

# بررسی عملکرد شبکه عصبی مصنوعی MLP، RBF و ORN در یک کانال افقی همراه با انتقال جرم و انتقال حرارت همزمان

فاطمه کریمی زاد گوهری

آمل، دانشگاه آزاد اسلامی واحد آیت الله آملی، دانشکده فنی مهندسی، گروه مهندسی شیمی

اکبر شاهسونند\*<sup>+</sup>

مشهد، دانشگاه فردوسی مشهد، دانشکده فنی مهندسی

**چکیده:** در بیش تر فرایندهای مهندسی شیمی پدیده‌های انتقال جرم و انتقال گرما مشخصه‌های جدایی ناپذیر فرایندها می‌باشند. در این پژوهش با استفاده از یک دستگاه آزمایشگاهی، به بررسی تجربی همزمان این دو پدیده در فرایندهای مهندسی شیمی و تأثیراتی که بر روی هم و بر روی فرایندها می‌توانند داشته باشند، پرداخته شده است. در این دستگاه وجود پدیده‌های چگالش و تبخیر، باعث انتقال جرم شده و سرانجام بر ضریب انتقال گرمایی تأثیر می‌گذارند همچنین وجود انتقال جرم، توزیع دما در پدیده انتقال گرما را تغییر داده و باعث ایجاد تغییر کلی در شار گرمایی می‌شود. آزمایش‌های بسیاری با تغییر پارامترهای گوناگون مانند دما و شدت جریان برای هر دو سیال آب و هوا انجام گرفت، که از نتیجه‌های به دست آمده از این آزمایش‌ها در بررسی انواع شبکه عصبی مصنوعی و مقایسه عملکرد این شبکه‌ها با یکدیگر و با نتیجه‌های به دست آمده از آزمایش‌ها استفاده شد. از جمله شبکه‌های عصبی به کار برده شده در این مقاله می‌توان به شبکه RBF (Radial Basis exact Fit) و شبکه MLP (Multi Layer Perceptron) و شبکه ORN (Optimal Regularization Network) اشاره نمود. بررسی‌های انجام شده بیانگر این است که شبکه MLP به دلیل نبود امکان برطرف کردن خطا و اغتشاش قادر به پیش‌بینی مناسب نبوده و شبکه ORN به دلیل دارا بودن مبنای نظری قوی‌تر و استفاده از روش‌های پیشرفته ریاضی مانند مقابله عدد دارای عملکرد بهتری است.

**واژه‌های کلیدی:** انتقال جرم؛ انتقال گرما؛ شبکه عصبی مصنوعی؛ MLP؛ RBF؛ ORN.

**KEYWORDS:** Mass transfer; Heat transfer; Artificial neural network MLP; RBF; ORN.


## مقدمه

جهت باعث کاهش ضریب انتقال گرما می‌شود. افزون بر این وجود پدیده‌های میعان و تبخیر که ناشی از انتقال جرم می‌باشند نیز می‌توانند باعث کاهش یا افزایش چشمگیری در شار گرمایی شوند.

انتقال جرم و انتقال گرما پدیده‌هایی هستند که می‌توانند در حضور و در غیاب یکدیگر رخ دهند. وقوع همزمان این دو پدیده در یک راستا باعث افزایش ضریب انتقال گرما و وقوع آن در خلاف

<sup>+</sup>E-mail: shahsavand@um.ac.ir

\*عده دار مکاتبات



شکل ۱- نمای کلی سامانه انتقال جرم و گرمای همزمان.

نتیجه‌های به دست آمده از این پژوهش بیان کننده عملکرد موفق شبکه عصبی مصنوعی در پیش بینی مسئله‌های مربوط به انتقال گرما می‌باشد [۱۴].

در این مقاله ضمن مدل سازی ریاضی پدیده های انتقال جرم و انتقال گرمای همزمان، دستگاهی با قابلیت کار در آزمایشگاه ساخته شد که با تغییر پارامترهای فرایندی گوناگون در آن مانند دما و شدت جریان سیال‌های آب و هوا می توان آزمایش‌های بسیاری انجام داد. تعداد ۲۵۶ آزمون با تغییر این پارامترها انجام شد. این تعداد آزمایش‌ها مبنای خوبی برای سنجش عملکرد انواع شبکه عصبی مصنوعی می‌باشد، از این رو خروجی‌های به دست آمده از این شبکه‌ها با نتیجه‌های تجربی مقایسه شد و تحلیل روند این نتیجه‌ها ارایه شد.

### بخش تجربی

#### شرح دستگاه و چگونگی انجام آزمایش‌ها

شکل ۱ نمایی از دستگاه به کار برده شده در این پژوهش می‌باشد، که شامل یک بدنه فلزی با پوشش MDF می باشد. قطعه‌ها و اتصال‌های موجود در دستگاه همگی از فولاد ضد زنگ بوده که بسته به نوع کاربرد آن دارای ضخامت‌های متفاوت می باشند. در ساخت این دستگاه دو مسیر برای عبور سیال‌های آب و هوا تعبیه شده است، سیال هوا در مسیر عبور خود در درون دستگاه پس از خروج از کمپرسور ابتدا وارد یک شدت جریان سنج به منظور کنترل شدت جریان هوای ورودی به سامانه شده

پژوهش‌های صورت گرفته در این راستا شامل مطالعه‌های عددی و آزمایشگاهی بوده، که نتیجه‌های به دست آمده از این مطالعه‌ها را می‌توان توسط انواع شبکه عصبی مورد بررسی قرار داد و عملکرد شبکه‌های گوناگون را از نظر تحلیل روند نتیجه‌ها با یکدیگر مقایسه نمود.

مدل‌های بسیاری از شبکه‌های عصبی به طور گسترده در فرایندهای تجربی مربوط به مهندسی شیمی مورد استفاده قرار گرفته اند این مطالعه‌ها در پژوهش‌های بسیاری از دانشمندان به چشم می‌خورد [۸-۱]. در سال ۲۰۰۷ میلادی چندین پژوهشگر از شبکه عصبی مصنوعی در تجزیه و تحلیل انتقال گرما در مبدل‌های گرمایی پوسته و لوله بر اساس داده‌های تجربی استفاده نموده اند. در این مطالعه‌ها با استفاده از بیشینه تفاوت درجه گرما در خروجی‌های مبدل، نرخ کل انتقال گرما برآورد شده است [۹]. همچنین می‌توان از شبکه عصبی در مدل‌سازی انتقال گرما در جریان جوششی مایعات استفاده نمود که در سال ۲۰۰۶ میلادی اسکالابرین<sup>(۱)</sup> و همکاران در درون یک لوله افقی در شرایط اشباع موفق به انجام این کار شدند [۱۰]. در صنایع غذایی نیز شبکه عصبی مصنوعی جایگاه ویژه‌ای را دارد. در پژوهشی در سال ۲۰۰۷ میلادی مدل‌سازی فرایند یک خشک‌کن با استفاده از توان گرم‌کن و سرعت عبور هوا مورد بررسی قرار گرفت. از مقایسه نتیجه‌های ANN<sup>(۲)</sup> و رابطه‌های ریاضی از شبکه عصبی مصنوعی نتیجه‌های دقیق تری به دست آمد [۱۱].

در سال ۲۰۱۱ میلادی، پژوهشی مبنی بر عملکرد شبکه عصبی مصنوعی بر تعیین ویژگی‌های انتقال گرما در فرایند چگالش در درون یک لوله عمودی صاف صورت گرفت. در این مطالعه، از هوش مصنوعی به منظور برآورد همرفت گرما، اندازه‌گیری ضریب انتقال و افت فشار در جریان استفاده شد [۱۲].

در پژوهشی دیگر در سال ۲۰۱۱ میلادی عملکرد دو شبکه RBF و MLP در ارتباط با داده‌های مربوط به نتیجه‌های جذب کربن دی اکسید در یک برج پر شده با استفاده از محلول‌های دی اتانول آمین و متیل دی اتانول آمین مورد بررسی قرار گرفت و سرانجام شبکه RBF عملکرد بهتری در برطرف کردن خطاها و اختلال‌های مربوط به داده‌های آزمایشگاهی داشته است و توانسته پیش بینی‌های دقیق تری را انجام دهد [۱۳]. در سال ۲۰۱۲ میلادی در پژوهشی عملکرد شبکه عصبی مصنوعی در ارتباط با انتقال گرما و ویژگی‌های جریان از نظر پیش بینی عدد ناسلت و ضریب اصطکاک در لوله‌های مارپیچ مورد بررسی قرار گرفت.

(۱) Scalabrin

(۲) Artificial Neural Network

ثابت نگه داشتن دمای آب از یک دوش در طول مخزن و از یک گرم‌کن با توان ۴٫۵ kW استفاده شده است.

ثبت تغییرهای دمایی در این سامانه توسط پنج حسگر از نوع DS18B20 در بازه‌ی دمایی ۰ تا ۱۴۰ درجه سلسیوس که به دستگاه ثبت داده وصل است، انجام می‌گیرد. مکان‌هایی که در آن حسگرهای دما نصب شده است عبارتند از: خروجی از اشباع‌کننده، ورودی هوا به محفظه، خروجی هوا از محفظه، ورودی آب به محفظه و خروجی آب از محفظه.

شدت جریان آب، شدت جریان هوا، دمای هوا و دمای آب پارامترهای قابل تغییر در این آزمایش‌ها بوده و بازه‌ی تغییر شدت جریان برای سیال آب  $1 \text{ m}^3/\text{h}$  تا  $0.25 \text{ m}^3/\text{h}$  بوده و برای سیال هوا بین  $20 \text{ m}^3/\text{h}$  تا  $50 \text{ m}^3/\text{h}$  و بازه‌ی تغییر دما برای سیال هوا بین  $80^\circ\text{C}$  تا  $50^\circ\text{C}$  و برای سیال آب موجود در مخزن پایین دستگاه، بین  $20^\circ\text{C}$  تا  $35^\circ\text{C}$  و برای آب موجود در مخزن اشباع‌کننده بین  $40^\circ\text{C}$  تا  $70^\circ\text{C}$  می‌باشد. با توجه به تعداد پارامترها و تغییر تنها یک پارامتر در هر مرحله و تقسیم این بازه‌ها به چهار قسمت، برای هر پارامتر در حال تغییر، ۶۴ آزمون و برای کل پارامترها ۲۵۶ آزمون خواهیم داشت.

### نتیجه‌ها و بحث

نتیجه‌های به دست آمده از آزمایش‌ها در جدول ۱ آمده است.

#### تحلیل داده‌های تجربی

نمودارهای به دست آمده از نتیجه‌های تجربی در شکل‌های ۲ و ۳ به ترتیب برای دمای آب ورودی ۲۵ و ۲۰ درجه سلسیوس موجود است. همان گونه که در شکل‌های ۲ و ۳ با افزایش دمای هوای ورودی، کاهش اختلاف دما بین آب ورودی و هوای ورودی را خواهیم داشت که این امر بر نیروی محرکه انتقال گرما تأثیر گذاشته و باعث کاهش انتقال گرما می‌شود. از سویی با افزایش دمای آب ورودی به سامانه و پیرو آن کاهش اختلاف دمای آب ورودی به سامانه و خروجی از آن، میزان دمای فیلم میعان یافته موجود در سطح لوله داخل محفظه آزمون افزایش یافته و این افزایش دما منجر به افزایش فشار جزئی سامانه شده است. که این افزایش فشار جزئی اختلاف فشار در سامانه را کاهش داده که منجر به کاهش نیروی محرکه انتقال جرم و نیز کاهش نیروی محرکه انتقال گرما شده است، این روند در منحنی‌های موجود در شکل ۲ و ۳ دیده می‌شود.

