

## ارائه مدل شبکه عصبی از موتور دیزل پاشش مستقیم جهت بهینه‌سازی آلاینده‌گی و عملکرد به صورت همزمان با استفاده از الگوریتم ژنتیک

محمد حسن بهروزی

دانشگاه علم و صنعت ایران  
[mbehroozi718@gmail.com](mailto:mbehroozi718@gmail.com)

امیرحسین شامخی

دانشگاه صنعتی خواجه نصیرالدین طوسی  
[shamekhi@kntu.ac.ir](mailto:shamekhi@kntu.ac.ir)

سیداحسان صمدانی

دانشگاه صنعتی خواجه نصیرالدین طوسی  
[e\\_samadani@sina.kntu.ac.ir](mailto:e_samadani@sina.kntu.ac.ir)

رضا چینی

دانشگاه صنعتی خواجه نصیرالدین طوسی  
[r\\_chini@sina.kntu.ac.ir](mailto:r_chini@sina.kntu.ac.ir)

### چکیده

امروزه یکی از ضروریات در طراحی موتورهای دیزل ارائه روشهایی است که بطور همزمان مقادیر کم آلاینده‌ها (NOx-SOOT) و مصرف بهینه سوخت را به دنبال داشته باشد. بدین منظور از روش بهینه‌سازی چندمنظوره - که در آن چند پارامتر هدف به طور همزمان ماکزیمم یا مینیمم می‌شوند- استفاده می‌شود. در این مقاله مدل احتراقی دو ناحیه‌ای از یک موتور دیزل پاشش مستقیم توسعه و صحت‌گذاری شده است. هدف یافتن نقاط کاری از موتور است که در آن نقاط آلاینده‌ها مینیمم و گشتاور خالص موتور ماکزیمم باشد. پارامترهای زمان پاشش و مدت زمان پاشش و نسبت هوا به سوخت به عنوان متغیرهای طراحی انتخاب شده است. یک مدل شبکه عصبی از موتور به عنوان جایگزینی برای مدل احتراقی ارائه شده است که بر مبنای این مدل و با استفاده از الگوریتم ژنتیک مقدار بهینه آلاینده‌ها و گشتاور خالص تولیدی در یک سیکل بسته در دور و باری مشخص تعیین می‌شود.

**واژه‌های کلیدی:** NOx، SOOT، Imep، الگوریتم ژنتیک، بهینه‌سازی، دیزل، شبکه عصبی.

### مقدمه

نگرانی جامعه بین‌الملل در زمینه حفظ محیط زیست و به موازات آن مساله کاهش هر روزه منابع فسیلی و خطر اتمام این منابع، اهمیت توسعه موتورهایی با آلاینده‌گی کم و راندمان بالا را دوچندان نموده است. آزمایشهایی که در این زمینه صورت می‌گیرد، معمولاً مستلزم صرف هزینه و زمان زیادی است که به طور قطع یک جایگزین مناسب برای این آزمایش‌ها استفاده از مدل‌های ریاضی و شبیه‌سازی کامپیوتری عملکرد موتور است [۱]. فرآیند احتراق در موتور دیزل بسیار پیچیده و دارای ماهیتی گذرا و غیرهمگن است. تاکنون مدل‌های گوناگونی برای احتراق در موتور دیزل ارائه شده است که در میان این مدل‌ها، مدل‌های شبه-بعدی (دوناچه‌ای) - چند ناحیه‌ای) برای توصیف پدیده احتراق و پیش‌بینی آلاینده‌ها از دقت و هزینه محاسباتی مناسبی برخوردار هستند. در کار حاضر مدلی دوناچه‌ای برای احتراق موتور دیزل پاشش مستقیم ارائه و صحت‌گذاری شده است. این مدل مقدار آلاینده‌های خروجی (NOx-SOOT) و گشتاور خالص تولیدی را در هر سیکل بدست می‌دهد. اما با توجه به اینکه مدل احتراقی زمان اجرای نسبتاً بالایی دارد و برای پرهیز از اجرای این مدل به ازاء هر نقطه کار موتور و صرفه‌جویی در زمان، یک مدل شبکه عصبی برای موتور توسعه داده شد. است. شبکه عصبی قادر به مدلسازی مسایل پیچیده در زمینه های مختلف

از جمله موتور خودرو و مدلسازی آلاینده است. از جمله مزایای شبکه عصبی پیش بینی خروجی سیستم با سرعت و دقت بالاست. تاکنون روشهای کلاسیک مختلفی در زمینه بهینه سازی ارائه شده است که همگی در موارد زیر محدودیت دارند:

- ۱- وابستگی نتایج به مقادیر اولیه،
- ۲- توقف الگوریتم حل در صورت رسیدن به یک نقطه اکسترمم محلی
- ۳- قابل استفاده بودن این روشها تنها درمسائلی که تابع هدف پیوسته و مشتق پذیر است. با توجه به اینکه روش ژنتیک الگوریتم هیچکدام از محدودیتهای فوق را ندارد. این ابزار برای بهینه سازی موتور دیزل مناسب است.

