



مدل‌سازی سایش سطح براده ابزار و زبری سطح قطعه در ماشین‌کاری فولاد ۴۱۴۰ با استفاده از شبکه‌های عصبی مصنوعی

ولی‌علی میرزالو^{۱*}، منصور کریمی تکانلو^۲، وحید مدانلو^۱، علی دنیوی^۱، رامین محمدی کلیر^۲

۱- استادیار، دانشکده مهندسی مکانیک، دانشگاه ارومیه، ارومیه

۲- کارشناس ارشد، دانشکده مهندسی مکانیک، دانشگاه ارومیه، ارومیه

۳- دانشجوی دکترا، دانشکده مهندسی مکانیک، دانشگاه ارومیه، ارومیه

۴- استادیار، دانشکده مهندسی مکانیک، دانشگاه ارومیه، ارومیه

۵- کارشناس ارشد، دانشگاه جامع علمی کاربردی ایدم، تبریز

*ارومیه، صندوق پستی ۵۷۱۵۳-۱۶۵، v.alimirzaloo@urmia.ac.ir

چکیده

پیش‌بینی سایش ابزار و زبری سطح، نقش مهمی در تنظیم پارامترهای ماشین‌کاری و بهینه‌سازی آن دارد. در پژوهش حاضر سایش سطح براده ابزار و زبری سطح قطعه‌کار در تراش‌کاری فولاد ۴۱۴۰ برحسب پارامترهای موثر ماشین‌کاری با روش شبکه عصبی مصنوعی مدل‌سازی شده است. عمق برش، سرعت برشی، سرعت پیشروی و مدت زمان عملیات به عنوان متغیرهای ورودی لحاظ شده‌اند. داده‌های لازم برای آموزش شبکه عصبی با استفاده از آزمایش‌های تجربی استخراج شده است. ابتدا با استفاده از روش طراحی آزمایش‌های عاملی بهینه، آزمایش‌های لازم طراحی شده و پس از انجام آزمایش‌های تجربی، میزان سایش ابزار و زبری سطح نمونه‌ها اندازه‌گیری شده است. در ادامه با طراحی شبکه عصبی مصنوعی مطلوب و آموزش آن با داده‌های تجربی، مدل شبکه عصبی برای پیش‌بینی توابع هدف بدست آمده است. برای مدل‌سازی از دو نوع شبکه تغذیه رو به جلو انتشار برگشتی و تغذیه رو به جلو کاسکاد انتشار برگشتی و سه نوع الگوریتم آموزش متفاوت و تعداد گره‌های مختلف برای لایه پنهان استفاده شده است. نتایج نشان می‌دهد که هر دو نوع شبکه با تابع آموزش گرادینان مزدوج مدرج مقدار سایش ابزار و زبری سطح را با دقت خوبی پیش‌بینی می‌کنند. کلید واژگان: شبکه عصبی مصنوعی، تراش‌کاری، فولاد ۴۱۴۰، سایش ابزار، زبری سطح

Modeling of the tool wear and surface roughness of workpiece in turning operation of AISI 4140 steel using artificial neural networks

Vali Alimirzaloo^{1*}, Mansour Karimi Takanlou¹, Vahid Modanloo¹, Ali Doniavi¹, Ramin Mohamadi Koliber²

1- Department of Mechanical Engineering, Urmia University, Urmia, Iran

2- Department of Mechanical Engineering, University of Applied Science and Technology of IDEM, Tabriz, Iran

*P.O.B. 57153-165 Urmia, Iran, v.alimirzaloo@urmia.ac.ir

ABSTRACT

Prediction of the tool wear and surface roughness has important role in adjustment of the machining parameters and their optimization. In this research, tool wear and workpiece surface roughness in turning process of 4140 steel have been modeled using the artificial neural networks. Cutting depth, cutting speed, feed rate and operation time were considered as input parameters. Required data for training the neural network were obtained using the experimental tests. First, the experiments were designed using the optimal factorial design method and implemented. Then, the tool wear and surface roughness of the test pieces were measured. In the next stage, artificial neural network was designed and trained by the experimental data. Two types of neural networks that were used are Feed Forward Back Propagation and Feed Cascade Forward Back Propagation. Three types of turning algorithm and different node numbers for the hidden layer were used. Results showed that the both type of the networks with the scaled conjugate gradient training algorithm predict the tool wear and surface roughness, precisely.

