



ارزیابی عملکرد شبکه عصبی مصنوعی در تخمین آلاینده NO_x موتور دیزل

مهدی علی جانی^{۱*}، سید رضا موسوی سیدی^۲، سید مهدی عابدی^۳

۱- دانشجوی کارشناسی ارشد دانشگاه علوم کشاورزی و منابع طبیعی ساری

۲- استادیار دانشگاه علوم کشاورزی و منابع طبیعی ساری

۳- دانش آموخته کارشناسی ارشد دانشگاه آزاد اسلامی واحد ساری

ایمیل مکاتبه کننده: mehdii.aliyani@gmail.com

چکیده

این مقاله قابلیت شبکه عصبی مصنوعی را به عنوان یک ابزار پیش بینی کننده آلاینده ی اکسید نیتروژن در موتور دیزل چند سیلندر، ارزیابی می کند. برای مقایسه و تحلیل داده‌ها از RMSE ، R^2 و MRE استفاده شد. در میان ترکیب های آزمایش شده از شرایط آموزش در معماری های متفاوت پس انتشار (BP)، بهترین الگوریتم برای حالت بار صفر، ۰/۲۵، ۰/۵۰، ۰/۷۵ و ۱/۰۰ به ترتیب الگوریتم با تابع و تعداد نرون SCG و ۱۴، BR، ۱۱ و BR، ۱۴ و SCG و ۱۳، SCG و ۱۱ و برای حالت کلی که شامل تمامی داده‌ها بود الگوریتم با تابع SCG و ۳۶ نرون بود. مقدار RMSE برای بار صفر، ۰/۲۵، ۰/۵۰، ۰/۷۵، ۱/۰۰ و حالت کلی بترتیب برابر با ۰/۰۴، ۰/۰۴، ۰/۰۲، ۰/۰۷، ۰/۱۵ و ۰/۰۵ بود. شاخص اصلی در مقایسه، کمترین مقدار RMSE بود.

واژه کلیدی: آلاینده NO_x ، موتور دیزل، شبکه عصبی مصنوعی، الگوریتم یادگیری

مقدمه

در آینده نزدیک، استفاده از موتور های دیزل در وسائلی که نیاز به صرفه اقتصادی سوخت دارند مانند اتوبوس ها و کشنده های سنگین، ژنراتورها، لوکوموتیو ها و کاربرد های غیر جاده ای بیشتر خواهد شد. از آنجایی که میزان سختگیری و دقت در استاندارد آلاینده ها در حال افزایش است لذا برای بهبود بازده، کنترل احتراق در این موتورها ضروری خواهد بود. موتور های آینده بطور معناداری نیاز به کنترل پیچیده تری نسبت به استراتژی کنترل موجود، که بر اساس نقشه است، دارند و همچنین دارای درجه آزادی بیشتری نسبت به موتورهای امروزی هستند. کنترل کلاسیک، یک بعدی و یا اساسا کنترل بر مبنای نقشه در مواجهه با درجه آزادی چند گانه ای که بواسطه اشکال مختلف نرخ پاشش سوخت، EGR^۱ و کنترل سوپاپ ها در موتور های دیزل آینده فراهم می شود، شکست سختی خواهد خورد. بعلاوه هزینه‌ها، زمان مورد نیاز و پیچیدگی های مرتبط با توسعه ی موتور، عملکرد نگاشت، و

^۱. Exhaust gas recycled



همچنین توسعه و کالیبره کردن سیستم کنترل به طور معناداری در حال افزایش است. چیزی که برای این مقوله مورد نیاز است باید چند بعدی باشد، قابلیت تطبیق داشته باشد، مجهز به یک سیستم کنترل یادگیرنده باشد که برای رساندن موتور به سطح کارایی ایده‌آل نیازمند تغییرات جدی در مدل موتور نباشد و همچنین توانایی پیش‌بینی آلاینده‌های موتور برای تمامی وضعیت‌های عملیاتی موتور را داشته باشد. شبکه عصبی مصنوعی (ANN)^۲ تمامی این قابلیت‌ها را بر اساس احساس واقعی ارائه می‌دهد

(Hewlett et al., 2005; He and Rutland, 2004).