### ساختار مدل احتراقی

این مدل شامل زیر مدل‌های تراکم، پاشش سوخت و اسپری، تاخیر در احتراق، نرخ سوختن سوخت، احتراق، آلاینده‌ها و مرحله انبساط است. مرحله تراکم از لحظه بسته شدن سوپاپ هوا تا پایان تاخیر در احتراق ادامه دارد. در این مرحله تنها هوا وجود دارد و معادله انرژی مربوط به آن همان قانون اول برای سیستم بسته است. معادلات (۱) و (۲) معادلات انرژی و حالت حاکم بر سیستم هستند که از آنها برای محاسبه فشار و دما در این مرحله استفاده می‌شود.

$$dQ = dE + pdV \quad (1)$$

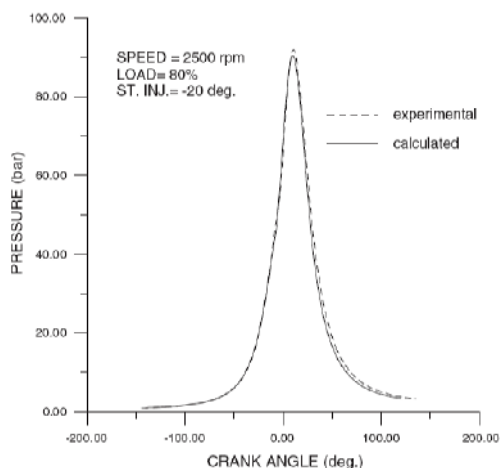
$$p.V = m(R_{mol} / M_{ch})T \quad (2)$$

مدلسازی اسپری شامل تعیین پارامترهای طول و زمان از هم پاشیدن اسپری، پیشروی اسپری، نفوذ هوا به درون اسپری و برخورد اسپری با دیواره اتاق احتراق است. سوخت استفاده شده سوخت معمول در موتورهای اشتعال تراکمی با فرمول شیمیایی (C12H26) n-Dodecane است. زمان شکست، مقدار پیشروی و زاویه اسپری از روابط (۳) تا (۵) بدست می‌آید:

$$t_{br} = 28.61 \rho_l . D_N / \sqrt{\rho_a . \Delta p} \quad (3)$$

$$x = 2.95 (\Delta p / \rho_a)^{0.25} \sqrt{D_N} t^\beta \quad (4)$$

$$\theta = 2 \arctan \left( \frac{1}{A'} 4\pi \sqrt{\frac{\rho_a}{\rho_l}} \frac{\sqrt{3}}{6} \right) \quad (5)$$



شکل ۱- نمودار فشار بدست آمده از مدل و آزمایش در بار ۸۰ درصد و دور ۲۵۰۰ rpm به ازاء لحظه پاشش ۲۰ درجه قبل از مرگ بالا

### مدل تشکیل آلایند

مقدار غالب در NOx متعلق به NO است و NO<sub>2</sub> مقدار ناچیزی دارد. مدل تعادلی قادر به پیش بینی دقیق غلظت NO نمی‌باشد. لذا برای مدل‌سازی NO از مدل سینتیکی لای [۲] استفاده شده است. برای تعیین مقدار SOOT از مدل پیشنهادی هیروياسو [۳] و بهبود یافته توسط لپ کی و دجود [۴] استفاده شده است. در این مدل نرخ تشکیل و نرخ اکسیداسیون دوده عبارتند از:

$$\frac{dm_{sf}}{dt} = c_{sf} dm_f^{.08} P^{0.5} \exp(-E'_{sf} / (R_{mol} T)) \quad (8)$$

$$\frac{dm_{sc}}{dt} = c_{sc} (P_{O_2} / P) P^n \exp(-E'_{sc} / (R_{mol} T)) \quad (9)$$

در روابط فوق  $P$  و  $P_{O_2}$  و  $T$  به ترتیب فشار جزیی اکسیژن در ناحیه سوخته و فشار محفظه احتراق بر حسب (bar) و دمای ناحیه سوخته می‌باشد.  $dm_f$  جرم بخار سوختی است که باید در مدت زمان  $dt$  بسوزد. در نهایت نرخ خالص تشکیل دوده (با اندیس sn) از رابطه زیر بدست می‌آید:

$$\frac{dm_{sn}}{dt} = \frac{dm_{sf}}{dt} - \frac{dm_{sc}}{dt} \quad (10)$$

در شکل ۲ نمودار غلظت NOx و Soot بر حسب زاویه میل لنگ در دور ۲۵۰۰ rpm و بار ۸۰ درصد نشان داده شده است.

