



موسسه آموزش عالی غیر دولتی غیرانتفاعی انرژی

پایان نامه برای دریافت درجه کارشناسی ارشد «*M.Sc.*»

رشته مهندسی مکانیک گرایش تبدیل انرژی

## عنوان:

ارائه مدلی قابل اعتماد برای تخمین ضریب کلی انتقال  
حرارت درون مبدل حرارتی پوسته و لوله با استفاده از نرم  
افزار متلب

استاد راهنما:

دکتر حیدر مداح

دکتر یاسی

نام دانشجو:

محمد مهدی کریمی

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

## تأییدیه‌ی صحت و اصالت نتایج

### باسمه تعالی

اینجانب محمد مهدی کریمی به شماره دانشجویی ۳۱۱۵۳۱۱۵ دانشجوی رشته مهندسی مکانیک مقطع تحصیلی کارشناسی ارشد تأیید می‌نمایم که کلیه‌ی نتایج این پایان‌نامه/رساله حاصل کار اینجانب و بدون هرگونه دخل و تصرف است و موارد نسخه‌برداری‌شده از آثار دیگران را با ذکر کامل مشخصات منبع ذکر کرده‌ام. در صورت اثبات خلاف مندرجات فوق، به تشخیص دانشگاه مطابق با ضوابط و مقررات حاکم (قانون حمایت از حقوق مؤلفان و مصنفان و قانون ترجمه و تکثیر کتب و نشریات و آثار صوتی، ضوابط و مقررات آموزشی، پژوهشی و انضباطی ...) با اینجانب رفتار خواهد شد و حق هرگونه اعتراض درخصوص احقاق حقوق مکتسب و تشخیص و تعیین تخلف و مجازات را از خویش سلب می‌نمایم. در ضمن، مسئولیت هرگونه پاسخگویی به اشخاص اعم از حقیقی و حقوقی و مراجع ذی‌صلاح (اعم از اداری و قضایی) به عهده‌ی اینجانب خواهد بود و دانشگاه هیچ‌گونه مسئولیتی در این خصوص نخواهد داشت.

نام و نام خانوادگی: محمد مهدی کریمی

امضا و تاریخ:

## مجوز بهره‌برداری از پایان‌نامه

بهره‌برداری از این پایان‌نامه در چهارچوب مقررات کتابخانه و با توجه به محدودیتی که توسط استاد راهنما به شرح زیر تعیین می‌شود، بلامانع است:

- بهره‌برداری از این پایان‌نامه/ رساله برای همگان بلامانع است.
- بهره‌برداری از این پایان‌نامه/ رساله با اخذ مجوز از استاد راهنما، بلامانع است.
- بهره‌برداری از این پایان‌نامه/ رساله تا تاریخ ..... ممنوع است.

نام استاد یا اساتید راهنما:

دکتر یاسی و دکتر حیدر مداح

تاریخ:

امضا:

## چکیده:

نانوسیالات، سیالات جدیدی هستند که با پراکنش ذرات نانو مقیاس در سیالات متعارف بدست می آیند. گزارش شده است که نانوسیالات پتانسیل زیادی در محدوده گسترده ای از کاربردهای صنعتی دارند. به طور خاص ، نانوسیالات بهترین خنک کننده برای جایگزینی سیالات مرسوم انتقال حرارت هستند. تعیین هدایت حرارتی و ویسکوزیته به صورت آزمایشگاهی، وقت گیر، پر زحمت و پرهزینه است و موجب محدودیت استفاده از نانوسیالات در کاربردهای آبی و به موقع می شود. این تحقیق، آخرین تحقیقات انجام شده در مورد تعیین خواص ترموفیزیکی (حرارتی فیزیکی) نانوسیالات مختلف با استفاده از محاسبات نرم افزاری و تکنیک های هوشمند را خلاصه کرده است و فرصت هایی را برای تحقیقات آینده پیش رو قرار می گذارد و باعث کاهش تلاش برای توسعه آزمون های آزمایشگاهی و تعداد فرضیه ها می شود.

**کلمات کلیدی:** هیدروکربن؛ نانوسیالات ، هدایت حرارتی ، ویسکوزیته ، ابزار محاسبات نرم افزاری

## فهرست مطالب

صفحه	عنوان
۱	فصل اول کلیات تحقیق
۲	۱-۱- مقدمه
۲	۱-۲- روش‌های عمل‌آوری شیمیایی
۳	۱-۲-۱- افزودن سورفکتانت
۵	۱-۲-۲- عامل دار کردن سطحی
۶	۱-۲-۳- کنترل pH
۶	۱-۳- روش‌های عمل‌آوری فیزیکی
۶	۱-۳-۱- التراسونیک کردن
۸	۱-۳-۲- هموژن سازی
۹	۱-۴- نرم افزار محاسباتی:
۹	۱-۵- ابزار گردآوری اطلاعات:
۹	۱-۶- روش تحقیق و مراحل پایان نامه:
۱۱	فصل دوم پیشینه تحقیق
۱۲	۲-۱- مقدمه
۱۲	۲-۲- اصول انتقال حرارت جا به جایی
۱۳	۲-۳- توسعه نانوسیالات
۱۴	۲-۳-۱- تکنیک های محاسبات نرم در نانوسیالات
۲۱	فصل سوم شرح کار و روش آزمایش
۲۲	مقدمه:
۲۲	۳-۱- اندازه گیری خواص ترموفیزیکی
۲۳	۳-۲- تشریح سیستم آزمایشگاهی

۲۳	۳-۳- معادلات به کار رفته در آزمایش
۲۵	۳-۴- آنالیز داده های حاصل از ضریب هدایت حرارتی
۲۶	۳-۵- نتایج و بحث
۲۶	۳-۵-۱- مورد آب مقطر
۲۹	۳-۵-۲- تاثیر روی عدد ناسلت
۳۲	فصل چهارم مدل سازی و بررسی نتایج
۳۳	۴-۱- مقدمه
۳۳	۴-۲- بانک اطلاعاتی
۳۴	۴-۳- روش کار
۳۶	۴-۳-۱- ارائه مدل با استفاده از شبکه عصبی
۳۸	۴-۴- نتایج مدل سازی عدد ناسلت به کمک شبکه عصبی
۳۹	۴-۴-۱- نتایج پیش بینی مدل برای کل داده ها
۴۰	۴-۴-۲- نمودار رگرسیون برای عدد ناسلت
۴۲	۴-۴-۳- نمودار مقایسه ای و هیستوگرام خطا
۴۴	۴-۴-۴- نمودار همگرایی در روند آموزش
۴۶	۴-۵- نتیجه گیری:
۴۷	۴-۶- پیشنهادات:
۴۹	مراجع:
۵۱	اختصارات