Keywords: AISI 4140 Steel, Artificial Neural Network, Surface Roughness, Turning, Tool Wear.

از کار افتادن تدریجی قسمت‌های مختلف ماشین می‌گردد. از طرف دیگر یکی از مهمترین شاخص‌های ارزیابی کیفیت سطح قطعات ماشین‌کاری شده، میزان زبری سطح قطعات نهایی می‌باشد. کیفیت سطح قطعه‌کار به طور مستقیم از پارامترهای برشی تاثیر می‌پذیرد. انتخاب پارامترهای برشی به صورت تجربی و بر مبنای سعی و خطا، منجر به افزایش هزینه و تولید محصولاتی با کیفیت نامطلوب خواهد شد. با توجه به اهمیت دو پارامتر خروجی سایش ابزار و زبری سطح قطعه‌کار در اقتصاد ماشین‌کاری، اندازه-

۱- مقدمه

سایش ابزار و زبری سطح قطعه‌کار دو پارامتر مهم جهت ارزیابی فرآیندهای ماشین‌کاری فلزات می‌باشند. سایش ابزار شکست تدریجی ابزار برشی بوده که وقوع آن غیرقابل اجتناب است. در میان انواع سایش، سایش در سطح براده ابزار پارامتر بسیار مهمی در ارزیابی عمر ابزار به شمار می‌رود. عمر طولانی ابزار به معنای سایدگی کم ابزار است. زمانی که فرآیند ماشین‌کاری با فرسودگی ابزار ادامه پیدا کند، هزینه و زمان تولید افزایش و همچنین سبب

برای ارجاع به این مقاله از عبارت ذیل استفاده نمایید:

Please cite this article using:

V. Mirzaloo, M. Karimi Takanlou, V. Modanloo, A. Doniavi, R. Mohamadi Koliber, Modeling of the tool wear and surface roughness of work piece in Turning Operation of AISI 4140 Steel using Artificial Neural Networks, *Modares Mechanical Engineering, Proceedings of the Advanced Machining and Machine Tools Conference*, Vol. 15, No. 13, pp. 187-191, 2015 (in Persian فارسی)

آزمایش‌ها در شرایط یکسان و جلوگیری از عدم یکنواختی در نتایج خروجی، آزمایش‌ها توسط دستگاه تراش کنترل عددی فانوک^۲ مطابق شکل ۱ انجام شده است. ابزار مورد استفاده در این آزمایش تیغچه الماسه-TNMA160408 KR ساخت شرکت سندویک^۳ می‌باشد. برای اندازه‌گیری سایش سطح براده ابزار، از میکروسکوپ نوری لیتز^۴ ساخت کشور آلمان استفاده شده است. بزرگ‌نمایی این دستگاه بین ۵۰ تا ۱۰۰۰ برابر است. همچنین دستگاه زبری‌سنج مورد استفاده برای اندازه‌گیری زبری سطح، میتوتویو^۵ می‌باشد. شکل ۲ این تجهیزات را نشان می‌دهد و در شکل ۳ نمونه اندازه‌گیری شده نشان داده شده است.

