

مدل سازی و بهینه سازی فرایند EDM با استفاده از ANFIS و CBGA

مجتبی حکیمی مقدم^۱, محمد رضا اکبرزاده توتونچی^۲
mojtaba_hakimi@yahoo.com

چکیده

ماشینکاری تخلیه الکتریکی بعنوان یک فرآیند ماشینکاری غیرسنتی شناخته می شود که در آن هیچ نیرویی بین ابزار و قطعه کار در حین ماشینکاری ایجاد نمی شود. در این فرآیند، براده برداری با دقت بسیار بالا و بر مبنای حرارت ناشی از کانالهای جرقه صورت می گیرد و ضمن اینکه قطعه باید از صافی سطح مناسب برخوردار شود. مطلوب است که زمان براده برداری تا حد امکان کوتاه گردد. در این مقاله، از سیستم استنتاج نور-فازی تطبیقی (ANFIS) بعنوان رگرسور غیرخطی برای مدل سازی نگاهت بین ورودیها و خروجی های فرآیند استفاده شده است و سپس الگوریتم ژنتیک مقید (CBGA) برای بهینه سازی نرخ براده برداری (MRR)، با قید عدم تجاوز متوسط ناصافی سطح (Ra) از یک مقدار از پیش تعیین شده، مورد استفاده قرار گرفته است. داده های ورودی-خروجی با انجام آزمایشهای مختلف به کمک دستگاه اسپارک پیشتازان حاصل شده است.

کلمات کلیدی: فرآیند ماشینکاری تخلیه الکتریکی (EDM)، مدل سازی با ANFIS، بهینه سازی با CBGA

۱- مقدمه

ماشینکاری سنتی پر هزینه بوده و بسیاری از خواص مفید قطعه از جمله استحکام آنرا مخدوش می کند. داشتن سرعت براده برداری مناسب و کمینه کردن زیان وارد بر خواص مواد در حین ماشینکاری، همچنین پیچیدگی کار شکل دهی سطح و قالب و نیاز به ماشینکاری مینیاتوری با دقت در حد میکرو یا نانو از جمله عوامل عمده در توسعه انواع پیشرفته فرآیندهای ماشینکاری بوده اند. این فرآیندها از ابزارها و شکل‌های جدید انرژی (مکانیکی، شیمیایی، الکتروشیمیایی و یا حرارتی) استفاده می کنند، از جمله فرآیند EDM را می توان نام برد که مبتنی بر انرژی حرارتی است [۱].

ماشینکاری تخلیه الکتریکی به عنوان یک فرآیند ماشینکاری غیرسنتی شناخته می شود، که در آن هیچ نیرویی بین ابزار و قطعه کار در حین ماشینکاری ایجاد نمی شود. مکانیزم براده برداری در این فرآیند توسط یک سری جرقه های الکتریکی متوالی میان ابزار و قطعه کار در یک محیط مایع دی الکتریک صورت می گیرد. نظریه های بنیادین پیشنهاد کرده اند که مکانیزم براده برداری بر پایه پدیده پیچیده هدایت حرارتی صورت می گیرد. تحقیقاتی در زمینه فرآیند تک جرقه صورت گرفته و به صورت های مختلف مدل سازی شده است. اما نتایج آنها قابلیت تعمیم به حالت چند جرقه، که حالت واقعی ماشینکاری تخلیه الکتریکی است، را ندارند و تلاشها در این راستا همچنان ادامه دارد. دلیل این امر یکسان نبودن اثر ناشی از

^۱ - دانشجوی کارشناسی ارشد برق-کنترل، دانشگاه فردوسی مشهد

^۲ - استادیار گروه برق، دانشگاه فردوسی مشهد، akbazar@yahoo.com

هر جرقه می باشد، بطوریکه حفره های کوچک حاصل از دو تخلیه الکتریکی متوالی با هم همپوشانی داشته و توزیع جرقه ها در فضای اندک میان الکتروود و قطعه کار، بصورت اتفاقی است [۲ و ۳ و ۴].

ماشینکاری فولادهای با استحکام بالا، کاربردهای تنگستن و فولادهای آلیاژی سخت شده، که در ساخت ابزارهای برش، قالبها و دیگر قطعات دقیق صنعتی کاربرد دارند، با روشهای ماشینکاری سنتی بسیار مشکل است. در این فرآیند، با توجه به سختی قطعات، ماشینکاری آنها مستلزم صرف زمان زیادی است و این امر منجر به تلاشهای زیادی برای تعیین پارامترهای ورودی دستگاه شده است، بطوریکه ضمن برآورده کردن صافی سطح مطلوب قطعه، زمان براده برداری را تا حد امکان کوتاه گرداند. در واقع با یک مسأله برنامه ریزی مقید غیرخطی مواجه هستیم که در آن هدف انتخاب بهینه مقادیر پارامترهای ورودی است، بطوریکه صافی سطح مطلوب قطعه، بعنوان قید برآورده شود و نرخ براده برداری بعنوان تابع هدف بیشترین مقدار ممکن را داشته باشد.

