

تشخیص عیوب با استفاده از شبکه عصبی بر روی مدل مقدار میانگین موتور دیزل دارای توربوشارژر

علی نصیری طوسی

استادیار – دانشکده خودرو

دانشگاه علم و صنعت ایران

a_nasiri@iust.ac.ir

امیرحسین شامخی

استادیار – دانشکده مکانیک

دانشگاه صنعتی خواجه نصیرالدین طوسی

shamekhi@kntu.ac.ir

محمد حسن بهروزی

دانشجوی کارشناسی ارشد – دانشکده خودرو

دانشگاه علم و صنعت ایران

mbehrooz718@gmail.com

مهدی پلارو

دانشجوی کارشناسی ارشد – دانشکده خودرو

دانشگاه علم و صنعت ایران

mehdi_pvr@yahoo.com

چکیده:

یکی از جدیدترین زمینه‌های تحقیقات در موتورهای دیزل امروزی، پیدا کردن عیوب و دادن اخطرال به راننده 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. سپس خطاها بر روی مدل ایجاد شده تا دینامیک خطاها معلوم گردد. نهایتاً با استفاده از یک شبکه عصبی طبقبند، این خطاها به همراه حالت نرمال آموزش داده می‌شود. برای یک حالت نمونه نیز شبکه آموزش داده شده مورد تست قرار می‌گیرد که نتایج خوبی را گزارش می‌کند.

واژگان کلیدی: جریان جرمی، شبیه سازی، متغیرهای خروجی، متغیرهای ورودی، مدل مقدار میانگین، موتور دیزل.

مقدمه

در این مقاله به تشخیص برخی از عیوب احتمالی که در موتور دیزل به وجود می‌آید می‌پردازیم. در ابتدای بحث به طور کلی در مورد عیوبی که در این مقاله مورد بررسی قرار خواهیم داد، صحبت به میان می‌آید. سپس در ادامه این بخش روشی که برای تشخیص عیوب مورد استفاده قرار می‌گیرد، تبیین خواهد شد و الگوریتم پیشنهادی را شبیه‌سازی خواهیم کرد.

سیستمهای تشخیصی عیوب در موتور دیزل ابتدا توسط Oberg و Nyberg در سالهای ۱۹۹۷ و ۲۰۰۱ بر روی موتور دیزل انجام گرفت [۱]، [۲] و [۳]. در این مقاله الگوریتم تشخیص عیوب بر روی مدل ارایه شده توسط شامخی و همکاران [۴] اعمال شده است. در انتهای مقاله نیز به بررسی نتایج حاصل از شبیه‌سازی سیستم تشخیصی عیوب می‌پردازیم.

مطالعه موردی عیوب

مدل فضای حالت ما دارای یک ورودی اصلی (میزان پاشش) و سه خروجی اصلی می‌باشد که شامل دور موتور، فشار و دمای منیفولد ورودی می‌باشند که در [۴] به طور مفصل به آن پرداخته شد.

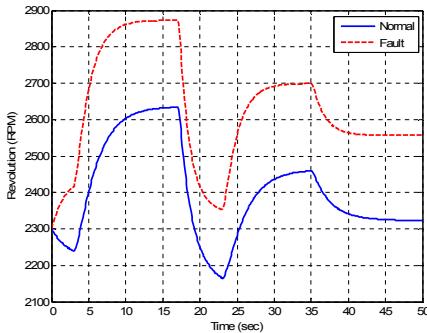
در مدل تشخیص عیوب به کار رفته در این مقاله، ۴ عیوب زیر قابل تشخیص است:

BLF: خطا ناشی در سیستم مکش (Intake System Leak Fault)

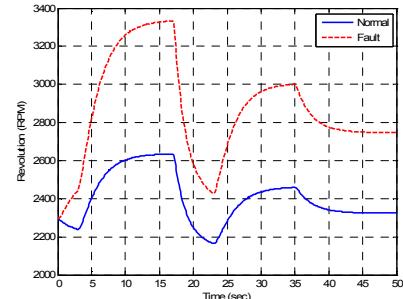
FIGF: خطا مقدار پاشش سوخت (Fuel Injection Gain Fault)