۲- طراحی و اجرای آزمایش‌ها


برای انجام آزمایش‌های کامل جهت کنترل فرآیند، باید آزمایش‌های بسیاری



شکل ۱ دستگاه CNC استفاده شده در آزمایش‌های تجربی



شکل ۲ تجهیزات آزمایشگاهی (الف) میکروسکوپ نوری (ب) زبری سنج



شکل ۳ اندازه‌گیری سایش سطح براده ابزار با میکروسکوپ نوری


گیری و مدل‌سازی این دو پارامتر برحسب پارامترهای ورودی ماشین کاری مانند پیشروی، سرعت برشی، عمق برش و مدت زمان عملیات حائز اهمیت بالایی بوده و امکان بهینه‌سازی شرایط تولید را تسهیل خواهد کرد. محققان در سال‌های اخیر با به کارگیری روش‌های علمی، انواع فرآیندهای تولید را به میزان چشمگیری بهبود بخشیده‌اند. در سال‌های اخیر، محققان از روش‌های گوناگونی برای تعیین تاثیر پارامترهای مختلف ماشین کاری بر کیفیت نهایی قطعات استفاده کرده‌اند. دیلما و لیستر [۱] نشان دادند که برای جلوگیری از شکست ناگهانی ابزار باید کلیه مراحل از سایش تا برش ابزار به دقت بررسی گردد. سایش ابزار در طی فرآیند سایش سبب افزایش نیروی برشی می‌شود. بنابراین نیروی برشی به عنوان مرجعی برای اندازه‌گیری غیرمستقیم و نظارت بر سایش ابزار بسیار مناسب است. از میان روش‌های غیرمستقیم نظارت بر سایش ابزار، نیروی برشی از مهم‌ترین متغیرها به شمار می‌رود. تتی و همکارانش [۲] دریافتند که تخمین سایش و شناسایی شکست در ابزار یکی از مهم‌ترین مشکلات در ماشین‌های کنترل عددی کامپیوتری^۱ مدرن می‌باشد. اجرای سیستم نظارت بر شرایط صحیح ابزار اطلاعاتی را از سایش ابزار به واحد کنترل دستگاه برای عملکرد مناسب می‌فرستد. ماتسوموتو و همکارانش [۳] گزارش داده‌اند که جنس و سختی قطعه‌کار در کیفیت و یکپارچگی سطح ماشین کاری شده موثر است. برای مطلوب بودن سطح ماشین کاری شده، ضروری است که ابزار با فلزات مختلف به کار گرفته شده در قطعه‌کار متناسب باشد. ابزارهای الماسه به دلیل این‌که زبری کمتری نسبت به ابزارهای معمولی دیگر دارند برای براده و پلیسه برداری مناسب‌تر می‌باشند. بنابراین برای آماده‌سازی ابزار براده‌برداری باید لبه آن از استحکام بالایی برخوردار باشد تا بتوان قطعه دلخواه نهایی را با ویژگی‌های مطلوب تولید نمود. کوئینگ و کلینگر [۴] به این نکته پی بردند که لبه برشی پخ‌دار ابزار، سبب کاهش عمر ابزار و ایجاد شکاف شده و لبه تیز نسبت به لبه پخ دار نتایج مطلوبی دارد. همچنین افزایش سرعت پیشروی، سبب افزایش حداکثر تنش باقیمانده تراکمی شده و ناحیه براده‌برداری را عمیق‌تر می‌کند. نالبانت و همکارانش [۵] تاثیر نرخ پیشروی، شعاع نوک ابزار و عمق برش را بر روی صافی سطح در تراش کاری فولاد AISI 1030 مورد بررسی قرار دادند. آن‌ها دریافتند که نرخ پیشروی و شعاع نوک ابزار تاثیر بیشتری بر روی صافی سطح دارند. در حالی‌که عمق برش تقریباً در صافی سطح بی‌تاثیر است. مانا و سالودکار [۶] موفق شدند که یک شرایط بهینه برش جهت دستیابی به کیفیت سطح مناسب و هزینه ماشین کاری کمینه، در تراش کاری فولاد آلیاژی E0300 تعیین کنند. آتاناسیو و همکارانش [۷] مقایسه‌ای بین روش رویه پاسخ و شبکه عصبی مصنوعی را به منظور پیش‌بینی تکنیک‌های سایش ابزار انجام دادند. نتایج آن‌ها نشان داد که مدل شبکه عصبی مصنوعی نسبت به مدل رویه پاسخ نتایج نزدیک‌تری به داده‌های تجربی دارد. در مورد صافی سطح قطعه‌کار همزمان با سایش ابزار در ماشین کاری فولاد ۴۱۴۰ کارچندان قابل توجهی تاکنون انجام نگرفته و در کارهای انجام شده به بررسی اثر دو یا سه پارامتر بر روی سایش ابزار پرداخته شده است. در این تحقیق تاثیر چهار پارامتر موثر بر سایش ابزار و زبری سطح قطعه یعنی سرعت دورانی، سرعت پیشروی، زمان و عمق بار با روش شبکه عصبی مصنوعی مدل‌سازی شده است.