در دهه اخیر شبکه های عصبی بطور وسیعی در مدل سازی فرآیندهای ماشینکاری مورد استفاده قرار گرفته اند، با این حال هر نوع از شبکه های عصبی دارای مشخصه ورودی-خروجی خاصی است، که آنرا برای مدل سازی برخی از نگاشتها بهینه می سازد. در مقابل ساختارهای فازی دارای توابع تعلق، عملگرهای فازی و قواعد اگر-آنگاه فازی بوده و توانایی کار با داده های کمی و کیفی را دارا می باشند. این دو ساختار دارای مزایایی نسبت به یکدیگر هستند، مزیت عمده شبکه عصبی توانایی یادگیری و تطبیق است و مزیت عمده ساختار فازی توانایی استفاده از متغیرهای زبانی و برخورد مستقل با هر متغیر ورودی است. ANFIS در سال ۱۹۹۳ بعنوان یک روش کارا که مزایای هر دو ساختار فوق را داراست، برای حل نگاشتهای غیرخطی پیچیده معرفی شد [۵].

در [۶] از شبکه عصبی MLP برای شناسایی حین کار^۱ و دسته بندی انواع پالس ها و نیز کنترل فرآیند EDM استفاده شده است. همچنین مدل سازی فرآیند EDM با حرکت چرخشی الکتروود در [۷] صورت گرفته و نشان داده شده که نتایج حاصل از مدل سازی با شبکه عصبی در مقایسه با روشهای رگرسیون چندگانه از دقت بیشتری برخوردارند. در [۸] مدل سازی و بهینه سازی فرآیند AFM^۲ توسط شبکه عصبی انجام گرفته و با نتایج حاصل از اعمال الگوریتم ژنتیک بر مدل ارائه شده برای این فرآیند در [۹] مورد تأیید قرار گرفته است. در [۱۹] مدل سازی فرآیند EDM با استفاده از شبکه عصبی انجام گرفته است و در [۲۰] این مدل در بهینه سازی فرآیند EDM مورد استفاده قرار گرفته است. در [۱۰] نشان داده شده است که ساختارهای مختلف عصبی و ساختار ANFIS در پیش بینی پایان پرداخت سطح در فرآیند EDM از دقت کافی برخوردارند، ولی نرخ همگرایی در ANFIS بهتر است. در [۱۱] نشان داده شده است که ANFIS در مقایسه با ساختارهای مختلف عصبی از دقت بیشتر و سرعت همگرایی بالاتر برخوردار است؛ همچنین نگارندگان [۱۱]، بر اساس تجربیاتشان، ادعا کرده اند که ساختار ANFIS تنها در مواردی که تعداد متغیرهای ورودی از هفت کمتر است، کارآیی دارد. در [۱۲] نیز از ANFIS برای مدل سازی متوسط ناصافی سطح در دستگاه CNC استفاده شده است.


هدف از این مقاله، مدل سازی نرخ براده برداری (MRR^۳) و ناصافی سطح (Ra^۴) در فرایند EDM، به کمک ANFIS و نشان دادن برتری آن بر شبکه عصبی MLP [۱۹] و سپس استفاده از الگوریتم ژنتیک مقید برای انتخاب بهینه شرایط ماشینکاری با توجه به این مدل است. حداکثر ناصافی سطح قابل قبول برای هر قطعه را با R_{max} نشان می دهیم؛ مرحله بهینه سازی برای هر قطعه با R_{max} متفاوت باید تکرار گردد. شکل (۱) این روند را نشان می دهد. در ادامه، در بخش دوم مدل سازی فرآیند، مورد مطالعه قرار می گیرد. در بخش سوم بهینه سازی فرآیند تشریح می شود و در بخش چهارم نتایج حاصل از شبیه سازیها ارائه می شود. و در بخش پنجم جمع بندی و نتایج آورده شده است.

1- on line

2- Abrasive Flow Machining (AFM)

3- Material Removal Rate (MRR)

4- Roughness Average (Ra)