TSGF: خطا اندازه‌گیری مقدار دما (Temperature Sensor Gain Fault)

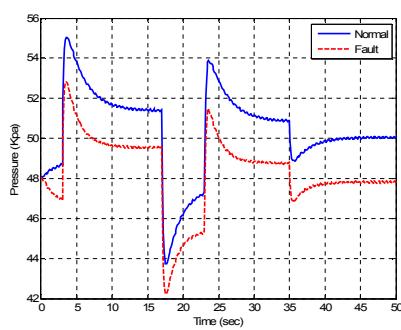
PSGF: خطا اندازه‌گیری مقدار فشار (Pressure Sensor Gain Fault)



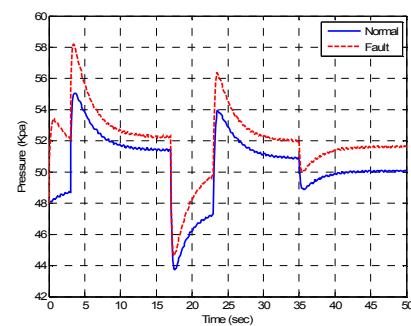
شکل (۴): تغییرات به وجود آمده در سیگنال دور به ازای خطای FIGF



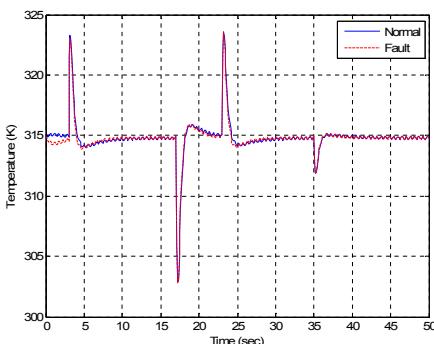
شکل (۱): تغییرات به وجود آمده در سیگنال دور به ازای خطای BLF



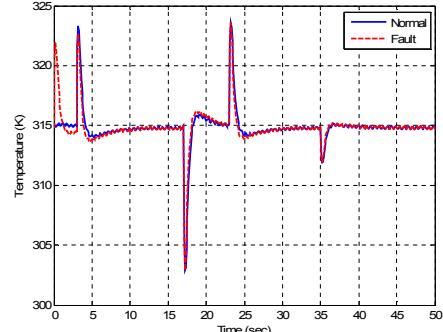
شکل (۵): تغییرات به وجود آمده در سیگنال فشار به ازای خطای FIGF



شکل (۲): تغییرات به وجود آمده در سیگنال فشار به ازای خطای BLF



شکل (۶): تغییرات به وجود آمده در سیگنال دما به ازای خطای FIGF



شکل (۳): تغییرات به وجود آمده در سیگنال دما به ازای خطای BLF

همانطوری که از شکل‌های (۴) تا (۶) مشاهده می‌شود، دور و فشار دارای تغییرات زیادی می‌باشند، اما این تغییرات برای دما بسیار ناچیز است.

عیب عیب

این نوع عیب مربوط به خطای سنسور اندازه‌گیری فشار درون منیفولد ورودی می‌شود که ممکن است به دلیل اشکال اتصال الکتریکی این سنسور رخ دهد. برای ایجاد این نوع خطأ، می‌توان مقدار بهره مربوط به سنسور دما را به میزان ۱۰ درصد کاهش داد. با این کاهش، سنسور فشار مقدار ۱۰ درصد کمتر از مقدار واقعی فشار را اندازه‌گیری می‌کند و متناظر با آن مقدار دما و دور نیز دارای تغییر می‌شود. در شکل‌های (۷) تا (۹) می‌توان تغییرات بوجود آمده ناشی از اشتباه در اندازه‌گیری فشار را به خوبی مشاهده و بررسی نمود.

همانطوری که از شکل (۳) ملاحظه می‌گردد، در اثر این عیب مقدار دما تغییرات چندانی ندارد. ولی دور و فشار به مقدار زیادی دچار تغییر می‌شود.

