



پیش‌بینی سختی در نانو‌کامپوزیت‌های $\text{Al-Al}_2\text{O}_3$ با استفاده از شبکه عصبی مصنوعی با تغییر عوامل موثر در روش آلیاژسازی مکانیکی

علی شکوفه‌فر^{۱*}، سعیده قربان‌پور^۲، سجاد نصیری خلیل‌آباد^۳، اشکان ذوالریاستین^۴، علی اصغر جعفری^۵

- ۱- استاد مهندسی مواد، دانشکده مکانیک، دانشگاه صنعتی خواجه نصیر الدین طوسی، تهران
- ۲- دانشجوی کارشناسی ارشد مهندسی مکانیک، دانشکده مکانیک، دانشگاه صنعتی خواجه نصیر الدین طوسی، تهران
- ۳- دانشجوی دکترا مهندسی مواد، دانشکده مهندسی مواد، دانشگاه صنعتی سهند، تبریز
- ۴- دانشجوی دکترا مهندسی مواد، دانشکده مکانیک، دانشگاه صنعتی خواجه نصیر الدین طوسی، تهران
- ۵- دانشیار مهندسی مکانیک، دانشکده مکانیک، دانشگاه صنعتی خواجه نصیر الدین طوسی، تهران

* تهران، صندوق پستی ۱۹۳۹۵۱۹۹۹ shokuhfar@kntu.ac.ir

چکیده- در این پژوهش یک شبکه پیشرو با الگوریتم پسانشوار خطأ، برای پیش‌بینی سختی نانوکامپوزیت‌های آلومینیوم-آلومینیا، تولید شده به روش آلیاژسازی مکانیکی، با استفاده از داده‌های موجود طراحی شد. مقدار و اندازه ذرات تقویت‌کننده، نیرو در آزمون سختی؛ همچنین برخی از عوامل موثر بر فرآیند آلیاژسازی به عنوان متغیرهای ورودی شبکه و سختی ویکرز به عنوان خروجی شبکه درنظر گرفته شدند. نرخ آموزش، تعداد لایه‌های پنهان و تعداد نرون‌ها با درنظر گرفتن مقدار و درصد خطأ تعیین شدند. برای بررسی عملکرد شبکه، از میانگین مربعات خطأ و نمودارهای رگرسیون استفاده شد. شبکه طراحی شده سختی ویکرز داده‌های تست را با میانگین خطای ۲/۶۷ درصد (معدل ۲/۲۵ ویکرز) پیش‌بینی می‌نماید. با استفاده از مدل شبکه عصبی، سختی ویکرز نانوکامپوزیت آلومینیوم-آلومینیا، بدون نیاز به کارهای آزمایشگاهی پرهزینه، قابل پیش‌بینی می‌باشد.

کلیدواژگان: نانوکامپوزیت زمینه آلومینیومی، میکرو سختی ویکرز، آلیاژسازی مکانیکی، شبکه عصبی مصنوعی.

Prediction of hardness in $\text{Al-Al}_2\text{O}_3$ nanocomposite using artificial neural network with alternation in effective parameters of mechanical alloying method

A. Shokuhfar^{1*}, S. Ghorbanpour², S. Nasiri Khalil Abad³, A. Zolriasatein⁴, A.A. Jafari⁵

1- Prof., Materials Eng., Faculty of Mech. Eng., K. N. Toosi Univ. of Tech., Tehran, Iran

2- MSc Student, Mech. Eng., Faculty of Mech. Eng., K. N. Toosi Univ. of Tech., Tehran, Iran

3- PhD Candidate, Materials. Eng., Faculty of Materials Engineering, Sahand University of Technology, Tabriz, Iran

4- PhD Candidate, Materials. Eng., Faculty of Mechanical Engineering, K. N. Toosi University of Technology, Tehran, Iran

5- Assoc. Prof., Mech. Eng., Faculty of Mech Eng. K. N. Toosi Univ of Tech, Tehran, Iran

* P.O.B. 19395-1999 Tehran, Iran. shokuhfar@kntu.ac.ir

Abstract- In this study a feed forward back propagation artificial neural network (ANN) model was established to predict Vickers microhardness in aluminum-alumina nanocomposites which have been synthesized by mechanical alloying. Volume percent and size of reinforcement, force in microhardness test; and some of mechanical alloying parameters were used as the inputs and hardness was the output of the model. learning rate, hidden layers and number of neurons, were determined due to amount and percentage of errors. Regression analysis and mean squared error were used to verify the performance of neural network. Average error of predicted results was 2.67% or 2.25 Vickers. As can be expected, ANN methods reduce the expenses of experimental investigations, by predicting the optimum parameters.