## فهرست اشکال

عنوان	صفحه
شکل ۱.۱. نمونه ای از ساختار سورفکتانت: دودسیل سولفات سدیم (SDS)	۴
شکل ۱.۲. توصیف شکل میسل سورفکتانت	۴
شکل ۱.۳. اصلاح سطح CNT با پیوند کووالانسی	۵
شکل ۱.۴. شماتیک کاوش فراصوتی	۷
شکل ۱.۵. توصیف شماتیک همگن ساز برشی بالا	۸
شکل ۳.۱. دستگاه مربوط به انجام آزمایشات	۲۳
شکل (۱-۴) مراحل بهینه سازی تابع هدف	۳۵
شکل (۲-۴) متغیرهای ورودی و خروجی مدلسازی به کمک شبکه عصبی	۳۷
شکل (۳-۴) ساختار شبکه عصبی جهت پیش بینی عدد ناسلت	۳۸
مقایسه نتایج مدل و شبکه برای عدد ناسلت	۴۰
شکل (۴-۴) درصد خطای بی بعد شده مدلسازی به کمک شبکه عصبی	۴۰
شکل (۵-۴) نمودار رگرسیون داده مدل و داده واقعی	۴۱
شکل (۶-۴) نمودار مقایسه های داده های مدل و داده تجربی برای دسته ی آموزش	۴۲
شکل (۷-۴) نمودار خطا داده های دسته صحنه سنجی	۴۳
شکل (۸-۴) نمودار میزان انحراف خطا	۴۴
شکل (۹-۴) نمودار مقایسه های داده های مدل و داده تجربی برای دسته تست	۴۵



## فهرست نمودار

عنوان	صفحه
نمودار ۳-۲. تاثیر رینولدز بر ضریب انتقال حرارت جابه جایی	۲۷
نمودار ۳-۳. (الف) نتایج آزمایش تاثیرات عدد رینولدز و غلظت بر ضریب انتقال حرارت جابجایی	۲۸
نمودار ۳-۳. (ب) نتایج آزمایش تاثیرات عدد رینولدز و غلظت بر ضریب انتقال حرارت جابجایی.	۲۸
نمودار ۳-۴. (الف و ب) نتایج آزمایشی تغییرات همزمان غلظت و عدد رینولدز بر عدد ناسلت	۳۰
نمودار ۳-۴ - تغییرات عدد ناسلت با تغییرات عدد رینولدز	۳۱

## فهرست جداول

صفحه	عنوان
۲۶	جدول ۱-۳. بررسی تاثیر دما بر ضریب هدایت حرارتی و ویسکوزیته
۳۴	جدول (۱-۴) جدول داده های ورودی و خروجی مدل شبکه عصبی به همراه بازه تغییرات آن
۳۴	جدول (۲-۴) تقسیم بندی کل داده های آزمایشگاهی جهت ایجاد مدل شبکه عصبی
۳۶	جدول (۳-۴) شاخص های آماری مورد استفاده
۳۸	جدول (۴-۴) شاخص های آماری بدست آمده از مدل

# **فصل اول**

## **کلیات تحقیق**

## ۱-۱- مقدمه

این واقعیت شناخته شده است که مواد جامد دارای درجه انتقال حرارت جابه جایی بالاتر از درجه حرارت در دمای اتاق نسبت به مایعات هستند. انتقال حرارت جابه جایی مس ۷۰۰ برابر بیشتر از آب در دمای اتاق است. بنابراین به خوبی درک شده است که با پراکندگی این ذرات جامد در هدایت حرارتی سیال می توان انتظار داشت به میزان قابل توجهی افزایش یابد. علاوه بر این در مقایسه با ذرات میکروزیائیده، نانوذرات دارای سطح بسیار بزرگتری هستند. جیره بندی سطح به حجم بسیار بالاتر است بنابراین باعث افزایش هدایت حرارتی در مقیاس بسیار بالاتر می شود.

### اهداف:

با توجه به کاربرد فراوان مبدل های حرارتی، ارائه روشی جهت کاهش اتلاف آن ها ضروری می باشد.

کاهش اتلاف مبدل حرارتی با بکار بردن نانو سیال هیبریدی

## ۱-۲- روش های عمل آوری شیمیایی

پایداری<sup>۱</sup> نانوسیال ها به طبیعت مایع پایه و نانوذرات مورد استفاده، بستگی دارد. برای مثال، نانوذرات اکسیدی دارای طبیعت آب دوست هستند در حالی که نانوتیوب های کربنی (CNTs) آب گریز هستند. علاوه بر این، آب به عنوان یک مایع پایه، قطبی است در حالی که روغن یک ماده ی غیر قطبی است. بنابراین، افزودن سورفکتانت یا اصلاح کننده ی سطح ذرات می تواند موجب بهبود خاصیت پراکندگی

---

<sup>1</sup> Stability

نانوذرات در داخل سیال پایه شود. مثلاً این مسئله مشاهده می‌شود که با استفاده از این مواد، می‌توان CNTها را در داخل آب و یا نانوذرات اکسیدی را در داخل روغن پراکنده ساخت.

سورفکتانت در واقع عوامل فعال سطحی هستند که به عنوان یک پل میان نانوذره و سیال پایه عمل می‌کنند و بدین صورت از آگلومره شدن<sup>۱</sup> ذرات جلوگیری می‌کنند. یکی دیگر از روش‌های پایدارسازی شیمیایی دیگر، اصلاح سطحی است که در حقیقت پیش از پراکنده سازی نانوذرات در داخل سیال پایه، بر روی سطح نانوذرات انجام می‌شود. افزودن اسیدها یا بازها می‌تواند pH را در خارج از گستره‌ی pH مربوط به نقطه‌ی ایزوالکتریک (IEP) قرار دهد و بدین صورت پایداری سوسپانسیون کلوئیدی بهبود می‌یابد. این روش‌ها به صورت خلاصه در بخش‌های زیر مورد بررسی قرار می‌گیرد [۱].