به علت توانایی شبکه‌های عصبی مصنوعی در حل مسائل غیر خطی، از اواخر دهه‌ی ۸۰ مورد توجه بسیاری قرار گرفته است. Krijnsen et al, 1999 از شبکه عصبی به عنوان یک ابزار دقیق در تخمین آلاینده NO_x موتور استفاده کرد که این روش جایگزین آنالیزهای گران قیمت و مدل‌های کامپیوتری شد. میانگین انحراف مطلق بین میزان آلاینده-ی NO_x تخمین زده شده و اندازه‌گیری شده ۶/۷٪ بود. این کار ثابت کرد که شبکه عصبی مصنوعی یک ابزار دقیق برای تخمین آلاینده‌ی NO_x موتور می‌باشد.

Clark et al. (2002) تلاش کرد تا برای ۱۶ شاسی مختلف اتومبیل آلاینده‌ی NO_x را تخمین بزند در این راستا تست و آزمون جداول را به سه روش متفاوت انجام داد، نتایج نشان داد مدل شبکه عصبی با ورودی‌های گشتاور محور و دور محور به عنوان متغیرهای ورودی، قابلیت تخمین آلاینده NO_x را با خطای ۵٪ داشت. Traver et al (1999) مطالعه‌ای را انجام داد مبنی بر استفاده از متغیرهای درون سیلندری و بر پایه‌ی فشار، به منظور تخمین سطح آلاینده-های خروجی از آگروز موتور دیزل پاشش مستقیم Navistar T444 بواسطه استفاده از شبکه عصبی مصنوعی. آنها به این نتیجه رسیدند که NO_x و CO₂ پاسخ خوبی به این متد می‌دهند. بخصوص که NO_x نتایج خوبی را نشان داد، چون تولید آن به طور مستقیم حاصل دمای بالا در سیلندر و این دمای بالا بطور مستقیم وابسته است به بالاترین پیک فشار، که از ورودی‌های اصلی می‌باشد.

مواد و روش‌ها

شبکه عصبی مصنوعی (ANN) یک سیستم کامپیوتری می‌باشد و این توانایی را دارد که از مغز انسان تقلید کند. شبکه عصبی متداول شامل سه لایه ورودی، پنهان و خروجی می‌باشد. هر لایه شامل تعدادی گره یا نرون مخصوص به خود می‌باشد. شبکه پرسپترون چند لایه (MLP)^۳ با یک لایه مخفی و توابع تبدیل زیگموییدی در لایه میانی و توابع تبدیل خطی در لایه خروجی قادر به تقریب تمامی توابع مورد نظر با هر درجه تقریب خواهد بود، مشروط بر اینکه به اندازه کافی در لایه مخفی نرون داشته باشیم.

در این مطالعه ۲۲۵ داده آزمایشگاهی که بواسطه‌ی واحد آزمون اندازه‌گیری شدند، به دو بخش برای آموزش و تست تقسیم شدند. لازم به ذکر است که در این مطالعه به منظور دست یافتن به بهترین عملکرد شبکه، داده‌ها

^۲. Artificial neural network

^۳. Multi layer perceptron




بصورت مجزا نیز بررسی شدند. بطوریکه داده‌های مرتبط با حالت بدون بار، بار ۲۵٪، بار ۵۰٪، بار ۷۵٪ و بار ۱۰۰٪ نیز هر کدام بصورت جداگانه با الگوریتم یادگیری مختلف و ساختارهای متفاوت مورد ارزیابی قرار گرفتند. برای حالت کلی؛ میزان بار، دور موتور و فشار پاشش سوخت به عنوان لایه ورودی در نظر گرفته شدند و یک نرون در لایه خروجی NO_x را نمایندگی می‌کرد. برای حالتی که هر وضعیت بار بطور جداگانه بررسی می‌شود، لایه ورودی شبکه عصبی دارای ۲ نرون می‌باشد که نشان دهنده دور موتور و فشار پاشش سوخت می‌باشد. در این تحقیق از معماری پس انتشار خطا با الگوریتم یادگیری $trainlm^4$ ، $traingdx^5$ ، $trainbr^6$ و $trainscg^7$ استفاده شد که برای هر کدام از این الگوریتم‌ها تعداد نرون‌ها در لایه مخفی برای حالت کلی از ۳۰ تا ۴۰ و برای حالتی که هر وضعیت بار بطور جداگانه بررسی شد از ۶ تا ۱۵ تغییر کرد تا بهترین ساختار شبکه بدست آید. در فرآیند آموزش، شبکه فراخوانی می‌شود و مقادیر داده‌های ورودی را همراه با مقادیر خروجی مرتبط یاد می‌گیرد. وزن‌ها تنظیم می‌شوند در نتیجه شبکه تلاش می‌کند که خروجی‌های مطلوب را تولید کند. دقت و صحت پروسه‌ی آموزش بواسطه فرآیند آزمون مورد ارزیابی قرار می‌گیرد. پروسه آزمون شامل ارائه مجموعه‌ای از داده‌های تجربی است که کاملاً منحصر به فرد می‌باشند تا اینکه صحت و دقت شبکه آموزش دیده در تخمین متغیرهای موردنظر مورد ارزیابی قرار گیرد. تابع انتقال شبکه عصبی بصورت زیر بیان می‌شود.