Keywords: Aluminum Based Nanocomposite, Vickers Microhardness, Mechanical Alloying, Artificial Neural Network.

۱- مقدمه

امروزه با پیشرفت فناوری نیاز به مواد پیشرفته مهندسی با کارایی بالا و خواص مطلوب در بخش‌های مختلف صنعت افزایش یافته است. در میان این مواد پیشرفته نانوکامپوزیت‌ها جایگاه ویژه‌ای را به خود اختصاص داده‌اند. در میان انواع نانوکامپوزیت‌ها، نانوکامپوزیت‌های زمینه فلزی به دلیل استحکام بالا با حفظ رفتار فلزی نظری انعطاف‌پذیری مناسب، خواص الکتریکی و حرارتی مطلوب و نقطه ذوب نسبتاً بالا مورد توجه محققان قرار گرفته‌اند. انواع زمینه‌های فلزی نظری آلومینیوم، مس، آهن، منیزیم، تیتانیم و دیگر فلزات مورد بررسی قرار گرفته که نانوکامپوزیت‌های پایه آلومینیومی تقویت شده با ذرات سرامیکی به دلیل وزن کم، استحکام ویژه بالا و خواص مکانیکی عالی مانند استحکام تسلیم، استحکام نهایی، سختی، مقاومت به خستگی، مقاومت به سایش بالا، قابلیت ماشین‌کاری و ضربه انبساط حرارتی پایین‌بیشتر برای کاربردهای مختلف به ویژه در صنایع حمل و نقل و هواپما پیشنهاد شده‌اند [۲، ۱].

تاکنون برای تولید نانوکامپوزیت‌های زمینه فلزی از روش‌های ساخت مختلفی شامل آلیاژسازی مکانیکی^۱، تفجوشی نانو^۲، خلازایی اولتراسونیک^۳ و ریخته‌گری استفاده شده است. نکته مهم در تولید نانوکامپوزیت‌های فلزی با ذرات تقویت‌کننده سرامیکی، این است که ذرات سرامیک به طور یکنواخت در سراسر ماتریس توزیع شوند [۲]. از بین روش‌های ممکن برای تولید نانوکامپوزیت‌های با پایه فلزی، روش آلیاژسازی مکانیکی توزیع مناسب‌تری از نانو ذرات تقویت‌کننده در ماتریس ایجاد می‌کند [۴، ۳].

تقویت ماتریس آلومینیومی با استفاده از یک فاز قوی‌تر مانند اکسیدها، کاربیدها و نیتریدها به عنوان تقویت‌کننده، ترکیبی از خواص ماتریس فلزی و تقویت‌کننده سرامیکی را ایجاد می‌کند که منجر به بهبود قابل ملاحظه خواص مکانیکی و فیزیکی کامپوزیت می‌شود [۵]. متدائل‌ترین تقویت‌کننده‌ای که برای ماتریس آلومینیومی به کار می‌رود، کاربید سیلیکون (SiC) و آلومینا (Al₂O₃) است که به دلیل در دسترس بودن، قیمت پایین و ایجاد خواص مکانیکی مناسب می‌باشد [۶].

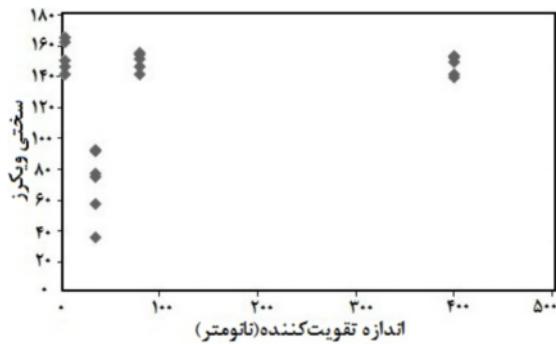
۲- طراحی شبکه عصبی

مدل‌سازی شبکه عصبی شامل مراحل جمع‌آوری داده‌ها، پردازش و فرآوری داده‌ها، انتخاب پارامترهای شبکه شامل معماری شبکه و الگوریتم آموزش، صحت‌سنجی شبکه آموزش دیده شده توسط داده‌های تست و استفاده از شبکه برای پیش‌بینی داده‌ها می‌باشد [۱۲]. شبکه‌های عصبی با استفاده از

- 4. Artificial Neural Network
- 5. Neuron
- 6. Regression
- 7. Mean Squared Error

- 1. Mechanical Alloying
- 2. Nano Sintering
- 3. Ultrasonic Cavitation

می‌باشد که با یک روند سعی و خطأ صورت می‌گیرد [۱۲، ۱۳].