## ۱-۲-۱- افزودن سورفکتانت

سورفکتانت یکی از محصولات فراگیر مورد استفاده در صنعت شیمیایی، شوینده، داروسازی، گل مورد استفاده در حفاری، فرایند فلوتاسیون و ... می‌باشد. این ماده به صورت گسترده در تولید نانوسیال‌های با خاصیت پراکنده سازی خوب، استفاده می‌شود. سورفکتانت‌ها می‌توانند به عنوان مواد محلول در روغن و مواد محلول در آب مورد استفاده قرار گیرند. بنابراین، نوع سورفکتانت می‌تواند بر اساس نوع سیال پایه، انتخاب شود. سورفکتانت‌ها می‌توانند آنیونی (دارای بار منفی)، کاتیونی (دارای بار مثبت)، غیر آنیونی (خنثی) یا آمفوتر (هم دارای بار منفی و هم مثبت) باشند. در حقیقت این طبقه بندی بر اساس بار ایجاد شده در سرگروه‌های عاملی این مواد، انجام شده است. در اصل، بار سطحی نانوذرات و نوع سیال پایه‌ی مورد استفاده، این مسئله را تعیین می‌کند که چه سورفکتانتی مورد استفاده قرار گیرد. چندین سورفکتانت متداول در تحقیقات نانوسیال عبارتند از: سدیم دو دسیل سولفونات سدیم دو دسیل بنزن سولفونات


<sup>1</sup> aggregation

،ستیلتری متیل آمونیوم برومید ، دو دسیل تری متیل آمونیوم برومید ، صمغ عربی و پلی وینیل پیرولیدین. یک مثال از ساختار شیمیایی سورفکتانت‌ها در شکل ۱ نشان داده شده است.



شکل ۱.۱. نمونه ای از ساختار سورفکتانت: دودسیل سولفات سدیم (SDS)

عبارت غلظت بحرانی میسل<sup>۱</sup> (CMC) در حقیقت غلظتی است که در بالا آن سورفکتانت تشکیل میسل می‌دهد و تمام سورفکتانت‌های اضافی به میسل تبدیل می‌شوند (شکل ۲) [۲].




شکل ۱.۲. توصیف شکل میسل سورفکتانت

<sup>1</sup> Critical Micelle Concentration

بنابراین، در طی افزودن سورفکتانت‌ها به سیستم‌های نانوسیال، با کاهش غلظت سورفکتانت به کمتر از غلظت CMC، از تشکیل میسل‌ها جلوگیری می‌شود. این مسئله باید در نظر گرفته شود که استفاده از سورفکتانت ممکن است استفاده از نانوسیال در دماهای بالا را با مشکل روبرو کند. وقتی دما بالاتر از ۶۰ درجه‌ی سانتی‌گراد باشد، سورفکتانت‌ها به صورت کلی تخریب می‌شود [۲]. این مسئله به طور قابل توجهی، استفاده از این مواد در کاربردهای انتقال حرارت دما بالا و متوسط را محدود می‌کند.

## ۲-۱-۲- عامل دار کردن<sup>۱</sup> سطحی

در این روش، سطوح نانوذرات یا نانوتیوب‌ها قبل از پراکنده شدن در داخل سیال پایه، عامل دار می‌شود. یک مثال نمونه وار از اصلاح کننده‌های سطحی عامل دار کردن CNTs با استفاده از عمل‌آوری اسیدی (شکل ۳) می‌باشد. عامل دار کردن در حقیقت ایجاد مکان‌های فعال الکتروشیمیایی بر روی سطوح CNTها است که موجب بهبود پراکنده سازی این مواد در آب می‌شود.



شکل ۱.۳. اصلاح سطح CNT با پیوند کووالانسی

<sup>1</sup> Functionalization

### ۳-۲-۱- کنترل pH

دستکاری پتانسیل زتا یک روش برای افزایش پایداری پراکنده سازی کلوئیدی است. نانوذرات در زمانی پایداری بیشتری دارند که pH محلول در خارج از نقطه‌ی ایزوالکتریکی (IEP) قرار دارد. در این گستره، بار سطحی ذرات و مقادیر پتانسیل زتا صفر است. به هر حال، pH مربوط به سوسپانسیون معمولاً باید در حوالی pH خنثی نگهداری شود زیرا محلول‌های قلیایی و اسیدی ممکن است منجر به خوردگی سطوح انتقال حرارت و ته نشینی نانوذرات شوند [۳].

### ۳-۱- روش‌های عمل‌آوری فیزیکی<sup>۱</sup>

در این روش، یک میزان انرژی بالا از طریق التراسونیک به نانوسیال وارد می‌شود. هموژن سازی یا بال میل کردن موجب شکسته شدن خوشه‌های نانوذره‌ای و تشکیل یک سوسپانسیون کلوئیدی پایدار می‌شود. معمولاً سورفکتانت‌ها سپس به منظور جلوگیری از آگلومره شدن نانوذرات استفاده می‌شوند.


#### ۱-۳-۱- التراسونیک کردن

حمام‌ها یا پروب‌های التراسونیک (شکل ۴) معمولاً برای پراکنده سازی فیزیکی خوشه‌های نانوذره‌ای<sup>۲</sup> استفاده می‌شوند. پروب‌های التراسونیک متداولترین روش پایداری سازی در بین روش‌های عمل‌آوری فیزیکی است.

<sup>1</sup> Physical Treatment

<sup>2</sup> nanoparticle clusters






شکل ۱.۴. شماتیک کاوش فراصوتی

انرژی صوت در یک سطح التراسونیک 20 kHz و بالاتر، برای یک دوره‌ی زمانی از پیش تعیین شده مورد استفاده قرار می‌گیرد و بدین صورت خوشه‌های نانوذره‌ای شکسته می‌شود و نانوذرات در داخل سیال پایه پراکنده می‌شوند. محققین از سطوح فرکانس و توان مختلف التراسونیک در بازه‌های زمانی مختلف استفاده می‌کنند. شرایط بهینه‌ی اعمال فرایند التراسونیک ممکن است با پارامترهای مختلف، تغییر کند. این پارامترها، عبارتند از: غلظت نانوذره، اندازه‌ی نانوذره، نوع ذره، نوع سیال پایه و ... با افزایش زمان التراسونیک، یک پراکنده‌ی کلونیدی بهتر و یک ویسکوزیته‌ی پایین‌تر حاصل می‌شود. نانوسیال‌های CuO بر پایه‌ی اتیلن گلیکول که با استفاده از ژنراتور التراسونیک (20 kHz, 100 W) تولید شده‌اند، برای دوره‌ی زمانی ۱ تا ۳۰ ساعت، پایدار هستند. زمان التراسونیک بهینه برای نانوسیال CuOEG در شرایط گفته شده، برابر ۹ ساعت است [۴].

