

مدلسازی مقدار میانگین موتور دیزل به هدف تشخیص عیب

با استفاده از شبکه عصبی

امیرحسین شامخی

عضو هیأت علمی دانشگاه خواجه نصیر الدین طوسی

amirshamekhi@gmail.com

علی نصیری طوسی

عضو هیأت علمی دانشگاه علم و صنعت

مهدی پلاور

محمد حسن بهروزی

رضا چینی

چکیده

یکی از جدیدترین زمینه‌های تحقیقاتی در موتورهای دیزل امروزی، پیدا کردن عیب و دادن اخطار به راننده یا اپراتور هنگام بروز مشکل در آن است. برای انجام این کار در موتور دیزل، ابتدا باید مدلسازی مناسبی از موتور انجام شود. از روش‌های به کار رفته در مدلسازی، می‌توان به مدل مقدار میانگین (Mean Value) اشاره نمود که از مزایای این مدل سادگی در معادلات و در نظر گرفتن مقادیر میانگین است. شبیه‌سازی در محیط نرم‌افزار Matlab/Simulink انجام شده و نتایج خروجی این مدل با داده‌های تجربی مقایسه شده است. در این مقاله از روش تشخیص عیب بر مبنای مدل استفاده می‌شود. برای این منظور خطاهایی در سیستم ایجاد می‌گردد و در نهایت با استفاده از یک طبقه‌بند شبکه عصبی، تعداد ۴ خطای معمول موتورهای دیزل مورد شناسایی قرار می‌گیرد.

کلمات کلیدی: تشخیص عیب، شبکه عصبی، طبقه‌بندی داده‌ها، مدل مقدار میانگین، موتور دیزل.

۱- مقدمه

یکی از روشهای مدلسازی به کار رفته برای سیستمهای دینامیکی، به ویژه سیستمهای چند ورودی- چند خروجی (MIMO) و پیچیده، استفاده از روش مقدار میانگین است. مزیت استفاده از روش مقدار میانگین در موتور، سادگی و کارا بودن آن است. این روش (MVEM) برای اولین بار در سال ۱۹۹۰ در دانشگاه صنعتی دانمارک ارائه شد [۱]. با گذر زمان استفاده از این نوع مدل توسعه یافت [۲-۴].

حرکت جدی در زمینه عیب‌یابی سیستمهای دینامیکی به سال‌های دهه ۷۰ باز می‌گردد. Beard (۱۹۷۱) [۵] و Jones (۱۹۷۳) [۶] شناسایی عیب مبتنی بر مشاهده‌گر در سیستم‌های خطی را بنا نهادند. مرور و تحلیلی بر پیشرفت‌های آن سالها توسط Willisky (۱۹۷۶) [۷] ارائه شد.

تشخیص نقص حسگر اولین بار توسط Clark (۱۹۷۶) [۸] انجام شد. استفاده از تکنیک‌های تخمین پارامتر توسط Bakiotis (۱۹۷۹) [۹]، Gerger (۱۹۸۲) [۱۰] و Filbert (۱۹۸۲) [۱۱] توسعه داده شد. در آن سالها Isermann (۱۹۸۴) [۱۲] روشهای مبتنی بر فضای حالت برابری که از مدتها پیش مورد استفاده قرار می‌گرفت، توسط Patton (۱۹۹۱) [۱۳] و Chen (۱۹۹۱) [۱۴] و Gertler (۱۹۹۱) [۱۵] و Hofling (۱۹۹۳) [۱۶] تعمیم داده شد. با پیشرفت زمینه‌های مختلف هوش محاسباتی، تحقیقات در زمینه FDI شکل تازه‌ای به خود گرفت. Mc-Clelland (۱۹۸۹) [۱۶] امکان استفاده از شبکه‌های عصبی برای طراحی سیستم‌های تشخیص عیب را مطرح کرد. با رواج و پیشرفت سیستمهای طراحی شده بر مبنای منطق فازی، محققین و مهندسين در بسیاری از شاخه‌ها از جمله FDI توجه زیادی به آن نشان دادند. Frank (۱۹۹۷) از شبکه‌های عصبی برای تخمین پارامترهای فیزیکی سیستم بر اساس ویژگی تخمین‌گر شبکه عصبی، استفاده کردند. در این روش بعد از تخمین، انحراف پارامترها از حالت نرمال آنها نشان دهنده وقوع عیب است. در مورد مدل مقدار میانگین نیز مدلسازی‌های متعددی تاکنون معرفی شده است که از جمله جدیدترین آنها می‌توان به مدل Ritzen (۲۰۰۳) [۱۷] و مدل Ramstedt (۲۰۰۴) [۱۸] اشاره کرد.

