

مدل سازی گرانروی مخلوط‌های روان کننده و خنک کننده به کمک شبکه عصبی مصنوعی

حمیده ذوالفقاری، فخری یوسفی*⁺، رضوان کریمی

گروه شیمی، دانشکده علوم پایه، دانشگاه یاسوج، یاسوج، ایران

چکیده: در این پژوهش از شبکه عصبی مصنوعی (ANNs) برای پیش‌بینی گرانروی مخلوط روان کننده و خنک کننده استفاده شده است. دما، فشار، وزن مولکولی، کسر مولی خنک کننده و گرانروی خنک کننده به عنوان متغیرهای ورودی و گرانروی مخلوط روان کننده و خنک کننده به عنوان خروجی مورد استفاده قرار گرفت. تعداد کل داده‌های تجربی مورد استفاده در این مطالعه ۱۰۵۳ عدد بود که شبکه عصبی مصنوعی به طور تصادفی با ۷۰٪ (۷۳۷ نقطه داده)، ۱۵٪ (۱۵۸ نقطه داده) و ۱۵٪ (۱۵۸ نقطه داده) به ترتیب مورد آموزش، ارزیابی و آزمون قرار گرفت. مقادیر میانگین خطای مطلق برای مجموعه داده‌های آموزش، ارزیابی و آزمون به ترتیب ۰/۳۹، ۰/۴۸ و ۰/۴۹ است. بنابراین مدل شبکه عصبی مصنوعی مطالعه شده با ۱۵ نرون در لایه میانی هم‌خوانی خوبی با داده‌های تجربی دارد.

واژه‌های کلیدی: گرانروی، شبکه عصبی مصنوعی، مخلوط روان کننده و خنک کننده، لایه میانی.

KEYWORDS: Viscosity; Artificial neural network; Lubricant and refrigerant mixtures; Middle layer.

مقدمه

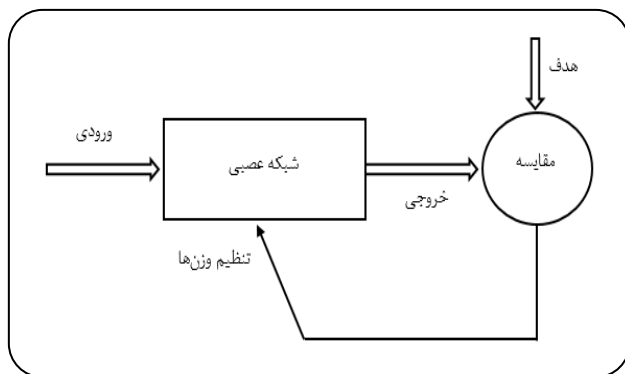
مخلوط روان کننده و خنک کننده عامل اصلی در کمپرسورهای تبرید، تهویه مطبوع و پمپ‌های گرمایی است. کمپرسورهای تبرید و تهویه مطبوع دارای اجزای بسیار حساسی هستند که باید به درستی روانکاری شوند تا بتوانند عمر طولانی‌تری داشته باشند. روان کننده نه تنها باید بتواند همه اجزای داخل کمپرسور را روان کند، بلکه باید با خنک کننده‌ای که با آن در تماس است نیز به خوبی کار کند. اگرچه سازگاری بین عامل سرمایش و روان کننده شاید مهم‌ترین مسئله روانکاری باشد ولی مسئله‌های دیگری نیز وجود دارند. به عنوان نمونه آلودگی با رطوبت می‌تواند منجر به تغییر گرانروی شود و ویژگی‌های روانکاری روغن از بین ببرد [۶-۱]. همچنین، گرانروی روغن در اتصال‌های کمپرسور می‌تواند به طور چشمگیری به دلیل حضور خنک کننده حل نشده، کاهش یابد و به روان کنندگی

کم‌تر منجر شود. به طوری که احتمال از کار افتادگی در اجزای مکانیکی کمپرسور افزایش یابد. بنابراین، گرانروی و انحلال پذیری مخلوط روان کننده-خنک کننده عامل‌های مهمی در تعیین کاربردپذیری این مواد در کاربردهای خاص می‌باشد [۷]. اندازه‌گیری گرانروی، در طراحی انرژی سامانه‌های مهندسی، همچون سامانه‌های تبادل گرما و سامانه‌های خنک کننده کاربرد دارند، زیرا قدرت پمپ و افت‌وخیز فشار به وسیله‌ی مقدار گرانروی تخمین زده می‌شود [۸].

با توجه به اهمیت گرانروی به عنوان یکی از ویژگی‌های مهم پدیده‌های انتقال به کار برده شده در صنایع شیمیایی، معدنی، دارویی و غیره، نیاز به تخمین گرانروی مخلوط‌ها بیش از پیش محسوس می‌باشد. با توجه به موردهای ذکر شده و نیز اهمیت مخلوط روان کننده‌ها

*عهدہ دار مکاتبات

+E-mail: fyousefi@yu.ac.ir



شکل ۱- نمایی کلی از روند شبکه عصبی.

- لایه ورودی: لایه ورودی شامل اطلاعات و یا الگوهایی است که برای آموزش به شبکه داده می‌شود.
- لایه‌های پنهان: این لایه شامل نرون‌ها، وزن‌ها، پارامتری تحت عنوان بایاس و تابع عملگر می‌باشد که عملکرد شبکه عصبی وابستگی زیادی به طراحی این لایه دارد.
- لایه خروجی: این لایه شامل خروجی شبکه عصبی می‌باشد. چگونگی اتصال‌های نرون‌ها می‌تواند به گونه‌ای باشد که شبکه تک لایه و یا چند لایه را بوجود می‌آورد. شبکه‌های چند لایه تشکیل شده از لایه ورودی (که الگوهای ورودی به آن اعمال می‌شود)، لایه خروجی (که خروجی شبکه را تعیین می‌کنند)، و لایه (یا لایه‌های) پنهان^(۱) که بین لایه ورودی و خروجی قرار دارند. وظیفه لایه پنهان ارتباط دادن بین لایه ورودی و لایه خروجی است. شبکه عصبی تک‌لایه تنها از یک لایه نرون تشکیل شده‌اند و هر یک از ورودی‌ها به همه نرون‌ها متصل است [۱۰-۱۳]. شبکه پرسپترون چند لایه^(۲) (MLP) از پرکاربردترین آرایش‌های شبکه عصبی مصنوعی در مدل‌سازی مسئله‌های گوناگون است. اساس یادگیری این شبکه بر اساس تشویق عملکرد خوب و تنبیه عملکرد بد است. این شبکه دو دویی بوده و از یک لایه ورودی، یک لایه خروجی و یک یا چند لایه پنهان تشکیل شده است.

۲- الگوریتم یادگیری: یک الگوریتم یادگیری، روشی برای تنظیم ضریب‌های وزنی (وزن‌ها و بایاس‌ها) شبکه است که تابع خطا را کمینه می‌سازد. تابع خطا اختلاف بین خروجی‌های شبکه و مقادیرهای دلخواه را برای یک مجموعه آموزشی محاسبه می‌کند [۱۵، ۱۴]. معروف‌ترین الگوریتم‌هایی که برای کمینه کردن خطا مورد استفاده قرار می‌گیرند عبارتند از:

- الگوریتم دلتا

و خنک‌کنندها در صنایع، طراحی شبکه هوشمند عصبی به منظور تخمین گرانروی این مخلوط‌ها بیش از پیش می‌تواند سودمند باشد. به تازگی شبکه‌های عصبی به طور چشمگیری در همه صنایع در مباحث بهینه‌سازی و پیش‌بینی مورد استفاده قرار می‌گیرند. این شبکه‌ها به عنوان ابزار قدرتمندی برای ارزیابی داده‌هایی که برای آن‌ها معادله، فرمول یا شرایط ارزان آزمایشگاهی وجود ندارد، ظهور کرده است. برتری‌های این روش نبودن هیچ نیازی به فرمول یا رابطه پارامترهای موثر می‌باشد، تنها می‌بایست ویژگی‌ها و کمیت‌های تاثیر گذار بر کمیت مورد نظر را به عنوان داده‌های اولیه جمع‌آوری و طبقه‌بندی کرد از این رو هیچ جای تعجبی ندارد که برخی پژوهشگران از این ابزار قدرتمند برای تعیین گرانروی استفاده کنند.