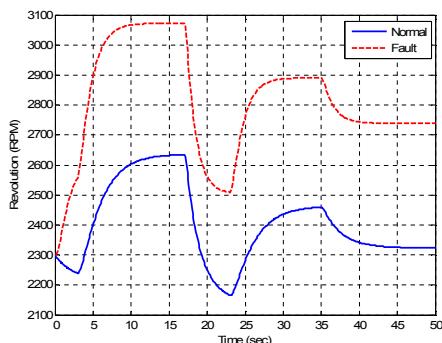
عیب FIGF

در این نوع عیب، در سیستم پاشش سوخت خطاهایی حاصل می‌شود و در نتیجه این خطا (افزایش پاشش سوخت)، تغییرات زیادی در دور موتور (به دلیل غنی‌تر شدن سوخت) و تغییرات محسوسی در فشار حاصل می‌گردد. مدل‌سازی این خطا را می‌توان با افزایش ۱۰ درصدی در میزان پاشش سوخت در قسمت مربوط به پاشش سوخت در سیمولینک انجام داد.

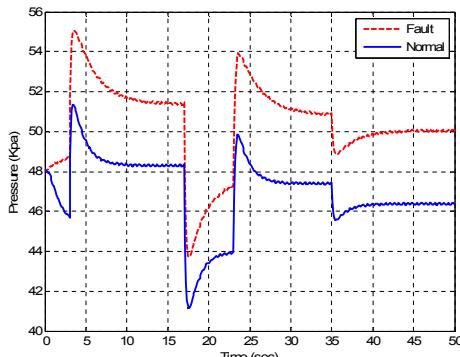
نکته دیگری که قابل بیان است، در تمام عیوب که تاکنون مورد بررسی قرار گرفت و تمام عیوبی که در ادامه مورد ملاحظه قرار می‌گیرد، چه در حالت نرمال و چه در حالت وجود عیوب، حرکت اولیه سیگنال از مقادیر اولیه‌ای که برای آن در نظر گرفته شده بود آغاز می‌شود.

TSGF عیب

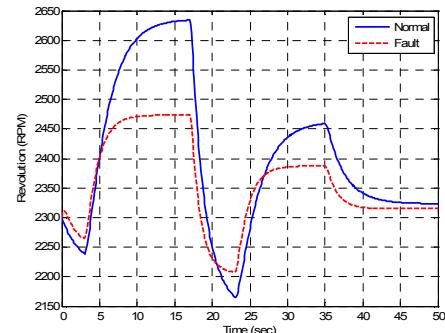
در این عیب، سنسور دما مشکل‌ساز می‌شود و قادر نیست دما را به صورت مناسبی مورد شناسایی قرار دهد. در اینجا برای ایجاد این مشکل و مدلسازی این عیب، در مدل سیمولینک، ۱۵ درصد تغییر را در سیگنال دما بوجود می‌آوریم. این نوع عیب در میزان بهره سنسور اندازه‌گیری دما رخ داده است. در شکلهای (۱۰) تا (۱۲) می‌توان تغییرات بوجود آمده در اثر این عیب در سیگنال دور موتور، فشار منیفولد و دمای منیفولد ورودی به خوبی ملاحظه نمود.



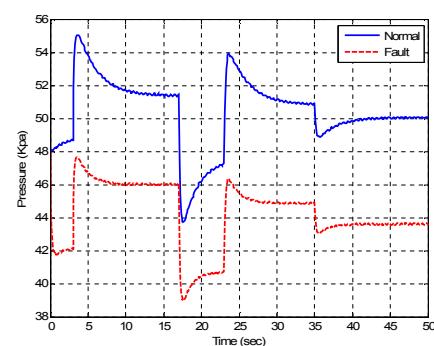
شکل (۱۰): تغییرات به وجود آمده در سیگنال دور به ازای خطای TSGF



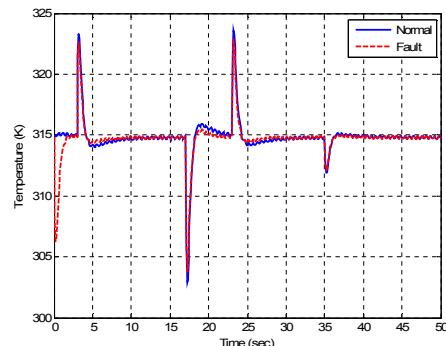
شکل (۱۱): تغییرات به وجود آمده در سیگنال فشار به ازای خطای TSGF