۲- مواد و تجهیزات


جنس قطعه‌کار فولاد ۴۱۴۰ با سختی ۱۹۷ برینل می‌باشد. جهت انجام

1. CNC

2. Fanuk
3. Sandvik
4. Leitz
5. Mitutoyo



شکل ۴ دیاگرام شبکه تغذیه رو به جلوی انتشار برگشتی



شکل ۵ دیاگرام تغذیه رو به جلوی انتشار برگشتی کاسکاد

نتایج حاصل از لایه پنهانی به لایه بیرونی وارد می‌شوند، اما در شبکه کاسکاد علاوه بر نتایج حاصل از لایه پنهانی، ورودی‌ها هم با تابع وزنی دیگری به لایه بیرونی وارد شده و تحلیل‌ها انجام می‌گیرد. برای آموزش شبکه‌ها از سه نوع الگوریتم آموزش لونیگ-مارکواردت^۵ (LM)، گرادیان نزولی^۶ (GD) و گرادیان مزدوج مدرج^۷ (SCG) استفاده شده و تعداد سه لایه با تعداد گره‌های ۵، ۱۰ و ۱۵ برای لایه پنهان مورد بررسی قرار گرفته است.

منظور از میزان یادگیری و عملکرد این است که تا چه حد قادر است به ورودی‌هایی که توسط آنها آموزش داده شده و به ورودی‌های جدیدی که در دسته آموزش نیستند جواب قابل قبول ارائه دهد. میزان یادگیری و عملکرد شبکه از طریق پارامترها و روش‌های مختلفی مانند جذر میانگین مربع خطاها و ضریب همبستگی بین خروجی‌های حقیقی و دلخواه سنجیده می‌شود. منظور از جذر میانگین مربع خطاها (RMS) در یک شبکه، جذر میانگین مربع خطاهای ایجاد شده بین خروجی‌های حقیقی و دلخواه لایه خروجی است. چنین مقدار در الگوریتم انتشار برگشتی به عنوان تابع هدف و وزن‌های شبکه به عنوان متغیر تابع در نظر گرفته می‌شوند. این الگوریتم با استفاده از یک روش کاهش گرادیان، تمایل به حداقل رساندن تابع هدف را دارد. طی آموزش شبکه، کاهش مقدار RMS نشان دهنده روند رو به رشد شبکه در میزان یادگیری است. هر چه مقدار RMS کاهش یابد، شبکه ورودی‌های موجود در دسته آموزش را بهتر یاد گرفته و جواب‌های دقیق‌تری برای آن‌ها ارائه می‌نماید. پارامتر R مقدار متغیرها را در پاسخ مشاهده شده به وسیله مدل را شرح می‌دهد و نشان می‌دهد مدل برازش شده چقدر به داده‌های واقعی نزدیکتر است. برای آموزش مدل شبکه عصبی، تعداد داده‌ها برای آموزش، تست و اعتباردهی به ترتیب ۲۰، ۵ و ۵ اعمال شد.

۵- نتایج و بحث

در شکل ۶ نتایج سه تابع آموزشی در شبکه تغذیه رو به جلو انتشار برگشتی نشان داده شده است. با توجه به هر نمودار مشخص می‌شود که در کدام تکرار بهترین عملکرد، یعنی کمترین خطا حاصل شده است. به عبارت دیگر در کدام

را انجام داد. از این رو یکی از اهداف اصلی روش طراحی آزمایش‌ها، انتخاب بهترین حالت‌های ممکن است که با استفاده از آن بتوان فرآیند را ضمن توجه‌پذیر بودن تعداد آزمایش‌ها، به بهترین شکل ممکن بررسی کرد [۸]. در این تحقیق از نرم‌افزار مینی‌تب^۱ جهت طراحی آزمایش‌ها استفاده شده است. در ابتدا با توجه به سطوح انتخابی پارامترهای مورد بررسی (جدول ۱)، با استفاده از طرح عاملی کامل تعداد ۲۵۶ آزمایش طراحی شد. سپس براساس طراحی بهینه، تعداد ۳۰ آزمایش از بین آزمایش‌های موجود انتخاب شد.

