

# استفاده از شبکه‌های عصبی مصنوعی برای شناسایی خواص ترمودینامیکی محلول لیتیوم برماید-آب

سیدمصطفی حسینعلی‌پور<sup>i\*</sup>; سیدمحمدابراهیم درخشانی<sup>ii</sup>; محمد Mehdi عارفی<sup>iii</sup>

چکیده

در این مقاله از شبکه‌های عصبی برای شناسایی خواص ترمودینامیکی محلول لیتیوم برماید-آب که یکی از پرکاربردترین محلول‌ها در شبیه‌سازی‌های ترمودینامیکی می‌باشد، استفاده شده است. برای آموزش شبکه عصبی از داده‌های شبیه‌سازی شده ناشی از تحلیل ترمودینامیکی استفاده شده است. به جای استفاده از معادلات پیچیده دیفرانسیلی و داده‌های تجربی محدود، استفاده از مدل شبکه عصبی استخراج شده پاسخ‌های سریع‌تر و ساده‌تری را در اختیار قرار می‌دهد. با استفاده از شبکه‌های عصبی، خواص محلول لیتیوم برماید-آب به صورت روابط ریاضی استخراج گردید. نتایج شبیه‌سازی دقت بسیار زیاد شبکه‌های عصبی را در شناسایی خواص ترمودینامیکی محلول لیتیوم برماید-آب نشان می‌دهند.

**كلمات کلیدی :** محلول لیتیوم برماید-آب، شبکه‌های عصبی، خواص ترمودینامیکی

## *Identification of LiBr-Water Solution Thermodynamic Properties using the ANN Technique*

S.M. Hosseinalipour; S.M.E. Derakhshani; M.M. Arefi

### ABSTRACT

In this study, Artificial Neural Networks (ANNs) technique is applied for the determination of thermodynamic properties of the Lithium Bromide-Water solution, which is widely used in the thermodynamic simulations. For training of the ANNs the simulation results of a thermodynamic analysis are used. The presented ANN model provides simpler and faster results comparing to complex differential equations and existing limited experimental data. Using the ANN technique, the thermodynamic properties of LiBr-Water solution are derived as the mathematical relations. Simulation results show the effectiveness of ANN in identification of LiBr-Water solution thermodynamic properties.

**KEYWORDS :** Lithium-Bromide Water Solution, Artificial Neural Networks, Thermodynamic Properties

تاریخ دریافت مقاله: ۱۳۸۶/۷/۲۲

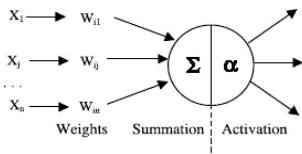
تاریخ اصلاحات مقاله: ۱۳۸۷/۱۲/۲۲

<sup>i</sup>\* نویسنده مسئول و دانشیار، دانشکده مهندسی مکانیک، دانشگاه علم و صنعت ایران، E-mail: alipour@iust.ac.ir

<sup>ii</sup> مریبی، دانشکده مهندسی مکانیک، موسسه غیر انتفاعی غیردولتی راغب اصفهانی، E-mail: e.derakhshani@raghebisf.ac.ir

<sup>iii</sup> دانشجوی دکتری، دانشکده مهندسی برق، دانشگاه علم و صنعت ایران، E-mail: arefi@iust.ac.ir

مختلف نظیر کنترل، بهینه‌سازی، تشخیص الگو، فشرده‌سازی و طبق‌بندی اطلاعات، پیش‌بینی آب و هوا، پردازش تصویر و صدا بکار برده می‌شوند. شبکه‌های عصبی برای غله بر محدودیتهای روشهای مرسوم برای حل مسائل پیچیده آموخته دیده می‌شوند. اصلی‌ترین جزء شبکه عصبی سلول نام دارد. به طور اساسی سلولهای بیولوژیکی با دریافت و رویدها از برخی منابع، آنها را از طرق مختلفی با یکدیگر ترکیب می‌نمایند و سپس با انجام عملیات غیرخطی بر روی نتایج، خروجی نهایی را ارائه می‌نمایند. شبکه‌های عصبی بیشتر شامل یک لایه ورودی و یک یا چند لایه میانی و یک لایه خروجی می‌باشند [۶]. هر ورودی در وزن مربوط به خودش ضرب می‌گردد. در ساده‌ترین حالت خروجی‌ها و بایاس‌ها با یکدیگر جمع و سپس از تابع فعال‌سازی برای تولید خروجی‌ها عبور می‌نمایند. در شکل ۱ پردازش اطلاعات در یک سلول شبکه عصبی نشان داده شده است. شبکه‌های دارای بایاس، رابطه بین ورودی‌ها و خروجی‌ها را بسیار راحت‌تر از شبکه‌های بدون بایاس بدست می‌آورند.



شکل (۱): پردازش اطلاعات در یک سلول شبکه عصبی

در شکل ۱، خروجی برای سلول نام به صورت رابطه ۱ می‌باشد:

$$\alpha_i = f\left(\sum_{j=1}^n X_j W_{ij}\right) \quad (1)$$

تابع فعال‌سازی به طور کلی از روابط جبری خطی و یا غیرخطی تشکیل شده‌اند [۸]. مهمترین مرحله در شبکه‌های عصبی بخش آموخته شبکه می‌باشد. در حالت کلی دو روش مختلف برای آموخته شبکه وجود دارد که عبارتند از: آموخته کنترل‌پذیر و آموخته غیرقابل کنترل. مرسوم‌ترین الگوریتم آموخته، الگوریتم آموخته پس انتشار خطای می‌باشد.