۲- مدلسازی موتور

در این قسمت به توصیف مدلسازی حرکت هوا در موتور دیزل توربوشاژر شده پرداخته می‌شود. این مدل به نام "مدل موتور مقدار میانگین" (MVEM) معروف است که به این معناست که مقدار سیگنالها و متغیرهای در نظر گرفته شده دارای مقدار متوسط در چندین سیکل مختلف می‌باشند. در هر بخش شبیه‌سازی مربوط به هر قسمت با استفاده از نرم‌افزار Matlab/Simulink انجام شده است.

منیفولد ورودی

منیفولد ورودی بر حسب پارامترهای دما و فشار به صورت ایده آل در نظر گرفته می شوند. اگر منیفولد ورودی به صورت ایده آل در نظر گرفته شود، می توان قانون گاز کامل را برای آن در نظر گرفت:

$$p = \frac{mRT}{V} \quad (1)$$

از رابطه بالا می توان برای استخراج تغییرات فشار در منیفولد ورودی استفاده کرد. با دیفرانسیل گیری از رابطه (۱) می توان رابطه زیر را استخراج نمود:

$$\dot{p} = \frac{\dot{m}RT}{V} + \frac{mR\dot{T}}{V} \quad (2)$$

با فرض اینکه دما به کندی تغییر می کند، رابطه زیر استخراج می شود:

$$\dot{T} \approx 0 \quad (3)$$

بنابراین خواهیم داشت:

$$\dot{p}_{im} = \frac{R_i T_{im}}{V_{im}} (W_{im_{in}} - W_{im_{out}}) \quad (4)$$

که در این رابطه $W_{im_{in}}$ جریان جرمی به درون منیفولد ورودی و $W_{im_{out}}$ جریان جرمی خارج شده از منیفولد ورودی می باشد. جریان جرمی وارد به منیفولد ورودی فرض می شود که هوای جریان یافته در کمپرسور می باشد. بنابراین:

$$W_{im_{in}} = W_{cmp} \quad (5)$$

جریان جرمی وارد شده به منیفولد ورودی را جریان جرمی ورودی به سیلندرها در نظر می گیریم که مانند زیر مدل می شود:

$$W_{im_{out}} = W_{eng_{in}} \quad (6)$$

$$W_{eng_{in}} = \eta_{vol} \frac{p_{im} V_d N_{cyl} n_{eng}}{60 N_r R_{im} T_{im}} \quad (7)$$

که در این رابطه η_{vol} بازده حجمی، V_d حجم جابجایی، N_{cyl} تعداد سیلندرها، n_{eng} دور موتور، R_{im} ثابت گاز و T_{im} دمای منیفولد ورودی می باشد.

بازده حجمی

بازده حجمی عبارتست از قابلیت تنفسی موتور. این مقدار به عنوان نرخ جریان حجمی واقعی تقسیم بر نرخ جریان حجمی نظری از جریان هوای جابجا شده در پیستون در نظر گرفته می شود. این مقدار با رابطه زیر مدل می شود:

$$\eta_{vol} = f_{\eta_{vol}}(n_{eng}, p_{im}) \quad (8)$$

که در آن η_{vol} تابعی از دور و فشار منیفولد ورودی است و مقدار آن از جداول مرجع استخراج شده از اطلاعات موتور به دست می آید.