شکل (۱): روند مدل‌سازی و بهینه‌سازی فرآیند

۲- مدل‌سازی فرآیند EDM

داده‌های آموزش از انجام آزمایشات مختلف روی دستگاه اسپارک پیشتازان (SP120A) حاصل شده است. با توجه به مشخصات دستگاه، جریان، ولتاژ و پریود پالس‌ها به عنوان متغیرهای کنترلی فرآیند و نرخ براده برداری و ناصافی سطح به عنوان پارامترهای ارزیابی آن در نظر گرفته شده‌اند. دامنه تغییرات پارامترهای ورودی عبارت است از: $50 \mu\text{sec} \leq t \leq 500 \mu\text{sec}$; $2 A \leq i \leq 17 A$; $35 V \leq v \leq 70 V$ سطح مختلف از جریان (۲ و ۵ و ۸ و ۱۱ و ۱۴ و ۱۷ آمپر)، ۴ سطح از ولتاژ (۳۵ و ۵۰ و ۶۰ و ۷۰ ولت) و نیز ۴ سطح از پریود پالس‌ها (۵۰ و ۱۰۰ و ۲۰۰ و ۵۰۰ میکرو ثانیه) صورت گرفته است. دامنه تغییرات پارامترهای خروجی بر اساس آزمایشات انجام شده عبارت است از: $0.12 \text{ gr/h} \leq MRR \leq 30.72 \text{ gr/h}$; $1.02 \mu\text{m} \leq Ra \leq 7.87 \mu\text{m}$ ، بنابراین تعداد کل داده‌های آموزش ۹۶ عدد خواهد بود. قطعه کار از جنس فولاد ۲۰۸۰ بوده که قبلاً با انجام عملیات حرارتی تا حدود 58RC سخت شده است. جنس الکتروود نیز از مس معمولی انتخاب شده است. در کلیه موارد قطر الکتروود و قطعه کار برابر بوده و آزمایشات همگی در حالت تراشیدن سطح صورت گرفته‌اند. زمان در نظر گرفته شده برای انجام آزمایشات با توجه به میزان جریان در هر آزمایش متفاوت بوده و مدت زمان بیشتری به آزمایشات با جریان پایین‌تر اختصاص داده شده است. جرم قطعات کار قبل و بعد از هر مرحله از آزمایش با دقت یک صدم گرم اندازه‌گیری شده است و با توجه به میزان تغییر جرم و زمان صرف شده برای انجام براده برداری، نرخ براده برداری محاسبه شده است. ناصافی سطح نیز به کمک زبری سنج اندازه‌گیری شده است.

۲-۱- ساختار ANFIS

این ساختار در سال ۱۹۹۳ بعنوان یک روش کارا که مزایای هر دو نوع ساختار عصبی و فازی را داراست معرفی شد. همانطور که در شکل (۲) آمده است، ساختار نوروفازی مزایای اصلی شبکه‌های عصبی، یعنی پردازش موازی و توانایی یادگیری نگاشته‌های غیر خطی از روی داده‌های عددی و نیز مزیت عمده ساختارهای فازی، یعنی قابلیت پردازش داده‌های زبانی را داراست. می‌دانیم دانش در وزنه‌های شبکه عصبی پخش می‌شود و درک دانش موجود در وزنه‌ها بی‌معنی است، در حالیکه منطق فازی از قواعد زبانی قابل درک برای بیان دانش سیستم استفاده می‌نماید [۱۳].

شکل (۳) ساختار ANFIS را نشان می‌دهد، توضیح مختصری در مورد هر لایه آورده شده است:


لایه اول: پارامترهای این لایه به پارامترهای بخش مقدم موسوم هستند و خروجی آن مقادیر توابع تعلق بخش مقدم است.

لایه دوم: خروجی هر گره در این لایه مبین میزان آتش شدن یک قاعده است.

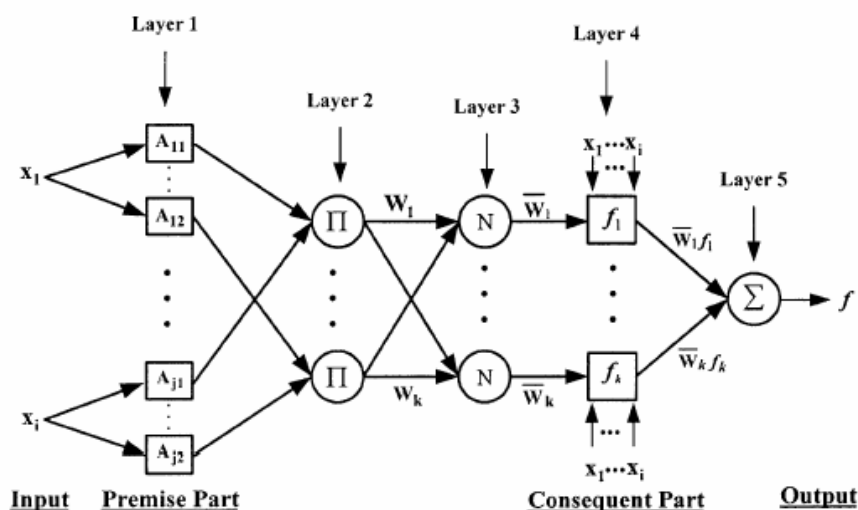
لایه سوم: خروجی این لایه موسوم به میزان آتش شدن نرمالیزه شده است.

لایه چهارم: خروجی این لایه ترکیب خطی داده‌های ورودی است و پارامترهای آن به پارامترهای بخش تالی موسوم است.

لایه پنجم: این لایه تک‌گره بوده و خروجی آن برابر مجموع خروجی‌های لایه قبل است



شکل ۲- مقایسه مزایای ساختارهای عصبی، فازی و نورو فازی [۱۳].



شکل ۳- ساختار ANFIS [۱۱].

