



پیش‌بینی زبری سطح در فرزکاری آلیاژهای آلومینیوم با استفاده از شبکه فازی عصبی همراه با روش‌های یادگیری فرا ابتکاری

امین سیاهوشی^۱، محمد شهبازی^۲، سید علی نیک نام^{۲*}

۱- دانشجوی کارشناسی ارشد، دانشکده مهندسی مکانیک، دانشگاه علم و صنعت ایران، تهران، ایران

۲- استادیار، دانشکده مهندسی مکانیک، دانشگاه علم و صنعت ایران، تهران، ایران

* ایمیل نویسنده مسئول: saniknam@iust.ac.ir

اطلاعات مقاله

مقاله پژوهشی

دریافت: ۳۰ مرداد ۱۴۰۲

پذیرش: ۲۴ بهمن ۱۴۰۲

چکیده

با توجه به اهمیت زبری سطح در قطعات ماشینکاری شده، باید با انتخاب پارامترهای صحیح برشی و غیر برشی، پیش‌بینی و بهینه‌سازی آن را تحقق بخشید. یکی از روش‌های استفاده شده در این حوزه پیش‌بینی زبری سطح با روش‌های سنتی بوده است و از روش‌های فراابتکاری کمتر استفاده شده است. در نتیجه در این تحقیق، با استفاده از الگوریتم‌های هوش مصنوعی و به صورت خاص‌تر با استفاده از الگوریتم شبکه عصبی فازی و همچنین الگوریتم ترکیبی شبکه عصبی فازی مبتنی بر ژنتیک، بر روی داده‌های بدست آمده مدلی ایجاد می‌گردد که بتواند پیش‌بینی یک خروجی خاص (به طور مثال زبری سطح) را انجام دهد. در مجموع از داده‌های ۱۶۲ آزمایش برای سه آلیاژ آلومینیوم ۷۰۷۵، ۶۰۶۱ و ۲۰۲۴ استفاده شد که شامل سرعت برشی، عمق برش، نوع پوشش ابزار، نرخ پیشروی ابزار و خروجی زبری سطح می‌باشد. ورودی پنجمی نیز که مبین خواص مکانیکی مواد از جمله استحکام کششی، مقاومت برشی و سختی می‌باشد استفاده گردید و مدل‌سازی به صورت یکپارچه برای هر سه آلیاژ انجام گردید. در این پژوهش داده‌های دو نوع از سه نوع آلیاژ موجود به عنوان داده آموزش و سومی برای داده تست استفاده شد. شبیه‌سازی انجام شده روی داده‌ها با استفاده از معیارهای رگرسیون (R) و مجذور میانگین مربعات خطا (RMSE) مورد ارزیابی قرار گرفت. دقیق‌ترین نتیجه از بین دو روش ANFIS (سیستم استنتاجی فازی-عصبی تطبیقی) و ANFIS-GA (مدل ترکیبی سیستم استنتاجی فازی-عصبی تطبیقی همراه با الگوریتم ژنتیک) با رگرسیون ۰/۸۳۸ برای زبری سطح برای داده‌های تست بدست آمد.

کلیدواژگان:

ماشینکاری

زبری سطح

ANFIS

ANFIS-GA

The use of a neuro-fuzzy network coupled with meta-heuristic learning methods to predict surface roughness in the machining of aluminum alloys

Amin Siahvashi¹, Mohammad Shahbazi², Seyed Ali Niknam^{2*}

1- MSc Student, School of Mechanical Engineering, Iran University of Science and Technology, Tehran, Iran

2- Assistant Professor, School of Mechanical Engineering, Iran University of Science and Technology, Tehran, Iran

* Corresponding Author's Email: saniknam@iust.ac.ir

Article Information

Original Research Paper

Received: 21 August 2023

Accepted: 13 February 2024

Keywords:

Machining

Surface Roughness

ANFIS

ANFIS-GA

Abstract

Considering the importance of surface roughness in machined parts, it is necessary to identify the factors that play an essential role in determining and improving surface quality. In this regard, they can be predicted and optimized by choosing suitable parameters. One of the methods used in this area is the prediction of surface roughness with traditional methods. However, limited studies were found on using meta-heuristic methods. As a result, this study proposed a model using A.I. algorithms and, more specifically, the fuzzy neural network algorithm and the combined algorithm of the fuzzy neural network. In total, 162 tests were used on three aluminum alloys 7075, 6061 and 2024, which include a variation of cutting speed, depth of cut, tool coating, feed rate, and surface roughness output. The fifth input parameter was the mechanical properties of materials, such as tensile strength, shear strength and hardness. During the modeling process, the corresponding data of two alloys were used as training data and the third as test data. The simulation performed on the data was evaluated using regression (R) and root mean square error (RMSE) criteria. The most accurate result among the two ANFIS and ANFIS-GA methods was obtained with a regression of 0.838 for the surface roughness of the test data.