## ۲-۳-۱- هموژن سازی<sup>۱</sup>

هموژن سازهای با انرژی برشی بالا (شکل ۵) برای شکستن خوشه‌های نانوذره‌ای در سوسپانسیون‌های کلوئیدی مناسب می‌باشند. در تحقیقی [۳۴] از روش‌های مختلف از جمله هم زدن، استفاده از حمام التراسونیک، پراکنده سازهای التراسونیک و هموژن سازهای با فشار بالا برای پایدارسازی نمونه‌های نانوسیال، استفاده کردند. آنها اندازه‌ی کلوئیدها را به منظور بررسی آگلومره شدن ذرات در سوسپانسیون‌ها، مورد بررسی قرار دادند. آنها پیشنهاد کردند که هموژن سازهای فشار بالا یک ابزار مؤثر برای شکستن آگلومره‌های نانوذره‌ای می‌باشد. همچنین از هموژن سازی فشار بالا برای پایدارسازی نانوتیوب‌های کربنی تک جداره<sup>۲</sup> و نانوذرات اکسید تیتانیوم در سوسپانسیون‌ها، استفاده کردند. این فهمیده شد که روش اعمال شده برای پراکنده سازی نانوذرات در داخل سیال‌های پایه، مفید می‌باشد [۵].



شکل ۵.۱. توصیف شماتیک همگن ساز برشی بالا

<sup>1</sup> Homogenization

<sup>2</sup> SWCNH

## ۴-۱- نرم افزار محاسباتی:

بردارهای پشتیبان مدل های محاسباتی هستند که قادرند رابطه میان ورودی ها و خروجی های یک سیستم فیزیکی را کشف و استخراج کنند. در طی مرحله آموزش خطای ریسک پیش بینی بصورت تدریجی کاهش می یابد.

در بسیاری از کاربردها برای تحلیل و بررسی یک سیستم، ابتدا رفتار آن سیستم را بر اساس اطلاعاتی که از سیستم داریم، مدل می کنیم و سپس از آن مدل برای تشخیص رفتارهای آتی آن سیستم استفاده خواهیم کرد. این فرآیند در واقع همان فرآیندی است که در مهندسی معکوس انجام می شود.

در اینجا تمرکز ما بر روی سیستمهای نرم افزاری است. هدف ما این است که رفتارهای یک نرم افزار را مدل کنیم و سپس از این مدل برای تحلیل رفتارهای ناشناخته آن نرم افزار استفاده کنیم. برای مدلسازی رفتار یک نرم افزار می توانیم از روشهای مختلفی مانند زنجیره های مارکوف، گرافها و تئوری گرافها، روشهای خوشه بندی و روشهای طبقه بندی استفاده کنیم. در این گزارش ما یکی از روشهای مدلسازی رفتار نرم افزار مبتنی بر روش طبقه بندی با استفاده از تکنیک ماشینهای بردار پشتیبان را شرح می دهیم.

## ۵-۱- ابزار گردآوری اطلاعات:

بهره گیری از اینترنت جهت جمع آوری آخرین نتایج انجام شده و استفاده از کتابخانه دانشگاه تهران

دستگاه اندازه گیر ضریب هدایت حرارتی، دستگاه ویسکوزیته سنج، SEM، TEM

## ۶-۱- روش تحقیق و مراحل پایان نامه:

ابتدا دادهای مدل را استخراج نموده و سپس وارد نرم افزار اکسل میکنیم و با استفاده از نرم افزار متلب به ارائه مدل میپردازیم. مدل های داده محور مانند بردارهای پشتیبان بر اساس شرایط ورودی و خروجی

سیستم‌ها یا به نوعی شرایط اولیه و نهایی، به تخمین متغیر وابسته می پردازند. در این پژوهش متغیرهای Temp ، Concentration، Re پارامتر ورودی بردارهای پشتیبان ماشین هستند و ضرایب انتقال حرارت به عنوان خروجی محسوب میگردد. که بعد از انجام محاسبات و رسم نمودارهای مربوطه به بررسی و تحلیل یک یک آنها میپردازیم. روش تجزیه و تحلیل از مقایسه داده های حاصل با داده های سایر گزارشهای ارائه شده در این زمینه و مقایسه دادههای آزمایشگاهی با یکدیگر در شرایط مختلف خواهد بود.

## **فصل دوم**

### **پیشینه تحقیق**

## ۱-۲- مقدمه

با معرفی انتقال حرارت تک - فاز و جریان ذره ای و انتقال حرارت، ما اکنون در پی بررسی خواص ترموفیزیکی و ضرایب انتقال حرارت مربوطه در نانوسیالات هستیم. اگر چه تعدادی از مطالعات در دسترس در این ناحیه محدود شده اند در مقایسه با ناحیه رسانایی حرارتی نانوسیالات، نظریه ها و روش هایی که در مطالعات جا به جایی استفاده شده است کاملاً واگرا هستند و از اینرو نیازمند بررسی دقیق هستند. انتقال حرارت جا به جایی تا حد زیادی در ارتباط با ویسکوزیته سوسپانسیون ها است، و از اینرو در تعداد زیادی از این مطالعات تغییرات ویسکوزیته بیشتر از جا به جایی مطرح شده بحث شده است. در اینجا ما همچنین ابتدا طبیعت تغییرات ویسکوزیته نانوسیالات را بررسی می کنیم. سپس، ما به داده های تجربی نگاه می کنیم، که توسط روش های مختلفی برای تحلیل پدیده های برجسته به کارهای عددی و نرم افزاری بر روی جا به جایی در نانوسیالات می پردازیم. بحث در فصل های اخیر حقایق فریبنده درباره ساختار، ترکیب، و رسانایی حرارتی نانوسیالات نشان میدهد. علاقه اولیه در نانو سیالات از یک دیدگاه فنی امکان استفاده از این سیالات برای اهداف سرمایه‌گذاری است. اگر چه رسانایی بالاتر یک اتفاق دلگرم کننده است، به هیچ وجه مدرک قطعی از توانایی های سرمایه‌گذاری چنین سیالاتی نیست. برای این منظور، لازم است که یک تایید معین از عملکرد چنین سیالی تحت یک محیط جا به جایی داشته باشیم. آن نه تنها برای نشان دادن رفتار جا به جایی نانوسیالات مهم است بلکه همچنین تئوری های جامع دینامیک سیالات و انتقال حرارت نانوسیالات را ارائه می دهد. در حال حاضر، مطالعات جابه جایی نانوسیالات در مقایسه با مطالعات تجربی و تئوری بر روی رسانش خیلی محدود است. در این فصل ما مفاهیم محدود شده انتقال حرارت جا به جایی در نانو سیالات را که در سال های اخیر توسعه داده شده است را ارائه می دهیم. قبل از انجام این کار، تشریح تعدادی مفاهیم پایه ای انتقال حرارت جابه جایی به ویژه برای خوانندگان میان رشته ای که مطالعات دقیق انجام شده از انتقال حرارت جا به جایی ندارند، مهم است.

