

## پیش بینی استحکام تسلیم آلیاژهای فولادی با شبکه عصبی پرسپترون چند لایه

مجید طاهری<sup>۱</sup>، میثم بیات<sup>۲</sup>، ارشیا حسین زاده<sup>۳</sup>

<sup>۱</sup> کارشناسی، دانشکده مهندسی مواد و صنایع، دانشگاه سمنان، ایران (نویسنده مسئول)

<sup>۲</sup> کارشناسی، دانشکده مهندسی مواد و صنایع، دانشگاه سمنان، ایران

<sup>۳</sup> دانشجوی کارشناسی، دانشکده هنر، دانشگاه سمنان، ایران

### چکیده

پایه تشکیل دهنده ی فولاد، کربن و آهن و مقدار کربن موجود در آهن، تعیین کننده ی نوع و خاصیت فولاد تشکیل دهنده میباشد. فولاد دارای استحکام بالا فراوانی، قیمت مناسب، قابلیت عملیات حرارتی می باشد به همین علت پرکاربرد ترین و اساسی ترین فلز مورد استفاده در صنعت به شمار می رود، استحکام مقدار نیرویی است که یک ماده تحمل می کند و استحکام تسلیم حداکثر استحکامی است که قطعه بعد از آن وارد تغییر شکل مومسان میگردد. استحکام تسلیم که یک موضوع چالش برانگیز در فولاد بوده حائز اهمیت بالایی است و یکی از مهم ترین پارامترهایی جهت تعیین خواص مکانیکی مواد به شمار می رود که از طریق یکی از آزمایشات مهم و انعطاف پذیر به نام آزمون کشش اندازه گیری می شود. از عوامل موثر براستحکام تسلیم می توان به ترکیب شیمیایی، نحوه عملیات حرارتی، میزان جذب ضربه، سختی، درصد ازدیاد طول، نرخ بارگذاری، کرنش و مدول الاستیک اشاره کرد. مقاله پیش رو به معرفی روشی که پیش بینی استحکام تسلیم آلیاژهای فولادی با شبکه عصبی پرسپترون چند لایه می پردازد. پرسپترون ساده ترین نوع مدل سازی نورو با قابلیت یادگیری است. با در اختیار داشتن دیتا های معلوم از استحکام تسلیم و ترکیب شیمیایی، درصد ازدیاد طول، میزان جذب ضربه، نحوه عملیات حرارتی و سختی، شبکه ی عصبی به تشکیل الگوریتم برای یافتن استحکام تسلیم آلیاژهای مجهول که مقدار آن به وسیله ی تست کشش قابل اندازه گیری نبوده، می پردازد که به مقدار حقیقی و آزمون کشش نزدیک تر می باشد. در نتیجه داده های حاصل از آزمون تجربی با دقت قابل قبول توسط مدل حاصله در شبکه عصبی قابل پیش بینی بوده که بر هم منطبق می باشند.

**واژه های کلیدی:** استحکام تسلیم، آلیاژهای فولادی، شبکه عصبی

## ۱. مقدمه

فولاد، فلز مقاومی است که از آهن بدست می آید. ساده ترین روش ساخت فولاد، ریختن آهن گداخته و مذاب داخل کوره تبدیل و دمیدن هوای گرم و اکسیژن روی آن (بخش عمده کربن موجود در آهن با استفاده از این روش میسوزد) و در نهایت آهن تبدیل به فولاد خواهد شد. [۱]

فولادی که تا ۰/۲ درصد کربن دارد برای ساختن سیم، لوله، ورق فولادی و از فولاد متوسط کربن ۰/۲ تا ۰/۶ درصد برای ساختن ریل، دیگ بخار و قطعات ساختمانی و از فولاد سخت که ۰/۶ تا ۱/۵ درصد کربن دارد برای ساختن ابزار آلات، فنر و کارد و چنگال استفاده می شود. [۲] به طور کلی فولاد خام از دو روش زیر تولید می شود:

تهیه آهن خام یا چدن مذاب در کوره بلند و تولید فولاد در کانونرترهای اکسیژنی نظیر ذوب آهن اصفهان. [۳]

روش تولید فولادها:

احیای مستقیم سنگ آهن و ذوب آهن اسفنجی و قراضه در کوره های الکتریکی از قبیل قوس الکتریکی نظیر فولاد خوزستان یا القایی نظیر مجتمع فولاد جنوب. [۴] لازم به ذکر است که تولید فولاد از روشهای دیگری نظیر روش کوره باز نیز انجام میگردد. [۵] فولاد دارای مزایایی نظیر مقاومت بالا، خواص یکنواخت، دوام بالا، خواص ارتجاعی مناسب، شکل پذیری بالا شرایط آسان در ساخت و نصب، سرعت نصب بالا، پایین بودن وزن ساختمان فولادی نسبت به ساختمان های بتن مسلح، اشغال فضای کمتر و پایین بودن ضریب نیروی لرزه ای در فولاد به نسبت بتن می باشد. [۶] استحکام تسلیم تنش است که به حساسیت اندازه کرنش بستگی دارد و در آن تسلیم یا شروع تغییر شکل پلاستیک مشاهده میشود. و برای ایجاد مقداری تغییر شکل پلاستیک، کوچک و معین است. تعریف متداول این خاصیت، استحکام تسلیم خارج از مرکز است که با تنش واقع بر نقطه تقاطع منحنی تنش - کرنش و خطی موازی با بخش الاستیک منحنی در یک کرنش معین تعیین میشود. [۷] فولاد سازه ای یک نمونه از موادی است که رفتار الاستیک - پلاستیک غیر یکنواخت، پلاستیک یکنواخت از خود نشان میدهد. در این مواد انتقال از تغییر شکل الاستیک به پلاستیک بصورت کاملاً مشخص است. [۸] پس از تسلیم ( تسلیم بالایی ) به دلیل آزاد شدن قفل های لومر - کاترل و تشکیل نوار های لودر تنش تا میزان تسلیم پایینی کاهش میابد. این پدیده نقطه ی تسلیم نام دارد. [۹]