Please cite this article using:

Siahvashi A, Shahbazi M, Niknam SA. The use of a neuro-fuzzy network coupled with meta-heuristic learning methods to predict surface roughness in the machining of aluminum alloys. Iranian Journal of Manufacturing Engineering. 2024 January 21;10(11):49-60. doi: 10.22034/IJME.2024.412021.1816 [In Persian]

برای ارجاع به این مقاله از عبارت ذیل استفاده نمایید:

۱- مقدمه

فرایندهای ساخت، از جمله ساخت افزودنی، ریخته‌گری، ماشین‌کاری و جوشکاری، قطعاتی را تولید می‌کنند که دارای عیوب سطحی هستند (مانند خط‌های ساخت، حفره‌ها، خطوط فرزکاری، یا پاشش جوش) فرایندهای مختلفی برای از بین بردن این عیوب از جمله سنباده‌زدن، سنگ‌زنی، بلاست‌کردن و پرداخت ارتعاشی در دسترس هستند [۱]. همچنین میزان کیفیت سطح نشانه‌ای بسیار مهم از کیفیت ماده مهندسی است و مهم‌ترین نشانه‌ی کیفیت سطح قطعه کار ماشین‌کاری شده ساختار کیفی سطح و زبری سطح است. اندازه‌گیری دقیق زبری سطح در زمینه‌ی مهندسی دقیق و مهندسی تولید در صنعت از اهمیت بسیار زیادی برخوردار است. معمولاً زبری و ساختار کیفی سطح با دستگاه قلم نوک سوزنی به صورت مکانیکی اندازه‌گیری می‌شود. سالیان سال است که دستگاه قلم نوک سوزنی برای اندازه‌گیری پارامترهای زبری سطح به طور گسترده استفاده می‌شوند. این دستگاه‌ها از قابلیت اعتماد بسیار زیادی برخوردار است. از محدودیت‌های این روش یکی اینکه حرکت عمودی نوک قلم برای طول مشخصی اندازه‌گیری می‌شود و همچنین نوک قلم به همه‌ی دره‌های سطحی نمی‌رسد [۲].

به‌طور کلی ساخت قطعات با هزینه کم و کیفیت مطلوب از اولویت اصلی صنایع مرتبط می‌باشد و برای نیل به قطعات با کیفیت سطح بالا انتخاب مناسب پارامترهای ماشین‌کاری از اهمیت ویژه‌ای برخوردار است. کنترل و پیش‌بینی دقیق زبری سطح ماشین‌کاری شده برای افزایش کارایی و رسیدن به قطعاتی با قابلیت اطمینان و طول عمر بالا، در قطعات نیروگاهی حیاتی است. فرزکاری^۱ یکی از متداول‌ترین عملیات ماشین‌کاری در بخش‌های تولیدی متعدد است که حالت‌های پیچیده‌ای از شکل‌گیری تراشه و تعامل بین ابزارهای برش و قطعه کار دارد. بنابراین، پارامترهای برش باید به اندازه کافی با دقت انتخاب شوند. در غیر این صورت، مشکلاتی از قبیل لرزش ابزار، نوسان نیروی برش و دمای بالای برش باعث کاهش کیفیت سطح و همچنین افزایش زمان ماشین‌کاری می‌شود که در نهایت منجر به افزایش هزینه تولید خواهد شد.

زبری سطح از مهم‌ترین ویژگی‌های فرزکاری هستند. متوسط زبری سطح (Ra^2) و مقادیر میانگین نیروهای برشی، ویژگی‌های اصلی یکپارچگی سطح و نیروهای برش در هنگام کار با عملیات فرزکاری هستند. بناردس^۳ و وسنیکس^۴ [۳] تکنیک‌های مدل‌سازی اعمال شده برای پیش‌بینی زبری سطح را به سه دسته اصلی تقسیم کردند: مدل‌های تجربی، تحلیلی/عددی و هوش مصنوعی (AI). مدل‌های تجربی و تحلیلی بر اساس اطلاعات تجربی و رویکردهای مرسوم مانند رگرسیون آماری معروف به [۳-۶] RSM^۵ است. مدل‌های هوش مصنوعی از رویکردهای مختلفی مانند شبکه‌های عصبی مصنوعی [۷-۱۰] (ANN)، الگوریتم‌های ژنتیک [۱۱] (GA)، منطق فازی [۱۲] و سیستم‌های ترکیبی [۱۳-۱۵] استفاده می‌کنند.

رویکردهای تحلیلی عددی عمدتاً به سینماتیک ماشین‌کاری، خواص ابزار برش و اثرات متقابل بین پارامترهای برش وابسته هستند. با توجه به پیچیدگی بسیاری از عوامل برش و غیر برش در فرایند ماشین‌کاری، نظریه فوق، علی‌رغم پیشینه نظری قوی، مدل دقیقی نیست. علاوه بر این، چندین پارامتر مانند سایش، انحراف ابزار برش، یا پدیده‌های حرارتی هنوز به خوبی مدل‌سازی نشده‌اند. رویکردهای تجربی، برای تولید داده‌های مبتنی بر تجربی طراحی شده‌اند که در صورت استفاده از پارامترهای برش متفاوت قابل اعتماد نیستند. در تحلیل‌های رگرسیون آماری، بینش محققین نقش اصلی را ایفا می‌کند و هیچ فرمول سیستمی در دسترس نیست. به طور کلی نتایج یک محدوده عملی محدود را پوشش می‌دهد که منطقه‌ای است و به دلیل ناآگاهی از برخی عوامل، امکان دستیابی به نتایج غیرمنتظره نیز وجود ندارد. علاوه بر این، مطالعه تجربی برای طیف وسیعی از پارامترهای برش زمان‌بر و پرهزینه است [۳-۱۶].