### مدل انتقال حرارت

همواره در تمام مراحل کاری موتور احتراق داخلی بین جرم محبوس درون سیلندر و دیواره های اطراف آن انتقال حرارت وجود دارد. از جمله متداولترین مدل‌های مورد استفاده برای انتقال حرارت مدل توسعه داده شده وشنی [۵] است که در اینجا نیز به کار برده شده است. روابط حاکم بر این مدل عبارتند از:

$$\dot{Q}_w = HA_{hex} (T_w - T_g) \quad (11)$$

### مدل تاخیر در احتراق

بطور کلی تاخیر در احتراق تابع پیچیده ای از پارامترهای مختلفی مانند دما، فشار، نسبت هم ارزی و خواص سوخت است. برای محاسبه تاخیر در احتراق از رابطه تجربی آرنیوسی ساده ارائه شده توسط واتسون برای احتراق در موتورهای دیزل استفاده شده است.

$$\tau = A^n P^{-n} \exp\left(\frac{T_a}{T}\right) \quad (6)$$

که  $P$ ،  $T$  به ترتیب دما و فشار درون محفظه احتراق و  $\tau$  مدت زمان تاخیر در احتراق است. مقادیر  $T_a$  و  $n$  و  $A^n$  با توجه به نوع سوخت تعیین می‌شوند. برای در نظر گرفتن اثر تغییرات فضا و دما در محاسبه  $\tau$  از رابطه انتگرالی زیر استفاده می‌شود:

$$\int_{t_{soi}}^{t_{soc}} \frac{dt}{\tau} = 1 \quad (7)$$

$$t_{del} = t_{soc} - t_{soi}$$


که  $t_{del}$  زمان تاخیر در احتراق است.

### مدل احتراق

نرخ آزاد سازی حرارت (ROHR) از مهمترین عوامل تاثیرگذار بر عملکرد و میزان آلایندهای خروجی از موتور است. البته به علت پیچیدگی این پدیده در موتور دیزل تاکنون مدل‌های گوناگونی برای آن ارائه شده است. در کار حاضر از مدل تجربی میاموتو که احتراق را با تابع وایب دوگانه مدل می‌کند استفاده شده است.

### شیمی احتراق

برای مدل‌سازی محصولات احتراق از مدل تعادل شیمیایی ارائه شده توسط وی برای سیستم C-H-O-N استفاده شده است. این مدل شامل ۱۱ جزء است:



چنانچه برای ناحیه سوخته پارامترهایی نظیر حجم، دما و فشار مشخص باشد با حل یک دستگاه معادلات غیر خطی شامل ۱۱ معادله، ۴ معادله برای موازنه جرم اتمها و ۷ معادله تعادلی، غلظت هر یک از اجزا را بدست آورد.

شکل ۱ تغییرات فشار بدست آمده از مدل احتراقی و آزمایش را در دور ۲۵۰۰ و بار ۸۰ درصد نشان می‌دهد که حاکی از تطابق بسیار مناسب این دو نمودار است.

به نورون  $i$ -ام و  $W_{ij}$  و  $W_{ki}$  به ترتیب مقادیر وزن‌های نورون لایه فعلی  $i$  به نورون لایه بعدی  $j$  و وزن‌های نورون لایه قبلی  $k$  به نورون لایه فعلی  $i$  می‌باشد. در روابط بالا تابع  $\text{sgn}()$  تابع فعالسازی (activation function) نامیده می‌شود [۶]. در حالت کلی با توابع فعالسازی متنوعی برخورد می‌شود که بسته به کاربرد می‌توانند دارای اقسام مختلفی باشند. از جمله تابع خطی (linear)، تابع سیگموئیدی (sigmoid) و تابع تانژانت هایپربولیک (hyperbolic tangent).

همانطور که قبلاً بیان شد، شبکه عصبی به کار رفته در این مطالعه پرسپترون چند لایه (MLP) می‌باشد که می‌توان نمونه‌ای از آن را در شکل ۴ ملاحظه نمود. شبکه عصبی نشان داده شده در شکل ۴ دارای لایه ورودی، یک لایه پنهان (میانی) و لایه خروجی می‌باشد. قانون یادگیری پرسپترون، یک الگوریتم برای تنظیم وزن‌های شبکه عصبی می‌باشد که با تنظیم این مقادیر قادر می‌توان تفاوت بین خروجی‌های واقعی  $out_j$  و خروجی‌های مطلوب به کمترین مقدار ممکن رساند. تابع خطا برای محاسبه مقدار خطا به صورت زیر تعریف می‌گردد:

$$E(w_{ij}) = \frac{1}{2} \sum_p \sum_j (tar_j - out_j)^2 \quad (۱۳)$$

به دلیل کاملاً روشن، این تابع به نام تابع خطای جمع مربعات نامیده می‌شود. هدف از یادگیری، مینیمم کردن این مقدار از خطا با تنظیم وزن‌های  $W_{ij}$  می‌باشد. می‌توان مقادیر تنظیمی کوچکی را به این مقادیر اضافه نمود؛ یعنی در نهایت نتیجه خواهد شد:

$$W_{ij} \rightarrow W_{ij} + \Delta W_{ij} \quad (۱۴)$$

یک راه‌حل منطقی برای محاسبه مقدار وزن اضافه شده این است که اطلاعات خود را در مورد تغییرات مقدار خطای  $E(w_{ij})$  افزایش داده و این معیار یعنی میزان تغییرات این خطا را برای محاسبه تغییرات مقدار وزن مورد استفاده قرار داد. بدین منظور از مقدار خطای بدست آمده در انتهای هر مرحله از یادگیری (Epoch) نسبت به میزان وزن‌های  $W_{ij}$ ، گرادیان به عمل می‌آوریم. این روش با نام کاهش گرادیان نامیده می‌شود [۶].

باید شبکه را به کمک تنظیم وزن‌های  $W_{ij}$  در جهت مینیمم کردن تابع خطا آموزش دهیم. برای این کار از تابع خطا که در زیر نشان داده شده است، برای گرفتن گرادیان مورد استفاده قرار می‌گیرد.


$E(w_{ij}) = \frac{1}{2} \sum_p \sum_j (tar_j - out_j)^2$	(۱۵)
$\Delta W_{kl} = -\eta \frac{\partial E(w_{ij})}{\partial w_{kl}}$	(۱۶)

و در نتیجه خواهیم داشت:


$$\Delta W_{kl} = -\eta \frac{\partial}{\partial w_{kl}} \left( \frac{1}{2} \sum_p \sum_j \left( tar_j - f \left( \sum_i in_i w_{ij} \right) \right)^2 \right) \quad (۱۷)$$

$A_{hex} = A_w + A_{pis} + A_{cd}$	که :
------------------------------------	------

در روابط فوق  $\dot{Q}_w$  بر حسب (J/s) نرخ انتقال حرارت و  $H$  بر حسب  $(w/m^2k)$  ضریب انتقال حرارت است.



الف- NOx



ب- Soot

شکل ۲: نمودار تغییرات غلظت آلاینده هادر بار ۸۰ درصد و دور ۲۵۰۰ rpm به ازاء لحظه پاشش ۲۰ درجه قبل از مرگ بالا

#### شبکه عصبی


شبکه عصبی را می‌توان به عنوان یکی از تکنیک‌های جدید در موارد طبقه‌بندی و مدل‌سازی سیستم‌ها مورد استفاده قرار داد. شبکه عصبی از مجموعه‌ای از نورون‌ها تشکیل شده است که در لایه‌های مختلف قرار گرفته‌اند [۸]. نمایی از یک نورون مصنوعی در شکل ۳ ملاحظه می‌شود. در این شکل مقادیر هر کدام از پارامترهای نشان داده شده برابر است با:

$$\begin{aligned} in_{ki} &= out_k w_{ki} \\ out_i &= \text{sgn} \left( \sum_{k=1}^n in_{ki} - \theta_i \right) \\ in_{ij} &= out_i w_{ij} \end{aligned} \quad (۱۲)$$


که در این رابطه  $k, i$  و  $j$  به ترتیب شماره‌دهنده مربوط به لایه قبلی، لایه فعلی و لایه بعدی می‌باشد. مقدار  $in_{ki}$  خروجی نورون  $k$ ، مقدار بایاس مربوط

جدول ۱- محدوده تغییرات پارامترهای طراحی جهت تولید داده‌ها

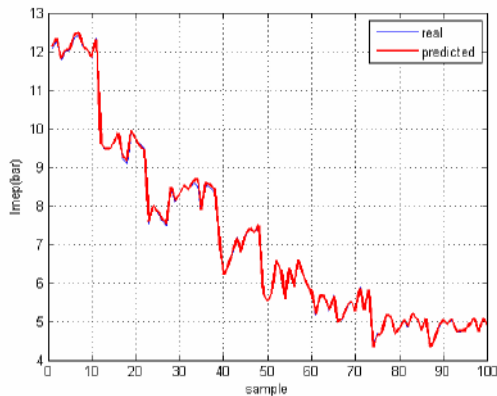
Design Parameter	Range of Variation
SOI	330-350 crank angle
AFR	24-66
Injection Duration	16-41 crank angle
Engine Load	40%-100%
Engine RPM	1500-4000



الف: نتایج تست شبکه عصبی برای NOx




ب: نتایج تست شبکه عصبی برای Soot




ج: نتایج تست شبکه عصبی برای Imep

شکل ۵: نتایج تست شبکه عصبی در دور ۲۵۰۰rpm و بار ۸۰درصد

و بدین ترتیب می‌توان شبکه را آموزش داد و برای منظوره‌های مختلف از جمله تشخیص مورد استفاده قرار داد [۶].



