



Prediction of Tool Wear using Experimental Studies and Artificial Neural Network in Hardened Steel Machining



ARTICLE INFO

Authors

Jafarian F.¹

Fallah M.²

Dehghani S.^{3*}

¹ Faculty of Engineering, Mahallat Institute of Higher Education, Mahallat, Iran.

² Faculty of Mechanical Engineering, Shahid Rajaee Teacher Training University, Tehran, Iran.

³ Faculty of Mechanical Engineering, Shahid Rajaee Teacher Training University, Tehran, Iran.

* Correspondence

Address: Faculty of Mechanical Engineering, Shahid Rajaee Teacher Training University, Tehran, Iran.

Sajadmst94@gmail.com

How to cite this article

Jafarian F, Fallah M, Dehghani S. Prediction of tool wear using experimental studies and artificial neural network in hardened steel machining. Proceedings of 3rd Iranian National Conference on Advanced Machining and Machine Tools (CAMMT). 2023;23(10):89-93.

ABSTRACT

The ability to predict tool wear during machining is a very important part of diagnosis, which makes it possible to replace the tool at the appropriate time. Therefore, in this research, the artificial neural network approach was used to predict tool wear. First, hardened steel 4140 was turned with uncoated cemented carbide tool TCMW 16T304 H13A and with input parameters including cutting speed, feed rate and machining time in three different levels and with constant cutting depth, and the amount of tool wear was measured. And the experimental test results were used to train and validate the artificial neural network. The optimal neural network architecture was obtained with 3 nodes in the input layer, two hidden layers with 12 and 36 nodes in the first and second hidden layers, and 1 node in the output layer to predict tool wear. The prediction values of the artificial neural network model were compared with the experimental results and the average error percentage of the validation data was calculated as 3.32%.

Keywords Artificial neural network, AISI 4140, Machining, Tool wear, Cutting speed

ماهنامه علمی مهندسی مکانیک مدرس، ویژه نامه مجموعه مقالات سومین کنفرانس ملی ماشین‌کاری و ماشین‌های ابزار پیشرفته
مهر ۱۴۰۲، دوره ۲۳، شماره ۱۰، صفحه ۸۹-۹۳



پیش‌بینی سایش ابزار در ماشین‌کاری فولاد سخت کاری شده با استفاده از مطالعات تجربی و شبکه عصبی مصنوعی



چکیده

توانایی پیش‌بینی سایش ابزار در هنگام ماشین‌کاری بخش بسیار مهمی از تشخیص است که باعث می‌شود ابزار در زمان مربوطه جایگزین شود. از این رو، در این پژوهش از رویکرد شبکه عصبی مصنوعی برای پیش‌بینی سایش ابزار استفاده شد. ابتدا فولاد سخت‌کاری شده ۴۱۴۰ با ابزار کاربید سیمانی بدون پوشش TCMW 16T304 H13A و با پارامترهای ورودی شامل سرعت برشی، نرخ پیشروی و زمان ماشین‌کاری در سه سطح مختلف و با عمق برش ثابت تراشکاری شد و میزان سایش ابزار اندازه‌گیری شد و از نتایج آزمایش تجربی برای آموزش و اعتبارسنجی شبکه عصبی مصنوعی استفاده شد. معماری بهینه شبکه عصبی با ۳ گره در لایه ورودی، دو لایه پنهان با ۱۲ و ۳۶ گره به ترتیب در لایه‌های اول و دوم پنهان و ۱ گره در لایه خروجی برای پیش‌بینی سایش ابزار به دست آمد. مقادیر پیش‌بینی مدل شبکه عصبی مصنوعی با نتایج تجربی مقایسه شد و میانگین درصد خطای داده‌های اعتبارسنجی برابر با ۳/۳۲ درصد محاسبه شد.