با علم به اینکه معادلات ریاضی کافی و دانش جامع در مورد اثرات مستقیم و غیرمستقیم پارامترهای برش بر پاسخ‌های ماشین‌کاری در دسترس نیست، بنابراین استفاده از روش‌های مبتنی بر هوش مصنوعی برای توسعه مدل‌های نزدیک به واقعیت موضوع مورد توجه بخش‌های صنعتی و دانشگاهی بوده است. رویکردهای مبتنی بر هوش مصنوعی توانایی زیادی در مدل‌سازی پدیده‌ها و عدم قطعیت‌های پیچیده دارند. شبکه‌های عصبی مصنوعی^۶، سیستم‌های منطق فازی و سیستم استنتاج فازی مبتنی بر شبکه از جمله

¹ Milling

^۲ میانگین حسابی پروفیل زبری است که مقدار آن از محاسبه مجموع انحرافات از خط مرکزی در طول مورد بررسی بدست می‌آید.

³ Benardos

⁴ Vosniakos

⁵ Response Surface Method

⁶ ANN

محبوب‌ترین روش‌های هوش مصنوعی هستند که به طور گسترده برای مدل‌سازی و بهینه‌سازی فرایندهای ماشین‌کاری مورد استفاده قرار می‌گیرند.

سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) روش مناسبی برای حل مسایل غیرخطی است. این روش، ترکیبی از روش استنتاج فازی و شبکه عصبی مصنوعی است که از مزایای هر دو روش بهره می‌برد، در نتیجه در این تحقیق از دو نوع شبکه عصبی فازی با الگوریتم‌های یادگیری فراابتکاری به نام‌های ANFIS-GA و ANFIS بر روی بخش خاصی از ورودی‌های تجربی به عنوان داده‌های آموزشی اعمال شده‌اند. بقیه داده‌های ورودی و خروجی به عنوان داده‌های آزمایشی استفاده شد. پس از آن، عملکرد شبکه‌های پیشنهادی به عنوان پیش‌بینی‌کننده یا تخمین‌گر با مقایسه خروجی‌های شبکه و داده‌های تجربی واسطه شد. در مطالعه حاضر، روش‌های هوش مصنوعی بر اساس شبکه چند ورودی توسعه داده شد. رابطه بین ورودی‌ها و خروجی‌ها لزوماً خطی نیست و دلیل استفاده از این شبکه‌ها توانایی آن‌ها در تخمین عوامل مختلف ماشین‌کاری غیرخطی است.


۲- آزمایش و مدل‌سازی

در این پژوهش آزمایش‌های تجربی برای سه آلیاژ آلومینیوم با فرایند فرزکاری و استراتژی فرزکاری شیار^۱ با فرز سه دندانه با قطر ۱۹/۰۵ بر روی بلوک‌های به ابعاد ۱/۲×۳/۵×۳/۵ سانتیمتر (شکل ۱) با ورودی‌های جدول ۱ انجام شد و برای هر قطعه زبری سطح آن با معیار Ra ثبت شد. دستگاه پروفیل‌متر استفاده شده از معتبرترین سازنده‌های دستگاه اندازه‌گیری به نام Mitutoyo مدل SJ400 با مشخصات: طول اندازه‌گیری ۲۰۴ میلیمتر، رنج حرکتی ۸۰۰ میکرون، سرعت حرکت یک میلیمتر بر ثانیه و تعداد نقاط داده برداری ۴۸۰۰ عدد می‌باشد که تصویر آن در شکل ۲ قابل مشاهده است. به دلیل امکان وجود خطاهای تکرار ناپذیر در هنگام ورود و خروج ابزار به داخل قطعه، هنگام اندازه برداری زبری سطح در هر قطعه از سه قسمت ابتدا، وسط و انتها اندازه‌گیری شده و میانگین آن به عنوان خروجی دریافت شده در نظر گرفته شده است.

جدول ۱ پارامترهای ماشین‌کاری استفاده شده

ردیف	ورودی	واحد	مقدار
۱	سرعت برش	m/min	۳۰۰ ۷۵۰ ۱۲۰۰
۲	نرخ پیشروی	mm/rev	۰/۰۱ ۰/۰۵۵ ۰/۱
۳	عمق برش	mm	۱ ۲
۴	پوشش ابزار	-	Ticn TiAln TiCn+Al2O3+Tin

^۱ Slot Milling



شکل ۱ قطعات ماشینکاری



شکل ۲ زبری سنج استفاده شده (Mitutoyo SJ 400)

داده‌ها آماده مدل‌سازی و استراتژی به این صورت می‌باشد که هر بار داده‌های دو آلیاژ به همراه یکی از خواص مکانیکی مواد (استحکام کششی، مقاومت برشی و سختی که هر سه در زمان ران کردن برنامه قابل انتخاب می‌باشد و می‌توان در هر بار ران کردن از یکی از آن‌ها به عنوان ورودی پنجم مدل استفاده کرد) مطابق جدول ۲ به عنوان ورودی پنجم به مدل اضافه شده و با این داده‌ها مدل آموزش داده می‌شود. در انتها برای ارزیابی دقت مدل‌سازی، داده‌های زبری سطح آلیاژ باقیمانده به عنوان داده تست داده شده و این سنجش با رگرسیون^۱ بین خروجی اندازه‌گیری شده و خروجی ارائه شده توسط هوش مصنوعی نمایش داده می‌شود.