شکل ۳: نمایی از یک نورون ساده



شکل ۴: نمونه‌ای از شبکه عصبی پرسپترون چند لایه

### اجرای شبکه عصبی

از طریق تغییر دادن پارامترهای طراحی مقادیر مختلف NOx, Soot و Imep از مدل احتراقی محاسبه و ثبت می‌گردد. محدوده تغییرات این پارامترها در جدول (۱) نشان داده شده است. از داده‌های بدست آمده جهت آموزش و تست شبکه عصبی استفاده می‌شود. جعبه ابزار شبکه عصبی نرم‌افزار matlab برای این منظور مورد استفاده قرار گرفته است. برای هر مجموعه از دور و بار موتور یک شبکه آموزش داده شده که ورودی‌های آن عبارتند از: نسبت هوا به سوخت، لحظه شروع پاشش و مدت زمان پاشش و خروجی‌های آن عبارتند از: آلاینده‌ها و فشار متوسط القایی. ۲۴ مجموعه داده حاصل از ۶ حالت سرعت و ۴ حالت بار در مجموع مورد استفاده قرار گرفت. شبکه طراحی شده یک MLP است شامل ۴ لایه که لایه ورودی و خروجی آن ۳ گره و ۲ لایه پنهان آن ۱۵ گره دارد. از روش Quick propagation برای آموزش شبکه استفاده می‌شود. در این روش از الگوریتم Fahlman استفاده می‌شود. آموزش بایستی به گونه‌ای باشد که از یک طرف شبکه تمام حالات موجود را فرا بگیرد و از طرف دیگر دچار overtraining نشود. زیرا در چنین حالتی شبکه در مواجهه با ورودی‌های جدید بسیار ضعیف عمل خواهد نمود. پارامتر مهم دیگر در آموزش شبکه این است که به ازای هر مجموعه داده شبکه به مینیمم خطای کلی ( global minimum error) برسد.

### نتایج تست شبکه عصبی

۲۸۴ داده در هر دور و بار با استفاده از مدل احتراقی برای آلاینده‌ها و عملکرد بدست آمد که از این تعداد ۲۵۶ داده برای آموزش شبکه و ۱۲۸ داده برای تست شبکه استفاده شد. نتایج تست در دور ۲۵۰۰ و بار ۸۰ درصد در شکل ۵ مشاهده می‌شود. منحنی آبی رنگ مربوط به مقادیر واقعی حاصل از مدل احتراقی و منحنی قرمز رنگ مربوط به پاسخ شبکه عصبی به مقادیر تست است. همانطور که مشاهده می‌شود نتایج تست از دقت بسیار بالایی برخوردار است به طوری که دو منحنی از هم قابل تشخیص نیستند.