شکل ۱ نمودار سختی نانوکامپوزیت بر حسب ابعاد تقویت‌کننده

در پژوهش حاضر یک شبکه عصبی پیشرو با الگوریتم پس‌انتشار خطأ، به منظور پیش‌بینی میکروسختی نانوکامپوزیت پایه آلومینیوم، تقویت‌شده با نانوذره آلومینا، که با استفاده از آلیاژسازی مکانیکی و پرس گرم تولید شده‌اند، طراحی شده است. شبکه شامل یک لایه ورودی و یک لایه خروجی و دو لایه پنهان می‌باشد. متغیرهای ورودی؛ اندازه نانوذره، کسر حجمی آلومینا، زمان و سرعت آلیاژسازی مکانیکی، نسبت وزنی گلوله به پودر در فرایند آلیاژسازی مکانیکی و مقدار بار در تست میکروسختی و خروجی شبکه عدد تست میکروسختی ویکرز انتخاب شده است. بنابراین، لایه ورودی شامل ۶ نرون و لایه خروجی شامل ۱ نرون می‌باشد. در میان داده‌های جدول ۱ به صورت تصادفی، از ۱۴ سری داده برای آموزش شبکه و از ۲ سری داده برای تست شبکه و تعیین میزان کارآمد بودن شبکه استفاده شد. تعداد نرون‌های لایه پنهان طی فرآیند آموزش، با سعی و خطأ و بررسی روند خطای داده‌های تست تعیین شدند. کد مربوط به مدل‌سازی شبکه در نرمافزار متلب^۱، نسخه R2010a نوشته شد.

۲-۲- روند آموزش شبکه

در مطالعه انجام شده، از الگوریتم لونبرگ- مارکوات^۲ (LM) برای آموزش شبکه استفاده شده است [۱۳]. همچنین از تابع سیگموئید^۳ به عنوان تابع تحریک استفاده شد.

1. Matlab
2. Levenberg-Marquardt
3. Sigmoid

داده‌ها آموزش می‌یابند. از این رو داده‌های ورودی مناسب، منجر به آموزش صحیح شبکه و در نتیجه رسیدن به خروجی مناسب می‌شوند. آموزش شبکه از طریق تغییر وزن‌ها به صورت متناوب تا زمانی ادامه می‌یابد که خروجی شبکه تا حد ممکن به خروجی مطلوب نزدیک شود و شبکه به مقدار خطای قابل قبول برسد. پس از آموزش، شبکه قادر است تا با استفاده از الگویی که در مرحله آموزش به آن رسیده است، خروجی داده‌هایی را که آموزش ندیده، پیش‌بینی کند [۱۲].

برای آموزش شبکه از جفت داده‌های ورودی- خروجی استفاده می‌شود. این بدان معنا است که هرچه داده‌ها کامل‌تر و مناسب‌تر باشند، شبکه بهتر آموزش می‌یابد [۱۲]. در این تحقیق، داده‌ها از نتایج تست میکروسختی انجام شده بر روی نانوکامپوزیت آلومینیوم- آلومینا موجود در مراجع، استخراج شده‌اند.

به منظور جمع‌آوری داده‌ها، از مقالات معتبر موجود [۹-۵]، پژوهش‌هایی که در آن‌ها نانوکامپوزیت آلومینیوم-آلومینا به روش آلیاژسازی مکانیکی و پرس گرم تولید شده بودند، انتخاب شدند. با توجه به ورودی‌های شبکه مورد نظر، داده‌هایی که اطلاعات مربوط به آلیاژسازی مکانیکی (زمان، سرعت و نسبت وزنی گلوله به پودر) و اطلاعات مربوط به تقویت‌کننده (اندازه و مقدار نانوذره) و مقدار بار وارد شده در آزمون میکروسختی را به طور کامل دارا بودند، حفظ و بقیه داده‌ها از جامعه آماری حذف شدند.