$$NET_i = \sum_{j=1}^n W_{ij} X_j + W_{in} \quad (1)$$

$$f(NET_i) = \frac{1}{1 + e^{-NET_i}} \quad (2)$$

بطوریکه NET_i برابر با ورودی خالص برای تابع انتقال نرون i ام، W_{ij} وزن ارتباطی بین نرون i ام در لایه مخفی و ورودی i ام در لایه اول می‌باشد و W_{bi} بایاس مربوط به نرون i ام و f تابع تبدیل می‌باشد که در این تحقیق از تابع تبدیل زیگموئیدی استفاده شده است. مقادیر ورودی و خروجی بین ۰ و ۱ نرمالیزه می‌شوند.



شکل ۱ ساختار شبکه عصبی مصنوعی

⁴.Levenberg-Marquardt

⁵.Gradient descent momentum and an adaptive learning rate

⁶.Bayesian regularization

⁷.Scaled conjugate gradient



اندازه‌گیری دقت برای فاز آزمون با استفاده از RMSE^۸ که در معادله (۳) نشان داده شده است محاسبه می‌شود. خطای میانگین نسبی (MRE)^۹ و ضریب همبستگی^{۱۰} (R²) در معادلات (۴) و (۵) نشان داده شده‌اند، از این مقادیر نیز برای مقایسه داده‌های تخمین زده شده و تجربی استفاده می‌شود. RMSE اطلاعاتی مختصر را در مورد کارایی و عملکرد مدل ارائه می‌دهد بطوریکه انحراف واقعی بین داده‌های تخمین زده شده و اندازه‌گیری شده را با مقایسه یک به یک عبارات اندازه می‌گیرد. مقدار RMSE همیشه مثبت است و مقدار مطلوب آن برابر صفر می‌باشد. شاخص MRE خطای مقادیر اندازه‌گیری شده را نسبت به مقادیر درست می‌سنجد. مقدار MRE پایین‌تر نشان‌دهنده همبستگی بهتر بین نتایج تخمین زده شده و اندازه‌گیری شده می‌باشد. مقدار R² نشان‌دهنده شاخصی دیگر بین داده‌های تخمین زده شده و تجربی می‌باشد، بطوریکه هرچه مقدار R² به عدد ۱ نزدیکتر باشد، نشان‌دهنده دقت بالاتر داده‌های تخمین زده شده می‌باشد.

$$RMSE = \sqrt{\frac{\sum (t_i - a_i)^2}{N}} \quad (3)$$

$$MRE = \frac{1}{N} \left(\sum_{i=1}^N \frac{|t_i - a_i|}{t_i} \right) \times 100\% \quad (4)$$

$$R^2 = 1 - \left(\frac{\sum (t_i - a_i)^2}{\sum a_i^2} \right) \quad (5)$$

بطوریکه N تعداد کل داده‌ها می‌باشد، t_i مقادیر تجربی و a_i مقادیر تخمین زده شده می‌باشد.