هر شکستی شامل دو مرحله است: ایجاد ترک و اشاعه آن که در واکنش به یک تنش اعمالی بروز میکند. حالت شکست به میزان زیادی به مکانیزم اشاعه ترک بستگی دارد. بستگی دارد. شکست نرم توسط تغییر شکل پلاستیک زیاد در مجاورت ترک روبه رشد متمایز میگردد. [۱۰]

انواع شکست: شکست نرم: سطوح این شکست دارای جنبه های متمایز مربوط به خود در هر دو حالت ماکروسکوپی و میکروسکوپی میباشد. شکست ترد: بدون وقوع تغییر شکل محسوس و توسط اشاعه ترک سریع بروز میکند. [۱۱] عوامل موثر در استحکام: برای بررسی عوامل موثر بر سختی پذیری باید به عوامل موثر بر دگرگونی پرلیت توجه شود. در صورتی سختی پذیری یک فولاد زیاد می شود که در آهنگ های سرد شدن نسبتاً آهسته، دگرگونی نفوذی تشکیل پرلیت انجام نشده و آستنیت به مارتنزیت تبدیل شود. [۱۲] برعکس در فولاد هایی که سختی پذیری آنها کم است، تشکیل مارتنزیت مستلزم سرد شدن سریع می باشد. در هر دو حالت، پارامتر محدود کننده، آهنگ تشکیل پرلیت در دماهای بالا است، عواملی که سختی پذیری را در فولاد افزایش میدهند عبارت است از:

۱. اندازه دانه های آستنیت

۲. درصد کربن

۳. عناصر آلیاژی

۴. آخال - ناخالصی های غیر فلزی

۵. همگن بودن ریزساختار. [۱۳]

روشهای اندازه گیری استحکام عبارت است از:

آزمون کشش: یکی از آزمون های مخرب علم مواد است که در آن یک نمونه تحت اثر کشش تک محوری تا حد شکست مورد مطالعه قرار میگیرد. [۱۴] خواصی که بطور مستقیم از طریق آزمون کشش اندازه گیری میشوند عبارتند از: مقاومت کششی نهایی، مدول یانگ، نسبت پوآسون، استحکام تسلیم و کرنش سختی ماده. آزمون کشش تک محوری برای تعیین خواص مواد همسانگرد و برای مواد ناهمسانگرد مانند کامپوزیت ها از آزمون دو محوری استفاده میشود.

مقاومت فشاری؛ عبارت است از ظرفیت تحمل یک جسم در مقابل نیروهای فشاری محوری. [۱۵] شبکه های عصبی سیستم ها و روش های محاسباتی نوین برای یادگیری ماشینی، نمایش دانش و در انتها اعمال دانش به دست آمده در جهت پیش بینی پاسخ های خروجی از سامانه های پیچیده هستند. ایده ی اصلی این گونه شبکه ها تا حدودی الهام گرفته از شیوه ی کارکرد سیستم عصبی زیتی برای پردازش داده ها و اطلاعات به منظور یادگیری و ایجاد دانش قرار دارد. [۱۶] این سیستم از شمار زیادی عناصر پردازشی فوق العاده به هم پیوسته به نام نورون تشکیل شده است که برای حل این مساله با هم هماهنگ عمل و توسط سیناپس ها اطلاعات را منتقل میکنند. با استفاده از دانش برنامه نویسی رایانه میتوان ساختار داده ای طراحی کرد که همانند یک نورون عمل نماید. [۱۷]

سپس با ایجاد شبکه ای از این نورون های مصنوعی به هم پیوسته، ایجاد یک الگوریتم آموزشی برای شبکه و اعمال این الگوریتم به شبکه آن را آموزشی داد. این شبکه ها برای تخمین و تقریب، کارایی بسیار بالایی از خود نشان داده اند. گستره کاربرد این مدل های ریاضی برگرفته از عملکرد مغز انسان، بسیار وسیع میباشد که به عنوان چند نمونه کوچک میتوان استفاده از این ابزار ریاضی در پردازش سیگنال های بیولوژیکی، مخابراتی و الکترونیکی تا کمک در نجوم و فضانوردی نام برد. [۱۸] شبکه عصبی با قابلیت قابل توجه آنها در جست و جو معانی، داده های پیچیده یا مبهم، میتوان برای استخراج الگوها و شناسایی روش هایی که آگاهی از آنها برای انسان و دیگر تکنیک های کامپیوتری بسیار پیچیده و دشوار است به کار گرفته شود. یک شبکه عصبی تربیت یافته میتواند به عنوان یک متخصص در مقوله اطلاعاتی که برای تجزیه تحلیل به آن داده شده به حساب آید. [۱۹]