به منظور آماده‌سازی شرایط آزمایش، مواد از فولاد ۴۱۴۰ به قطر ۳۰ میلی‌متر و طول ۵۰ میلی‌متر در دستگاه اره نواری برش کاری شده و سپس جهت انجام مراحل تراش کاری به دستگاه تراش انتقال یافت. لازم به توضیح است که جهت یکسان‌سازی شرایط آزمایش، از هیچ‌گونه مواد روان‌کار و خنک‌کننده‌ای در انجام آزمایش‌ها استفاده نشده است. بعد از اتمام آزمایش‌ها تیغچه‌های الماسه مورد استفاده در هر آزمایش به‌طور جداگانه جهت اندازه‌گیری مقدار سایش به زیر میکروسکوپ نوری منتقل و مقادیر بدست آمده ثبت شد. همچنین زبری سطح نمونه‌ها با دستگاه زبری‌سنج طبق معیار Ra محاسبه شد.

۴- مدل‌سازی با شبکه عصبی مصنوعی

شبکه عصبی یک سیستم عملیاتی موازی بوده که نرون انسان را شبیه‌سازی می‌کند. همواره هر نرون پس از دریافت اطلاعات از لایه قبلی، آن را محاسبه و به نرون‌های لایه بعدی منتقل می‌کند [۹]. یک شبکه به‌گونه‌ای آموزش داده می‌شود که با به کار بردن یک دسته از ورودی‌ها، دسته خروجی‌های دلخواه تولید شود. هر کدام از این دسته‌های ورودی یا خروجی را می‌توان به صورت یک بردار در نظر گرفت. آموزش با به کار بستن متوالی بردارهای ورودی و تنظیم وزن‌های شبکه به تدریج به مقادیری همگرا می‌شوند که به ازای آن‌ها با اعمال بردار ورودی، بردار خروجی دلخواه تولید شود. در این تحقیق برای مدل‌سازی به وسیله شبکه عصبی ابتدا داده‌های ورودی و خروجی در نرم‌افزار متلب [۱۰] وارد گردید. ماتریس ورودی یک ماتریس ۴×۳۰ ردیف و ۳۰ ستون است که تعداد ردیف‌ها بیانگر ۴ پارامتر ورودی و تعداد ستون‌ها نشان دهنده ۳۰ آزمایش می‌باشد که توسط طرح عاملی کامل طراحی شده است. ماتریس خروجی ماتریسی از نوع ۲×۳۰ ردیف در ۳۰ ستون است که ۲ ردیف نشانگر خروجی‌های مطلوب یعنی سایش سطح براده ابزار و صافی سطح قطعه کار می‌باشد. برای مدل‌سازی از دو نوع شبکه تغذیه رو به جلو انتشار برگشتی^۲ و تغذیه رو به جلو کاسکاد انتشار برگشتی^۳ استفاده شده است. تابع تصمیم‌گیری در هر دو لایه پنهانی و بیرونی تابع حلقوی^۴ است. در شکل‌های ۴ و ۵ دیاگرام‌های تغذیه رو به جلوی انتشار برگشتی و کاسکاد به ترتیب نشان داده شده‌اند. تنها تفاوت شبکه کاسکاد با شبکه تغذیه رو به جلوی انتشار برگشتی این است که در شبکه اول فقط

جدول ۱ محدوده عوامل ورودی

پارامتر	مقدار			
زمان (min)	۱	۳	۵	۷
سرعت دورانی (rpm)	۳۰۰	۶۰۰	۹۰۰	۱۲۰۰
سرعت پیشروی (mm/min)	۰/۱	۰/۳	۰/۵	۰/۷
عمق برش (mm)	۰/۲۵	۰/۵	۰/۷۵	۱

