

طراحی سیستم تشخیص عیب مبتنی بر شبکه عصبی و مانده های نرمالیزه شده برای سیستم مکش موتور دیزل

رضا چینی^۱، امیر حسین شامخی^۲، سید احسان صمدانی^۳

r_chini@sina.kntu.ac.ir؛ نصیر الدین طوسی؛

shamekhi@kntu.ac.ir؛ نصیر الدین طوسی؛

e_samadani@sina.kntu.ac.ir؛ نصیر الدین طوسی؛

عیوب در سیستم های خطی پرداخت. کلارک [۲] برای اولین بار تشخیص عیب حسگرها را مطرح ساخت. پیتون و چن [۳] نیز معادلات فضای برابری^۴ را در سیستم های تشخیص عیب به کار بردن. آیزمن [۴]، گرتل [۵] و نایبرگ [۶] نیز استفاده از روش های تشخیص عیب مبتنی بر مدل را در خودروها مورد بررسی قرار دادند. با توسعه روش های هوش مصنوعی، تحقیقات در زمینه روش های تشخیص عیب مبتنی بر مدل جان تازه ای گرفت. آیزمن توانایی برتر شبکه های عصبی در تبیین فرآیند طبقه بندی را معرفی کرد [۷]. در مراجع [۸]، امکان استفاده از شبکه های عصبی در مدل سازی، کنترل، طراحی و همچنین تشخیص عیب موتور مورد بررسی قرار گرفته است.

با وجود اینکه روش های متفاوتی برای تشخیص و جداسازی عیوب وجود دارد، در حالت کلی می توان آنها را به دو دسته طبقه بندی کرد، روش های با ناظر و بدون ناظر.^۵ سورسا و کویوو بر ظرفیت بالاتر روش های با ناظر شبکه عصبی مانند توابع شعاعی^۶ و پرسپترون چند لایه ای تاکید داشتند [۹]. کاربرد شبکه های عصبی پرسپترون چند لایه ای در تشخیص عیوب موتور، قبلاً در مراجع [۱۰، ۱۱] مورد بررسی قرار گرفته است.

در مرجع [۱۲] یک سیستم نصب شده بر روی خودروی مبتنی بر شبکه عصبی توابع شعاعی، قادر به تشخیص آنی عیوب سیستم مکش یک موتور بنزینی است. مرجع [۱۳]، کاربرد یک شبکه عصبی خود-شرکت پذیر^۷ در تشخیص عیوب حسگرهای یک موتور دیزل را مورد بررسی قرار داده است. در این مقاله نشان داده شده است که این سری از شبکه های عصبی توانایی خوبی برای کاربرد در زمینه های تشخیص عیوب را دارند. چینی و همکاران [۱۴، ۱۵]، یک سیستم تشخیص عیب پوشش دهنده کلیه محدوده مجاز عیوب سیستم مکش و پاشش موتور بنزینی را پیشنهاد کرده اند.

در این مقاله کاربردی جدید از شبکه های عصبی پرسپترون چند لایه ای در آشکارسازی و جداسازی عیوب منیفولد ورودی یک موتور دیزل مورد بررسی قرار گرفته است. هدف اصلی از این کار، طراحی و اجرای یک سیستم تشخیص عیب است که نه تنها سریع و دقیق باشد بلکه دارای حجم محاسباتی اندکی نیز باشد. برای رسیدن

چکیده

بکی از اجزای اصلی سیستمهای اتوماتیک تشخیص عیب در موتور-های دیزل، تشخیص عیوب در منیفولد ورودی است. عیوب در این بخش می توانند منجر به انحراف نسبت هوا به سوخت شوند که به نوبه خود افزایش آلینده ها، احتراق ناقص و به خصوص کاهش توان و کیفیت سوای را به همراه خواهد داشت.

در این مقاله یک سیستم تشخیص عیب مبتنی بر مدل برای عیوب احتمالی در سیستم منیفولد ورودی موتورهای دیزل طراحی شده است. به این منظور، یک مدل دینامیکی غیرخطی از موتور دیزل مجهز به توربوشارژ^۸ با هندسه متغیر توربین^۹ و سیستم بازخوران گازهای خروجی^{۱۰} مورد استفاده قرار گرفته است. سپس، سیستم تشخیص عیب جدید در چارچوب شبکه های عصبی پرسپترون چند لایه^{۱۱} طبقه بند، بر روی آن پیاده سازی شده است.

نتایج شبیه سازی بیانگر این مطلب می باشد که سیستم تشخیص عیوب به خوبی توانایی آشکارسازی و جداسازی^{۱۲} شش گروه متفاوت از شرایط کاری موتور را دارا است. از جمله عیوبی که در مقالات قبلی تشخیص عیوب توسط شبکه های عصبی به ندرت به آنها پرداخته شده است، می توان به عیوب در حسگر دمای هوای منیفولد ورودی، حسگر دور موتور و عملگر پاشش سوخت اشاره کرد. به علاوه، در این کار کلیه عیوب در تمامی محدوده اندازه های مثبت و منفی ممکنه خود مورد عیب یابی قرار گرفته اند که در نوع خود کاری جدید است. کلمات کلیدی: تشخیص عیب، مدل سازی مقدار میانگین موتور، شبکه های عصبی طبقه بند، منیفولد ورودی، موتور دیزل.