## ۲-۲- اصول انتقال حرارت جا به جایی

جا به جایی یک نوع انتقال حرارت است که انتقال حرارت از یک دیوار جامد به توسط یک سیال جاری در همسایگی دیوار تحت تاثیر قرار می گیرد. انتقال حرارت همچنین می تواند در جهت مخالف باشد (یعنی، از سیال به دیوار). جا به جایی به طور گسترده به دو نوع تقسیم می شود: جابه جایی واداشته و جابه جایی

آزاد (یا طبیعی). هنگامی که سیال توسط عوامل خارجی نظیر یک پمپ، فن، کمپرسور، یا دمنده بر روی سطح اتلاف حرارتی (یا پذیرنده حرارت) "وادر به جاری شدن می شود"، جا به جایی، جا به جایی اجباری نامیده می شود. زمانی که جریان توسط نیروی شناوری در طول گرمایش یا سرمایش یک سیال ایجاد می شود، آن جا به جایی، جا به جایی آزاد یا طبیعی نامیده می شود. در حال گرمایش یک سیال در یک ظرف روی اجاق، ما حرکت سیال را قبل از اینکه شروع به جوشیدن کند می بینیم.

قانون اساسی جا به جایی توسط نیوتن حتی قبل از اینکه قانون رسانش فوری پیشنهاد شده بود ادعا شده بود. این قانون، قانون سرمایش نیوتن نامیده می شود. این اصل قانون سرمایشی نیوتن را می دهد، که به سادگی بیان می کند که فلاکس حرارت جا به جایی با اختلاف دمای بین دیوار و سیال متناسب است.  $h$  تنها ثابت تناسب است که ضریب انتقال حرارت نامیده می شود، با واحد  $W/m^2 \cdot K$  در سیستم SI. باید توجه شود که برخلاف رسانایی حرارتی، که یک خاصیت مادی است،  $h$  یک ثابت نیست. در مقابل،  $h$  به تعدادی فاکتور بستگی دارد، نظیر سیال و خواصش، هندسه جریان، رژیم جریان (آرام یا درهم)، سرعت جریان و شرط مرزی حرارتی در دیوار است.

### ۳-۲- توسعه نانوسیالات

محدودیت‌های خواص ترموفیزیکی، به ویژه هدایت حرارتی سیالات مرسوم انتقال حرارت و شرایط برای برطرف کردن سرمایش مورد نیاز به منظور توسعه فن آوری برای کوچک سازی سیستم های الکترونیکی، الکتریکی و حرارتی، زمینه ای برای توسعه نانوسیالات با انتقال حرارت زیاد هستند. با توجه به این دیدگاه، چوی<sup>۱</sup> (۱۹۹۵) در آزمایشگاه ملی آرگون ایالات متحده<sup>۲</sup> به طور آزمایشگاهی نانوسیالاتی را با پراکنش ذرات نانو مقیاس، در محدوده ۱۰۰-۱ نانومتر، به سیالات پایه مرسوم توسعه داده است. چوی و ایستمن<sup>۳</sup> [۱] نشان دادند که پراکنش نانوذرات جامد باعث بهبود هدایت حرارتی و ویسکوزیته نسبت به سیالات پایه می شود. همچنین داس<sup>۴</sup> و همکاران [۲] گزارش کردند که هدایت حرارتی نانوسیالات  $Al_2O_3$  (اکسید آلومینیوم) در محدوده دمای ۵۱-۲۱ درجه سانتیگراد با روش آزمایشگاهی تا ۴-۲ برابر، افزایش می یابد. در ادامه کارهای تحقیقاتی در زمینه نانوسیالات، بسیاری از محققان مدل های ریاضی و آزمایشگاهی را

<sup>1</sup> Choi

<sup>2</sup> Argonne National laboratory USA

<sup>3</sup> Eastman

<sup>4</sup> Das

برای پیش بینی خواص ترموفیزیکی توسعه دادند. اکثر آنها پیشنهاد کردند که سه تفاوت بین نتایج ریاضی و آزمایشگاهی خواص ترموفیزیکی نانوسیالات وجود دارد. هدایت حرارتی و ویسکوزیته نقش اصلی کاربردهای انتقال حرارت را ایفا می کند. بنابراین آنها توسط بسیاری از محققان به صورت آزمایشگاهی، ریاضی و محاسباتی مورد بررسی قرار گرفته اند.

لی<sup>۱</sup> و همکاران [۳] این آزمایش را با نانوذرات CuO (اکسید مس) به عنوان مواد پایه و اتیلن گلیکول به عنوان سیال پایه انجام داد. آنها دریافتند که نانوسیالات اکسید مس/ آب افزایش ۲۰٪ در هدایت حرارتی را نشان داد و افزایش هدایت حرارتی با افزایش کسر حجمی ذرات صورت گرفت. بررسی های انجام شده بر روی نانوسیالات توسط بسیاری از محققان پیشنهاد می دهد که افزایش خواص ترموفیزیکی نانوسیالات مانند هدایت حرارتی، ویسکوزیته، چگالی و گرمای ویژه به عوامل زیادی مانند اندازه ذرات، شکل، سیال پایه، مقدار pH، دما، کسر حجمی، مواد پایه ذرات، هدایت حرارتی مواد پایه و روش ساخت نانوذرات بستگی دارد (کانگ<sup>۲</sup> و همکاران [۴]، لیو<sup>۳</sup> و همکاران [۵]، موشد<sup>۴</sup> [۶]، واجها<sup>۵</sup> و داس [۷]، لیو و همکاران [۸]، مهتا<sup>۶</sup> و همکاران [۹]، و پیراحمدیان<sup>۷</sup> و ابراهیمی<sup>۸</sup> [۱۰]). آنها همچنین گزارش کردند که پیش بینی هدایت حرارتی و ویسکوزیته یک چالش فنی است و در تعیین آنها از نظر آزمایشگاهی و ریاضی اختلاف وجود دارد. توسعه مدل های نظری از دیگر راه حل های محدودیت های مطالعه خواص ترموفیزیکی نانوسیالات مانند هدایت حرارتی و ویسکوزیته است. براساس مرور مطالعات انجام شده، بررسی شده است که بیشتر مدل های کلاسیک و تجربی اختلافات زیادی در پیش بینی نتایج با دقت خوب دارند.