بخش نظری

شبکه‌های عصبی از عنصرهای عملیاتی ساده‌ای ساخته می‌شوند که به صورت موازی در کنار هم عمل می‌کنند. این عنصرها از سامانه‌های عصبی زیستی الهام گرفته شده‌اند. در طبیعت عملکرد شبکه‌های عصبی از طریق چگونگی اتصال بین اجزا تعیین می‌شود. بنابراین می‌توان یک ساختار مصنوعی به تبعیت از شبکه‌های طبیعی ساخت و با تنظیم مقادیرهای هر اتصال، به عنوان وزن اتصال، چگونگی ارتباط بین اجزا را تعیین کرد [۹].

در روند آموزش شبکه عصبی همان‌گونه که در شکل ۱ قابل دیدن است برای آموزش شبکه ابتدا ماتریسی به عنوان وزن و بایاس اولیه در نظر گرفته می‌شود و شبکه به صورت پیشرو اجرا می‌شود و سرانجام خروجی شبکه با مقدار هدف مقایسه می‌شود. در روند پس‌رو روش پس‌انتشار به کار گرفته شده و وزن‌ها و بایاس شبکه تغییر می‌کند و این روند تکرار شده تا خطا به حداقل برسد.

از شبکه‌های عصبی برای پیاده‌سازی تابع‌های پیچیده در زمینه‌های گوناگون از جمله تشخیص الگو، طبقه‌بندی، تشخیص هویت، مدل‌سازی آزمایشگاهی و ... استفاده می‌شود. امروزه شبکه‌های عصبی مصنوعی را برای حل مسائل پیچیده‌ای که حل آن‌ها با روش‌های معمولی دشوار است، به کار می‌برند.

به طور کلی یک شبکه عصبی مصنوعی به وسیله پارامترهای زیر

مشخص می‌شود:

۱- معماری شبکه: در حالت کلی

در شبکه‌های عصبی سه نوع لایه وجود دارد:

(۱) Hidden layer

(۲) Multi-Layer Perceptron

داشته باشد میزان درصد AAD کم‌تر می‌باشد و می‌توان گفت شبکه عصبی بهتر آموزش داده شده است. معیار دیگری که برای بیان انحراف داده‌های آموزش، ارزیابی و آزمون بر حسب دما مورد استفاده قرار می‌گیرد درصد خطای (E%) داده‌هاست که از معادله‌ی زیر پیروی می‌کند:

$$E\% = \frac{(Target - Output)}{Target} \times 100 \quad (4)$$

که در این معادله، Target بیان‌گر داده تجربی و Output خروجی شبکه عصبی می‌باشد.

نتیجه‌ها و بحث

در این پژوهش با بررسی‌های انجام شده از شبکه پرسپترون چند لایه برای مدل‌سازی استفاده شد. تعداد نورون‌های موجود در لایه پنهان شبکه عصبی و ارزیابی عملکرد شبکه با استفاده از روش آزمون و خطا، با استفاده از شاخص‌های میانگین مربع‌های خطا (MSE) برازش خطی (R^2) و قدر مطلق انحراف میانگین (AAD) داده‌های آموزش و آزمون تعیین شد. لیست موادی که در این شبکه استفاده شد در جدول ۱ گزارش شده است. در روند آموزشی شبکه، از الگوریتم لوبنبرگ-مارکواریت برای بهینه‌سازی وزن‌ها و بایاس لایه‌ها استفاده شده است که مقدارهای وزن‌ها و بایاس در جدول ۲ گزارش شده است. برتی بررسی عملکرد شبکه، تابع‌های انتقال گوناگونی برای به دست آوردن بهترین تابع برای لایه پنهان و خروجی بررسی شد.

همان‌گونه که در جدول ۳ مشخص است شبکه با تابع تانژانت سیگموئید برای لایه‌ی پنهان و تابع انتقال خطی (Pure Line) در لایه‌ی خروجی دارای کم‌ترین خطا بود. تعداد سیکل‌های آموزش شبکه به صورت پیش فرض تعداد ۱۰۰۰ سیکل در نظر گرفته شده است.

همچنین فرایند آموزش، شبکه‌های عصبی به کمک داده‌های آموزش، ارتباط بین نورون‌ها را در هر سیکل آموزش یاد می‌گیرند تا این‌که مقدارهای متغیرهای پیش بینی شده به مقدارهای واقعی نزدیک شود و مقدارهای خطای به دست آمده، از مقدارهای خطای مشخص شده کم‌تر شود. در شبکه عصبی چند لایه پرسپترون هر لایه متشکل از وزن‌ها، بایاس و تابع عملگر می‌باشد. خروجی لایه میانی

• الگوریتم با نرخ یادگیری متغیر

• الگوریتم ژنتیک

• الگوریتم لوبنبرگ-مارکواریت (LM)^(۱)

۳- تابع انتقال: تابع اعمال شده بر جمع وزندار ورودی‌ها برای تولید خروجی نرون [۱۷، ۱۶].
برای سنجش عملکرد شبکه عصبی مصنوعی از معیارهای متفاوتی می‌توان استفاده کرد. از مهم‌ترین این معیارها می‌توان به موارد زیر اشاره کرد:

یکی از معیارهای معروف در سنجش عملکرد شبکه عصبی مصنوعی، میانگین مربع خطا^(۲) (MSE) است که این معیار برای داده‌های آموزش و آزمون مورد استفاده قرار می‌گیرد. معادله‌ی زیر میانگین مربع خطا برای یک شبکه عصبی مصنوعی با هدف (Target) و خروجی (Output) نشان می‌دهد:

$$MSE = 1/N \sum_{i=1}^N (target_i - output_i)^2 \quad (1)$$

معیار برازش خطی^(۳) (R^2) میزان تطابق خروجی شبکه عصبی بر هدف را نشان می‌دهد. هر چه این مقدار به یک نزدیک‌تر باشد به معنی آنست که واریانس خطای به دست آمده از مدل‌سازی کم‌تر بوده و خروجی شبکه با هدف مورد نظر تطابق بیشتری دارد. برازش خطی از معادله‌ی زیر به دست می‌آید:

$$R^2 = \frac{\sum_{i=1}^N (t_i - o_i)}{\sum_{i=1}^N (t_m - o_i)} \quad (2)$$

که در این معادله t_i هدف نام، o_i خروجی نام شبکه و t_m میانگین هدف می‌باشد.

معیار قدر مطلق انحراف میانگین (AAD) یکی دیگر از مواردی که می‌تواند نشان‌گر عملکرد شبکه باشد. بر این اساس هر چه مقدار AAD شبکه به صفر نزدیک‌تر باشد می‌توان گفت انحراف خروجی شبکه از هدف کم‌تر بوده و شبکه عملکرد بهتری دارد. ولی همیشه رسیدن به AADهای نزدیک صفر کار آسانی نیست. معادله‌ی زیر برای به دست آوردن درصد AAD برای هدف نام به کار گرفته می‌شود:

$$\%AAD_i = 1/N \sum \frac{(t_i - o_i)}{t_i} \times 100 \quad (3)$$

با توجه به آن‌چه گفته شد هر چه برازش خطی مقدار بالاتری

(۱) Levenberg- Marquardt

(۲) Mean Square Error

(۳) Linear regression

جدول ۱- لیست مواد روان کننده و خنک کننده.

ترکیب	مخفف
HFC-134a	۲،۱،۱،۱- تترا فلئورو اتان
TriEGDME	تری اتیلن گلیکول دی متیل اتر
TEGDME	تترا اتیلن گلیکول دی متیل اتر
PEC5	پنتا اریترول تترا پنتا نوات
PEC7	پنتا اریترول تترا هپتا نوات
PEC9	پنتا اریترول تترا نونا نوات
PEB8	پنتا اریترول تترا -۲- اتیل هگزانات
R125	۲،۲،۱،۱- پنتا فلئورو اتان
BAB15/ BAB32	آلکیل بنزن شاخه ای
R143a	۱،۱،۱- تری فلئورو اتان
R32	دی فلئورو متان
RL68H	پلی ال استر خطی
PVE68	پلی وینیل اتر
RL68E	پلی ال استر شاخه‌ای

جدول ۲- وزن‌ها و بایاس‌های لایه پنهان و لایه خروجی.