انتخاب بهترین و سریع‌ترین الگوریتم آموخته برای حل مسائل بسیار مشکل و مهم می‌باشد. شبکه عصبی به کمک الگوریتم پس انتشار خطای از طریق تغییر وزن لایه‌های میانی آموخته می‌بیند و این تغییرات به عنوان مفروضات شبکه ذخیره می‌گردند. برخی از روشهای آماری نظریه ریشه میانگین مربعات خطای میانگین مربعات خطای، کسر مطلق واریانس و درصد ضریب واریانس برای بررسی درستی نتایج مورد استفاده قرار می‌گیرند. خطای در طول آموخته با ریشه میانگین

یکی از کاربردهای خواص ترمودینامیکی محلول لیتیوم برماید-آب در شبیه‌سازی عملکرد سیکل چیلرهای جذبی می‌باشد. از آنجا که برخی از خواص این محلول به صورت جداول ترمودینامیکی موجود می‌باشد و برخی دیگر به صورت فرمولهای تجربی که تنها برای محدوده خاصی از دما و غلظت محلول دارای دقت کافی می‌باشند، لذا به کمک شبکه عصبی و استخراج مقادیر معتبر روابطی برای کلیه خواص ترمودینامیکی این محلول استخراج گردید. از طرف دیگر برنامه‌های رایانه‌ای تحلیلی برای ارائه جوابی دقیق نیاز به انجام محاسبات زیادی دارند که نیازمند گذران زمان و استفاده از رایانه‌های قدرتمند می‌باشد. در صورتی که تعداد پارامترهای مورد بررسی افزایش یابد، زمان و حجم محاسبات به صورت نمایی افزایش می‌یابد [۱]. در نتیجه برای محققین، استفاده از روابط ساده و فراگیر به دست آمده از شبکه‌های عصبی با قابلیت یادگیری الگوهای مختلف بجای استفاده از روابط پیچیده و محدود و همچنین استفاده از جداول ناقص و ناپیوسته مطلوبتر می‌باشد. در دهه‌های اخیر از شبکه‌های عصبی به طور گستردگی استفاده شده است [۲-۱۰] که اینک به مواردی اشاره می‌گردد. آقای سن‌کن و همکارانش [۱۱]، فشار محلول لیتیوم برماید-آب را بر اساس دما و غلظت محلول با استفاده از شبکه عصبی بدست آورند و در تحقیقی دیگر [۱۲] برای مدلسازی سیکل چیلر جذبی، رابطه آنتالپی با غلظت و دمای محلول لیتیوم برماید-آب را به کمک شبکه‌های عصبی شناسایی کردند. آقای سن‌کن [۱۳]، در آخرین تحقیق خود روابط ترمودینامیکی محلول آمونیاک-آب را به کمک شبکه عصبی شناسایی کرد. آقای کایتا [۱۴]، برخی از روابط ترمودینامیکی مربوط به محلول لیتیوم برماید-آب را برای دماهای بالا به صورت آزمایشگاهی استخراج کرده است. آقای سوزن و همکارانش [۱۵]، رابطه چگالی محلول لیتیوم برماید-آب را بر اساس دما و غلظت محلول به کمک شبکه عصبی مدلسازی نمود. در مقاله حاضر به کمک شبکه‌های عصبی روابط ترمودینامیکی محلول لیتیوم برماید-آب بر اساس دما و غلظت محلول بدست آمده‌اند. به علت استفاده از مقادیر مختلف و متنوع جهت آموخته شبکه عصبی، روابط به دست آمده در این مقاله قابل کاربرد در گسترده وسیعی از دماها و غلظتها می‌باشند.

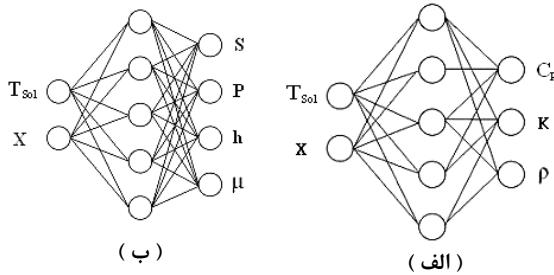
## ۲- شبکه‌های عصبی مصنوعی

شبکه‌های عصبی به صورت گستردگی در زمینه‌های



شناسایی روابط ترمودینامیکی محلول لیتیوم برماید-آب در شکل ۲ نمایش داده شده‌اند.

غاظت محلول لیتیوم برماید-آب،  $x$ ، و دمای محلول،  $T_{sol}$ ، به عنوان ورودی‌های شبکه عصبی در نظر گرفته شده‌اند. همچنین آتروپی،  $s$ ، آنتالپی،  $h$ ، فشار،  $p$ ، چگالی،  $\rho$ ، ظرفیت گرمایی ویژه،  $C_p$ ، گرانروی،  $\mu$ ، و ضریب گردایت حرارتی،  $k$ ، به عنوان خروجی‌های شبکه عصبی در نظر گرفته شده‌اند.



شکل (۲): ساختار آموزشی شبکه عصبی با خروجی‌های متفاوت

جدول (۱): مقادیر اسمی و حوزه تغییرات پارامترهای مدل‌سازی [۶] و [۷]

Parameter	Temperature Range	Solution Concentration Range
$S (kj/kg.K)$	$0 \leq T \leq 190^{\circ}C$	$40 \leq x \leq 75 \text{ wt.\%}$
$P (kPa)$	$5 \leq T \leq 175^{\circ}C$	$45 \leq x \leq 70 \text{ wt.\%}$
$h (kj/kg)$	$15 \leq T \leq 165^{\circ}C$	$40 \leq x \leq 70 \text{ wt.\%}$
$\rho (kg/m^3)$	$0 \leq T \leq 200^{\circ}C$	$20 \leq x \leq 60 \text{ wt.\%}$
$\mu (kg/m.s)$	$0 \leq T \leq 190^{\circ}C$	$45 \leq x \leq 65 \text{ wt.\%}$
$k (w/m.K)$	$0 \leq T \leq 400^{\circ}C$	-----
$C_p (j/kg.K)$	-----	-----

برای شناسایی روابط ترمودینامیکی موجود بین متغیرهای ورودی و خروجی، از شبکه عصبی پرسپترون دولایه استفاده شده است. مقادیر مورد استفاده در این شبکه بر اساس مقادیر آزمایشگاهی موجود در مراجع معتبر بدست آمده‌اند. شبکه مورد استفاده دارای یک لایه ورودی، یک لایه خروجی و یک لایه میانی می‌باشد. با افزایش تعداد لایه‌های میانی دقت افزایش می‌باید ولی معادلات بدست آمده بعدی، پیچیده‌تر می‌شوند. در مسائل مهندسی روابط ساده با دقت مناسب مورد نظر می‌باشند. توابع فعال‌سازی لایه ورودی خطی می‌باشند ولی در لایه میانی از توابع غیرخطی پیوسته و مشتق‌پذیر تائزانت سیگموئید استفاده شده است. تابع تائزانت سیگموئید به شکل رابطه ۹ تعریف می‌گردد:

$$\text{tansig}(n) = 2/(1 + \exp(-2 \times n)) - 1 \quad (9)$$

که در آن  $n$  عبارتست از

مربعات خطأ و یا میانگین مربعات خطأ مشخص می‌شود که به صورت روابط ۲ و ۳ محاسبه می‌گردد:

$$RMS = \left( (1/p) \sum_j |t_j - o_j|^2 \right)^{1/2} \quad (2)$$

$$MSE = \frac{1}{n} \sum_{j=1}^n (t_j - o_j)^2 \quad (3)$$

همچنین کسر مطلق واریانس و درصد ضریب واریانس به ترتیب بر طبق روابط ۴ و ۵ تعریف می‌شوند

$$R^2 = 1 - \left( \sum_j |t_j - o_j|^2 / \sum_j (o_j)^2 \right) \quad (4)$$

$$\text{cov} = \frac{RMS}{o_{mean}} \times 100 \quad (5)$$

که در آن  $t$  مقدار هدف،  $o$  مقدار خروجی،  $p$  به عنوان الگو و  $o_{mean}$  میانگین مقدار کلیه خروجی‌ها می‌باشد. همچنین  $n$  بیانگر تعداد خروجی‌های شبکه عصبی می‌باشد. برای افزایش دقت و یادگیری شبکه، مقادیر ورودی و خروجی به شبکه عصبی بین [۱۰-۱۶] نرمالیزه شدن. ورودی‌ها و خروجی‌های مورد نظر برای آزمون و آموزش شبکه به صورت روابط ماتریسی ۷، ۶ و ۸ چیدمان شدند.

$$Input = \begin{bmatrix} T_{sol1} & X_1 \\ \vdots & \vdots \\ T_{soln} & X_n \end{bmatrix} \quad (6)$$

$$Output_1 = \begin{bmatrix} C_{p1} & K_1 & \rho_1 \\ \vdots & \vdots & \vdots \\ C_{pn} & K_n & \rho_n \end{bmatrix} \quad (7)$$

$$Output_2 = \begin{bmatrix} S & P & h & \mu \\ \vdots & \vdots & \vdots & \vdots \\ S & P & h & \mu \end{bmatrix} \quad (8)$$

این مقادیر براساس نتایج آزمایشگاهی مراجع معتبر [۱۶] و [۱۰] استخراج گردیده‌اند.

### ۳- شناسایی روابط ترمودینامیکی محلول لیتیوم

#### برماید-آب به کمک شبکه‌های عصبی

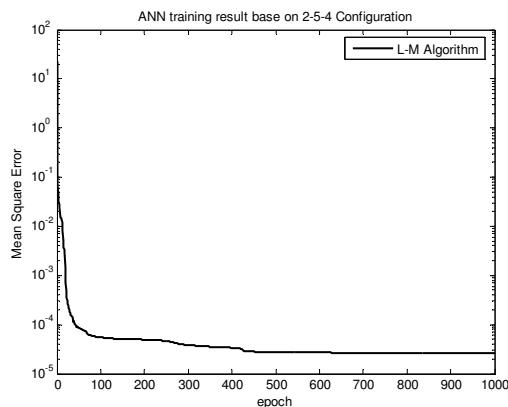
شبکه‌های عصبی با پردازش روی داده‌های تجربی، دانش یا قانون نهفته در ورای داده‌ها را شناسایی می‌کنند. هدف این مقاله بکارگیری شبکه‌های عصبی برای شناسایی خواص ترمودینامیکی محلول لیتیوم برماید-آب به صورت روابط تحلیلی می‌باشد.

بانوچه به ناشتن همپوشانی حوزه اعتبار برخی از متغیرهای موجود، از دو شبکه عصبی متفاوت استفاده گردید. همچنین برای آموزش و آزمون هر شبکه از مقادیر معتبر در حوزه اعتبار آن استفاده شد.

ساختار آموزشی شبکه‌های عصبی مورد استفاده برای

## ۴- نتایج شبیه‌سازی

در این مقاله روابط ترمودینامیکی محلول لیتیوم برماید-آب با استفاده از شبکه‌های عصبی استخراج گردیدند. برای آموزش شبکه عصبی از دو نوع الگوریتم آموزشی پس‌انتشار خطا استفاده شد و مشخص گردید که الگوریتم لوینبرگ-مارکوارت نسبت به الگوریتم گرادیان نزولی از همگرایی و دقت بهتری برخوردار می‌باشد که به روشنی در شکل‌های ۴ و ۵ قابل دیدن است. برای آموزش و آزمون شبکه عصبی از ۱۸۰۰ حالت سیستم استفاده گردید. از این تعداد ۱۲۰۰ دسته برای آموزش شبکه و ۶۰۰ دسته باقی‌مانده برای آزمون شبکه استفاده شد. امکان استفاده از الگوریتم‌های مختلفی برای آموزش شبکه عصبی وجود دارد. دو الگوریتم آموزشی لوینبرگ-مارکوارت و گرادیان نزولی برای آموزش شبکه مورد استفاده قرار گرفتند. پس از آموزش شبکه عصبی با این دو الگوریتم و مقایسه مقدار میانگین مربعات خطا آنها با یکی‌گر، دیده شد که الگوریتم آموزشی لوینبرگ-مارکوارت دارای دقت و سرعت بیشتری برای آموزش شبکه می‌باشد. این نتایج در جدول ۲ آمده‌اند.



شکل (۵): آموزش شبکه عصبی (ب) بر اساس مقادیر نرمالیزه شده

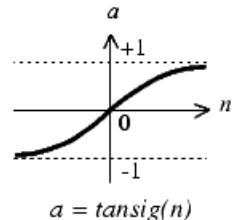
جدول (۲): بررسی نتایج روش‌های مختلف برای آموزش شبکه عصبی (الف)

Algorithm	Neurons in Hidden Layer	Test Data	MSE
Levenberg-Marquardt	۳	Normalized	$9.0278 \times 10^{-6}$
	۵	Normalized	$1.0437 \times 10^{-6}$
Gradient Descent	۳	Normalized	$4.705 \times 10^{-1}$
	۵	Normalized	$3.469 \times 10^{-1}$

برای شناسایی بهترین ساختار برای شبکه عصبی، تعداد سلولهای لایه پنهان از ۳ تا ۱۲ سلول تغییر داده شد. در پایان

$$n = w_{ji} \times u_i + b_i \quad (10)$$

خروجی‌های تابع تانژانت سیکموئید بین اعداد ۱ و -۱ می‌باشند.



