

پیش بینی رفتار تغییر شکل داغ آلیاژ آلومینیوم ۲۰۳۰ با استفاده از شبکه عصبی مصنوعی

حمیدرضا رضایی آشتیانی*
استادیار، دانشکده مهندسی مکانیک، دانشگاه صنعتی اراک، اراک، ایران
پیمان شاهسواری
دانشجوی کارشناسی ارشد، دانشکده مهندسی مکانیک، دانشگاه صنعتی اراک، اراک، ایران

چکیده

رفتار تغییر شکل داغ مواد بدلیل وابستگی آن به تغییرات کرنش، نرخ کرنش و دما دارای پیچیدگی های قابل ملاحظه ای است و لذا پیش بینی رفتار ماده در این شرایط مشکل می باشد. هدف از این بررسی پیش بینی رفتار تغییر شکل داغ آلیاژ آلومینیوم ۲۰۳۰ با استفاده از یک شبکه عصبی مصنوعی توسعه یافته مناسب می باشد. برای این منظور از آزمایش های فشار داغ در محدوده دمایی بین ۳۵۰ تا ۵۰۰ درجه سلسیوس و در نرخ کرنش های بین ۰/۰۰۵ تا ۰/۵ بر ثانیه استفاده شد. با استفاده از نتایج تجربی حاصل از این آزمایشات، یک مدل شبکه عصبی پس انتشار پیش-سو جهت پیش بینی رفتار تغییر شکل داغ این آلیاژ توسعه داده شد که دمای تغییر شکل، لگاریتم نرخ کرنش و کرنش بعنوان ورودی و تنش سیلان به عنوان خروجی این شبکه عصبی در نظر گرفته شد. شبکه مورد استفاده شامل یک لایه مخفی متشکل از ۱۲ نورون با تابع انتقال هلالی مماسی و الگوریتم آموزش لونیبرگ - مارکارت است. بررسی نتایج پیش بینی حاکی از همبستگی بسیار خوب بین نتایج تجربی و نتایج پیش بینی شده می باشد، که نشان دهنده توانایی بالای مدل شبکه عصبی مصنوعی توسعه یافته در پیش بینی سطوح تنش سیلان، و همچنین نواحی سخت شوندگی و نرم شوندگی دینامیکی در منحنی های تنش - کرنش می باشد.

واژه های کلیدی: تغییر شکل داغ، آلیاژ آلومینیوم ۲۰۳۰، شبکه عصبی مصنوعی، تنش سیلان.

Prediction of Hot Deformation Behavior of AA2030 Alloy Using Artificial Neural Networks

H. R. Rezaei Ashtiani
P. Shahsavari

Department of Mechanical Engineering, Arak University of Technology, Arak, Iran
Department of Mechanical Engineering, Arak University of Technology, Arak, Iran

Abstract

Hot deformation behavior of materials is completely complex. Flow stress during hot deformation depends mainly on the strain, strain rate and temperature, and shows a complex and nonlinear relationship with them. Hot deformation characteristics of a AA2030 alloy were investigated by hot compression test over the temperature range from 350-500 °C and strain rate range from 0.005 to 0.5 s⁻¹. Based on these experimental results, a feed-forward back propagation artificial neural network (ANN) model was developed to predict the flow behaviors of AA2030 alloy during hot deformation. The inputs of the neural network were deformation temperature, log strain rate and strain whereas flow stress was the output. This developed network consisted of one hidden layer containing 12 neurons with a tan-sigmoid activation function and Levenberg-Marquardt training algorithm. A very good correlation between experimental and predicted results has been obtained. The results show that the developed artificial neural network model presented an excellent capability to predict the flow stress level, and also the hardening and dynamic softening behavior.

Keywords: Hot deformation, AA2030 alloy, artificial neural network, flow stress.

اکستروژن، مواد از خود رفتارهای پیچیده ای نشان می دهند. در نتیجه بررسی رفتار تغییر شکل فلزات در دماهای بالا و پیش بینی رفتار سیلان مواد دارای اهمیت زیادی می باشد. در سال های اخیر محققان زیادی به ارائه و توسعه مدل های مختلف رفتاری به منظور پیش بینی رفتار سیلان فلزات و آلیاژها در فرایندهای شکل دهی داغ پرداخته اند [۳-۶]. مدل های رفتاری مختلفی جهت توصیف رفتار سیلان مواد پیشنهاد شده است؛ که شامل مدل های پدیدار شناختی^۱، مدل های فیزیکی^۲ و مدل های شبکه عصبی مصنوعی^۳ می باشند. از جمله مهمترین مدل های پدیدار شناختی و فیزیکی که بر اساس روش های رگرسیونی توسعه داده می شوند، می توان به مدل های آرینوسی، جانسون - کوک و زربلی - آرمسترانگ اشاره کرد [۷-۹].

۱- مقدمه

آلیاژهای آلومینیوم به دلیل داشتن ترکیبی بهینه از خواص مکانیکی و فیزیکی در صنایع مختلف دارای کاربردهای فراوانی می باشند. به خصوص، آلیاژهای سری ۲۰۰۰، همچون آلیاژهای AlCuMgPb و AlCuMg که به دلیل داشتن نسبت استحکام به وزن بالا دارای کاربردهای فراوانی در صنایع هوا-فضا و صنایع خودروسازی می باشند [۱ و ۲].

