتابخانه پانداز فراخوانی شده است. توزیع آماری داده‌ها، استخراج شاخصه‌های آماری و تشخیص داده‌های پرت توسط کتابخانه پانداز انجام گرفته است. شبکه طراحی شده از نوع سکوئنشال می‌باشد. تمامی داده‌های ورودی به شبکه با استفاده از کتابخانه سایکیت-لرن در زبان برنامه‌نویسی پایتون استاندارد سازی شده‌اند. جهت ذخیره‌سازی و تعیین بهترین وزن‌های شبکه از کال بک modelcheckpoint استفاده شده است.



شکل (۴): تابع لیکی رلو.

۳- نتایج و بحث

در فرآیند پردازش مجموعه‌ی داده، در گام اول تعداد داده‌ها جهت یادگیری مدل ۴۹۳ عدد معادل ۸۵ درصد از کل مجموعه‌ی داده انتخاب شد و ۸۸ داده‌ی باقی‌مانده به عنوان داده‌های آزمایشی تعیین شد. سپس ۵۰ داده معادل ۱۰ درصد از داده‌های تعیین شده جهت یادگیری شبکه را به عنوان داده‌های ارزیاب انتخاب شد. در انتهای، ۴۴۳ عدد داده جهت آموزش به مدل به عنوان داده‌ی آموزشی، وارد شبکه گردید و به وسیله‌ی ۸۸ داده‌ی آزمایشی عملکرد مدل ایجاد شده ارزیابی شد (جدول ۱ و شکل ۵).

۳-۱- معماری شبکه

معماری شبکه عصبی عمیق ارائه شده نتیجه بررسی تعداد زیادی از گونه‌های مختلف توابع فعال‌ساز، اعمال شیوه‌های مختلف در وزن دهی اولیه به لایه‌ها، تغییر در میزان نرخ یادگیری الگوریتم بهینه‌ساز، شیوه‌های مختلف مقیاس کردن

آن تعریف کرد. گریدسرج سیوی با جستجوی تمام شبکه‌های قابل تعریف با فراپارامترهای تعیین شده مناسب‌ترین شبکه را با توجه به میزان دقت و خطای داده‌های ارزیاب پیشنهاد می‌دهد و طراح شبکه با مشاهده آن می‌تواند کران و بازه‌ی مناسبی برای تعداد فراپارامترهای بهینه مدل انتخاب کند. در مدل پیش رو با بهره‌مندی از این امکان، بازه‌ی مناسب برای هایپرپارامترهای مدل به صورت نرخ یادگیری در بازه اطراف عدد ۱۰۰۰۰، تعداد نورون‌ها در حدود ۱۰۰ عدد و تعداد لایه‌های مخفی بین ۵ تا ۱۰ عدد ارائه شد. مدل ارائه‌شده‌ی این تحقیق با جستجو از میان فراپارامترهای پیشنهادی گریدسرج سیوی و بررسی ویژگی‌های آماری و پیشینه داده‌ها در ادبیات تحقیق انتخاب گردیده است. همچنین در این مدل از کال بک که ابزاری جهت ذخیره‌سازی پارامترهای شبکه در حین اجرا و در مراحل مختلف پردازش شبکه می‌باشد، استفاده شده است.

یکی از انواع کال بک‌ها Modelcheckpoint است که هدف آن، ذخیره‌سازی وزن‌های مدل بعد از هر تکرار و خواندن داده‌های ورودی می‌باشد. این رویکرد جهت ذخیره‌سازی وزن‌ها و پارامترهای تعیین شده در مدل در مقابل مشکلات فنی احتمالی در هنگام فرآیند پردازش شبکه که ممکن است ساعتها یا حتی دقایقی به طول انجامد ارائه گردیده است اما آنچه حائز اهمیت است، استفاده از ابزار پرکاربرد restore_best_weights جهت شناسایی بهترین و بهینه‌ترین پارامترها تا هر مرحله از آموزش شبکه برای دریافت، ذخیره‌سازی و فرآخوانی مدل آموزش دیده می‌باشد.

۴-۳- کارایی مدل

فرآیند اجرا و تعلیم شبکه با استفاده از پردازنده گرافیکی در حدود کمتر از ۳ دقیقه به طول انجامید. مدل ارائه‌شده‌ی تحقیق از میان ۸۸ داده‌ی آزمایشی، ۷۶ درصد از داده‌ها معادل ۶۷ عدد را در بازه خطای کمتر از ۱۰ درصد پیش‌بینی کرد که با توجه به محدودیت تعداد داده‌های موجود در پایگاه داده و ترکیب ۴ نوع فلز مختلف قابل توجه است. همچنین این مدل توانست ۸۸ درصد از داده‌ها معادل ۷۸ عدد را در بازه خطای کمتر از ۲۰ درصد پیش‌بینی کند. لازم به ذکر است داده‌های این تحقیق توسط الگوریتم‌های سنتی یادگیری

به عنوان داده آموزشی انتخاب می‌شوند و پس از آموزش مدل، شاخص‌های ارزیابی محاسبه می‌گردد. در مرحله‌های بعدی آموزش، این داده‌های ارزیابی تغییر می‌کنند و بخش دیگری از داده‌ی آموزشی به عنوان داده ارزیابی انتخاب شده و این روند پیگیری می‌شود تا مشاهده گردد که فرآیند آموزش به چه سمتی پیش می‌رود و مدل دچار بیش برازش در آموزش نگردد. در فرآیند آموزش مدل، از محیط برنامه‌نویسی پایتون با استفاده از کتابخانه تنسور فلو و رابط برنامه‌نویسی کراس [۳۶] استفاده گردیده است. در این مدل با توجه به اینکه تعداد داده‌های موجود در ادبیات تحقیق زیاد نمی‌باشد، تمامی داده‌ها را به صورت یک باره به مدل ارائه و از ریز دسته کردن داده‌ها اجتناب شده است.