شکل (۷): تغییرات به وجود آمده در سیگنال دور به ازای خطای PSGF



شکل (۸): تغییرات به وجود آمده در سیگنال فشار به ازای خطای PSGF



شکل (۹): تغییرات به وجود آمده در سیگنال دما به ازای خطای PSGF

در این نوع خطای تغییرات بوجود آمده در دما از مقادیر بالاتری است و به خوبی از روی شکل مشاهده می‌گردد. ولی نمی‌توان این خطاهای را در دما به ازای عیوبی که بالاتر ذکر شد، ملاحظه نمود. همچنین تغییراتی که به ازای عیوب BLF در دور موتور بوجود می‌آمد، نسبت به حالت مقدار نهاییش دارای تفاوت زیادی با حالت نرمال بود. اما در عیوب PSGF سیگنال دور موتور پس از مدتی تمایل به آن دارد که به مقدار نهاییش متامیل گردد. اما در هیچ‌کدام از عیوبی که تا الان ذکر گردید، سیگنال فشار هیچ تمایلی به رسیدن به مقدار اولیه خود ندارد و همواره با سیگنال نرمال در یک حالت افسست عمودی قرار می‌گیرد.

بینند، آنگاه قادر است اگر شکل عیب تا حدودی تغییر یابد، کماکان آن را به عنوان همان عیب مشخص بشناسد. بدین معنی که شبکه عصبی از قدرت تعمیم (Generalization) و پیش‌بینی (Prediction) عیوب نیز برخوردار است.

در ادامه این بخش در مورد چگونگی استفاده از شبکه عصبی در عمل تشخیص عیب و نحوه وارد کردن داده به آن صحبت به میان خواهد آمد. سپس چگونگی آموزش شبکه و ساختار آن را مورد بررسی قرار می‌دهیم. برای مرتب کردن داده‌ها و استفاده از آن در شبکه عصبی از محیط MATLAB و برای انجام کارهای شبکه عصبی و آموزش آن از نرم‌افزار Neural-Power استفاده می‌کنیم.

طبقه‌بندی با استفاده از شبکه عصبی

در [۵]، توضیح کاملی در مورد چگونگی استفاده از شبکه عصبی به عنوان طبقه‌بند داده شده است. در اینجا مطلب گفته شده در [۵] را شرح می‌دهیم تا بتونیم طراحی مناسبی را با آن انجام دهیم. با توجه به اطلاعات داده شده می‌توان دریافت که شبکه عصبی همانند یک جعبه سیاه عمل می‌کند که یک سری داده را به عنوان داده ورودی و یک سری داده دیگر را به عنوان داده خروجی انتخاب می‌کند. در این میان با آموزش شبکه عصبی سعی می‌کنیم تا با تنظیم وزنهای شبکه به مقادیر خروجی‌های مطلوب برای شبکه عصبی دست یابیم.

در این مقاله، ورودی‌های شبکه عصبی عبارتند از:

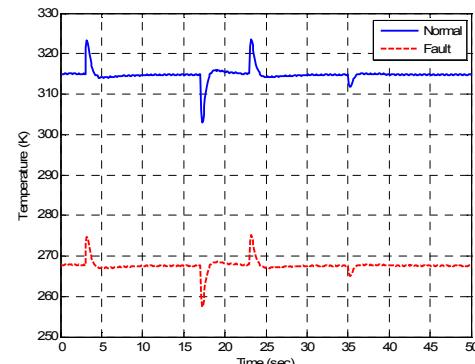
- دور موتور
- فشار منیفولد ورودی
- دمای منیفولد ورودی

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 می‌نماییم. در جدول (۱) می‌توان این بردارهای در نظر گرفته شده برای هر کدام از کلاس‌ها را مشاهده نمود. در واقع برای انجام عمل جداسازی عیوب و حالت نرمال، از چیدمان صفر و یک به صورتهای مختلف استفاده می‌شود. همواره در بحث مربوط به طبقه‌بندی با استفاده از شبکه عصبی، به تعداد کلاس‌هایی که قرار است طبقه‌بندی شوند، خروجی برای شبکه عصبی تعریف می‌شود.