نتایج و بحث

این مطالعه میزان آلاینده‌ی NO_x موتور دیزل بوسیله‌ی شبکه عصبی مصنوعی پیش بینی شده است. مقادیر بدست آمده از شبکه عصبی مصنوعی با نتایج حاصل از آزمایشات تجربی مقایسه می‌شود تا قابلیت اعتماد شبکه مورد بررسی قرار گیرد. برای تعیین بهترین الگوریتم یادگیری از الگوریتم‌های LM، SCG، GDX و BR استفاده می‌شود. برای تعیین تعداد بهینه نرون در لایه میانی، تعداد نرون‌ها برای ۵ وضعیت بار، از ۶ نرون تا ۱۵ نرون متغیر بود و برای وضعیت کلی که شامل تمامی داده‌ها بود تعداد نرون در لایه میانی از ۳۰ نرون تا ۴۰ نرون تغییر کرد. در این تحقیق تمامی ساختارهای شبکه تنها دارای یک لایه پنهان بودند. ساختارهای مختلف شبکه و آنالیز داده‌های حاصل از شبکه با استفاده از شاخص‌های RMSE، MRE و R² برای وضعیت بدون بار در جدول ۱ آمده است. همانطور که در جدول ۱ نشان داده شده است، کمترین مقدار RMSE که نشان‌دهنده‌ی بهترین دقت شبکه می‌باشد متعلق به شبکه با ۱۴ نرون در لایه پنهان و الگوریتم SCG می‌باشد. روش نشان داده شده در جدول ۱، برای وضعیت بار ۲۵٪، ۵۰٪، ۷۵٪ و ۱۰۰٪ و حالتی که از تمامی داده‌ها استفاده شد یعنی حالتی که وضعیت بار خود یکی از پارامترهای ورودی بود، انجام شد. برای وضعیت بار ۲۵٪ بهترین ساختار دارای ۱۱ نرون در لایه پنهان بود و از الگوریتم BR استفاده کرد، برای بار ۵۰٪ ساختار شبکه با تعداد نرون ۱۴ و الگوریتم BR بهترین عملکرد را از خود نشان داد، در بار ۷۵٪ شبکه با الگوریتم SCG و تعداد ۱۳ نرون در لایه مخفی بهترین عملکرد را داشت، در حالت بار ۱۰۰٪

⁸. Root mean square error

⁹. Mean relative error

¹⁰. Correlation coefficient



نهمین کنگره ملی مهندسی ماشین‌های کشاورزی

(مکانیک بیوسیستم) و مکانیزاسیون

پردیس کشاورزی و منابع طبیعی دانشگاه تهران

۲ و ۳ اردیبهشت ۱۳۹۴ - کرج



ساختاری از شبکه بهترین عملکرد را از خود نشان داد که دارای ۱۱ نرون در لایه میانی بود و از الگوریتم SCG استفاده کرد و در نهایت برای وضعیت کلی یعنی حالتی که از تمامی داده برای آموزش و آزمون شبکه استفاده شد، ساختار شبکه با تعداد نرون ۳۶ و الگوریتم SCG بهترین عملکرد را از خود نشان داد. در جدول ۲ مقادیر خطا برای ساختارهایی که بهترین عملکرد را داشتند نشان داده شده است.



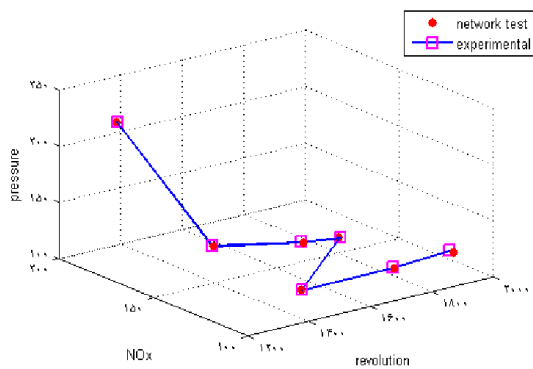
جدول ۱ ساختار و آنالیز داده‌ها برای وضعیت بدون بار