منیفولد خروجی

منیفولد خروجی همانند منیفولد ورودی بر حسب پارامترهای دما و فشار، ایده آل فرض می شود. با استفاده از روابط (۱)، (۲) و (۳) می توان رابطه زیر را استخراج نمود:

$$\dot{p}_{em} = \frac{R_e T_{em}}{V_{em}} (W_{em_{in}} - W_{em_{out}}) \quad (9)$$

جریان جرمی خروجی از منیفولد خروجی برابر با جریان جرمی درون توربین در نظر گرفته می شود:

$$W_{em_{out}} = W_{tb} \quad (10)$$

جریان جرمی خروجی از موتور و ورودی به منیفولد خروجی به صورت زیر در نظر گرفته می شود:

$$W_{em_{in}} = W_{eng_{out}} \quad (11)$$

جریان جرمی خروجی از موتور برابر با مجموع جریان جرمی ورودی به سیلندرها و سوخت پاشیده شده به جریان جرمی است:

$$W_{eng_{out}} = W_{eng_{in}} + W_{fuel} \quad (12)$$

که در اینجا:

$$W_{fuel} = \frac{\delta n_{eng} N_{cyl}}{60 N_r} \quad (13)$$

که در آن δ مقدار سوخت پاشیده شده در هر مرحله است.

دمای گاز خروجی

دمای گاز خروجی در سیکل ایده آل با رابطه زیر داده شده است:

$$T_{em} = T_1 \left(\frac{p_{em}}{p_{im}} \right)^{\frac{\gamma_e - 1}{\gamma_e}} \cdot \left(1 + \frac{q_{in}}{c_v T_1 r_c^{\gamma_e - 1}} \right)^{\frac{1}{\gamma_e}} \quad (14)$$

که در آن γ_e ، نسبت گرمایی ویژه است. انرژی مخصوص سوخت آماده شده بر حسب جرم عبارتست از:

$$q_{in} = \frac{W_{fuel} q_{HV}}{W_{eng_{in}} + W_{fuel}} (1 - x_r) \quad (15)$$

نسبت گاز پسماند عبارتست از:

$$x_r = \frac{1}{r_c} \left(\frac{p_{em}}{p_{im}} \right)^{\frac{1}{\gamma_e}} \left(1 + \frac{q_{in}}{c_v T_1 r_c^{\gamma_e - 1}} \right)^{\frac{1}{\gamma_e}} \quad (16)$$

که در آن r_c نسبت تراکم و c_v ظرفیت حرارتی مخصوص در حجم ثابت است. مدل را می توان با رابطه زیر تکمیل نمود:

$$T_1 = x_r T_{em} + (1 - x_r) T_{im} \quad (17)$$

سیستم خروجی

همانند روابط بالا، دینامیک این سیستم عبارتست از:

$$\dot{p}_{es} = \frac{R_e T_{es}}{V_{es}} (W_{es_{in}} - W_{es_{out}}) \quad (18)$$

که در این رابطه جریان جرمی وارد به سیستم ورودی برابر با جریان درون توربین می باشد.

$$W_{es_{in}} = W_{es_{tb}} \quad (19)$$

سیستم خروجی با قیدهای مرتبه ۲ مدل می شود:

$$W_{es_{out}}^2 = \frac{k_{es} R_e T_{es}}{p_{es}} (p_{es} - p_{amb}) \quad (20)$$

که در آن k_{es} ، ثابت قید سیستم خروجی می باشد. دمای سیستم خروجی با رابطه زیر مدل می شود:

$$T_{es} = T_{tb_{out}} \quad (21)$$

که در آن $T_{tb_{out}}$ دمای خروجی از توربین می باشد.

۳- مدل سازی توربوشارژر

مدل سازی توربوشارژر شامل سه بخش زیر می شود:

الف) مدل سازی دینامیکی

توربوشارژر با استفاده از روابط ارائه شده در مرجع [۲] شبیه سازی می شود. نقشه عملکردی با استفاده از داده های تهیه شده از کارخانجات سازنده توربوشارژر مدل می شوند. با استفاده از قانون اویلر داریم:

$$J \dot{\omega} = M \quad (22)$$

که با استفاده از آن، سرعت دورانی توربین به صورت زیر بیان می گردد:

$$\dot{\omega}_{tb} = \frac{1}{J_{tb}} (M_{tb} - M_{cmp}) \quad (23)$$

که در آن J_{tb} ، اینرسی مکانیکی توربوشارژر، M_{tb} ، گشتاور پیچشی ایجاد شده توسط توربین و M_{cmp} ، گشتاور ایجاد شده توسط کمپرسور می باشد.