فرایندهای شکل دهی داغ فلزات در صنعت از اهمیت زیادی برخوردار می باشند بطوریکه بیش از ۸۰ درصد محصولات فلزی حداقل یکبار فرایند کار داغ را در حین تولید تجربه می کنند. کار داغ فلزات در محدوده دمایی بین ۰/۵-۰/۹ دمای ذوب و تحت تغییر شکل های بزرگ در نرخ کرنش های بین ۱۰^{-۳}-۱۰ بر ثانیه انجام می گیرد. از این رو در فرایندهای شکل دهی داغ فلزات مانند فرایندهای آهنگری، نورد و

^۱ Phenomenological model

^۲ Physical based model

^۳ Artificial neural network (ANN) model

۲- ماده اولیه و روش تحقیق

درصد عناصر تشکیل دهنده آلیاژ آلومینیوم ۲۰۳۰ در جدول ۱ آورده شده است. برای انجام تست فشار داغ مطابق با استاندارد ASTM E208، نمونه‌های با قطر ۸ میلی‌متر و ارتفاع ۱۲ میلی‌متر با نسبت ارتفاع به قطر ۱/۵ ماشین کاری شده است.

جدول ۱- درصد ترکیب شیمیایی آلیاژ ۲۰۳۰

عنصر	درصد
Cu	۳/۸۵
Pb	۱/۱۲
Mg	۰/۹۲
Fe	۰/۵۸
Si	۰/۳۷
Mn	۰/۲۵
Cr	۰/۰۱
Zn	۰/۳۷
Ti	۰/۰۱

در مرحله بعد بمنظور دستیابی به میکروساختار و خواص مکانیکی یکنواخت در تمامی نمونه‌های آزمایش، نمونه‌ها تحت عملیات حرارتی آنیل قرار گرفت بطوریکه ابتدا در دمای ۴۵۰ سلسیوس به مدت ۱۲۰ دقیقه حرارت داده شده سپس تا دمای ۲۴۰ سلسیوس سرد و برای مدت زمان ۹۰ دقیقه در این دما قرار گرفته و نهایتاً در هوا تا دمای محیط سرد شد. آزمایش‌های فشار داغ بر روی آلیاژ آلومینیوم ۲۰۳۰ پس از انجام عملیات حرارتی آنیل روی نمونه‌ها در دماهای ۳۵۰، ۴۰۰، ۴۵۰ و ۵۰۰ سلسیوس و نرخ کرنش‌های ۰/۰۰۵، ۰/۰۵ و ۰/۵ بر ثانیه صورت گرفت. هر یک از نمونه‌ها به مدت ۵ دقیقه برای رسیدن به تعادل گرمایی درون کوره حرارت داده شدند. سپس تا کرنش ۰/۶ تحت بارگذاری قرار گرفتند. برای کاهش اثرات اصطکاک بین نمونه و فک‌ها از ورق بسیار نازک میکا به عنوان روانکار استفاده شد. شکل ۱ نمونه آزمایش قبل و پس از انجام آزمایش فشار داغ بر روی آن را نشان می‌دهد. منحنی‌های تنش حقیقی در برابر کرنش حقیقی حاصل از آزمایش‌های فشار داغ در نرخ کرنش‌ها و دماهای مختلف در شکل ۲ نشان داده شده است. همان‌طور که مشاهده می‌شود، اثرات نرخ کرنش و دمای تغییر شکل بر تنش سیلان قابل توجه است. به طوری که با افزایش نرخ کرنش و کاهش دما تنش سیلان افزایش می‌یابد. در حالیکه تغییرات مقادیر تنش با کرنش در دماها و نرخهای کرنش مختلف متفاوت می‌باشد.



شکل ۱- نمونه آلومینیوم ۲۰۳۰ قبل (نمونه سمت چپ) و بعد (نمونه سمت راست) از آزمایش فشار داغ