مقدمه

با در نظر داشتن انعطاف پذیری و پیچیدگی موتورهای دیزل، احتمال رخ داد عیوب بالقوه در آنها افزایش می یابد. این پدیده وجود یک سیستم تشخیص عیب کارآمد را برای این سری از سیستم های دینامیکی بسیار ضروری می سازد. اولین تحقیقات صورت گرفته در زمینه تشخیص عیب سیستم های دینامیکی به دهه ۷۰ بر می گردد. بیرد [۱۱] به روش شناسایی عیب مبتنی بر مشاهده گر^{۱۲} به تشخیص

^۱Turbocharger

^۲Variable Geometry Turbine (VGT)

^۳Exhaust Gas Recirculation (EGR)

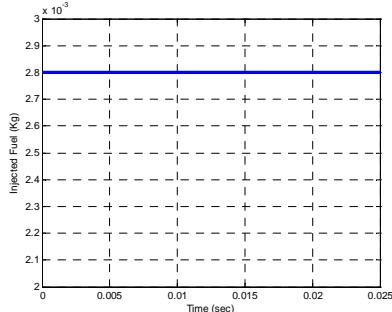
^۴Multi Layer Perceptron (MLP)

^۵Detection and Isolation

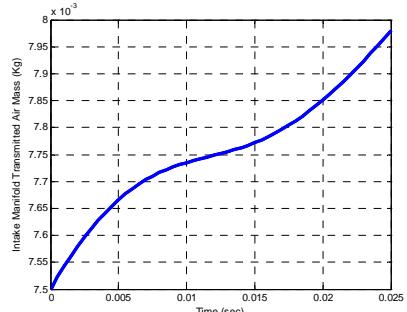
^۶Observer-Based Fault Diagnosis

عیب، به عنوان حالت بدون عیب موتور مورد استفاده و مبنایی برای مقایسه با حالت معیوب قرار گرفته است.

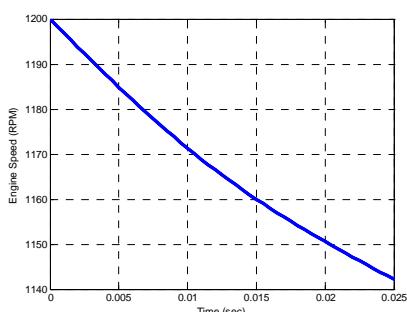
به منظور بررسی صحت مدل فوق، مدل در پنچ دور ۱۲۰۰، ۱۹۰۰، ۲۶۰۰، ۳۳۰۰ و ۴۰۰۰ (RPM) شبیه‌سازی شده است و مقادیر حاصله با نتایج تجربی به دست آمده در [۱۷] مقایسه شده است. نتیجه این مقایسه در شکل ۶ نشان داده شده است. شایان ذکر است که بیشینه خطای در دور (RPM) ۱۲۰۰ می باشد که برابر با٪۴ است



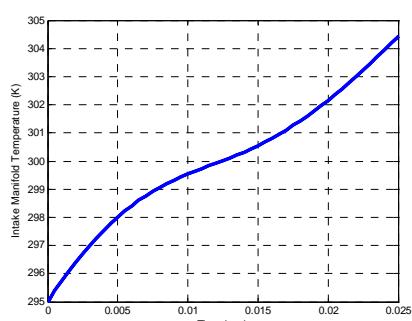
شکل ۱: مقدار سوخت پاششی بر حسب زمان



شکل ۲: تغییرات جرم هوای عبوری از منیفولد بر حسب زمان



شکل ۳: تغییرات دور موتور بر حسب زمان



شکل ۴: تغییرات دمای منیفولد بر حسب زمان

به این منظور، سیستم تشخیص عیب بر پایه استفاده از جداسازهای شبکه عصبی طراحی شده و با الگوریتم انتشار سریع^۱ مورد آموزش قرار گرفته است. نتایج به دست آمده بیانگر این مطلب است که این روش، روشهای مطمئن و کارآمد به منظور تشخیص عیوب این بخش از موتور است. روش پیشنهادی در این کار نه تنها قادر به تشخیص عیوب از پیش آموزش داده شده می باشد، بلکه به خوبی توانایی تشخیص و جداسازی مطمئن تمامی محدوده های مجاز آن سری از عیوب را نیز دارد، که در نوع خود کار جدیدی محسوب می شود. به علاوه سیستم تشخیص عیوب ارائه شده قادر به جداسازی طیف وسیعی از عیوب است که با توسعه و اعمال اصلاحات لازم، امکان کاربرد آن در صنعت خودرو سازی کشور نیز وجود خواهد داشت.

مدل سازی دینامیکی موتور دیزل

در این بخش، قسمت هایی از یک مدل دینامیکی سیستم مکش موتور دیزل به همراه توربوشارژر و سیستم باخورانی گازهای خروجی آورده شده است که به شبیه سازی رفتار سیستم در طول مرحله مکش بر حسب زمان می پردازد [۱۶]. هدف اصلی از این مدل سازی، برآورده جرم هوای ورودی به درون سیلندر در طی مرحله مکش در موتور دیزل است. در این مطالعه، مانند بخش های ضروری از مدل داریم که به نحوه ایجاد عیوب و گسترش تأثیر آن در موتور دیزل می پردازد. از اینرو، مدل دینامیکی آورده شده در این فصل تنها شامل معادلات حالتی است که عیوب در نظر گرفته شده در سیستم تشخیص عیوب، در آنها ایجاد شده اند و دارای نقش کلیدی در انتشار اثر این سری از عیوب در موتور دیزل می باشند. شرح کامل تر این مدل سازی در [۱۷] آمده است.

$$\frac{dM_{im}}{dt} = \dot{m}_c + \dot{m}_{egr} - \dot{m}_{cyl} \quad (1)$$

$$M_{im} c_p \frac{dT_{im}}{dt} = -\dot{m}_{im} c_p T_c + \dot{m}_{egr} c_p T_{eg} + \dot{m}_{cyl} c_p T_{im} \quad (2)$$

$$P_{im} = \frac{R \cdot T_{im} \cdot M_{im}}{V_{im}} \quad (3)$$

$$\frac{dN}{dt} = \frac{-W_{ad} - T_L}{J_e} \quad (4)$$

$$M_{em} c_p \frac{dM_{em}}{dt} = (\dot{m}_{fuel} + \dot{m}_{cyl}) c_p T_{eg} - \dot{m}_{egr} c_p T_{em} - \dot{m}_{em} c_p T_{em} \quad (5)$$

$$W_t = c_p (\dot{m}_c + \dot{m}_{fuel})(T_{em} - T_t) \quad (6)$$

نتایج شبیه سازی و صحه گذاری

در این قسمت، به بررسی نتایج حاصل از شبیه سازی سیستم مکش موتور دیزل مدل سازی شده در قسمت قبل می پردازیم. معادلات فوق و روابط مربوط به دیگر اجزای موتور دیزل در محیط Simulink/MATLAB و برای پنج دور مختلف شبیه سازی شده است و نتایج حاصله برای دور (RPM) ۱۲۰۰ در زیر آمده است. باقیستی توجه داشت که این نتایج در بخش طراحی سیستم تشخیص