داده‌های تست	ساختار			الگوریتم یادگیری
	R ²	MRE	RMSE	
۰/۹۹۹۹۸	۰/۰۹۵۰	۰/۶۵۶۰	۲-۶-۱	trainbr
۰/۹۹۹۷۸	۰/۰۳۲۲	۰/۳۸۰۸	۲-۷-۱	trainbr
۰/۹۹۹۹۷	۰/۰۱۳۰	۰/۱۱۶۲	۲-۸-۱	trainbr
۰/۹۹۹۹۸	۰/۰۰۹۴	۰/۱۲۳	۲-۹-۱	trainbr
۰/۹۹۹۹۱	۰/۰۲۱	۰/۲۷۵۰	۲-۱۰-۱	trainbr
۰/۹۹۹۹۶	۰/۰۱۴۲	۰/۱۷۷۳	۲-۱۱-۱	trainbr
۰/۹۹۹۲۸	۰/۰۵۷۸	۰/۶۳۵۵	۲-۱۲-۱	trainbr
۰/۹۹۷۳۴	۰/۱۰۸۹	۱/۱۱۷۷	۲-۱۳-۱	trainbr
۰/۹۹۸۴	۰/۰۸۵۵	۱/۰۰۹۷	۲-۱۴-۱	trainbr
۰/۹۹۹۹۳	۰/۰۱۸۳	۰/۱۸۳۹	۲-۱۵-۱	trainbr
۱	۰/۰۰۳۰	۰/۰۳۶۱	۲-۶-۱	trainidx
۰/۹۹۸۸	۰/۰۷۴۳	۰/۸۷۸۳	۲-۷-۱	trainidx
۰/۹۹۹۱	۰/۰۶۱۸	۰/۵۳۵۶	۲-۸-۱	trainidx
۰/۹۹۹۹	۰/۰۱۶۱	۰/۱۳۳۱	۲-۹-۱	trainidx
۰/۹۹۹۹	۰/۰۲۲۸	۰/۱۵۶۱	۲-۱۰-۱	trainidx
۰/۹۹۹۲	۰/۰۶۰۸	۰/۷۵۷	۲-۱۱-۱	trainidx
۰/۹۹۹۸	۰/۰۲۴۱	۰/۱۹۹۶	۲-۱۲-۱	trainidx
۰/۹۹۷۵	۰/۱۰۵۰	۱/۲۴	۲-۱۳-۱	trainidx
۰/۹۹۹۹	۰/۰۰۵۷	۰/۰۵۸۸	۲-۱۴-۱	trainidx
۰/۹۹۹۶	۰/۰۳۹	۰/۴۶۰۵	۲-۱۵-۱	trainidx
۰/۹۹۹۹	۰/۰۱۵۲	۰/۱۵۳۱	۲-۶-۱	trainlm
۰/۹۹۰۸	۰/۲۳۵۴	۱/۶۱۱۲	۲-۷-۱	trainlm
۰/۹۹۴۹	۰/۱۸۴۵	۱/۲۶۲۸	۲-۸-۱	trainlm
۰/۹۸۷۱	۰/۲۲۶۶	۲/۹۶۴۵	۲-۹-۱	trainlm
۰/۹۹۷۴	۰/۱۱۷۴	۰/۹۶۸۹	۲-۱۰-۱	trainlm
۰/۹۹۹۷	۰/۰۳۲۸	۰/۴۲۹۰	۲-۱۱-۱	trainlm
۰/۹۹۶۹	۰/۱۱۵۵	۱/۳۶۴۷	۲-۱۲-۱	trainlm
۰/۹۹۵۱	۰/۱۶۶۵	۱/۲۶۳۲	۲-۱۳-۱	trainlm
۰/۹۹۳۵	۰/۱۹۴۰	۱/۶۷۹۶	۲-۱۴-۱	trainlm
۰/۹۹۹۹	۰/۰۱۱۶	۰/۱۰۰۹	۲-۱۵-۱	trainlm
۰/۹۹۹۹	۰/۰۱۱۳	۰/۱۴۲۱	۲-۶-۱	trainscg
۰/۹۹۹۸	۰/۰۲۵۹	۰/۳۱۳۴	۲-۷-۱	trainscg
۰/۹۹۴۰	۰/۱۸۵۳	۱/۲۶۹۴	۲-۸-۱	trainscg
۰/۹۹۷۷	۰/۱۱۰۸	۰/۷۵۸۱	۲-۹-۱	trainscg
۰/۹۹۹۶	۰/۰۴۹۴	۰/۳۲۸۹	۲-۱۰-۱	trainscg
۰/۹۹۲۸	۰/۱۷۳۲	۱/۲۵۴۸	۲-۱۱-۱	trainscg
۰/۹۹۸۴	۰/۰۸۳۰	۰/۹۸۰۷	۲-۱۲-۱	trainscg
۰/۹۹۹۹	۰/۰۱۲۵	۰/۰۹۳۷	۲-۱۳-۱	trainscg
۱	۰/۰۰۰۴	۰/۰۰۴۳	۲-۱۴-۱	trainscg
۰/۹۹۹۳	۰/۰۵۷۹	۰/۴۱۹۷	۲-۱۵-۱	trainscg