از آنجا که پاسخ رفتار تغییر شکل مواد تحت مقادیر بالای دما و نرخ کرنش غیرخطی بوده و همچنین بسیاری از پارامترهای مؤثر در تعیین تنش سیلان نیز غیرخطی می‌باشند، دقت پیش‌بینی توسط روش‌های رگرسیونی کاهش یافته و کاربرد این مدل‌ها محدود می‌باشد. این درحالی است که شبکه‌های عصبی بهترین مدل برای مسائل پیچیده هستند که حل آن‌ها به وسیله روش‌های سنتی محاسباتی اغلب سخت و پیچیده می‌باشند. شبکه عصبی می‌تواند بر اساس داده‌های آماری و با عددی یک رویکرد کاملاً متفاوت برای مدلسازی رفتار مواد و شیوه‌های کنترل فرایندهای تولید مواد فراهم کند. یکی از مزایای اصلی این روش این است که در ابتدا نیازی به یک مدل ریاضیاتی نیست بلکه با شناسایی پارامترها لازم در شبکه عصبی مصنوعی می‌توان به پیش‌بینی رفتار ماده پرداخت [۱۳-۱۰]. لین و همکارانش [۱۰] با استفاده از شبکه عصبی به بررسی تغییر شکل فشاری فولاد 42CrMo در دماهای بالا پرداختند؛ آنها با ارائه یک مدل شبکه عصبی سه لایه با الگوریتم پس انتشار پیش‌سو رفتار این فلز را بررسی نمودند؛ نتایج نشان از دقت بالای این مدل در پیش‌بینی رفتار سیلان داغ این فلز داشت. میرزایی و همکارانش [۱۴] در سال ۲۰۱۵ یک شبکه عصبی با یک لایه مخفی با ۲۰ نورون برای شبیه‌سازی رفتار فولاد سوپر آستنیت استفاده کردند. آنها با استفاده از الگوریتم پس‌انتشار پیش‌سو شبکه را آموزش دادند. در سال ۲۰۰۸، ردی و همکارانش [۱۵] از مدل شبکه عصبی پس انتشار برای پیش‌بینی رفتار سیلان داغ آلیاژ Ti-6Al-4V استفاده کردند. کین و همکارانش [۱۶] نیز از یک شبکه پس انتشار پیش‌سو سه لایه با یک لایه مخفی و ۱۳ نورون در لایه مخفی برای پیش‌بینی رفتار سیلان آلیاژ منیزیم ZK60 استفاده کردند؛ از نتایج بدست آمده مشخص گردید که این شبکه توانایی پیش‌بینی رفتار سیلان داغ آلیاژ منیزیم ZK60 را دارد. شبکه‌های عصبی مصنوعی با یک یا چند لایه مخفی نیز برای پیش‌بینی رفتار مواد نیز استفاده شده است. هان و همکارانش [۱۷] با استفاده از شبکه عصبی پس انتشار تنش سیلان فولاد ضد زنگ ریخته‌گری شده 904L را در دماها و نرخ کرنش‌های مختلف پیش‌بینی کردند، که در این مدل از سه لایه مخفی با تعداد نورون ۱۱، ۹ و ۳ به ترتیب در لایه‌های اول تا سوم استفاده کردند؛ آنها دقت و کارایی بالا این شبکه برای توصیف رفتار تغییر شکل فشاری در دماهای بالا این فلز را گزارش نمودند. تعداد زیادی از محققان با استفاده از شبکه عصبی مصنوعی و معادلات رفتاری پدیدار شناختی و فیزیکی به بررسی رفتار سیلان فلزات و آلیاژها پرداختند؛ دقت و کارایی بالا شبکه‌های عصبی مصنوعی نسبت به انواع مدل‌های رفتاری برای پیش‌بینی رفتار سیلان از نتایج بدست آمده می‌باشد [۲۱-۱۷].


هدف اصلی این مطالعه توسعه یک شبکه عصبی مصنوعی برای پیش‌بینی رفتار سیلان آلیاژ آلومینیوم ۲۰۳۰ در دماهای بالا می‌باشد. برای این منظور شبکه عصبی با استفاده از داده‌های تجربی حاصل از آزمایش‌های فشار داغ در دماها و نرخ کرنش‌های مختلف توسعه داده می‌شود. همچنین با مقایسه بین داده‌های تجربی و پیش‌بینی شده توانایی شبکه در پیش‌بینی تنش سیلان، سخت شوندگی و نرم شوندگی دینامیکی با استفاده از تحلیل‌ها آماری مانند ضریب همبستگی، میانگین خطای مطلق و ریشه میانگین مربع خطا مورد ارزیابی قرار می‌گیرد.

دهد. شبکه‌های عصبی یک ابزار برای مدل‌سازی داده‌های آماری غیر-خطی می‌باشد. آن‌ها را می‌توان برای مدل روابط پیچیده بین ورودی‌ها و خروجی‌ها یا برای پیدا کردن الگوهای موجود در داده‌ها استفاده کرد [۱۲]. یک شبکه عصبی معمولی شامل یک لایه ورودی، یک یا چند لایه مخفی و یک لایه خروجی است. هر نورون در لایه‌های مخفی نشان دهنده یک متغیر مستقل است. همه نورون‌های شبکه به وسیله وزن‌ها به یکدیگر متصل هستند.

همانطور که از شکل ۳ مشخص شده است لایه ورودی، داده‌های ورودی را دریافت و بعد از پردازش، آن‌ها را به لایه مخفی ارسال می‌کند سپس لایه‌های مخفی داده‌ها را پردازش و یک پاسخ به لایه خروجی می‌فرستد و نهایتاً لایه خروجی پاسخ را پذیرفته و نتایج را ارائه می‌کند. به طور کلی، خروجی‌های یک نورون از حاصلضرب ورودی‌هایش با بردار وزن و جمع نتایج با بکارگیری تابع فعال‌سازی مانند رابطه (۱) محاسبه می‌گردد [۲۲]:

$$y = f\left(\sum_{i=1}^n \omega_i x_i - b\right) \quad (1)$$


که y مقادیر خروجی، x_i مقادیر ورودی، f تابع انتقال نورون، ω_i وزن اتصال و b بایاس نورون می‌باشند.




شکل ۳- نحوه عملکرد یک شبکه عصبی سه لایه

توسعه یک شبکه عصبی ترکیبی از انتخاب داده‌های تجربی؛ تعیین پارامترهای ورودی و خروجی؛ تحلیل و پیش پردازش داده‌های انتخابی، آموزش شبکه؛ آزمایش شبکه آموزش دیده و نهایتاً ارزیابی کارایی شبکه توسعه یافته می‌باشد [۲۳]. از میان انواع مختلف شبکه‌های عصبی مصنوعی، شبکه پیش-سو^۱ با الگوریتم پس انتشار^۲ کارآمدترین در علوم و کاربردهای مهندسی می‌باشد. در واقع شبکه عصبی پس انتشار پیش-سو از ترکیب دو الگوریتم پیش سو و پس انتشار ساخته شده است [۱۰]. اصطلاح پیش-سو به این معناست که نورون‌های در لایه‌های متوالی قرار گرفته‌اند و خروجی خود را به جلو می‌فرستند. در حالی که اصطلاح پس انتشار نیز به این معنا می‌باشد که خطاها به سمت عقب در شبکه ارسال می‌شوند تا وزن‌ها را اصلاح کنند و پس از آن، مجدداً ورودی مسیر پیش-سو خود را تکرار کند.