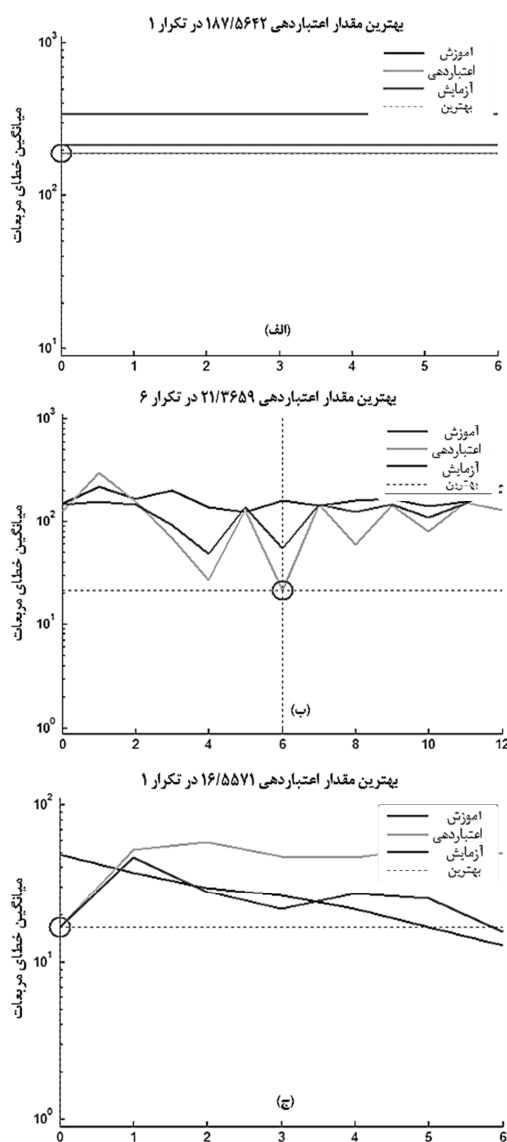
1. Minitab
2. Feed Forward Back Propagation
3. Feed Cascade Forward Back Propagation
4. Sigmoid

تکرار، جواب حاصل از اعتباردهی و آموزش شبکه به هم نزدیک‌تر هستند. در روش LM بعد از ۸ بار تکرار آموزش شبکه متوقف شده است و بهترین عملکرد در تکرار دوم حاصل شده که برابر ۵۳/۲۲۵۳ است. در تابع آموزشی GD بعد از ۱۵ بار تکرار آموزش شبکه متوقف و در تکرار نهم بهترین عملکرد حاصل برابر ۶۵/۵۷۲ است. در روش SCG بهترین عملکرد مربوط به تکرار یازدهم بوده که آموزش بعد از ۱۷ بار تکرار متوقف شده و بهترین عملکرد برابر ۹/۲۲۰۸ است. در این قسمت فقط نتایج حاصل از ۱۰ نرون در شکل‌ها دیده می‌شود. در تحلیل انجام شده در نرم‌افزار متلب، رابطه بین خروجی واقعی و نتیجه حاصل از آموزش شبکه به صورت خطی برای حالت‌های آزمایش، آموزش و اعتباردهی بررسی می‌گردد.


مقدار خطی بودن با پارامتر R بیان می‌شود که بیانگر رابطه بین خروجی واقعی و خروجی حاصل از نرم‌افزار است. هرچه این مقدار به یک نزدیک‌تر باشد، رابطه حاصل به خطی بودن نزدیک است. حالت مطلوب آن است که مقدار R در تمامی حالت‌ها از ۰/۹۳ بیشتر باشد. با توجه به تکرارهایی که در آموزش این حالت داده شد، حالت مشاهده شده بهترین حالت حاصل بود.