و سپس وارد خطوط لوله می‌شود. خطوط لوله نیز در طی مسیر به دو بخش تقسیم شده است، مسیر افقی و مسیر رو به پایین. در مسیر افقی ابتدا یک شیر از نوع کروی قرار دارد، که به این خط لوله، کنار گذر<sup>(۱)</sup> گفته می‌شود، که به منظور ایمنی بیش‌تر در سامانه به کار برده شده است.

مسیر دوم یعنی انشعاب رو به پایین، شامل یک شیر از نوع کروی است که در ادامه مسیر خود به یک چهار راه از جنس آلومینیوم با خروجی‌های  $1/4$  اینچ متصل است. این خروجی‌ها توسط چهار شلنگ از جنس پلاستیک به مخزن اشباع‌کننده که خود شامل دو استوانه هم مرکز با قطر ها و ارتفاع‌های متفاوت است، وصل می‌باشند. در امتداد مسیر شلنگ‌ها در داخل استوانه پایینی مخزن اشباع‌کننده، لوله‌هایی تعبیه شده که علت استفاده از این لوله‌ها جلوگیری از درهمی، خروج آب همراه با هوا و جلوگیری از خروج هوای اشباع نشده از اشباع‌کننده است.

در کف مخزن اشباع‌کننده یک شیر به منظور تخلیه آب درون مخزن تعبیه شده است. همچنین در بالای مخزن اشباع‌کننده دو منفذ یکی برای نصب حسگر فشار و دیگری برای نصب فشارسنج در نظر گرفته شده است که در صورت نیاز به کار در فشار غیر از فشار جو، فشار به دو صورت قابل دیدن باشد. همچنین در مخزن اشباع‌کننده، از دو هیتر ۴٫۵ کیلو واتی به منظور رساندن دمای آب درون اشباع‌کننده به دمای مورد نظر استفاده شده است.

هوای اشباع خروجی از اشباع‌کننده پس از اتصال به مسیر جریان کنار گذر وارد یک شیر از نوع کروی شده و در ادامه مسیر از یک گرم‌کن ۲٫۵kW به منظور جلوگیری از عبور قطره‌های آب و رساندن دمای هوای اشباع شده به دمای مورد نظر عبور می‌نماید و سپس دوباره وارد خط لوله می‌شود. در امتداد مسیر خط لوله یک محفظه با سطح مقطع  $20 \text{ cm} \times 20 \text{ cm}$  و طول ۴۰ cm نصب شده است. در درون محفظه و در مسیر عمود بر جریان هوای ورودی یک لوله با قطر یک اینچ برای عبور آب تعبیه شده است. در کف محفظه، یک خروجی به قطر ۱۰ mm وجود دارد که قطره‌های به دست آمده از میعان هوای اشباع را به یک استوانه مدرج با قابلیت تخلیه آب هدایت می‌کند.

در مسیر عبور آب، جریان آب به صورت یک چرخه است که ابتدا از یک مخزن فولادی با ضخامت ورق ۲ mm به حجم ۱۵۰L توسط یک پمپ به شدت جریان‌سنج فرستاده می‌شود که خروجی شدت جریان‌سنج توسط یک شلنگ ۱ in به ورودی مسیر آب در محفظه وصل می‌شود. همچنین در این مخزن به منظور

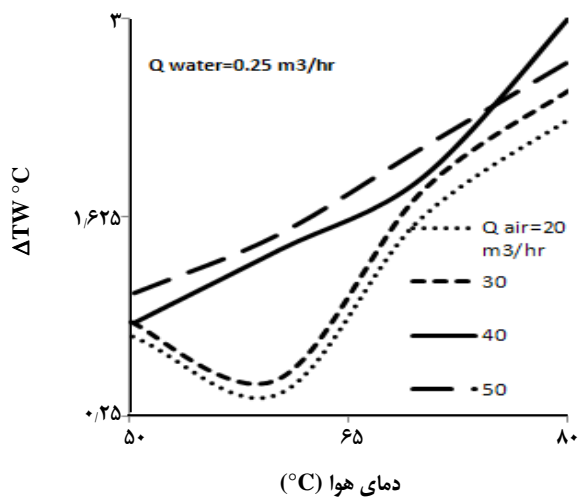
(۱) by pass

جدول ۱ - نتیجه‌های به دست آمده از آزمایش‌ها.


ردیف	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲	۱۳	۱۴	۱۵	۱۶
Qair	۲۰	۲۰	۲۰	۲۰	۳۰	۳۰	۳۰	۳۰	۴۰	۴۰	۴۰	۴۰	۵۰	۵۰	۵۰	۵۰
Qw	۱	۰/۷۵	۰/۵	۰/۲۵	۰/۲۵	۰/۵	۰/۷۵	۱	۱	۰/۷۵	۰/۵	۰/۲۵	۰/۲۵	۰/۵	۰/۷۵	۱
Tw	۲۰	۲۰	۲۰/۱	۲۰/۱	۲۰	۱۹/۹	۲۰	۲۰	۲۰/۱	۲۰	۲۰/۱	۲۰	۲۰	۱۹/۸	۱۹/۹	۱۹/۹
Tair	۴۸/۳	۵۰	۵۰/۵	۵۰/۲	۵۰/۱	۵۰/۱	۵۰/۳	۵۰/۱	۵۰/۲	۵۰/۱	۵۰/۱	۵۰/۴	۵۰/۳	۵۰/۱	۵۰	۵۰/۱
Tw exp	۲۰	۲۰/۱	۲۰/۳	۲۰/۹	۲۰/۹	۲۰	۲۰	۲۰/۱	۲۰/۲	۲۰/۱	۲۰/۳	۲۰/۹	۲۰/۱	۲۰	۲۰	۲۰
ردیف	۱۷	۱۸	۱۹	۲۰	۲۱	۲۲	۲۳	۲۴	۲۵	۲۶	۲۷	۲۸	۲۹	۳۰	۳۱	۳۲
Qair	۵۰	۵۰	۵۰	۵۰	۴۰	۴۰	۴۰	۴۰	۳۰	۳۰	۳۰	۳۰	۲۰	۲۰	۲۰	۲۰
Qw	۰/۲۵	۰/۵	۰/۷۵	۱	۱	۰/۷۵	۰/۵	۰/۲۵	۰/۲۵	۰/۵	۰/۷۵	۱	۱	۰/۷۵	۰/۵	۰/۲۵
Tw	۲۵/۱	۲۵/۱	۲۵/۲	۲۵/۵	۲۵	۲۴/۹	۲۵	۲۵	۲۵/۲	۲۵/۱	۲۵	۲۵/۲	۲۵	۲۵	۲۵/۲	۲۵
Tair	۵۰/۲	۵۰/۲	۵۰/۱	۵۰	۵۰/۱	۵۰/۱	۵۰/۱	۵۰	۵۰	۴۹/۸	۴۹/۹	۴۹/۹	۴۹/۸	۴۹/۸	۴۹/۷	۴۹/۸
Tw exp	۲۵/۸	۲۵/۲	۲۵/۳	۲۵/۶	۲۵/۱	۲۵	۲۵/۱	۲۵/۸	۲۵/۸	۲۵	۲۵	۲۵/۳	۲۵/۱	۲۵/۱	۲۵/۳	۲۵/۶
ردیف	۳۳	۳۴	۳۵	۳۶	۳۷	۳۸	۳۹	۴۰	۴۱	۴۲	۴۳	۴۴	۴۵	۴۶	۴۷	۴۸
Qair	۲۰	۲۰	۲۰	۲۰	۳۰	۳۰	۳۰	۳۰	۴۰	۴۰	۴۰	۴۰	۵۰	۵۰	۵۰	۵۰
Qw	۱	۰/۷۵	۰/۵	۰/۲۵	۰/۲۵	۰/۵	۰/۷۵	۱	۱	۰/۷۵	۰/۵	۰/۲۵	۰/۲۵	۰/۵	۰/۷۵	۱
Tw	۳۰	۳۰/۱	۲۹/۸	۳۰	۲۹/۹	۲۹/۸	۳۰	۳۰	۳۰/۱	۳۰	۳۰/۱	۳۰	۳۰/۱	۲۹/۹	۲۹/۹	۳۰/۱
Tair	۵۰/۴	۵۰/۱	۵۰/۲	۵۰/۳	۵۰/۵	۵۰/۵	۵۰	۵۰/۱	۵۰	۵۰	۵۰	۵۰	۴۹/۷	۵۰/۱	۵۰	۴۹/۸
Tw exp	۳۰	۳۰/۱	۲۹/۸	۳۰/۲	۳۰/۳	۲۹/۹	۳۰	۳۰	۳۰/۱	۳۰	۳۰/۲	۳۰/۵	۳۰/۶	۳۰	۳۰	۳۰/۱
ردیف	۴۹	۵۰	۵۱	۵۲	۵۳	۵۴	۵۵	۵۶	۵۷	۵۸	۵۹	۶۰	۶۱	۶۲	۶۳	۶۴
Qair	۵۰	۵۰	۵۰	۵۰	۴۰	۴۰	۴۰	۴۰	۳۰	۳۰	۳۰	۳۰	۲۰	۲۰	۲۰	۲۰
Qw	۱	۰/۷۵	۰/۵	۰/۲۵	۰/۲۵	۰/۵	۰/۷۵	۱	۱	۰/۷۵	۰/۵	۰/۲۵	۰/۲۵	۰/۵	۰/۷۵	۱
Tw	۳۵	۳۵/۱	۳۵/۱	۳۵/۱	۳۵	۳۴/۸	۳۴/۸	۳۴/۹	۳۵	۳۵/۱	۳۵/۱	۳۵/۱	۳۵	۳۴/۹	۳۴/۹	۳۴/۸
Tair	۴۹/۸	۴۹/۸	۴۹/۸	۴۹/۸	۴۹/۹	۴۹/۸	۴۹/۸	۵۰	۵۰/۳	۵۰	۵۰/۱	۵۰	۵۰/۲	۵۰	۴۹/۸	۴۹/۸
Tw exp	۳۵/۱	۳۵/۲	۳۵/۳	۳۵/۴	۳۵/۲	۳۴/۹	۳۴/۸	۳۵	۳۵	۳۵/۲	۳۵/۲	۳۵/۴	۳۵/۱	۳۵	۳۴/۹	۳۴/۸
ردیف	۶۵	۶۶	۶۷	۶۸	۶۹	۷۰	۷۱	۷۲	۷۳	۷۴	۷۵	۷۶	۷۷	۷۸	۷۹	۸۰
Qair	۲۰	۲۰	۲۰	۲۰	۳۰	۳۰	۳۰	۳۰	۴۰	۴۰	۴۰	۴۰	۵۰	۵۰	۵۰	۵۰
Qw	۱	۰/۷۵	۰/۵	۰/۲۵	۰/۲۵	۰/۵	۰/۷۵	۱	۱	۰/۷۵	۰/۵	۰/۲۵	۰/۲۵	۰/۵	۰/۷۵	۱
Tw	۲۰/۱	۲۰/۲	۲۰/۲	۱۹/۸	۱۹/۸	۱۹/۸	۱۹/۹	۲۰	۲۰	۲۰/۱	۲۰	۱۹/۹	۲۰/۱	۲۰/۲	۲۰	۲۰/۱
Tair	۶۰	۵۹/۸	۶۰/۳	۶۰/۲	۶۰/۱	۶۰/۱	۶۰/۱	۶۰/۱	۶۰/۱	۶۰/۱	۶۰	۶۰/۳	۶۰/۱	۶۰	۵۹/۶	۵۹/۷
Tw exp	۲۰/۱	۲۰/۳	۲۰/۳	۲۰/۲	۲۰/۳	۲۰	۲۰	۲۰	۲۰	۲۰/۱	۲۰	۲۱/۳	۲۱/۶	۲۰/۳	۲۰	۲۰/۱

ادامه جدول ۱ - نتیجه‌های به دست آمده از آزمایش‌ها.