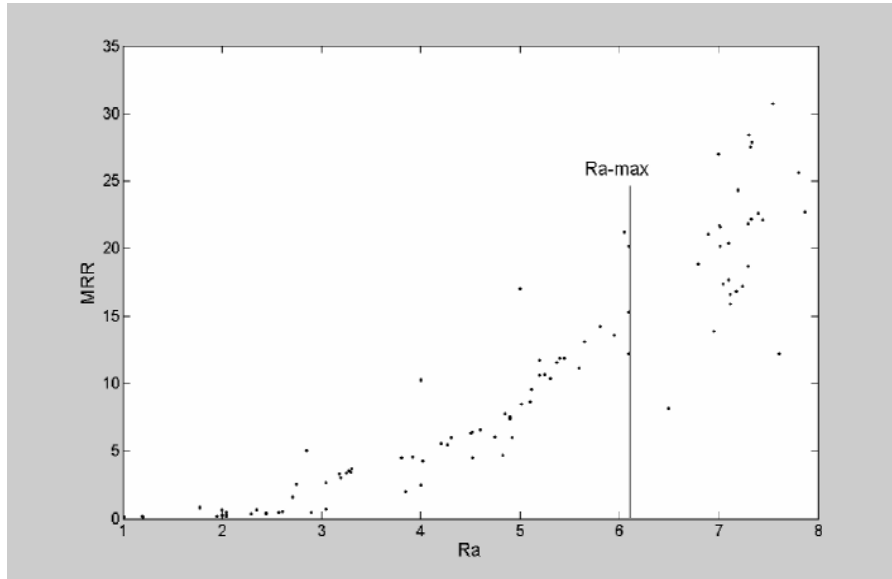
۳- طرح مسأله بهینه سازی فرآیند EDM

ماشینکاری آخرین مرحله در فرآیند تولید قطعات است، که باید صافی سطح مطلوب آنها را فراهم آورد. در فرآیند ماشینکاری تخلیه الکتریکی، ضمن اینکه قطعه باید از صافی سطح مناسبی برخوردار باشد، مطلوب است که زمان براده برداری تا حد امکان کوتاه شود، لازم به ذکر است که زمان براده برداری در این فرآیند گاه ممکن است ساعتها بطول انجامد. بنابراین با یک مسأله برنامه ریزی مقید غیرخطی^۱ مواجه هستیم که در آن هدف انتخاب بهینه مقادیر پارامترهای ورودی است، بطوریکه صافی سطح مطلوب بعنوان قید برآورده شود و نرخ براده برداری بعنوان تابع هدف بیشترین مقدار ممکن را داشته باشد.

^۱ - Nonlinear Constrained Programming

ساختار استاندارد بهینه‌سازی فرآیند EDM در رابطه (۲) آمده است که در آن پارامتر طراحی بوده و معلوم می‌باشد و هدف از بهینه‌سازی تعیین X_{opt} یا شرایط ورودی بهینه است.

$$\begin{aligned} & \text{Minimize } f(\mathbf{X}) = -MRR(\mathbf{X}) \\ & \text{St: } C(\mathbf{X}) = (Ra(\mathbf{X}) - Ra_{\max}) \leq 0 \\ & x_{i,\min} \leq x_i \leq x_{i,\max} \quad ; \quad i = 1, 2, 3 \end{aligned} \quad (2)$$



شکل ۴- فعال بودن قید و وجود پاسخهای بهینه محلی

شکل (۴)، نرخ براده برداری (MRR) را بر حسب میزان ناصافی سطح (Ra)، برای داده‌های حاصل از آزمایشات عملی نشان می‌دهد. با توجه به فیزیک فرآیند، منطقی به نظر می‌رسد که، افزایش نرخ براده برداری با افزایش ناصافی سطح همراه باشد. شکل (۴) نیز موید این واقعیت است، بنابراین قید همواره فعال بوده و محدود کننده نرخ براده برداری است. همچنین این شکل نشان می‌دهد که مسأله برای هر مقدار Ra_{\max} ، می‌تواند دارای چندین پاسخ بهینه محلی باشد.

۱-۳- الگوریتم ژنتیک (GA)

مفاهیم اولیه الگوریتمهای ژنتیک اولین بار در سال ۱۹۷۵ توسط Holland معرفی شد [۱۴]. تلاشهای وی سپس توسط Goldberg ادامه پیدا کرد و مفاهیم آن توسعه یافت. وی نشان داد که GA یک الگوریتم ساده بهینه‌سازی است که مستقل از

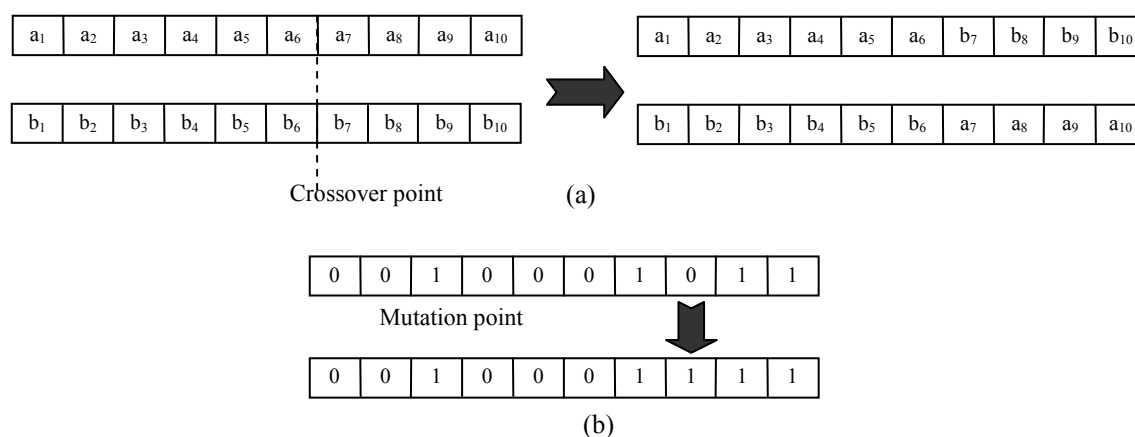
- 1- Genetic Algorithm
- 2- Survival of the fittest