نتایج ارائه شده در این پژوهش به دو بخش کلی تقسیم می‌گردد. بخش اول به چالش جستجوی معماری شبکه می‌پردازد که در آن موارد مختلف یک شبکه اعم از تعداد لایه‌ها، تعداد نورون‌ها، توابع فعال‌ساز و توابع بهینه‌ساز و سایر فراپارامترها مورد بررسی قرار گرفته و با توجه به شاخص‌های ارزیابی بهترین معماری مدل انتخاب می‌گردد. در بخش دوم با توجه به اینکه آزمایش و جمع‌آوری داده‌های تجربی در سالیان مختلف و توسط افراد متفاوت انجام پذیرفته است، این نتایج با پیش‌بینی‌های مدل مورد مقایسه قرار گرفته است. شایان ذکر است، روش‌های متفاوتی اعم از روابط تحلیلی و کلاسیک ریاضیاتی نیز اقدام به این پیش‌بینی‌ها نموده است. در اینجا بهبود عملکرد این مدل را در مقایسه با این تلاش‌ها سنجیده و میزان دقت بالای آن مورد بررسی قرار داده شده است.

۳-۳- شناسایی فراپارامترها

قاعده‌تاً طراح شبکه برای ایجاد شبکه‌ای مناسب و بهینه نیاز به بررسی و مشاهده شبکه‌های ایجاد شده از مجموعه مختلفی از فراپارامترها همچون نرخ یادگیری، تعداد نورون‌ها، تعداد لایه‌های مخفی و... را دارد تا بر اساس آن‌ها گزینه‌ی مناسب برای مجموعه داده‌ها را ارائه دهد. گریدسرج سیوی از کتابخانه سایکیت-لرن در دسترس است و با تلفیق آن به وسیله رپرزا کتابخانه کراس می‌توان برای مدل طراحی شده کلاسی ایجاد و فراپارامترهای وابسته به عملکرد شبکه را در

نمونه‌های آموزشی صورت نگرفته است. همچنین طیف خاصی از فلزهای یکسان برای سنجش عملکرد مدل به کار نرفته و از میان انواع فلزات موجود در فرآیند آموزش شبکه نمونه آزمایشی در میان داده‌های تست وجود دارد. شکل ۸ گویای این دو ادعا است.

در شبکه طراحی شده نشانه و شاخصی مبنی بر وقوع بیش برآراش و کم برآراش مدل دریافت نکردیم و سیر نزولی و مشابه دو نمودار خطای آموزشی و آزمایشی در شکل ۹ گویای این ادعا است.

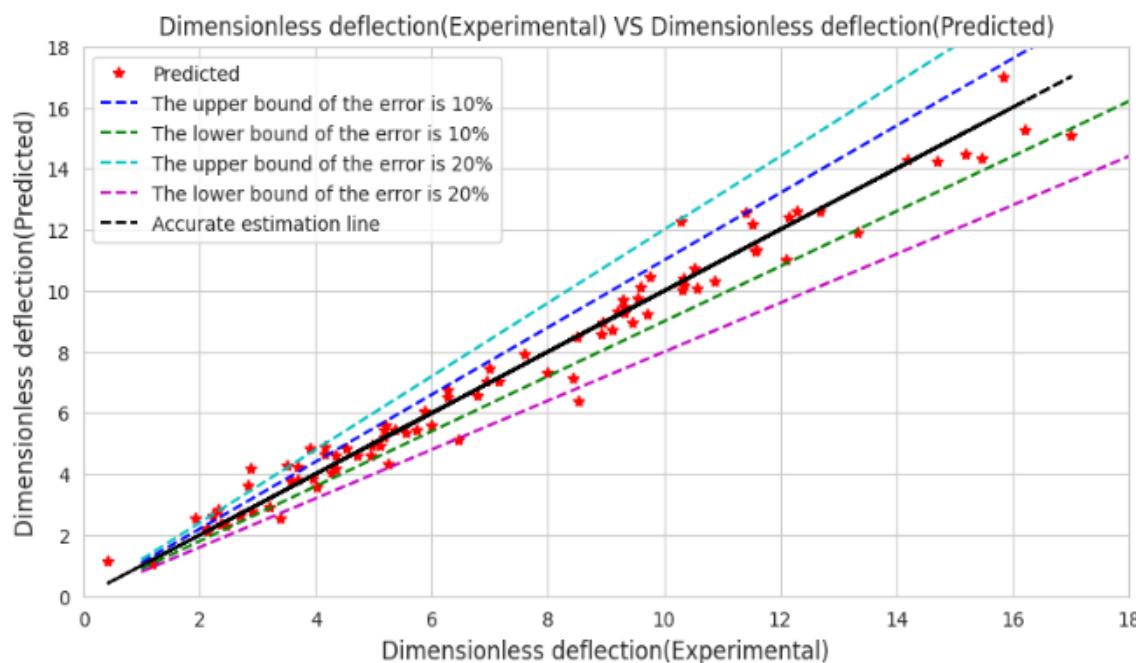
همچنین مقایسه‌ی تصویری میزان دقت و خطای شبکه در پیش‌بینی میزان خیز به ازای ضخامت آن ورق در شکل ۱۰ نشان داده شده است.