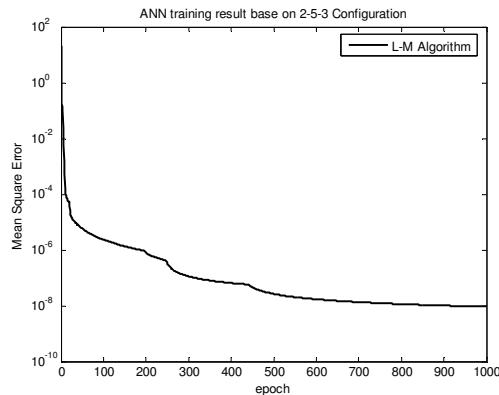
شکل (۳): نمودار تابع تانژانت سیکموئید

در این تحقیق از دو نوع الگوریتم آموزش استفاده شده است که عبارتند از:

۱. الگوریتم پس‌انتشار خطا لوینبرگ-مارکوارت که از روش‌های بهینه‌سازی مرتبه دوم مبتنی بر مشتق‌ات مرتبه دوم تابع خطا می‌باشد [۱۷].

۲. الگوریتم گرادیان نزولی که از روش‌های بهینه‌سازی مرتبه اول مبتنی بر مشتق مرتبه اول تابع خطا می‌باشد [۱۸]. شبکه عصبی با مقادیر ورودی و خروجی واقعی و همچنین مقادیر نرمالیزه شده بین [۰۱] به صورت جداول آموزش دید.

به کمک بسته شبکه عصبی نرم‌افزار متلب برنامه‌ای نوشته شده است. در این برنامه کارایی شبکه عصبی به کمک میانگین مربعات خطا ارزیابی قرار می‌گیرد. کاهش مقدار میانگین مربعات خطا در زمان آموزش شبکه عصبی و مقادیر کمتر از  $1 \times 10^{-7}$  بیانگر همگرایی شبکه می‌باشد. آموزش شبکه تا رسیدن به همگرایی مطلوب می‌تواند ادامه یابد. در اشکال ۴ و ۵ همگرایی شبکه‌های عصبی الف و ب نشان داده شده است.



شکل (۴): آموزش شبکه عصبی (الف) بر اساس مقادیر نرمالیزه شده

جدول (۵): بررسی آماری اثر تعداد سلولهای لایه پنهان برای شبکه عصبی (ب) بر اساس نتایج آموزش شبکه عصبی

Neurons	MSE	RMS	R <sup>2</sup>	COV
۳	۱/۲×۱۰ <sup>-۳</sup>	۰/۰۰۰۱۲۵	۰/۹۹۸۵	۵/۰۶۵۳
۴	۲/۰۱×۱۰ <sup>-۴</sup>	۸/۵۶×۱۰ <sup>-۵</sup>	۰/۹۹۹۹	۳/۴۵۶۴
۵	۲/۶۳×۱۰ <sup>-۷</sup>	۲/۷۶×۱۰ <sup>-۶</sup>	۱	۱/۲۱×۱۰ <sup>-۱</sup>
۶	۷/۴۳×۱۰ <sup>-۵</sup>	۴/۰۶×۱۰ <sup>-۵</sup>	۰/۹۹۹۸	۱/۶۳۹۴
۷	۲/۹×۱۰ <sup>-۶</sup>	۲/۱۹×۱۰ <sup>-۵</sup>	۰/۹۹۹۹	۸/۸۶×۱۰ <sup>-۱</sup>
۸	۱/۳×۱۰ <sup>-۶</sup>	۱/۱۶×۱۰ <sup>-۵</sup>	۰/۹۹۹۹	۴/۶۸×۱۰ <sup>-۱</sup>
۹	۸/۱۱×۱۰ <sup>-۷</sup>	۱/۰۷×۱۰ <sup>-۵</sup>	۰/۹۹۹۹	۴/۳×۱۰ <sup>-۱</sup>
۱۰	۹/۸۹×۱۰ <sup>-۷</sup>	۱/۰۲×۱۰ <sup>-۵</sup>	۰/۹۹۹۹	۰/۴۱۱۴۶
۱۱	۱/۲۹×۱۰ <sup>-۶</sup>	۱/۱۶×۱۰ <sup>-۵</sup>	۰/۹۹۹۹	۰/۴۶۹۷۳
۱۲	۴/۷×۱۰ <sup>-۵</sup>	۸/۲۱×۱۰ <sup>-۵</sup>	۰/۹۹۹۳	۳/۳۱۷۱

جدول (۶): بررسی آماری اثر تعداد سلولهای لایه پنهان برای شبکه عصبی (ب) بر اساس مقادیر مورد استفاده برای آزمون شبکه عصبی

Neurons	MSE	RMS	R <sup>2</sup>	COV
۳	۲/۲۵×۱۰ <sup>-۸</sup>	۰/۰۰۰۱۵۳	۰/۹۹۷۸	۶/۲۹۲۳
۴	۱/۰۳×۱۰ <sup>-۸</sup>	۱/۰۲×۱۰ <sup>-۴</sup>	۰/۹۹۹۰	۴/۱۵۲۵
۵	۱/۰۵۰×۱۰ <sup>-۱۱</sup>	۲/۹۴×۱۰ <sup>-۶</sup>	۱	۱/۶۰×۱۰ <sup>-۱</sup>
۶	۲/۵۵×۱۰ <sup>-۹</sup>	۵/۰۵×۱۰ <sup>-۵</sup>	۰/۹۹۹۷	۲/۰۵
۷	۸/۵۹×۱۰ <sup>-۱۰</sup>	۲/۹۳×۱۰ <sup>-۵</sup>	۰/۹۹۹۹	۱/۱۹
۸	۲/۲۰×۱۰ <sup>-۱۰</sup>	۱/۴۸×۱۰ <sup>-۵</sup>	۰/۹۹۹۹	۶/۰۳×۱۰ <sup>-۱</sup>
۹	۱/۸۲×۱۰ <sup>-۱۰</sup>	۱/۲۵×۱۰ <sup>-۵</sup>	۰/۹۹۹۹	۵/۵×۱۰ <sup>-۱</sup>
۱۰	۲/۱۶×۱۰ <sup>-۱۰</sup>	۱/۴۷×۱۰ <sup>-۵</sup>	۰/۹۹۹۹	۵/۹۸×۱۰ <sup>-۱</sup>
۱۱	۲/۱۲×۱۰ <sup>-۱۰</sup>	۱/۴۶×۱۰ <sup>-۵</sup>	۰/۹۹۹۹	۵/۹۳×۱۰ <sup>-۱</sup>
۱۲	۱/۰۵×۱۰ <sup>-۹</sup>	۱/۰۳×۱۰ <sup>-۵</sup>	۰/۹۹۹۸	۱/۲۱۴۳