- 4- Individual
- 5- Generation

محدودیت‌های مسأله می‌تواند نسبت به حل مسأله اقدام کند [۱۵]. مبنای این الگوریتم تکامل ژنهای طبیعی بر اثر مرور زمان و بقای کاملترینها است. این الگوریتم نیازی به محاسبه شیب و یا مفروضاتی همچون پیوستگی فضای جستجو و یا مشتق پذیر بودن مسأله ندارد زیرا که اساس کار آن اطلاعات ژنی و قانون بقای کاملترین فرد^۲ است.

وقتی GA بعنوان ابزار حل مسأله بکار گرفته می‌شود، لازم است روشی برای کد کردن مجموعه پارامترهای سیستم به رشته‌های ژنی^۳ شناسایی شود. این رشته‌های ژنی که از آنها بعنوان فرد^۴ نام برده می‌شود در ابتدای مسأله بصورت تصادفی تولید می‌شوند که هر کدام می‌توانند بخشی از جواب را با خود به همراه داشته باشند. مجموعه این رشته‌ها یک نسل^۵ را تشکیل می‌دهند. با اعمال عملگرهای GA که سعی در تقلید رفتار طبیعی ژنها در طبیعت دارند، نسلها یکی پس از دیگری تکامل می‌یابند. نسل جدید در حقیقت فرزندان برگزیده نسلهای قبلی هستند، بطوریکه عملگرهای GA به رشته‌های با ارزشتر، شانس بیشتری برای انتقال از یک نسل به نسل بعد را می‌دهند.

عملگرهای پایه ای GA/انتخاب^۱، ترکیب^۲ و جهش^۳ می‌باشند. طی عمل انتخاب، افرادی که مقدار ارزش بالاتری داشته باشند با احتمال بیشتری انتخاب می‌شوند و سپس تحت عمل ترکیب اطلاعات افراد مبادله می‌شود. سپس طی عمل جهش



شکل ۵- عملگرهای الگوریتم ژنتیک. (a) عملگر برش. (b) عملگر جهش.

افراد به صورت آماری دستخوش تغییرات می‌شوند، به این امید که مجموعه جدیدی از جوابها تولید شوند و GA را از همگرایی زود هنگام (نقطه بهینه محلی) برهاند. نحوه عمل ترکیب و جهش در شکل (۵) نشان داده شده است.

۱-۱-۳- بهینه سازی سیستمهای مقید با استفاده از GA

عمده ترین کار GA در بهینه سازی، ماکزیمم سازی یک تابع با نام تابع برازندگی^۴ است. در عمل اغلب مسائل بهینه سازی باید یک سری قیود را نیز برآورده نمایند. مشکلی که GA در بهینه سازی مسائل مقید با آن مواجه است، این است که قسمت عمده ای از کروموزومها، قیود را نقض می‌کنند، که این از عملکرد عملگرهای آن ناشی می‌شود. یک راه برای مقابله با این مسأله حذف کروموزومهایی از این دسته است، که باعث از بین رفتن بخش عمده ای از اطلاعات می‌شود و سرعت همگرایی را کاهش می‌دهد. روش دوم تصحیح عملگرها به گونه ای است که از تولید کروموزومهای نامطلوب خودداری کنند و

3- Gene string

- 1- Selection
- 2- Crossover
- 3- Mutation
- 4- fitness function

روش سوم، افزودن عملگر جدیدی است که این تضاد را برطرف نماید؛ این روش نیز به شدت وابسته به صورت مسأله است و پیاده‌سازی آن بسیار پیچیده است. روش چهارم، افزودن یک جمله اضافی در تابع برازندگی است، که به آن تابع جریمه می‌گویند. این روش با الهام از روشهای کلاسیک سعی در تبدیل مسأله مقید به یک مسأله نامقید را دارد، به این ترتیب که با اصلاحاتی در تابع برازندگی کروموزومهایی که شرط مربوط به قید را نقض می‌کنند دارای ارزش کمتری می‌شوند [۱۶] و [۱۷] و [۱۸].