میزان پراکندگی و توزیع داده‌های آزمایشی و آموزشی به ازای خیز ورق نیز به صورت دو شکل ۱۱ و ۱۲ قابل مشاهده است که تصادفی بودن انتخاب داده‌های آزمایشی نسبت به داده‌های آزمایشی را با وضوح بیشتری نشان می‌دهد.

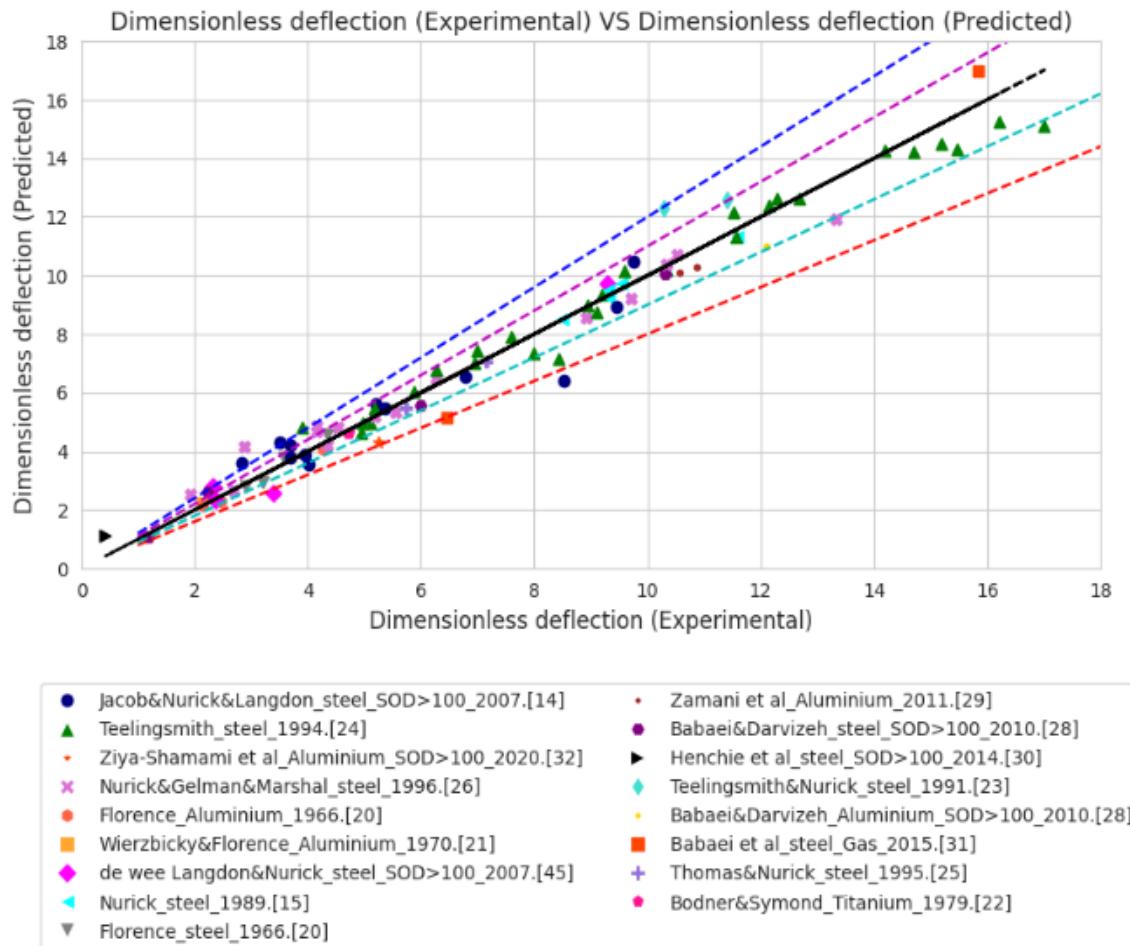
ماشین نیز بررسی شد که نتیجه مناسب را در برنداشت و استفاده از شبکه عصبی عمیق به دلیل عملکرد نسبتاً ضعیف مدل‌های سنتی یادگیری ماشین و کاربرد آن در پردازش داده‌های با حجم بالا در نظر گرفته شد.

در شکل ۶ میزان خیز دائمی ورق بر اساس مقدار واقعی موجود حاصل از انجام آزمایش‌های تجربی و مقدار پیش‌بینی شده توسط مدل نمایش داده شده است که داده‌های قرار گرفته روی خط سیاهرنگ نمایانگر برآبری مقدار واقعی و پیش‌بینی شده توسط مدل می‌باشد و پراکندگی داده‌های اطراف خط سیاهرنگ میزان اختلاف میان مقدار پیش‌بینی شده و مقدار واقعی را نشان می‌دهد. گاهی عملکرد یک شبکه و میزان دقت آن در پیش‌بینی‌ها می‌تواند وابسته به خطای موجود در انجام آزمایش‌های تجربی و تولید داده‌ها باشد که اجتناب‌ناپذیر است. در این‌گونه موارد می‌توان یا تفکیک داده‌های خروجی شبکه و بررسی مراجع و شیوه‌ی تولید آن داده تحلیلی دقیق‌تر از عملکرد و دقت شبکه داشت (شکل ۷).