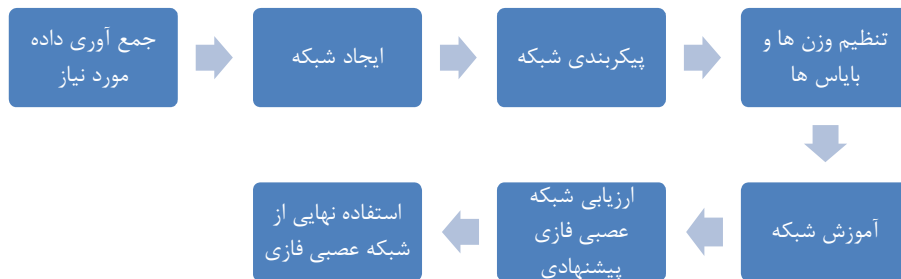
جدول ۲ خواص مکانیکی آلیاژهای آلومینیوم

ردیف	خواص مکانیکی (واحد)	AA7075	AA6061	AA2024
۱	استحکام کششی (مگا پاسکال)	۵۷۲	۳۱۰	۴۹۵
۲	استحکام برشی (مگا پاسکال)	۳۱۷	۲۰۷	۲۹۰
۳	سختی (برینل)	۱۵۰	۹۵	۱۳۰

¹ Regression

۲-۱- سیستم استنتاجی عصبی- فازی تطبیقی^۱

یک سیستم ANFIS بر اساس ترکیب سیستم فازی و سیستم عصبی توسعه یافته است که از دانش و تجربه بشری از طریق سیستم‌ها و قوانین فازی بهره می‌برد که به صورت اگر ... آنگاه ... با توانایی سیستم‌های عصبی برای ایجاد و آموزش می‌باشد. همانطور که در شکل ۳ نشان داده شده است، یک ساختار ANFIS از پنج لایه تشکیل شده است:



شکل ۳ معماری شبکه‌های عصبی مصنوعی [۱۷]

لایه ۱: این لایه به نام فازی‌سازی (fuzzifier) شناخته می‌شود. برای هر ورودی در این لایه، توابع عضویت در نظر گرفته می‌شود. به عبارت دیگر خروجی هر مربع عبارت است از:

$$O_i^1 = \mu_{A_{ki}} \cdot i = 1, 2, k \in \{a_p, F_z, V_c, C\} \quad (1)$$

که در آن $\mu_{A_{ki}}$ نشان دهنده توابع عضویت (MF^2) هر ورودی است و A_{ki} نشان دهنده متغیرهای زبانی مرتبط با هر یک از این گره‌ها می‌باشد. در اکثر ساختارهای ANFIS، توابع عضویت‌های گausی زیر به عنوان $\mu_{A_{1i}}$ و $\mu_{A_{2i}}$ استفاده می‌شود:

$$\mu_{A_i} = \exp\left\{-\left[\frac{x - c_i}{a_i}\right]^2\right\} \quad (2)$$

x ورودی است و $[a_i, b_i, c_i]$ پارامترهای پیش‌فرض برای هر تابع عضویت پیشنهادی هستند.

لایه ۲: یا لایه Rule که خروجی هر گره نشان دهنده وزن گره بر روی ورودی‌ها است. عملگر این لایه می‌تواند جمع یا ضرب باشد که در بیشتر موارد عملگر ضرب در نظر گرفته می‌شود. به عنوان مثال، خروجی گره‌های لایه دوم به شرح زیر است:

$$O_i^2 = w_i = \mu_{A_{1i}}(a_p) \cdot \mu_{A_{2i}}(F_z) \cdot \mu_{A_{3i}}(V_c) \cdot \mu_{A_{4i}}(C), i = 1, 2 \quad (3)$$

لایه ۳: یا لایه نرمال شده. هر گره در این لایه دارای یک مقدار ثابت با نماد N است. خروجی هر لایه نسبت وزن ورودی یا ورودی به کل وزن‌های قواعد است و به صورت زیر بیان می‌شود:

$$O_i^3 = w_i = \frac{w_i}{\sum_i w_i}, i = 1, 2 \quad (4)$$

لایه ۴: همچنین به عنوان لایه فازی‌سازی شناخته می‌شود. هر گره در این لایه تطبیقی است. مقدار خروجی برای هر قاعده (Rule) بر اساس لایه‌ها و ورودی‌های قبلی به صورت زیر تعیین می‌شود:

$$O_i^4 = w_i Y_i = w_i (p_i a_p + q_i F_z + z_i V_c + s + r_i), i = 1, 2 \quad (5)$$

کدام وزن‌های نرمال شده لایه سوم است و p_i, q_i, z_i, r_i و h_i پارامترهای بخش پیامد (نتایج مدل‌سازی) هستند.

لایه ۵: یا لایه خروجی کل. این لایه از مجموع تمام مقادیر خروجی لایه قبلی تشکیل شده است که به صورت زیر نمایش داده می‌شود:

$$O_i^5 = \sum_i w_i Y_i = \frac{\sum_i w_i Y_i}{\sum_i w_i}, i = 1, 2 \quad (6)$$

¹ Adaptive Neuro Fuzzy Inference System

² Membership Function

لطفی‌زاده، از مفهوم مجموعه‌های فازی نوع ۲ برای گسترش رویکرد سیستم فازی نوع اول استفاده کرد [۱۸]. در این نوع سیستم، عضویت فازی نوع ۲ فازی در نظر گرفته می‌شود و منجر به تعریف دو تابع عضویت برای مجموعه‌های فازی نوع ۲ می‌شود که عضویت‌های اولیه و ثانویه نامیده می‌شوند و زیر مجموعه‌های بازه [۰، ۱] هستند. پس از معرفی سیستم‌های فازی نوع ۲، گام‌های بعدی برای ایجاد سیستم‌های فازی و رسیدگی به عدم قطعیت این مجموعه‌ها توسط کارنیک و مندل انجام شد. بنابراین، الگوریتم‌های کاهش^۱ KM معرفی شدند. امروزه به دلیل دقت نتایج پیش‌بینی، کاربردهای گسترده‌ای از الگوریتم‌های کاهش KM در حوزه‌ها و فرآیندهای مختلف معرفی شده‌اند.