لایه خروجی		لایه پنهان					
وزن	بایاس	وزن				بایاس	
-۱،۱۱۸۲۸۲۸	-۰،۲۴۲۶۴۰	-۰،۷۰۰۹۲۰۴	-۱،۷۵۸۴۸۱۱	۱،۳۴۸۳۱۰۵	۰،۴۵۷۸۹۰	-۰،۳۶۵۵۲۴۰	۳،۴۲۳۴۵۴۹
۰،۰۴۰۳۱۶۷		-۰،۲۹۸۸۲۷۱	۰،۱۴۱۳۰۵۳	۰،۲۱۷۳۱۹۲	-۲،۲۱۱۹۷۹۲	-۰،۰۹۶۱۷۹۸	۲،۱۹۵۴۰۸۳
-۰،۰۳۵۲۷۹۴		-۰،۲۵۹۰۵۷۵	-۰،۲۵۷۷۸۶۳	-۰،۴۰۴۸۰۴۲	۲،۴۸۴۰۶۳۱	-۱،۱۱۲۷۱۳۷	-۱،۷۰۰۴۲۴۹
-۱،۹۳۸۴۰۶۴		-۰،۰۸۰۴۶۴۴	-۱،۱۹۷۰۹۵۹	۰،۷۹۸۲۳۷۰	-۲،۵۲۲۴۳۷۰	۰،۲۴۳۰۲۳۵	-۰،۴۸۳۹۸۲۱
۰،۰۸۸۱۴۶		۰،۱۱۱۶۳۹۷	-۱،۳۰۰۱۱۵۳	۱،۰۴۲۸۳۴۶	-۲،۵۸۳۰۳۹۳	-۰،۰۳۰۸۲۸۴	-۰،۷۷۷۷۳۸۲
۰،۰۱۸۲۹۲۶		۱،۴۰۳۲۴۰۳	-۱،۲۶۵۹۶۵۹	۰،۷۲۷۷۵۹۲	۰،۵۵۳۹۶۹۶	۰،۹۵۴۴۸۹۲	-۰،۸۸۶۶۵۷۴
۰،۰۰۲۳۱۰۹		۰،۰۶۳۱۰۹۳	-۱،۵۰۶۷۵۶۷	۰،۹۸۶۳۲۹۲	۰،۶۹۳۱۰۸۶	-۱،۲۷۴۲۶۱۰	۰،۵۵۹۴۳۱۶
-۰،۰۹۶۶۳۴۳۱		۰،۳۰۵۳۵۰۴	۱،۲۱۵۸۹۴۱	-۰،۶۳۶۶۴۸۷	۲،۵۳۳۲۹۳۳	-۰،۵۷۸۴۲۶۴	۰،۲۱۷۶۲۶۹
۰،۰۱۱۷۲۰۹		-۱،۸۵۲۷۱۷۴	۰،۲۵۴۵۴۵۶	۰،۹۱۸۹۲۰۹	۰،۰۵۳۶۲۹۴	-۰،۴۵۶۶۹۱۱	-۰،۴۸۹۳۶۸۹
۰،۲۳۳۱۱۲۷		-۱،۴۵۷۱۲۸۸	-۰،۱۸۰۲۰۵۲	-۰،۸۴۴۰۳۱۲	۱،۴۰۴۷۱۶۸	۱،۹۷۳۷۲۱۵	-۱،۴۹۲۲۱۵۱
-۰،۰۰۴۸۲۶۱		۰،۶۸۹۶۹۹۴	-۰،۱۷۷۷۳۳۵	۱،۰۱۳۲۰۱۴	۰،۸۲۱۶۶۰۸	۱،۸۳۳۲۸۲۰	۰،۹۵۹۵۵۲۵
-۰،۵۶۷۶۳۰۳		-۱،۳۵۱۸۱۳۵	۱،۳۲۳۲۵۵۲	-۰،۰۸۰۶۲۲۱	۰،۵۳۳۶۵۴۶	۱،۶۰۲۷۴۰۵	-۱،۲۷۴۷۷۵۹
۰،۲۹۴۴۳۹۸		-۲،۹۹۰۳۵۴۰	۰،۴۰۲۷۸۹۵	-۰،۵۵۴۱۸۸۳	۰،۶۷۹۵۶۱۲	۰،۱۸۹۸۲۶۰	-۲،۰۴۷۹۶۳۲
۰،۴۱۷۹۶۶۶		۲،۶۲۰۸۵۶۸	۰،۱۵۹۵۷۴۴	۰،۳۳۲۱۶۶۴	-۰،۸۹۶۱۰۷۵	-۰،۱۱۱۶۶۳۳	۲،۵۱۴۰۳۳۴

جدول ۳- پارامترهای R2, MSE, AAD برای طراحی‌های گوناگون با تعداد نرون مطلوب.

TF1_TF2	تعداد نرون	R ²		میانگین خطای مطلق		میانگین مربع‌های خطا	
		آموزش	آزمون	آموزش	آزمون	آموزش	آزمون
purelin-purelin	۱۱	۰٫۶۱۱۵	۰٫۷۹۲۳	۱٫۵۱۳۲	۱٫۴۰۰۳	۰٫۰۰۰۴	۰٫۰۰۰۲
satlins-satlins	۱۲	۰٫۹۹۷۶	۰٫۹۸۸۷	۰٫۲۳۹۱	۰٫۲۴۳۸	۴٫۷۱×۱۰ ^{-۵}	۱٫۷۷×۱۰ ^{-۶}
tansig-satlins	۱۵	۰٫۹۹۹۵	۰٫۹۹۸۹	۰٫۱۶۰۴	۰٫۱۶۵۵	۲٫۱۸×۱۰ ^{-۶}	۲٫۴۷×۱۰ ^{-۶}
logsig-satlins	۱۵	۰٫۹۹۸۱	۰٫۹۸۰۹	۰٫۱۷۱۳	۰٫۱۵۹۷	۷٫۵۳×۱۰ ^{-۷}	۴٫۴۰×۱۰ ^{-۶}
logsig-purelin	۱۲	۰٫۹۹۹۶	۰٫۹۹۸۳	۰٫۱۹۳۷	۰٫۱۲۱۶	۳٫۵۳×۱۰ ^{-۶}	۱٫۱۵×۱۰ ^{-۶}
tansig-purelin	۱۵	۰٫۹۹۹۶	۰٫۹۹۲۹	۰٫۱۳۶۱	۰٫۱۴۵۹	۷٫۹۷×۱۰ ^{-۷}	۶٫۵۰×۱۰ ^{-۷}
tansig-tansig	۱۵	۰٫۹۹۰۸	۰٫۹۹۶۵	۰٫۱۴۲۰	۰٫۱۳۴۷	۸٫۸۷×۱۰ ^{-۷}	۳٫۹۸×۱۰ ^{-۷}

جدول ۴- بازه‌ی پارامترهای ورودی و خروجی شبکه عصبی برای مخلوط روان کننده و خنک کننده.