ب) مدل کمپرسور

کمپرسور با دو نقشه عملکردی مجزا تعریف می گردد، اول نقشه جریان جرمی، $f_{W_{cmp}}$ ، و دوم نقشه عملکردی، $f_{\eta_{cmp}}$. جریان جرمی و بازده عملکردی با استفاده از روابط زیر تعریف می شوند.

$$W_{cmp} = f_{W_{cmp}} \left(\frac{p_{im}}{p_{amb}}, n_{tb} \right) \frac{p_{im}}{\sqrt{T_{amb}}} \quad (24)$$

$$\eta_{cmp} = f_{\eta_{cmp}} \left(\frac{p_{im}}{p_{amb}}, n_{tb} \right) \quad (25)$$

در نهایت گشتاور ایجاد شده توسط کمپرسور عبارتست از:

$$M_{cmp} = \frac{W_{cmp} c_{pi} T_{amb}}{\eta_{cmp} \omega_{tb}} \left(\left(\frac{p_{im}}{p_{amb}} \right)^{\frac{\gamma_e - 1}{\gamma_e}} - 1 \right) \quad (26)$$

که در آن c_{pi} ، ظرفیت مخصوص گرمایی در فشار ثابت قبل از اشتعال و η ، نسبت ظرفیت گرمایی قبل از اشتعال می‌باشد.

(ج) مدل توربین

مانند آنچه در مورد کمپرسور گفته شد، توربین نیز با استفاده از دو نقشه عملکردی بیان می‌شود که از این دو نقشه مقادیر $f_{\eta_{tb}}$ و $f_{W_{tb}}$ استخراج می‌شوند. این مقادیر با رابطه زیر بیان می‌شوند:

$$W_{tb} = f_{W_{tb}} \left(\frac{p_{em}}{p_{es}}, n_{tb} \right) \frac{p_{em}}{\sqrt{T_{em}}} \quad (27)$$

$$\eta_{tb} = f_{\eta_{tb}} \left(\frac{p_{em}}{p_{es}}, n_{tb} \right) \quad (28)$$

دمای خروجی از توربین نیز با رابطه زیر مدل می‌شود:

$$T_{tbOut} = \left(1 + \eta_{tb} \left(\left(\frac{p_{im}}{p_{amb}} \right)^{\frac{\gamma_e - 1}{\gamma_e}} - 1 \right) \right) T_{tbIn} \quad (29)$$

گشتاور ایجاد شده توسط کمپرسور عبارتست از:

$$M_{tb} = \frac{W_{tb} c_{pe} \eta_{tb}}{\omega_{tb}} \left(1 - \left(\frac{p_{em}}{p_{es}} \right)^{\frac{1 - \gamma_e}{\gamma_e}} \right) \quad (30)$$

که در این رابطه c_{pe} ، ظرفیت گرمایی مخصوص در فشار ثابت و پس از اشتعال می‌باشد.

خنک‌کن میانی

هوای وارد شده به موتور پس از عبور از کمپرسور وارد این قسمت می‌شود. در این فرآیند فرض می‌شود که تغییرات فشار ناچیز و قابل صرف‌نظر باشد.

$$T_2 = T_1 - \eta_{cool} (T_1 - T_{cool}) \quad (31)$$

که در این رابطه T_1 ، دمای خروجی از کمپرسور و ورودی به خنک کن میانی، T_2 ، دمای خروجی از خنک کن میانی، η_{cool} ، بازده خنک کن و T_{cool} ، دمای مایع خنک کننده می باشد.