در الگوریتم پس انتشار، خطای بین خروجی‌های شبکه و خروجی‌های هدف مقایسه شده و خطای شبکه محاسبه می‌گردد. در این الگوریتم با استفاده از کاهش شیب و کمینه کردن خطا، وزن‌های لازم برای یک شبکه چند لایه با ساختار شبکه ثابت را پیدا می‌کند.



(الف)



(ب)



(ج)

شکل ۲- منحنی‌های تنش-کرنش حقیقی در دماهای مختلف و در نرخ کرنش‌های (الف) 0.005 s^{-1} (ب) 0.05 s^{-1} و (ج) 0.5 s^{-1}


۳- توسعه شبکه‌های عصبی مصنوعی

۳-۱- تئوری شبکه‌های عصبی مصنوعی


یک شبکه عصبی مصنوعی یک مدل ریاضی یا محاسباتی می‌باشد که در تلاش برای شبیه سازی ساختار و یا جنبه‌های اساسی شبکه‌های عصبی بیولوژیکی هستند. این شبکه‌ها شامل تعداد زیادی عناصر پردازنده‌ی متصل به هم با نام نورون هستند، که به صورت هماهنگ با یکدیگر کار می‌کنند. در اغلب موارد یک شبکه عصبی مصنوعی یک سیستم تطبیقی است که ساختار خود را بر اساس اطلاعات خارجی و یا داخلی از طریق جریان در شبکه در طول مرحله یادگیری تغییر می-

¹ Feed-forward

² Back Propagation (BP)



شکل ۴- طرحواره‌ای از معرفی ساختار شبکه عصبی مصنوعی برای پیش‌بینی تنش سیلان



شکل ۵- تابع هلالی مماسی

کل داده‌های ورودی و خروجی مورد استفاده برای شبکه عصبی ۳۳۶ داده می‌باشد، که از نمودارهای تنش- کرنش حقیقی بین کرنش‌های ۰/۰۶ تا ۰/۶ با فاصله ۰/۰۲ انتخاب شده‌اند. از میان کل داده‌ها، ۸۰٪ داده (۲۶۹ داده) برای آموزش شبکه استفاده شد و ۲۰٪ (۶۷ داده) باقی‌مانده برای آزمایش پیش‌بینی پذیری شبکه آموزش دیده مورد استفاده قرار گرفت. کلیه متغیرهای ورودی و خروجی در بازه بین ۰ و ۱ جهت یکسان‌سازی در یک بازه نرمالیزه شده‌اند. توسعه شبکه عصبی با استفاده از نرم افزار MATLAB ۲۰۱۵ انجام گردید.

تعیین تعداد لایه‌های مخفی و تعداد نورون‌های لایه مخفی یکی از وظایف مهم در به دست آوردن یک شبکه عصبی کارآمد است که می‌تواند برای پیش‌بینی رفتار سیلان دقیق مورد استفاده قرار گیرد. تعداد نورون‌های لایه مخفی به ماهیت مسائل مورد بررسی، اثرات قابل توجه پیچیدگی مدل شبکه و دقت و صحت نتایج پیش‌بینی مرتبط است. اگر معماری شبکه خیلی ساده باشد، شبکه ممکن است توانایی کافی برای یادگیری فرایند را نداشته باشد. از سوی دیگر اگر شبکه بیش از حد پیچیده باشد، مدل ممکن است در طول آموزش همگرا نشود یا شبکه از حالت یادگیری خارج شود. روش سعی و خطا برای تعیین تعداد نورون‌ها در لایه مخفی در محدوده بین ۱ تا ۲۰ استفاده می‌شود که تعداد نورون‌ها با مقادیر بیش‌تر از ۲۰ به منظور جلوگیری از وقوع خارج شدن شبکه از حالت یادگیری در نظر گرفته نمی‌شوند. به طور کلی، شبکه‌های عصبی هرمی به‌خوبی برای بسیاری از مسائل قابل استفاده می‌باشند. بنابراین چندین شبکه با یک، دو و سه لایه مخفی آموزش دیده‌اند و خطای میانگین مربعات^۲ متناظر با هر شبکه برای بررسی عملکرد معماری شبکه محاسبه گردید. در واقع، خطای میانگین

۳-۲- نرمالیزه کردن داده‌ها

شبکه عصبی نیاز دارد که داده‌های ورودی و خروجی در محدوده بین ۰ تا ۱ باشد، در نتیجه داده‌ها باید نرمالیزه شوند. روشی که به صورت گسترده برای نرمالیزه کردن یا یکسان سازی استفاده می‌شود به صورت زیر است:

$$X_n = 0.1 + 0.8 \times \left(\frac{X - X_{\min}}{X_{\max} - X_{\min}} \right) \quad (2)$$