همچنین شبکه با مقادیر حقیقی و نرمالیزه شده در بازه [۰۱] آموزش داده شد. برای نرمالیزه کردن این مقادیر از رابطه شماره ۱۱ استفاده شده است.

$$v_n = 2(v_R - v_{Min}) / (v_{Max} - v_{Min}) - 1 \quad (11)$$

نتایج نشان می‌دهند که شبکه آموزش دیده شده با مقادیر نرمالیزه از دقت بالاتری برخوردار می‌باشد. در شکل ۶ می‌توان دقت نتایج به دست آمده از شبکه عصبی آموزش دیده شده با مقادیر نرمالیزه را دید.

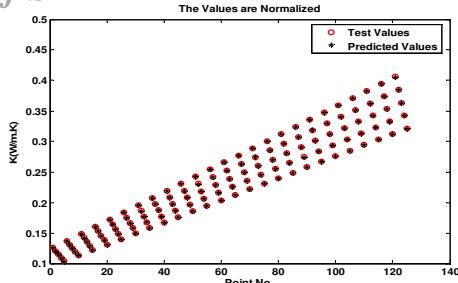
شبکه‌ای که مقدار میانگین مربعات خطأ آن نسبت به سایر شبکه‌ها کمتر بود به عنوان شبکه عصبی مرجع انتخاب گردید. پس از مقایسه نتایج حاصل از آموزش و تست شبکه‌های عصبی با سلولهای مختلف در لایه میانی که در جداول ۳ الی ۶ آمده است، شبکه عصبی با ۵ سلول در لایه میانی بدلیل دقت بالاتر انتخاب گردید.

جدول (۳): بررسی آماری اثر تعداد سلولهای لایه پنهان برای شبکه عصبی (الف) بر اساس نتایج آموزش شبکه عصبی

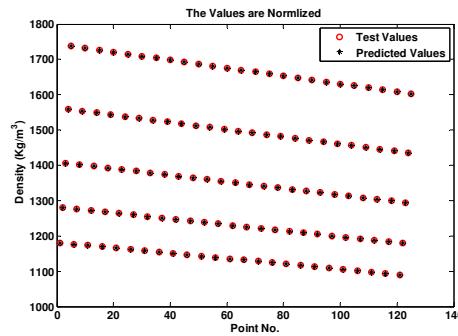
Neurons	MSE	RMS	R <sup>2</sup>	COV
۳	۱/۹×۱۰ <sup>-۵</sup>	۰/۰۰۰۳۲۱	۱	۰/۰۲۲۴۸
۴	۱/۷۶×۱۰ <sup>-۶</sup>	۸/۶۶×۱۰ <sup>-۵</sup>	۱	۰/۰۰۵۸۱۴
۵	۱/۲۵×۱۰ <sup>-۱۰</sup>	۷/۹۳×۱۰ <sup>-۷</sup>	۱	۵/۳۳×۱۰ <sup>-۵</sup>
۶	۱/۳۹×۱۰ <sup>-۹</sup>	۱/۶۳×۱۰ <sup>-۶</sup>	۱	۰/۰۰۱۰۹
۷	۲/۳×۱۰ <sup>-۱۰</sup>	۹/۵۱×۱۰ <sup>-۷</sup>	۱	۶/۳۹×۱۰ <sup>-۵</sup>
۸	۵/۸۹×۱۰ <sup>-۸</sup>	۸/۶۶×۱۰ <sup>-۵</sup>	۱	۰/۰۰۷۱۹
۹	۱/۶۹×۱۰ <sup>-۱۰</sup>	۸/۹۷×۱۰ <sup>-۷</sup>	۱	۶/۰۲×۱۰ <sup>-۵</sup>
۱۰	۸/۱۲×۱۰ <sup>-۱۰</sup>	۱/۸۱×۱۰ <sup>-۴</sup>	۱	۰/۰۰۱۲۱
۱۱	۵/۷۹×۱۰ <sup>-۱۰</sup>	۱/۸×۱۰ <sup>-۶</sup>	۱	۰/۰۰۱۲۱
۱۲	۷/۲۵×۱۰ <sup>-۱۰</sup>	۹/۴۶×۱۰ <sup>-۷</sup>	۱	۶/۳۵×۱۰ <sup>-۵</sup>

جدول (۴): بررسی آماری اثر تعداد سلولهای لایه پنهان برای شبکه عصبی (الف) بر اساس مقادیر مورد استفاده برای آزمون شبکه عصبی

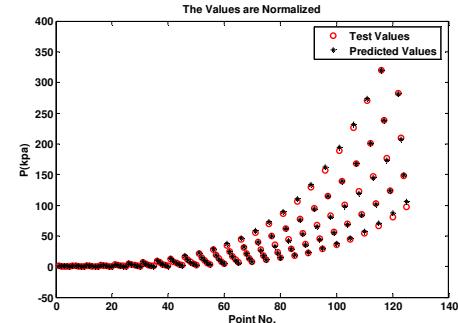
Neurons	MSE	RMS	R <sup>2</sup>	COV
۳	۲/۴۵×۱۰ <sup>-۶</sup>	۰/۰۰۱۵۶۴	۱	۰/۰۰۰۷۷۶
۴	۴/۲۳×۱۰ <sup>-۷</sup>	۰/۰۰۰۶۵	۱	۰/۰۰۳۲۲
۵	۴/۹۴×۱۰ <sup>-۱۱</sup>	۷/۰۳×۱۰ <sup>-۶</sup>	۱	۳/۴۹×۱۰ <sup>-۶</sup>
۶	۴/۰۵×۱۰ <sup>-۹</sup>	۶/۳۷×۱۰ <sup>-۵</sup>	۱	۳/۱۶×۱۰ <sup>-۵</sup>
۷	۱/۰۵×۱۰ <sup>-۹</sup>	۳/۲۴×۱۰ <sup>-۵</sup>	۱	۱/۶۱×۱۰ <sup>-۵</sup>
۸	۲/۲۷×۱۰ <sup>-۸</sup>	۰/۰۰۱۵۱	۱	۷/۴۸×۱۰ <sup>-۵</sup>
۹	۲/۲۴×۱۰ <sup>-۸</sup>	۰/۰۰۰۱۵	۱	۷/۴۲×۱۰ <sup>-۵</sup>
۱۰	۲/۵۵×۱۰ <sup>-۱۰</sup>	۱/۶×۱۰ <sup>-۵</sup>	۱	۷/۹۳×۱۰ <sup>-۶</sup>
۱۱	۵/۸۰×۱۰ <sup>-۱۱</sup>	۷/۶۲×۱۰ <sup>-۶</sup>	۱	۳/۷۸×۱۰ <sup>-۶</sup>
۱۲	۳/۵۰×۱۰ <sup>-۱۰</sup>	۱/۸۷×۱۰ <sup>-۵</sup>	۱	۹/۲۸×۱۰ <sup>-۶</sup>