شبکه عصبی با قابلیت قابل توجه آنها در جست و جو معانی، داده های پیچیده یا مبهم، میتوان برای استخراج الگوها و شناسایی روش هایی که آگاهی از آنها برای انسان و دیگر تکنیک های کامپیوتری بسیار پیچیده و دشوار است به کار گرفته شود. یک شبکه عصبی تربیت یافته میتواند به عنوان یک متخصص در مقوله اطلاعاتی که برای تجزیه تحلیل به آن داده شده به حساب آید. [۱۹] نرخ بارگذاری، کرنش و مدول الاستیک به عنوان ورودی ها و حد استحکام تسلیم به عنوان خروجی شبکه ی عصبی مصنوعی در نظر گرفته شده است. [۲۱] با استفاده از شبکه عصبی به بررسی تاثیر هر یک از پارامترها به طور جداگانه بر خواص مکانیکی پرداختند. نتایج نشان داد که مدل آموزش داده شده می تواند حساسیت خواص مکانیکی به متغیرهای ورودی را پیش بینی نماید. [۲۲] در گام بعدی با استفاده از نتایج به دست آمده از شبکه عصبی، معادله ای برای استفاده در مدل الگوریتم حدس زده شد. استفاده از الگوریتم باعث گردید تا نتایج به دست آمده از شبکه عصبی بهینه گردد و پیش بینی بهتری را در پی داشته باشد. [۲۳]

## ۲. روش کار

با استفاده از شبکه عصبی مصنوعی سعی می شود ساختار مغز انسان شبیه سازی شود. در مغز انسان حدود  $10^{10}$  واحد سازنده به نام نورون وجود دارد که هر یک از آن ها به حدود  $10^4$  نورون دیگر متصل است. هر یک از این نورون ها دارای ورودی و

خروجی بوده، مغز انسان را به ماهیچه ها مرتبط کرده و علائم را از ارگان های حساس به مغز منتقل میکند. [۲۴] شبکه عصبی های مصنوعی بر اساس مدل بیولوژیکی مغز انسان به وجود آمده، که از چند تا چند هزار نورون تشکیل شده و اندازه آن ها به پیچیدگی مسائل بستگی دارد. هر شبکه عصبی دارای خصوصیتی است که آن ها را از شبکه های دیگر متمایز می کند. [۲۵] این خصوصیات شامل نحوه ارتباط بین نورون ها، روش آموزش شبکه، نحوه ی تعیین مقادیر وزن های رابط و نوع تابع تحریک هر نورون است. [۲۶] در این مقاله نمونه ی مورد آزمایش در آزمایشگاه وارد برنامه متلب و در شبکه ی عصبی آن نمودار رگرسیون و در این دیتا پارامتر های موثر و حائز اهمیت بر روی استحکام تسلیم اعم از ( ترکیب شیمیایی، نحوه عملیات حرارتی، میزان جذب ضربه، سختی، ازدیاد طول، نرخ بارگذاری و ... ) به دست آمد. دیتاهای به دست آمده به عنوان ورودی و استحکام تسلیم به عنوان خروجی در نظر گرفته شد. [۲۷] از آنجا که مقادیر عددی مربوط به عوامل ماشین کاری دارای واحد و اندازه های متفاوتی هستند فرایند آموزش شبکه عصبی مصنوعی به خوبی انجام نمی شود. زیرا تفاوت اندازه اعداد، در اصلاح وزن های شبکه تاثیر زیادی می گذارد و در نتیجه میباید تعداد داده های تجربی بسیار زیاد باشند تا وزن ها را تعدیل نمایند و نتیجه مطلوب حاصل شود. [۲۸] به عنوان مثال اگر یک بردار ورودی دارای اعداد بسیار بزرگتر تری نسبت به بقیه ورودی ها باشد، پس از اصلاح وزن ها بر مبنای اعداد بزرگ، سایر ورودی ها باید به تعداد دفعات بسیار زیادی به شبکه اعمال شوند تا بتوانند اثر خود را بر روی شبکه بگذارند و اثر داده های با ابعاد بزرگ را تا حدی تعدیل نمایند. [۲۹] بنابراین قبل از آموزش شبکه عصبی، به یک تابع متعادل کننده برای اصلاح وزن ها نیاز است تا مشکل گفته شده از بین برود. برای متعادل سازی داده ها، با استفاده از روابط (۱) و (۲) داده های ورودی و خروجی تراشکاری بر مقادیر حداکثرشان تقسیم شده اند. [۳۰]

$$P_n = \frac{P}{P_{max}} \quad (1)$$

$$T_n = \frac{T}{T_{max}} \quad (2)$$


$P_n$  بردار ورودی تعدیل شده،  $T_n$  بردار خروجی تعدیل شده،  $P$  و  $T$  بردار ورودی و خروجی،  $P_{max}$  و  $T_{max}$  حداکثر مقدار بردار ورودی و خروجی هستند.