۲-۲- الگوریتم ژنتیک

الگوریتم ژنتیک به عنوان یک الگوریتم محاسباتی بهینه‌سازی با در نظر گرفتن مجموعه‌ای از نقاط فضای جواب در هر تکرار محاسباتی به نحو مؤثری نواحی مختلف فضای جواب را جستجو می‌کند. امتیاز دیگر این الگوریتم آن است که هیچ محدودیتی برای تابع بهینه شونده، مثل مشتق‌پذیری یا پیوستگی لازم ندارد و در روند جستجو خود تنها به تعیین مقدار تابع هدف در نقاط مختلف نیاز دارد و هیچ اطلاعات کمکی دیگری، مثل مشتق تابع را استفاده نمی‌کند. لذا می‌تواند در مسائل مختلف اعم از خطی، پیوسته یا گسسته استفاده شود و به سهولت با مسائل مختلف قابل تطبیق باشد.

در هر تکرار هر یک از رشته‌های موجود در جمعیت رشته‌ها، رمزگشایی شده و مقدار تابع هدف برای آن به دست می‌آید. بر اساس مقادیر به دست آمده تابع هدف در جمعیت رشته‌ها، به هر رشته یک عدد برازندگی نسبت داده می‌شود. این عدد برازندگی احتمال انتخاب را برای هر رشته تعیین خواهد کرد. بر اساس این احتمال انتخاب، مجموعه‌ای از رشته‌ها انتخاب شده و با اعمال عملکردهای ژنتیکی روی آن‌ها رشته‌های جدید جایگزین رشته‌هایی از جمعیت اولیه می‌شوند تا تعداد جمعیت رشته‌ها در تکرارهای محاسباتی مختلف ثابت باشد.

مکانیزم‌های تصادفی که روی انتخاب و حذف رشته‌ها عمل می‌کنند به گونه‌ای هستند که رشته‌هایی که عدد برازندگی بیشتری دارند، احتمال بیشتری برای ترکیب و تولید رشته‌های جدید داشته و در مرحله جایگزینی نسبت به دیگر رشته‌ها مقاوم‌تر هستند. بدین لحاظ جمعیت دنباله‌ها در یک رقابت بر اساس تابع هدف در طی نسل‌های مختلف، کامل شده و متوسط مقدار تابع هدف در جمعیت رشته‌ها افزایش می‌یابد.

در الگوریتم ژنتیک، مجموعه‌ای از متغیرهای طراحی را توسط رشته‌هایی با طول ثابت^۲ یا متغیر^۳ کدگذاری می‌کنند که در سیستم‌های بیولوژیکی آن‌ها را کروموزوم یا فرد^۴ می‌نامند. هر رشته یا کروموزوم یک نقطه پاسخ در فضای جستجو را نشان می‌دهد. به ساختمان رشته‌ها یعنی مجموعه‌ای از پارامترها که توسط یک کروموزوم خاص نمایش داده می‌شود ژنوتیپ^۵ و به مقدار رمزگشایی آن فنوتیپ^۶ می‌گویند. الگوریتم‌های وراثتی فرآیندهای تکراری هستند، که هر مرحله تکراری را نسل و مجموعه‌هایی از پاسخ‌ها در هر نسل را جمعیت نامیده‌اند.

الگوریتم‌های ژنتیک، جستجوی اصلی را در فضای پاسخ به اجرا می‌گذارند. این الگوریتم‌ها با تولید نسل^۷ آغاز می‌شوند که وظیفه ایجاد مجموعه نقاط جستجوی اولیه به نام «جمعیت اولیه»^۸ را بر عهده دارند و به طور انتخابی یا تصادفی تعیین می‌شوند. از آنجایی که الگوریتم‌های ژنتیک برای هدایت عملیات جستجو به طرف نقطه بهینه از روش‌های آماری استفاده می‌کنند، در فرآیندی که به انتخاب طبیعی وابسته است، جمعیت موجود به تناسب برازندگی افراد آن برای نسل بعد انتخاب می‌شود. سپس عملگرهای ژنتیکی شامل انتخاب^۹، پیوند (ترکیب)، جهش و دیگر عملگرهای احتمالی اعمال شده و جمعیت جدید به وجود می‌آید. پس از آن جمعیت جدیدی جایگزین جمعیت پیشین می‌شود و این چرخه ادامه می‌یابد.

¹ K Means Clustering

² Fixed Length

³ Variable

⁴ Individual

⁵ Genotype

⁶ Phenotype

⁷ Seeding

⁸ Initial Population

⁹ Selection

معمولاً جمعیت جدید برازندگی بیشتری دارد این بدان معناست که از نسلی به نسل دیگر جمعیت بهبود می‌یابد. هنگامی جستجو نتیجه‌بخش خواهد بود که به حداکثر نسل ممکن رسیده باشیم یا همگرایی حاصل شده باشد و یا معیارهای توقف برآورده شده باشد [۲۴].