### ۱-۳-۲- تکنیک های محاسبات نرم در نانوسیالات

در اینجا تکنیک های هوشمند برای حل مسئله ارائه شده است. تکنیک های هوشمند قادر به پیش بینی دقیق هدایت حرارتی و ویسکوزیته نانوسیالات هستند. شبکه عصبی مصنوعی<sup>۹</sup> (ANN)، الگوریتم ژنتیک<sup>۱۰</sup> (GA) و منطق فازی به طور گسترده ای در پیش بینی هدایت حرارتی و ویسکوزیته نانوسیالات

<sup>1</sup> Lee

<sup>2</sup> Kang

<sup>3</sup> Liu

<sup>4</sup> Mushed

<sup>5</sup> Vajzha

<sup>6</sup> Mehta

<sup>7</sup> Pirahmadian

<sup>8</sup> Ebrahimi

<sup>9</sup> Artificial Neural Network

<sup>10</sup> Genetic algorithm



استفاده می شود. کریمی<sup>۱</sup> و همکاران [۱۱] پیش بینی ویسکوزیته نانوسیالات را با استفاده از مدل GA-ANN بررسی کردند. آنها دما، کسر حجمی نانوذرات، اندازه نانوذرات و خواص ترموفیزیکی سیال پایه را به عنوان پارامترهای پیش بینی ویسکوزیته نانوسیالات در نظر گرفتند. آنها مطرح کردند که مدل GA-NN، بهترین پیش بینی ویسکوزیته نانوسیالات را با دقت بهتر ارائه می دهد. آنها همچنین پیشنهاد کردند که این مدل در مقایسه با مدل های دیگر بسیار ساده است.

صالحی<sup>۲</sup> و همکاران [۱۲] به طور محاسباتی مقادیر هدایت حرارتی و مقاومت حرارتی را با محاسبات نرم ابزارهای شبکه عصبی ادراک چند لایه تحلیل کرده و آنها را با داده های آزمایشگاهی مقایسه کردند. آنها گزارش دادند که تخمین هدایت حرارتی و مقاومت حرارتی نانوسیالات بسیار دقیقتر از روشهای مرسوم است. تاجیک<sup>۳</sup> و زم<sup>۴</sup> [۱۳] به کمک روشهای بهینه سازی غیرخطی و شبکه عصبی مصنوعی، تأثیر پارامترهای وابسته مختلفی از قبیل کسر حجمی ذرات، اندازه ذرات، شکل و درجه حرارت را بر هدایت حرارتی نانوسیالات بهینه کردند. آنها دقت بهینه سازی هدایت حرارتی نانوسیالات را با روش گرادیان کاهش یافته تعمیم یافته و شبکه های عصبی مصنوعی مقایسه کردند. آنها پیشنهاد کردند که شبکه عصبی مصنوعی دقت بیشتری نسبت به گرادیان کاهش یافته تعمیم یافته دارد. علی صدالله<sup>۵</sup> و همکاران [۱۴] نقش پارامترهای مختلف را در پایداری نانوسیالات با روش سطح پاسخ بررسی کردند و آن را با شبکه عصبی مصنوعی آموزش دیده پیش بینی کردند. آنها شبکه عصبی مصنوعی، که نتایج دقیقتری نسبت به RSM از جنبه درصد خطا می دهد، را ارائه دادند و رگرسیون خطی بین نتایج شبکه و نتایج آزمایشگاهی را مشاهده کردند.

حجت<sup>۶</sup> و همکاران [۱۵] به طور آزمایشگاهی سه نانوسیال اکسید آلومینیوم، اکسید تیتانیوم و اکسید مس / کربوکسیمتیل سلولز<sup>۷</sup> (CMC) را به مقدار ۰/۵ درصد وزنی تهیه کردند و با تغییر دما، هدایت حرارتی را اندازه گیری کردند. آنها مدلهای شبکه عصبی را برای پیش بینی هدایت حرارتی با تغییر دما، غلظت نانوذرات و هدایت حرارتی نانوذرات توسعه دادند. آنها گزارش دادند که مدل توسعه یافته با نتایج آزمایشگاهی نانوسیال ها مطابقت خوبی دارد. آنها پیشنهاد کردند که مدل مرسوم همیلتون-کراسر<sup>۸</sup> برای

<sup>1</sup> Karimi<sup>2</sup> Salehi<sup>3</sup> Tajik<sup>4</sup> Zam<sup>5</sup> Ali sadollah<sup>6</sup> Hojjat<sup>7</sup> carboxymethyl cellulose<sup>8</sup> Hamilton-Crosser

تعیین هدایت حرارتی، تنها برای غلظت‌های کم نانوذرات، قابل قبول است. ریان<sup>۱</sup> و همکاران [۱۶] یک شبکه عصبی مصنوعی پیشخور دو لایه شامل چهارده ساختار نوروپنهان برای پیش بینی نسبت هدایت حرارتی نانوسیالات پیشنهاد کردند. آنها درجه حرارت، کسر حجمی و قطر نانوذرات را به عنوان پارامترهای کاربردی برای توسعه مدل در نظر گرفتند. آنها مشاهده کردند که قابلیت پیش بینی مدل شبکه عصبی مصنوعی در مقایسه با سایر مدل ها بسیار کارآمد است.

موهانراج<sup>۲</sup> و همکاران [۱۷] کاربرد شبکه عصبی مصنوعی را در آنالیز حرارتی مبدل‌های حرارتی، انجام داد. آنها دریافتند که شبکه عصبی مصنوعی روش جایگزین بینظیری برای ارزیابی آنالیز حرارتی یک مبدل حرارتی است. آذری<sup>۳</sup> و مرحمتی<sup>۴</sup> [۱۸] با استفاده از شبکه عصبی چند جمله‌ای به صورت روش کنترل گروهی داده، مدلی را برای تعیین خواص حرارتی نانوسیالات توسعه دادند. آنها پیشنهاد کردند که مدل آنها با داده های آزمایشگاهی مطابقت خوبی دارد. آنها همچنین پیشنهاد کردند که مدل آنها ارتباط خوبی داشته و خواص حرارتی انواع مختلفی از نانوسیالات را پیش بینی می کند. اسفه<sup>۵</sup> و همکاران [۱۹،۲۰] هدایت حرارتی نانوسیالات ترکیبی ZnO – EG را مدلسازی کردند. نانوسیالات ترکیبی، ترکیبی از دو ماده پایه مختلف در سیالات پایه است. آنها در غلظت‌های حجمی ۰/۰۰۰۶۲۵، ۰/۰۰۱۲۵، ۰/۰۰۰۵، ۰/۰۰۱، ۰/۰۱۵، ۰/۰۲، ۰/۰۳، ۰/۰۴ و ۰/۰۵ و در دمای ۲۴-۵۰ درجه سانتیگراد، از نانوذرات اکسید روی با اندازه ۱۸ نانومتر در اتیلن گلیکول استفاده کردند. آنها برای مدل سازی هدایت حرارتی از شبکه عصبی پرسپترون چند لایه پیشخور استفاده کردند. آنها از ۴۰ داده آزمایشگاهی استفاده کردند که ۲۸ داده را برای آموزش شبکه انتخاب کردند. بقیه ۱۲ داده برای آزمایش و اعتبارسنجی شبکه استفاده کردند. آنها نشان دادند که مدل، به خوبی برای پیش بینی هدایت حرارتی نانوسیالات توسعه داده شده است.