شکل ۱ ساختار شبکه عصبی چند لایه پرسپترون را نشان میدهد. شبکه دارای سه لایه شامل: ورودی با چهار نورون پنهان که تعداد نورون های آن بعد از آموزش صحیح شبکه، انتخاب گردیده اند و خروجی که شامل یک نورون برای زبری سطح است. [۳۱] شبکه عصبی با تابع پایه شعاعی که در شکل ۲ نشان داده شده است از لایه های ورودی، پنهان و خروجی تشکیل شده است که هر یک از نورون های لایه خروجی، ترکیب خطی از خروجی های نورون های لایه پنهان است. تابع انتقال لایه پنهان شبکه عصبی با تابع پایه شعاعی به صورت تابع گوسی شکل ۳ است و تابع انتقال لایه خروجی یک تابع خطی است. رابطه ورودی ها و خروجی های شبکه عصبی با تابع پایه شعاعی از رابطه ۳ محاسبه میشوند. [۳۲]

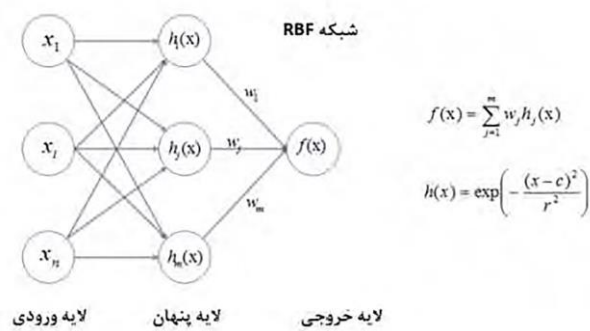
$$f(x) = \sum_{j=1}^M w_j \cdot h_f(x) \quad (3)$$

$$h_f(x) = \exp\left[-\frac{(x-c)^2}{r}\right]$$


$x$  بردار ورودی شبکه،  $w_j$  بردار وزنها و  $h_f(x)$  پاسخ در لایه پنهان است. تابع و  $h_f(x)$  با فرض فرم گاوسی تعریف می شوند.



شکل ۱ - ساختار شبکه عصبی چند لایه پرسپترون



شکل ۲ - شبکه عصبی با تابع پایه شعاعی



شکل ۳ - تابع گوسی

$C_j$  مرکز تابع گوسی،  $I_j$  ضریب پراکندگی است. مقدارش به تدریج با فاصله گرفتن از بردار ورودی  $X$  و مرکز  $C_j$  کاهش مییابد. [۳۳]

اولین مرحله در طراحی شبکه عصبی چند لایه پرسپترون، ایجاد معماری شبکه است. برای ایجاد معماری شبکه چند لایه پرسپترون، برنامه ای در نرم افزار متلب با استفاده از تابع newff نوشته شده است. [۳۴] این تابع دارای چهار ورودی بوده که شبکه ایجاد شده را به خروجی مرتبط ساخته است. اولین ورودی، یک ماتریس  $R \times 2$  به عنوان مقادیر حداقل و حداکثر هر ورودی به تعداد  $R$  بردار ورودی است. [۳۵] دومین ورودی، یک آرایه از اندازه هر لایه است که تعداد نرون های لایه های مختلف را تعیین میکند. سومین ورودی، یک آرایه سلولی است که شامل توابع انتقال مورد استفاده در هر لایه است و چهارمین ورودی، نام تابع آموزشی مورد استفاده است. [۳۶] در این پژوهش برای اینکه بهترین توابع انتقال و همچنین تعداد نرون های بهینه در لایه میانی حاصل شود، از سه حلقه for استفاده شده است. اولین و دومین حلقه for برای تعیین بهترین توابع انتقال و سومین حلقه برای تعیین تعداد نرون های بهینه در لایه میانی استفاده شده است. توابع انتقال شامل توابع: Tansig، Logsig و Purelin بوده است که به ترتیب در روابط ۴ و ۵ و ۶ تعریف شده اند: [۳۷]

$$\text{logsig}(n) = \frac{1}{(1+\exp(-n))} \quad (۴)$$

$$\text{Tansig}(n) = \frac{2}{(1+\exp(-2 \times n)) - 1} \quad (۵)$$

$$\text{Purelin}(n) = n \quad (۶)$$

$n$  ورودی ورودی توابع است. تابع Logsig به ازای ورودی  $(-\infty, +\infty)$  خروجی بین ۱ و -۱ تولید میکند. تابع Purelin به ازای ورودی  $(-\infty, +\infty)$  در خروجی همان داده ورودی را تولید میکند. [۳۸] در ابتدا در لایه میانی، ۵۰ عدد نرون و مقادیر وزن ها و بایاس ها صفر انتخاب شده اند. تابع کارایی مورد استفاده در شبکه عصبی چند لایه پرسپترون به صورت مجموع متوسط مربعات خطاها در رابطه ۷ تعریف شده است:

$$\text{MSN} = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2 \quad (۷)$$

تعداد کل نمونه های آموزشی،  $t_i$  مقدار خروجی واقعی و  $a_i$  مقدار خروجی شبکه می باشد. [۳۹] برای آموزش شبکه عصبی چند لایه پرسپترون در نرم افزار متلب از الگوریتم لونیگ - مارکورت استفاده شد. برای آموزش شبکه عصبی چند لایه پرسپترون، داده ها به سه مجموعه: داده های آموزش، داده های آزمایش و داده های معتبرسازی تقسیم شدند. [۴۰] داده های آموزش به آن دسته از داده هایی اطلاق شد که برای آموزش شبکه استفاده شدند و عوامل شبکه با توجه به خطاهای بدست آمده از این داده ها تنظیم شد. داده های معتبرسازی برای اندازه گیری عمومیت شبکه استفاده شد. خطای معتبرسازی در طول فرآیند آموزش، مانند خطای مجموعه آموزشی باید کاهش میافت. [۴۱] به هر حال زمانی که شبکه سعی در تطابق بیش از حد با داده ها داشت، خطای معتبرسازی افزایش میافت. زمانی که خطای معتبرسازی برای تعداد خاصی از تکرارها افزایش میافت، آموزش متوقف میشد و مقدار وزن ها و بایاس ها با زمانی که این خطا حداقل بودند، انطباق داده میشدند. سومین زیرمجموعه، داده های آزمایش هستند که در طول فرآیند آموزش، کاربردی نداشته اند اما از آنها برای مقایسه مدل های مختلف استفاده شد. همچنین از داده های آزمایش، برای رسم خطای مجموعه داده های آموزش در طول فرآیند آموزش استفاده شد. در این پژوهش نیمی از داده ها به عنوان مجموعه داده های آموزش داده، یک چهارم داده ها به عنوان مجموعه داده های معتبرسازی و همچنین یک چهارم دیگر داده ها به عنوان مجموعه داده های آزمایش استفاده شد. [۴۲] در مرحله اول هدف از آموزش شبکه عصبی چند لایه پرسپترون، بدست آوردن توابع انتقال هیپنه و همچنین تعداد نورونهای بهینه در لایه پنهان بود

در این مرحله از تمامی داده های آموزشی برای دستیابی به این هدف استفاده شد. در مرحله دوم، آموزش تمامی داده ها در سه زیرمجموعه داده های آموزشی، معتبرسازی و آزمایش انجام شد. این آموزش بر مبنای توابع انتقال بهینه، که از مرحله قبل بدست آمده و همچنین با تعداد نورون های بهینه در لایه میانی انجام شد. [۴۳]

### ۳- نتایج و بحث

با توجه به نتایج حاصل از دو شبکه ایجاد شده، تعداد نورون های شبکه عصبی با تابع پایه شعاعی بسیار بیشتر از تعداد نورون های شبکه عصبی چند لایه پرسپترون است. به این علت که در شبکه عصبی چند لایه پرسپترون از توابع Sigmoid به عنوان تابع انتقال استفاده شده است. توابع Sigmoid میتوانند روی محدوده گستردهای از فضای ورودی عمل نمایند. در حالی که نورون های با تابع پایه شعاعی فقط میتوانند روی فضای محدودی عکس العمل نشان دهند و در نتیجه برای گسترش این فضا نیاز به نورون های بیشتری دارند. مقایسه مشخصات دو شبکه عصبی چند لایه پرسپترون و شبکه عصبی با تابع پایه شعاعی در جدول ۱ و ۲ نشان داده شده است. [۴۴]

جدول ۱- مقایسه

مشخصات دو شبکه عصبی

نوع شبکه		مشخصات شبکه
تابع پایه شعاعی	چند لایه پرسپترون	
۴	۴	تعداد ورودی ها
۱	۱	تعداد خروجی ها
۵۰	۲۸	تعداد نورون های لایه پنهان
۱	۱	تعداد نورون های لایه خروجی
Gaussian	Log-sigmoid	تابع انتقال لایه پنهانی
Linear	Tan-sigmoid	تابع انتقال لایه خروجی

جدول ۲- نتایج تحلیل رگرسیون برای شبکه های عصبی


داده های آزمایش		تمامی داده ها		خروجی شبکه
MLP	RBF	MLP	RBF	
۰/۵۲۴	۰/۸۳۵	۰/۷۴۰	۰/۸۲۹	ضریب همبستگی

جدول ضریب همبستگی بین خروجی واقعی و خروجی شبکه را نشان میدهد. ضریب همبستگی بین خروجی واقعی و خروجی شبکه عصبی چند لایه پرسپترون انطباق بهتری نسبت به شبکه عصبی با تابع پایه شعاعی نشان میدهد ۰/۸۲۹ و ۰/۸۳۵ برای شبکه عصبی چند لایه پرسپترون در مقایسه با ۰/۷۴۰ و ۰/۵۲۴ برای شبکه عصبی با تابع پایه شعاعی (به علت داشتن ضریب همبستگی بالا در شبکه عصبی چند لایه پرسپترون، قابلیت این شبکه برای مدلسازی سطح به وضوح مشاهده میشود). [۴۵]

نتایج مربوط به آموزش شبکه عصبی مصنوعی و نتایج حاصل از آن به شرح ذیل میباشد.