مشخصات مقاله

نویسندگان

فرشید جعفریان^۱

محمد مقداد فلاح^۲

سجاد دهقانی^{۳*}

^۱ مرکز آموزش عالی محلات، محلات

^۲ دانشگاه تربیت دبیر شهید رجایی،

تهران

^۳ دانشگاه تربیت دبیر شهید رجایی،

تهران

* نویسنده مسئول

آدرس:

دانشگاه تربیت دبیر شهید رجایی،

تهران

Sajadmst94@gmail.com

کلیدواژه‌ها شبکه عصبی مصنوعی، فولاد ۴۱۴۰، ماشین‌کاری، سایش ابزار، سرعت برشی

۱- مقدمه

در فرایندهای ماشین‌کاری، کیفیت سطح به طور قابل توجه تحت تأثیر ابزار برش قرار دارد. در ماشین‌کاری فولادهای سخت‌کاری شده شناسایی طول عمر مطلوب ابزار به‌طوری‌که کیفیت سطح در حد مطلوب حفظ شود، یک کار ضروری است. اندازه‌گیری سایش ابزار به‌عنوان یک روش عملی نمی‌تواند برای صنعتگران و مهندسان مورد استفاده قرار بگیرد، زیرا متوقف کردن فرایند و اندازه‌گیری سایش ابزار مقرون به‌صرفه نیست. برای غلبه بر این مشکل، سایش ابزار را می‌توان به طور غیرمستقیم و با روش‌های هوشمند پیش‌بینی کرد. شبکه عصبی مصنوعی روشی است که با استفاده از آن می‌توان سایش ابزار و تأثیر پارامترهای ورودی بر روی آن را بررسی کرد.

در شبکه عصبی مصنوعی، رابطه بین ورودی و خروجی با استفاده از یک شبکه شبیه‌سازی شده متشکل از نورون‌های به‌هم‌پیوسته ایجاد می‌شود که در لایه‌های مختلف (لایه‌های ورودی، خروجی و پنهان) سازمان‌دهی شده‌اند و با استفاده از پیوندهای اتصال وزنی به یکدیگر متصل می‌شوند. علاوه بر این، یک وزن مستقل (بایاس) می‌تواند به هر نورون اضافه شود. پارامترهای قابل کنترل شبکه عصبی شامل توابع فعال‌سازی، تعداد نورون‌ها و لایه‌های پنهان برای ساخت توپولوژی‌های مختلف انتخاب می‌شوند. فرایند تنظیم وزن‌ها و سوگیری‌ها را آموزش شبکه می‌گویند. لازم به ذکر است که روش آموزش شبکه تأثیر بسزایی در دقت مدل دارد؛ بنابراین این پارامترها باید به‌درستی انتخاب شوند تا روند مدل‌سازی شود. پژوهشگران متعددی با استفاده از شبکه عصبی مصنوعی اقدام به پیش‌بینی پارامترهای مختلف ماشین‌کاری همچون سایش ابزار، زبری سطح و نیروهای ماشین‌کاری نمودند. پاتوری و همکاران^[1]، تراشکاری فولاد ۵۲۱۰۰ را با استفاده از ابزار برش کاربید (SNMG ۱۲۰۴۰۸) انجام دادند و از رویکرد شبکه عصبی مصنوعی برای تخمین سایش کنار ابزار استفاده کردند. متغیرهای ورودی انتخاب شده برای مدل‌سازی شبکه عصبی عبارت‌اند از سرعت برشی، نرخ پیشروی و عمق برش همچنین پارامتر سایش کنار ابزار متغیر خروجی بود. مدل شبکه عصبی مصنوعی توسعه‌یافته به کمک ضریب همبستگی ارزیابی شد و مقدار R داده‌های آموزش و اعتبارسنجی شبکه به ترتیب ۰/۹۹۹۸۲ و ۰/۹۹۹۹۹ از پاسخ پیش‌بینی شده سایش ابزار مدل شبکه عصبی مصنوعی است. این نتایج نشان می‌دهد که بین مقادیر تجربی و مقادیر مدل شبکه عصبی مصنوعی تطابق قوی وجود دارد. باگا و همکاران^[2]، مطالعه‌ای را به طور تجربی انجام دادند که در آن فولاد کربن متوسط EN8 با ابزار برش کاربید سیمانی (CNMG۱۲۰۴۰) با پارامترهای ورودی شامل سرعت برشی، نرخ پیشروی و عمق برش در سه سطح مختلف ماشین‌کاری شد و میزان سایش ابزار اندازه‌گیری شد. هدف از این کار ارائه روش تخمین سایش ابزار در حین