برای داده‌هایی که تمامی اطلاعات ورودی را دارا بودند، نمودار متغیرها بر حسب سختی رسم شد. به جز در مورد اندازه نانوذره تقویت‌کننده، سایر نمودارها پراکندگی مناسبی داشتند. در مورد نمودار مربوط به اندازه نانوذره، داده‌های مربوط به اندازه ۴۰۰ نانومتر دارای پراکندگی زیادی نسبت به سایر داده‌ها بودند. لذا ۵ داده مربوط به اندازه ۴۰۰ نانومتر حذف شدند. شکل ۱ نمودار مربوط به بررسی پراکندگی داده‌ها را برای ابعاد نانوذره بر حسب سختی ویکرز نشان می‌دهد. همچنین جدول ۱، داده‌هایی را که در روند آموزش شبکه مورد استفاده قرار گرفته‌اند، نشان می‌دهد.

۲-۱- معماری شبکه عصبی

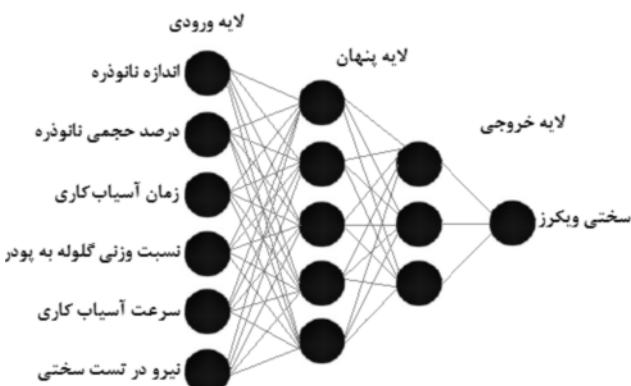
منظور از معماری شبکه، در واقع تعیین تعداد لایه‌های پنهان و همچنین مشخص نمودن تعداد نرون‌ها در لایه‌های پنهان

در مرحله آموزش شبکه، دیگر پارامترهای موثر بر آموزش مانند نرخ یادگیری^۲ و پارامتر مو^۳ نیز مورد بررسی قرار گرفتند. این پارامترها مشخص کننده میزان تغییرات وزن‌ها و بایاس می‌باشند. لذا تعیین دقیق آن‌ها به بهبود کارایی شبکه کمک می‌کند. پارامترهای گفته شده با توجه به وضعیت پیش‌بینی‌های شبکه در مرحله آموزش، تغییرات مقدار میانگین مربعات خطأ برای داده‌های صحبت‌سنگی و مقدار خطای داده‌های تست تغییر داده شدند تا مقدار مطلوب آن‌ها مشخص شد. برای شبکه طراحی شده در این پژوهش مقادیر مربوط به نرخ یادگیری و پارامتر مو به ترتیب ۰/۰۰۱ و ۰/۰۱ در نظر گرفته شدند.

۳-۲- بررسی عملکرد شبکه

به منظور یافتن تعداد لایه‌های پنهان مناسب، شبکه با ۱، ۲ و ۳ لایه میانی آموزش داده شد. بهترین عملکرد و کمترین مقدار میانگین مربعات خطأ مربوط به زمانی بود که از ۲ لایه میانی استفاده شد. همچنین برای یافتن تعداد بهینه نرون‌های لایه پنهان، تعداد نرون‌ها از ۲ تا ۸ تغییر یافت و مقدار MSE برای تمامی داده‌ها و درصد و مقدار خطای برای داده‌های تست بررسی شد. برای محاسبه مقدار خطأ از رابطه ۲ استفاده شد. بهترین نتایج هنگامی حاصل شد که در لایه پنهان اول، ۵ نرون و در لایه پنهان دوم، ۳ نرون قرار داشت. بنابراین ساختار شبکه به صورت ۶-۵-۳-۲ طراحی شد. در شکل ۲، شبکه به صورت شماتیک نشان داده شده است.

$$(2) \quad \text{عدد سختی و یکرز آزمایشگاهی} = \frac{\text{پیش‌بینی شبکه عصبی - عدد سختی و یکرز آزمایشگاهی}}{\text{مقدار خطأ}}$$



شکل ۲ شکل شماتیک شبکه عصبی پژوهش حاضر

جدول ۱ داده‌های استفاده شده برای آموزش شبکه عصبی [۶,۵]