ردیف	۸۱	۸۲	۸۳	۸۴	۸۵	۸۶	۸۷	۸۸	۸۹	۹۰	۹۱	۹۲	۹۳	۹۴	۹۵	۹۶
Qair	۲۰	۲۰	۲۰	۲۰	۳۰	۳۰	۳۰	۳۰	۴۰	۴۰	۴۰	۴۰	۵۰	۵۰	۵۰	۵۰
Qw	۱	۰٫۷۵	۰٫۵	۰٫۲۵	۰٫۲۵	۰٫۵	۰٫۷۵	۱	۱	۰٫۷۵	۰٫۵	۰٫۲۵	۰٫۲۵	۰٫۵	۰٫۷۵	۱
Tw	۲۵٫۱	۲۵	۲۵٫۱	۲۴٫۹	۲۵	۲۴٫۸	۲۴٫۹	۲۵	۲۵	۲۵	۲۵٫۱	۲۴٫۹	۲۵	۲۵	۲۴٫۹	۲۵
Tair	۶۰٫۱	۶۰	۶۰	۶۰٫۱	۶۰	۵۹٫۸	۵۹٫۹	۵۹٫۹	۶۰	۵۹٫۹	۵۹٫۷	۵۹٫۷	۶۰٫۲	۶۰٫۳	۶۰	۵۹٫۹
Tw exp	۲۵٫۲	۲۵	۲۵٫۱	۲۵٫۸	۲۶	۲۴٫۹	۲۵	۲۵٫۱	۲۵	۲۵٫۱	۲۵٫۳	۲۶٫۱	۲۶٫۳	۲۵٫۱	۲۵	۲۵
ردیف	۹۷	۹۸	۹۹	۱۰۰	۱۰۱	۱۰۲	۱۰۳	۱۰۴	۱۰۵	۱۰۶	۱۰۷	۱۰۸	۱۰۹	۱۱۰	۱۱۱	۱۱۲
Qair	۵۰	۵۰	۵۰	۵۰	۴۰	۴۰	۴۰	۴۰	۳۰	۳۰	۳۰	۳۰	۲۰	۲۰	۲۰	۲۰
Qw	۱	۰٫۷۵	۰٫۵	۰٫۲۵	۰٫۲۵	۰٫۵	۰٫۷۵	۱	۱	۰٫۷۵	۰٫۵	۰٫۲۵	۰٫۲۵	۰٫۵	۰٫۷۵	۱
Tw	۳۰٫۱	۳۰	۲۹٫۹	۳۰	۲۹٫۸	۲۹٫۸	۲۹٫۷	۲۹٫۷	۲۹٫۷	۲۹٫۸	۲۹٫۸	۳۰٫۲	۳۰٫۲	۳۰	۳۰	۳۰
Tair	۵۹٫۸	۶۰٫۱	۵۹٫۸	۶۰٫۱	۶۰٫۱	۵۹٫۸	۶۰	۶۰	۵۹٫۹	۶۰٫۱	۵۹٫۹	۶۰٫۳	۵۹٫۸	۶۰	۶۰	۵۹٫۸
Tw exp	۳۰٫۱	۳۰٫۱	۳۰٫۱	۳۱٫۱	۳۰٫۸	۲۹٫۹	۲۹٫۸	۲۹٫۸	۲۹٫۸	۲۹٫۹	۲۹٫۹	۳۱٫۹	۳۰٫۵	۳۰٫۱	۳۰٫۱	۳۰
ردیف	۱۱۳	۱۱۴	۱۱۵	۱۱۶	۱۱۷	۱۱۸	۱۱۹	۱۲۰	۱۲۱	۱۲۲	۱۲۳	۱۲۴	۱۲۵	۱۲۶	۱۲۷	۱۲۸
Qair	۲۰	۲۰	۲۰	۲۰	۳۰	۳۰	۳۰	۳۰	۴۰	۴۰	۴۰	۴۰	۵۰	۵۰	۵۰	۵۰
Qw	۱	۰٫۷۵	۰٫۵	۰٫۲۵	۰٫۲۵	۰٫۵	۰٫۷۵	۱	۱	۰٫۷۵	۰٫۵	۰٫۲۵	۰٫۲۵	۰٫۵	۰٫۷۵	۱
Tw	۳۵٫۱	۳۴٫۹	۳۴٫۸	۳۴٫۷	۳۵	۳۴٫۸	۳۴٫۸	۳۴٫۹	۳۵	۳۵	۳۵	۳۴٫۹	۳۵	۳۵٫۱	۳۵	۳۴٫۸
Tair	۶۰٫۱	۶۰٫۱	۶۰	۶۰٫۱	۶۰	۵۹٫۸	۶۰	۵۹٫۹	۶۰	۶۰٫۱	۵۹٫۸	۶۰	۶۰٫۱	۵۹٫۸	۶۰	۶۰٫۱
Tw exp	۳۵٫۲	۳۵	۳۴٫۹	۳۵٫۳	۳۵٫۶	۳۵	۳۴٫۹	۳۵	۳۵٫۱	۳۵٫۱	۳۵٫۱	۳۵٫۶	۳۵٫۸	۳۵٫۳	۳۵٫۱	۳۵



شکل ۳- نمودار تجربی تغییر اختلاف دمای آب ورودی و خروجی بر حسب دمای هوای ورودی.



شکل ۴- نمودار تجربی تغییر اختلاف دمای آب ورودی و خروجی بر حسب دمای هوای ورودی.

به شبکه وارد می‌شود. لایه پنهان ممکن است از یک تا چند لایه باشد و کار پردازش اطلاعات در این لایه انجام می‌شود. تعداد نورون‌ها نیز در این لایه متغیر است، هر یک از عناصر بردار ورودی به یک لایه، در زمان اتصال به نورون‌های آن در وزن متناظر خود ضرب می‌شوند. فرایند آموزش شبکه نیز در واقع تنظیم وزن‌های نورون‌ها در پاسخ به خطای محاسبه شده میان مقدارهای محاسباتی و مقدارهای هدف می‌باشد. سومین لایه نیز لایه خروجی است که عملکرد این لایه به فعالیت واحد پنهان و وزن نورون‌ها بستگی دارد.

#### انواع اتصال‌های لایه‌ها به همراه تابع وزن در شبکه‌های عصبی

- ۱- پیشرو: بیش‌ترین پیوندها از این نوع است که در آن سیگنال‌ها تنها در یک جهت حرکت می‌کنند. از ورودی به خروجی هیچ بازخوردی (حلقه) وجود ندارد. خروج هر لایه بر همان لایه تأثیر ندارد.
- ۲- پسرو: داده‌ها از گره‌ها لایه بالا به گره‌های لایه پایین بازخورنده می‌شوند.
- ۳- جانبی: خروج گره‌ها هر لایه به عنوان ورود گره‌های همان لایه استفاده می‌شوند.

#### شبکه تابع پایه شعاعی

شبکه RBF از شبکه‌های عصبی آماری است که از روش‌های آماری برای طبقه بندی الگوها الهام گرفته اند و یادگیری آن‌ها بر منطق شبکه‌های زیستی استوار نیست. این شبکه‌ها برای جداسازی در فضا از سطوح زنگوله‌ای شکل استفاده می‌کنند که در وسط و روی مرکز خود برجسته می‌باشند و در اطراف به سمت پایین کشیده شده اند که در شکل ۴ دیده می‌شود. با معرفی مقدار باز شدگی سطح زنگوله<sup>(۴)</sup>، تقسیم فضای الگوها صورت می‌گیرد. شبکه RBF در لایه میانی خود تنها دارای یک لایه پنهان است و خصوصیت یگانه RBF پردازشی است که در لایه پنهان انجام می‌دهد. در این لایه هر یک از نورون‌ها یک سطح زنگوله را تشکیل می‌دهند [۱۵].

#### شبکه پرسپترون چند لایه ای (MLP)<sup>(۵)</sup>

شبکه‌های چند لایه پیش‌خور یکی از مهم‌ترین ساختارهای شبکه‌های عصبی مصنوعی می‌باشد. به طور معمول این شبکه‌ها

البته در شکل ۳ به علت خطاهای موجود در سامانه و یا خطاهای احتمالی موجود در آزمایش‌ها، منحنی‌های مربوط به شدت جریان‌های هوای  $m^3/h$  (۲۰ و ۳۰) دارای یک روند نزولی بوده اما نمودار تأیید کننده تحلیل این روند است.

### بخش نظری

#### مقدمه ای بر شبکه‌های عصبی مصنوعی

##### شبکه‌های عصب مصنوعی<sup>(۱)</sup>

در حالت کلی، یک شبکه عصبی زیستی از مجموعه یا مجموعه‌ای از نورون‌ها به صورت فیزیکی به هم متصل یا از لحاظ عملکرد به هم وابسته تشکیل شده است. هر نورون می‌تواند به تعداد بسیار زیادی از نورون‌ها وصل باشد و تعداد کل نورون‌ها و اتصال‌های بین آن‌ها می‌تواند بسیار زیاد باشد. اتصالات، که به آن‌ها سیناپس گفته می‌شود، به طور معمول از آکسون‌ها و دندریت‌ها تشکیل شده‌اند. عملکرد شبکه عصبی برگرفته از کارایی نورون‌های زیستی است. نقطه مقابل نورون‌های زیستی نورون‌های مصنوعی بوده که سامانه‌ای است شامل تعداد زیادی ورودی و تنها یک خروجی. ساختار نورون‌های مصنوعی شامل دو بخش آموزشی و عملکرد می‌باشند. در حالت آموزش نورون یاد می‌گیرد در مقابل الگوهای ورودی خاص برانگیخته شود و در حالت عملکرد وقتی یک الگوی ورودی شناسایی شده وارد شود، خروجی متناظر با آن ارائه می‌شود. شبکه‌های عصبی مصنوعی روش‌ها محاسبه‌های نوین هستند برای یادگیری ماشینی، نمایش دانش و سرانجام اعمال دانش به دست آمده در راستای پیش‌بینی پاسخ‌های خروجی از سامانه‌های پیچیده. این شبکه‌ها برای تخمین<sup>(۲)</sup> و تقریب<sup>(۳)</sup> کارایی بسیار بالایی دارند. گستره کاربرد این مدل‌های ریاضی بر گرفته از عملکرد مغز انسان، بسیار گسترده می‌باشد که به عنوان چند نمونه کوچک می‌توان استفاده از آن ابزار ریاضی در پردازش سیگنال‌های زیستی، مخابرات و الکترونیکی تا کمک در نجوم و فضا نوردی را نام برد.

#### ساختار شبکه‌ها عصب

یک شبکه عصبی شامل اجزای سازنده لایه‌ها و وزن‌ها می‌باشد. لایه‌ها به سه دسته تقسیم شده که شامل لایه ورودی و لایه پنهان و لایه خروجی می‌باشد. در لایه ورودی اطلاعات خام


(۱) Artificial Neural Network-ANN

(۲) Estimation

(۳) Approximation

(۴) Spread

(۵) Multi layer perceptron



شکل ۵ - سطح سیگموئیدی تشکیل شده از هر واحد شبکه MLP.


ورودی به سامانه است. (مقدار  $i$  از یک تا  $N$  تغییر می‌کند).  
چگونگی ورود توابع، مرحله‌های عملیات و خروجی فرایند در شکل ۶ نمایان است.