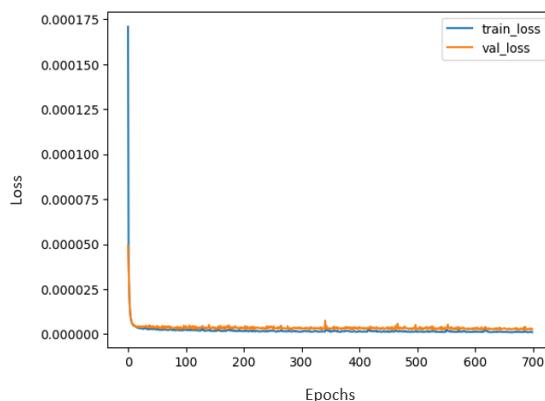
داده‌های آموزشی و آزمایشی در این مدل دارای توزیع همسان بوده و تجمعی داده‌های آزمایشی در ناحیه‌ی خاصی از



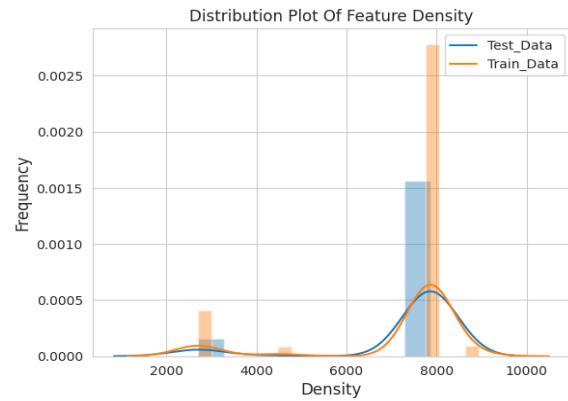
شکل (۶): پراکندگی میزان خیز ورق در محدوده خطای ۱۰ و ۲۰ درصد.



شکل (۷): پراکندگی میزان خیز ورق در محدوده خطای ۱۰ و ۲۰ درصد با ذکر مرجع.



شکل (۹): نمودار خطای شبکه به ازای داده‌های آموزشی و ارزیاب بر حسب تعداد تکرار الگوریتم.



شکل (۸): فراوانی داده‌های آزمایشی و آموزشی بر حسب چگالی.

شیوه‌ی محاسبه‌ی آن ارائه شد، وجود دارد و در مدل طراحی شده در این تحقیق مقادیر جدول ۳ را به خود اختصاص داده‌اند. جدول ۴ مقایسه‌ی میزان شاخص خطای خطای جذر میانگین مربعات را به ازای نتایج حاصل از مدل‌های موجود در ادبیات تحقیق نشان می‌دهد که در مطالعه‌ی حاضر این شاخص بیش از ۱۰۰ برابر نسبت به آخرین میزان خطای به دست‌آمده در سال ۲۰۲۰ کاهش پیدا کرد.

جدول (۳): شاخص‌های ارزیابی مدل.

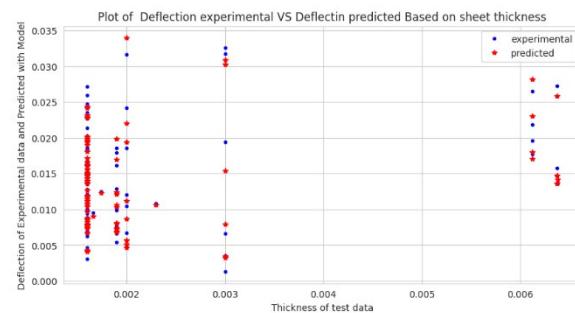
| | |
|--------|-------------------------|
| ۰/۹۶ | ضریب تعیین |
| ۰/۸۳ | D_2 |
| ۰/۰۰۱۲ | خطای جذر میانگین مربعات |
| ۱۴۴ | زمان حل |
| GPU | پردازنشگر |
| ۶۷۶۹۱ | پارامترها |

جدول (۴): مقایسه مقدار شاخص میانگین مربعات خطای با روابط پیشین.

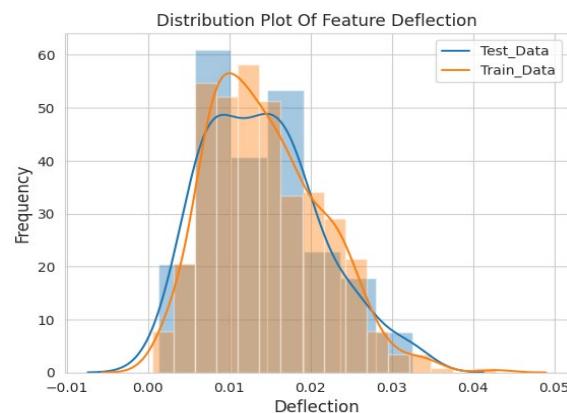
| RMSE | سال | مرجع | محققان |
|--------|------|------------------|--------|
| ۷/۷ | ۱۹۷۱ | جونز | [۳۷] |
| ۶/۹۴ | ۱۹۸۱ | گودس سوارز | [۳۸] |
| ۵/۴۲ | ۱۹۸۳ | کالادین | [۳۹] |
| ۲/۱ | ۱۹۸۴ | پرون و باهادر | [۴۲] |
| ۱/۷ | ۱۹۷۱ | جونز | [۳۷] |
| ۱/۵۱ | ۲۰۱۴ | کولوت و نوریک | [۴۳] |
| ۱/۲۷ | ۲۰۱۰ | بابایی و درویزه | [۴۸] |
| ۱/۲۶ | ۱۹۷۴ | لیپمن | [۴۴] |
| ۰/۹۹ | ۱۹۸۹ | نوریک و مارتین | [۱۵] |
| ۰/۸۹ | ۲۰۱۲ | بابایی و درویزه | [۴۷] |
| ۰/۹۷ | ۲۰۱۷ | یوان و همکاران | [۸] |
| ۰/۸۴ | ۲۰۲۰ | مستوفی و همکاران | [۳] |
| ۰/۰۰۱۲ | ۲۰۲۳ | مطالعه‌ی حاضر | |