شکل ۷ نتایج سه تابع آموزشی در شبکه تغذیه رو به جلو کاسکاد انتشار برگشتی را نشان می‌دهد. طبق شکل در روش LM بعد از ۶ بار تکرار آموزش

در جدول ۲ نتایج حاصل از حالت‌های مختلف شبکه‌ها و الگوریتم‌های آموزش نشان داده شده است. مشاهده می‌شود که کمترین خطا در شبکه تغذیه رو به جلو انتشار برگشتی با الگوریتم آموزش SCG و ۱۰ گره در لایه پنهان حاصل می‌شود و بیشترین R در شبکه تغذیه رو به جلو انتشار



شکل ۷ نمودار خطای میانگین مربعات برای شبکه تغذیه رو به جلو کاسکاد انتشار برگشتی با استفاده از تابع LM (الف) GD (ب) SCG (ج)



شکل ۸ نمودار خطای میانگین مربعات برای شبکه تغذیه رو به جلو انتشار برگشتی با استفاده از تابع LM (الف) GD (ب) SCG (ج)

در این شبکه نتیجه مطلوبی را نمی‌دهد. در تابع آموزشی GD بعد از ۱۲ بار تکرار آموزش شبکه متوقف و در تکرار ششم جواب حاصل از آموزش شبکه و اعتباردهی به هم نزدیکتر هستند. در روش SCG بهترین عملکرد مربوط به حالت شروع است که آموزش بعد از ۶ بار تکرار متوقف شده است. با مقایسه تابع‌های به کار برده شده در این روش مشخص می‌شود که تابع SCG دارای عملکرد بهتری است.

- ۴- در شبکه تغذیه روه جلوی کاسکاد انتشار برگشتی با مقایسه نمودارهای رگرسیون در می‌یابیم که روش SCG به خوبی برآورد کننده شرایط آموزش شبکه است ولی تابع GD تا حدی شرایط برآورد کننده شبکه را داراست. شبکه LM به دلیل اینکه تابع آموزشی مناسبی نیست نمی‌تواند شرایط مورد نیاز را برآورد کند.
- ۵- در آموزش شبکه تغذیه رو به جلوی کاسکاد انتشار برگشتی با تابع SCG کمترین اختلاف بین خروجی واقعی و حاصل از آموزش وجود دارد (بهترین همبستگی بین داده‌های ورودی و خروجی).

۷- مراجع

- [1] D.E. Dimla, P.M. Lister, On-line metal cutting tool condition monitoring. I:force and vibration analyses, *International Journal of Machine Tools & Manufacture*, Vol. 40, pp. 739-768, 2000.
- [2] R. Teti, K. Jemielniak, G. O'Donnell, D. Dornfeld, Advanced monitoring of machining operations, *CIRP Annals - Manufacturing Technology*, Vol. 59, No. 2, pp. 717-739, 2010.
- [3] Y. Matsumoto, F. Hashimoto, G. Lahoti, Surface integrity generated by precision hard turning, *Annals of the CIRP*, Vol. 48, No. 1, pp. 59-62, 1999.
- [4] W. Koenig, M. Klinger, Machining hard materials with geometrically defined cutting edges, *Annals of the CIRP*, Vol. 39, No. 1, pp. 61-64, 1990.
- [5] M. Nalbant, H. Gokkaya, G. Sur, Application of Taguchi Method in the Optimization of Cutting Parameters for Surface Roughness in Turning, *Materials and Design*, Vol. 28, pp. 1379-1385, 2007.
- [6] A. Manna, S. Salodkar, Optimization of Machining Conditions for Effective Turning of E0300 Alloy Steel, *Journal of Materials Processing Technology*, Vol. 203, pp. 143-157, 2008.
- [7] A. Attanasio, E. Ceretta, C. Giardinib, Analytical Models for Tool Wear Prediction during AISI 1045 Turning Operations, *Procedia CIRP*, Vol. 8, pp. 218 - 223, 2013.
- [8] D. C. Montgomery, *Design and analysis of experiments*, forth edition, Wiley, 1997.
- [9] Y. Dadgar Asl, M. Tajdari, H. Moslemi Naeini, B. Davoodi, R. Azizi Tafti, V. Panahizadeh, Prediction of Required Torque in Cold Roll Forming Process of Channel Section Using Artificial Neural Networks, *Moadares Mechanical Engineering*, Vol. 15, No. 7, pp. 209-214, 2015. (In Persian)
- [10] *Matlab User Manual, Version (R2012a)*, The Math Work Inc, 2012.