کاویتا<sup>۶</sup> و موکشکومار<sup>۷</sup> [۲۱] مقالات پژوهشی مختلفی را به منظور پیش بینی هدایت حرارتی نانوسیالات با استفاده از تکنیک های هوشمند یا ابزارهای محاسبات نرم با هدف جمع آوری اطلاعات اولیه در مورد کاربردهای ابزارهای محاسبات نرم استفاده شده در پیش بینی هدایت حرارتی نانوسیالات تحت عوامل مختلف وابسته به محدوده گسترده آنها، مورد بررسی قرار دادند. آنها نتیجه گرفتند که تعداد کمی از کارهای

<sup>1</sup> Riana<sup>2</sup> Mohanraj<sup>3</sup> Azari<sup>4</sup> Marhemati<sup>5</sup> Esfe<sup>6</sup> Kavitha<sup>7</sup> Mukeshkumar

تحقیقاتی در مورد کاربرد ابزارهای محاسبات نرم در تعیین هدایت حرارتی و ویکسوزیته نانوسیالات گزارش شده است. آنها همچنین پیشنهاد کردند که بیشترین محاسبات نرم مورد استفاده، شبکه عصبی مصنوعی و الگوریتم ژنتیک با الگوریتم آموزشی مختلف هستند و بیشتر مدلهای با ضریب همبستگی ( $R^2$ )، جذر میانگین مجذور خطا<sup>۱</sup> (RMSE) و میانگین قدر مطلق خطا<sup>۲</sup> (MAE) برای ارزیابی صحت و اعتبار مدل توسعه یافته، ارزیابی شده اند. اسفه و همکاران [۲۲] هدایت حرارتی و ویکسوزیته دینامیکی نانوسیالات را با استفاده از شبکه عصبی مصنوعی تعیین کرد. آنها دریافتند که نتایج همبسته با استفاده از ANN، مطابقت خوبی با داده های آزمایشگاهی دارد.

خسروجریدی<sup>۳</sup> و همکاران [۲۳] هدایت حرارتی نانوسیالات گرافن را با استفاده از شبکه عصبی مصنوعی پرسپترون چند لایه<sup>۴</sup> (MLP) با درصد وزنی ۰/۰۰۰۲۵، ۰/۰۰۰۵، ۰/۰۰۱ و ۰/۰۰۵ و در دمای ۵۰-۲۵ درجه سانتیگراد پیش بینی کرد. آنها از جذر میانگین مجذور خطا (RMSE)، ضریب تعیین ( $R^2$ ) و میانگین قدرمطلق درصد خطا<sup>۵</sup> (MAPE) برای ارزیابی صحت مدل استفاده کردند و دریافتند که دقت آن ۹۹٪ است. آنها نتیجه گرفتند که شاخص ها و پیش بینی ها، دقت و تأیید بالای مدل سازی ANN را در مقایسه با نتایج آزمایشگاهی نشان می دهد و مدل های نظری به نتایج نزدیک هستند. آقاییاری<sup>۶</sup> و همکاران [۲۴] با تغییر دما و کسر حجمی، با استفاده از ابزار محاسبات نرم، شبکه عصبی مصنوعی (ANN) و تأیید آن با داده های آزمایشگاهی، هدایت حرارتی نانوسیالات اکسید آهن ( $Fe_3O_4$ ) را ارزیابی و پیش بینی کردند. آنها از شبکه عصبی مصنوعی پرسپترون دولایه پیشخور و الگوریتم آموزشی لونبرگ-مارکوارت پس انتشار<sup>۷</sup> (BP-LM) استفاده کردند. آنها برای آزمایش اثربخشی ANN از اندازه ذرات ۲۵-۲۰ نانومتر و سه دما ۳۰، ۳۵ و ۴۰ درجه با غلظت حجمی در محدوده ۰/۰۵ تا ۵ درصد، استفاده کردند. آنها مشاهده کردند که هدایت حرارتی نانوسیال  $Fe_3O_4$  بطور خطی با غلظت حجمی و دما، افزایش میابد. آنها نتیجه گرفتند که مدل ANN مطابقت خوبی با داده های آزمایشگاهی دارد و ANN در مقایسه با روش های نظری از دقت و سادگی پیش بینی بهتری برخوردار است.

<sup>1</sup> root mean square error

<sup>2</sup> mean absolute error

<sup>3</sup> Khosrojerdi

<sup>4</sup> multilayer Perceptron

<sup>5</sup> mean absolute percentage error

<sup>6</sup> Aghayari

<sup>7</sup> back propagation Levenberg-Marquardt

وفایی<sup>۱</sup> و همکاران [۲۵] نسبت هدایت حرارتی نانوسیالات ترکیبی MgO – MWCNTs/EG را با یک شبکه عصبی مصنوعی بهینه در کسرهای حجمی جامد ۰/۰۵، ۰/۱، ۰/۱۵، ۰/۲، ۰/۴ و ۰/۶ درصد در محدوده دمای ۵۰-۲۵ درجه سانتی گراد با حضور سی و شش داده آزمایشگاهی، پیش بینی کردند. آنها چهار شبکه عصبی مصنوعی بهینه با ۶، ۸، ۱۰ و ۱۲ نورون در لایه پنهان را طراحی کردند. آنها گزارش دادند که ANN با ۱۲ نورون در لایه پنهان بهترین مدل در بین چهار نتیجه ANN بهینه است که حداکثر حد انحراف آن ۰/۸٪ است. کاویتا و موکشکومار [۲۶] نسبت هدایت حرارتی DWCNT – ZnO/Water – EG را با استفاده از شبکه عصبی پرسپترون چند لایه<sup>۲</sup> (MLP-NN) با تابع آموزشی مختلف در نرم افزار MATLAB نسخه ۲۰۱۳، بررسی کردند. آنها مطالعه کردند که داده های پیش بینی شده، مطابقت خوبی با داده های آزمایشگاهی دارد. آنها گزارش دادند که نتایج پیش بینی شده با مقدار ضریب رگرسیون ( $R^2$ ) ۰/۹۷۳۵۴ که نزدیک به یک است، معتبر است.