¹ Quick Propagation

خطای عملگر پاشش سوخت^۳ (FAG)

در شرایط عملکردی FAG، عیب در عملکرد پاشش با اعمال و ضرب یک بهره اسکالار g_{FAG} به مقدار فیزیکی میزان پاشش سوخت، ایجاد می‌شود که محدوده اعمال این بهره بصورت زیر خواهد بود
 $g_{FAG} \in [-20\%, 20\%]$. رابطه (۸) بیانگر نحوه اعمال این عیب در مدل موتور دیزل می‌باشد.

$$m_{f,FAG} = m_{f,NF} + g_{FAG} m_{f,NF} \quad (8)$$

خطای حسگر فشار منیفولد ورودی^۴ (MPSG)

این نوع عیب مربوط به خطای حسگر اندازه‌گیر فشار درون منیفولد ورودی می‌شود که ممکن است به دلیل اشکال اتصال الکتریکی این حسگر رخ دهد. مدل متناسب با این عیب بر اثر خطا در خواندن میزان فشار منیفولد توسط حسگرهای مربوطه به دست می‌آید. این عیب به صورت یک ضریب بهره کاهشی و افزایشی g_{MPSG} که میزان واقعی فشار در منیفولد را کم و زیاد می‌کند، در مدل اصلی موتور اعمال می‌گردد $g_{MPSG} \in [-20\%, 20\%]$ (رابطه (۹)).

$$P_{im,MPSG} = P_{im,NF} + g_{MPSG} P_{im,NF} \quad (9)$$

خطای حسگر دمای منیفولد ورودی^۵ (MTSG)

در این عیب، حسگر دما میزان دما در داخل منیفولد ورودی را به صورت ضریبی از میزان واقعی آن گزارش می‌کند. این مقدار می‌تواند بنا به مثبت یا منفی بدون ضریب بهره جایگذاری شده، زیادتر یا کمتر از مقدار فیزیکی خوانده شود $g_{MTSG} \in [-20\%, 20\%]$. رابطه (۱۰) بیانگر نحوه اعمال این عیب در مدل می‌باشد.

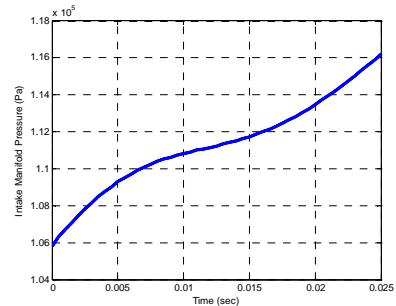
$$T_{im,MTSG} = T_{im,NF} + g_{MTSG} T_{im,NF} \quad (10)$$

خطای حسگر دور موتور^۶ (RSG)

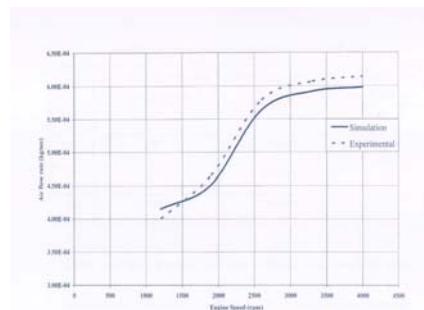
ممکن‌آن حسگر دور موتور قابل اعتماد بوده و عیوب در این حسگر به ندرت گزارش شده است. اما به علت تاثیر این عیب بر دینامیک هوای منیفولد ورودی، تاثیر آن در سیستم تشخیص عیب طراحی شده دیده شده است. این عیب به صورت ضریب بهره g_{RSG} در معادلات ظاهر می‌شود $g_{RSG} \in [-20\%, 20\%]$. رابطه (۱۱) بیانگر نحوه اعمال این عیب بر مدل موتور دیزل موجود می‌باشد.

$$N_{RSG} = N_{NF} + g_{RSG} N_{NF} \quad (11)$$

به عنوان مثال، شکل‌های ۷ و ۸ تاثیر عیوب مدل‌سازی شده بالا را بر روی عملکرد حسگر دمای مدل موتور دیزل نشان می‌دهند. بزرگی عیوب مدل‌سازی شده در جدول ۱ آورده شده است.



شکل ۵: تغییرات فشار منیفولد بر حسب زمان



شکل ۶: صحه‌گذاری نتایج مدل‌سازی با نتایج تجربی [۱۷]

مدل‌سازی عیوب

به منظور حفظ کلیت کار، هر سه نوع عیب ممکن در طراحی سیستم تشخیص عیب لحاظ شده است [۴، ۳].

حالت بدون عیوب یا نرمال^۱ (NF)

در این حالت عملکردی تمامی حسگرها و عملگرها به درستی کارکرد و هیچگونه نشتی در دیواره منیفولد ورودی وجود ندارد.

خطای نشتی در منیفولد ورودی^۲ (IL)

این عیوب توسط ایجاد یک محفظه یا سوراخ در دیواره منیفولد ورودی به وجود می‌آید. در اثر این عیوب، هوای خارج از منیفولد راه پیدا می‌کند که در نهایت موجب کاهش هوای ورودی به سیلندرها می‌شود. علت این امر، وجود سیستم توربوشارژ در موتور است که موجب بالاتر رفتن فشار منیفولد نسبت به فشار محیط می‌شود. در نتیجه با ایجاد یک سوراخ در دیواره منیفولد، هوای همواره در جهت خارج از منیفولد جریان می‌یابد. مدل خطای نشتی در دیواره منیفولد با استفاده از مدل حالت نرمال و جایگذاری رابطه (۷) در آن به دست می‌آید. این رابطه با اعمال یک ضریب بهره کاهشی g_{IL} با محدوده تغییرات بین ۰٪ تا ۲۰٪، موجب کاهش میزان هوای عبوری از منیفولد خواهد شد $g_{IL} \in [0, 20\%]$. آشکار است که $g_{IL} = 0$ بیانگر حالت نرمال خواهد بود.