برگشتی با الگوریتم آموزش SCG و ۵ گره در لایه پنهان با مقدار ۰/۹۷۷۹ حاصل می‌شود. در حالت کلی می‌توان گفت که هر دو نوع شبکه با الگوریتم آموزش SCG مناسب هستند.

۶- نتیجه‌گیری

این مقاله تاثیر چهار پارامتر عمق برشی، سرعت برشی، سرعت پیشروی و زمان عملیات بر روی سایش سطح براده ابزار و زبری سطح قطعه کار در فرآیند تراش‌کاری فولاد ۴۱۴۰ با روش شبکه عصبی مصنوعی مدل‌سازی شده است. نتایج نشان می‌دهد که:

- ۱- در شبکه عصبی تغذیه کننده رو به جلو برگشتی و روش آموزش LM بعد از ۸ بار تکرار بهترین عملکرد در تکرار دوم حاصل گردیده است. همچنین در روش آموزش GD بعد از ۱۵ بار تکرار آموزش شبکه متوقف و در تکرار نهم جواب حاصل از آموزش شبکه و اعتباردهی به هم نزدیکتر هستند. در روش SCG بهترین عملکرد مربوط به تکرار یازدهم است که آموزش بعد از ۱۷ بار تکرار متوقف شده است.
- مقدار R (همبستگی) که نشان دهنده رابطه بین خروجی واقعی و خروجی حاصل از شبکه است، هرچه مقدار R به ۱ نزدیکتر باشد رابطه حاصله به خطی بودن نزدیک است. با توجه به این که در هر سه روش آموزش مقدار همبستگی بیشتر از ۰/۹۳ بوده، بنابراین در آموزش شبکه عصبی تغذیه رو به جلو برگشتی هر سه روش به خوبی برآورد کننده شرایط آموزش شبکه هستند.
- ۲- در آموزش شبکه تغذیه رو به جلو برگشتی برای سایش ابزار و زبری سطح، در تابع آموزش SCG تعداد گره ۱۰، کمترین اختلاف بین خروجی واقعی و حاصل از آموزش وجود دارد.
- ۳- در شبکه تغذیه و روش آموزش LM بعد از ۶ بار تکرار، آموزش شبکه متوقف شده و بهترین عملکرد در تکرار اول حاصل شده است. با توجه به تحلیل انجام گرفته مشخص می‌شود که تابع LM در این

جدول ۲ حالت‌های مورد بررسی در مدل سازی به وسیله شبکه عصبی

نوع شبکه	الگوریتم آموزش	تعداد گره	R	MSE
		۵	۰/۹۷۶۲	۳۳/۹۸۳۳
	LM	۱۰	۰/۹۲۷۴	۵۳/۲۲۵۳
		۱۵	۰/۲۸۱۳	۶۸۰/۷۲۴۸
شبکه تغذیه رو به جلو انتشار برگشتی		۵	۰/۹۰۸۷	۶۸/۵۰۷۶
	GD	۱۰	۰/۹۰۱۷	۶۵/۵۷۲۳
		۱۵	۰/۹۵۴۰	۱۶۶/۵۴۰
		۵	۰/۹۷۷۹	۲۵/۴۴۶۲
	SCG	۱۰	۰/۹۴۷۱	۹/۲۲۰۸
		۱۵	۰/۹۷۶۵	۳۲/۸۹۷۴
		۵	۰/۴۸۹۳	۴۹۰/۱۹۱۲
	LM	۱۰	۰/۵۵۲۴	۱۵۷/۵۶۴۲
		۱۵	۰/۹۴۵۶	۲۴/۷۵۸۴
		۵	۰/۷۷۴۷	۸۹/۹۶۰۵
شبکه کاسکاد	GD	۱۰	۰/۸۳۲۰	۲۱/۳۶۵۹
		۱۵	۰/۷۸۷۷	۱۸۱/۸۰۷
		۵	۰/۹۷۵۷	۲۹/۶۳۳۲
	SCG	۱۰	۰/۹۲۶۶	۱۶/۵۵۷۱
		۱۵	۰/۹۴۹۶	۲۶/۵۹۷۶