جدول (۱): بردارهای طبقه‌بندی برای هر کلاس

TSGF	PSGF	FIGF	BLF	نرمال
[0]	[0]	[0]	[0]	[1]
0	0	0	1	0
0	0	1	0	0
0	1	0	0	0
[1]	[0]	[0]	[0]	[0]

کلاس‌های مختلف داده در اینجا عبارتند از:
• حالت نرمال



شکل (۱۲): تغییرات به وجود آمده در سیگنال دما به ازای خطای TSGF

در این عیب، میزان ۱۵ درصد به صورت کاهشی، در اندازه‌گیری دما ملاحظه می‌شود. یعنی در حالت ایجاد این خطای مقدار دما به صورت قابل ملاحظه‌ای کاهش یافته است. البته از آنجاییکه این مطالعه به صورت موردنی انجام می‌شود، خلی در این کار وارد نخواهد شد. چون می‌توان حالات دیگر تغییر در دما را نیز مورد ملاحظه قرار داد و مدل جدایهای برای آنها استخراج کرد. در حالت عیب در سنسور دما، مقادیر نهایی دور و فشار به هیچ وجه به مقدار نهاییشان میل نمی‌کنند و دارای خطای پایستاری در مقدار نهایی خواهیم بود. تا اینجا خطاهایی که قرار بود در این مقاله به صورت مطالعه موردنی بررسی شود را به طور کامل با جزئیات مربوطه موردن ملاحظه قرار دادیم. از این به بعد، به طراحی الگوریتم شناسایی این عیوب بوسیله شبکه عصبی می‌پردازیم.

طراحی سیستم تشخیص عیب

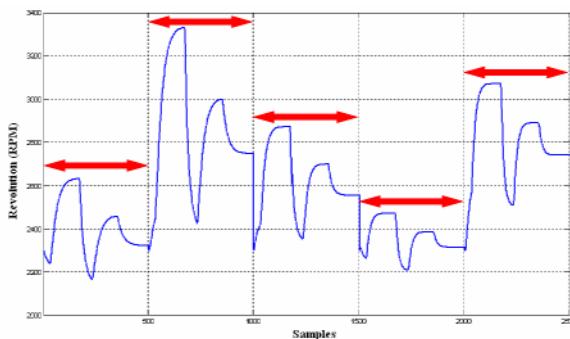
در این بخش به طراحی سیستم تشخیص عیب می‌پردازیم که قادر است عیوب شرح داده شده در بخش قبل را شناسایی نماید. روش شناسایی در اینجا روش بر مبنای مدل می‌باشد. در واقع این روش بدان معناست که تمام عیوب به طور اولیه شناخته شده هستند و حال می‌خواهیم اگر عیوبی در راستای عیهای قبلی رخ داد، سیستم شناسایی عیب قادر باشد آن را تشخیص دهد [۵].

چرا شبکه عصبی

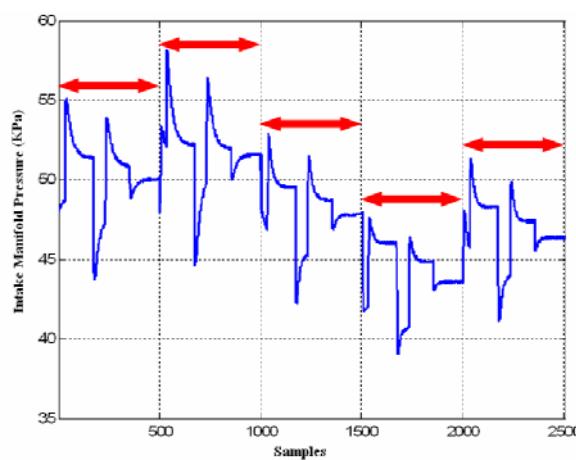
یکی از مناسبترین روش‌های تشخیص عیب، استفاده از الگوریتم‌های هوشمند برای شناسایی عیوب‌است. شبکه عصبی به دلیل استفاده زیاد در سایر مسائلی که با مساله طبقه‌بندی روبرو هستند، از پتانسیل خوبی برای استفاده در این کار برخوردار است.