علت ایست شبکه تعداد تکرار شبکه (Epoch) میباشد. مقدار میانگین مربعات خطا در قسمت آموزش شبکه ۰۰۱۰۱ و این مقدار برای آزمون شبکه ۰۰۳۴۳ بدست آمد. تعداد دور تکرار آموزش شبکه ۱۰۰۰، میزان عملکرد شبکه (حداقل صفر) ۰۰۱۱۴، میزان مشتق شبکه (حداقل  $1 \times 10^{-7}$ ) و میزان  $\mu$  (حداقل  $1 \times 10^{10}$ ) هم  $1 \times 10^{-6}$  می باشد. [۴۶]

شکل ۴ نشان دهنده نرمالیزه خروجی (Ytr) و خروجی آموزش شبکه (YtrNet) می باشد که به ترتیب با دایره قرمز و مربع آبی مشخص شده اند. همچنین در شکل ۵ نرمالیزه خروجی (Yts) و خروجی آزمون شبکه (YtsNet) قابل رویت است که مجدداً با دایره های قرمز رنگ و مربع آبی رنگ مشاهده میشوند در این نمودارها مشاهده می شود که نمودار خروجی و نمودار آموزش و آزمون انطباق نسبتاً خوبی دارند که نشان دهنده آموزش و آزمون خوب شبکه می باشد. [۴۷]






شکل ۴- نمودار خروجی و خروجی آموزش شبکه




شکل ۵- نمودار خروجی و خروجی آزمون شبکه

شکل های شماره ۶ و ۷ به ترتیب مربوط به قسمت آموزش و آزمون شبکه عصبی میباشند که شامل مقدار نرمالیزه شده استحکام پیشبینی شده بر حسب مقدار نرمالیزه شده حد استحکام واقعی میباشد. هر چه تراکم حول محور افقی بیشتر باشد، نشان از پیش بینی مناسب شبکه دارد.




شکل ۶- مقدار نرمالیزه شده استحکام پیشبینی شده بر حسب استحکام واقعی در آموزش شبکه




شکل ۷- مقدار نرمالیزه شده استحکام پیشبینی شده بر حسب استحکام واقعی در آزمون شبکه

در شکل ۸ نمودار میانگین مربعات خطا بر حسب تعداد دور تکرار آموزش شبکه آورده شده است. نمودار نشان دهنده این است که مقدار میانگین مربعات خطا در تعداد دور ۱۰۰۰ تکرار دارای کمترین مقدار میباشد. [۴۸]

نمودار رگرسیون در شکل ۹ ارائه شده است. این نمودار میزان انحراف یا پس رفت از حالت ایده آل که  $R=1$  می باشد را نشان میدهد که در تحقیق حاضر مقدار آن ۰,۹۷۱۰۱ بدست آمده است. در این نمودار هر چه داده ها به خط رگرسیون نزدیکتر باشند به این معنی است که نمودار خوب آموزش دیده و مقادیر پیشبینی خطای کمی با مقدار واقعی دارند. [۴۹]



شکل ۸- نمودار میانگین مربعات خطا بر حسب تعداد دور تکرار آموزش شبکه



شکل ۸- نمودار رگرسیون

#### ۴- نتیجه گیری

استحکام یکی از موضوعات چالش برانگیز در فولاد به شمار میرود. آزمون های تجربی برای اندازه گیری این ویژگی با صرف زمان و هزینه زیاد انجام می شوند. لذا برای صرفه جویی در زمان و هزینه از برنامه های هوش مصنوعی با هدف پیش بینی خواص قطعات مختلف استفاده میشود در این پژوهش با استفاده از شبکه عصبی مصنوعی مدلی طراحی شد که براساس ترکیب شیمیایی، نحوه عملیات حرارتی و میزان جذب ضربه، سختی، درصد ازدیاد طول، نرخ بارگذاری، کرنش و مدول الاستیک میزان استحکام را برآورد کند. [۵۰]

شبکه عصبی با ۵ نورون در قسمت لایه پنهان بهینه سازی گردید و از ۵۴ داده در قسمت آموزش و ۱۳ داده در قسمت آزمون استفاده شد. دقت شبکه در حین آزمون و آموزش با مقدار میانگین مربعات خطا سنجیده شد. تابع فعال سازی تانژانت سیگموئید در ساختار این شبکه (سلولهای لایه مخفی) مورد استفاده قرار گرفت. به منظور راحتی در پردازش؛ دادهها نرمالیزه شده و سپس در لایه مخفی استفاده شدند. با توجه به نتایج میتوان مشاهده نمود که شبکه عصبی مورد استفاده با دقت بالایی قادر به برآورد و پیشبینی استحکام فولادهای کم کربن و پرکربن مورد مطالعه می باشد. [۵۱]