مخلوط‌ها	NP	ΔT(K)	ΔP(bar)	ΔX	Δη _{re} (Pa s)**	Δη _{mix} (Pa s)*	ref
HFC-134a+TriEGDME	۱۰۵	۲۹۳٫۱۵-۳۷۳٫۱۵	۷۰۰-۱۰۰	۰٫۳۴۲۷-۰٫۸۸۰۰	۰٫۰۰۰۱-۰٫۰۰۰۴	۰٫۰۰۰۲-۰٫۰۰۲۷	[۱۹],[۲۰]
HFC-134a+TEGDME	۱۷۵	۲۹۳٫۱۵-۳۷۳٫۱۵	۷۰۰-۱۰۰	۰٫۲۷۶۹-۰٫۸۷۹۷	۰٫۰۰۰۱-۰٫۰۰۰۴	۰٫۰۰۰۲-۰٫۰۰۵۱	[۱۸],[۱۹]
CO2 + PEC5	۱۱۳	۳۰۳٫۱۵-۳۵۳٫۱۵	۶۰۰-۱۰۰	۰٫۹۸۳۱-۰٫۹۹۱۹	۵٫۵۲×۱۰ ^{-۵} -۰٫۰۰۰۱	۰٫۰۰۰۱-۰٫۰۰۰۲	[۲۱]
CO2 + PEC7	۱۱۰	۳۰۳٫۱۵-۳۵۳٫۱۵	۶۰۰-۱۰۰	۰٫۹۸۷۲-۰٫۹۹۳۴	۵٫۵۲×۱۰ ^{-۵} -۰٫۰۰۰۱	۶٫۳×۱۰ ^{-۵} -۰٫۰۰۰۲	[۲۱]
CO2 + PEC9	۹۳	۳۰۳٫۱۵-۳۵۳٫۱۵	۶۰۰-۱۵۰	۰٫۹۸۷۹-۰٫۹۹۴۷	۶٫۱۳×۱۰ ^{-۵} -۰٫۰۰۰۱	۰٫۰۰۰۱-۰٫۰۰۰۳	[۲۱]
CO2+ PEB8	۱۱۰	۳۰۳٫۱۵-۳۵۳٫۱۵	۶۰۰-۱۰۰	۰٫۹۸۸۵-۰٫۹۹۴۲	۵٫۵۲×۱۰ ^{-۵} -۰٫۰۰۰۱	۰٫۰۰۰۱-۰٫۰۰۰۲	[۲۲]
CO2+Squalane	۶۰	۲۹۳٫۱۵-۳۵۳٫۱۵	۲۰۰-۱۰۰	۰٫۰۹۵-۰٫۴۱۷	۲٫۲×۱۰ ^{-۵} -۰٫۰۰۰۱	۰٫۰۰۰۳-۰٫۰۰۴۰۶	[۲۳]
R125+BAB15	۱۴	۳۱۳٫۱۵-۳۵۳٫۱۵	۱۲٫۲۵-۳۷٫۶	۰٫۱۴۸-۰٫۴۱۷	۱٫۳×۱۰ ^{-۵} -۲٫۰۴×۱۰ ^{-۵}	۰٫۰۰۱۹-۰٫۰۰۶۹	[۲۴]
R134a+BAB15	۱۶	۳۱۳٫۱۵-۳۵۳٫۱۵	۱٫۸۷-۲۰٫۴۶	۰٫۱۱۸-۰٫۵۴۰	۱٫۲۳×۱۰ ^{-۵} -۱٫۴×۱۰ ^{-۵}	۰٫۰۰۱۵-۰٫۰۰۸۶	[۲۴]
R143a+BAB15	۲۵	۳۱۳٫۳۵۳-۱۵٫۱۵	۴٫۰۱-۴۲٫۶۶	۰٫۱۰۵-۰٫۵۹۲	۱٫۱۶×۱۰ ^{-۵} -۲٫۶×۱۰ ^{-۵}	۰٫۰۰۰۹-۰٫۰۰۹۴	[۲۴]
R32+BAB15	۱۵	۳۱۳٫۳۵۳-۱۵٫۱۵	۴٫۷۴-۵۳٫۶۹	۰٫۱۳۸-۰٫۶۲۶	۱٫۳۳×۱۰ ^{-۵} -۱٫۸×۱۰ ^{-۵}	۰٫۰۰۰۹-۰٫۰۰۹۱	[۲۴]
R125+BAB32	۱۴	۳۱۳٫۳۵۳-۱۵٫۱۵	۶٫۹۴-۳۶٫۳۸	۰٫۱۰۰-۰٫۲۷۸	۱٫۳×۱۰ ^{-۵} -۲٫۰۱×۱۰ ^{-۵}	۰٫۰۰۲۸-۰٫۰۰۱۷۳	[۲۴]
R134a+BAB32	۱۹	۳۱۳٫۳۵۳-۱۵٫۱۵	۴٫۱۸-۲۶٫۱۱	۰٫۱۴۶-۰٫۵۴۴	۱٫۲۳×۱۰ ^{-۵} -۱٫۵×۱۰ ^{-۵}	۰٫۰۰۱۶-۰٫۰۰۱۵۰	[۲۴]
R143a+BAB32	۲۱	۳۱۳٫۳۵۳-۱۵٫۱۵	۴٫۲۲-۶۰٫۶۲	۰٫۱۰۶-۰٫۵۸۴	۱٫۱۶×۱۰ ^{-۵} -۵٫۸×۱۰ ^{-۵}	۰٫۰۰۱۴-۰٫۰۰۱۸۱	[۲۴]
R32+BAB32	۱۵	۳۱۳٫۳۵۳-۱۵٫۱۵	۶٫۸۴-۵۰	۰٫۱۶-۰٫۵۸۲	۱٫۳۳×۱۰ ^{-۵} -۱٫۷×۱۰ ^{-۵}	۰٫۰۰۱۷-۰٫۰۰۱۵۶	[۲۴]
RL68H + R134a	۴۲	۳۰۳٫۳۷۳-۱۵٫۱۵	۴۰۰-۱۰۰	۰٫۱۸۰-۰٫۴۲۷	۱٫۰۸×۱۰ ^{-۴} -۸٫۷×۱۰ ^{-۴}	۰٫۰۰۲۹-۰٫۰۰۳۰۹۰	[۲۲]
PVE68 +R134a	۲۸	۳۰۳٫۳۷۳-۱۵٫۱۵	۴۰۰-۱۰۰	۰٫۱۸۰-۰٫۲۲۷	۱٫۰۸×۱۰ ^{-۴} -۸٫۷×۱۰ ^{-۴}	۰٫۰۰۴۵-۰٫۰۰۳۱۴۰	[۲۵]
RL68E + R134a	۲۸	۳۰۳٫۳۷۳-۱۵٫۱۵	۴۰۰-۱۰۰	۰٫۱۰۷-۰٫۲۵۵	۱٫۰۸×۱۰ ^{-۴} -۸٫۷×۱۰ ^{-۴}	۰٫۰۰۳۹-۰٫۰۰۶۰۴۰	[۲۵]
R-600a+LAB ISO 5	۵۰	۲۹۵٫۳۵۳-۹۵٫۱۵	۰٫۱۲-۴۲٫۷۶	۰٫۰۷۳-۰٫۹۹۷	۷٫۴۳×۱۰ ^{-۶} -۹٫۳×۱۰ ^{-۶}	۰٫۰۰۰۲-۰٫۰۰۵۲	[۲۶]

*: بازه‌ی ویسکوزیته مخلوط روان کننده و خنک کننده برحسب پاسکال ثانیه
**: بازه‌ی ویسکوزیته مخلوط خنک کننده برحسب پاسکال ثانیه

در سیکل ۲۵ روند آموزش شبکه متوقف شده است و این بدان معنی است که تا سیکل ۲۵ شبکه آموزش را یاد گرفته است و پس از آن شروع به حفظ کردن معادله بین داده‌ها کرده است و آموزشی پس از سیکل ۲۵ صورت نگرفته بنابراین در آن سیکل متوقف شده است.

شکل ۵ و ۶ نشان‌دهنده عملکرد شبکه در یادگیری هدف برای داده‌های آموزش و آزمون می‌باشند. در این کار درصد یادگیری داده‌های آموزش و آزمون گرانروی مخلوط خنک‌کننده و روان‌کننده (R^2)، ۰٫۹۷۸۴ و ۰٫۹۹۰۴ میانگین خطای نسبی (% AAD) بین داده‌های تجربی و داده‌های پیش‌بینی شده از شبکه عصبی به دست آمده از داده‌های آموزش و آزمون ۰٫۳۹ و ۰٫۴۹ می‌باشد، که نشان‌دهنده توافق خوب بین داده‌های تجربی با داده‌های پیش‌بینی شده است.