شبکه عصبی که کار طبقه‌بندی را انجام می‌دهد، به دلیل سازگاری مناسب برای انجام عمل تشخیص عیب در اینجا مورد استفاده قرار گرفته است. یکی از مزایای استفاده از شبکه عصبی، میزان هزینه محاسباتی (Cost) آن است که آن را نسبت به سایر روش‌های کلاسیک مثل استفاده از روش تولید مانده مجزا می‌کند [۵].

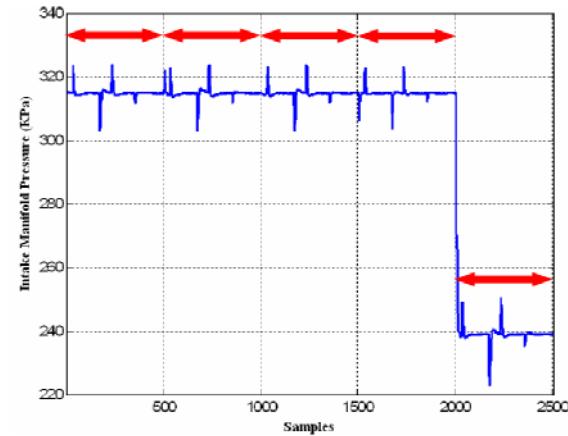
یکی دیگر از مزایای استفاده از شبکه عصبی، غیر حساس (non-sensitive) بودن آن به تغییر شکل سیگنال‌ها در عیوب مختلف می‌باشد. بدین معنی که اگر شبکه عصبی توانست یک سری عیوب را به صورت پیش فرض آموزش



شکل (۱۴): نمونه‌های دور موتور برای ۵ کلاس مختلف



شکل (۱۵): نمونه‌های فشار برای ۵ کلاس مختلف



شکل (۱۶): نمونه‌های دما برای ۵ کلاس مختلف

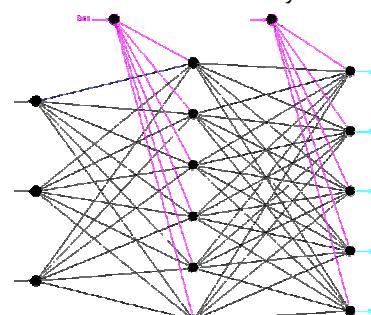
داده‌های مزبور را به نرم‌افزار Neural-Power وارد می‌کنیم و سپس نتایج خروجی را از آن استخراج می‌کنیم. این نرم‌افزار برای رسیدن به جواب نهایی حداقل به $100/000$ حلقه (epoch) نیاز دارد؛ که در این مقاله برای دقت بیشتر از $1/000/000$ حلقه تکرار استفاده شده است.

- 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 گسترش دهنده در انجام کارهای مدلسازی و تشخیص عیب مورد استفاده قرار می‌گیرد [۶]. این شبکه دارای یک لایه ورودی، یک لایه خروجی و یک یا چند لایه پنهان می‌باشد. هر چه تعداد لایه‌های پنهان بیشتر باشد، قدرت شبکه عصبی در تطبیق با داده‌های غیرخطی افزایش می‌یابد. همچنین تعداد گره‌های هر لایه پنهان، قدرت شبکه را در پردازش داده‌ها افزایش می‌دهد. اما تا آنجاییکه که امکان دارد باید شبکه را با کمترین تعداد لایه و گره آموزش داد. چون در صورت استفاده از شبکه در دنیای واقعی، باید تا جای ممکن تعداد گره‌ها و لایه‌ها کمتر باشد تا هزینه محاسباتی نیز به تناسب آن کاهش یابد.

