

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

سیدمصطفی حسینی‌پور<sup>۱\*</sup>; سیدمحمدابراهیم درخشانی<sup>۲</sup>; محمد مهدی عارفی<sup>۳</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.

**کلمات 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: ۱۳۸۶/۷/۲۳


تاریخ اصلاحات مقاله: ۱۳۸۷/۱۲/۲۲

<sup>۱\*</sup> نویسنده مسئول و دانشیار، دانشکده مهندسی مکانیک، دانشگاه علم و صنعت ایران، E-mail: alipour@iust.ac.ir

<sup>۲</sup> مربی، دانشکده مهندسی مکانیک، موسسه غیر انتفاعی غیردولتی راغب اصفهانی، E-mail: e.derakhshani@raghebisf.ac.ir

<sup>۳</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 طبقه‌بندی اطلاعات، پیش‌بینی آب و هوا، پردازش تصویر و صدا بکار برده می‌شوند. شبکه‌های عصبی برای غلبه بر محدودیتهای روشهای مرسوم برای حل مسائل پیچیده آموزش دیده می‌شوند. اصلی‌ترین جزء شبکه عصبی سلول نام دارد. به طور اساسی سلولهای بیولوژیکی با دریافت ورودیها 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:

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

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

انتخاب بهترین و سریعترین الگوریتم آموزشی برای حل مسائل بسیار مشکل و مهم می‌باشد. شبکه عصبی به کمک الگوریتم پس انتشار خطا از طریق تغییر وزن لایه‌های میانی آموزش می‌بیند و این تغییرات به‌عنوان مفروضات شبکه ذخیره می‌گردند. برخی از روشهای آماری نظیر ریشه میانگین مربعات خطا، میانگین مربعات خطا، کسر مطلق واریانس و درصد ضریب واریانس برای بررسی درستی نتایج مورد استفاده قرار می‌گیرند. خطا در طول آموزش 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 گسترده‌ای استفاده شده است [۱۰-۲] 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 آوردند 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 براساس 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. به‌علت استفاده از مقادیر مختلف و متنوع جهت آموزش شبکه عصبی، روابط به دست آمده در این مقاله قابل کاربرد در گستره وسیعی از دماها و غلظتها می‌باشند.

## ۲- شبکه‌های عصبی مصنوعی

شبکه‌های عصبی به صورت گسترده‌ای در زمینه‌های

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

غلظت محلول لیتیوم برماید-آب،  $x$ ، و دمای محلول،  $T_{Sol}$ ، به عنوان ورودی‌های شبکه عصبی در نظر گرفته شده‌اند. همچنین آنتروپی،  $s$ ، آنتالپی،  $h$ ، فشار،  $p$ ، چگالی،  $\rho$ ، ظرفیت گرمایی ویژه،  $C_p$ ، گرانشی،  $\mu$ ، و ضریب هدایت 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 [۶۰۴]

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

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 به دست آمده‌اند. شبکه مورد استفاده دارای یک لایه ورودی، یک لایه خروجی و یک لایه میانی می‌باشد. با افزایش تعداد لایه‌های میانی دقت افزایش می‌یابد 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 تانژانت سیگموئید استفاده شده است. تابع تانژانت 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

مربعیات خطا و یا میانگین مربعیات خطا مشخص می‌شود که به صورت روابط ۲ و ۳ محاسبه می‌گردند:

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

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

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

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

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

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 [۱ و -۱] نرمالیزه شدند. ورودی‌ها و خروجی‌های مورد نظر برای آزمون و آموزش شبکه به صورت روابط ماتریسی ۶، ۷ و ۸ چیدمان شدند.

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

$$\text{Output}_1 = \begin{bmatrix} C_{p1} & K_1 & \rho_1 \\ \vdots & \vdots & \vdots \\ C_{pn} & K_n & \rho_n \end{bmatrix} \quad (7)$$

$$\text{Output}_2 = \begin{bmatrix} S & P & h & \mu \\ \vdots & \vdots & \vdots & \vdots \\ S & P & h & \mu \end{bmatrix} \quad (8)$$

این مقادیر براساس نتایج آزمایشگاهی مراجع معتبر [۱۶ و ۱۴] استخراج گردیده‌اند.