۴- نتیجه‌گیری

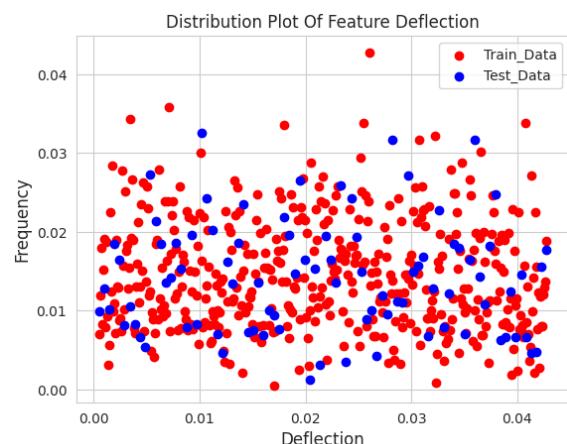
در این مقاله، با ایجاد یکی از مدل‌های مبتنی بر یادگیری عمیق، یک پیش‌بینی کاربردی از میزان خیز ورق‌های فلزی دایره‌ای تحت بار انفجاری یکنواخت انجام شده است که از مهم‌ترین نتایج آن می‌توان به موارد زیر اشاره کرد:



شکل (۱۰): پیش‌بینی میزان خیز به ازای ضخامت ورق.



شکل (۱۱): فراوانی داده‌های آزمایشی و آموزشی بر حسب میزان خیز.



شکل (۱۲): پراکندگی داده‌های آموزشی و آزمایشی بر حسب میزان خیز.

۵-۳- مقادیر شاخص‌های ارزیابی

جهت ارزیابی و سنجش عملکرد مدل‌های مبتنی بر یادگیری ماشین در مسائل رگرسیون سه شاخص مهم آماری که پیشتر

۶) ایجاد تعادل میان انواع داده‌ها یکی از موارد تأثیرگذار در بهبود عملکرد شبکه است. در مدل رائه‌شده‌ی این تحقیق میزان داده‌های مربوط به فلزات تیتانیوم و مس نسبت به دو فلز دیگر فولادی و آلومینیوم کمتر بود که در میان داده‌های تست نیز سهم کمتری به خود اختصاص دادند. افزودن یا حذف داده‌ها جهت ایجاد تعادل به عنوان یک راهکار در میان طراحان شبکه‌های عصبی مرسوم است اما در این تحقیق از آنجاکه سهم ناچیزی از داده‌های تست را فلزات کم تعداد در برگرفته‌اند از انجام آن صرف‌نظر شد هرچند که در فرآیند تعلیم شبکه حضور داشتند و مدل بر اساس آن‌ها تعلیم دیده است اما حذف آن‌ها از فرآیند آموزش شبکه نیز تغییر محسوسی در بهبود شاخص‌های ارزیابی ایجاد نکرد.

۵- مراجع

- [1] Sakaridis E, Karathanasopoulos N, Mohr D. Machine-learning based prediction of crash response of tubular structures. International Journal of Impact Engineering. 2022;166:104240. **DOI** 10.1016/j.ijimpeng.2022.104240.
- [2] Mostofi TM, Babaei H, Alitavoli M. Theoretical analysis on the effect of uniform and localized impulsive loading on the dynamic plastic behaviour of fully clamped thin quadrangular plates. Thin-Walled Structures. 2016;109:367-76. **DOI** 10.1016/j.tws.2016.10.009.
- [3] Mirzababaie Mostofi T, Sayah Badkhor M, Babaei H. A study on plastic response of circular plates under uniformly and locally distributed dynamic loading. Journal of Solid and Fluid Mechanics. 2020;10(2):11-27. **DOI** 10.22044/JSFM.2020.9264.3091
- [4] Babaei H, Mostofi TM, Alitavoli M, Darvizeh A. Empirical modelling for prediction of large deformation of clamped circular plates in gas detonation forming process. Experimental Techniques. 2016;40(6):1485-94. **DOI** 10.1007/s40799-016-0063-3.
- [5] Mostofi TM, Babaei H, Alitavoli M. The influence of gas mixture detonation loads on large plastic deformation of thin quadrangular plates: Experimental investigation and empirical modelling. Thin-Walled Structures. 2017;118:1-11. **DOI** 10.1016/j.tws.2017.04.031.

(۱) کاهش میزان خطأ و زمان آموزش مدل و افزایش دقت و سرعت آموزش مدل نسبت به روابط سنتی و تحلیلی پیشین. اگرچه تولید داده‌های مصنوعی با استفاده از روابط آماری از روی داده‌های تجربی موجود جهت آموزش بیشتر و بهتر مدل با ویژگی‌های نهفته و جزئی موجود در دل داده‌ها روشنی مرسوم جهت افزایش کارایی مدل و قدرت تحلیل و پیش‌بینی آن است، اما در تحقیق پیش رو به جهت امکان بروز مشکلات علمی و رعایت انواع بارگذاری‌ها جهت مقایسه و استناد و ارجاع به مقالات پیشینه پژوهش از آن صرف‌نظر گردید اما در پژوهش‌های آینده جهت ایجاد یک مدل جامع و مرجع می‌توان از این شیوه بهره برد.