۲-۳- مدل ترکیبی سیستم استنتاجی عصبی-فازی تطبیقی همراه با الگوریتم ژنتیک

یکی از پارامترهای ANFIS که نیاز به تنظیم برای ایجاد نتیجه بهتر را دارد پارامترهای توابع عضویت ورودی و خروجی می‌باشد، این توابع عضویت که برای نوع ورودی چندین نوع (گوسی، مثلثی، دوزنقه‌ای و ...) و برای خروجی دو نوع (خطی (Linear) و ثابت (constant)) دارد دارای ضریب‌هایی هستند که با تغییر این ضریب‌ها می‌توان در جهت بهبود مدل‌سازی و نزدیک کردن مدل به داده اصلی و کم کردن خطا پیش رفت. به عنوان مثال در معادله ۲ تابع گوسی دو پارامتر انحراف معیار و مختصات مرکز آن تعیین کننده در شکل این تابع می‌باشند. برای تغییر مقدار این پارامترها در نظر گرفته می‌شود که به طول مثال P_1^0 مقدار اولیه این پارامترها و P_1^* مقدار بهینه این پارامترها باشد و با یک نگاشتی به عنوان مثال $x_i \in [10^{-\alpha} \ 10^{\alpha}]$ که به P_1^0 ضرب می‌شود بایستی به P_1^* (بهینه) رسید و پیدا کردن همین مقدار x_i کاری هست که الگوریتم ژنتیک انجام خواهد داد. در واقع بایستی این پارامترها به صورت بردار از داخل ANFIS استخراج شده، مقادیر بهینه با الگوریتم ژنتیک استخراج شده و دوباره همان بردار بهینه شده به داخل ANFIS انتقال داده شود.

۳- نتایج و بحث

چندین معیار برای ارزیابی عملکرد مدل‌های توسعه یافته از نظر اندازه‌گیری دقت پیش‌بینی استفاده شده است. برای به دست آوردن تفاوت بین اهداف و خروجی‌ها، معیار RMSE یک معیار محبوب است. مقادیر پایین‌تر حاصل از این معیار، عملکرد مناسب‌تر پیش‌بینی را نشان می‌دهد. این معیار به صورت معادله ۷ بیان می‌شود:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad (7)$$

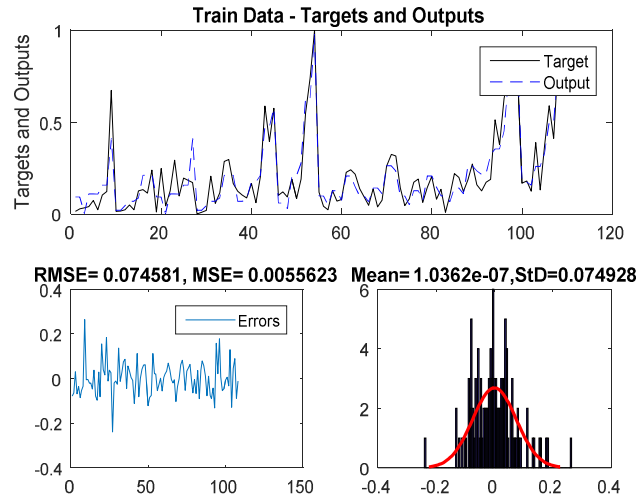
رابطه بین خروجی‌ها و اهداف (نتایج تجربی حاصل شده) با R نشان داده می‌شود که با معادله زیر تعریف می‌شود:

$$R = \frac{\sum_{i=1}^N (x_i - x)(y_i - y)}{\sqrt{\sum_{i=1}^N (x_i - x)^2 \sum_{i=1}^N (y_i - y)^2}} \quad (8)$$


x_i, y_i, x, y و N به ترتیب مقادیر مشاهده شده، مقادیر پیش‌بینی شده، میانگین داده‌های مشاهده شده، میانگین داده‌های پیش‌بینی شده و تعداد داده‌ها را نشان می‌دهند.

در شکل ۴ مدل‌سازی توسط ANFIS انجام شده و همانطور که قابل مشاهده است خروجی مدل‌سازی (خط‌چین آبی) با تقریب خوبی به خروجی تجربی (خط مشکی) منطبق شده و همچنین مقایسه داده‌های اصلی و داده‌های بدست آمده از مدل در قسمت آموزش مدل با RSME ۰/۰۷ و همچنین در شکل ۵ رگرسیون آن‌ها با دقت ۰/۹۳ قابل مشاهده می‌باشد. همچنین بعد از آموزش مدل با اطلاعات دو آلیاژ (انتخاب به صورت رندوم) از مدل آموزش دیده برای تست آلیاژ سوم تحت شرایط برشی ارائه شده در جدول ۱ استفاده گردید و همانطور که در شکل ۶ قابل مشاهده می‌باشد، زبری سطح آلیاژ سوم با دقت حدود ۷۲ درصد پیش‌بینی شده است.

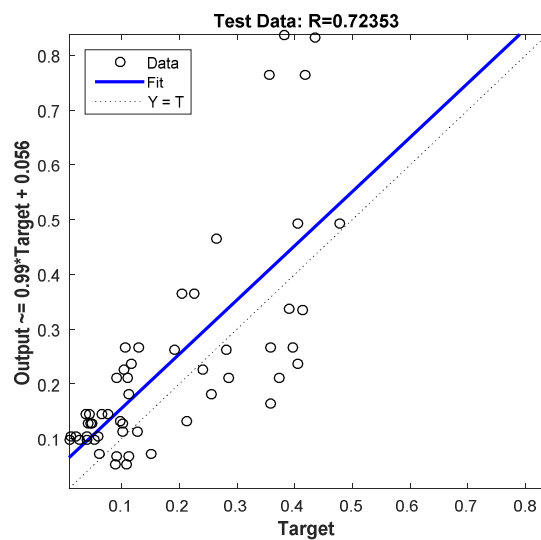
نتایج بدست آمده از ANFIS هر بار با تغییر متغیر پنجم (خواص مکانیکی) ورودی تست شد که در بین نتایج مشاهده شده بهترین نتیجه با ورودی مقاومت برشی می‌باشد. جدول ۳ نتایج بدست آمده برای داده‌های تست را نمایش می‌دهد. مدل‌سازی با ANFIS-GA نیز انجام شد و نتایج مدل‌سازی با داده‌های آموزش در شکل‌های ۷ و ۸ قابل مشاهده می‌باشد. مقایسه داده‌های تجربی (خط مشکی) و داده‌های بدست آمده از مدل (خط‌چین قرمز) در شکل ۸ که خطای RSME ۰/۱ و همچنین رگرسیون آن با دقت ۰/۸۳ در شکل ۷ قابل مشاهده می‌باشد.