در اینجا از روش چهارم استفاده شده و تابع برازندگی بصورت رابطه (۳) اصلاح شده است که در آن β, α پارامترهای تابع جریمه بوده و میزان تأثیر و اهمیت قید در بهینه‌سازی را مشخص می‌کنند. انتخاب مناسب این دو پارامتر در هر مسأله بهینه‌سازی، به رفتار توابع هزینه و قید وابسته بوده و نیاز به سعی و خطا و تجربه دارد، همچنین سرعت همگرایی الگوریتم ژنتیک به انتخاب مناسب مقادیر β, α وابسته است، بطوریکه گاه انتخاب نامناسب این مقادیر ممکن است منجر به پاسخهایی شود که قید را نقض می‌کنند. بدیهی است که انتخابها به $\beta < 0, \alpha > 0$ محدود می‌گردد.

$$fitness = fit_{prime} + penalty = MRR(\mathbf{X}) + penalty$$

$$penalty = \begin{cases} 0 & Ra(\mathbf{X}) \leq Ra_{max} \\ \beta \times (Ra(\mathbf{X}) - Ra_{max})^\alpha & Ra(\mathbf{X}) > Ra_{max} \end{cases} \quad (3)$$

۴- شبیه‌سازی

نتایج شبیه‌سازی در دو بخش ارائه می‌شود: بخش اول مدل‌سازی فرآیند و بخش دوم بهینه‌سازی آن.

۴-۱- مدل‌سازی

تمامی داده‌های ورودی-خروجی به بازه [۰,۹ ۰,۱] نگاشته شده‌اند. در ساختار ANFIS خروجی را از نوع سوگنو درجه صفر در نظر گرفته ایم و با توجه به اینکه آزمایشات در ۶ سطح مختلف از جریان، ۴ سطح از ولتاژ و ۴ سطح از پریود پالس‌ها صورت گرفته است، سه تابع تعلق گوسی برای جریان، دو تابع تعلق گوسی برای ولتاژ و دو تابع تعلق گوسی برای پریود در نظر گرفته ایم. به این ترتیب ۲۶ پارامتر برای مدل‌سازی هر کدام از خروجیها اختصاص یافته است. در ساختار عصبی، تعداد نرونهای لایه میانی برابر $n = 5$ در نظر گرفته شده است؛ بنابراین بطور مشابه، شبکه عصبی بکار رفته برای هر کدام از خروجیها، دارای ۲۶ پارامتر قابل تنظیم خواهد بود. به علت کم بودن تعداد کل داده‌های حاصل از آزمایشات عملی، تمامی داده‌ها، در آموزش بکار گرفته شده‌اند.

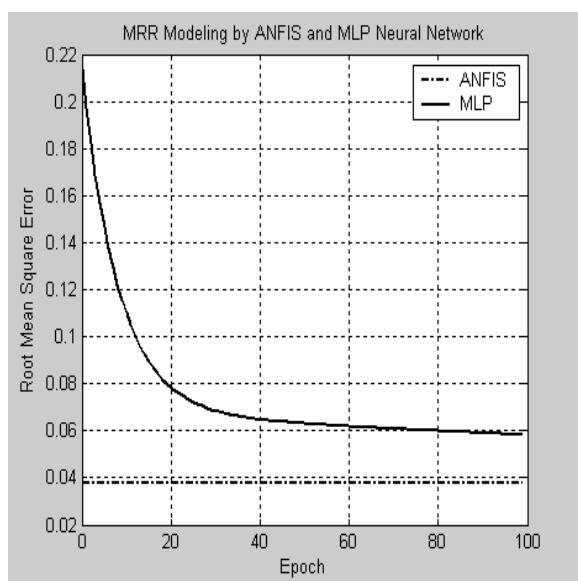
نرخ همگرایی در شکل (۶) نشان داده شده است، در ساختار عصبی خطای اولیه معمولاً بسیار بزرگتر از معادل ANFIS است و این ناشی برخورد یکسان شبکه عصبی با متغیرهای ورودی است زیرا تمامی متغیرهای ورودی به نرون‌های لایه میانی اتصال دارند.

۴-۲- بهینه‌سازی با الگوریتم ژنتیک مقید

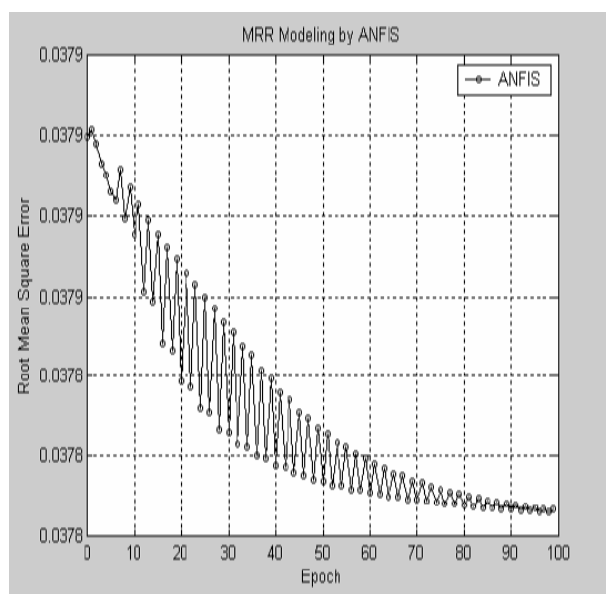
همانطور که گفته شد، هدف از بهینه‌سازی این فرآیند؛ تعیین پارامترهای ورودی بگونه‌ای است که ضمن حفظ صافی سطح، نرخ براده برداری تا حد امکان افزایش یابد. نشان دادیم که قید فعال و مسأله دارای پاسخ‌های بهینه محلی است؛ در ادامه نتایج بهینه‌سازی الگوریتم ژنتیک مقید را ارائه می‌دهیم.