(۲) افزایش سرعت پردازش و ساخت مدل برای داده‌های با تعداد بالا. دسترسی به پردازنده گرافیکی در ساخت این مدل الزامی نبود و زمان محاسبه تفاوت زیادی با پردازنده‌های مرکزی نداشت اما در صورت افزایش مجموعه داده استفاده از پردازنده‌های گرافیکی رایگان از طریق دسترسی آنلاین پیشنهاد می‌گردد که مناسب و کاربردی است.

(۳) استفاده از ویژگی نرخ کرنش در مدل‌سازی و فرآیند تعلیم شبکه.

(۴) ارزیابی پاسخ فلزات مختلف به‌وسیله یک مدل واحد و یکسان که به ازای ۴ نوع فلز مختلف در مجموعه داده توانستیم ۷۶ درصد از داده‌های آزمایشی را در محدوده خطای کمتر از ۱۰ درصد و ۸۸ درصد را در محدوده خطای کمتر از ۲۰ درصد پیش‌بینی می‌کند.

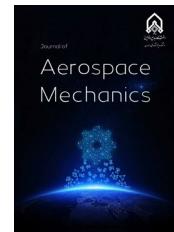
(۵) عدم وقوع بیش‌پرازش یا کم‌پرازش در حین آموزش شبکه. همچنین در این مدل به دلیل عدم دسترسی به مجموعه داده با حجم زیاد و کاهش تعداد داده‌ها، حذف داده‌های پرت باعث ایجاد تأثیر منفی در یادگیری شبکه شد که از حذف داده‌های پرت صرف‌نظر گردید.

- experimental studies. International journal of impact engineering. 1989;8(2):171-86. DOI 10.1016/0734-743X(89)90015-8.
- [16] Goodfellow I, Bengio Y, Courville A. Deep learning: MIT press; 2016.
- [17] Bishop CM, Nasrabadi NM. Pattern recognition and machine learning: Springer; 2006.
- [18] Bengio Y. Practical recommendations for gradient-based training of deep architectures. In Neural networks: Tricks of the trade: Second edition 2012 May (pp. 437-478). Berlin, Heidelberg: Springer Berlin Heidelberg. DOI 10.1007/978-3-642-35289-8_26.
- [19] Zhang A, Lipton ZC, Li M, Smola AJ. Dive into deep learning: Cambridge University Press; 2023. DOI 10.48550/arXiv.2106.11342.
- [20] Florence A. Circular plate under a uniformly distributed impulse. International Journal of Solids and Structures. 1966;2(1):37-47. DOI 10.1016/0020-7683(66)90005-9.
- [21] Wierzbicki T, Florence A. A theoretical and experimental investigation of impulsively loaded clamped circular viscoplastic plates. International Journal of solids and structures. 1970;6(5):553-68. DOI 10.1016/0020-7683(70)90030-2.
- [22] Bodner SR, Symonds PS. Experiments on viscoplastic response of circular plates to impulsive loading. Journal of the Mechanics and Physics of Solids. 1979;27(2):91-113. DOI 10.1016/0022-5096(79)90013-9.
- [23] Teeling-Smith R, Nurick G. The deformation and tearing of thin circular plates subjected to impulsive loads. International Journal of Impact Engineering. 1991;11(1):77-91. DOI 10.1016/0734-743X(91)90032-B.
- [24] Nurick GN, Teeling-Smith RG. Predicting the onset of necking and hence rupture of thin plates loaded impulsively—an experimental view. In Structures Under Shock and Impact II: Proceedings of the Second International Conference, held in Portsmouth, UK, 16th–18th June, 1992 1992 (pp. 431-445). Thomas Telford Publishing.
- [25] Thomas B. The effect of boundary conditions on thin plates subjected to impulsive loads. Dynamic Plasticity and Structural Behaviours. 1995;85.
- [26] Nurick G, Gelman M, Marshall N. Tearing of blast loaded plates with clamped boundary conditions. International Journal of Impact Engineering. 1996;18(7-8):803-27. DOI 10.1016/S0734-743X(96)00026-7.
- [27] Nurick G, Lumpp D. Deflection and tearing of clamped stiffened circular plates subjected to uniform [6] Mostofi TM, Babaei H, Alitavoli M, Lu G, Ruan D. Large transverse deformation of double-layered rectangular plates subjected to gas mixture detonation load. International Journal of Impact Engineering. 2019;125:93-106. DOI 10.1016/j.ijimpeng.2018.11.005.
- [7] Nurick G, Martin J. Deformation of thin plates subjected to impulsive loading—a review: Part i: Theoretical considerations. International Journal of Impact Engineering. 1989;8(2):159-70. DOI 10.1016/0734-743X(89)90015-8.
- [8] Yuen SCK, Nurick G, Langdon G, Iyer Y. Deformation of thin plates subjected to impulsive load: Part III—an update 25 years on. International Journal of Impact Engineering. 2017;107:108-17. DOI 10.1016/j.ijimpeng.2016.06.010.
- [9] Mirzababaie Mostofi T, Sayah Badkhor M, Ghasemi E. Experimental investigation and optimal analysis of the high-velocity forming process of bilayer plates. Journal of Solid and Fluid Mechanics. 2019;9(3):65-80. DOI 10.22044/JSFM.2019.8586.2953.
- [10] Haghgoo M, Babaei H, Mostofi TM. 3D numerical investigation of the detonation wave propagation influence on the triangular plate deformation using finite rate chemistry model of LS-DYNA CESE method. International Journal of Impact Engineering. 2022;161:104108. DOI 10.1016/j.ijimpeng.2021.104108.
- [11] Nasiri S, Sadegh-Yazdi M, Mousavi S, Ziay-Shamami M, Mostofi T. Repeated underwater explosive forming: Experimental investigation and numerical modeling based on coupled Eulerian-Lagrangian approach. Thin-Walled Structures. 2022;172:108860. DOI 10.1016/j.tws.2021.108860.
- [12] Babaei H, Mirzababaie Mostofi T. Modeling and prediction of fatigue life in composite materials by using singular value decomposition method. Proceedings of the Institution of Mechanical Engineers, Part L: Journal of Materials: Design and Applications. 2020;234(2):246-54. DOI 10.1177/1464420716660875.
- [13] Nurick GN, Martin JB. Deformation of thin plates subjected to impulsive loading—a review Part II: Experimental studies. International Journal of Impact Engineering. 1989;8(2):171-86. DOI 10.1016/0734-743X(89)90015-8.
- [14] Jacob N, Nurick G, Langdon G. The effect of stand-off distance on the failure of fully clamped circular mild steel plates subjected to blast loads. Engineering Structures. 2007;29(10):2723-36. DOI 10.1016/j.engstruct.2007.01.021.
- [15] Nurick G, Martin J. Deformation of thin plates subjected to impulsive loading—a review part II:

- [38] Soares CG. A mode solution for the finite deflections of a circular plate loaded impulsively. *Engineering Transactions*. 1981;29(1):99-114.
- [39] Mostofi TM, Babaei H, Alitavoli M, Hosseinzadeh S. On dimensionless numbers for predicting large ductile transverse deformation of monolithic and multi-layered metallic square targets struck normally by rigid spherical projectile. *Thin-Walled Structures*. 2017;112:118-24. DOI 10.1016/j.tws.2016.12.014.
- [40] Duffey TA. Large deflection dynamic response of clamped circular plates subjected to explosive loading. Sandia National Lab. (SNL-NM), Albuquerque, NM (United States); 1967.
- [41] Babaei H, Mirzababaie Mostofi T. New dimensionless numbers for deformation of circular mild steel plates with large strains as a result of localized and uniform impulsive loading. *Proceedings of the Institution of Mechanical Engineers, Part L: Journal of Materials: Design and Applications*. 2020;234(2):231-45. DOI 10.1177/1464420716654195.
- [42] Babaei H, Mirzababaie Mostofi T, Armoudli E. On dimensionless numbers for the dynamic plastic response of quadrangular mild steel plates subjected to localized and uniform impulsive loading. *Proceedings of the Institution of Mechanical Engineers, Part E: Journal of Process Mechanical Engineering*. 2017;231(5):939-50. DOI 10.1177/0954408916650713.
- [43] Cloete T, Nurick G. On the influence of radial displacements and bending strains on the large deflections of impulsively loaded circular plates. *International Journal of Mechanical Sciences*. 2014;82:140-8. DOI 10.1016/j.ijmecsci.2014.02.026.
- [44] Lippmann H. Kinetics of the axisymmetric rigid-plastic membrane subject to initial impact. *International Journal of Mechanical Sciences*. 1974;16(5):297-303. DOI 10.1016/0020-7403(74)90046-0.
- [45] C.K. De Wee, G.S. Langdon, G.N. Nurick. The influence of confined and unconfined explosions on the structural response of fully clamped mild steel plates. Undergraduate thesis, University of Cape Town, 2007.
- [46] Mirzababaie Mostofi T, Babaei H. Plastic deformation of polymeric-coated aluminum plates subjected to gas mixture detonation loading: Part II: Analytical and empirical modelling. *Journal of Solid and Fluid Mechanics*. 2019;9(2):15-29. DOI 10.22044/JSF.M.2019.7816.2778.
- [47] Babaei H, Darvizeh A. Analytical study of plastic deformation of clamped circular plates subjected to impulsive loading. *Journal of Mechanics of Materials* impulsive blast loads. *WIT Transactions on The Built Environment*. 1970;25. DOI 10.2495/SUSI960361.
- [28] Gharababaei H, Darvizeh A. Experimental and Analytical Investigation of Large Deformation of Thin Circular Plates Subjected to Localized and Uniform Impulsive Loading#. *Mechanics Based Design of Structures and Machines*. 2010;38(2):171-89. DOI 10.1080/15397730903554633.
- [29] Zamani J, Safari K, Ghamsari A, Zamiri A. Experimental analysis of clamped AA5010 and steel plates subjected to blast loading and underwater explosion. *The Journal of Strain Analysis for Engineering Design*. 2011;46(3):201-12. DOI 10.1177/0309324710396601.
- [30] Henchie TF, Yuen SCK, Nurick G, Ranwaha N, Balden V. The response of circular plates to repeated uniform blast loads: An experimental and numerical study. *International Journal of Impact Engineering*. 2014;74:36-45. DOI 10.1016/j.ijimpeng.2014.02.021.
- [31] Babaei H, Mostofi TM, Sadraei SH. Effect of gas detonation on response of circular plate-experimental and theoretical. *Structural Engineering and Mechanics*. 2015;56(4):535-48. DOI 10.12989/sem.2015.56.4.535.
- [32] Ziya-Shamami M, Babaei H, Mostofi TM, Khodarahmi H. Structural response of monolithic and multi-layered circular metallic plates under repeated uniformly distributed impulsive loading: An experimental study. *Thin-Walled Structures*. 2020;157:107024. DOI 10.1016/j.tws.2020.107024.
- [33] Souza ML, da Costa CA, de Oliveira Ramos G. A machine-learning based data-oriented pipeline for Prognosis and Health Management Systems. *Computers in Industry*. 2023;148:103903. DOI 10.1016/j.compind.2023.103903.
- [34] Ketkar N, Santana E. Deep learning with Python. Berkeley, CA: Apress; 2017. DOI 10.1007/978-1-4842-5364-9.
- [35] Kingma DP, Ba J. Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980. 2014. DOI 10.48550/arXiv.1412.6980.
- [36] Abadi M, Agarwal A, Barham P, Brevdo E, Chen Z, Citro C, Corrado GS, Davis A, Dean J, Devin M, Ghemawat S. Tensorflow: Large-scale machine learning on heterogeneous distributed systems. arXiv preprint arXiv:1603.04467. 2016. DOI 10.48550/arXiv.1603.04467.
- [37] Jones N. A theoretical study of the dynamic plastic behavior of beams and plates with finite-deflections. *International Journal of Solids and Structures*. 1971;7(8):1007-29. DOI 10.1016/0020-7683(71)90078-3.