شکل ۴ نمودار داده آموزش در روش ANFIS




شکل ۵ رگرسیون بین داده آموزش و خروجی مدل روش ANFIS




شکل ۶ رگرسیون بین داده تست و خروجی مدل روش ANFIS

جدول ۳ مقایسه دقت خواص مکانیکی متفاوت در مدل‌سازی روش ANFIS

R	RMSE	ورودی متغیر پنجم
0.680	0.210	استحکام کششی
0.723	0.141	مقاومت برشی
0.655	0.292	سختی




شکل ۷ رگرسیون بین داده آموزش و خروجی مدل روش ANFIS-GA



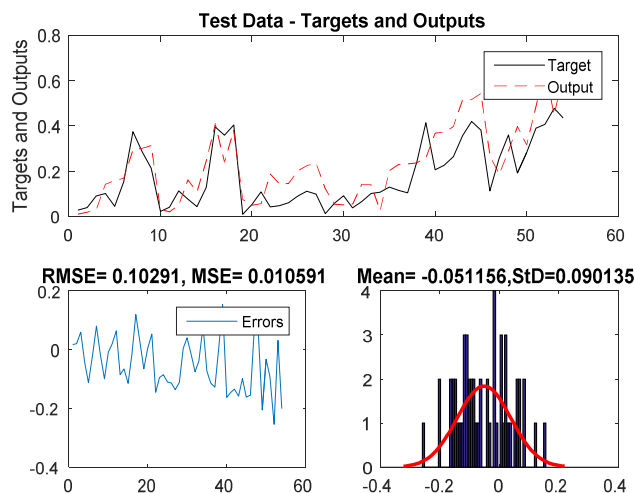
شکل ۸ نمودار داده آموزش در روش ANFIS-GA

همچنین بعد از آموزش مدل با اطلاعات دو آلیاژ (انتخاب به صورت رندوم) از مدل آموزش دیده برای تست آلیاژ سوم و مقایسه خروجی مدل و خروجی تجربی زبری سطح خروجی گرفته شده که همانطور که در شکل ۹ قابل مشاهده می‌باشد زبری سطح آلیاژ سوم با دقت حدود ۸۳ درصد پیش‌بینی شده است.



شکل ۹ رگرسیون بین داده تست و خروجی مدل روش ANFIS-GA

مجدد در این روش نیز نتایج بدست آمده از ANFIS-GA هر بار با تغییر متغیر پنجم ورودی تست شد که در بین نتایج مشاهده شده بهترین نتیجه با ورودی استحکام کششی می باشد (جدول ۴).



شکل ۱۰ نمودار داده تست در روش ANFIS-GA

جدول ۴ مقایسه دقت خواص مکانیکی متفاوت در مدل‌سازی روش ANFIS-GA

R	RMSE	ورودی متغیر پنجم
0.838	0.102	استحکام کششی
0.790	0.201	مقاومت برشی
0.815	0.190	سختی

۴- نتیجه گیری

هدف از این پژوهش مدل‌سازی و پیش‌بینی زبری سطح با استفاده از شبکه فازی عصبی بود. بر روی سه آلیاژ آلومینیوم با خواص مکانیکی متفاوت و هم‌میتور با پارامترهای ورودی متفاوت ۱۶۲ تست انجام شد و زبری سطح هر تست با معیار Ra ثبت شد. با دو

روش ANFIS و ANFIS-GA مدل‌سازی انجام شد و مشاهده شد که دقت ANFIS-GA حدود ده درصد بهتر از ANFIS ثابت شده است. در هر دو روش ۱۰۸ آزمایش که جمع آزمایش دو آلیاژ می باشد برای داده آموزش و داده‌های ورودی یک آلیاژ برای داده تست در نظر گرفته شد. با توجه به اینکه چهار پارامتر ورودی هر سه آلیاژ (سرعت برشی، عمق برش، نرخ پیشروی و پوشش ابزار) یکسان می‌باشد ورودی پنجمی به مدل تحت عنوان خواص مکانیکی (استحکام کششی، مقاومت برشی و سختی) به آن اضافه شد که تاثیر تفاوت مقداری زبری در هر آلیاژ قابل مدل‌سازی باشد و شاید این امکان را فراهم کند که بدون آزمایش مجدد برای دیگر آلیاژهای آلومینیوم با ورودی‌های مشخص و خواص مکانیکی آن زبری سطح آن‌ها را پیش‌بینی کرد.