## الگوریتم ژنتیک

در میان روش‌های بهینه‌سازی الهام گرفته شده از طبیعت جاندار الگوریتم ژنتیک از تکامل یافته‌ترین‌ها به‌شمار می‌رود. این الگوریتم برای بهینه‌سازی، جستجو و زبان ماشین مورد استفاده قرار می‌گیرد. قانون داروین اساس این الگوریتم می‌باشد که می‌گوید موجودات پست از بین می‌روند و موجودات کامل‌تر باقی می‌مانند. در الگوریتم ژنتیک، الگوریتم‌های جستجویی وجود دارند که بر اساس مکانیزم انتخاب طبیعی و ژنتیک طبیعی ذکر شده در بالا، عمل می‌نمایند. این الگوریتم‌ها مناسب‌ترین رشته‌ها را از میان اطلاعات تصادفی سازماندهی شده انتخاب می‌کنند. در هر نسل، یک گروه جدید رشته‌ها با استفاده از بهترین قسمت‌های دنباله‌های قبلی و بخش جدید اتفاقی برای رسیدن به یک جواب مناسب به‌وجود می‌آید. هنگام پیشامدسازی، الگوریتم‌های ژنتیک داده‌های پیشین را با تفکر انتخاب نقاط جستجوی جدید برای رسیدن به پیشرفت موردنظر، توأم می‌کنند. در الگوریتم ژنتیک، مجموعه‌ای از متغیرهای طراحی را توسط رشته‌هایی با طول ثابت یا متغیر کدگذاری می‌کنند که در سیستم‌های بیولوژیکی آنها را کروموزوم یا فرد می‌نامند. هر متغیر طراحی از چند حرف که معمولاً به‌صورت دودویی‌می‌باشند، تشکیل شده که آن را ژن نامیده‌اند. هر رشته یک نقطهٔ پاسخ در فضای جستجو را نشان می‌دهد. الگوریتم‌های وراثتی فرآیندی تکراری است که هر مرحلهٔ تکراری را نسل و مجموعه‌ای از پاسخ‌ها در هر نسل را جمعیت نام نهاده‌اند. الگوریتم‌های ژنتیک، جستجوی اصلی را در فضای پاسخ به اجرا می‌گذارند. این الگوریتم‌ها با تولید نسل آغاز می‌شوند که وظیفهٔ ایجاد مجموعهٔ نقاط جستجوی اولیه‌ای به نام جمعیت اولیه را برعهده دارند و به‌طور انتخابی و یا تصادفی تعیین می‌شوند. از آنجاییکه الگوریتم‌های ژنتیک برای هدایت عملیات جستجو به‌طرف نقطهٔ بهینه از روش‌های آماری استفاده می‌کنند، در فرآیندی که به انتخاب طبیعی وابسته است، جمعیت موجود به تناسب برآزندگی افراد آن برای نسل بعد انتخاب می‌شود سپس عملگرهای ژنتیکی شامل انتخاب، پیوند جهش و دیگر عملگرهای احتمالی اعمال و جمعیت جدید به‌وجود می‌آید. پس از آن، جمعیت جدیدی جایگزین جمعیت پیشین می‌شود و این چرخه ادامه می‌یابد. معمولاً جمعیت جدید برآزندگی بیشتری دارد. این بدان معنا است که از نسلی به نسل دیگر جمعیت بهبود می‌یابد. هنگامی جستجو نتیجه‌بخش خواهد بود که به حداکثر نسل موردنظر رسیده باشیم یا همگرایی حاصل شده باشد و یا معیارهای توقف برآورده شده باشد. شرط‌های توقف بر دو نوعند:

۱- شرط غیر فعل که در این حالت توقف الگوریتم مستقل از نتیجهٔ بدست آمدهٔ الگوریتم است. این شرط را می‌توان به‌صورت گذشت تعداد ثابتی نسل تعریف کرد.

۲- شرط‌های دنباله‌ای که در این حالت توقف الگوریتم به جواب بدست آمده از الگوریتم وابسته است. شرطی از این نوع عبارت است از این که جمعیت از حد معینی یکنواخت‌تر شود. برای مثال اگر ۹۵ درصد ژن‌های دارای موقعیت مکانی مشابه مقداری برابر داشته باشند، جمعیت همگرا شده درنظر گرفته می‌شود.

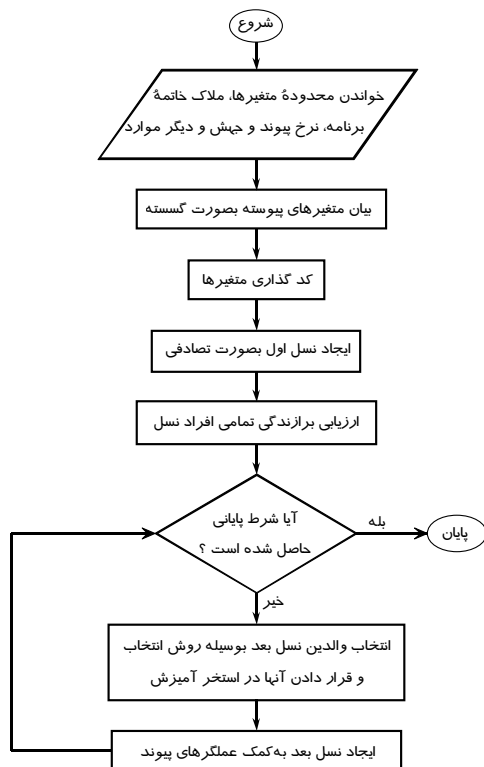
ویژگی اصلی الگوریتم‌های ژنتیک عبارت است از:

۱- الگوریتم‌های ژنتیک به‌جای خود متغیرها از متغیرهای کدگذاری شده استفاده می‌کنند. این ویژگی برای استفاده از متغیرهای گسسته بسیار مناسب است.