سرعت همگرایی پاسخ GA بشدت به انتخاب مناسب مقادیر β, α در رابطه (۳) وابسته است، حتی گاه انتخاب نامناسب این مقادیر ممکن است منجر به جوابهایی شود که قید را نقض می‌کنند. در شبیه‌سازی‌ها مقدار احتمال ترکیب و احتمال

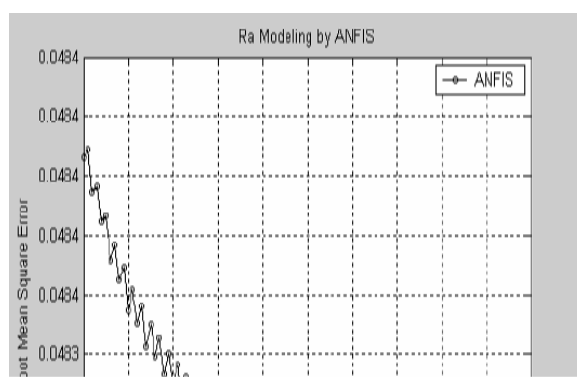
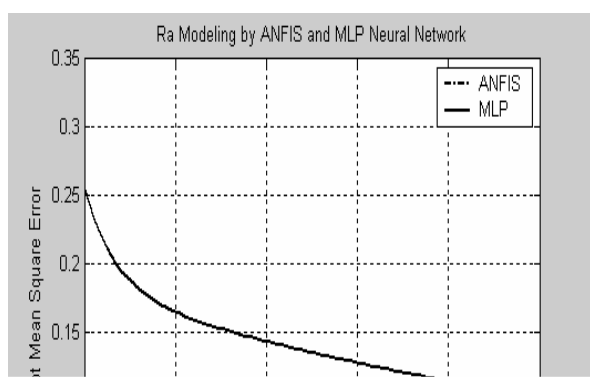
جهش به ترتیب برابر $P_c = 0.7$, $P_m = 0.01$ در نظر گرفته شده است. اطلاع از روند تغییر و رفتار توابع هزینه و قید نیز می تواند برای انتخاب مناسب این مقادیر مورد استفاده قرار گیرد. نمودار تابع برازندگی برای سه حالت الف) $\alpha = 1$, $\beta = -1000$; ب) $\alpha = 2$, $\beta = -80$; ج) $\alpha = 2$, $\beta = -200$ به ترتیب در شکل‌های (۷) و (۸) و (۹) آورده شده است. پارامتر G در هر مرحله، تعداد نسل را نشان می دهد. بدیهی است به ازای $\alpha = 1$ که میزان جریمه برابر مضرری از مقدار نقض قید است، سرعت همگرایی کمتر از مقدار $\alpha = 2$ است، ولی احتمال نقض قید در حالت $\alpha = 2$ بیشتر است، زیرا نقض قید کوچکتر از واحد است و میزان جریمه تضعیف می شود. برای داشتن سرعت همگرایی بالا و کاهش احتمال نقض قید، از حالت (ج) استفاده شده است. نتایج حاصل از بهینه سازی به روش GA با α ی متغیر در جدول (۱) آمده است.



(a)



(b)



(c)

(d)




شکل ۶- مقایسه خطای مدل‌سازی در ANFIS و شبکه عصبی MLP:

(a,b) مدل‌سازی نرخ براده برداری (MRR)

(c,d) مدل‌سازی متوسط نا صافی سطح (Ra)

۵- نتیجه گیری

ماشینکاری آخرین مرحله در فرایند تولید یک قطعه است که باید صافی سطح مطلوب قطعه را فراهم آورد. در فرآیند EDM جریان، ولتاژ و پریود پالس ها به عنوان سیگنالهای کنترل ورودی و نرخ براده برداری و ناصافی سطح خروجی های آن می باشند. در این تحقیق فرآیند EDM به کمک ANFIS با دقت مناسبی مدل شد و سپس این مدل در بهینه سازی فرآیند مورد استفاده قرار گرفت. از مزایای ANFIS می توان به سرعت بالای همگرایی آن و نیز توانایی برخورد مستقل با متغیرهای ورودی در مقایسه با شبکه عصبی اشاره نمود.