جمع بندی، مدل کلی موتور

در اینجا مدل موتور دیزل که با چهار متغیر حالت ارائه می گردد، با چهار رابطه زیر نیز بیان می شود:

$$\dot{p}_{im} = \frac{R_i T_{im}}{V_{im}} (W_{im_{in}} - W_{im_{out}}) \quad (32)$$

$$\dot{p}_{em} = \frac{R_e T_{em}}{V_{em}} (W_{em_{in}} - W_{em_{out}}) \quad (33)$$


$$\dot{p}_{es} = \frac{R_e T_{es}}{V_{es}} (W_{es_{in}} - W_{es_{out}}) \quad (34)$$

$$\dot{\omega}_{tb} = \frac{1}{J_{tb}} (M_{tb} - M_{cmp}) \quad (35)$$

که در این رابطه متغیرهای p_{amb} ، T_{amb} ، T_{im} ، δ و n_{eng} به عنوان ورودی های مدل هستند.

۴- خروجی های مدل و ارزیابی


در شکل (۱) می توان عملیات پاشش سوختی که در آن شبیه سازی انجام شده است را ملاحظه نمود. همزمان عمل ارزیابی مدل بر روی نمودارهای دور و فشار انجام می شود که در شکل های (۲) و (۴) قابل ملاحظه است.




شکل (۱)- عملیات پاشش سوخت

همان گونه که در سه نمودار شکل (۲)، (۳) و (۴) مشاهده می شود، به ترتیب پاسخ دور موتور، دمای منیفولد ورودی و فشار منیفولد ورودی مورد بررسی قرار گرفته است. به طور مثال همانطوری که در شکل (۲) آمده است، نمودار با خط پر (آبی رنگ) مربوط خروجی مدل و نمودار با خط چین (قرمز رنگ) از داده های واقعی موتور استفاده شده است. برای صحت گذاری مدل از نتایج موتور مورد بررسی در مرجع [۱۹] استفاده شده است. به همین ترتیب عمل


صحه گذاری برای شکل (۴) انجام شده است. همان گونه که از این دو شکل دیده می شود، نتایج ارزیابی، صحت مدل را در دورهای ۱۵۰۰ تا ۴۰۰۰ تایید می نمایند.



شکل (۲) - تاثیر عملیات پاشش سوخت بر روی دور موتور



شکل (۳) - تاثیر عملیات پاشش سوخت بر روی دمای منیفولد ورودی



شکل (۴) - تاثیر عملیات پاشش سوخت بر روی فشار منیفولد ورودی

۵- شبکه‌های عصبی

شبکه عصبی را می‌توان به عنوان یکی از روش‌های 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 [۲۰]. در این شکل مقادیر هر یک از پارامترهای نشان داده شده برابر است با:

$$\begin{aligned} in_{ki} &= out_k w_{ki} \\ out_i &= \text{sgn}\left(\sum_{k=1}^n in_{ki} - \theta_i\right) \end{aligned} \quad (36)$$

$$in_{ij} = out_i w_{ij}$$

که در این رابطه k, i و j به ترتیب شمارنده مربوط به لایه قبلی، لایه فعلی و لایه بعدی می‌باشد. مقدار in_{ki} خروجی نورون k, i مقدار بایاس مربوط به نورون i و w_{ki} و w_{ij} به ترتیب مقادیر وزن‌های نورون لایه فعلی i به نورون لایه بعدی j و وزن‌های نورون لایه قبلی به k به نورون لایه فعلی i می‌باشد. در روابط بالا تابع sgn تابع فعالسازی (activation function) نامیده می‌شود [۱۹]. در حالت کلی با توابع فعالسازی متنوعی برخورد می‌شود که بسته به کاربرد می‌توانند دارای اقسام مختلفی باشند. شبکه عصبی بکار رفته در این مقاله پرسپترون چند لایه (MLP) است که دارای لایه ورودی، لایه پنهان (میانی) و لایه خروجی می‌باشد.