همان‌گونه که در شکل ۶ دیده می‌شود ورودی‌ها در قالب بردارهای  $N$  بعدی بر حسب  $x_i$  می‌باشد ( $i$  از یک تا  $P$  تغییر می‌کند)، که با قرارگیری در لایه‌های گوناگون و تشکیل توابع  $G$  به صورت ماتریس  $N \times N$  و با دخالت توابع وزن و نرم کردن توابع ورودی می‌توان از ورودی‌های  $N$  بعدی خروجی‌های تک بعدی را به صورت یک اسکالر داشت. نرم کردن مقدارهای فضای  $N$  بعدی را به فضای یک بعدی تبدیل می‌نماید.

برای به‌دست آوردن خروجی‌های دلخواه در این شبکه از معادله ۲ استفاده کرده و که این معادله بیان‌کننده تابع ریاضی گوسین بر اساس پارامترهای  $x$  و  $t_j$  می‌باشد.

$$G(x_i, t_j) = \exp\left[-\frac{\|x_i, t_j\|^2}{2\sigma_j^2}\right] \quad (2)$$

در این معادله  $x_i$  و  $t_j$  بردارهایی است که برای آموزش<sup>(۳)</sup> استفاده می‌شود. صورت کسر موجود در این معادله نرم تفاضل بردارهای معرفی شده می‌باشد، که نرم یک تابع برابر است با حاصل ضرب نقطه‌ای یک ماتریس در ماتریس ترانپوز آن. در اینجا حاصل تفاضل در صورت کسر یک ماتریس بوده که سرانجام نرم آن برابر است با یک اسکالر که در صورت کسر قرار می‌گیرد.



شکل ۴ - سطح تابع انتقال گوسین در هر واحد شبکه RBF.

شامل مجموعه‌ای از واحدهای حسی (نرون‌های پایه) می‌باشند که در بین لایه‌های گوناگون قرار می‌گیرند. سیگنال ورودی در خلال شبکه و در مسیری رو به جلو به صورت لایه به لایه منتشر می‌شود. این نوع شبکه معمولاً با عنوان پرسپترون چندلایه (MLP) نامیده می‌شود. شبکه MLP قادر به مدل‌سازی مسایل گوناگون می‌باشد. در مهم‌ترین بخش شبکه‌های MLP، باید تعداد لایه‌های میانی و تعداد نرون‌ها در این لایه‌های ورودی و خروجی توسط پارامترهای مسئله تعیین می‌شوند. پرسپترون چند لایه می‌تواند با به‌کارگیری تعداد کافی از لایه‌های پرسپترون در شبکه و تعداد مناسبی از پرسپترون‌ها در هر لایه، طبقه‌بندی‌های پیچیده‌ای را انجام دهد. این طبقه‌بندی‌ها با استفاده از تابع انتقال سیگموئید می‌باشد که در شکل ۵ دیده می‌شود [۱۹].

### شبکه ORN<sup>(۱)</sup>

در سال ۱۹۹۰ میلادی *Girosi* و *Poggio* [۱۷، ۱۶] نظریه تنظیم توابع چند متغییره را بر اساس معادله (۱) بیان نمودند:

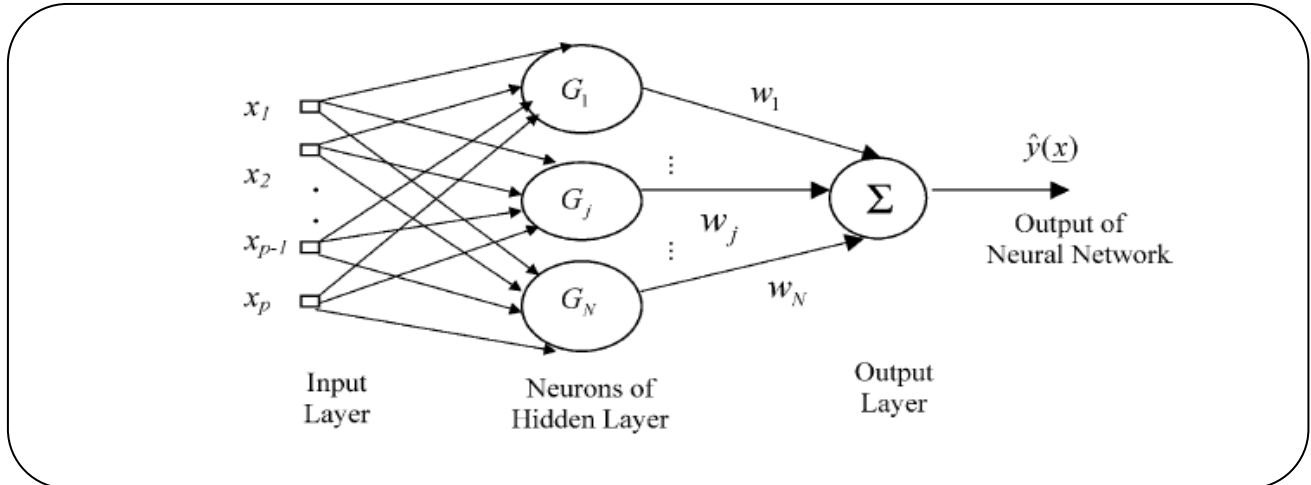
$$(G + \lambda I_N) W_\lambda = Y \quad (1)$$

در معادله (۱)،  $G$  یک ماتریس متقارن و  $\lambda$  پارامتر پارامتر تنظیم‌کننده<sup>(۲)</sup>،  $I_N$  یک ماتریس واحد،  $W_\lambda$  بردار وزنی سامانه بوده، که نشان‌دهنده سهم هر یک از داده‌های ورودی بر اساس نقش مؤثرشان در فرایند می‌باشد،  $Y$  نیز پاسخ مربوط به مقدارهای

(۱) Optimal regularization network

(۲) Regularization

(۳) Training



شکل ۶ - شبکه بهینه منظم.

بر اساس معادله (۵) است. CV مخفف Cross Validation می‌باشد، این پارامتر به منظور برطرف کردن خطاهای مقدارهای ورودی در محاسبات شبکه قرار گرفته است. بنابراین بین داده‌ها براساس  $\delta$  و  $\lambda$  اعتبار سنجی می‌کند.

$$V(\lambda_s) = \frac{1}{N} \sum_{k=1}^N \left[ \frac{e_k^T (I_N - G(G + \lambda_s I_N)^{-1}) y}{e_k^T (I_N - G(G + \lambda_s I_N)^{-1}) e_k} \right]^2 \quad (5)$$

حال در اینجا اگر  $\lambda_s$  ای را که در محاسبه CV از فرمول (۴) به دست آوریم بیش‌تر از  $\lambda_{max}$  باشد یک حدس جدید برای  $\lambda_s$  و مقدار CV را دوباره می‌یابیم. اما جایی که  $\lambda_s$  کوچک‌تر شود باید به دنبال یافتن  $\lambda^*$  یا همان پارامتر Regularization بهینه باشیم که برای این کار مقدارهای  $\lambda_s$  را بر حسب CV رسم کرده جایی که مقدار  $\lambda_s$ ، مقدار کمینه شود  $\lambda_s$  برابر با  $\lambda^*$  می‌باشد.

در این مرحله پارامتر Regularization بهینه شد اما در یافتن این پارامتر بهینه از پارامتر بهینه نشده Spread استفاده شده است، که در اینجا نوبت به بهینه نمودن Spread است. برای این کار  $\sigma_r$  به دست آمده از فرمول (۳) را با بیشینه مقدار  $\sigma$  مقایسه می‌نماییم، اگر  $\sigma_{max} < \sigma_r$  باشد حدس دیگری زده و محاسبه‌ها را تکرار می‌کنیم. در غیر این صورت یعنی زمانی که  $\sigma_{max} > \sigma_r$  باشد اقدام به یافتن  $\sigma$  بهینه می‌کنیم، به این صورت که در  $\lambda^*$  گوناگون مقدارهای  $\sigma_r$  را به دست آورده و نمودار  $\lambda^*$  را بر حسب  $\sigma_r$  رسم می‌نماییم.  $\sigma_r$  ای که در مقدار خود، مقدار  $\lambda^*$  بیش‌ترین مقدار ممکن شود،  $\sigma_r$  برابر با  $\sigma^*$  (پارامتر Spread بهینه) می‌باشد.

در مخرج کسر پارامتر  $\sigma$  یا همان Spread دیده می‌شود که بیان‌کننده گستردگی نقاط نسبت به بازه پاسخ دریافتی از سامانه می‌باشد. عملکرد شبکه ORN به شدت وابسته به انتخاب یک Spread صحیح و بهینه کردن مقدار این Spread برای کل فرایند می‌باشد.

در روند بهینه کردن Spread، ابتدا باید بیشینه و کمینه مقدار این  $\sigma$  برای نرم افزار تعریف شود، سپس بر اساس فرمول (۳) مقدار این پارامتر به دست می‌آید که آن را با  $\sigma_r$  نشان می‌دهیم.

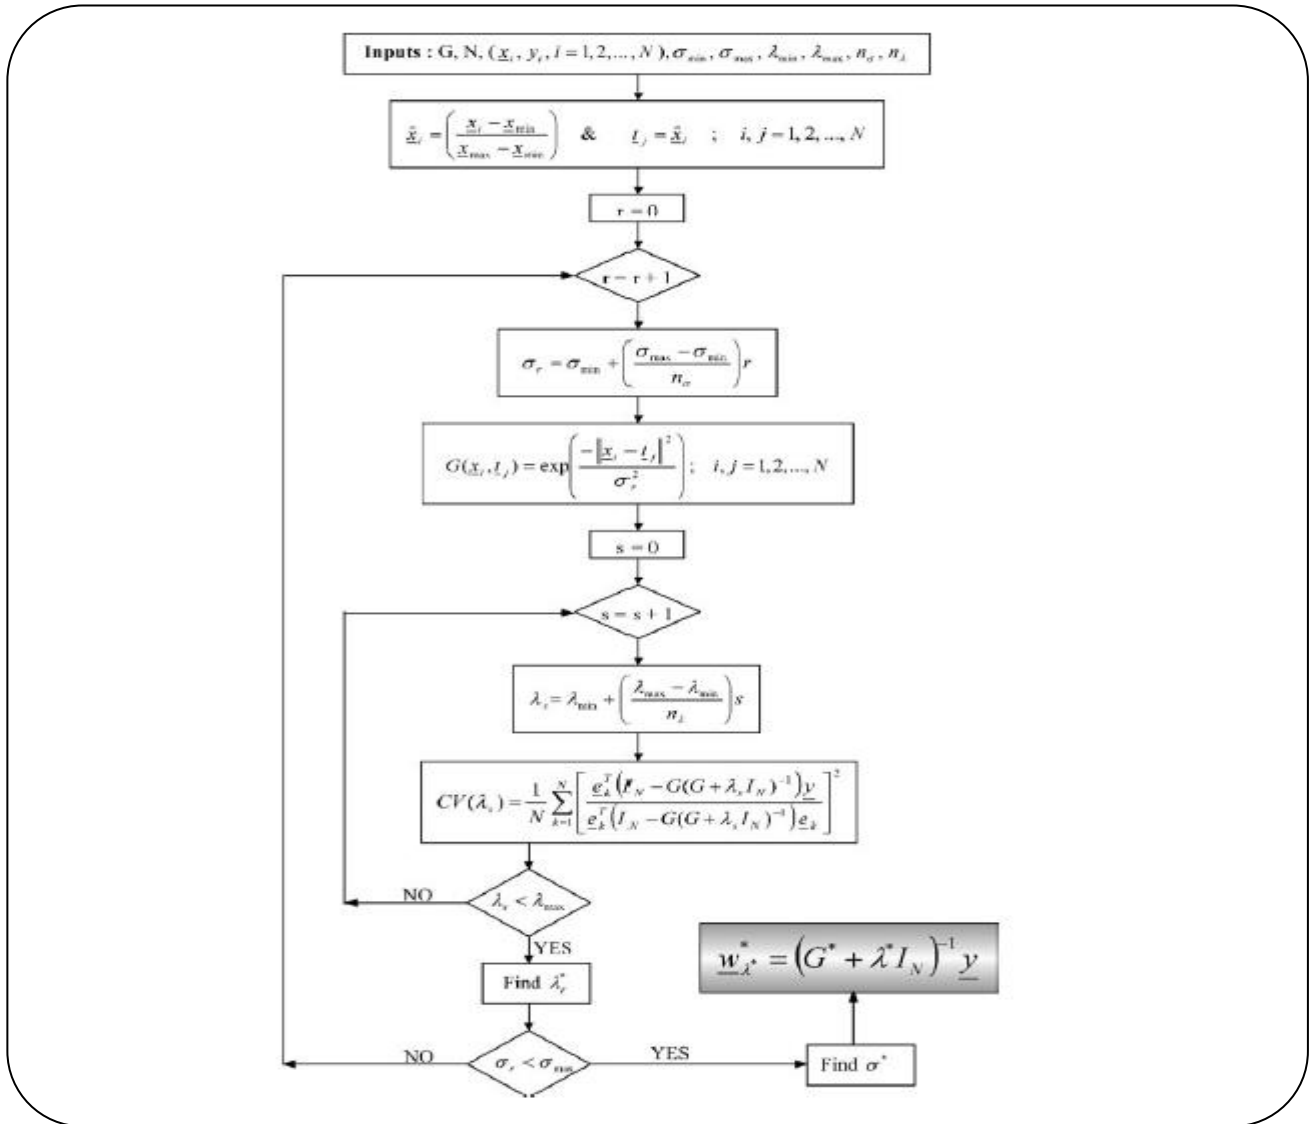
$$\sigma_r = \sigma_{min} + \left[ \frac{\sigma_{max} - \sigma_{min}}{n} \right] \quad (3)$$