- [1] Y.J. Park, R.B. Gundlach, R.G. Thomas, and J.F. Janowak, Trans. AFS, Vol 93, 1985, p 415.
- [2] L. E. Sevensson, B. Gketoft, B. Ulander and H. K. D. H. Bhadeshia, "Fe-Cr-C Hardfacing Alloys for High Temperature Application", Journal of Materials Science, Vol. 2, pp. 1015-1019, 1986.
- [3] The Materials Information Society: ASM Specialty Handbook: Stainless Steel, ASM INTERNATIONAL, Metals Park, OH, (1994), 314-315.
- [4] D. Zendelovska, G. Pavlovska, K. Cundeva, T. Stafilov, Talanta 54 (2001) 139.
- [5] Humphreys, David K. , Manuel P. Eisner , and Douglas J. Wiebe . "Evaluating the Impact of Flexible Alcohol Trading Hours on Violence: An Interrupted Time Series Analysis." • PLOS ONE 8, no. 2 (2013). Accessed July 15, 2015.
- [6] Reip, C.P., Shanmugam, S. and Misra, R.D.K., "High strength microalloyed CMn(V–Nb–Ti) and CMn(V–Nb) pipeline steels processed through CSP thin-slab technology: Microstructure, precipitation and mechanical properties", *Materials Science and Engineering A*, Vol. 424, pp. 307–۳۱۷, ۲۰۰۶.
- [7] sakuma,y. et , "next-Generstion high – strength sheet steel ultizing Transformation – Induced plasticity (TRIP)effect" , Nippon steel technical report , No 64 , pp , 20-25 , March 1995.
- [8] R. Radis and E. Kozeschnik, "Kinetics of AlN precipitation in microalloyed steel", *Modelling and Simulation in Materials Science and Engineering* 2010, Vol. 18, pp. 1-16.
- [9] Tomita, Y., "Effect of microstructure on mechanical properties of isothermally bainite-transformed 300M steel", *Mater. Sci. Eng. A.*, 172, pp.145-151, (1993).
- [10] Gooch, T. G. (1995) "Embritterment of stainless steel welds by temperature heat treatment." *Welding in the World*, Vol. 35, No. 4, PP. 248–254.
- [11] Gooch, T. G. (1995) "Embritterment of stainless steel welds by temperature heat treatment." *Welding in the World*, Vol. 35, No. 4, PP. 248–254.
- [12] J. D. Kwon, J. C. Park, W. H. Lee, Y. W. Park, "Effect of temperature and time on microstructure, hardness and impact energy of CF8M", *Met. Mater.* Vol. 6, 2000, pp. 559-563.
- [13] G. Dini, A. Najafizadeh, R. Ueji, S. M. Monir-Vaghefi, "Improved tensile properties of partially recrystallized submicron grained TWIP steel", *Materials Letters*, 2010, vol. 64, pp. 15-18.
- [14] Raghavan, M., Berkovitz, B. J. and Kane, R. D., "A Transmission Electron Microscopic Investigation of Phase Transformations in MP35N", *Met. Trans.*, Vol. 11, (1980), 203-207.

- [15] Naipeng Zhou, Renbo Song, Renfeng Song, Xuan Li and Jiajia Li, Influence of Nb Addition on Microstructure and Mechanical Properties of Medium-Mn Low-Density Steels, *steel research international*, 89, 8, (2018).
- [16] N. Kim and H. Cho: J. Mater. Process. Tech., 208 ( 2008 ), 211.
- [17] A.M. Rashidia, A.R. Eivani, A. Amadeh, "Application of Artificial Neural Networks to Predict the Grain Size of Nano-Crystalline Nickel Coatings", *Computational Materials Science*, 2009, Vol. 45, Issue 2, 499–504.
- [18] Dahamsheh, Ahmad, Aksoy, Hafzullah (2009) Artificial neural network models for forecasting intermittent monthly precipitation in arid regions, *Royal Meteorology Society* 16, 325-337
- [19] M. Khayet, and C. Cojocaru, "Artificial neural network model for desalination by sweeping gas membrane distillation," *Desalination*, vol. 308, no. 0, pp. 102-110, 1/2/, 2013.
- [20] T. S. Shun, C. M. Wan, J. G. Byrne, "A study of work hardening in austenitic Fe-Mn-C and Fe-Mn-Al-C alloys *Acta Metallurgica et Materialia*, 1992, vol. 40, pp. 3407-3412.
- [21] M. Khayet, C. Cojocaru, and M. Essalhi, "Artificial neural network modeling and response surface methodology of desalination by reverse osmosis," *Journal of Membrane Science*, vol. 368, no. ۱-۲, pp. ۲۰۲-۲۱۴, ۲/۱۵/, ۲۰۱۱.
- [22] H. Beladi, G.L. Kelly, A. Shokouhi and P.D. Hodgson, "Effect of thermomechanical parameters on the critical strain for ultra ferrite formation through hot torsion testing", *Materials Science and Engineering A*. 673 (4002) 154-131.
- [23] MATLAB® Software, R2008a, Neural Network Toolbox, User's Guide, 2008.
- [24] Attar M., A. "A transfer matrix method for free vibration analysis and crack identification of stepped beams with multiple edge cracks and different boundary conditions", *International Journal of Mechanical Sciences* Vol. 57, )2012(, 19-33
- [25] N. Tosun, L. Ozler, A study of tool life in hot machining using artificial neural networks and regression analysis method, *Materials Processing Technology*, Vol. 124, No. 1, pp. 99-104, 2002.
- [26] H. R. Baghaee, M. Mirsalim, G. B. Gharehpetian, Multi-objective optimal power management and sizing of a reliable wind/PV microgrid with hydrogen energy storage using MOPSO, *Intelligent & Fuzzy Systems*, Vol. 32, No. 3, pp. 1753-1773, 2017.
- [27] J. Kennedy, R. C. Eberhart, Particle swarm optimization, *Proceedings of International Conference on Neural Networks*, Perth, Australia: IEEE Press, pp. 1942-1948, 1995.
- [28] Botlani Esfahani, M., Toroghinejad, M.R. and Key Yeganeh, A.R., "Modeling the yield strength of hot strip low carbon steels by artificial neural network", *Materials & Design*, Vol. 30, pp. 3653-۳۶۵۸, (۲۰۰۹).