تراشکاری با شبکه عصبی مصنوعی بود. عملکرد مدل شبکه عصبی مصنوعی با مقایسه آن با مقادیر اندازه‌گیری دستی سایش ابزار بررسی شد. مشاهده شد که سرعت برش و عمق برش پارامتر اصلی تأثیرگذار برای به‌حداقل‌رساندن سایش ابزار است. نتایج تطابق خوبی بین مقادیر سایش ابزار پیش‌بینی‌شده توسط مدل شبکه عصبی مصنوعی و اندازه‌گیری دستی نشان داد. میانگین درصد اختلاف ۳/۴۸ درصد بود که نشان می‌دهد مدل توسعه‌یافته دقت خوبی در پیش‌بینی سایش ابزار دارد. تانگراسو و همکاران^[3]، سایش کناره ابزار برش را با استفاده از شبکه عصبی مصنوعی پیش‌بینی کردند. مدل با معماری ۱-۵-۵ طراحی شد که سرعت برش، نرخ پیشروی، عمق برش، نیروی برش و زبری سطح به‌عنوان ورودی و سایش پهلوی ابزار به‌عنوان خروجی در نظر گرفته شد. میانگین مربع خطا برای مدل شبکه عصبی برابر با ۰/۰۰۰۰۰۱۴۶ به دست آمد که دقت به‌دست‌آمده با مدل پیشنهادی، آن را به‌عنوان ابزاری مؤثر برای پایش وضعیت ابزار در تراشکاری فولاد EN8 تبدیل می‌کند. تواردوفسکی و همکاران^[4]، شبکه‌های عصبی مصنوعی برای پیش‌بینی سایش ابزار بر اساس داده‌های مختلف ورودی مانند نیروهای برش و ارتعاشات مکانیکی ارائه دادند. مدل شبکه عصبی مصنوعی با معماری ۱-۲۰-۲، بر اساس معیارهای شتاب ارتعاشات در جهت شعاعی و پیشروی به‌عنوان مقادیر ورودی، توانایی پیش‌بینی سایش ابزار با میانگین مربع خطای ۰/۰۰۴۹ را ارائه داد. همچنین پیش‌بینی سایش ابزار بر اساس اندازه‌گیری نیروی برش در جهت پیشروی و شعاعی به‌عنوان مقادیر ورودی، نتایج بهتری نسبت به شتاب ارتعاش به دست آورد. میانگین مربع خطا انجام شده برابر با ۰/۰۴۵ بود. این بدان معناست که هم نیروی برش و هم شتاب ارتعاش برای ارزیابی سایش ابزار در حین ماشین‌کاری مواد سخت‌کاری شده به یک اندازه خوب هستند.

در پژوهش حاضر تلاش شد که یک مدل شبکه عصبی مصنوعی با کمترین میانگین خطای مطلق و میانگین مربع خطا برای پیش‌بینی سایش ابزار توسعه داده شود.


۲- مواد و روش‌ها

۲-۱- آزمایش تجربی

ماده قطعه کار مورد استفاده برای آزمایش فولاد ۴۱۴۰ بود که سختی آن تحت عملیات حرارتی از ۱۵ به ۴۵ راکول C رسانده شد. مطابق شکل ۱ برای آزمایش‌ها از میله به قطر ۱۹ میلی‌متر و طول ۱۵۰ میلی‌متر استفاده شد. جدول ۱ به ترکیب شیمیایی فولاد ۴۱۴۰ اشاره دارد.

ابزار اینسرتی TCMW 16T304 H13A از جنس کاربید سیمانی بدون پوشش از برند سندویک در این پژوهش مورد استفاده قرار گرفت.