تعداد لایه‌های پنهان را یک و تعداد نودهای لایه پنهان را برابر با ۶ عدد در نظر می‌گیریم [۶]. برای آموزش شبکه از روش Quick-Propagation (QP) استفاده می‌شود. عمل آموزش شبکه عصبی نیز با استفاده از نرم‌افزار Neural-Power انجام می‌شود. ساختار شبکه عصبی مورد بحث را می‌توان در شکل (۱۳) ملاحظه نمود.



شکل (۱۳): ساختار شبکه عصبی طبقه‌بند

داده‌های مختلف هر کلاس که با استفاده از نرم‌افزار Matlab در کنار هم چیده شده‌اند را می‌توان در شکل‌های (۱۴) تا (۱۶) ملاحظه کرد.



شکل (۲۰): نتایج آموزش برای حالت PSGF

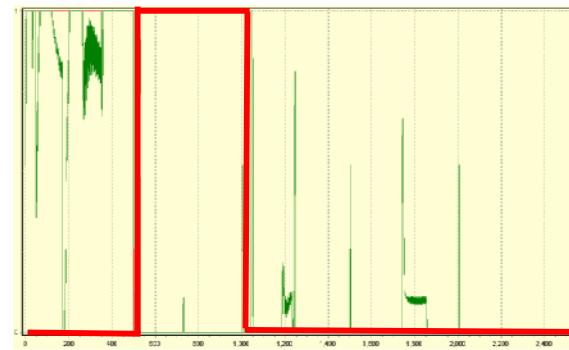


شکل (۲۱): نتایج آموزش برای حالت TSGF

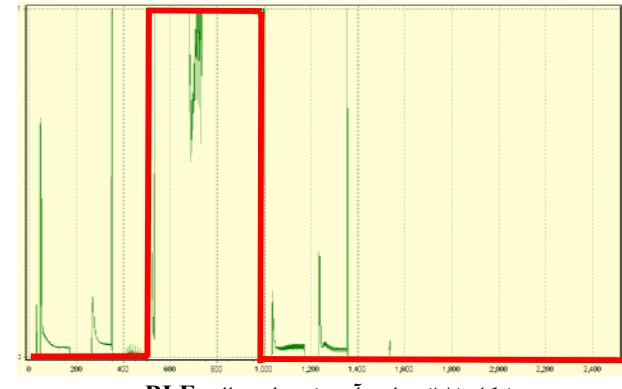
جدول (۲): مقادیر خطا برای کلاسهای مختلف

۰/۱۳۲۴۸	مقدار RMSE برای حالت نرمال
۰/۰۹۱۸۲۴	مقدار RMSE برای حالت BLF
۰/۱۷۳۸۱	مقدار RMSE برای حالت FIGF
۰/۱۴۹۴۱	مقدار RMSE برای حالت PSGF
۰/۰۱۹۴۶۵	مقدار RMSE برای حالت TSGF
۰/۱۵۳۴	مقدار متوسط

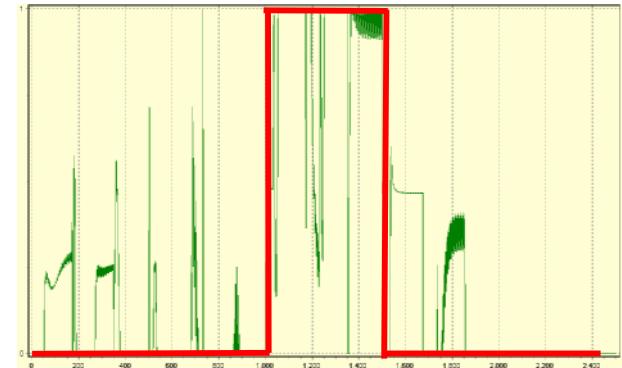
شکلهای (۱۷) تا (۲۱) نتایج حاصل از شبیه‌سازی با استفاده از شبکه را نشان می‌دهد. بهترین نتیجه آموزشی برای عیب TSGF و بدترین نتیجه آموزشی برای عیب FIGF گزارش می‌شود. در نهایت با استفاده از کد نوشته شده با Matlab نتایج نهایی را ارزیابی می‌نماییم. نتایج مربوط به RMSE (جذر جمع خطای توان دوی متوسط) را می‌توان در جدول (۲) ملاحظه نمود. این نتایج خطای بسیار مناسبی را برای آموزش شبکه گزارش می‌دهد. در نهایت نتیجه حاصل از تست شبکه را به ازای یک ورودی با نوع خطای نامعلوم انجام می‌شود که نتیجه آن در شکل (۲۲) و (۲۳) آورده شده است.