### ۳- شناسایی روابط ترمودینامیکی محلول لیتیوم برماید-آب به کمک شبکه‌های عصبی

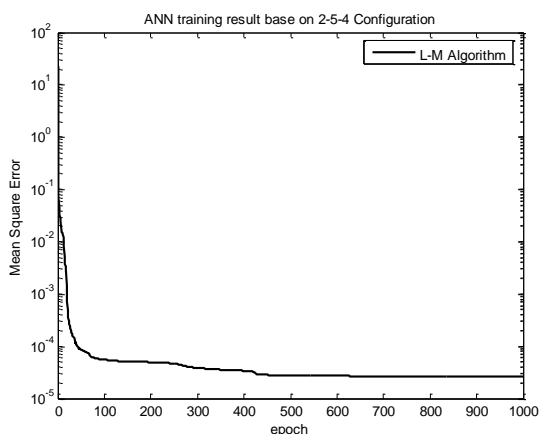
شبکه‌های عصبی با پردازش روی داده‌های تجربی، دانش یا قانون نهفته در ورای داده‌ها را شناسایی می‌کنند. هدف این مقاله بکارگیری شبکه‌های عصبی برای شناسایی خواص ترمودینامیکی محلول لیتیوم برماید-آب به صورت روابط تحلیلی می‌باشد.

باتوجه به نداشتن 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 لونیبرگ-مارکواریت 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 لونیبرگ-مارکواریت 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 یکدیگر، دیده شد که الگوریتم آموزشی لونیبرگ-مارکواریت 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	$9/0.278 \times 10^{-6}$
	۵	Normalized	$1/0.437 \times 10^{-6}$
Gradient Descent	۳	Normalized	$4/70.5 \times 10^{-1}$
	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 سیگموئید بین اعداد ۱ و -۱ می‌باشند.



شکل (۳): نمودار تابع تانژانت سیگموئید

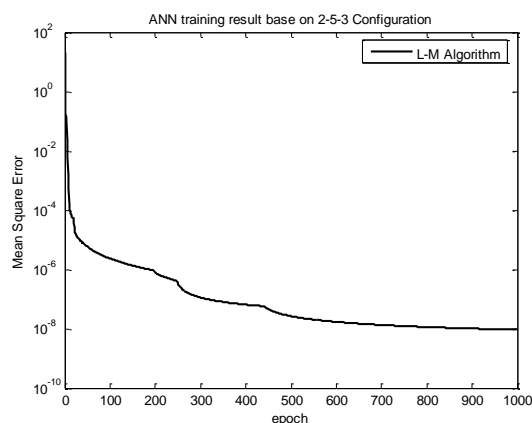
در این تحقیق از دو نوع الگوریتم آموزش استفاده شده است که عبارتند از:

۱. الگوریتم پس‌انتشار خطای لونیبرگ-مارکواریت 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 [-۱، ۱] به صورت جداگانه آموزش دید.

به کمک بسته شبکه‌عصبی نرم‌افزار متلب برنامه‌ای نوشته شده است. در این برنامه کارایی شبکه عصبی به کمک میانگین مربعات خطا مورد ارزیابی قرار می‌گیرد.