شکل (۹): $\alpha = 2 - 0.001 \times G$, $\beta = -200$ شکل (۸): $\alpha = 2$, $\beta = -80$ شکل (۷): $\alpha = 1$, $\beta = -1000$

جدول (۱): نتایج بهینه سازی با الگوریتم ژنتیک مقید

| قید | I_{opt} | V_{opt} | $T_{opt} (\mu\text{sec})$ | $Ra_{opt} (\mu\text{m})$ | $MRR_{opt} (\text{gr} / \text{hr})$ |
|-------------------|-----------|-----------|---------------------------|--------------------------|-------------------------------------|
| $Ra_{\max} = 2.4$ | 4.01 | 46.43 | 398 | 2.4 | 3.11 |
| $Ra_{\max} = 3.7$ | 6.50 | 43.28 | 374 | 3.7 | 6.32 |
| $Ra_{\max} = 4.5$ | 7.81 | 35 | 50 | 4.5 | 9.81 |
| $Ra_{\max} = 5.3$ | 10.93 | 35 | 50 | 5.3 | 17.41 |

مراجع

- [1] Neelesh K. Jain, Vijay K. Jain, "Modeling of material removal in mechanical type advanced machining processes: a state-of-art review", Pergamon, Int. Jou. Machine Tools & Manufacture 41 (2001) 1573-1635.
- [2] J.A. McGeough, "Advanced Methods of Machining" Chapman & Hall, New York, 1988.
- [3] P. Madhu, V.K. Jain, T. Sundarajan and K.P. Rajurkar, "Finite element analysis of EMD process" Processing of Advanced Materials, 1 pp. 161-173, 1991.
- [4] A. Singh and A. Ghosh, "A thermo-electric model of material removal during electrical discharge machining" Int. J. Mach. Tools Manufact. 39, pp. 669-682, 1999.
- [5] J.S.R. Jang, ANFIS: Adaptive-Network-Based Fuzzy Inference System, IEEE Trans. Syst. Man Cyb. 23 (1993) 665-685.
- [6] J.Y. Kao and Y.S. Tarn, "A neural network approach for the on-line monitoring of the electrical discharge machining process" J. Mater. Proc. Tech., 69 pp. 112-119, 1997.
- [7] G. Indurkha and K.P. Rajurkar, "Artificial neural network approach in modeling of EMD process", in: Proc. Artificial neural network in engineering (ANNIE 92) conf., USA, November, pp. 845-850, 1992.
- [8] R. K. Jain, V. K. Jain, "Optimum selection of machining conditions in abrasive flow machining using neural network", J. Mate. Proc. Tech, Elsevier Science, 108 pp. 62-67, 2000.
- [9] V. K. Jain, S. G. Adsul, "Experimental investigations into abrasive flow machining", Int. J. Mech. Tool. Manuf, 40 pp. 1003-1021, 2000.
- [10] Kuo-Ming Tsai, Pei-Jen Wang, "Predictions on surface finish in electrical discharge machining based upon neural network models," Pergamon, Int. Jou. Machine Tools & Manufacture 41 (2001) 1385-1403.
- [11] Kuo-Ming Tsai, Pei-Jen Wang, "Comparisons of neural network models on material removal rate in electrical discharge machining," Jou. Materials Processing Technology, elsevier, 117 (2001), 111-124.
- [12] F. Dweiri, M. Al-Jarrah, H. Al-Wedyan, "Fuzzy Surface roughness modeling of CNC down milling of Allumic-79," Jou. Materials Processing Technology, elsevier, 133(2003) 266-275.
- [13] T. Ojala, "Neuro-Fuzzy Systems in Control," Msc. Thesis, Tampere Uni. Dep. Elec. Eng. www.ecst.csuchico.edu/~juliano/csci397/FuzzyLogic/
- [14] J. H. Holland, "Adaptation in natural and artificial systems.", Ann Arbor, MI University of Michigan Press 1975.
- [15] D. E. Goldberg, "The genetic algorithms in search, optimization, and machine learning.", New York: Addison-Wesley, 1989.
- [16] Z. Michalewicz, "Genetic Algorithms + Data Structure = Evolution Program", Springer-Verlag, AI series, New York, 1992.
- [17] J. A. Joins, C. R. Houck, "On the use of non-stationary penalty function to solve nonlinear constrained optimization problems with GA's", IEEE, 1994.
- [18] J. Richardson, M. Palmer, G. Liepins, M. Hilliard, "Some guidelines for genetic algorithms with penalty function", Proc. of the third Int. Conf. on Genetic Algorithm, 1989.
- [۱۹] حکیمی مقدم مجتبی؛ عصارزاده سعید؛ روحانی سید مجتبی؛ "مدل سازی و بهینه سازی فرآیند EDM بخش اول: مدل سازی با استفاده از شبکه عصبی؛ پنجمین کنفرانس سیستمهای هوشمند؛ مشهد، ایران، پائیز ۱۳۸۲.
- [۲۰] حکیمی مقدم مجتبی؛ اکرمی زاده علی؛ رجبی مشهدی حبیب؛ "مدل سازی و بهینه سازی فرآیند EDM بخش دوم: بهینه سازی با استفاده از روش لاگراتژ و الگوریتم ژنتیک مقید؛ پنجمین کنفرانس سیستمهای هوشمند؛ مشهد، ایران، پائیز ۱۳۸۲.