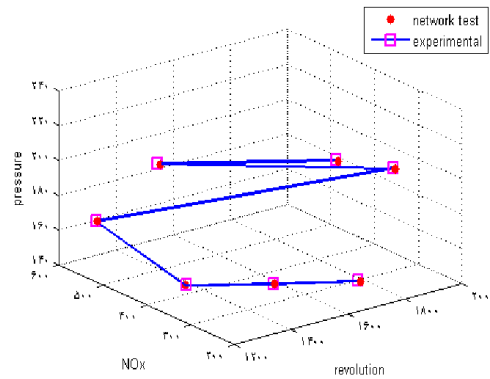


جدول ۲ ساختارهای دارای بهترین عملکرد


حالت بار	تابع انتقال	ساختار شبکه	RMSE	MRE	R ²	داده‌های تست
٪۰	trainscg	۲-۱۴-۱	۰/۰۰۴۳	۰/۰۰۰۴	۱	داده‌های تست
٪۲۵	trainbr	۲-۱۱-۱	۰/۰۴۳	۰/۰۰۲۱	۱	داده‌های تست
٪۵۰	trainbr	۲-۱۴-۱	۰/۰۲۴۷	۰/۰۰۰۹	۱	داده‌های تست
٪۷۵	trainscg	۲-۱۳-۱	۰/۰۷۴۲	۰/۰۰۰۵	۱	داده‌های تست
٪۱۰۰	trainscg	۲-۱۱-۱	۰/۱۵۶۶	۰/۰۰۶۶	۰/۹۹۹۹	داده‌های تست
حالت کلی	trainscg	۳-۳۶-۱	۰/۰۵۶۵	۰/۰۰۰۶	۱	داده‌های تست




نمودار ۱ مقایسه داده‌های تست شبکه و داده‌های تجربی برای حالت بدون بار



نمودار ۲ مقایسه داده‌های تست شبکه و داده‌های تجربی

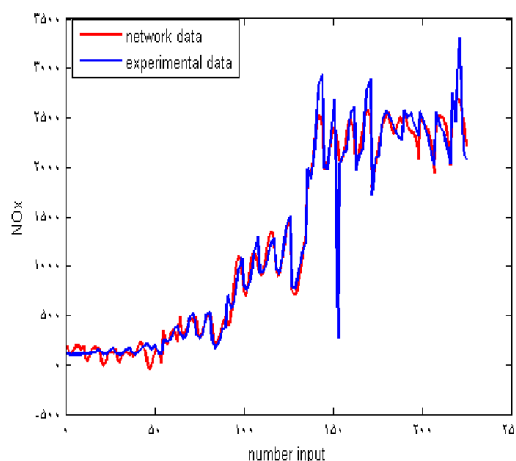


نمودار ۵ مقایسه داده‌های تست شبکه و داده‌های تجربی برای بار ٪۱۰۰



نمودار ۴ مقایسه داده‌های تست شبکه و داده‌های تجربی

برای بار ٪۷۵



نمودار ۶ مقایسه داده‌های شبکه در هر دو حالت آموزش و آزمون با داده‌های تجربی برای حالت کلی