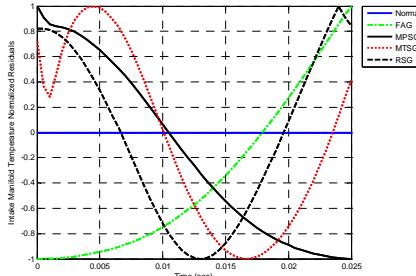
$$M_{im,IL} = M_{im,NF} + g_{IL} M_{im,NF} \quad (Y)$$

Fuel Injection Actuator Gain Fault^۷
Manifold Pressure Sensor Gain Fault^۸
Manifold Temperature Sensor Gain Fault^۹
RPM Sensor Gain Fault^{۱۰}

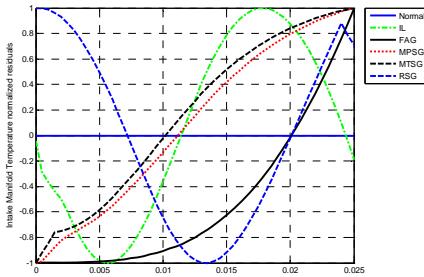
No Fault^۱
Intake Manifold Leakage^{۱۱}

$$\text{Normalized residuals} = \frac{\Delta y(t)}{|\Delta y(t)|} \quad (13)$$

به منظور طراحی دو شبکه عصبی کاملاً مجزا که قادر به جداسازی عیوب در تمامی بازه‌های مجاز باشند، عیوب مشخصی را انتخاب و به عنوان داده‌های ورودی شبکه عصبی وارد محیط MATLAB کردۀ‌ایم. این عیوب و بزرگی آنها در جدول ۱ آورده شده‌اند. در انتخاب این ترتیب از عیوب سعی شده است که ضریب بهره خطاهای در میانه بازه مجاز مثبت و منفی مدل‌سازی شده در مدل موتور قرار گیرند. شیوه کنونی انتخاب عیوب این امکان را به ما می‌دهد که حداکثر استفاده را از قدرت تعمیم و پیش‌بینی شبکه‌های عصبی به منظور تشخیص و جداسازی عیوب در کلیه بازه‌های مجاز ببریم. به عنوان مثال، شکل‌های ۹ و ۱۰ مانده‌های نرمالیزه شده حسگر دمای مدل موتور دیزل را برای عیوب آمده در جدول ۱ نشان می‌دهند.



شکل ۹: تغییرات مانده نرمالیزه مثبت دمای منیفولد برای عیوب مختلف بر حسب زمان



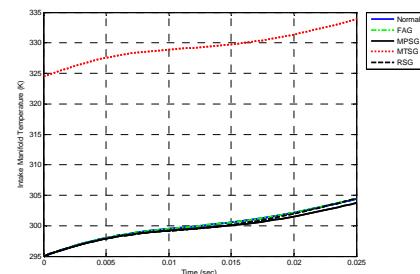
شکل ۱۰: تغییرات مانده نرمالیزه منفی دمای منیفولد برای عیوب مختلف بر حسب زمان

انحراف داده‌های واقعی از مقادیر مشابه گزارش شده از شبکه عصبی، به عنوان خطای شبکه تعریف می‌شود. این خطاهای بر اساس رابطه خطای مریع میانگین^۱ محاسبه می‌شوند.

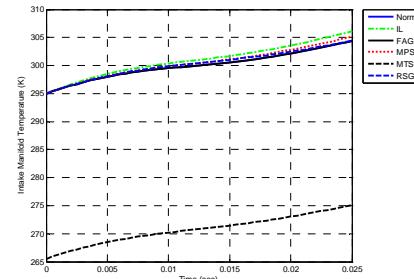
$$MSE = \sum_{p=1}^P \sum_{i=1}^N \left(Y_{real}^{p,i} - Y_{predicted}^{p,i} \right)^2 \quad (14)$$

که "z" تعداد گره‌ها در لایه خروجی، "p" تعداد نمونه‌های زمانی، "Y_{predicted}" خروجی شبکه عصبی و "Y_{real}" داده‌های واقعی برگرفته از موتور دیزل می‌باشد. برای هر کدام از کلاس‌ها یک بردار را به عنوان خروجی انتخاب می‌نماییم. در جداول ۲ و ۳ می‌توان بردار اختصاص یافته به هر یک از کلاس‌ها را مشاهده نمود.

¹ Mean Square Error (MSE)



شکل ۷: تغییرات دمای منیفولد به ازای مدل‌سازی مثبت عیوب مختلف بر حسب زمان



شکل ۸: تغییرات دمای منیفولد به ازای مدل‌سازی منفی عیوب مختلف بر حسب زمان

جدول ۱: مقادیر ویژه ورودی‌های شبکه‌های عصبی در مرحله آموزش

	شبکه عصبی	IL	FAG	MPSG	MTSG	RSG
مثبت	---	10%	10%	10%	10%	10%
منفی	-10%	-10%	-10%	-10%	-10%	-10%

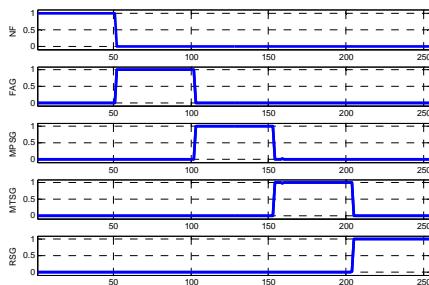
طراحی سیستم تشخیص عیوب و بررسی نتایج

در این بحث، دو شبکه عصبی مجرزا، طراحی و سپس آموزش داده شده‌اند تا عیوب از پیش تعریف شده در منیفولد ورودی موتور دیزل را مورد شناسایی و جداسازی قرار دهند. شبکه عصبی اول عیوب مثبت (با ضریب بهره خطای مثبت) و شبکه عصبی دوم عیوب منفی (با ضریب بهره خطای منفی) را مورد تشخیص قرار می‌دهند. ورودی‌های شبکه عصبی، داده‌های برگرفته از شرایط عملکردی موتور می‌باشند. ورودی‌های شبکه، میزان سوخت پاششی، میزان جرم هوای عبوری از منیفولد ورودی، دور موتور، فشار منیفولد ورودی و دمای منیفولد ورودی موتور در نظر گرفته شده‌اند. اولین قدم به منظور تولید مانده‌ها، برآورد انحراف سیگنال‌های خروجی $y(t)$ ، از سیگنال‌های حاصله از مدل در حالت عملکرد نرمال $\bar{y}(t)$ می‌باشد.