با به دست آمدن صورت و مخرج کسر موجود در تابع گوسین می‌توان  $G(x_i, t_j)$  را بر اساس مقدار Spread تعیین شده به دست آورد. پس از این مرحله نوبت به یافتن  $\lambda$  یا همان پارامتر Regularization می‌باشد، که براساس فرمول (۴) مقدار آن قابل دستیابی است.

$$\lambda_s = \lambda_{min} + \left[ \frac{\lambda_{max} - \lambda_{min}}{n} \right] \quad (4)$$

مقدار این پارامتر بین مقدارهای کم‌ترین و بیش‌ترین  $\lambda$  در نوسان است. مقدار کم‌ترین و بیش‌ترین  $\lambda$  در بهترین حالت ممکن در بازه  $10^{-5}$  و  $10^{-2}$  قرار دارد اما اگر در بازه  $10^{-10}$  و  $10^{-2}$  قرار گیرد ضریب اطمینان عملکرد آن بالا تر است [۱۸]. پس از یافتن  $\delta$  و  $\lambda$  نوبت به معرفی و یافتن پارامتر CV





شکل ۷ - الگوریتم روش حل معادله‌های شبکه ORN.

**پیش‌بینی خروجی‌های پایلوت با شبکه عصبی مصنوعی**

**انتخاب پارامتر بهینه در شبکه‌ها MLP، RBF و ORN**

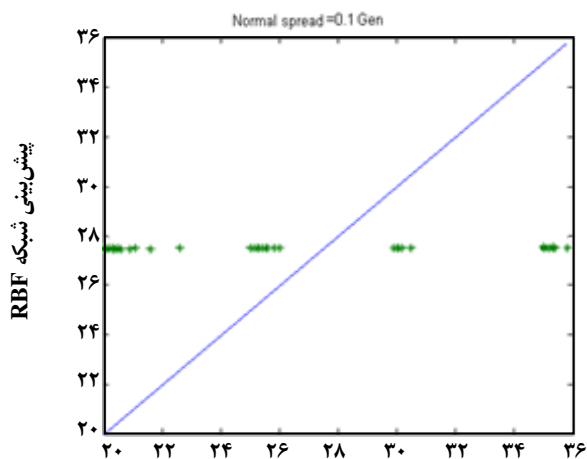
هر شبکه برای به‌وجود آمدن و قابل پذیرش بودن به دو گروه داده نیازمند است: گروه آموزش و گروه آزمون. در حدود ۸۰٪ داده‌ها صرف گروه آموزش و بقیه صرف گروه آزمون می‌شوند. که در این مسیر پارامتر بهینه برای هر شبکه خاص به‌دست می‌آید. در طی فرایند یادگیری میزان فراگیری شبکه توسط توابع هدف به طور مرتب سنجیده می‌شوند و سرانجام شبکه‌ای مورد پذیرش قرار می‌گیرد که دارای کم‌ترین میزان خطا باشد.

پس از یافتن  $\sigma^*$  و  $\lambda^*$  با توجه به فرمول (۶) می‌توان تنها پارامتر باقیمانده از این معادله یعنی تابع وزن را بهینه نمود که مقدار آن از فرمول زیر و با قرار دادن مقدارهای بهینه  $\sigma^*$  و  $\lambda^*$  به‌دست خواهد آمد.


$$W_{\lambda^*}^* = (G^* + \lambda^* I_N)^{-1} Y \quad (6)$$

حال می‌توان با این مقدار بهینه خروجی‌های بهینه‌ای را از شبکه دریافت نمود.

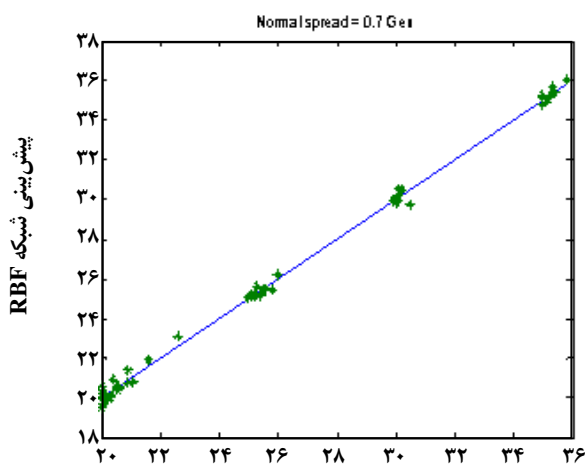
روند انجام محاسبه‌های این معادله‌ها در الگوریتم شکل ۷، از مرحله دریافت اطلاعات تا بهینه نمودن تابع وزن به ترتیب موجود است.



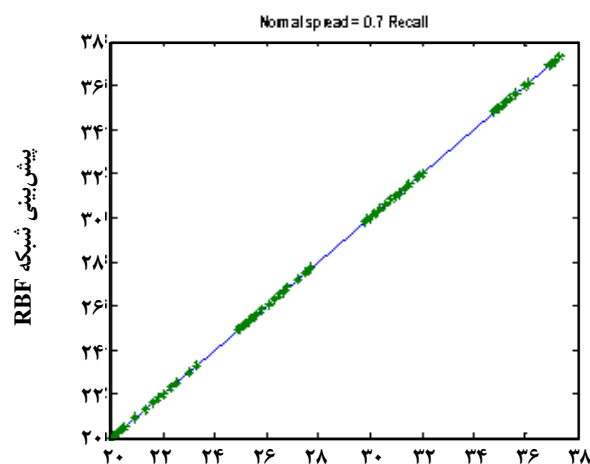
خروجی دمای آزمایشگاه



خروجی دمای آزمایشگاه

شکل ۸ - منحنی Recall و Generation برای  $\text{Spread} = 0.1$ .

خروجی دمای آزمایشگاه



خروجی دمای آزمایشگاه

شکل ۹ - منحنی Recall و Generation برای  $\text{Spread} = 0.7$ .

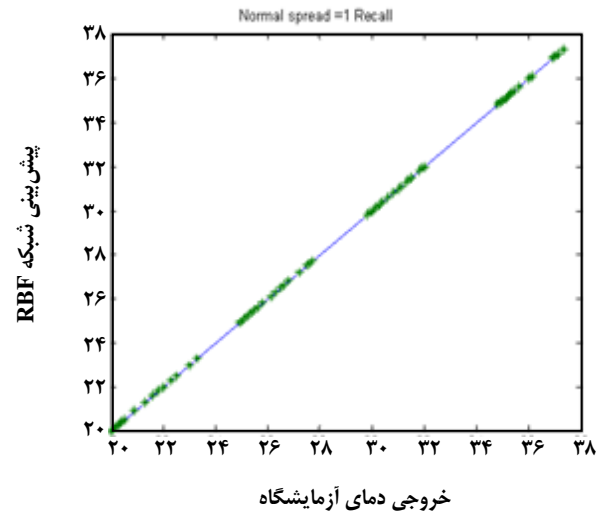
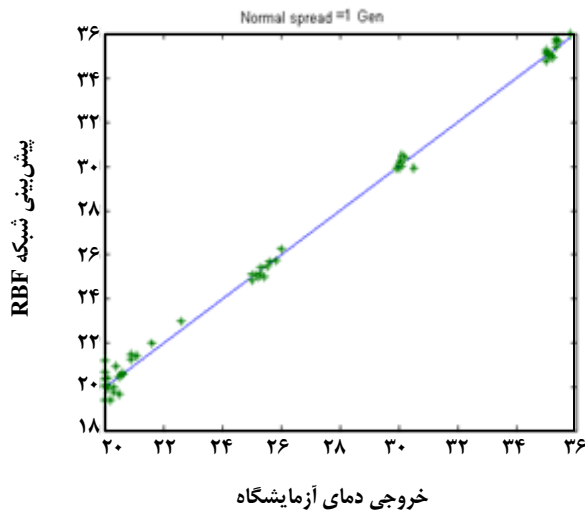
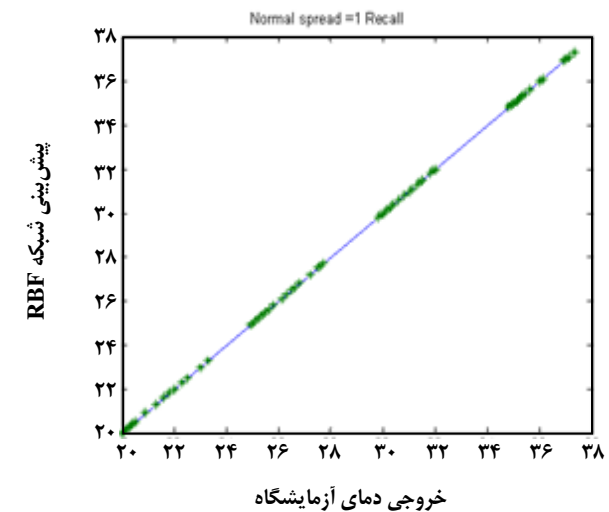

اطلاعاتی (۴\*۲۵۶)، همچنین اطلاعات خروجی در قالب یک ماتریس (۱\*۲۵۶) برای شبکه تعریف شود. البته تعریف این اطلاعات برای سایر انواع شبکه نیز نیاز است. شکل‌های ۸، ۹ و ۱۱ نمودارهای مربوط به نتیجه‌های آزمون و آموزش برای مقادیرهای  $\text{Spread}$  برابر با ۰/۱، ۰/۵، ۰/۷ و ۱ است.

در بررسی این شکل‌ها انتظار می‌رود که خروجی‌های شبکه در اطراف خط ۴۵ درجه قرار گرفته یا بر روی آن منطبق شوند. که با بررسی نمودارهای مربوطه و مقایسه آنها با یکدیگر، در  $\text{Spread}$  برابر با ۰/۷ تجمع داده‌ها به صورت معقول‌تری در شکل ظاهر شده است.