سرعت برشی، نرخ پیشروی و زمان ماشین‌کاری به‌عنوان متغیرهای ورودی و عمق برش در همه آزمایش‌ها ثابت و برابر با



شکل ۲) سایش ابزار برای قطعه ماشین‌کاری شده


پس از اتمام فرایند ماشین‌کاری، ابزار زیر میکروسکوپ نوری مدل M3 از برند وایلد قرار گرفت و سپس تصاویر به‌دست‌آمده با بزرگ‌نمایی ۵۰ برابر از سایش پهلوی ابزار که در شکل ۲ مشاهده می‌شود با خط‌کش‌های مدرج مربوطه میکروسکوپ نوری اندازه‌گیری شد.

نتایج اندازه‌گیری شده برای سایش ابزار در جدول ۳ آورده شده است.

جدول ۳) داده‌های اندازه‌گیری شده از سایش ابزار

شماره آزمایش	سرعت برشی	نرخ پیشروی	زمان ماشین‌کاری	عمق برش	سایش ابزار
۱	۲۴	۱۴	۱۵	۰/۸	۰/۴۱
۲	۲۴	۱۴	۶۰	۰/۸	۰/۴۸
۳	۲۴	۱۴	۱۲۰	۰/۸	۰/۵۶
۴	۲۴	۲۸	۱۵	۰/۸	۰/۴۴
۵	۲۴	۲۸	۶۰	۰/۸	۰/۵۵
۶	۲۴	۲۸	۱۲۰	۰/۸	۰/۶۱
۷	۲۴	۴۲	۱۵	۰/۸	۰/۴۹
۸	۲۴	۴۲	۶۰	۰/۸	۰/۵۹
۹	۲۴	۴۲	۱۲۰	۰/۸	۰/۶۶
۱۰	۴۸	۱۴	۱۵	۰/۸	۰/۵۳
۱۱	۴۸	۱۴	۶۰	۰/۸	۰/۵۸
۱۲	۴۸	۱۴	۱۲۰	۰/۸	۰/۶۵
۱۳	۴۸	۲۸	۱۵	۰/۸	۰/۵۹
۱۴	۴۸	۲۸	۶۰	۰/۸	۰/۶۴
۱۵	۴۸	۲۸	۱۲۰	۰/۸	۰/۷۲
۱۶	۴۸	۴۲	۱۵	۰/۸	۰/۶۲
۱۷	۴۸	۴۲	۶۰	۰/۸	۰/۶۷
۱۸	۴۸	۴۲	۱۲۰	۰/۸	۰/۸
۱۹	۷۲	۱۴	۱۵	۰/۸	۰/۶۷
۲۰	۷۲	۱۴	۶۰	۰/۸	۰/۶۹
۲۱	۷۲	۱۴	۱۲۰	۰/۸	۰/۷۸
۲۲	۷۲	۲۸	۱۵	۰/۸	۰/۷۰
۲۳	۷۲	۲۸	۶۰	۰/۸	۰/۷۱
۲۴	۷۲	۲۸	۱۲۰	۰/۸	۰/۸۳
۲۵	۷۲	۴۲	۱۵	۰/۸	۰/۷۵
۲۶	۷۲	۴۲	۶۰	۰/۸	۰/۷۶
۲۷	۷۲	۴۲	۱۲۰	۰/۸	۰/۸۹

۰/۸ میلی‌متر در نظر گرفته شد. جدول ۲ سطوح مختلف متغیرهای ورودی را نشان می‌دهد. طراحی آزمایش‌های به روش آرایه متعامد تاگوچی L۲۷ صورت گرفت.



شکل ۱) تصویر نمونه‌ها قبل از ماشین‌کاری

جدول ۱) ترکیبات شیمیایی فولاد آلیاژی ۴۱۴۰ [5]

درصد وزنی	ترکیبات
۰/۱۷۰	مولیبدن
۱/۱۰۰	کروم
۰/۰۲۹	گوگرد
۰/۴۱۰	کربن
۹۷/۳۰۰	آهن
۰/۲۶۰	سیلیسیم
۰/۷۴۰	منگنز
۰/۰۱۲	فسفر

جدول ۲) سطوح مختلف پارامترهای ماشین‌کاری

سطح ۳	سطح ۲	سطح ۱	واحد	پارامتر ورودی
۷۲	۴۸	۲۴	متر در دقیقه	سرعت برشی
۴۲	۲۸	۱۴	میلی‌متر در دقیقه	نرخ پیشروی
۱۲۰	۶۰	۱۵	ثانیه	زمان ماشین‌کاری

دستگاه تراش مدل HLV-H از برند فلت‌هام که در فرایند ماشین‌کاری از آن استفاده شد، دستگاهی بود که سرعت پیشروی و سرعت برشی آن از یکدیگر مستقل بود. به دلیل این ویژگی، تأثیر پارامترهای سرعت برشی و نرخ پیشروی به‌صورت مستقل از هم مورد بررسی قرار گرفت.