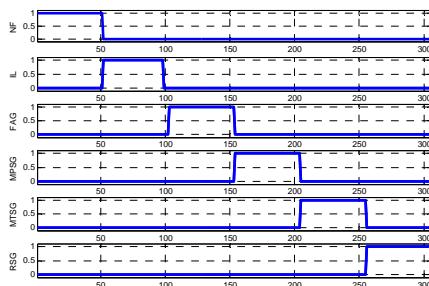
$$\Delta y(t) = y(t) - \bar{y}(t) \quad (12)$$

به منظور کاهش حساسیت نسبت به اغتشاشات و همچنین ورودی‌های مزاحم مدل نشده، بهتر است خطاهای به دست آمده از رابطه فوق را نرمالیزه کنیم. با نرمالیزه کردن مانده‌های بین ۱ و -۱ در واقع امکان تاثیر ناجای اندازه تغییرات را در سیستم به حداقل می‌رسانیم. قابل ذکر است که فرآیند محاسبه مانده‌های نرمالیزه شده در هر گام محاسباتی مدل که ۵۰۰۰ تا ۵۰۰۰۰ ثانیه می‌باشد، انجام پذیرفته است.

به منظور امتحان توانایی شبکه‌های عصبی در تشخیص عیوب آموزش داده شده، این خطاهای دوباره به عنوان ورودی به شبکه‌های عصبی داده می‌شوند. نتایج عملکردی این دو شبکه در شکل‌های ۱۳ و ۱۴ نشان داده شده است. همان‌گونه که انتظار داشتیم هر دو شبکه عصبی به خوبی قادر به تشخیص و جداسازی این عیوب هستند.



شکل ۱۳: خروجی شبکه عصبی مثبت نسبت به عیوب آموزش داده شده



شکل ۱۴: خروجی شبکه عصبی منفی نسبت به عیوب آموزش داده شده

در هر دو شکل، اولین گروه 51×5 در شبکه مثبت و 6×51 در شبکه منفی بیانگر واکنش شبکه عصبی به حالت نرمال است، در حالی که دیگر گروه‌ها (با توجه به جدول ۱) نشانگر واکنش شبکه‌ها به دیگر کلاس‌های عیوب می‌باشند. همان‌طور که از این شکل‌ها بر می‌آید، عملکرد شبکه‌ها بسیار خوب است. زیرا تقریباً مقادیر تمامی نمونه‌ها در ستون وابسته به عیوب یک می‌باشد، در حالی که در ستون وابسته به دیگر عیوب صفر است.

به منظور امتحان توانایی و برآورد قدرت تعمیم و پیش‌بینی شبکه‌های عصبی مثبت و منفی، مقادیر مختلف عیب MPSG به عنوان ورودی به سیستم تشخیص عیب انتخاب شده است. به همین منظور دو کرانه بالایی و پایینی مثبت و منفی این عیب در موتور دیزل شبیه‌سازی شده و نتایج این شبیه‌سازی به سیستم تشخیص عیب خورانده شده است. همان‌گونه که در شکل ۱۵ نشان داده شده است، خطوط پیوسته بیانگر مانده‌های نرمالیزه شده عیب $g_{MPSG} = 3\%$ و خطوط گسسته بیانگر عیب $g_{MPSG} = -20\%$ باشد. به همین صورت در شکل ۱۶ خطوط پیوسته بیانگر مانده‌های نرمالیزه شده عیب $g_{MPSG} = -3\%$ و خطوط گسسته بیانگر عیب $g_{MPSG} = -20\%$ است.

اغتشاشات و ورودی‌های مزاحم مدل نشده مهمترین عوامل ایجاد هشدار نادرست می‌باشند. به منظور بالا بردن اینمی سیستم تشخیص

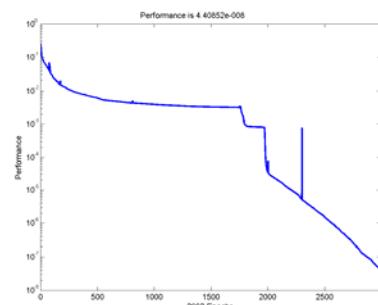
جدول ۲: بردارهای طبقه‌بندی برای هر کلاس در شبکه مثبت

نرمال	FAG	MPSG	MTSG	RSG
[1]	[0]	[0]	[0]	[0]
0	1	0	0	0
0	0	1	0	0
0	0	0	1	0
0	0	0	0	1

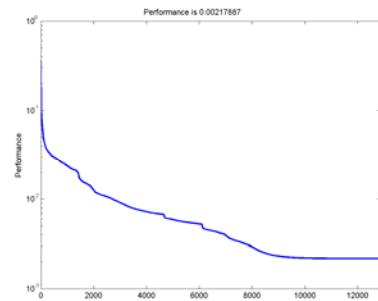
جدول ۳: بردارهای طبقه‌بندی برای هر کلاس در شبکه منفی

نرمال	IL	FAG	MPSG	MTSG	RSG
[1]	[0]	[0]	[0]	[0]	[0]
0	1	0	0	0	0
0	0	1	0	0	0
0	0	0	1	0	0
0	0	0	0	1	0
0	0	0	0	0	1

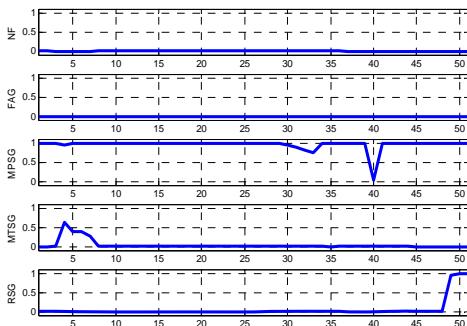
تعداد لایه‌های پنهان را یک و تعداد گره‌های لایه پنهان را برابر با ۱۰ عدد در نظر می‌گیریم. بنابراین شبکه عصبی دارای ۵ ورودی و ۶ خروجی به ترتیب در حالات عیوب مثبت و منفی خواهد بود. هر کدام از کلاسهای ورودی با استفاده از نرم افزار MATLAB به صورت سری پشت سر هم چیده می‌شوند و در نهایت به روش انتشار سریع مورد آموزش قرار می‌گیرند. شکل‌های ۱۱ و ۱۲ دقت همگرایی و آموزش شبکه‌های عصبی مثبت و منفی را نشان می‌دهند. همان‌گونه که ملاحظه می‌شود، هر دو شبکه عصبی با دقت فوق العاده بالایی مورد آموزش قرار گرفته‌اند. این دقت در شبکه‌های عصبی مثبت و منفی به ترتیب برابر با $MSE = 4.4 \times 10^{-8}$ و $MSE = 2.2 \times 10^{-3}$ می‌باشد.