کاهش مقدار میانگین مربعات خطا در زمان آموزش شبکه عصبی و مقادیر کمتر از  $1 \times 10^{-6}$  بیانگر همگرایی شبکه می‌باشند. 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	۲/۳۵×۱۰ <sup>-۸</sup>	۰/۰۰۰۱۵۳	۰/۹۹۷۸	۶/۲۹۲۳
۴	۱/۰۳×۱۰ <sup>-۸</sup>	۱/۰۲×۱۰ <sup>-۴</sup>	۰/۹۹۹۰	۴/۱۵۳۵
۵	۱/۵۵×۱۰ <sup>-۱۱</sup>	۳/۹۴×۱۰ <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>	۱/۳۵×۱۰ <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 [۰-۱] 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 خطا آن نسبت به سایر شبکه‌ها کمتر بود به‌عنوان 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>	۰/۰۰۰۳۳۱	۱	۰/۰۲۲۲۴۸
۴	۱/۷۶×۱۰ <sup>-۶</sup>	۸/۶۶×۱۰ <sup>-۵</sup>	۱	۰/۰۰۵۸۱۴
۵	۱/۳۵×۱۰ <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	۰/۰۰۰۱۰۹
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	۰/۰۰۰۷۱۹
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>-۶</sup>	۱	۰/۰۰۰۱۲۱
۱۱	۵/۷۹×۱۰ <sup>-۱۰</sup>	۱/۸×۱۰ <sup>-۶</sup>	۱	۰/۰۰۰۱۲۱
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	۰/۰۰۰۳۲۲
۵	۴/۹۴×۱۰ <sup>-۱۱</sup>	۷/۰۳×۱۰ <sup>-۶</sup>	۱	۳/۴۹×۱۰ <sup>-۱</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>	۰/۰۰۰۱۵۱	۱	۷/۴۸×۱۰ <sup>-۵</sup>
۹	۲/۲۴×۱۰ <sup>-۸</sup>	۰/۰۰۰۱۵	۱	۷/۴۳×۱۰ <sup>-۵</sup>
۱۰	۲/۵۵×۱۰ <sup>-۱۰</sup>	۱/۶×۱۰ <sup>-۵</sup>	۱	۷/۹۳×۱۰ <sup>-۱</sup>
۱۱	۵/۸۰×۱۰ <sup>-۱۱</sup>	۷/۶۲×۱۰ <sup>-۶</sup>	۱	۳/۷۸×۱۰ <sup>-۱</sup>
۱۲	۳/۵۰×۱۰ <sup>-۱۰</sup>	۱/۸۷×۱۰ <sup>-۵</sup>	۱	۹/۲۸×۱۰ <sup>-۱</sup>




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



شکل (۶): ارزیابی شبکه عصبی آموزش داده شده با داده‌های نرمالیزه شده (نمودار بالا) و داده‌های حقیقی (نمودار پایین) برای گرانیوی

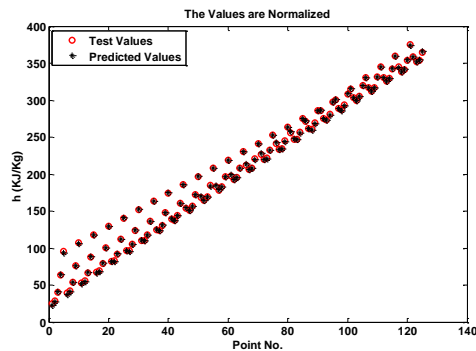


شکل (۱۰): ارزیابی شبکه عصبی آموزش داده شده با داده‌های نرمالیزه برای چگالی




شکل (۷): ارزیابی شبکه عصبی آموزش داده شده با داده‌های نرمالیزه برای آنتروپی

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

نرمالیزه می باشند و با استفاده از رابطه (۳۹) می توان مقادیر واقعی را بدست آورد. براساس مقادیر به دست آمده برای ضرایب رگرسیون خروجی های شبکه عصبی، می توان به دقت بالای جوابهای حاصل از شبکه پی برد. به عنوان نمونه در جدول ۷، برای گرانیروی محلول لیتیموم برماید بین مقادیر واقعی و مقادیر به دست آمده توسط شبکه عصبی مقایسه ای انجام شده است. با دقت در نتایج ثبت شده در این جدول می توان 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 گرانیروی محلول لیتیموم برماید

No.	Actual Output	ANN Output	% Relative Error
۱	۰/۰۰۱۲۴	۰/۰۰۱۲۸	-۳/۲۲
۲	۰/۰۰۲۷۱	۰/۰۰۲۷۵	-۱/۴
۳	۰/۰۰۲۶۷	۰/۰۰۲۶۲	۱/۱
۴	۰/۰۰۴۲۵	۰/۰۰۴۲۱	۰/۹
۵	۰/۰۰۵۳۷	۰/۰۰۵۳۰	۱/۳
۶	۰/۰۰۶۶۲	۰/۰۰۶۶۹	-۱/۰
۷	۰/۰۰۷۱۳	۰/۰۰۷۱۸	-۰/۷
۸	۰/۰۰۸۹۹	۰/۰۰۸۹۶	-۰/۳
۹	۰/۰۱۳۴۷	۰/۰۱۳۴۳	۰/۲

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 می گردند. در این روابط از ضرایب مقادیر ورودی برای استخراج تابع جمع سلول نام ( $E_i$ ) و تابع فعال سازی سلول نام ( $F_i$ ) استفاده می گردند. این ضرایب بیانگر مقادیر وزنی تابع جمع هر سلول در لایه میانی شبکه می باشند.