قانون یادگیری پرسپترون، یک الگوریتم برای تنظیم وزن‌های شبکه عصبی w_{ij} است که با تنظیم این مقادیر قادر می‌توان تفاوت بین خروجی‌های واقعی out_j و خروجی‌های مطلوب به کمترین مقدار ممکنه رساند. تابع خطا برای محاسبه مقدار خطا به صورت زیر تعریف می‌گردد:

$$E(w_{ij}) = \frac{1}{2} \sum_p \sum_j (tar_j - out_j)^2 \quad (37)$$

به دلیل کاملاً روشن، این تابع به نام تابع خطای مربع جمع‌ها 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:

$$w_{ij} \rightarrow w_{ij} + \Delta w_{ij} \quad (38)$$

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 گرادیانی نامیده می‌شود [۲۰].

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

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

$$\Delta w_{kl} = -\eta \frac{\partial E(w_{ij})}{\partial w_{kl}} \quad (39)$$

و در نتیجه خواهیم داشت:

$$\Delta w_{kl} = -\eta \frac{\partial}{\partial w_{kl}} \left(\frac{1}{2} \sum_p \sum_j \left(tar_j - f \left(\sum_i in_i w_{ij} \right) \right)^2 \right) \quad (40)$$

و بدین ترتیب می‌توان شبکه را آموزش داد و برای منظوره‌های مختلف از جمله تشخیص عیب مورد استفاده قرار داد [۲۰].

عیوب و تشخیص عیب

در این بخش به تشخیص بعضی از عیوب احتمالی که در موتور به وجود می‌آید پرداخته می‌شود. در مدل عیب به کار رفته در این مقاله، ۴ عیب زیر ارائه می‌شود:

۱. BLF: خطای ناشی پس از توربوشارژر (Boost Leak Fault)
۲. FIGF: خطای مقدار پاشش سوخت (Fuel Injection Gain Fault)
۳. TSGF: خطای مقدار اندازه‌گیری دما (Temperature Sensor Gain Fault)
۴. PSGF: خطای اندازه‌گیری مقدار فشار (Pressure Sensor Gain Fault)

این خطاها، عیوب معمولی هستند که ممکن است در یک سیستم دیزل رخ دهد.

طراحی سیستم تشخیص عیب

روش شناسایی عیوب در این مقاله تشخیص عیب بر مبنای مدل می‌باشد. در واقع این روش بدان معناست که تمام عیوب به طور اولیه شناخته شده هستند و حال می‌خواهیم اگر عیبی در راستای عیبهای قبلی رخ داد، سیستم شناسایی عیب قادر باشد آن را تشخیص دهد.

طبقه‌بندی با استفاده از شبکه عصبی

در این مطالعه موردی، ورودی‌های شبکه عصبی عبارتند از:

- دور موتور
- فشار منیفولد ورودی
- دمای منیفولد ورودی

اما خروجی‌های آن متفاوت هستند. بدین معنی که برای هر کدام از کلاس‌ها (هر کدام از عیوب و حالت نرمال عملکرد موتور) یک بردار را به عنوان خروجی انتخاب می‌شود. در جدول (۱) می‌توان این بردارهای در نظر گرفته شده برای هر کدام از کلاسها را مشاهده نمود.

جدول (۱) - بردارهای طبقه‌بندی برای هر کلاس

نرمال	BLF	FIGF	PSGF	TSGF
$\begin{bmatrix} 1 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}$	$\begin{bmatrix} 0 \\ 1 \\ 0 \\ 0 \\ 0 \end{bmatrix}$	$\begin{bmatrix} 0 \\ 0 \\ 1 \\ 0 \\ 0 \end{bmatrix}$	$\begin{bmatrix} 0 \\ 0 \\ 0 \\ 1 \\ 0 \end{bmatrix}$	$\begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 1 \end{bmatrix}$


کلاسهای مختلف داده در اینجا عبارتند از:

- حالت نرمال
- عیب BLF
- عیب FIGF
- عیب PSGF
- عیب TSGF


بنابراین شبکه عصبی در این مطالعه موردی دارای ۳ ورودی و ۵ خروجی خواهد بود. هر کدام از کلاسهای ورودی با استفاده از MATLAB به صورت سری پشت سر هم چیده می‌شوند. هر کلاس دارای ۵۰۱ نمونه زمانی (Sample) می‌باشد که با وجود داشتن ۵ کلاس داده، تعداد نمونه‌های کلی برابر با ۲۵۰۵ نمونه می‌شوند. بنابراین ورودی یک ماتریس ۳ در ۲۵۰۵ می‌باشد. برای استفاده از شبکه عصبی، تعداد نمونه‌های خروجی نیز باید به همین تعداد باشند که در مجموع تعداد آن برابر با ۵ در ۲۵۰۵ می‌شود.