که X داده‌های اصلی، $X_{\min}$ و $X_{\max}$ بترتیب مقدار کمینه و بیشینه X و X_n داده‌های یکپارچه متناظر با X می‌باشد. از این معادله برای یکسان‌سازی داده‌های ورودی و خروجی استفاده می‌شود. معادله (۲) برای نرمالیزه کردن همه داده‌های مورد بررسی در این مطالعه مناسب نیست؛ به دلیل این‌که به شدت نرخ کرنش تغییر می‌کند و کمترین مقدار نرخ کرنش نرمالیزه شده برای آموزش شبکه بسیار کوچک است. از آنجا که تغییرات نرخ کرنش ۱۰ برابر است، روش لگاریتمی نرمالیزه کردن برای کاهش این اختلاف و نزدیک شدن داده‌های نرمالیزه برای آموزش شبکه استفاده گردید، که به شرح زیر است:

$$\varepsilon_n = 0.1 + 0.8 \times \left(\frac{\log \varepsilon - \log \varepsilon_{\min}}{\log \varepsilon_{\max} - \log \varepsilon_{\min}} \right) \quad (3)$$

۳-۳- طراحی و آموزش شبکه برای پیش‌بینی تنش سیلان

در این پژوهش با توجه به آزمایش‌های صورت گرفته در دماها و نرخ کرنش‌های مختلف و بررسی رفتار سیلان آلیاژ آلومینیوم ۲۰۳۰، ورودی‌های مدل شبکه عصبی مورد بررسی شامل دمای تغییر شکل (T)، لگاریتم نرخ کرنش ($\log \dot{\varepsilon}$) و کرنش (ε) و خروجی مدل تنش سیلان (σ) در نظر گرفته شده است. در اینجا از یک شبکه سه لایه پیش-سو با الگوریتم یادگیری پس انتشار برای آموزش مدل با یک لایه ورودی، یک لایه مخفی و یک لایه خروجی استفاده شده است. یادگیری بر اساس الگوریتم لونیگ-مارکارت می‌باشد. این الگوریتم در مقایسه با دیگر الگوریتم‌ها معمولاً سریع‌تر و در تعداد تکرارهای کمتری همگرا می‌شود [۱۷]. طرحواره‌ای از ساختار شبکه برای پیش‌بینی تنش سیلان آلیاژ آلومینیوم ۲۰۳۰ در شکل ۴ نشان داده شده است. در شبکه‌های عصبی معمولاً از توابع انتقال مانند تابع هلالی مماسی^۱ یا هلالی لگاریتمی^۲ به عنوان تابع فعال‌سازی برای لایه‌های مخفی استفاده می‌شوند، در حالی که تابع انتقال خطی را می‌توان برای نورون‌های خروجی استفاده کرد [۲۴ و ۲۵]. توابع هلالی مماسی و هلالی لگاریتمی به ترتیب بین -۱ تا ۱ و ۰ تا ۱ تغییر می‌کنند که آن‌ها را می‌توان به صورت معادلات (۴) و (۵) بیان کرد. در این شبکه از یک تابع هلالی مماسی به عنوان تابع انتقال در لایه‌های مخفی و لایه خروجی استفاده شده است (شکل ۵).


$$f = \text{tansig}(x_i) = \frac{\exp(x_i) - \exp(-x_i)}{\exp(x_i) + \exp(-x_i)} \quad (4)$$

$$f = \text{logsig}(x_i) = \frac{1}{1 + \exp(-x_i)} \quad (5)$$


^۱Tan sigmoid

^۲ Log sigmoid


^۳ Mean Square Error (MSE)



(الف)



(ب)



(ج)

شکل ۶- نتایج تنش سیلان تجربی و پیش بینی شبکه عصبی در نرخ کرنش های (الف) 0.005 s^{-1} (ب) 0.05 s^{-1} و (ج) 0.5 s^{-1}

که E_i داده های تجربی، P_i داده های پیش بینی شده توسط شبکه عصبی، $\bar{E}$ و $\bar{P}$ به ترتیب مقادیر متوسط داده های تجربی و پیش بینی شده از شبکه عصبی هستند، N تعداد کل داده های مورد بررسی است. ضریب همبستگی معمولاً برای نشان دادن رابطه خطی بین مقادیر پیش بینی شده و داده های تجربی می باشد. ضریب همبستگی اغلب برای بررسی شدت رابطه خطی بین مقادیر تجربی و پیش بینی شده می باشد. مقدار R اغلب به صورت یک عدد بین ۰ و ۱ مشاهده می شود. R نزدیک به ۱ نشان می دهد که رگرسیون خطی داده ها، برازش خوبی دارند در حالی که هرچه قدر به صفر نزدیک شود نشان می دهد که رگرسیون خطی برازش داده ها خوب نیست. از این رو یک معادله ممکن

مربعات به عنوان معیاری برای ارزیابی توانایی معماری یک شبکه عصبی است، که از معادله (۶) بدست می آید:

$$MSE = \frac{1}{n} \sum_{i=1}^n (E_i - P_i)^2 \quad (6)$$

که n تعداد کل داده ها، E_i مقادیر تجربی و P_i مقادیر پیش بینی شده می باشند.