and Structures. 2012;7(4):309-22. DOI
10.2140/jomms.2012.7.309.

[48] Gharababaei H, Darvizeh A, Darvizeh M. Analytical and experimental studies for deformation of circular plates subjected to blast loading. Journal of mechanical Science and Technology. 2010;24:1855-64. DOI 10.1007/s12206-010-0602-2.



Predicting the Plastic Response of Circular Metal Plates Under Uniform Dynamic Load Using Deep Neural Network

Saeed Sarabandan ^{1*}, Amirhossein Bagherian ², Tohid Mirzababaie Mostofi ³

¹ Assistant Professor, Faculty of Science, Imam Hossein University, Tehran, Iran

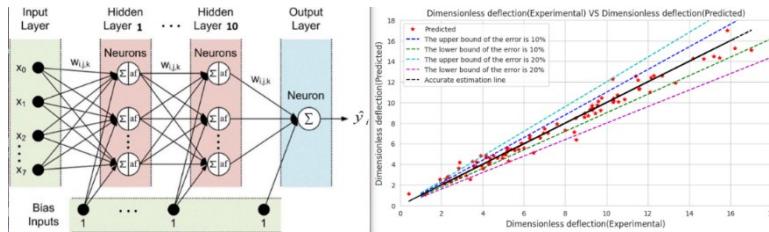
² M.Sc Student, Faculty of Science, Imam Hossein University, Tehran, Iran

³ Assistant Professor, Faculty of Mechanical Engineering, University of Eyyvanekey, Eyyvanekey, Iran

HIGHLIGHTS

- Using deep learning to predict the permanent deflection of metal sheets.
- Using Adam's optimizer algorithm in deep neural network model architecture.
- Determining optimal metaparameters based on evaluator search engines.

GRAPHICAL ABSTRACT



ARTICLE INFO

Article history:

Article Type: Research paper

Received: 8 February 2024

Received in revised form: 17 March 2024

Accepted: 20 April 2024

Available online: 18 June 2024

*Correspondence:

ssarabandan@ihu.ac.ir

How to cite this article:

S. Sarabandan, A. Bagherian, T.M. Mostofi. Predicting the plastic response of circular metal plates under uniform dynamic load using deep neural network. Journal of Aerospace Mechanics. 2024; 20(2):105-121.

Keywords:

Uniform dynamic loading

Circular metal sheets

Deep neural network

Artificial intelligence

Permanent deflection

Metallic plates

ABSTRACT

In the upcoming research, using deep neural networks, it is used to predict the maximum yield of circular metal sheets under uniform dynamic load. The neural network presented in this research was designed in the Python programming language and using the libraries available in it, including Tensorflow. The network is based on the regression problem and is of sequential type and includes 10 hidden layers which are the activation function in neurons of Leaky RELU type. The network optimizer algorithm was set to Adam and the objective function of the MSE problem and the number of network iterations was set to 700 times. The data set used in this article consists of 581 samples obtained from 16 series of experiments during the last forty years, which were standardized by the Scikit_learn library. The metal sheets are of 4 types: steel, aluminum, copper and titanium, and there is no separation between different metals. The number of training data in the model was determined to be 443 equals to 75% of the data set. Also, the number of experimental and evaluator data was selected as 88 numbers equivalent to 15% and 50 numbers equivalent to 10% of the entire data set. Each sample has 8 features as neural network inputs and one label as output. The presented intelligent model among the 88 test data that was completely randomly selected from the data set was able to classify 76% of the data, approximately equivalent to 67 numbers, within the error range of less than 10% and 88% of the data, or in other words, equivalent to approximately 78 numbers within the error range. Predict less than 20%. The amount of the root mean square error index decreased 102 times compared to the analytical and traditional predictive relationships available in the research records. Also, the coefficient of determination criterion, which is an important indicator for evaluating the performance of neural networks based on regression problems, includes the value of 0.96.