که Y_i مقدار تجربی، Y_d مقدار پیش‌بینی و N تعداد مجموعه داده‌ها را نشان می‌دهد. نتایج پیش‌بینی سایش ابزار برای داده‌هایی که در آموزش شبکه و آزمون و اعتبارسنجی استفاده شدند در جدول ۴ و ۵ ذکر شده است.

جدول ۴) سایش ابزار پیش‌بینی شده برای داده‌های آموزش شبکه عصبی مصنوعی

شماره آزمایش	سرعت برشی	نرخ پیشروی	زمان ماشین‌کاری	عمق برش	سایش ابزار پیش‌بینی
۱	۷۲	۱۴	۱۵	۰/۸	۰/۵۹۹
۲	۴۸	۴۲	۱۲۰	۰/۸	۰/۷۴۲
۳	۲۴	۴۲	۶۰	۰/۸	۰/۵۶۶
۴	۷۲	۴۲	۱۵	۰/۸	۰/۶۹۸
۵	۲۴	۱۴	۶۰	۰/۸	۰/۴۸۸
۶	۲۴	۲۸	۶۰	۰/۸	۰/۵۳۸
۷	۲۴	۲۸	۱۲۰	۰/۸	۰/۶۱۰
۸	۲۴	۱۴	۱۲۰	۰/۸	۰/۵۶۱
۹	۴۸	۴۲	۱۵	۰/۸	۰/۶۱۶
۱۰	۷۲	۲۸	۶۰	۰/۸	۰/۷۰۳
۱۱	۲۴	۲۸	۱۵	۰/۸	۰/۴۸۳
۱۲	۷۲	۴۲	۶۰	۰/۸	۰/۷۵۳
۱۳	۷۲	۲۸	۱۲۰	۰/۸	۰/۷۷۶
۱۴	۴۸	۴۲	۶۰	۰/۸	۰/۵۹۹
۱۵	۷۲	۴۲	۱۲۰	۰/۸	۰/۸۲۵
۱۶	۷۲	۱۴	۱۲۰	۰/۸	۰/۷۲۶
۱۷	۴۸	۲۸	۱۵	۰/۸	۰/۵۸۷
۱۸	۴۸	۱۴	۶۰	۰/۸	۰/۵۷۱
۱۹	۴۸	۲۸	۱۲۰	۰/۸	۰/۶۹۳
۲۰	۷۲	۱۴	۶۰	۰/۸	۰/۶۵۴
۲۱	۲۴	۴۲	۱۵	۰/۸	۰/۵۳۳

جدول ۵) سایش ابزار پیش‌بینی شده برای داده‌های اعتبارسنجی شبکه عصبی مصنوعی

شماره آزمایش	سرعت برشی	نرخ پیشروی	زمان ماشین‌کاری	عمق برش	سایش ابزار پیش‌بینی
۱	۲۴	۴۲	۱۲۰	۰/۸	۰/۶۵۹
۲	۴۸	۲۸	۶۰	۰/۸	۰/۶۲۰
۳	۴۸	۱۴	۱۵	۰/۸	۰/۵۱۷
۴	۷۲	۲۸	۱۵	۰/۸	۰/۶۴۹
۵	۲۴	۱۴	۱۵	۰/۸	۰/۴۳۴
۶	۴۸	۱۴	۱۲۰	۰/۸	۰/۶۴۳