۴- نتایج و بحث

در تعیین تعداد نورون های لایه مخفی پس از سعی و خطا و تکرار در آموزش شبکه به وسیله تغییر در تعداد نورون ها از ۲۰-۲۰۰ در لایه مخفی، در نهایت ۱۲ نورون در این لایه در نظر گرفته شد. در این حالت شبکه بهترین عملکرد را از خود نشان داد. به طوری که با کاهش و افزایش تعداد نورون در لایه مخفی از کارایی شبکه کم و شبکه از حالت یادگیری خارج می گردد. مقایسه بین نتایج تجربی حاصل از آزمایش و پیش بینی شبکه عصبی برای آلیاژ آلومینیوم ۲۰۳۰ در شکل ۶ نشان داده شده است. نتایج نشان می دهد که پیش بینی شبکه عصبی حاصل داده های آزمایش در طیف گسترده ای از داده ها قابل قبول است. داده های پیش بینی شده از شبکه عصبی به خوبی رفتار تغییر شکل آلومینیوم ۲۰۳۰ در دماها و نرخ کرنش های مختلف را نشان می دهند. همچنین توانایی خوب شبکه عصبی در پیش بینی رفتار سخت شوندگی و نرم شوندگی دینامیکی این آلیاژ مشاهده می شود. به طوری که در دماهای پایین، ۳۵۰ سانتی گراد، به خوبی رفتار سخت شوندگی و در نرخ کرنش ۰/۵ بر ثانیه رفتار نرم شوندگی آلیاژ آلومینیوم ۲۰۳۰ توسط شبکه عصبی با کمترین میزان خطا پیش بینی شده است. هان و همکارانش [۱۷] و ژیاو و همکارانش [۱۸] به ترتیب برای فولاد ضد زنگ و فولاد 12Cr3WV توانایی پیش بینی رفتار سخت شوندگی و نرم شوندگی توسط شبکه عصبی توسعه داده خود را گزارش کرده اند. قابلیت پیش بینی و کارایی مدل شبکه عصبی به طور کلی از طریق ضریب همبستگی^۱ (R)، میانگین خطای مطلق نسبی^۲ ($AARE$) و ریشه میانگین مربع خطا^۳ ($RMSE$) شرح داده می شود. که به صورت معادلات زیر تعریف می شوند:

$$R = \frac{\sum_{i=1}^N (E_i - \bar{E})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^N (E_i - \bar{E})^2 \sum_{i=1}^N (P_i - \bar{P})^2}} \quad (7)$$


$$AARE (\%) = \frac{1}{N} \sum_{i=1}^N \left| \frac{E_i - P_i}{E_i} \right| \times 100 \quad (8)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (E_i - P_i)^2} \quad (9)$$


¹Correlation coefficient (R)

²Average absolute relative error ($AARE$)

³Average root mean square error ($RMSE$)




(الف)



(ب)

شکل ۷- مقادیر تجربی و پیش بینی شده توسط شبکه عصبی برای داده‌های (الف) آموزش دیده و (ب) آزمایش شده



شکل ۸- پراکندگی میانگین خطای مطلق بین داده تجربی و پیش‌بینی

همان‌طور که قبلاً گفته شد، E_i و P_i به ترتیب داده‌های تجربی و پیش بینی شده هستند. نتایج به صورت تکرار در داده‌ها در مقابل درصد خطای نسبی برای هر دو داده‌های آموزش و آزمایش در شکل ۹ (الف)

است تمایل به سمت مقادیر بالاتر و پایین‌تر نشان دهد. بنابراین، مقادیر بالاتر R همیشه نشان دهنده عملکرد بهتر مدل نیست [۲۵]. $AARE$ و $RMSE$ آمارهای بی‌طرفانه‌ای برای اندازه‌گیری قابلیت پیش‌بینی یک مدل است، به‌طوری که برای مقادیر $AARE$ و $RMSE$ مقادیر کوچک‌تر بهتر هستند [۲۶]. جدول ۲ توانایی پیش‌بینی شبکه عصبی برای داده‌های آموزش و آزمایش را نشان می‌دهد. می‌توان دریافت که مقادیر $AARE$ برای مجموعه داده‌های آموزش و آزمایش به ترتیب برابر با ۰/۴۴۶۹٪ و ۰/۵۱۵۳٪ هستند، که نشان می‌دهد توانایی شبکه در آموزش و آزمایش راضی‌کننده است.

جدول ۲- توانایی مدل شبکه عصبی مصنوعی برای پیش‌بینی آموزش و آزمایش

داده‌ها	R	$AARE(\%)$	$RMSE$
داده‌های آموزش	۰/۹۹۹۹	۰/۴۴۶۹	$۰/۳۴۳۷ \times 10^{-۵}$
داده‌های آزمایش	۰/۹۹۹۸	۰/۵۱۵۳	$۳/۰۶۶۴ \times 10^{-۵}$

مقایسه مقادیر تنش سیلان تجربی حاصل از آزمایش فشار داغ و پیش‌بینی شبکه عصبی مصنوعی در طول آموزش و آزمایش شبکه عصبی برای آلیاژ آلومینیوم ۲۰۳۰ در شکل ۷ (الف) و (ب) نشان داده شده است؛ که مشاهده می‌شود که پیش‌بینی شبکه عصبی دارای دقت بالایی می‌باشد. خط فرضی ۴۵ درجه نشان می‌دهد که مدل شبکه عصبی توانایی پیش‌بینی رفتار تغییر شکل داغ آلیاژ آلومینیوم ۲۰۳۰ را با دقت بالا دارد. مندل و همکارانش [۱۳] دقت بالای شبکه عصبی جهت پیش‌بینی رفتار کار داغ فولاد 304L در آموزش و آزمایش داده را گزارش کردند.

شکل ۸ نشان دهنده میانگین خطای مطلق بین داده تجربی و پیش‌بینی شده می‌باشد که مشاهده می‌گردد که خطای مطلق بیش از ۹۵ درصد داده‌های پیش‌بینی شده کمتر از ۱ مگاپاسکال می‌باشد بر اساس شکل ۸ توانایی بالا شبکه عصبی در پیش‌بینی دقیق با کمترین میزان خطا قابل مشاهده است.