در شبکه RBF و شبکه ORN پارامتر بهینه  $\text{Spread}$  و در شبکه MLP این پارامتر تعداد لایه و تابع انتقال سامانه است.

#### پارامتر بهینه در شبکه RBF

پارامتر تأثیرگذار در شبکه RBF پارامتر  $\text{Spread}$  است که با توجه به اطلاعات ورودی و با حدس و خطا مقدار بهینه آن به دست خواهد آمد. در یافتن  $\text{Spread}$  بهینه ابتدا باید اطلاعات ورودی سامانه شامل دمای آب ورودی، شدت جریان آب، دمای هوای ورودی و شدت جریان هوا در قالب یک ماتریس با حجم

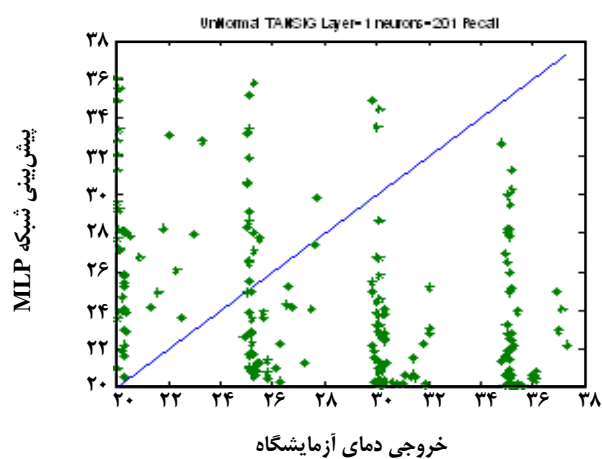

شکل ۱۰ - منحنی Recall و Generation برای  $\text{Spread} = 0.5$ .شکل ۱۱ - منحنی Recall و Generation برای  $\text{Spread} = 1$ .

پراکنده بوده و هیچ تجمعی در اطراف خط ۴۵ درجه دیده نمی‌شود. بنابراین انتخاب هر یک از توابع انتقال تأثیری بر خروجی‌های شبکه نخواهد داشت و می‌توان با انتخاب دلخواه یکی از این تابع‌ها، تأثیر تغییر تعداد لایه را بررسی نمود. از این رو با انتخاب تابع انتقال LogSig و ده عدد لایه، نتیجه‌های شبکه را بررسی نمود، که شکل ۱۵ نشان دهنده بررسی‌های انجام شده است. در شکل ۱۵ با تغییر تعداد لایه، در خروجی از شبکه تغییری رخ نداد و نتیجه‌ها کماکان به قوت خویش باقی ماند و نمی‌توان پارامتر بهینه‌ای برای حالت فوق‌ارایه نمود.

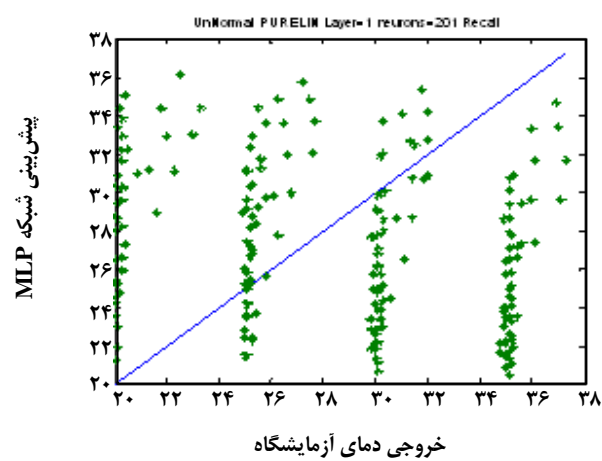
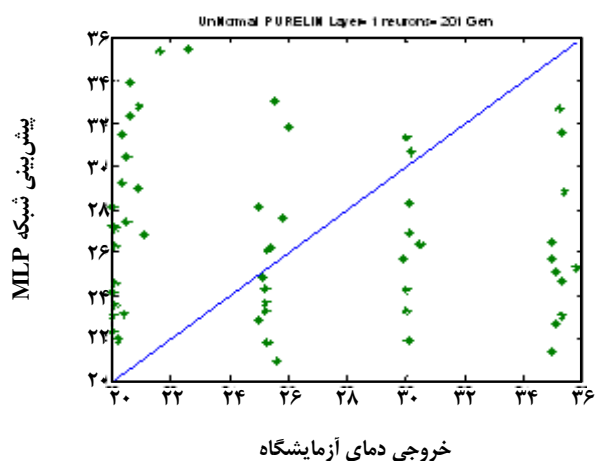
بنابراین Spread بهینه برای داده‌های نرمال برابر است با مقدار عددی ۰.۷.

#### پارامتر بهینه در شبکه MLP

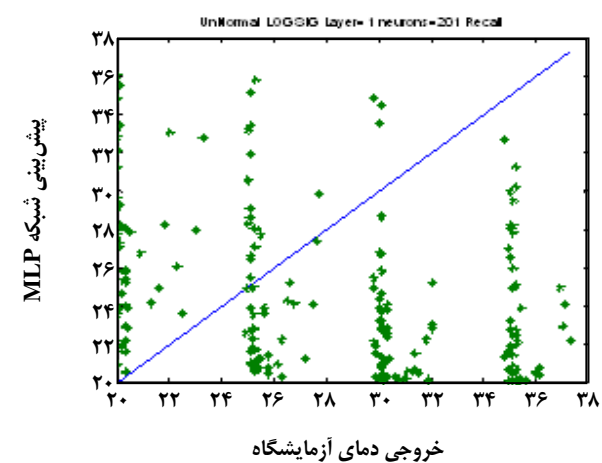

برای انتخاب پارامتر بهینه در شبکه MLP ابتدا با ثابت نگه داشتن تعداد لایه‌ها اثر تابع انتقال را بررسی نمود، که در شکل‌های ۱۲، ۱۳ و ۱۴ نتیجه‌های این بررسی برای توابع انتقال Tan Sig، Pure Lin و Log Sig موجود است. با توجه به شکل‌های ۱۳ و ۱۴ در هر سه شکل، داده‌ها در کل نمودار



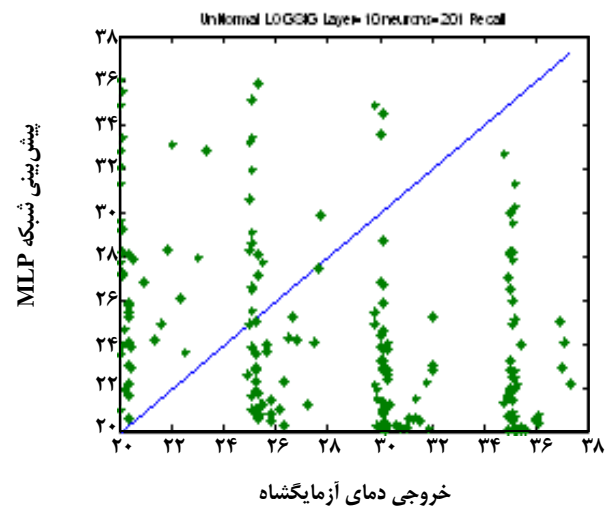
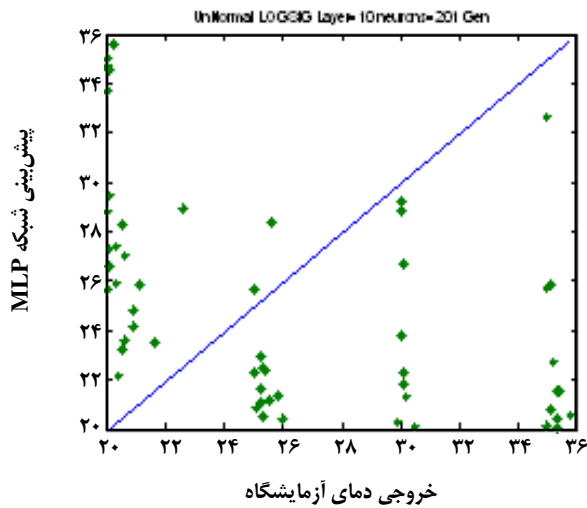
شکل ۱۲ - منحنی Recall و Generation، تابع انتقال TanSig و تعداد لایه=۱.



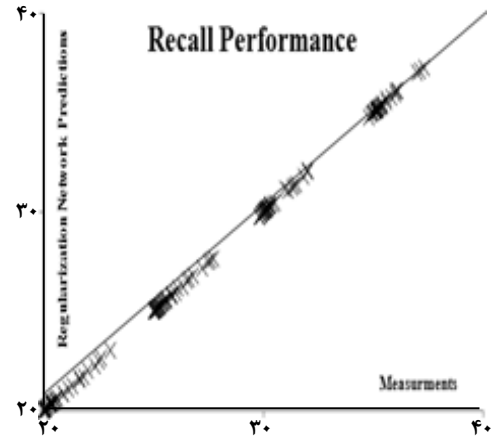
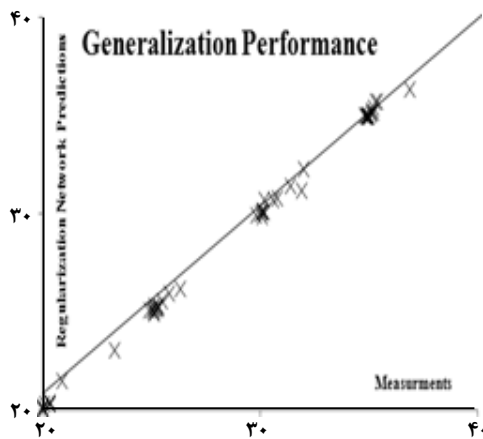
شکل ۱۳ - منحنی Recall و Generation، تابع انتقال PureLin و تعداد لایه=۱.



شکل ۱۴ - منحنی Recall و Generation، تابع انتقال LogSig و تعداد لایه=۱.



شکل ۱۵ - منحنی Recall و Generation برای تابع انتقال LogSig و تعداد لایه = ۱۰.



شکل ۱۶ - منحنی Recall و Generation در شبکه ORN برای تعیین Spread بهینه.

### عملکرد انواع شبکه بر مبنای کل داده ها

پس از یافتن پارامترهای بهینه در هر شبکه باید عملکرد شبکه را بر مبنای کل داده‌ها بررسی و شبکه را برای ۲۵۶ داده آزمایش نمود.

#### شبکه RBF

با توجه به شکل ۱۸ این شبکه براساس Spread بهینه، با مقدار عددی ۰٫۷، خروجی‌های مناسبی را پیش‌بینی نموده است و تمامی داده‌ها در امتداد خط ۴۵ درجه قرار دارند.

### پارامتر بهینه در شبکه ORN

در شبکه ORN پارامتر Spread پارامتری است که باید بهینه شود. در این شبکه مدل ریاضی به گونه‌ای است که با دریافت اطلاعات، شبکه محاسبه‌ها را به صورت خود به خود انجام داده و برای یافتن پارامتر بهینه نیاز به حدس و خطا نیست. شکل ۱۶ نمودارهای مربوط به آزمون و آموزش داده‌ها می‌باشد. تجمع مناسب نقاط در اطراف خط ۴۵ درجه مبین عملکرد مناسب این شبکه می‌باشد.

روند بهینه شدن Spread نیز در شکل ۱۷ نمایان است با توجه به شکل، Spread بهینه برابر با ۰٫۷ می‌باشد.

**شبکه MLP**

در شکل ۱۹ عملکرد شبکه MLP برای یک لایه و تابع انتقال LogSIG برای کل داده ها نمایش داده شده است. توزیع نامناسب نقاط در کل شکل نشان دهنده عملکرد نامناسب این شبکه می باشد.