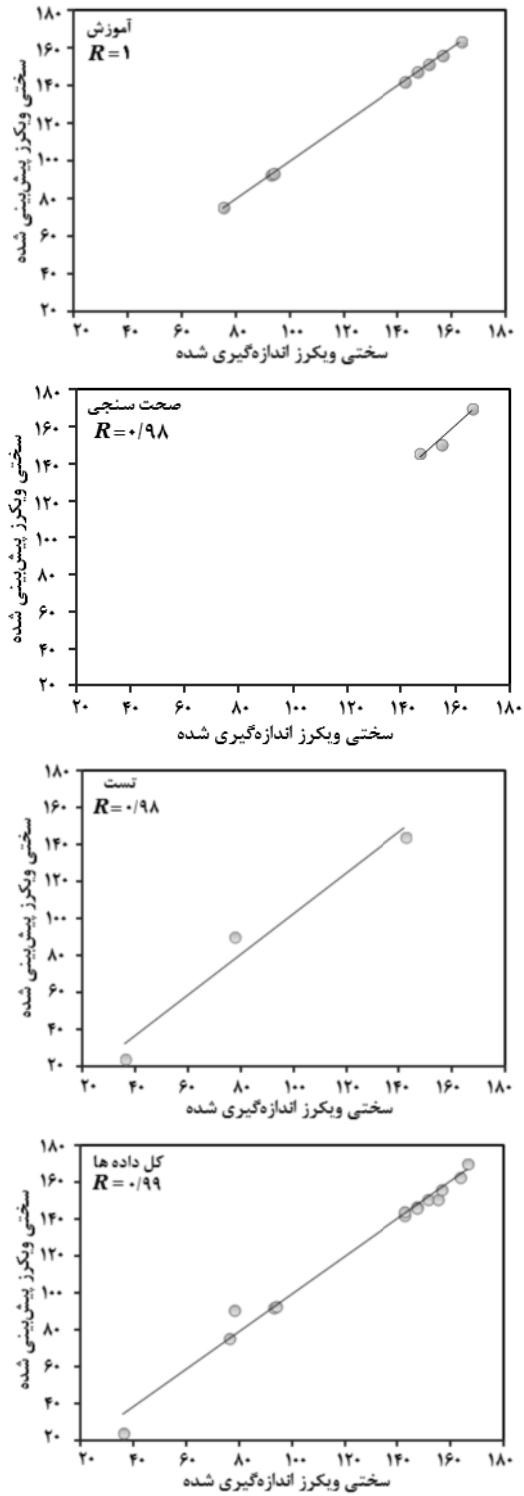
ردیف (ناتونزه)	اندازه نانو درصد (kg)	زمان (RPM)	گلوله به آسیاب پودر	نسبت وزنی سرعت میکروسختی و یکرز کاری (h)	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲	۱۳	۱۴	۱۵	۱۶
۳۶	۰/۰۲۵	۴۸۰	۱۵	۸	۰	۳۵	۱													
۵۸	۰/۰۲۵	۴۸۰	۱۵	۸	۱/۳۹	۳۵	۲													
۷۵	۰/۰۲۵	۴۸۰	۱۵	۸	۲/۱	۳۵	۳													
۹۳	۰/۰۲۵	۴۸۰	۱۵	۸	۲/۸	۳۵	۴													
۹۲	۰/۰۲۵	۴۸۰	۱۵	۸	۳/۵۲	۳۵	۵													
۷۷	۰/۰۲۵	۴۸۰	۱۵	۸	۴/۲۳	۳۵	۶													
۱۴۲	۰/۰۵	۱۲۰۰	۱۰	۵	۰	۴	۷													
۱۴۷	۰/۰۵	۱۲۰۰	۱۰	۵	۱	۴	۸													
۱۵۱	۰/۰۵	۱۲۰۰	۱۰	۵	۲	۴	۹													
۱۶۳	۰/۰۵	۱۲۰۰	۱۰	۵	۵	۴	۱۰													
۱۶۶	۰/۰۵	۱۲۰۰	۱۰	۵	۱۰	۴	۱۱													
۱۴۲	۰/۰۵	۱۲۰۰	۱۰	۵	۰	۸۰	۱۲													
۱۴۷	۰/۰۵	۱۲۰۰	۱۰	۵	۱	۸۰	۱۳													
۱۵۵	۰/۰۵	۱۲۰۰	۱۰	۵	۲	۸۰	۱۴													
۱۵۶	۰/۰۵	۱۲۰۰	۱۰	۵	۵	۸۰	۱۵													
۱۵۲	۰/۰۵	۱۲۰۰	۱۰	۵	۱۰	۸۰	۱۶													