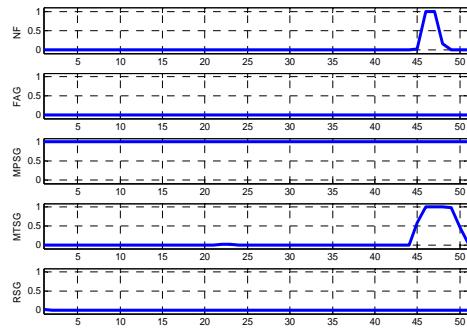
شکل ۱۱: منحنی دقت آموزش شبکه عصبی مثبت



شکل ۱۲: منحنی دقت آموزش شبکه عصبی منفی



شکل ۱۷: خروجی شبکه عصبی مثبت نسبت به کرانه مثبت پایین MPSG

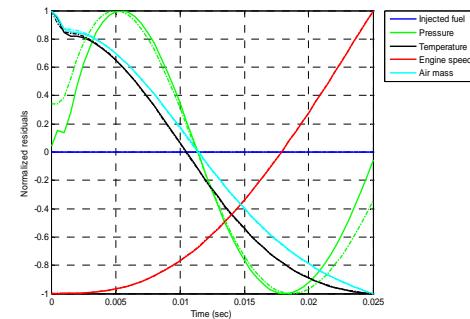


شکل ۱۸: خروجی شبکه عصبی مثبت نسبت به کرانه مثبت بالای MPSG

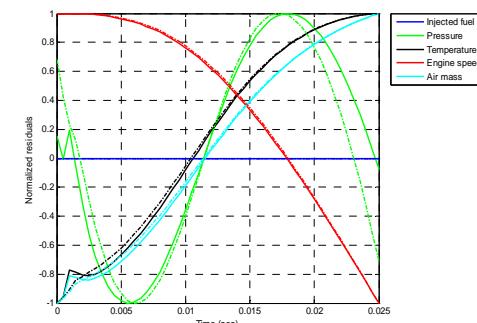
رفتار مشابهی در شکل ۱۸ قابل مشاهده است. شبکه عصبی مثبت در این درصد از عیوب نیز به خوبی قادر به جداسازی و تشخیص عیوب می‌باشد. در این حالت عملکردی، سیستم تشخیص عیوب کوچکترین وابستگی به کلاس‌های FAG و RSG ندارد. اما اغتشاشات کمی در ردیف مربوط به NF و MPSG مشاهده می‌شود. از آنجا که تمام مقادیر نمونه‌ها برای حالت MPSG یک شده است، شبکه عصبی به نظر می‌رسد کوچکترین وابستگی به دیگر حالتها و عملکرد خطاهای برای تشخیص عیوب $g_{\text{MPSG}} = 20\%$ ندارد. بنابراین در کل، شبکه عصبی مثبت در تشخیص کرانه‌های مثبت عیوب MPSG به خوبی عمل کرده و تقریباً در جداسازی تمامی مقادیر این عیوب کوچکترین حساسیتی نسبت به دیگر کلاس‌های عیوب ندارد.

شکل‌های ۱۹ و ۲۰ بیانگر عملکرد شبکه عصبی منفی در جداسازی کرانه‌های منفی عیوب MPSG می‌باشد. در شکل ۱۹ ملاحظه می‌شود که شبکه عصبی منفی نسبت به دو حالت عملکردی NF و MTSG کاملاً مستقل است. در عوض اغتشاشاتی در ردیف‌های مربوط به عیوب IL و RSG مشاهده می‌شود. این انحرافات از صفر در عیوب IL شدیدتر از عیوب RSG است. این اغتشاشات موجب کاهش عملکرد سیستم در تشخیص کرانه بالا و منفی عیوب MPSG می‌شود. اصطلاحاً در این حالت، سیستم تشخیص عیوب طراحی شده تمایل به گزارش دو عیوب IL و RSG به جای عیوب MPSG را دارد. علت این امر را می‌توان به خصوصیات غیرخطی مدل در واکنش به عیوب ایجاد شده دانست. در شرایطی که عیوب حادثه از حالت آموزش داده شده شبکه فاصله می‌گیرند، شبکه عصبی شروع به تعمیم و پیش‌بینی شرایط جدید می‌کند. در

عیب نسبت به این گزارش‌های عیوب غلط، میزان عیوب کوچک در سیستم را به حداقل 3% و 3% -افزایش می‌دهیم. در این حالت سیستم تشخیص عیوب به جای این که خطاهای با ضریب بهره افزایشی یا کاهشی بزرگتر از 3% را به عنوان عیوب گزارش کند، عملاً عیوبی را که بزرگی آنها بیشتر از 3% باشد را به عنوان عیوب اعلام می‌دارد. با این کار حساسیت سیستم را نسبت به اغتشاشات و ورودی‌های مزاحم مدل نشده تا حدود زیادی کاهش می‌دهیم.



شکل ۱۵: مانده های نرمالیزه کرانه های مثبت MPSG



شکل ۱۶: مانده های نرمالیزه کرانه های منفی MPSG

همان‌طوریکه که در شکل‌های ۱۷ و ۱۸ مشاهده می‌شود، شبکه عصبی مثبت به خوبی قادر به تشخیص و جداسازی کرانه‌های مثبت عیوب MPSG است.