۳- نتایج و بحث

مقایسه بین نتایج تجربی و نتایج پیش‌بینی مدل شبکه عصبی مصنوعی برای پارامتر سایش ابزار در شکل ۴ نشان داده شده است. جدول ۶ مقادیر میانگین مربع خطا، میانگین خطای مطلق و میانگین درصد خطا برای داده‌های آموزش و اعتبارسنجی را نشان می‌دهد. می‌توان مشاهده کرد که حداکثر و حداقل سایش ابزار که توسط شبکه عصبی مصنوعی پیش‌بینی شده است تقریباً مشابه اندازه‌گیری به صورت تجربی است. برای حداقل سایش ابزار که با

۲-۲- مدل‌سازی شبکه عصبی مصنوعی

در این پژوهش برای مدل‌سازی و آموزش شبکه از برنامه پایتون و کتابخانه‌های سایکت لرن، کراس، تنسورفلو و متپلات لیب استفاده شد. پس از سعی و خطای فراوان توپولوژی بهینه با ۳ نورون در لایه ورودی شامل پارامترهای ورودی ماشین‌کاری تجربی (سرعت برشی، نرخ پیشروی و زمان ماشین‌کاری)، دو لایه پنهان با ۱۲ و ۳۶ نورون به ترتیب در لایه اول و دوم پنهان و ۱ نورون در لایه خروجی به دست آمد. معماری شبکه عصبی مصنوعی بهینه در شکل ۳ نشان داده شده است.

پس از شناسایی ساختار مناسب، تعداد ۲۱ داده (۸۰٪) برای آموزش شبکه عصبی مصنوعی و ۶ داده (۲۰٪) برای آزمون و اعتبارسنجی مدل مورد استفاده قرار گرفت که انتخاب داده‌ها به صورت تصادفی انجام می‌شد. شبکه در تکرارهای مختلف آموزش داده شد تا مناسب‌ترین نسل برای آموزش شبکه عصبی مصنوعی شناسایی شود. در این مطالعه تعداد تکرار ۱۰۰۰ برای آموزش



شکل ۳) معماری بهینه ۱-۳۶-۱۲-۳ برای مدل شبکه عصبی مصنوعی

انتخاب شد که بعد از هر ۱۰ داده پس انتشار خطا انجام می‌شود تا خطای مطلق بین مقدار پیش‌بینی و آزمایش تجربی به کمترین مقدار برسد. برای اعتبارسنجی پیش‌بینی‌ها از مقدار میانگین خطای مطلق و میانگین مربع خطا استفاده شد. برای محاسبه میانگین خطای مطلق و میانگین مربع خطا از معادلات (۱) و (۲) استفاده شد. همچنین برای محاسبه میانگین درصد خطای داده‌های آموزش و اعتبارسنجی از معامله (۳) استفاده شد.

$$MAE = \frac{1}{N} \times \sum_0^N (|Y_i - Y_d|) \quad (1)$$

$$MSE = \frac{1}{N} \times \sum_0^N (Y_i - Y_d)^2 \quad (2)$$

$$\Delta = \frac{1}{N} \times \sum_0^N \frac{|Y_i - Y_d|}{Y_i} \times 100 \quad (3)$$

به‌عنوان ابزار مؤثر برای پایش وضعیت ابزار در تراشکاری فولاد ۴۱۰ تبدیل می‌کند. همچنین می‌تواند به‌عنوان یک روش جایگزین برای انجام یک سری آزمایش‌ها در نظر گرفته شود و از اتلاف وقت و هزینه جلوگیری کند.

تأییدیه اخلاقی: نویسندگان این تحقیق اقرار می‌نمایند که تمامی نتایج مندرج در این مقاله حاصل تحقیق صورت‌گرفته توسط ایشان و نتایج به‌دست‌آمده از آن می‌باشد.

تعارض منافع: نویسندگان متعهد می‌شوند که در این مقاله تضاد منافع وجود ندارد و این مقاله پیش‌ازین در جای دیگری ثبت نشده است و نخواهد شد.


منابع مالی: کلیه هزینه‌های صورت‌گرفته جهت انجام این تحقیق از منابع شخصی صورت‌گرفته است.