نتیجه گیری

در این مطالعه، از مدل شبکه عصبی مصنوعی به منظور تخمین آلاینده NO_x موتور دیزل استفاده شد. به منظور آموزش شبکه عصبی مصنوعی از الگوریتم‌های یادگیری پس انتشار خطا مختلف مانند BR، LM، GDX و SCG و ساختارهای مختلف استفاده شد. بهترین نتایج بدست آمده از تخمین آلاینده NO_x برای حالت بدون بار، بار ۲۵٪، بار ۵۰٪، بار ۷۵٪، بار ۱۰۰٪ و حالت کلی به ترتیب با استفاده از ساختارهای ۲-۱۴-۱، ۲-۱۱-۱، ۲-۱۴-۱، ۲-۱۳-۱، ۲-۱۱-۱ و ۳-۳۶-۱ و الگوریتم یادگیری SCG، BR، BR، SCG، SCG و SCG حاصل شد. در مدل شبکه عصبی مصنوعی، ضریب تبیین R^2 هم برای آموزش و هم برای آزمون بطور قابل توجهی نزدیک به ۱ بود. این موضوع نشان می‌دهد که نتایج بدست آمده حاصل از تخمین شبکه دارای محدوده‌ی خطا قابل قبول (۵٪ \pm) می‌باشد. نتایج نشان می‌دهد که قابلیت یادگیری شبکه عصبی مصنوعی در تخمین آلاینده NO_x زیاد است. بنابراین استفاده از شبکه عصبی مصنوعی به منظور تخمین آلاینده‌های خروجی از آگروز بدون نیاز به اعمال پیچیده، هزینه بر و صرف زمان که برای مطالعات تجربی امری اجتناب ناپذیر است، کاملاً توصیه می‌شود. این مطالعه نشان داد که مدل شبکه عصبی مصنوعی یک جایگزین مناسب برای تکنیک‌های مدل‌سازی مرسوم در تخمین آلاینده‌های موتور دیزل می‌باشد.



منابع و ماخذ

1. Clark, N. N., Tehranian, A., Jarrett, R. P. & Nine, R. D. (2002); Translation of Distance Specific Emissions Rates between Different Heavy Duty Vehicle Chassis Test Schedules, SAE Technical Paper No. 2002-01-1754.
2. He, Y. & Rutland, C. J. (2004); Application of Artificial Neural networks in Engine Modeling, International Journal of Engine Research, Vol. 5, No. 4, 281 – 296.
3. Howlett, R. J., Howson, P. A. & Walters, S. D. (2005); Determination of Air-Fuel Ratio in Automotive Ignition System using Neural networks, IEEE Transactions on Neural Networks, Vol. 41, No. 1, 60-67.
4. Krijnsen, H. C.; Van Kooten, W. J.; Calis, H. A.; Verbeek, R. P. & Van den Bleek, C. M. (1999); Prediction of NOx Emissions from a Transiently Operating Diesel Engine using an Artificial Neural Network, Chemical Engineering and Technology, Vol. 22, 601-607.
5. Traver, M.; Atkinson, R. & Atkinson, C. (1999); Neural Network-Based Diesel Emissions Prediction using In-cylinder Combustion Pressure, SAE Technical Paper No. 1999-01-1532.



نهمین کنگره ملی مهندسی ماشین‌های کشاورزی

(مکانیک بیوسیستم) و مکانیزاسیون

پردیس کشاورزی و منابع طبیعی دانشگاه تهران

۲ و ۳ اردیبهشت ۱۳۹۴ - کرج



Evaluation of Artificial Neural Network Performance in Predicting Diesel Engine NO_x Emissions

Abstract

This paper evaluates the capabilities of ANN as a predictive tool for multi-cylinder diesel engine NO_x emissions. Standard laboratory procedures were used to measure the engine operating parameters and its tailpipe emissions. ANNs were trained on experimental data and used to predict the oxides of nitrogen (NO_x) emissions under various operating variables. RMSE, MRE and R² were used for comparison in the sensitivity analysis. Among the examined combinations of learning criteria in different architectures of back propagation (BP) designs, the best results for condition have no load were obtained by SCG algorithm and 14 neuron, in condition load 25% best results obtained by BR algorithm and 11 neuron, in condition load 50% best results obtained by BR algorithm and 14 neuron, in condition load 75% best results obtained by SCG algorithm and 13 neuron, in condition load 100% best results obtained by SCG algorithm and 11 neuron and in general condition that include all data the best structure had 36 neuron in hidden layer and SCG learning algorithm. The main index that shows the best result was the lowest value of RMSE.

Keywords: NO_x emission, diesel engine, artificial neural network, learning algorithm