با توجه به شکل ۱۷، ملاحظه می‌شود که شبکه عصبی در تشخیص کرانه پایین عیوب MPSG به کلاس‌های FAG، NF و MTSG دیدگیر ندارد. با این وجود، انحرافاتی از مقدار صفر در ردیف مربوط به عیوب RSG دیده می‌شود. این انحرافات را نمی‌توان از دو شکل به دست آمده از خوراندن عیوب دوره آموزشی خود شبکه پیش‌بینی نمود (اشکال ۱۳ و ۱۴). چون در این اشکال هیچ نشانه‌ای از وابستگی شبکه عصبی در تشخیص یک عیوب خاص به دیگر عیوب وجود ندارد. انحرافات موجود در ردیف RSG و MTSG شکل ۱۷ نیز به هیچ وجه نگران کننده نیستند. زیرا میزان این عدم صفر بودن بسیار کم است. بنابراین در این حالت کاری، عیوب $g_{\text{MPSG}} = 3\%$ به خوبی قابل تشخیص و جداسازی است بدون آنکه با دیگر عیوب موجود در سیستم اشتباه شود.

که "P" و "N" عملکرد شبکه عصبی مثبت و منفی، "ا" و "ج" به ترتیب نماینده کلاس‌های عیب اعمالی و مقادیر متناظر آنها می‌باشند. "O" بیانگر خروجی هر نمونه از شبکه عصبی بر اثر اعمال عیب مربوطه (بین صفر و یک) و "F" نشان‌دهنده تمامی کلاس‌های عیب موجود در سیستم مورد نظر می‌باشد که سیستم تشخیص عیب طراحی شده قادر به تشخیص آنها خواهد بود. در نهایت "n" تعداد نمونه‌های تشکیل دهنده هر کلاس عیب است. لازم به ذکر است که شاخص‌های عملکردی "P" و "N" بردارهای اسکالاری هستند که به ترتیب دارای پنج و شش آرایه می‌باشند.

با ایستی توجه داشت که علیرغم وجود وابستگی‌ها میان کلاس‌های مختلف عیوب، عیب صحیح همواره دارای شاخص عملکردی بالاتر از دیگر کلاس‌ها است که این خود همواره موجب تشخیص و جداسازی صحیح عیب مورد نظر در سیستم تشخیص عیب طراحی شده می‌شود. به گونه‌ای که استفاده از این روش با کمی تغییرات در صنعت خودروسازی پیشنهاد می‌گردد (جدول ۴).

جدول ۴: عکس العمل شبکه‌های عصبی مثبت و منفی به تمامی محدوده‌های کلاس‌های عیوب

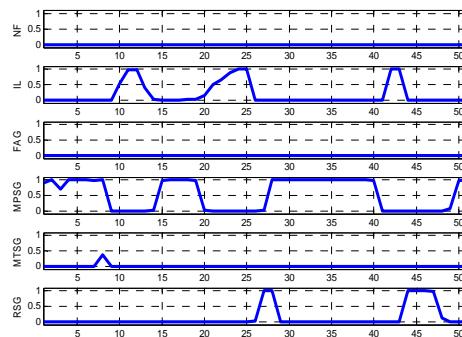
	F (%)	NF	IL	FAG	MPSG	MTSG	RSG
NF	----	51	0	0	0	0	0
IL	-3	0	41	0	2	5	2
	-20	0	40	0	0	1	6
FAG	-20	0	1	51	0	0	6
	-3	0	3	49	0	0	0
	3	0	----	38	0	9	7
	20	0	----	47	6	0	0
MPSG	-20	0	1	0	38	7	7
	-3	0	9	0	28	0	6
	3	0	----	0	49	2	3
	20	2	----	0	51	5	0
MTSG	-20	0	6	0	3	44	3
	-3	0	1	0	3	47	0
	3	0	----	0	1	50	0
	20	0	----	0	0	51	0
RSG	-20	1	0	0	3	0	47
	-3	1	0	0	0	0	50
	3	0	----	0	0	9	43
	20	7	----	0	1	0	46

نتیجه‌گیری و جمع‌بندی

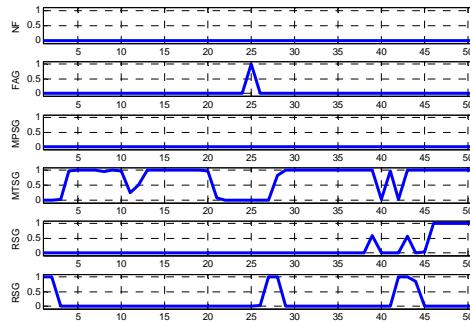
در این مقاله یک سیستم تشخیص عیب مبتنی بر شبکه‌های عصبی پرسپترون چندلایه‌ای و مانده‌های نرمال، به منظور تشخیص عیوب منیفولد ورودی یک موتور دیزل طراحی شده است. نتایج نشان می‌دهند که علیرغم سادگی و حجم کم، این سیستم تشخیص عیب قادر به تشخیص و جداسازی تمامی محدوده‌های منفی و مثبت عیوب با دقت بالا می‌باشد. به علاوه، این سیستم تشخیص عیب ارائه شده توانایی تشخیص عیوب نسبتاً زیادی را داردست که با اعمال اصلاحات لازمه امکان کاربرد آن در دیگر سیستم‌های پیچیده نیز وجود خواهد داشت.

این حالت، میزان درستی این پیش‌بینی به طراحی شبکه و میزان غیرخطی بودن سیستم بستگی دارد. هرچه میزان این پیش‌بینی از عملکرد سیستم دقیق‌تر باشد، سیستم تشخیص عیب در تشخیص و جداسازی عیب مورد نظر موفق‌تر عمل می‌کند.

شبکه عصبی منفی در تشخیص کرانه پایین عیب MPSG عملکردی متفاوت را با حالت قبل دارد. همان‌گونه که در شکل ۲۰ مشاهده می‌شود، شبکه عصبی نسبت به حالات عملکردی NF و FAG کاملاً غیرحساس است. به علاوه، میزان حساسیت سیستم تشخیص عیب نسبت به عیوب IL، MTSG و RSG نیز کم است. اغتشاشات موجود در این عیوب، کمتر از حالت قبل بوده و شبکه عصبی تمایل کمتری به اشتباہ گزارش دادن عیب MPSG در کرانه پایین منفی خود را دارد.