فهرست علائم

Adaptive neuro-fuzzy inference system	ANFIS
Genetic Algorithm	G.A.
تابع عضویت (Membership Function)	M.F.
ریشه میانگین مربعات خطا	RMSE
رگرسیون	R
قواعد	Rule
K-means Clustring	Km

References

- [1] Caesarendra W, Wijaya T, Tjahjowidodo T, Pappachan BK, Wee A, Roslan MI. Adaptive neuro-fuzzy inference system for deburring stage classification and prediction for indirect quality monitoring. Applied Soft Computing. 2018;72:565-78. doi: 10.1016/j.asoc.2018.01.008
- [2] Zain AM, Haron H, Sharif S, Prediction of surface roughness in the end milling machining using Artificial Neural Network. Expert Systems with Applications. 2010;37(2):1755-68. doi: org/10.1016/j.eswa.2009.07.033
- [3] Benardos PG, Vosniakos CC. Predicting surface roughness in machining: a review, international journal of machine tools and manufacture. 2003;43(8):833-44. doi: 10.1016/S0890-6955(03)00059-2
- [4] Asiltürk I, Çunkaş M. Modeling and prediction of surface roughness in turning operations using artificial neural network and multiple regression method, Expert systems with applications. 2003;38(5):5826-32. doi: 10.1016/j.eswa.2010.11.041
- [5] Fuht KH, Wu CF. A proposed statistical model for surface quality prediction in end-milling of Al alloy, International Journal of Machine Tools and Manufacture. 1995;8(35):1187-200. doi: 10.1016/0890-6955(95)90408-E
- [6] Zhang JZ, Chen JC, Kirby ED. Surface roughness optimization in an end-milling operation using the Taguchi design method, Journal of materials processing technology. 2007;184(1-3):233-9. doi: 10.1016/j.jmatprotec.2006.11.029
- [7] Çolak O, Kurbanoğlu C, Kayacan MC. Milling surface roughness prediction using evolutionary programming methods, Materials & design. 2007;28(2):657-66. doi: 10.1016/j.matdes.2005.07.004
- [8] Chen S, Hong X, Harris CJ, Sharkey PM. Sparse modeling using orthogonal forward regression with PRESS statistic and regularization, IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics). 2004;34(2):898-911. doi: 10.1109/TSMCB.2003.817107
- [9] Briceno JF, El-Mounayri H, Mukhopadhyay S. Selecting an artificial neural network for efficient modeling and accurate simulation of the milling process, International Journal of Machine Tools and Manufacture. 2002;42(6):663-74. doi: 10.1016/S0890-6955(02)00008-1
- [10] Meddour I, Yallese MA, Bensouilah H, Khellaf A, Elbah M. Prediction of surface roughness and cutting forces using RSM, ANN, and NSGA-II in finish turning of AISI 4140 hardened steel with mixed ceramic tool, The International Journal of Advanced Manufacturing Technology. 2018;97:1931-49. doi: 10.1007/s00170-018-2026-6
- [11] Sekulic M, Pejic V, Brezocnik M, Gostimirović M, Hadzistevic M. Prediction of surface roughness in the ball-end milling process using response surface methodology, genetic algorithms, and grey wolf optimizer algorithm, Advances in Production Engineering & Management. 2018;13(1):18-30. doi: 10.14743/apem2018.1.270

- [12] Dweiri F, Al-Jarrah M, Al-Wedyan H. Fuzzy surface roughness modeling of CNC down milling of Alomic-79, *Journal of Materials Processing Technology*. 2003;133(3):266-75. doi: [10.1016/S0924-0136\(02\)00847-6](https://doi.org/10.1016/S0924-0136(02)00847-6)
- [13] Ho WH, Tsai JT, Lin BT, Chou JH. Adaptive network-based fuzzy inference system for prediction of surface roughness in end milling process using hybrid Taguchi-genetic learning algorithm, *Expert Systems with applications*. 2009;36(2):3216-22. doi: [10.1016/j.eswa.2008.01.051](https://doi.org/10.1016/j.eswa.2008.01.051)
- [14] Harsha N, Kumar IA, Raju KSR, Rajesh S. Prediction of Machinability characteristics of Ti6Al4V alloy using Neural Networks and Neuro-Fuzzy techniques, *Materials Today, Proceedings*. 2018;5(2):8454-63. doi: [10.1016/j.matpr.2017.11.541](https://doi.org/10.1016/j.matpr.2017.11.541)
- [15] Sharkawy AB, El-Sharief MA, Soliman ME. Surface roughness prediction in end milling process using intelligent systems, *International journal of machine learning and cybernetics*. 2014;5:135-50. doi: [10.1007/s13042-013-0155-7](https://doi.org/10.1007/s13042-013-0155-7)
- [16] Kumanan S, Jesuthanam C.P, Ashok Kumar R. Application of multiple regression and adaptive neuro fuzzy inference system for the prediction of surface roughness, *The International Journal of Advanced Manufacturing Technology*. 2008;35:778-88. doi: [10.1007/s00170-006-0755-4](https://doi.org/10.1007/s00170-006-0755-4)
- [17] Asadi R, Yeganefar A, Niknam SA. Optimization and prediction of surface quality and cutting forces in the milling of aluminum alloys using ANFIS and interval type 2 neuro fuzzy network coupled with population-based meta-heuristic learning methods, *The International Journal of Advanced Manufacturing Technology*. 2019;105:2271-87. doi: [10.1007/s00170-019-04309-6](https://doi.org/10.1007/s00170-019-04309-6)
- [18] Seising R. fuzzy sets and systems. In *Computer Aided Systems Theory–EUROCAST 2019, 17th International Conference, Las Palmas de Gran Canaria, Spain. 2020; Part I 17 (101-108)*. doi: [10.1007/978-3-030-45093-9](https://doi.org/10.1007/978-3-030-45093-9)