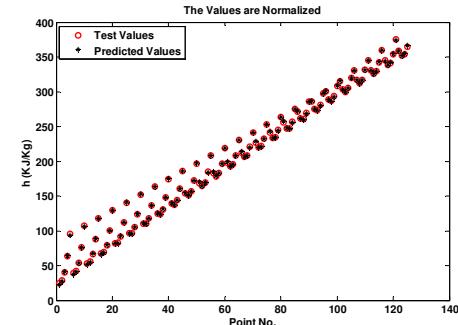
شکل (۹): ارزیابی شبکه عصبی آموزش داده شده با داده‌های نرمالیزه برای ضریب گردایت حرارتی



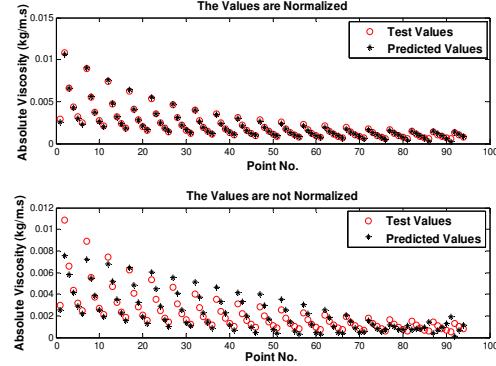
شکل (۱۰): ارزیابی شبکه عصبی آموزش داده شده با داده‌های نرمالیزه برای چکالی



شکل (۱۱): ارزیابی شبکه عصبی آموزش داده شده با داده‌های نرمالیزه برای فشار

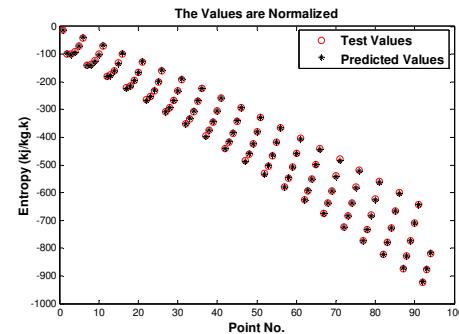


شکل (۱۲): ارزیابی شبکه عصبی آموزش داده شده با داده‌های نرمالیزه برای آنتالپی

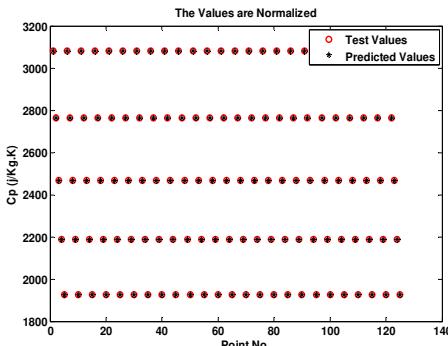


شکل (۱۴): ارزیابی شبکه عصبی آموزش داده شده با داده‌های نرمالیزه شده (نمودار بالا) و داده‌های حقیقی (نمودار پایین) برای گرانزوی

در ادامه نتایج شبیه‌سازی روابط خواص ترمودینامیکی محلول لیتیوم برماید-آب که با مقادیر نرمالیزه آموزش دیده شده‌اند برای سایر خواص محلول در اشکال ۷ الی ۱۲ نمایش داده شده است.



شکل (۱۵): ارزیابی شبکه عصبی آموزش داده شده با داده‌های نرمالیزه برای آنتروپی



شکل (۱۶): ارزیابی شبکه عصبی آموزش داده شده با داده‌های نرمالیزه برای ظرفیت گرمایی ویژه



نرم‌الیزه می‌باشد و با استفاده از رابطه (۳۹) می‌توان مقادیر واقعی را بدست آورد. براساس مقادیر به دست آمده برای ضرایب رگرسیون خروجی‌های شبکه عصبی، می‌توان به دقت بالای جوابهای حاصل از شبکه پی برد. به عنوان نمونه در جدول ۷، برای گرانزوی محلول لیتیوم برماید بین مقادیر واقعی و مقادیر به دست آمده توسط شبکه عصبی مقایسه‌ای انجام شده است. با دقت در نتایج ثبت شده در این جدول می‌توان به دقت بالای جوابهای به دست آمده از شبکه عصبی پی برد.

جدول (۷): بررسی بین مقادیر واقعی و مقادیر به دست آمده از

#### شبکه عصبی (الف) برای گرانزوی محلول لیتیوم برماید

No.	Actual Output	ANN Output	% Relative Error
۱	.۰۰۱۲۴	.۰۰۱۲۸	-۳٪
۲	.۰۰۲۷۱	.۰۰۲۷۵	-۱٪
۳	.۰۰۳۶۷	.۰۰۳۶۲	۱٪
۴	.۰۰۴۲۵	.۰۰۴۲۱	۰٪
۵	.۰۰۵۳۷	.۰۰۵۳۰	۱٪
۶	.۰۰۶۶۲	.۰۰۶۶۹	-۱٪
۷	.۰۰۷۱۳	.۰۰۷۱۸	-۰٪
۸	.۰۰۸۹۹	.۰۰۸۹۶	-۰٪
۹	.۰۱۳۴۷	.۰۱۳۴۳	۰٪