برای آموزش شبکه جهت پیش‌بینی سختی و یکرز، از ۱۴ سری داده استفاده شده است. از ۲ سری داده باقی‌مانده برای ارزیابی شبکه آموزش دیده شده استفاده شد. با استفاده از الگوریتم آموزش لونبرگ- مارکوات، ابتدا وزن‌های اولیه و بایاس^۱ به صورت تصادفی به شبکه اختصاص یافت. سپس با ورود داده‌های ورودی و با در نظر گرفتن خروجی شبکه و مقایسه آن با خروجی مطلوب و با هدف کاهش مقدار خطأ، وزن‌های اولیه تنظیم و اصلاح شدند که از این وزن‌های اصلاح شده در مراحل بعدی آموزش استفاده شد. در هر مرحله از آموزش، وزن‌ها با توجه به خروجی شبکه اصلاح شدند. با توجه به این که از مقدار میانگین مربعات خطای داده‌های صحبت‌سنگی برای بررسی نحوه عملکرد شبکه استفاده شد، عمل اصلاح وزن‌ها تا زمانی که شبکه به MSE مطلوب برسد، ادامه یافت. مقدار میانگین مربع خطأ با استفاده از رابطه ۱ محاسبه شد. در رابطه ۱، N تعداد داده‌ها، t خروجی مطلوب و a مقدار پیش‌بینی شده توسط شبکه می‌باشد.

$$(1) \quad MSE = \left(\frac{1}{N} \sum_{i=1}^N |t_i - a_i| \right)^2$$

1. Bias

مقایسه می‌کند، این روند افزایش سختی با افزایش مقدار آلومینا را به خوبی پیش‌بینی می‌نماید.



شکل ۳ نمودارهای رگرسیون در مراحل آموزش، صحت‌سنجی، تست و کل داده‌ها

مقدار متوسط درصد خطأ برای داده‌های تست، ۲/۶۷ درصد و مقدار میانگین مربعات خطأ برای داده‌های صحت‌سنجی ۷/۷۶ بود که نشان می‌دهد شبکه برای پیش‌بینی سختی نانوکامپوزیت آلومینیوم-آلومینا دقت کافی دارد. شکل ۳ نمودارهای رگرسیون پیش‌بینی شبکه برای میکروسختی ویکرز را در مراحل آموزش، صحت‌سنجی و تست و همچنین برای کل داده‌ها در مقایسه با مقادیر اندازه‌گیری شده نشان می‌دهد.

۳- نتایج و بحث

برای تعداد لایه‌های پنهان ۱، ۲ و ۳ مقدار و درصد خطأ، میانگین مربعات خطأ و روند آموزش شبکه بررسی شد. هنگامی که در شبکه از یک لایه پنهان استفاده شد، درصد خطأ برای داده‌های تست در بهترین حالت از ۵/۳ درصد کمتر نشد در حالی که با افزایش لایه‌های پنهان به ۲ لایه، خطأ ۲/۶۳ درصد کاهش یافت. با اضافه نمودن یک لایه پنهان دیگر، مجددًا خطأ افزایش یافت. بنابراین از ۲ لایه پنهان استفاده شد. شکل ۴ مقایسه درصد خطأ و MSE را برای تعداد لایه‌های پنهان مختلف نشان می‌دهد.

از ۱۴ سری داده برای آموزش شبکه استفاده شد. در مرحله آموزش نتایج پیش‌بینی شبکه عصبی با نتایج آزمایشگاهی سختی اختلاف کمی داشت. شکل ۵ مقایسه مقادیر پیش‌بینی شبکه و داده‌های آزمایشگاهی را در مرحله آموزش نشان می‌دهد.

داده‌های تست به صورت اتفاقی از بین داده‌های موجود انتخاب شده بودند و در مراحل قبلی شبکه این داده‌ها را آموزش ندیده بود. برای تشخیص این که آموزش شبکه به درستی صورت پذیرفته و نتایج پیش‌بینی شبکه قابل اطمینان است، پیش‌بینی‌های شبکه با مقادیر داده‌های واقعی مقایسه شدند. به این منظور مقدار و درصد خطأ محاسبه شد. داده‌های تست به طور میانگین، ۲/۶۷ درصد یا ۲/۲۵ ویکرز خطأ داشتند که مقدار میانگین می‌باشد. همچنین شکل ۶ مقایسه مقادیر پیش‌بینی شبکه و مقادیر داده‌های آزمایشگاهی را در مرحله تست نشان می‌دهد. با توجه به شکل‌های ۵ و ۶ مشاهده می‌شود پیش‌بینی شبکه با مقدار واقعی اختلاف کمی دارد. با توجه به جدول ۱، با افزایش کسر حجمی نانوذره در نانوکامپوزیت، سختی افزایش می‌یابد. شکل ۵ که مقادیر پیش‌بینی شبکه و مقادیر حاصل از آزمایش‌های تجربی را