شکل ۸ تطابق داده‌های پیش‌بینی شده با داده‌های واقعی را برای گرانروی مخلوط CO_2+PEB8 نشان می‌دهد که هر سه مدل نشان‌دهنده تطابق خوبی بین داده‌های تجربی با داده‌های پیش‌بینی شده است. مقدار R^2 برای گرانروی سه مدل معادله کتی-چاودری^(۱)، روش خود ارجاع^(۲) و شبکه عصبی مصنوعی به ترتیب ۰٫۹۶۹۷، ۰٫۹۷۷۸ و ۱ می‌باشد، که این نتیجه‌ها نشان می‌دهد شبکه عصبی عملکرد نسبتاً بهتری نسبت به دو مدل دیگر دارد و توانسته به خوبی تمامی نتیجه‌های تجربی را مدل کند. برای سایر شکل‌های ۱۰٫۹ و ۱۱ نیز نتیجه‌های R^2 بیانگر عملکرد بهتر شبکه عصبی مصنوعی در مقایسه با مدل‌ها و همبستگی‌ها است. در جدول ۶ مروری بر کارهای گذشته و مقایسه آن‌ها با شبکه عصبی انجام شده برای گرانروی مخلوط های خنک‌کننده + روان‌کننده در دما و فشارهای گوناگون گزارش شده است. مقایسه نتیجه‌های AAD حاکی از عملکرد بهتر شبکه در مدل‌سازی گرانروی مخلوط خنک‌کننده و روان‌کننده می‌باشد.

شکل ۷ بیان‌گر پراکندگی میزان درصد خطای (E%) داده‌های آموزش و ارزیابی و آزمون بر حسب دما می‌باشد. همان‌گونه که دیده می‌شود پراکندگی یکنواختی در اطراف صفر دیده می‌شود.

نتیجه‌گیری

به‌طور کلی نتیجه‌های به دست آمده از این پژوهش، نشان‌دهنده قدرت و توانایی شبکه‌ی عصبی مصنوعی در مدل‌سازی گرانروی

به لایه خروجی اعمال می‌شود و نتیجه به دست آمده از آن به عنوان خروجی شبکه معرفی و با هدف مقایسه می‌شود. پس از آن شبکه عصبی وارد فرایند یادگیری می‌شود. در این پژوهش، برای گرانروی مخلوط روان‌کننده و خنک‌کننده، پارامترهای دما (بر حسب کلونین)، فشار (بر حسب بار)، کسر مولی خنک‌کننده، وزن مولکولی (گرم بر مول)، گرانروی خنک‌کننده (بر حسب پاسکال ثانیه) به عنوان ورودی شبکه عصبی مصنوعی و پارامتر گرانروی مخلوط روان‌کننده و خنک‌کننده (بر حسب پاسکال ثانیه) به عنوان هدف شبکه عصبی در نظر گرفته می‌شوند که بازه‌ی این داده‌ها در جدول ۴ گزارش شده است. به منظور بالا بردن کارایی شبکه داده‌های ورودی و داده‌های به دست آمده از نتیجه‌های تجربی بین ۰٫۳ و ۰٫۸ نرمالیزه می‌شوند. برای این منظور از معادله‌ی زیر استفاده می‌شود.

$$Out = (in - \min_{(in)}) / ((\max_{(in)} - \min_{(in)}) \times 0.5 + 0.3) \quad (5)$$

که در معادله‌ی بالا پارامتر out بیانگر خروجی، پارامتر in معرف ورودی، $\min(in)$ بیانگر کمینه ورودی و $\max(in)$ بیانگر بیشینه ورودی می‌باشد. تعداد داده‌های تجربی گرانروی مخلوط روان‌کننده و خنک‌کننده‌ها ۱۰۵۳ می‌باشد که از این تعداد ۷۳۷ داده (۷۰٪) را به طور تصادفی برای آموزش و ۱۵۸ داده (۱۵٪) را به طور تصادفی برای آزمون و ۱۵۸ داده (۱۵٪) به طور تصادفی برای ارزیابی شبکه برگزیده‌ایم. نموداری برای ساختار شبکه عصبی مورد استفاده در این کار در شکل ۲ نشان داده شده است.

شکل ۳ میانگین نسبی خطای داده‌های آموزش و آزمون را بر حسب تعداد نرون‌ها در لایه‌ی پنهان می‌باشد که با آزمون و خطا، نرون بهینه، نرون ۱۵ مشخص شد که خطای آن در جدول ۵ ذکر شده است. برای مشخص کردن نرون بهینه دو فاکتور لازم است:

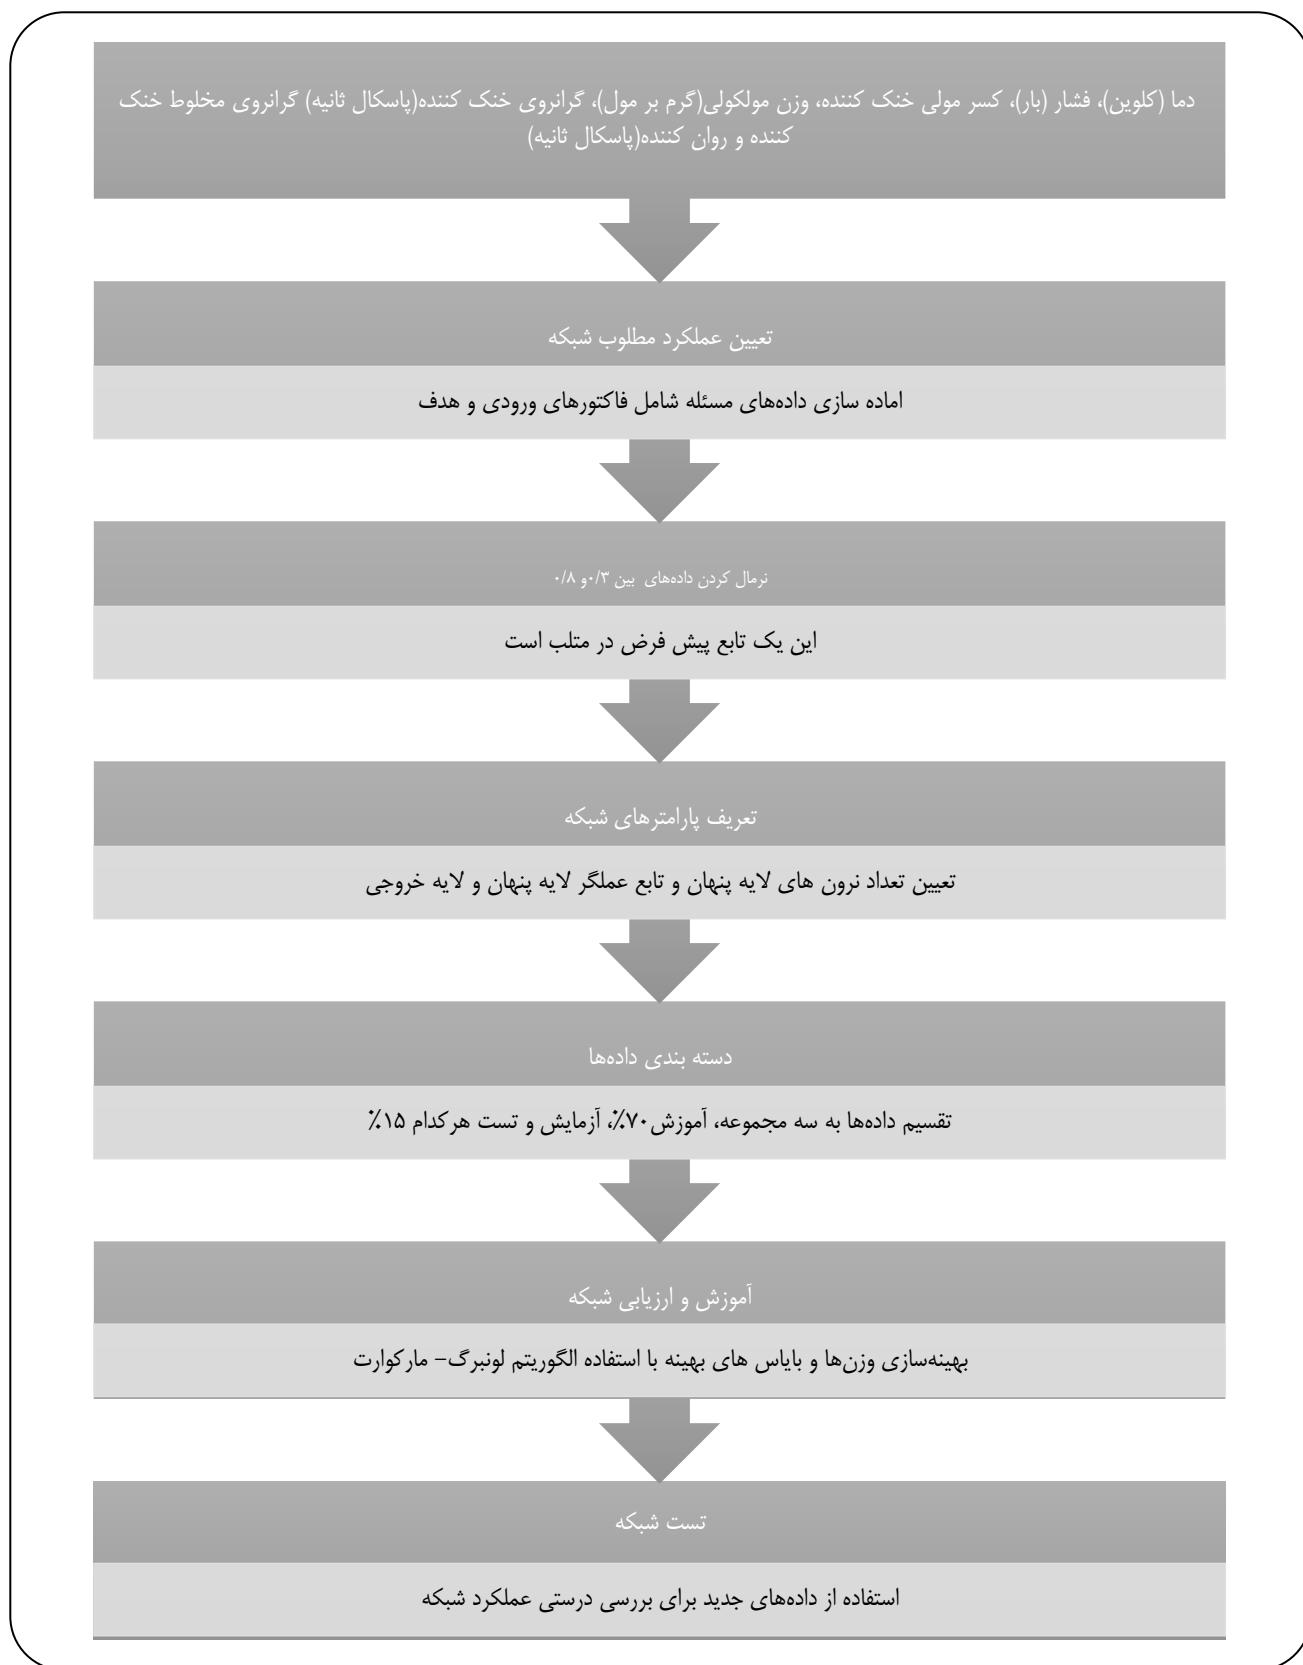
۱- خطای داده‌های آموزش کم باشد.