۲- در بسیاری از روش‌های بهینه‌سازی، با دقت بسیار از یک نقطه در فضای پاسخ و با استفاده از قوانین انتقال به نقطهٔ دیگر حرکت می‌کنیم. چنین روش نقطه به نقطه‌ای خطرناک است زیرا در فضای جستجو ممکن است چند نقطهٔ اوج در چند جهت وجود داشته باشد و محل قرارگیری نقطهٔ اوج اشتباه تعیین گردد. اما الگوریتم‌های ژنتیک به‌جای یک نقطهٔ جستجو، چندین نقطهٔ جستجوی متقارب ( بصورت مجموعه‌ای از رشته‌ها ) را به‌کار می‌برند که بطور موازی از چندین نقطهٔ اوج بالا می‌روند. بنابراین، احتمال سرگردان شدن در بهینهٔ محلی بشدت کاهش می‌یابد و از طرف دیگر احتمال دستیابی به بهینهٔ کلی افزایش خواهد یافت [۷].

۳- الگوریتم‌های ژنتیک توانایی تلفیق با دیگر روش‌های بهینه‌سازی را دارند. ۴- الگوریتم‌های ژنتیک برای اجرای جستجوی موثر، فقط به مقادیر تابع هدف نیاز دارند و دانسته‌های از پیش تعیین شده را نادیده می‌گیرند. به همین دلیل اینگونه الگوریتم‌ها را کور می‌نامند. این ویژگی، الگوریتم‌های ژنتیک را نسبت به دیگر روش‌های جستجو، روش مناسب‌تری جلوه می‌دهد. ۵- کارایی الگوریتم‌های ژنتیک در فضاهای طراحی نامناسب و پیچیده، که با روش‌های مبتنی بر گرادین بسیار دشوار و یا حتی غیر ممکن به‌نظر می‌رسد، به‌طور تئوری و تجربی اثبات شده است.

۶- الگوریتم‌های ژنتیک از انتخاب تصادفی بصورت ابزاری برای هدایت عملیات جستجو به‌طرف فضای جستجوی مناسب‌تر سود می‌برند. در شکل (۵) نمودار جریان الگوریتم ژنتیک ساده نشان داده شده است.



شکل ۶: نمودار جریان الگوریتم ژنتیک ساده [۸]


### اجرای الگوریتم ژنتیک و بررسی نتایج

با استفاده از جعبه ابزار الگوریتم ژنتیک نرم‌افزار MATLAB، عملکرد بهینه موتور در هر دور و بار مورد ارزیابی قرار گرفته است. پارامترهای ژنتیک الگوریتم به گونه ای تنظیم شده است که مقدار NOx و Soot مینیمم و


هیپربولیک آموزش داده شدند. با استفاده از شبکه مذکور می‌توان پارامترهای بهینه عملکردی را در هر دور و بار دلخواه تعیین نمود.

### نتیجه‌گیری


در این مقاله در ابتدا با استفاده از یک مدل احتراقی دوناچه‌ای، مقادیر آلاینده‌گی و عملکرد موتور دیزل پاشش مستقیم در سیکل بسته بدست آمد. سپس از نتایج بدست آمده برای ارائه یک مدل شبکه عصبی، به عنوان جایگزینی مناسب برای مدل احتراقی استفاده گردید. مقادیر بهینه آلاینده‌ها در دورها و بارهای متفاوت با اعمال یک الگوریتم ژنتیک بر مدل شبکه عصبی بدست آمد. اکنون از نتایج بدست آمده می‌توان به عنوان نقشه عملکردی موتور برای کارکرد در حالت بهینه استفاده نمود.



الف - نسبت هوا به سوخت



ب - زمان شروع پاشش



ج - مدت پاشش سوخت

شکل ۷: نمودار تغییرات پارامترهای طراحی بر حسب دور و بار موتور

Imep ماکزیمم شود. مقدار تابع تناسب (Fitness function) با توجه به تابعی که از مرحله قبل یعنی آموزش شبکه‌های عصبی در هر دور و بار بدست آمد، استفاده شده است. بدین ترتیب که به جای استفاده از مدل کلی موتور، تنها مدل بدست آمده از شبکه عصبی که مورد ارزیابی نیز قرار گرفت، به کار گرفته می‌شود. این کار سبب می‌شود که میزان هزینه محاسباتی به مراتب کاهش یابد و مرحله بهینه‌سازی با قدرت قابل ملاحظه‌ای صورت گیرد. به طوریکه اجرای کد احتراقی نوشته شده به زبان برنامه نویسی Matlab با استفاده از امکانات سخت‌افزاری از قبیل پروسسور اینتل P-IV 2.8 MHz و 1GB RAM در حدود ۵۰ ثانیه به طول می‌انجامد. در حالیکه با استفاده از وزنهای شبکه عصبی و استخراج آن به صورت یک تابع، با همان تجهیزات این زمان به کسری از ثانیه تبدیل می‌شود.