همچنین روابط ۲۵ تا ۳۴ براساس شبکه عصبی (ب) برای خواص ترمودینامیکی  $s$ ,  $h$ ,  $p$  و  $\mu$  به دست آمدند:

$$E_1 = 1.3205T - 0.4157X - 2.0214 \quad (25)$$

$$F_1 = \frac{2}{1 + \exp(-2E_1)} - 1 \quad (26)$$

$$E_2 = 0.2912T - 0.7190X + 0.8385 \quad (27)$$

$$F_2 = \frac{2}{1 + \exp(-2E_2)} - 1 \quad (28)$$

$$E_3 = -0.2352T - 0.0983X + 0.4781 \quad (29)$$

$$F_3 = \frac{2}{1 + \exp(-2E_3)} - 1 \quad (30)$$

$$E_4 = 0.2757T - 0.0206X + 0.1813 \quad (31)$$

$$F_4 = \frac{2}{1 + \exp(-2E_4)} - 1 \quad (32)$$

$$E_5 = 1.4010T - 0.8040X + 2.9618 \quad (33)$$

$$F_5 = \frac{2}{1 + \exp(-2E_5)} - 1 \quad (34)$$

در این بخش روابط ریاضی به دست آمده از شبکه عصبی را ارائه می‌گردد. در این روابط از ضرایب مقادیر ورودی برای استخراج تابع جمع سلول آم ( $E_i$ ) و تابع فعال‌سازی سلول آم ( $F_i$ ) استفاده می‌گردد. این ضرایب بیانگر مقادیر وزنی تابع جمع هر سلول در لایه میانی شبکه می‌باشند.

$$E_1 = -4.0035T + 0.0247X + 3.0104 \quad (12)$$

$$F_1 = \frac{2}{1 + \exp(-2E_1)} - 1 \quad (13)$$

$$E_2 = 0.0468T - 0.3349X - 0.6678 \quad (14)$$

$$F_2 = \frac{2}{1 + \exp(-2E_2)} - 1 \quad (15)$$

$$E_3 = 0.2283T + 0.1282X + 0.4958 \quad (16)$$

$$F_3 = \frac{2}{1 + \exp(-2E_3)} - 1 \quad (17)$$

$$E_4 = 1.8217T - 0.2286X + 1.5320 \quad (18)$$

$$F_4 = \frac{2}{1 + \exp(-2E_4)} - 1 \quad (19)$$

$$E_5 = 0.0651T - 0.4850X + 0.7041 \quad (20)$$

$$F_5 = \frac{2}{1 + \exp(-2E_5)} - 1 \quad (21)$$

در معادلات بالا  $E_i$ ها از ضرب مقادیر ورودی نرم‌الیزه شده در وزنهای مربوطه‌شان به دست آمده‌اند و آخرین مقدار بیانگر پایاس آم لایه میانی می‌باشد. جملات  $E_1$  تا  $E_5$  و  $F_1$  تا  $F_5$  هر کدام به ترتیب نمایشگر تابع جمع و فعال‌سازی یک سلول در لایه پنهان می‌باشند. در پایان مقدار نرم‌الیزه  $k$  و  $C_p$  و  $\rho$  بر اساس مقادیر ورودی  $T$  و  $X$  به صورت روابط ۲۲ تا ۲۴ به دست می‌آیند:

$$C_p|_n = 0.0054F_1 + 3.0797F_2 - 0.7460F_3 + 0.0170F_4 + 0.7932F_5 + 1.5710 \quad (22)$$

$$K|_n = -0.0299F_1 + 1.8762F_2 + 4.2731F_3 - 0.0844F_4 + 0.6477F_5 - 1.2556 \quad (23)$$

$$\rho|_n = 0.0032F_1 - 0.6876F_2 - 0.3254F_3 + 0.0096F_4 - 2.3110F_5 + 0.9346 \quad (24)$$

روابط به دست آمده برای خواص ترمودینامیکی براساس ورودی‌های نرم‌الیزه می‌باشند، لذا خروجی‌های شبکه نیز

استفاده گردید. همچنین از الگوریتم آموزشی لوبرگ-مارکوارت برای آموزش شبکه عصبی استفاده شد. روابط در دست آمده قابل کاربرد در گستره وسیعی از دمایا و غلظتها می‌باشد، در صورتیکه روابط موجود در مقالات دیگر کاربرد محدودتری نسبت به این روابط داشتند.

در این حالت پس از آموزش شبکه، مقدار ماکزیمم خطای نسبی کمتر از ۲/۴۳٪/ میانگین خطاهای نسبی حدود ۰/۶۷٪ و مقدار میانگین مریعات خطای بر اساس نتایج آموزش شبکه عصبی برای شبکه (الف) برابر با  $10^{-10} \times 35$  و برای شبکه عصبی (ب) برابر با  $10^{-7} \times 63$  می‌باشد.

## ۶- فهرست علائم

### علائم انگلیسی

b	پایاس
cov	ضریب تغییرات
C <sub>p</sub>	گرمای ویژه در فشار ثابت، $J/kg \cdot ^\circ C$
E <sub>i</sub>	تابع جمع سلول آم
F <sub>i</sub>	تابع غالسازی سلول آم
MSE	میانگین مریعات خطای
R <sup>2</sup>	ضریب رگرسیون
RMS	ریشه میانگین مریعات خطای
u	ورودیهای شبکه عصبی
w	وزن سلولهای لایه میانی
x	غلظت محلول LiBr-آب
Y	خروجی شبکه عصبی
علائم یونانی	
ρ	چگالی محلول، $kg/m^3$
μ	گرانوی محلول، $kg/m.s$
زیرنویس	
n	خروجیهای نرمالیزه شده شبکه عصبی

توابع جمع به دست آمده از ورودیها با ضرب در وزنهای لایه خارجی شبکه و جمع با مقادیر پایاس لایه خروجی به عنوان ورودی تابع فعال‌سازی مورد استفاده قرار می‌گیرند. با قرار دادن این مقادیر در تابع فعال‌سازی، خروجی‌های شبکه که همان خواص ترمودینامیکی مورد نظر می‌باشد به دست می‌آیند.

$$S|_n = 0.0314F_1 - 0.3254F_2 + 4.2502F_3 + 0.1927F_4 - 0.1140F_5 - 1.4150 \quad (35)$$

$$h|_n = 0.2553F_1 - 0.6158F_2 + 0.5436F_3 + 3.9887F_4 - 0.1605F_5 - 0.1333 \quad (36)$$

$$P|_n = 2.7498F_1 + 0.0810F_2 - 0.3911F_3 - 0.2835F_4 - 0.1411F_5 + 2.0491 \quad (37)$$

$$\mu|_n = 0.1376F_1 - 0.1501F_2 - 0.4123F_3 - 0.7894F_4 - 4.1501F_5 + 3.8347 \quad (38)$$

خروجی‌های نرمالیزه بدست آمده از شبکه عصبی را می‌توان از طریق رابطه شماره ۳۹ به مقدار واقعی تبدیل نمود:

$$Y = \text{Min} Y|_n + (Y|_n + 1).(\text{Max} Y|_n - Y|_n)/2 \quad (39)$$

که در آن Y متغیر خروجی از شبکه عصبی می‌باشد.