- [29] Hornik, K., Stinchcombe, M. and White, H., "Multilayer feedforward networks are universal approximators", *Neural Networks*, Vol. 2 (5), pp. 359–366, (1989).
- [30] R. Ueji, K. Harada, A. Takemura, K. Kunishige., "Strain rate sensitivity of 31Mn-3Al- $\epsilon$  steel with partially recrystallized fine grained structure", *Materials Science Forum*, 2008, vol. 584-586, pp. 673–678.
- [31] M.E. Hamzehie, S. Mazinani, F. Davardoost, A. Mokhtare, H. Najibi, B. Van der Bruggen, S. Darvishmanesh, Developing a feed forward multilayer neural network model for prediction of CO<sub>2</sub> solubility in blended aqueous amine solutions, *J. Nat. Gas Sci. Eng.* 21 (2014) 19–25.
- [32] Fernández-Fdz D, López-Puente J, Zaera R. Prediction of the behaviour of cfrps against high-velocity impact of solids employing an artificial neural network methodology. *Compos Part A: Appl Sci Manuf* 2008;39(6):989–96.
- [33] N.S. Reddy, A.K. Prasada Rao, M. Chakraborty, B.S. Murty, "Prediction of Grain Size of Al–7Si Alloy by Neural Networks", *Materials Science and Engineering A*, 2005, 391, 131–140.
- [34] A.M. Rashidia, A.R. Eivani, A. Amadeh, "Application of Artificial Neural Networks to Predict the Grain Size of Nano-Crystalline Nickel Coatings", *Computational Materials Science*, 2009, Vol. 45, Issue 2, 499–504.
- [35] López-Puente J, Zaera R, Navarro C. An analytical model for high velocity impacts on thin cfrps woven laminated plates. *Int J Solids Struct* 2007;44 (9):2837–51.
- [36] Fernández-Fdz D, López-Puente J, Zaera R. Prediction of the behaviour of cfrps against high-velocity impact of solids employing an artificial neural network methodology. *Compos Part A: Appl Sci Manuf* 2008;39(6):989–96.
- [37] Hahn H, Tsai S. On the behavior of composite laminates after initial failures. *J Compos Mater* ۱۹۷۴۱۸(۳):۲۸۸–۳۰۵
- [38] Codina, J., B. Morcego, J.M. Fuertes and A. Catala. (1992) A Novel Neural Network Structure for Control. *IEEE Int. Conf on Systems, Man and Cybernetics*. Chicago. pp. 1339-1344
- [39] Hornik, K., 1989. Multilayer feedforward networks are universal approximators. *Neural Networks* 2, 359–366
- [40] Warner, B., Misra, M., 1996. Understanding neural networks as statistical tools. *Amer. Statist.* 50, ۱۸۴–۲۹۳
- [41] Beaverstock, M.C., (1993), "It Takes Knowledge to Apply Neural Networks for Control", pp. ۳۳۵- ۳۴۳, *IEEE Trans on Systems, Man and Cybernetics*, ۱۹۹۳

- [42] Bonavita, N., (1997), “Reti Neurali e Sistemi di Controllo Distribuiti” (“Neural Technology Integrated in a Distributed Control System”), Automazione Oggi, pp. 156-164, March 1997 {in Italian}
- [43] Verbeke, W., Dejaeger, K., Martens, D., Hur, J., & Baesens, B. (2012). New insights into churn prediction in the telecommunication sector: A profit driven data mining approach. *European Journal of Operational Research*, 218(1), 211–229.
- [44] S.S. Ge, J. Zhang, T.H. Lee, Adaptive MNN control for a class of non-affine NARMAX systems with disturbances, *Syst. Control Lett.* 53 (2004) 1–12
- [45] Liestol, K., Andersen, P.K., Andersen, U., 1994. Survival analysis and neural nets. *Statist. Med.* 13, 1189–1200.
- [46] Zeithaml, V., Berry, L., Parasuraman, A., 1996. The behavioural consequences of service quality. *Journal of Marketing* 60 (2), 31–46.
- [47] Verbeke, W., Martens, D., & Baesens, B. (2014). Social network analysis for customer churn prediction. *Applied Soft Computing*, 14, 431–446
- [48] Lariviere, B., Van den Poel, D., 2005. Predicting customer retention and profitability by using random forest and regression forest techniques. *Expert Systems with Applications* 29 (2), 472–484
- [49] Coussement, K., Van den Poel, D., 2008. Churn prediction in subscription services: An application of support vector machines while comparing two parameterselection techniques. *Expert Systems with Applications* 34, 313– 327.
- [50] Hornik K., “Approximation Capabilities of Multilayer Feedforward Networks”, *NeuralNetworks*, Vol. 4, No. 2, 1991, pp. 251-257.
- [51] Hosseini, S.M.K., Zarei-Hanzaki, A., Yazdan Panah, M.J. and Yue, S., "ANN model for prediction of the effects of composition and process parameters on tensile strength and percent elongation of Si–64Mn TRIP steels", *Materials Science and Engineering A*, Vol. 374, pp. 122–128, (2004)