**شبکه ORN**

با توجه به شکل ۲۰ این شبکه براساس Spread بهینه، با مقدار عددی ۰/۷ بررسی شده و همان گونه که دیده می شود داده ها در اطراف خط ۴۵ درجه به صورت متقارن تجمع یافته اند که این امر بیانگر عملکرد درست شبکه می باشد.

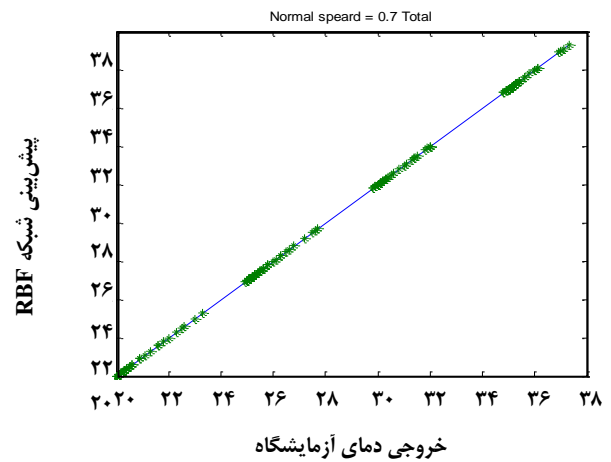
**تحلیل روند نتیجه ها (۱)**

در شکل ۲۱ و ۲۲ عملکرد انواع شبکه در مقایسه با نتیجه های تجربی موجود می باشد. در شکل ۲۱ دمای آب خروجی بر حسب شدت جریان هوا رسم شده است، این ترسیم در شرایط شدت جریان آب ۰/۲۵ m<sup>3</sup>/h و دمای آب ورودی ۲۲ °C صورت گرفته است. همان گونه که در شکل دیده می شود نتیجه های تجربی دارای منحنی های معقولی بوده و منحنی ها هیچ تداخلی با یکدیگر نداشته و نتیجه های به دست آمده از آزمایش ها قابل قبول است، متعاقب آن برای این داده های معقول شبکه MLP بدترین خروجی شبکه را پیش بینی نموده است، که با توجه به نتیجه های پیشین و بهینه نشدن هیچ پارامتری در این شبکه، این چنین رفتاری دور از انتظار نبود. اما شبکه ORN و RBF عملکرد مناسبی داشته و خروجی های منطقی ای در نمودارها نمایش داده شده است.

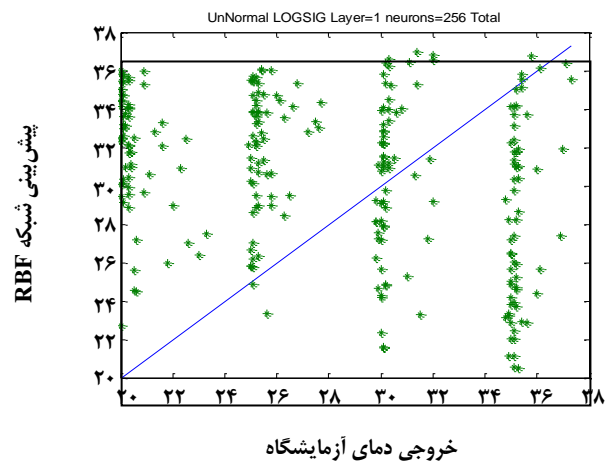
از مقایسه شبکه ORN و RBF در شکل ۲۱ در ظاهر، این دو نمودار تفاوت چندانی با یکدیگر ندارند، زیرا اساس کار در این نمودارها یکسان است و هر دو شبکه از نوع RBF ولی با توانایی های گوناگون می باشند. اگر کمی بیش تر در این دو شکل دقت نماییم، در شبکه RBF در یک مقیاس طولی و عرضی یکسان میزان نوسان داده های خروجی شبکه بیش تر از شبکه ORN می باشد و شبکه ORN میزان این نوسان را تا حد امکان کاهش داده است. زیرا این شبکه بر مبنای بهینه سازی این محاسبه ها را انجام می دهد و ساختار قوی تری از لحاظ نظری دارد و کارکرد ساده تری نسبت به شبکه RBF دارد. زیرا در این شبکه برای دریافت خروجی های شبکه تنها نیاز است که ورودی برای سامانه تعریف شود و دیگر کارها از مانند بهینه سازی، پیدا کردن  $\lambda$  بهینه،



شکل ۱۷ - منحنی تعیین Spread بهینه در شبکه ORN.

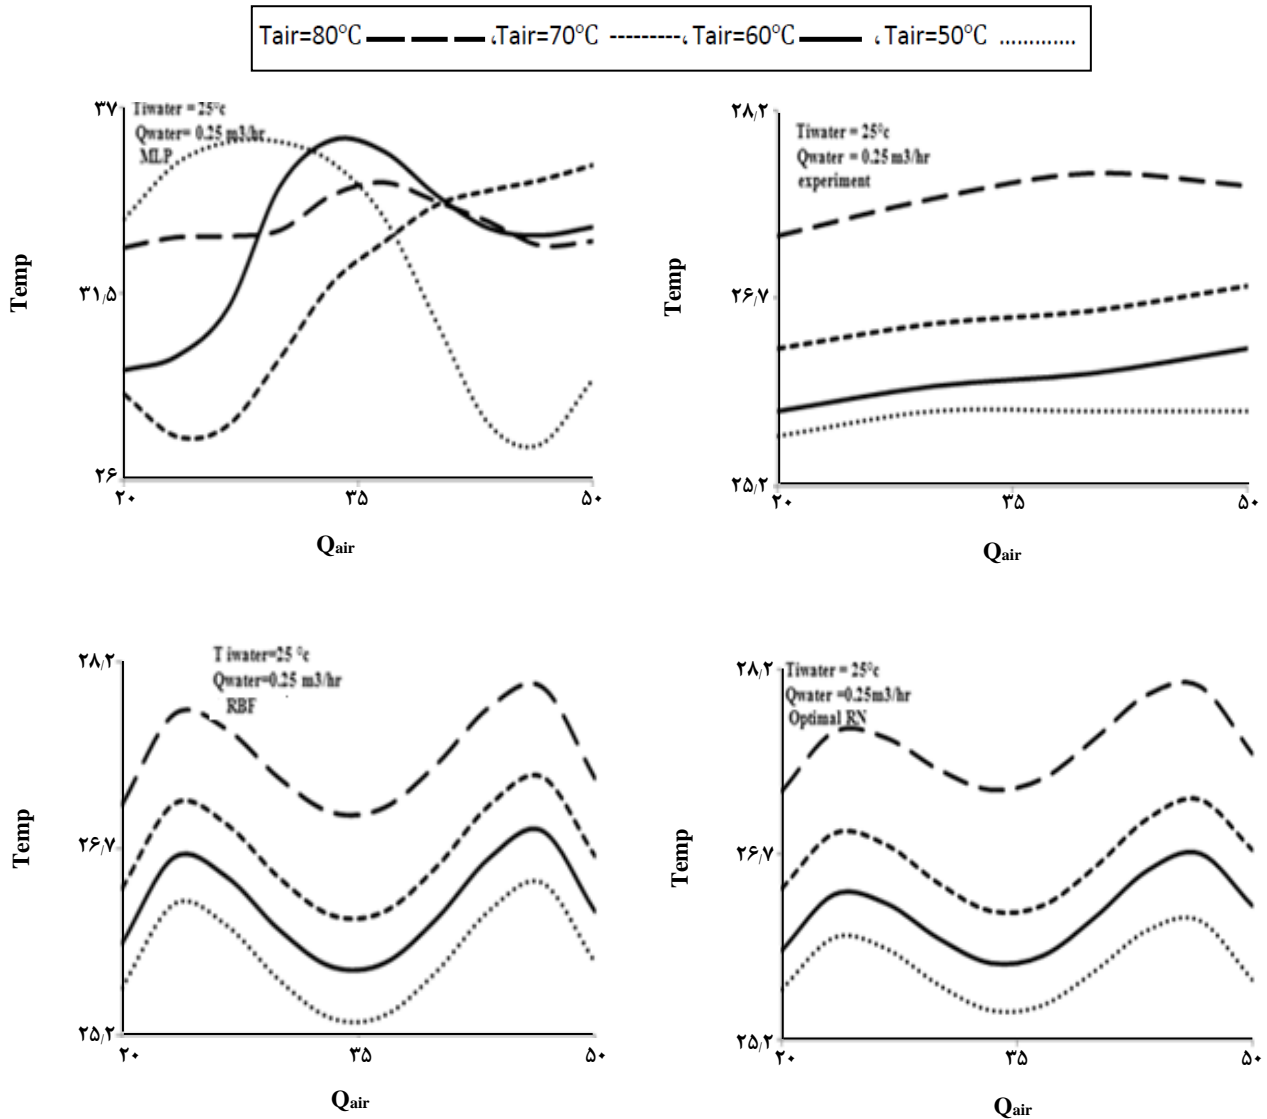


شکل ۱۸ - منحنی عملکرد شبکه RBF برای کل داده ها.



شکل ۱۹ - منحنی عملکرد شبکه MLP برای کل داده ها.

(1) Trend analysis



شکل ۲۱- مقایسه نتیجه‌های انواع شبکه عصبی با نتیجه‌های آزمایشگاهی.

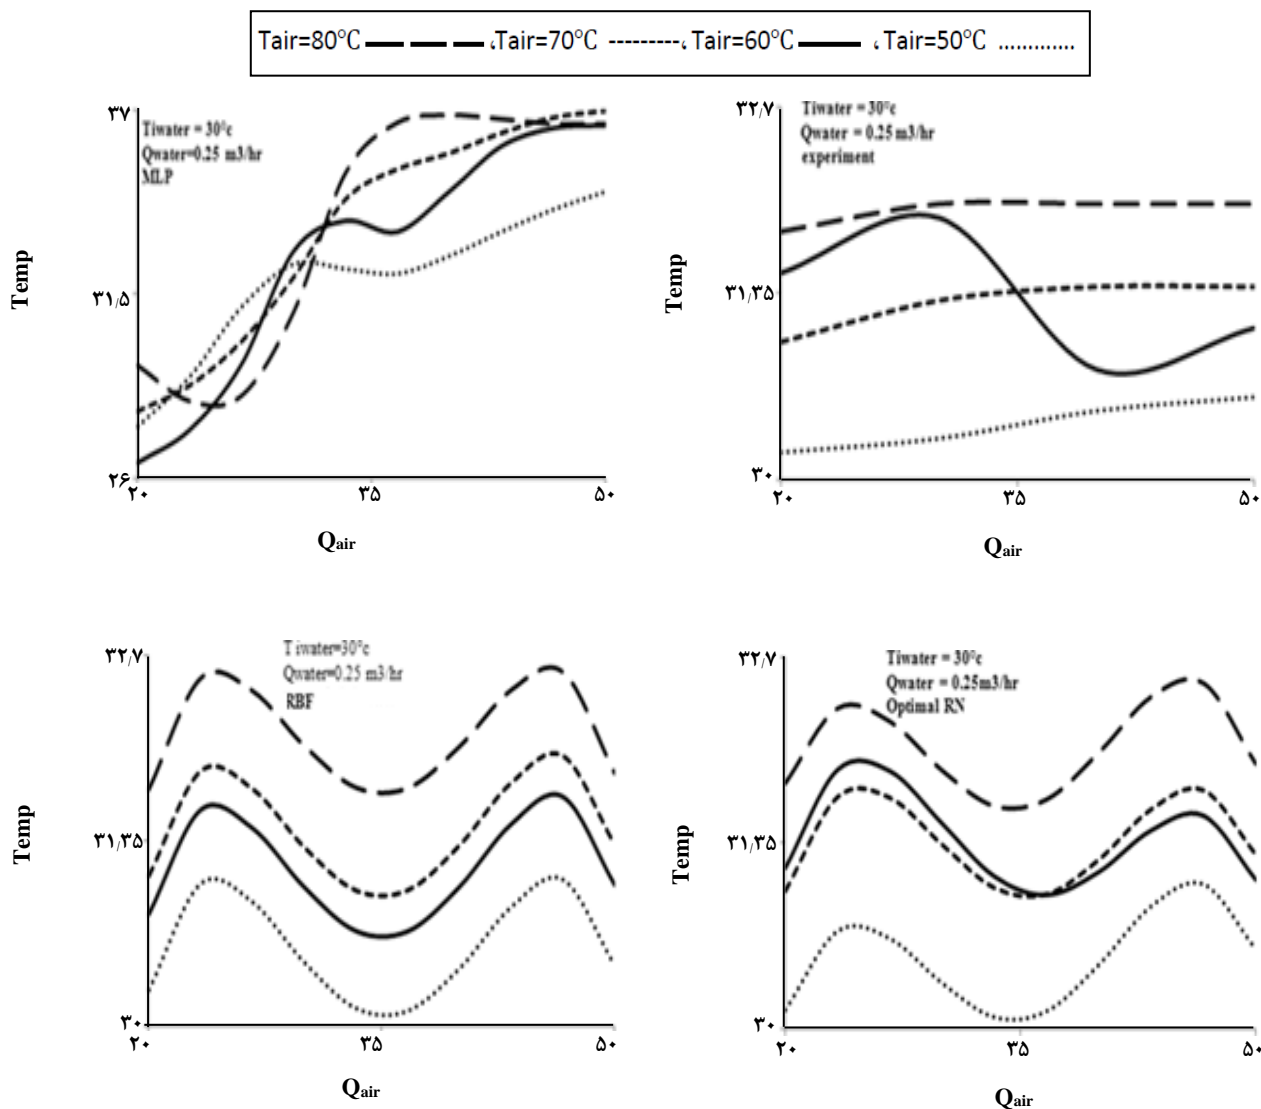
در این تحلیل برابر است با شدت جریان آب  $0.25 \text{ m}^3/\text{h}$  و دمای آب ورودی  $30^\circ\text{C}$ .