شکل ۱۹: خروجی شبکه عصبی منفی نسبت به کرانه منفی بالای MPSG



شکل ۲۰: خروجی شبکه عصبی منفی نسبت به کرانه منفی پایین MPSG

با وجود این که این اغتشاشات به ویژه در حالت کرانه پایین منفی عیب MPSG توانایی سیستم تشخیص عیب را در جداسازی عیب صحیح دشوار کرده است، اما این سیستم همچنان قادر است کار تشخیص عیب را به خوبی انجام دهد. به منظور اثبات درستی این مطلب جدول ۴ که شامل عکس العمل این دو شبکه عصبی به تمامی حدود کلاس‌های عیوب می‌باشد، تهیه شده است. مقادیر ارائه شده در این جدول با انتگرال‌گیری از مقادیر نمونه‌های زمانی خروجی از شبکه‌ها در واکنش به هر یک از کلاس‌های عیوب محاسبه شده‌است. رابطه‌های ۱۵ و ۱۶ بیانگر نحوه اعمال این انتگرال‌گیری می‌باشد.

$$P_j^i = \left[\sum_{n=1}^{501} O_{F,n} \right] \quad (15)$$

$$N_j^i = \left[\sum_{n=1}^{501} O_{F,n} \right] \quad (16)$$

فهرست علائم

[5]- Gertler, J., Costin, M., Fang, X., Hira, R., Kowalcuk, Z., and Luo, Q., "Model based on board fault detection and diagnosis for automotive engines," Control Engineering Practice, Vol. 1(1), pp. 3–17, 1993.	C_p	گرمای ویژه فشار ثابت، KJ/Kg.K
[6]- Nyberg, M., "Model based diagnosis of the air path of an automotive diesel engine," Control Engineering Practice, Vol. 12, pp. 513-525, 2004.	J	اینرسی، Kg.m ²
[7]- Isermann, R., "Process fault-detection based on modelling and estimation methods – a survey," Automatica, Vol. 20, pp. 387-404, 1984.	M	جرم، Kg
[8]- Tan, Y., and Saif, M., "Neural-networks-based nonlinear dynamic modelling for automotive engines," Neurocomputing, Vol. 30, pp. 129–142, 2000.	m	جرم، Kg
[9]- Sorsa, T., and Koivo, H. N., "Applications of artificial neural networks in process fault diagnosis," Automatica, Vol. 29(4), pp. 843-849, 1993.	N	سرعت موتور، RPM
[10]- Capriglione, D., Liguori, C., and Pianese, C., "On line sensor fault detection, isolation and accommodation in automotive engines," IEEE Transactions on Instruments and measurements, Vol. 52(4), pp. 1182-1189, 2003.	P	فشار، kPa
[11]- Shayler, J. P., Goodman, M., and Ma, T., "The exploitation of neural networks in automotive engine management systems," Engineering Applications of Artificial Intelligence, Vol. 13, pp. 147-157, 2000.	R	ثابت گاز، KJ/Kg.K
[12]- Sangha, M. S., Yu, D. L. and Gomm, J. B., " On-board monitoring and diagnosis for spark ignition engine air path via adaptive neural networks," Journal of Automobile Engineering, Vol. 220, Part D, PP:1641-1655, 2006.	t	زمان، sec
[13]- Antory, D., "Fault diagnosis application in an automotive diesel engine using auto-associative neural networks," IEEE Conference on Computational Intelligence for Modeling, Control and Automation and International Conference on Intelligent Agents, Web Technologies and Internet Commerce, CIMCA-IAWTIC'05, 0-7695-2504-0/05, 2005.	T	دما، K
[14]- Chini, R., Shamekhi, A. H., Behroozi, M. H., and Samadani, E., "A Neural Network Fault Diagnosis Method Applied for Faults in Intake System of a Spark Ignition Engine Using Normalized Process Variables," Accepted for publication in IEEE ICCAS2008, COEX, Seoul, Korea, 2008.	T	گشتاور، N.m
[15]- Chini, R., Shamekhi, A. H., Behroozi, M. H., and Samadani, E., "Intake Manifold Fault Diagnosis of a Spark Ignition Engine Using Residuals and Neural Network Classifier," Accepted for publication in IEEE SICE2008, Chofu, Tokyo, Japan, 2008.	V	حجم، m ³
[16]- Shamdani, A. H., Shamekhi, A. H., Ziabasharagh, M, Aghanajafi, C., "Air-to-Fuel Ratio Control of a Turbocharged Diesel Engine Equipped with EGR using Fuzzy Logic Controller," SAE World Conference, 2007-07-0976, Detroit, Michigan, USA, 2007.	W	کار و انرژی، KJ
[۱۷]- شمدانی، امیر حسین، "کنترل نسبت هوا به سوخت موتور دیزل مجهز به توربوشارژر با استفاده از کنترل فازی" پایان نامه کارشناسی ارشد، دانشکده مهندسی مکانیک، دانشگاه صنعتی خواجه نصیر طوسی، ۱۳۸۵.	cyl	زیرنویس
	e	ترمزی
	eg	کمپرسور
	egr	سیلندر
	em	بلوک سیلندر
	im	گازهای خروجی
	$fuel$	منیفولد ورودی
	L	سوخت پاششی
	t	بار
		توربین

مراجع

- [1]- Beard, R., "Failure Accommodation in Linear systems though self-Reorganization," Dept. MVT-71-1, Man Vehicle Laboratory, Cambridge, MA, 1971.
- [2]- Clark, R. N., "A Simplified Instrument Failure Detection Scheme," IEEE Transactions Aerospace Electronic System, Vol. 14, pp. 558-563, 1978.
- [3]- Patton, R. J., and Chen, J., "Robust Fault Detection Using Eigen structure Assignment, a Tutorial Consideration and some New Results," in Proceeding of the 30th IEEE Conference on Decision and Control, pp. 2242-2247, Brighton, 1991.
- [4]- Isermann, R., Schwarte, A., and Kimmich, F., "Model based fault detection of a Diesel engine with turbo charger – a case study," IFAC Symposium Automotive Systems, Salero, 2004.