۲- اختلاف خطای داده‌های آموزش و آزمون کم باشد.

شکل ۴ چگونگی بهبود عملکرد شبکه در تکرارهای متوالی تا رسیدن به جواب بهینه را نشان می‌دهد که تغییرهای شاخص MSE با تعداد سیکل‌های آموزش برای داده‌های آموزش، ارزیابی و آزمون را نشان می‌دهد. همان‌گونه که در شکل مشخص است

(۱) Katti-Chaudhri equation


(۲) Self-referencing method



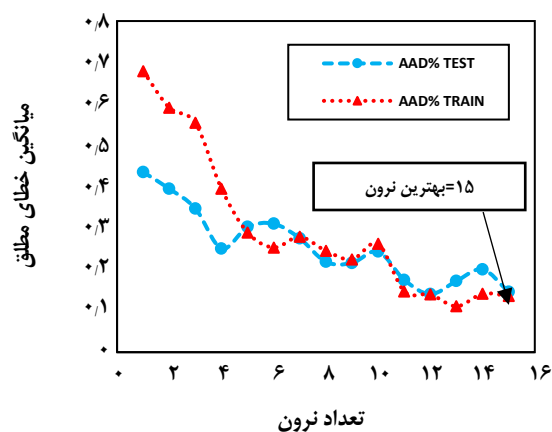
شکل ۲- نمودار ساختار شبکه عصبی مورد استفاده.

جدول ۵ - عملکرد شبکه‌های گوناگون نسبت به پارامترهای آماری برای داده‌های آموزش و آزمون.

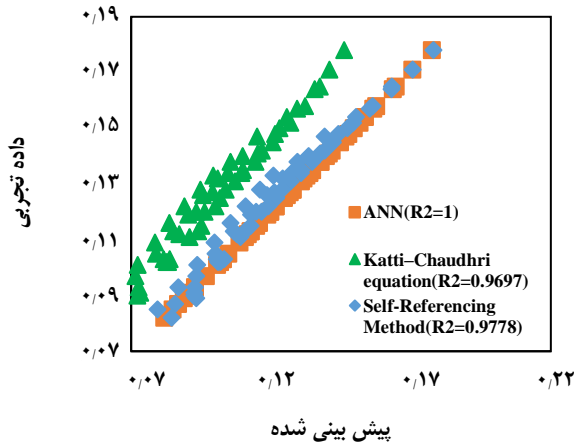
تعداد نرون‌ها	داده‌های آموزش			داده‌های آزمون		
	میانگین خطای مطلق	میانگین مربع‌های خطا	R ²	میانگین خطای مطلق	میانگین مربع‌های خطا	R ²
۱	۰.۶۸	۶.۹۸×۱۰ ^{-۵}	۰.۹۶۲۴	۰.۴۳	۵.۹۱×۱۰ ^{-۶}	۰.۹۹۲۷
۲	۰.۵۹	۳.۹۷×۱۰ ^{-۵}	۰.۹۶۳۴	۰.۳۹	۱.۳۹×۱۰ ^{-۵}	۰.۹۸۶۵
۳	۰.۵۵	۲.۵۰×۱۰ ^{-۵}	۰.۹۸۰۶	۰.۳۵	۸.۸۹×۱۰ ^{-۶}	۰.۹۹۲۹
۴	۰.۲۹	۱.۵۸×۱۰ ^{-۵}	۰.۹۹۳۷	۰.۲۵	۳.۳۳×۱۰ ^{-۶}	۰.۹۷۰۶
۵	۰.۲۵	۶.۵۳×۱۰ ^{-۶}	۰.۹۹۶۱	۰.۳۰	۴.۲۵×۱۰ ^{-۶}	۰.۹۸۹۴
۶	۰.۲۸	۴.۲۵×۱۰ ^{-۶}	۰.۹۹۷۷	۰.۳۱	۶.۰۴×۱۰ ^{-۶}	۰.۹۹۳۵
۷	۰.۲۴	۳.۳۹×۱۰ ^{-۶}	۰.۹۹۸۰	۰.۲۷	۳.۶۳×۱۰ ^{-۶}	۰.۹۵۳۸
۸	۰.۲۲	۳.۳۶×۱۰ ^{-۶}	۰.۹۹۷۸	۰.۲۲	۳.۰۰×۱۰ ^{-۶}	۰.۹۹۲۶
۹	۰.۲۶	۲.۱۱×۱۰ ^{-۶}	۰.۹۹۸۷	۰.۲۲	۱.۲۶×۱۰ ^{-۶}	۰.۹۹۰۴
۱۰	۰.۱۵	۲.۸۲×۱۰ ^{-۶}	۰.۹۹۷۶	۰.۲۴	۱.۶۷×۱۰ ^{-۶}	۰.۹۹۶۱
۱۱	۰.۱۴	۱.۴۰×۱۰ ^{-۶}	۰.۹۹۹۵	۰.۱۷	۱.۰۵×۱۰ ^{-۶}	۰.۹۸۶۴
۱۲	۰.۱۱	۱.۱۷×۱۰ ^{-۶}	۰.۹۹۹۵	۰.۱۴	۸.۰۴×۱۰ ^{-۷}	۰.۹۹۸۲
۱۳	۰.۱۱	۲.۱۷×۱۰ ^{-۶}	۰.۹۹۹۷	۰.۱۷	۳.۳۹×۱۰ ^{-۶}	۰.۹۹۷۶
۱۴	۰.۱۴	۲.۰۱×۱۰ ^{-۶}	۰.۹۹۹۴	۰.۲۰	۲.۴۵×۱۰ ^{-۶}	۰.۹۹۴۲
۱۵	۰.۱۴	۷.۹۷×۱۰ ^{-۷}	۰.۹۹۹۶	۰.۱۵	۷-۱×۶.۵۰	۰.۹۹۲۹




شکل ۴ - تغییر شاخص MSE با تعداد سیکل‌های آموزش.