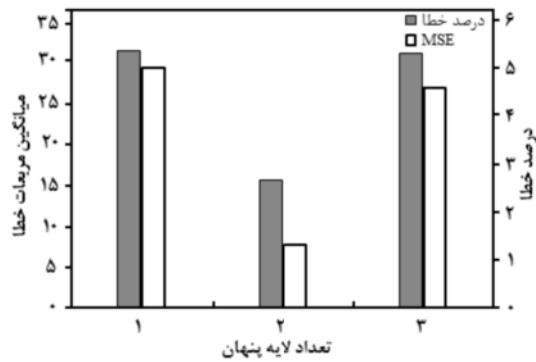
صحت‌سنگی، تست و کل داده‌ها به ترتیب برابر با ۱، ۰/۹۸ و ۰/۹۹ بودند که این مقادیر نشان‌دهنده آموزش خوب شبکه و در نتیجه قابل اعتماد بودن نتایج می‌باشد.

۴- نتیجه‌گیری

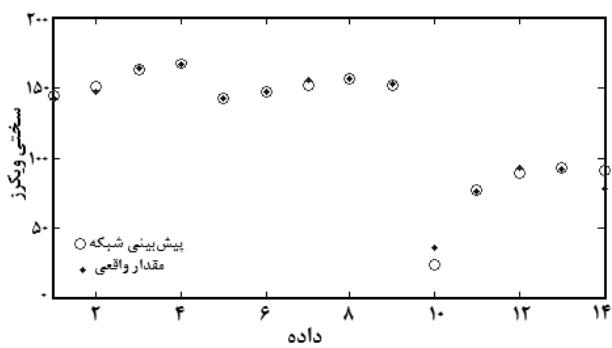
در این پژوهش یک شبکه عصبی پیش‌رو با الگوریتم پس انتشار-خطا برای پیش‌بینی سختی ویکرز نانوکامپوزیت آلمینیوم-آلومینیا با توجه به مقدار و اندازه نانوذره سرامیکی، پارامترهای آلیازسازی و نیرو در تست سختی مورد استفاده قرار گرفت. برای اطمینان از عملکرد صحیح شبکه عصبی، نمودارهای رگرسیون در مراحل آموزش، صحت‌سنگی و تست و همچنین مقدار میانگین مربعات خطأ، مورد بررسی قرار گرفتند. میانگین درصد خطای پیش‌بینی شبکه برای داده‌های تست، ۲/۶۷ درصد یا ۲/۲۵ ویکرز و میانگین مربعات خطأ در مرحله صحت‌سنگی ۷/۷۶ بود. این نتایج برای شبکه‌ای با ۲ لایه پنهان، که تعداد نمونه‌ها در لایه‌های میانی به ترتیب ۵ و ۳ بودند، حاصل شد. با توجه به نمودارهای پراکندگی و همچنین بودند، حاصل شد. با توجه به نمودارهای پراکندگی و همچنین درصد و درصد خطأ در مرحله تست، عملکرد شبکه برای مقدار پیش‌بینی سختی نانوکامپوزیت پایه آلمینیومی، تقویت شده با نانوذره سرامیکی آلومینیا، خوب ارزیابی شد. از آنجا که در شبکه عصبی این پژوهش اندازه و درصد حجمی نانوذره و ویژگی‌های آسیاب‌کاری مکانیکی و همچنین نیروی وارد شده در آزمایش سختی به عنوان ورودی در نظر گرفته شدند، بنابراین شبکه طراحی شده برای پیش‌بینی سختی با تغییر پارامترها در محدوده مطالعه شده قابل استفاده خواهد بود.

۵- مراجع

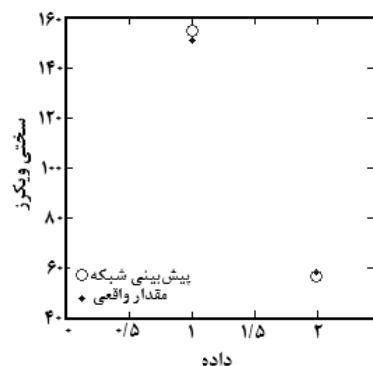
- [1] Ahamed H., Senthilkumar V., "Experimental investigation on newly developed ultrafine-grained aluminium based nano-composites with improved mechanical properties", *Materials and Design*, Vol. 37, 2012, pp. 182-192.
- [2] El-Daly A.A., Abdelhameed M., Hashish M., Daoush W.M., "Fabrication of silicon carbide reinforced aluminum matrix nanocomposites and characterization of its mechanical properties using non-destructive technique", *Materials Science & Engineering A*, Vol. 559, 2013, pp. 384-393.
- [3] Bera S., Chowdhury S.G., Estrin Y., Manna I., "Mechanical properties of Al7075 alloy with nano-