یکی دیگر از روش‌های بررسی توانایی مدل شبکه عصبی استفاده از تحلیل استاتیکی خطای پیش‌بینی شبکه عصبی برای داده‌های آموزش دیده و داده‌های مورد آزمایش است. پیش‌بینی‌های شبکه عصبی با داده‌های تجربی متناظر مقایسه می‌شوند، و در نهایت خطای مطلق به صورت زیر محاسبه می‌گردد:


$$\text{Relative Error}(\%) = \left(\frac{E_i - P_i}{E_i} \right) \times 100 \quad (10)$$

۱۰×۰.۶۶۴۳ شده‌اند؛ که نشان دهنده توانایی بالا شبکه در پیش بینی تنش سیلان می باشد. مقایسه نتایج تجربی حاصل آزمایش فشار داغ و نتایج پیش‌بینی شده از شبکه عصبی توسعه داده شده، نشان دهنده قابلیت خوب پیش‌بینی شبکه عصبی توسعه یافته در طیف گسترده‌ای از داده‌ها و شرایط آزمایشی می باشد. داده‌های پیش‌بینی شده به خوبی نواحی کارسختی و نرم شوندگی دینامیکی از رفتار تغییر شکل آلومینیوم ۲۰۳۰ در دماها و نرخ کرنش‌های مختلف را مدل می کند.


۶- مراجع

- [1] Lin Y. C., Li Q. F., Xia Y. C., and Li L. T., A phenomenological constitutive model for high temperature flow stress prediction of Al-Cu-Mg alloy, Mater.Sci.Eng. A, Vol. 534, pp. 654-662, 2012.
- [2] Malas J., Venugopal S., and Seshacharyulu T., Effect of microstructural complexity on the hot deformation behavior of aluminum alloy 2024, Mater.Sci.Eng. A, Vol. 368, No 1-2, pp. 41-47, 2004.
- [3] RezaeiAshtiani H.R., Parsa M., and Bisadi H., Constitutive equations for elevated temperature flow behavior of commercial purity aluminum, Mater.Sci.Eng. A, Vol. 545, pp. 61-67, 2012.
- [4] Guo J. H., Zhao S. D., Yan G. H., and Wang Z. B., Novel flow stress model of AA 4343 aluminium alloy under high temperature deformation, Mater.Sci.and Tech, Vol. 29, No. 2, pp. 197-203, 2013.
- [5] Lin Y., Xia Y. C., Chen X. M., and Chen M. S., Constitutive descriptions for hot compressed 2124-T851 aluminum alloy over a wide range of temperature and strain rate, Comput. Mater. Sci., Vol. 50, No. 1, pp. 227-233, 2010.
- [6] Shi C., Mao W., and Chen X. G., "Evolution of activation energy during hot deformation of AA7150 aluminum alloy", Mater.Sci.Eng. A, Vol. 571, pp. 86-91, 2013.
- [7] Lin Y., and Chen X. M., A critical review of experimental results and constitutive descriptions for metals and alloys in hot working, Mater. Des., Vol. 32, No. 4, pp. 1733-1759, 2011.
- [8] Shin H., and Kim J. B., A Phenomenological Constitutive Equation to Describe Various Flow Stress Behaviors of Materials in Wide Strain Rate and Temperature Regimes, J. Eng. Mater. Tech, Vol. 132, No. 2, pp. 1-6, 2010.
- [9] Rusinek A., and Rodriguez-Martinez J., A. Arias, A thermo-viscoplastic constitutive model for FCC metals with application to OFHC copper, Inter. J. Mech. Sci., Vol. 52, No. 2, pp. 120-135, 2010.
- [10] Lin Y. C., Zhang J., and Zhong J., Application of neural network to predict the elevated temperature flow behavior of a low alloy steel, Comput. Mater.Sci., Vol. 43, No. 4, pp. 752-758, 2008.
- [11] Sheikh H., and Serajzadeh S., Estimation of flow stress behavior of AA5083 using artificial neural networks with regard to dynamic strain ageing effect, J. Mater. Process. Tech., Vol. 196, No. 1-3, pp. 115-119, 2008.
- [12] Guoliang J., Fugue L., Qinghua L., Huiqu L., and Zhi L., Prediction of the hot deformation behavior for Aermet100 steel using an artificial neural network, Comput. Mater.Sci., Vol. 48, No. 3, pp. 626-632, 2010.
- [13] Mandal S., Sivaprasad P., Venugopal S., And Murthy K., Artificial neural network modeling to evaluate and predict the deformation behavior of stainless steel type AISI 304L during hot torsion, Applied Soft Comput., Vol. 9, No. 1, pp. 237-244, 2009.
- [14] Mirzaei A., Zarei-Hanzaki A., Pishbin M. H., Imandoust A., and Khoddam S., Evaluating the Hot Deformation Behavior of a Super-Austenitic Steel Through

و (ب) نشان داده شده است. آنچه مشخص است این که خطاهای آموزش و آزمایش به صورت گوسی معمولی توزیع شده‌اند. مشاهده می‌شود که خطای نسبی بیش از ۹۰٪ داده‌های آموزش و آزمایش بین $\pm 2\%$ قرار دارند. برای داده‌های آموزش شبکه عصبی میانگین برابر با ۰.۰۵۷٪ و انحراف استاندارد برابر با ۰.۴۶۵۹٪ می باشد، همچنین برای داده‌های آزمایش این مقادیر به ترتیب ۰.۱۲۳۱٪ و ۰.۶۵۴۹٪ محاسبه شده است.