نوع شبکه عصبی مورد استفاده، شبکه عصبی پرسپترون چند لایه (Multi-Layer Perceptron (MLP)) می‌باشد که به صورت گسترده در انجام کارهای مدلسازی و تشخیص عیب مورد استفاده قرار می‌گیرد. تعداد لایه‌های پنهان را یک و تعداد نودهای لایه پنهان را برابر با ۶ عدد در نظر گرفته می‌شود. برای آموزش داده‌ها از روش آموزش Quick-Propagation (QP) استفاده می‌شود. عمل آموزش شبکه عصبی نیز با استفاده از نرم‌افزار Neural-Power انجام می‌شود.


داده‌های مختلف هر کلاس که با استفاده از نرم‌افزار Matlab در کنار هم چیده شده‌اند را می‌توان در شکل‌های (۵) تا (۷) مشاهده کرد. در شکل (۵) نمونه‌های مربوط به دور موتور در ۵ کلاس مختلف آورده شده است و محور افقی، تعداد نمونه‌ها و محور عمودی مقدار دور را گزارش می‌کند. به همین ترتیب می‌توان در شکل‌های (۶) و (۷) نیز این روند را مشاهده نمود.



شکل (۵) - نمونه‌های دور موتور برای ۵ کلاس مختلف




شکل (۶) - نمونه‌های فشار برای ۵ کلاس مختلف



شکل (۷) - نمونه‌های دما برای ۵ کلاس مختلف

نتیجه بسیار مناسب آموزش شبکه عصبی را می‌توان برای خطای TSGF در شکل (۸) به طور نمونه ملاحظه نمود. نتایج نهایی خطای بسیار مناسبی را برای آموزش شبکه گزارش می‌دهد. در واقع یک نمونه خطای TSGF برای نمونه به شبکه عصبی آموزش دیده اعمال می‌شود که شبکه عصبی آن را آخرین عیب شناسایی می‌کند. زیرا که برای نمونه‌های آخر مقدار نمودار ۱ می‌گردد. بنابراین با ملاحظه به جدول (۱) می‌توان ملاحظه نمود که نوع عیب TSGF است.


در نهایت شکل (۱۰) نتیجه حاصل از تست شبکه را به ازای یک ورودی با نوع خطای نامعلوم (شکل (۹)) انجام می‌دهد. در شکل (۹) خطای TSGF با مقدار انحراف در مقدارش (۱۰ درصد تفاوت با خطای اصلی TSGF) به عنوان تست به شبکه عصبی داده می‌شود. در واقع با انجام این کار می‌خواهیم شمولیت شبکه (generalization) را در شناسایی عیوب با محدوده‌های مختلف مورد بررسی قرار دهیم.



شکل (۸)- نتایج آموزش برای حالت TSGF

شکل (۹)- سیگنال تست خطای TSGF با تفاوت ۱۰ درصد

همان گونه که از شکل (۱۰) مشاهده می‌شود، شبکه به خوبی آموزش دیده است و توانسته به خوبی خطای آزمایشی TSFG را شناسایی نماید. چون به ازای خطای TSGF وارده به آن، مقدار ۱ را که به معنی شناسایی عیب در خروجی است، منعکس می‌نماید.



شکل (۱۰)- نتیجه تست شبکه به ازای خطای TSFG

۶- نتیجه‌گیری

در این مقاله، به تشخیص عیب موتور دیزل با استفاده از شبکه عصبی پرداخته شد. در بخش مربوط به مدل‌سازی، مدل مقدار میانگین از موتور دیزل ارائه گردید. در نهایت با استفاده از شبکه عصبی چهار عیب رایج موتور دیزل مدل‌سازی شد که با تست نتایج با توجه به عیوب نزدیک، نتایج بسیار خوبی را گزارش داد. در مجموع، ادعا می‌شود که با استفاده از این روش می‌توان عیوب اتفاق افتاده در سطح موتور دیزل را به طور مناسبی مورد شناسایی قرار داد.