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

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

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

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

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

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

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

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

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

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

در معادلات بالا  $E_i$ ها از ضرب مقادیر ورودی نرمالیزه شده در وزنهای مربوطه شان به دست آمده اند و آخرین مقدار بیانگر بایاس نام لایه میانی می باشد. جملات  $E_1$  الی  $E_5$  و  $F_1$  الی  $F_5$  هر کدام به ترتیب نمایشگر توابع جمع و فعال سازی یک سلول در لایه پنهان می باشند. 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 می آیند:

$$C_{p,n} = 0.0054F_1 + 3.0797F_2 - 0.7460F_3 + 0.0170F_4 + 0.7932F_5 + 1.5710 \quad (22)$$

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

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

روابط به دست آمده برای خواص ترمودینامیکی براساس ورودیهای نرمالیزه می باشند، لذا خروجی های شبکه نیز





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

در این حالت پس از آموزش شبکه، مقدار ماکزیم خطای نسبی کمتر از  $3/43\%$ ، میانگین خطاهای نسبی حدود  $0/67\%$  و مقدار میانگین مربعات خطا بر اساس نتایج آموزش شبکه عصبی برای شبکه (الف) برابر با  $1/35 \times 10^{-10}$  و برای شبکه عصبی (ب) برابر با  $2/63 \times 10^{-7}$  می‌باشد.

## ۶- فهرست علائم

### علائم انگلیسی

b	بایاس
cov	ضریب تغییرات
$C_p$	گرمای ویژه در فشار ثابت، $J/kg^{\circ}C$
$E_i$	تابع جمع سلول آم
$F_i$	تابع فعالسازی سلول آم
MSE	میانگین مربعات خطا
$R^2$	ضریب رگرسیون
RMS	ریشه میانگین مربعات خطا
u	ورودیهای شبکه عصبی
w	وزن سلولهای لایه میانی
x	غلظت محلول LiBr-آب
Y	خروجی شبکه عصبی

### علائم یونانی

$\rho$	چگالی محلول، $kg/m^3$
$\mu$	گرانروی محلول، $kg/m.s$
n	زیرنویس خروجیهای نرمالیزه شده شبکه عصبی

توابع جمع به دست آمده از ورودیها با ضرب در وزنهاى لایه خارجی شبکه و جمع با مقادیر بایاس 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 می‌باشند 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:

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

که در آن Y متغیر خروجی از شبکه عصبی می‌باشد.

## ۵- نتیجه گیری

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

- |     |   |     |  |
|-----|---|-----|--|
| [۴] | 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.  | [۱] | 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. |
| [۵] | 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.   | [۲] | 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.          |
| [۶] | 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. | [۳] | 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.                       |



- 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.
- Kaita, Y.; "Thermodynamic properties of lithium bromide-water solution at high temperatures", *International Journal of refrigeration*, vol. 24, no. 5, pp. 374-390, 2001.
- 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.
- 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.
- 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.
- Haykin, S.; *Neural Networks: A Comprehensive Foundation*, Prentice Hall, 1999.
- [۱۳] Palau, A.; Velo, E.; Puigjaner, L.; "Use of neural networks and expert systems to control a gas/solid sorption chilling machine", *International Journal of Refrigeration*, vol. 22, no. 1, pp. 59-66, 1999.
- [۱۴] 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.
- [۱۵] 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.
- [۱۶] 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.
- [۱۷] Sencan, A.; Soteris, Kalogirou, S.A.; "A new approach using artificial neural networks for determination of the thermodynamic properties of fluid couples", *Energy Conversion and Management*, vol. 46, no. 15-16, pp. 2405-2418, 2005.
- [۱۸] Sencan, A.; Kemal, A.; Yakuta, B.; Soteris, A.; Kalogirou, H.; "Thermodynamic analysis of absorption systems using artificial neural network", *Renewable Energy*, vol. 31, no. 1, pp. 29-43, 2006.
- [۷]
- [۸]
- [۹]
- [۱۰]
- [۱۱]
- [۱۲]