شکل ۴ مقایسه درصد خطأ و میانگین مربعات خطأ برای تعداد لایه‌های پنهان متفاوت



شکل ۵ نتایج پیش‌بینی شبکه در مرحله آموزش



شکل ۶ نتایج پیش‌بینی شبکه در مرحله تست

همچنین با کاهش سرعت آسیاب‌کاری، به دلیل کاهش برخوردهای مؤثر، مقدار سختی کاهش می‌یابد. در این مورد نیز شبکه روند کاهش سختی را به خوبی پیش‌بینی می‌نماید. در مراحل آموزش، صحت‌سنگی و تست و همچنین برای کل داده‌ها، نمودار رگرسیون که نشان‌دهنده پراکندگی داده‌ها در حالت پیش‌بینی و مقادیر واقعی بود، مورد بررسی قرار گرفت. مقادیر R در این نمودارها در مراحل آموزش،

- subsequent casting”, *Journal of King Saud University – Engineering Sciences*, Vol. 25, 2013, pp. 75–80.
- [9] Mahboob H., Sajjadi S. A., Zebarjad S. M., “synthesis of Al-Al₂O₃ nano-composite by mechanical alloying and evaluation of the effect of ball milling time on the microstructure and mechanical properties”, *The International Conference on MEMS and Nanotechnology, ICMN'08*, 2008.
- [10] Zhu J., Shi Y., Feng X., Wang H., Lu X., “Prediction on tribological properties of carbon fiber and TiO₂ synergistic reinforced polytetrafluoroethylene composites with artificial neural networks”, *Materials and Design*, Vol. 30, 2009, pp.1042–1049.
- [11] Rashidi A.M., Hayati M., Rezaei A., “Application of artificial neural network for prediction of the oxidation behavior of aluminized nano-crystalline nickel”, *Materials and Design*, Vol. 42, 2012, pp. 308–316.
- [12] Dini G., Najafizadeh A., Monir-Vaghefi S.M., Ebnenasir A., “Predicting of mechanical properties of Fe–Mn–(Al, Si) TRIP/TWIP steels using neural network modeling”, *Computational Materials Science*, Vol. 45, 2009, pp. 959–965
- [13] Jiang Z., Gyurova L., Zhang Z., Friedrich K., Schlarb A.K., “Neural network based prediction on mechanical and wear properties of short fibers reinforced polyamide composites”, *Materials and Design*, Vol. 29, 2008, pp. 628–637.
- ceramic oxide dispersion synthesized by mechanical milling and consolidated by equal channel angular pressing”, *Journal of Alloys and Compounds*, Vol. 548, 2013, pp. 257–265.
- [4] Kollo L., Leparoux M., Bradbury C.R., Jaggi C., Carreno-Morelli E., Rodriguez-Arbaizar M., “Investigation of planetary milling for nano-silicon carbide reinforced aluminium metal matrix composites”, *Journal of Alloys and Compounds*, Vol. 489, 2010, pp. 394–400.
- [5] Tabandeh Khorshid M., Jenabali Jahromi S.A., Moshksar M.M., “Mechanical properties of trimodal Al matrix composites reinforced by nano- and submicron-sized Al₂O₃ particulates developed by wet attrition milling and hot extrusion”, *Materials and Design*, Vol. 31, 2010, pp. 3880–3884.
- [6] Poirier D., Drew R. A.L., Trudeau M.L., Gauvin R., “Fabrication and properties of mechanically milled alumina/aluminum nanocomposites”, *Materials Science and Engineering A*, Vol. 527, 2010, pp. 7605–7614.
- [7] Hosseini N., Karimzadeh F., Abbasi M.H., Enayati M.H., “Tribological properties of Al6061–Al₂O₃ nanocomposite prepared by milling and hot pressing”, *Materials and Design*, Vol. 31, 2010, pp. 4777–4785.
- [8] Hossein-Zadeh M., Razavi M., Mirzaee O., Ghaderi R., “Characterization of properties of Al–Al₂O₃ nano-composite synthesized via milling and