پیش‌بینی‌ای که هر یک از انواع شبکه برای دمای آب خروجی انجام می‌دهند باید به نوعی با نتیجه‌های تجربی همخوانی داشته باشد و بتواند عملکرد بهتری را نسبت به نتیجه‌های تجربی ارائه نماید، زیرا این شبکه‌ها بر اساس داده‌های تجربی آموزش دیده‌اند.

در شکل ۲۲ در نمودار تجربی به جز در حالتی که دمای آب  $60^\circ\text{C}$  می‌باشد، در دیگر حالت‌ها هیچ نوسانی دیده نمی‌شود. شکل مربوط به شبکه MLP بدترین خروجی شبکه را ارائه نموده است،

پیدا کردن Spread بهینه و تخمین طول بهینه، خود به خود انجام می‌گیرد و نیاز به سعی و خطا و محاسبه‌های دستی نمی‌باشد. اما در شبکه RBF، به دست آوردن پارامتر Spread بهینه و انتخاب تصادفی داده‌ها و انجام سعی و خطا توسط کاربر انجام می‌گیرد. سرانجام این نتیجه حاصل شد که شبکه ORN به دلیل دارا بودن مبنای نظری قوی‌تر و استفاده از روش‌های پیشرفته ریاضی همانند CV نتیجه‌های بهتری را نسبت به شبکه RBF ارائه می‌نماید.

در تحلیلی دیگر نمودار نتیجه‌های تجربی با انواع شبکه MLP، RBF و ORN در شکل ۲۲ مقایسه شده است. شرایط آزمایش



شکل ۲۲- مقایسه نتیجه‌های انواع شبکه عصبی با نتیجه‌های آزمایشگاهی.

اما در شبکه ORN این نوسان دیده می‌شود، که این امر نشان دهنده این است که این شبکه با دقت داده‌های تجربی را دریافت، بهینه‌سازی و تحلیل نموده است در صورتی که شبکه RBF مطلب یک چنین روندی را اصلاً در نظر نگرفته و کلاً نوسان را نادیده گرفته است.

بنابراین در این حالت نیز عملکرد شبکه ORN بهتر از شبکه RBF مطلب می‌باشد.

اگر در شکل‌های ۲۱ و ۲۲ دقت نماییم، خواهیم دید که در هر شکل به جز شبکه MLP بقیه نمودارها از مقیاس یکسانی در محورهای عمودی و افقی برخوردارند. این امر به دلیل عملکرد نامناسب

که با توجه به پایه نظری ضعیف و بهینه نشدن هیچ پارامتری در این شبکه، این چنین رفتاری دور از انتظار نیست. از مقایسه نتیجه‌های شبکه ORN و RBF کاملاً مشهود است که شبکه RBF توانسته داده‌ها را بهتر از هم تفکیک نماید اما لزوماً تفکیک بهتر نشان دهنده بهتر عمل نمودن شبکه مربوطه نمی‌باشد، زیرا این تفکیک باید بر اساس در نظر گرفتن داده‌های تجربی صورت گیرد. در داده‌های تجربی همان‌گونه که در شکل ۲۲ دیده می‌شود، در دمای آب برابر با  $60^{\circ}\text{C}$  یک نوسان وجود دارد، به این نوسان در شبکه RBF هیچ توجهی نشده است و خروجی‌های شبکه بدون در نظر گرفتن نوسان در داده‌های تجربی قابل دیدن است.



شدت جریان و دمای دو سیال آب و هوا صورت گرفته است. از نتیجه‌های به دست آمده از این آزمایش‌ها در بررسی انواع شبکه عصبی مصنوعی و مقایسه عملکرد این شبکه‌ها با یکدیگر و با نتیجه‌های به دست آمده از آزمایش‌ها استفاده شد.

از جمله شبکه‌های عصبی به کار برده شده در این مقاله می‌توان به شبکه RBF و شبکه MLP و شبکه ORN اشاره نمود. بررسی‌های انجام شده بیانگر از این است که شبکه MLP به دلیل نبود امکان برطرف نمودن خطا و اغتشای قادر به پیش‌بینی مناسب نبوده و شبکه ORN به دلیل دارا بودن مبنای نظری قوی‌تر و استفاده از فناوری‌های پیشرفته ریاضی مانند CV بهترین عملکرد را دارا می‌باشد.

تاریخ دریافت: ۱۳۹۳/۷/۷؛ تاریخ پذیرش: ۱۳۹۳/۷/۷

شبکه MLP و بهینه نشدن هیچ کدام از پارامترهای موجود در آن می‌باشد، از این رو نتیجه‌های مربوط به خروجی شبکه دارای مقدارهای غیر معقول و متفاوت از سه نمودار دیگر بوده و عملاً در بازه‌ای که سه نمودار دیگر دارای مقدارهای معقول می‌باشند شبکه MLP بدون پاسخ است. بنابراین تنها برای اینکه چگونگی تغییرهای نتیجه‌های به دست آمده از خروجی شبکه MLP آشکار شود، این شبکه در مقیاس بزرگ‌تری ارایه شده است.

## نتیجه‌گیری

در این پژوهش دستگاهی با قابلیت انجام آزمایش‌های مربوط به انتقال جرم و گرمای همزمان ارایه شده است. آزمایش‌های انجام شده توسط این دستگاه با تغییر پارامترهای فرایندی مانند

## مراجع

- [1] Himmelblau D.M., Hoskins J.C., [Artificial Neural Network models of Knowledge Representation in Chemical Engineering](#), *Computers and Chemical Engineering*, **12**: 881-890 (1988).
- [2] Venkatasubramanian V., Chan K., [A Neural Network Methodology for Process Fault Diagnosis](#), *AIChE Journal*, **35**: 1993-2002 (1989).
- [3] Watanabe K., Matsuura I., Abe M., Kubota M., Himmelblau D.M., [Incipient Fault Diagnosis of Chemical Engineering Processes via Artificial Neural Networks](#), *AIChE Journal*, **35**: 1803-1812 (1989).
- [4] Chan W.M., Nascimento C.A.O., [Use of Neural Networks for Modeling of Olefin Polymerization in High Pressure Tubular Reactors](#), *Journal of Applied Polymer Science*, **53**: 1277-1289 (1994).
- [5] Nascimento C.A.O., Guardani R., Giulietti M., [Use of Neural Networks in the Analysis of Particle Size Distributions by Laser Diffraction](#), *Powder Technology*, **90**: 89-94 (1997).
- [6] Iliuta S.I.I., Lavric V., [Two-Phase Downflow and Upflow Fixedbed Reactors Hydrodynamics Modeling Using Artificial Neural Network](#), *Chem. Ind.*, **53**(6): 176-186 (1999).
- [7] Nascimento C.A.O., Giudici R., Guardani R., [Neural Network Based Approach for Optimization of Industrial Chemical Processes](#), *Computers and Chemical Engineering*, **24**: 2303-2314 (2000).
- [8] Guardani R., Onimaru R.S., Crespo F.C.A., [Neural Network Model for the On-Line Monitoring of a Crystallization Process](#), *Braz. J. Chem. Eng.*, **18**(3):267-275, (2001).
- [9] Xie G.N., Wang Q.W., Zeng M., Luo L.Q., [Heat Transfer Analysis for Shell-and-Tube Heat Exchangers with Experimental Data by Artificial Neural Networks Approach](#), *Applied Thermal Engineering*, **27**(5-6):, 1096-1104 (2007).

- [10] Scalabrin G., Condosta M., Marchi P., [Modeling Flow Boiling Heat Transfer of Pure Fluids Through Artificial Neural Networks](#) *International, Journal of Thermal Sciences*, **45**(7): 643-663 (2006).
- [11] Movagharnejad K., Nikzad M., [Modeling of Tomato Drying Using Artificial Neural Network](#), *Computers and Electronics in Agriculture*, **59**(1-2): 78-85 (2007).
- [12] Balcilar M., Dalkilic A.S., Wongwises S., [Artificial Neural Network Techniques for the Determination of Condensation Heat Transfer Characteristics During Downward Annular Flow of R134a Inside a Vertical Smooth Tube](#), *International, Communications in Heat and Mass Transfer*, **38**(1): 75-84 (2011).
- [13] Shahsavand A., Derakhshan Fard F., Sotoudeh F., [Application of Artificial Neural Networks for Simulation of Experimental CO<sub>2</sub> Absorption Data in a Packed Column](#), *Journal of Natural Gas Science and Engineering*, **3**(3): 518-529 (2011).
- [14] Beigzadeh R., Rahimi M., [Prediction of Heat Transfer and Flow Characteristics in Helically Coiled Tubes Using Artificial Neural Networks](#), *International Communications in Heat and Mass Transfer*, **39**(8): 1279-1285 (2012).
- [15] "Neural Network Toolbox, Using of Matlab 7.0".
- [16] Poggio T., Girosi F., [Regularization Algorithms for Learning that are Equivalent to Multilayer Networks](#), *Science*, **247**: 978-982 (1990).
- [17] Poggio T., Girosi F., [Networks for Approximation and Learning](#), *Proceedings of the IEEE*, **78**: 1481- 1497 (1990b).
- [18] Shahsavand A., Ahmadpour A., [Application of Optimal RBF Neural Networks for Optimization and Characterization of Porous Materials](#), *Chemical Computers & Chemical Engineering*, **29**(10):2134-2143,( 2005).
- [۱۹] منہاج، محمد باقر؛ مبانی شبکه‌های عصبی هوش مصنوعی، مرکز نشر دانشگاه صنعتی امیر کبیر (۱۳۸۱).