نتایج بهینه سازی در جدول ۲ مشاهده می‌شود. همانطور که مشاهده می‌شود، در هر دور و بار با مراجعه به جدول می‌توان پارامترهای بهینه عملکردی موتور را استخراج نمود. از این رو با استفاده همزمان از مدل شبکه عصبی و الگوریتم ژنتیک می‌توان نقشه آلاینده‌گی و عملکرد موتور را بدست آورد. با توجه به جدول مذکور میتوان رویه های مربوط به تغییرات هر پارامتر طراحی را بر حسب دور و بار موتور ترسیم نمود. در شکل ۷ این رویه‌ها مشاهده می‌شوند.

جدول ۲- نتایج بهینه سازی

Rpm	Load (%)	afr	dur (deg)	SOI (deg)	NOx (ppm)	Soot (mg/m <sup>3</sup> )	Imep (bar)
1500	40	24	31	347	1731.5	115.32	4.9108
2000	40	42	21	347	1776	61.848	2.8316
2500	40	24	41	347	1761.7	83.584	5.2304
3000	40	30	41	347	1776.2	60.563	4.2319
3500	40	36	21	350	1676.8	46.12	3.5469
4000	40	30	31	350	1659.7	48.807	4.3419
1500	60	30	26	347	1738.2	132.76	5.8301
2000	60	42	21	350	1681.2	90.019	4.3795
2500	60	30	41	350	1635.9	101.83	6.3388
3000	60	30	31	347	1762.4	84.553	6.359
3500	60	36	31	347	1794.4	64.089	5.3336
4000	60	42	31	347	1792.6	50.451	4.6024
1500	80	42	21	347	1777	124.87	5.4864
2000	80	36	21	350	1710	125.69	6.714
2500	80	30	36	350	1620	126.8	8.3198
3000	80	30	31	344	1878	98.04	8.1524
3500	80	48	41	350	1656.8	54.783	4.3292
4000	80	42	21	350	1731.9	65.711	6.098
1500	100	42	36	347	1787.2	64.7	6.1606
2000	100	42	31	350	1627.8	137.06	7.3069
2500	100	42	26	350	1680.3	115.56	7.3926
3000	100	42	26	344	1898.4	101.7	7.1987
3500	100	36	36	350	1631.2	115.58	8.7528

### تعمیم جدول

جهت تعمیم گستره کاری موتور داده‌های بدست آمده در جدول ۲ توسط یک شبکه عصبی با یک لایه میانی با ۱۵ گره و تابع فعالسازی تانزانت

### فهرست علائم

$t_{br}$	زمان شکست اسپری
$\rho_l$	چگالی سوخت مایع
$\rho_a$	چگالی هوا
$\Delta p$	افت فشار در نازل انژکتور
$D_N$	قطر نازل انژکتور
$x$	مقدار پیشروی اسپری
$\theta$	زاویه اسپری
$A', \beta$	ثوابت تجربی
$A_w$	سطح جانبی دیواره سیلندر
$A_{pis}$	سطح مقطع پیستون
$A_{cd}$	سطح سر سیلندر
$T_w$	دمای دیواره محفظه احتراق
$Tg$	دمای جرم محبوس درون سیلندر
$t_{del}$	تاخیر در احتراق
$t_{soi}$	شروع پاشش سوخت
	زیرنویس ها :
sc	اکسیداسیون دوده
sf	تشکیل دوده

### منابع

- [1] C. D. Rakopoulos, 2003, Development and validation of a comprehensive two zone model for combustion and emission formation in a DI diesel engine, INTERNATIONAL JOURNAL OF ENERGY RESEARCH.
- [2] G. A. Lavoie, ET all, 1970, Experimental and theoretical study of Nitric Oxide formation in internal combustion engine, *Combustion Science and Technology*.
- [3] H. Hiroyasu, T. Kadota, 1983, Development and use of a spray combustion modeling to predict diesel engine efficiency and pollutant emissions, *Bulletin of the JSAE*.
- [4] W. H. Lipkea, A .D. Dejoode, 1994, Direct injection diesel engine soot modeling formulation and results, *SAE paper no. 940670*.
- [5] J. I. Ramos, 1989, Internal combustion engine modeling, *Hemisphere Publishing Corporation*.
- [6] T. Heykin, 2004, Introduction to Neural Networks.
- [7] T.Hiroyasu, 2003, Reduction of Heavy Duty Diesel Engine Emission and Fuel Economy with Multi-Objective Genetic Algorithm and Phenomenological Model, *SAE paper*.
- [8] Rajan Filomeno Coelho, 2004, Multicriteria Optimization with Expert Rules for Mechanical Design, *Dissertation in UNIVERSITÉ LIBRE DE BRUXELLES*.