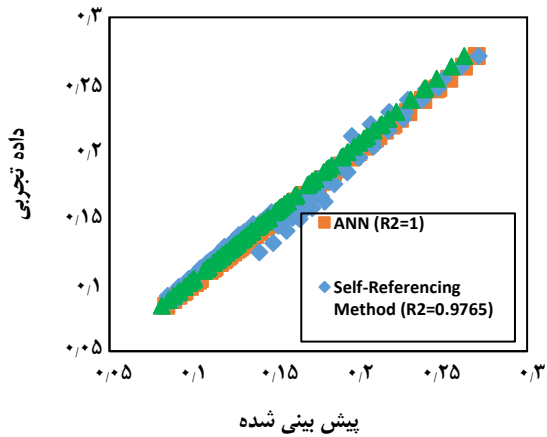
شکل ۳ - تغییر شاخص AAD % داده‌های آموزش و آزمون بر حسب تعداد نرون.




شکل ۸ - نمودار برازش گرانیوی داده‌های تجربی با پیش‌بینی شده مدل‌های گوناگون برای مخلوط $\text{CO}_2 + \text{PEB8}$.



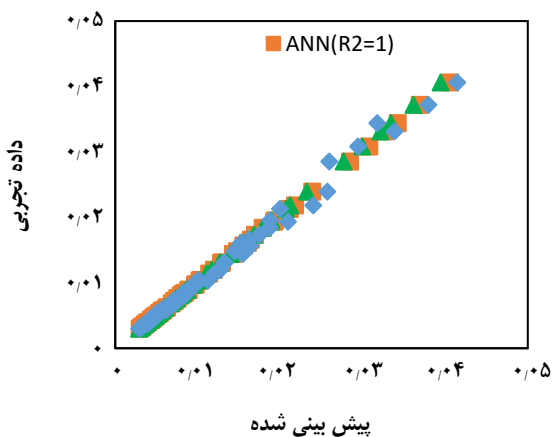
شکل ۵ - ارتباط مقدارهای گرانیوی پیش‌بینی شده شبکه و واقعی برای داده‌های آموزش.



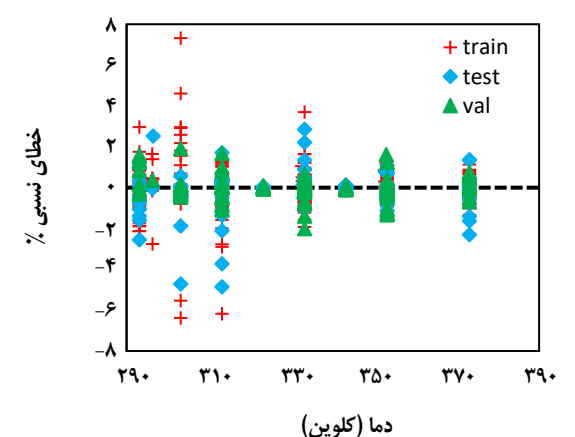
شکل ۹ - نمودار برازش گرانیوی داده‌های تجربی با پیش‌بینی شده مدل‌های گوناگون برای مخلوط $\text{CO}_2 + \text{PEC9}$.



شکل ۶ - ارتباط مقدارهای گرانیوی پیش‌بینی شده شبکه و واقعی برای داده‌های آزمون.



شکل ۱۰ - نمودار برازش گرانیوی داده‌های تجربی با پیش‌بینی شده مدل‌های گوناگون برای مخلوط $\text{CO}_2 + \text{Squalane}$.



شکل ۷ - خطای نسبی شبکه برای داده‌های آموزش، ارزیابی و آزمون بر حسب دما.

جدول ۶ - میانگین انحراف‌های مقدارهای محاسبه شده با استفاده از شبکه عصبی مصنوعی و مدل‌های گزارش شده در دماها و فشارهای گوناگون نسبت به مقدارهای تجربی.

مخلوط	مدل	AAD%	مدل	AAD%	مرجع
R-600a/LAB ISO 5	نوع ایرینگ ^(۱)	۶،۰۹	شبکه عصبی مصنوعی	۰،۴۹	[26]
R125+BAB15	معادله کاتسویا تاکیگاوا ^(۲)	۱،۴۷	شبکه عصبی مصنوعی	۰،۳۳	[24]
R134a+BAB15		۲،۲۳		۰،۴۸	
R143a+BAB15		۲،۲۷		۰،۴۸	
R32+BAB15		۳،۹۳		۰،۵۱	
R125+BAB32		۱،۹۰		۰،۴۷	
R134a+BAB32		۳،۸۳		۰،۴۴	
R143a+BAB32		۳،۴۰		۰،۴۳	
R32+BAB32		۱،۷۰		۰،۵۴	
CO2+Squalane	معادله گرونبرگ - نیسان ^(۳)	۳،۲	شبکه عصبی مصنوعی	۰،۶۸	[23]
CO2+Squalane	معادله آلیستر ^(۴)	۲،۹			
CO2 + PEC5	معادله کتی - چاودری	۲۲،۰۰	شبکه عصبی مصنوعی	۰،۱۰۸	[21]
	معادله گرونبرگ - نیسان	۲۴،۵۰			
	معادله گرونبرگ - نیسان اصلاح شده	۲،۲۰			
	روش خود ارجاع	۵،۲۰			
CO2 + PEC7	معادله کتی - چاودری	۲۲،۰۰	شبکه عصبی مصنوعی	۰،۱۰۸	[21]
	معادله گرونبرگ - نیسان	۲۳،۵۰			
	معادله گرونبرگ - نیسان اصلاح شده	۱،۶۰			
	روش خود ارجاع	۲،۵۵			
CO2 + PEC9	معادله کتی - چاودری	۳۰،۰۰	شبکه عصبی مصنوعی	۰،۱۰۸	[21]
	معادله گرونبرگ - نیسان	۳۲،۰۰			
	معادله گرونبرگ - نیسان اصلاح شده	۳،۲۵			
	روش خود ارجاع	۶،۵۰			
CO2+ PEB8	معادله کتی - چاودری	۲۱،۰۰	شبکه عصبی مصنوعی	۰،۱۰۸	[22]
	معادله گرونبرگ - نیسان	۲۲،۵۰			
	معادله گرونبرگ - نیسان اصلاح شده	۲،۰۰			
	روش خود ارجاع	۱،۹۰			

1) Eyring-type

2) Katsuya Takigawa equation

3) Grunberg-Nissan equation

4) McAllister equation

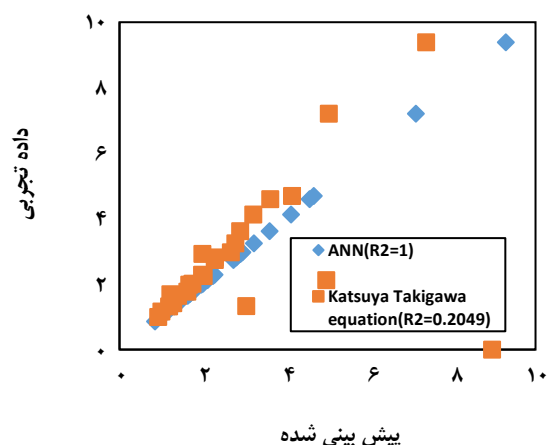
جدول ۶ - میانگین انحراف‌های مقدارهای محاسبه شده با استفاده از شبکه عصبی مصنوعی و مدل‌های گزارش شده در دماها و فشارهای گوناگون نسبت به مقدارهای تجربی. (ادامه)