مراجع

- 1- Paturi, U. M. R., Cheruku, S., Pasunuri, V. P. K., & Salike, S. (2021). Modeling of tool wear in machining of AISI 52100 steel using artificial neural networks. *Materials Today: Proceedings*, 38, 2358-2365.
- 2- Bagga, P. J., Makhesana, M. A., Patel, H. D., & Patel, K. M. (2021). Indirect method of tool wear measurement and prediction using ANN network in machining process. *Materials Today: Proceedings*, 44, 1549-1554
- 3- SK, T., Shankar, S., & K, D. (2020). Tool wear prediction in hard turning of EN8 steel using cutting force and surface roughness with artificial neural network. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, 234(1), 329-342.
- 4- Twardowski, P., & Wiciak-Pikuła, M. (2019). Prediction of tool wear using artificial neural networks during turning of hardened steel. *Materials*, 12(19), 3091.
- 5- Nikam, B., Khadtare, A., & Pawade, R. (2021). MACHINABILITY ASSESSMENT OF AISI 4140 HARDENED STEEL USING CBN INSERTS IN HARD TURNING. *International Journal of Modern Manufacturing Technologies (IJMMT)*, 13(1).

پارامترهای ماشینکاری سرعت برشی ۲۴ متر در دقیقه، نرخ پیشروی ۱۴ میلی‌متر در دقیقه و زمان ماشینکاری ۱۵ ثانیه بصورت تجربی برابر با ۰/۴۱ میلی‌متر اندازه‌گیری شده بود مدل شبکه عصبی مصنوعی مقدار سایش ابزار را با ۰/۲۴ میلی‌متر خطا، برابر با ۰/۴۳۴ میلی‌متر پیش‌بینی کرد. در نهایت میانگین درصد خطای داده‌های آموزش و اعتبارسنجی به ترتیب ۴/۵۸ و ۳/۳۲ درصد بدست آمد که نشانگر دقت بالای مدل شبکه عصبی مصنوعی است.

همان‌طور که در جدول ۶ نشان داده‌شده است، خطاهای آموزش و اعتبارسنجی تقریباً یکسان هستند و به این معنی است که شبکه عصبی به‌اندازه کافی آموزش‌دیده است و از میانگین خطای مطلق و میانگین مربع خطای تمام داده‌ها، داده‌های آموزش و داده‌های اعتبارسنجی برای به‌دست‌آوردن یک شبکه بهینه استفاده شد. میانگین خطای مطلق ۰/۱۹۳۳۳ و میانگین مربع خطای ۰/۰۰۰۶۳۳ برای داده‌های اعتبارسنجی عملکرد خوب شبکه عصبی مصنوعی طراحی شده برای پیش‌بینی سایش ابزار را نشان می‌دهد.



شکل ۴) مقایسه بین مقادیر پیش‌بینی مدل شبکه عصبی مصنوعی و اندازه‌گیری شده برای سایش ابزار

جدول ۶) میانگین مربع خطا، میانگین خطای مطلق و میانگین درصد خطا برای داده‌های آموزش و اعتبارسنجی

اعتبارسنجی	آموزش
۰/۱۹۳۳۳	میانگین خطای مطلق ۰/۰۳۰۹۰۵
۰/۰۰۰۶۳۳	میانگین مربع خطا ۰/۰۰۱۵۶۸
۳/۳۲	میانگین درصد خطا ۴/۵۸

۴- نتیجه‌گیری

هدف از این کار ارائه روش پیش‌بینی سایش ابزار در حین تراشکاری با استفاده از شبکه عصبی مصنوعی است. عملکرد مدل شبکه عصبی مصنوعی با مقایسه بین نتایج پیش‌بینی و نتایج اندازه‌گیری دستی بررسی شد. میانگین مربع خطا ۰/۰۰۰۶۳۳، میانگین خطای مطلق ۰/۱۹۳۳۳ و میانگین درصد خطای ۳/۳۲ برای داده‌های اعتبارسنجی مدل شبکه عصبی مصنوعی طراحی شده نشان می‌دهد مدل توسعه‌یافته دقت خوبی در پیش‌بینی سایش ابزار دارد. دقت به‌دست‌آمده با مدل پیشنهادی، آن را