(الف)



(ب)

شکل ۹- تحلیل استاتیکی خطای پیش‌بینی شبکه عصبی برای داده‌های (الف) آموزش و (ب) آزمایش

۵- نتیجه گیری

در این مطالعه یک مدل شبکه عصبی مصنوعی با الگوریتم پس انتشار پیش مسو جهت پیش‌بینی رفتار سیلان داغ آلیاژ آلومینیوم ۲۰۳۰ بر اساس نتایج تجربی حاصل از آزمایش‌های فشار داغ در دماهای ۳۵۰-۴۵۰ درجه سانتی گراد و در نرخ کرنش‌های ۰.۰۵-۰.۱ بر ثانیه توسعه داده شد. در این مدل توسعه یافته، ورودی‌ها شامل دما، کرنش و لگاریتم نرخ کرنش هستند و تنش سیلان به عنوان خروجی تعریف گردید. بعد از آزمایش‌های مکرر و براساس سعی و خطا، مشخص شد معماری بهینه شبکه با یک لایه مخفی متشکل از ۱۲ نورون است که برای پیش‌بینی تنش سیلان برای آلیاژ آلومینیوم ۲۰۳۰ استفاده می-گردد. مقادیر ضریب همبستگی (R) برای مجموعه داده‌های آموزش و آزمایش به ترتیب برابر با ۰.۹۹۹۹ و ۰.۹۹۹۸ میانگین خطای مطلق نسبی ($AARE$) به ترتیب برابر با ۰.۴۶۹٪ و ۰.۵۱۵۳٪ و ریشه میانگین مربع خطا ($RMSE$) نیز به ترتیب برابر با $10^{-5} \times 0.3437$ و 10^{-5}

- Microstructural and Neural Network Analysis, J. Mater.Eng.Perf.,Vol. 24, No. 6, pp. 1-10, 2015.
- [15] Reddy N. S., Lee Y. H., Park C. H., and Lee C. S., Prediction of flow stress in Ti-6Al-4V alloy with an equiaxed microstructure by artificial neural networks, Mater.Sci.Eng. A, Vol. 492, No. 1-2, pp. 276-282, 2008.
- [16] Qin Y. J., Pan Q. L., He Y. B., Li W. B., Liu X. Y., and Fan X., Artificial Neural Network Modeling to Evaluate and Predict the Deformation Behavior of ZK60 Magnesium Alloy During Hot Compression, Mater. Manu.Process., Vol. 25, pp. No. 7, 539-545, 2010.
- [17] Han Y., Qiao G., Sun J., and Zou D., A comparative study on constitutive relationship of as-cast 904L austenitic stainless steel during hot deformation based on Arrhenius-type and artificial neural network models, Comput. Mater. Sci., Vol. 67, pp. 93-103, 2013.
- [18] Xiao X., Liu G., Hu B., Zheng X., Wang L., Chen S., and Ullah A., A comparative study on Arrhenius-type constitutive equations and artificial neural network model to predict high-temperature deformation behaviour in 12Cr3WV steel, Comput. Mater.Sci., Vol. 62, pp. 227-234, 2012.
- [19] Li H. Y., Wang X. F., Wei D. D., Hu J. D., and Li Y. H., A comparative study on modified Zerilli-Armstrong, Arrhenius-type and artificial neural network models to predict high-temperature deformation behavior in T24 steel, Mater.Sci.Eng. A, Vol. 536, pp. 216-222, 201.
- [20] Chai R. X., Guo C., and Yu L., Two flowing stress models for hot deformation of XC45 steel at high temperature, Mater.Sci. Eng. A, Vol. 534, pp. 101-110, 2012.
- [21] Chen C., Yin H., Islam I., HumailS., Wang Y., and Qu X., A comparative study of a back propagation artificial neuralnetwork and a Zerilli-Armstrong model for pure molybdenumduring hot deformation, Inter. J. Refractory Metal. Hard Mater., Vol. 25, No. 5-6, pp. 411-416, 2007.
- [22] Liu J., Chang H., Hsu T. Y., and Ruan X., Prediction of the flow stress of high-speed steel during hot deformation using a BP artificial neural network, J. Mater. Process. Tech., Vol. 103, No. 2, pp. 200-205, 2000.
- [23] Zhao J., Ding H., Zhao W., Huang M., Wei D., and Jiang Z., Modelling of the hot deformation behaviour of a titanium alloy using constitutive equations and artificial neural network, Comput. Mater. Sci., Vol. 92, pp. 47-56, 2014.
- [24] Wu R. H., Liu J. T., Chang H. B., Hsu T. Y., and Ruan X. Y., Prediction of the flow stress of 0.4C-1.9Cr-1.5Mn-1.0Ni-0.2Mo steel during hot deformation, J. Mater. Process. Tech.,Vol. 116, No. 2-3, pp. 211-218, 2001.
- [25] Phaniraj P. M., and Lahiri K. A., The applicability of neural network model to predict flow stress for carbon steels, J. Mater. Process. Tech., Vol. No. 2, 141, pp. 219-227, 2003.
- [26] Srinivasulu S., and Jain A., A comparative analysis of training methods for artificial neural network rainfall-runoff models, Applied Soft Comput., Vol. 6, No. 3, pp. 295-306, 2006.