مخلوط	مدل	AAD%	مدل	AAD%	مرجع
HFC-134a + TriEGDME	روش خود ارجاع	۵/۸۰	شبکه عصبی مصنوعی	۰/۴۰	[19],[20]
	معادله کتی - چاودری	۲۰/۴۰			
	معادله گرونبرگ - نیسان	۱۸/۵۰			
	معادله گرونبرگ - نیسان اصلاح شده	۶/۳۰			
	روش خود ارجاع	۴/۱۰			
	مدل کره سخت	۱۲/۳۰			
	مدل حجم آزاد	۱۳/۵۰			
	نظریه اصطکاک	۷/۶۰			
HFC-134a + TEGDME	معادله کتی - چاودری	۲۰/۴۰	شبکه عصبی مصنوعی	۰/۶۰	[18],[19]
	معادله گرونبرگ - نیسان	۱۷/۰۰			
	معادله گرونبرگ - نیسان اصلاح شده	۴/۶۰			
	روش خود ارجاع	۵/۲۰			
	مدل کره سخت	۵/۰۰			
	مدل حجم آزاد	۱۵/۱۰			
	نظریه اصطکاک	۸/۵۰			

قرارگرفت و شبکه عصبی مصنوعی به طور تصادفی با ۱۵۸، ۷۳۷ و ۱۵۸ نقطه داده به ترتیب مورد آموزش، ارزیابی و آزمون قرار گرفت و نتیجه‌های AAD% برای مجموعه داده‌های آموزش، ارزیابی و آزمون به ترتیب ۰/۳۹، ۰/۴۸ و ۰/۴۹ است. بر این اساس و با مقایسه شبکه عصبی آموزش دیده با سایر مدل‌ها و همبستگی‌ها، سمدل شبکه عصبی مصنوعی مطالعه شده با داده‌های تجربی همخوانی خوبی دارند.

قدردانی

با تشکر از دانشگاه یاسوج که از این پژوهش حمایت کرده است.



شکل ۱۱ - نمودار برازش گرانروی داده‌های تجربی با پیش‌بینی شده مدل‌های گوناگون برای مخلوط R125+BAB15.

مخلوط روان کننده و خنک کننده می‌باشد. تعداد ۱۰۵۳ داده‌ی تجربی از مطالعه‌های پیشین جمع‌آوری و برای طراحی شبکه مورد استفاده

تاریخ دریافت: ۱۳۹۷/۱۰/۲۴؛ تاریخ پذیرش: ۱۳۹۸/۴/۲۴

مراجع

- [1] NSI/ASHRAE Standard 34-2001, "Designation and Safety Classification of Refrigerants", (2010).
- [2] Haaf S., Henrici H. "Refrigeration Technology" in "Ullmann's Encyclopedia of Industrial Chemistry", Wiley-VCH, 2002.
- [3] Bartz W., Tribology, Lubricants and Lubrication Engineering—A Review, *Wear.*, **49**: 1-18 (1978).
- [4] Donnet C., Erdemir A., Historical Developments and New Trends in Tribological and Solid Lubricant Coatings, *Surface and Coatings Technology*, **180**: 76-84 (2004).
- [5] Martín-Alfonso J., Valencia C., Sánchez M., Franco J., Gallegos C., Development of New Lubricating Grease Formulations Using Recycled LDPE as Rheology Modifier Additive, *European Polymer Journal*, **43**, 149-139 (2007).
- [6] Scharf, C.R., Twining, S.R., Todd, P.R., "Functionalized Polymer as Grease Additive", ed: Google Patents, (2001).
- [7] Mermond Y., Feidt M., Marvillet C., Thermodynamic and Physical Properties of Mixtures of Refrigerants and Oils, *International Journal of Refrigeration*, **22**: 569-579 (1999).
- [8] Marsh, K. N., Kandil, M. E., Review of Thermodynamic Properties of Refrigerants+ Lubricant Oils, *Fluid Phase Equilibria*, **199**: 319-334 (2002).
- [9] Dayhoff J.E., Neural Networks Principles. Prentice-Hall International, U.S.A, 1990.
- [۱۰] البرزی، م؛ آشنایی با شبکه‌های عصبی، انتشارات دانشگاه صنعتی شریف، ص. ۳۷ (۱۳۸۰).
- [11] Zolfaghari, H., Yousefi, F. Thermodynamic Properties of Lubricant/Refrigerant Mixtures Using Statistical Mechanics and Artificial Intelligence, *International Journal of Refrigeration*, **80**: 130-144(2017).
- [12] Zolfaghari, H., Yousefi, F. PVT Properties of Pure Lubricants Using Equations of State and Artificial Intelligence, *Physical Chemistry Research*, **7**: 181-200(2019).
- [۱۳] سایت: انجمن هوش مصنوعی ایران به نشانی www.artificial.ir
- [14] Rumelhart. D. E., Hinton. G.E., Williams R. j., Learning Internal Representations by Error Propagation. *Parallel Data Processing*, **1**: 318 (1986).
- [15] Hirose Y., Yamashita K., Hijiya S., Back- Propagation Algorithm which Varies number of Hidden Units, *Neural Networks*, **4**: 61-66 (1991).
- [۱۶] غضنفری، ی؛ و کاظمی، ز؛ "اصول و مبانی سیستم‌های خبره - با فصولی درباره شبکه عصبی مصنوعی و تئوری مجموعه فازی"، دانشگاه علم و صنعت ایران، ص ۶۴۸ (۱۳۸۲).
- [۱۷] ثقه الاسلامی، ن؛ کریمی، ه؛ اخوت، ا؛ وطن‌خواه، غ؛ "اصول و کاربرد شبکه‌های عصبی در صنایع نفت و گاز". تهران: نشر جهش (۱۳۸۸).
- [18] Monsalvo M.A., Baylaucq A., Reghem P., Quiñones-Cisneros S.E., Boned C., Viscosity Measurements and Correlations of Binary Mixtures: 1,1,1,2-tetrafluoroethane (HFC134a) + Tetraethylene Glycoldimethylether (TEGDME), *Fluid Phase Equilibria*, **233**: 1-8 (2005).

- [19] María J.P. Comuñas, Antoine Baylaucq, Christian Boned, Josefa Fernández, [Dynamic Viscosity for HFC-134a + Polyether Mixtures up to 373.15 K and 140 MPa at Low Polyether Concentration. Measurements and Modelling](#), *Industrial & Engineering Chemistry Research*, **43**: 804–814 (2004).
- [20] Matías A. Monsalvo, Antoine Baylaucq, Sergio E. Quiñones-Cisneros, Christian Boned., [High-Pressure Viscosity Behavior of \$x\$ 1,1,1,2-tetrafluoroethane\(HFC-134a\) + \(1-x\) triethylene glycol dimethylether \(TriEGDME\) mixtures: Measurements and Modeling](#), *Fluid Phase Equilibria*, **247**: 70–79 (2006).
- [21] Pensado A.S., Pádua A.A.H., Comuñas M.J.P., Fernández J., [Viscosity and Density Measurements for Carbon Dioxide + Pentaerythritolester Lubricant Mixtures at Low Lubricant Concentration](#), *J. of Supercritical Fluids*, **44**: 172–185 (2008).
- [22] Pensado A. S., H. Padua A. A., Comunas M. J. P., Fernandez J., [High-Pressure Viscosity and Density of Carbon Dioxide 1 Pentaerythritol Ester Mixtures: Measurements and Modeling](#), *AIChE Journal*, **54**: 1625-1636 (2008).
- [23] Tomida D., Kumagai A., Yokoyama C., [Viscosity Measurements and Correlation of the Squalane + CO₂ Mixture](#), *International Journal of Thermophysics*, **28**: 133-145 (2007).
- [24] Katsuya Takigawa., Stanley I.Sandler., Akimichi Yokozeki., [Solubility and Viscosity of refrigerant/Lubricant Mixtures: Hydrofluorocarbon/Alkylbenzene Systems](#), *International Journal of Refrigeration*, **25**: 1014–1024 (2002).
- [25] Bair S., Baker M., Pallister D.M., [The High-Pressure Viscosity of Refrigerant/Oil Systems](#), *Lubrication Science*, **6**: 377-394 (2017).
- [26] Moisés A., Marcelino Neto., Jader R. Barbosa Jr., [Solubility, Density and Viscosity of Mixtures of Isobutane \(R-600a\) and a Linear Alkylbenzene Lubricant](#), *Fluid Phase Equilibria*, **292**: 7-12 (2010).