۷- مراجع

- [1] E. Hendricks, S. C. Sorenson, Mean Value Engine Modeling of Spark Ignition Engines, SAE International Congress and Exposition, Detroit, 1990.
- [2] E. Hendricks, T. Vesterholm, The Analysis of Mean Value SI Engine Models, SAE International Congress and Exposition, Detroit, 1998
- [3] M. Muller, E. Hendricks, S. C. Sorenson, Mean Value of Turbocharged Spark Ignition Engines, SAE International Congress and Exposition, Detroit, 1998.
- [4] A. Chevalier, M. Muller, E. Hendricks, On the Validity of Mean Value Engine Models During Transient Operation, SAE International Congress and Exposition, Detroit, 2000.
- [5] Beard, R. Failure Accommodation in Linear System through Self-Reorganization. Dept. MVT-71-1, 1971, Man Vehicle Laboratory Cambridge, MA.
- [6] Jones, H. L. Failure Detection in Linear System. Ph.D. Thesis, 1973, MIT, Cambridge, Ma.
- [7] Willsky, A. A Survey of Design Methods for Failure Detection in Dynamic System, Automatica, No. 12, pp: 601-611, Nov. 1976
- [8] Clark, R. N. A Simplified Instrument Failure Detection Scheme. IEEE Transactions Aerospace Electron. System, Vol. 14, PP: 558-563, 1978.
- [9] Bakiotis, C. et al. parameter and Discriminate Analysis for Jet Engine Mechanical State Diagnosis, Proceeding of the IEEE Conference on Decision and Control, PP: 1-11, 1979, Piscataway, NJ.
- [10] Gerger, G. "Fault Identification of Motor Pump System Using Parameter Estimation and Patten Classification," Proceeding of 9th IFAC Congress, Budapest, Pergamon, Oxford Press, 1984.

- [11] Filbert, D. and Metzger, K. "Quality Test of Systems by Parameter Estimation", 9th IMEKO Congress, Berlin, 1982.
- [12] Isermann, R. Supervision, Fault Detection and Fault Diagnosis Methods. An Introduction, Control Engineering Practice, Vol. 5, PP: 639-652, 1997.
- [13] Patton, R. J. and Chen, J. Robust Fault Detection Using Eigenstructure Assignment: a Tutorial Consideration and some New Results, in Proceeding of the 30th IEEE Conference on Decision and Control, PP: 2242-2247, Brighton, 1991.
- [14] Gertler, J., Costin, M., Luo, Q., Fang, X. W., Hira, R. and Kowalczyk, Z. On-Board Fault Detection and Isolation for Automotive Engines Using Orthogonal Parity Equation. Invited Paper. Preprints of IFAC Conference on Fault Detection, Supervision and Safety (Baden-Baden, Germany, 1991), PP.Vol. 2, pp. 241-246.
- [15] Hofling, T. Detection of Parameter Variations by Continuous Time Parity Equations. IFAC World Congress, PP. 513-518, Sydney, Australia, 1993.
- [16] Rumelhart, D. E. and McClelland, J. L. Parallel Distributed Processing, 1986, M.I.T Press, Cambridge, Massachusetts.
- [17] J. Ritzen. Modeling and Fixed Step Simulation of a Turbo Charged Diesel Engine, Master's thesis performed in Vehicular Systems Reg nr: LiTH-ISY-EX-3442-2003, 3 Sep 2003.
- [18] M. Ramstedt. "Cylinder-by-Cylinder Diesel Engine Modeling-A Torque-based Approach". Master's thesis performed in Vehicular Systems Reg nr: LiTH-ISY-EX-3480-2004 18th June 2004.
- [19] J. Ritzen. Modelling and Fixed Step Simulation of a Turbo Charged Diesel Engine, september 2003, LiTH-ISY-EX-3442-2003.
- [20] T. Heykin. "Introduction to Neural Networks", 2004.