شکل (۱۷): نتایج آموزش برای حالت نرمال



شکل (۱۸): نتایج آموزش برای حالت BLF



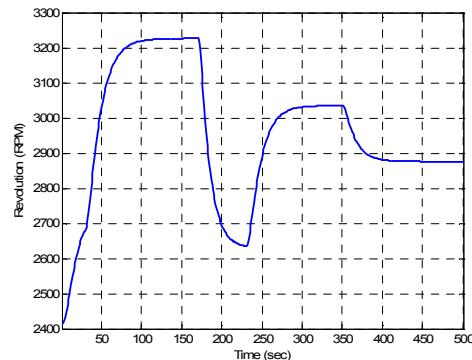
شکل (۱۹): نتایج آموزش برای حالت FIGF

[3] M. Nyberg and L. Nielsen. Model based diagnosis for the air intake system of the CI-engine. SAE Paper, (970209), 1997.

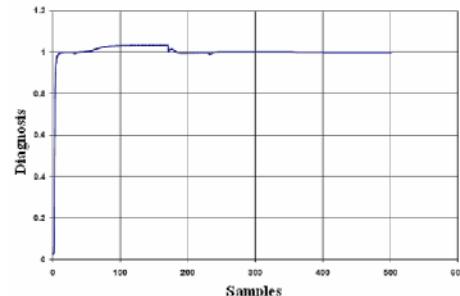
[۴] امیر حسین شامخی، علی نصیری طوسی، مهدی پلاور، محمد حسن بهروزی؛ مدلسازی مقدار میانگین موتور دیزل، کنفرانس بین المللی کرمان ۱۳۷۸

[5] Silvestry, G., Verona, F.B., Innocenti, M. and Napolitano, M. Fault Detection Using Neural Network, Neural Network, 1994 IEEE World Congress on Computational Intelligence, 1994 IEEE International Conference on, Vol 6, PP. 3796-3799 Jun. to 20 Jul. 1994.

[6] T. Heykin, "Introduction to Neural Networks", 2004.



شکل (۲۲): سیگنال تست خطای TSFG با تفاوت ۱۰ درصد از مقدار خطای اعمالی



شکل (۲۳): نتیجه تست شبکه به ازای خطای TSFG

همانطوری که از شکل (۲۳) مشاهده می‌شود، شبکه به خوبی آموزش دیده است و توانسته به خوبی خطای آزمایشی TSFG را شناسایی نماید.
نتیجه گیری

شبیه‌سازی در محیط نرم‌افزار Matlab/Simulink انجام شده و نتایج خروجی این مدل با داده‌های تجربی مقایسه شده است. خطاهای بر روی مدل ایجاد شده تا دینامیک خطاهای معلوم گردد. نهایتاً با استفاده از یک شبکه عصبی طبقه‌بند، این خطاهای به همراه حالت نرمال آموزش داده شد و برای یک حالت نمونه نیز شبکه آموزش داده شده مورد تست قرار گرفت که نتایج خوبی را گزارش می‌کند. همانطوری که از شکل (۲۳) مشاهده می‌شود، شبکه به خوبی آموزش دیده است و توانسته به خوبی خطای آزمایشی TSFG را شناسایی نماید.

مراجع

[1] S. Oberg. Identification and Improvements of an automotive diesel engine model purposed for model based diagnosis. Master's thesis LiTH-ISYEX-3161, Department of Electrical Engineering, Linkopings University, Linkoping, Sweden, December 2001.

[2] T. Stutte, M. Nyberg and V. Wilhelmi. Model based diagnosis of the Air Path of an automotive diesel engine. In IFAC Workshop: Advances in Automotive Control, Karlsruhe, Germany, 2001. IFAC Workshop: Advances in Automotive Control.