## ۵- نتیجه‌گیری

در این مقاله روابط ترمودینامیکی محلول لیتیوم برماید-آب بر اساس دما و غلظت محلول استخراج گردیدند. در تحقیقات قبلی این روابط در حوزه دما و غلظت محدودتری قابل کاربرد بودند، ولی در این تحقیق می‌توان از روابط به دست آمده در حوزه دما و غلظت وسیع‌تری استفاده نمود. برای آموزش شبکه عصبی از نتایج آزمایشگاهی مراجع معتبر استفاده شده است. پس از بررسی حالتهای مختلف برای ساختار شبکه عصبی از ۵ سلول برای لایه پنهان میانی بدلیل دقت بالاتر و مطلوب‌تر

## ۷- مراجع

Kalogirou, S.A.; Neocleous, C.S.; Schizas, C.N.; "Artificial neural networks for modeling the starting-up of a solar steam-generator", vol. 60, no. 2, pp. 89-100, 1998.

[۴]

Kalogirou, S.A.; Bojic, M.; "Artificial neural-networks for the prediction of the energy consumption of a passive solar building", Energy, vol. 25, no. 5, pp. 479-491, 2000.

[۵]

Pacheco-Vega, A.; Sen, M.; Yang, K.T.; McClain, R.L.; "Neural network analysis of a fin-tube refrigerating heat exchanger with limited experimental data", Int. J. Heat and Mass Transfer, vol. 44, no. 9, pp. 763-770, 2001.

[۶]

Kalogirou, S.A.; Panteliou, S.; Dentsoras, A.; "Artificial neural-networks used for the performance prediction of a thermosiphon solar water heater", Renewable Energy, vol. 18, no. 1-2, pp. 87-99, 1999.

[۱]

Chow, T.T.; Zhang, G.Q.; Lin, Z.; Song, C.L.; "Global optimization of absorption chiller system by genetic algorithm and neural network", Energy and Building, vol. 34, no. 1, pp. 103-109, 2002.

[۲]

Kalogirou, S.A.; Panteliou, S.; Dentsoras, A.; "Modeling of solar domestic water heating systems using artificial neural-networks", Solar Energy, vol. 65, no. 6, pp. 335-342, 1999.

[۳]

- |  |   |   |   |
|--|---|---|---|
| <p>Sencan, A.; "Artificial intelligent methods for thermodynamic evaluation of ammonia–water refrigeration systems", Energy Conversion and Management, vol. 47, no. 18-19, pp. 3319-3332, 2006.</p> <p>Kaita, Y.; "Thermodynamic properties of lithium bromide-water solution at high temperatures", International Journal of refrigeration, vol. 24, no. 5, pp. 374-390, 2001.</p> <p>Sozen, A.; Arcaklioglu, E.; oozalp, M.; "Formulation based on artificial neural network of thermodynamic properties of ozone friendly refrigerant/absorbent couples", Applied Thermal Engineering, vol. 25, no. 11-12, pp. 1808-1820, 2005.</p> <p>Florides, G.A.; Kalogirou, S.A.; Tassou, S.A.; Wrobel, L.C.; "Design and construction of a LiBr–water absorption machine", Energy Conversion and Management, vol. 44, no. 15, pp. 2483-2508, 2003.</p> <p>Hagan, M.T.; Menhaj, M.; "Training feedforward networks with the marquardt algorithm", IEEE Transactions on Neural Network, vol. 5, no. 6, pp. 989-993, 1994.</p> <p>Haykin, S.; Neural Networks: A Comprehensive Foundation, Prentice Hall, 1999.</p> | <p>[\#]</p> <p>[\#]</p> <p>[\#]</p> <p>[\#]</p> <p>[\#]</p> <p>[\#]</p> | <p>Palau, A.; Velo, E.; Puigjaner, L.; "Use of neural networks and expert systems to control a gas/solid sorption chilling machine", Internatioal Journal of Refrigeration, vol. 22, no. 1, pp. 59-66, 1999.</p> <p>Chouai, A.; Laugier, S.; Richon; D; "Modeling of thermodynamic properties using neural networks: application to refrigerants", Fluid Phase Equilibria, vol. 199, no. 1, pp. 53-62, 2002.</p> <p>Sharma, R.; Singhal, D.; Ghosh, R.; Dwivedi, A.; "Potential applications of artificial neural networks to Thermodynamics: vapor–liquid equilibrium predictions", Computers and Chemical Engineering, vol. 22, no. 3, pp. 385-390, 1999.</p> <p>Bechtler, H.; Browne, M.W.; Bansal, P.K.; Kecman, V.; "New approach to dynamic modeling of vapour compression liquid chillers: artificial neural-networks", Applied Thermal Engineering, vol. 21, no. 9, pp. 941-953, 2001.</p> <p>Sencan, A.; Soteris, Kalogirou, S.A.; "A new approach using artificial neural networks fordetermination of the thermodynamic properties of fluid couples", Energy Conversion and Management, vol. 46, no. 15-16, pp. 2405-2418, 2005.</p> <p>Sencan, A.; Kemal, A.; Yakuta, B.; Soteris, A.; Kalogiroub, H.; "Thermodynamic analysis of absorption systems using artificial neural network", Renewable Energy, vol. 31, no. 1, pp. 29-43, 2006.</p> | <p>[Y]</p> <p>[A]</p> <p>[A]</p> <p>[Y]</p> <p>[Y]</p> <p>[Y]</p> |
|--|---|---|---|