ژائو<sup>۳</sup> و لی<sup>۴</sup> [۲۷] هدایت حرارتی و ویسکوزیته نانوسیالات آب/آلومینا را با یک شبکه عصبی مصنوعی (ANN) پیش بینی کردند. آنها نانوسیالات آب/آلومینا را در غلظت ۱/۳۱٪، ۲/۷۲٪، ۴/۲۵٪ و ۵/۹۲٪، با قطر متوسط ۳۰ نانومتر و در محدوده دمای ۳۱۳-۲۹۶ درجه کلوین آماده کردند. آنها شبکه عصبی تابع پایه شعاعی<sup>۵</sup> (RBF) را برای پیش بینی هدایت حرارتی و ویسکوزیته با در نظر گرفتن کسر حجمی و دما به عنوان پارامترهای عملکردی، ایجاد کردند. آنها نتیجه گرفتند که هدایت حرارتی و ویسکوزیته به شدت به غلظت وابسته است و ویسکوزیته وابستگی کمی به دما دارد. آنها همچنین نتیجه گرفتند که شبکه عصبی RBF توانایی بسیار خوبی در تعیین هدایت حرارتی و ویسکوزیته نانوسیالات آب/آلومینا با خطای ۰/۵۶۱۸٪، دارد.

آلاد<sup>۶</sup> و همکاران [۲۸] مدل های رگرسیون بردار پایه<sup>۷</sup> (SVR) را برای پیش بینی افزایش هدایت حرارتی برای نانوسیالات فلزی و اکسید فلزی توسعه دادند. آنها دقت و قابلیت اطمینان مدل توسعه یافته را با ضریب همبستگی ( $R^2$ )، جذر میانگین مجذور خطا (RMSE) و میانگین قدر مطلق خطا (MAE)، ارزیابی کردند و ضریب همبستگی بالای ۰/۹۹/۳ و ۰/۹۶/۳ به ترتیب برای نانوسیالات فلزی و اکسید فلزی، مشخص

<sup>1</sup> Vafaei<sup>2</sup> Multi-Layer Perceptron Neural Network<sup>3</sup> Zhao<sup>4</sup> Li<sup>5</sup> radial basis function<sup>6</sup> Alade<sup>7</sup> support vector regression

کردند. آنها دریافتند که RMSE برای نانوسیالات فلزی و اکسید فلزی به ترتیب ۱/۱۱ و ۱/۳۳ است. علاوه بر این، نتایج مدل‌های توسعه یافته با مدل هدایت حرارتی مرسوم همیلتن-کراسر (HC)، مقایسه شده است. آنها مطالعه کردند که مدل SVR بسیار بهتر از مدل‌های ارائه شده، است. آنها از دما، کسر حجمی، اندازه و نوع نانوذرات و انواع سیالات پایه که فاکتورهای تطبیق با داده‌های آزمایشگاهی هتند، استفاده کردند. آنها نتیجه گرفتند که پیش‌بینی‌های SVR دقیق و بهتر از مدل‌های نظری موجود است.

کاویتا و موکشکومار [۲۹] آنالیز مقایسه‌ای مدل پرسپترون چندلایه (MLP) و مدل رگرسیون بردار پایه (SVR) را با استفاده از معیارهای مختلف ارزیابی کردند. آنها از نانوسیالات CNT/H<sub>2</sub>O (نانولوله‌های کربنی) برای پیش‌بینی هدایت حرارتی، استفاده کردند و از نرم افزار MATLAB نسخه ۲۰۱۷ برای بررسی، استفاده کردند. آنها مقادیر تجربی و مقادیر پیش‌بینی شده که در هر دو مدل مطابقت خوبی داشتند، ارائه دادند. آنها دریافتند که مقدار ضریب رگرسیون ( $R^2$ ) برای کلیه داده‌ها برای مدل‌های MLP و SVR به ترتیب ۰/۹۹ و ۰/۹۸ است. آنها گزارش دادند که مقدار جذر میانگین مجذور خطا (RMSE) در مدل MLP در مقایسه با مدل SVR، که به ترتیب ۰/۰۱۵۷۸ و ۰/۰۱۸۱۲ هستند، کمتر است. آنها به این نتیجه رسیدند که پیش‌بینی در مدل MLP با مجموعه داده‌های آزمایشگاهی محدود بهتر است و نمی‌توان به حل مسئله بیش‌برازش (قرار دادن تعداد بیش از اندازه متغیر مستقل در رگرسیون) پرداخت. به هر حال، مدل SVR با مجموعه داده محدود ایده‌آل است. کاویتا و موکشکومار [۳۰] با استفاده از روش توسعه GPR با پارامترهای دما و کسر حجمی، که متغیرهای مستقل/پیش‌بین هستند، نسبت هدایت حرارتی نانوسیالات CNT/H<sub>2</sub>O را پیش‌بینی کردند. آنها پیشنهاد کردند که با افزایش دما و غلظت، نسبت هدایت حرارتی، افزایش می‌یابد. آنها مشاهده کردند که بین مقادیر آزمایشگاهی و مقادیر پیش‌بینی شده، مطابقت خوبی وجود دارد.

آنها دریافتند که مقادیر RMSE تابع مجذور کوواریانس نمایی با پارامتر بیش از حد، ۰/۰۱۴۹۲۶ و ضریب رگرسیون ( $R^2$ ) برای کلیه داده‌ها، ۰/۹۸ است. آنها نتیجه گرفتند که داده‌های پیش‌بینی شده مطابقت خوبی با داده‌های آزمایشگاهی نسبت هدایت حرارتی، دارند. مداح<sup>۱</sup> و همکاران [۳۱] برای یافتن ویسکوزیته نسبی نانوسیالات برپایه روغن موتور با ویسکوزیته چند نقطه‌ای/نانولوله کربن، با تغییر دما و غلظت حجمی ۰/۱٪، ۰/۳٪، ۰/۵٪، ۰/۸٪ و ۱٪، مدل ANN را توسعه دادند. آنها از نانوسیالات در دمای ۵۰-۲۵ درجه سانتی گراد استفاده کردند. آنها برای توسعه این شبکه از شبکه عصبی پرسپترون دو

<sup>1</sup> Maddah

لایه با ۲۵ نرون استفاده کردند. یافته شده است که شبکه عصبی پرسپترون دو لایه با مقادیر جذر میانگین مجذور خطا، ضریب همبستگی و انحراف معیار که به ترتیب  $2.01e-008$ ، ۱ و  $0.000210$  هستند، بهترین نتیجه را می دهد. آنها نتیجه گرفتند که مدل پیشنهادی توانایی پیش بینی دقیق ویسکوزیته نسبی را دارد.

علاوه بر این ، از بررسی و مرور مطالعات قبلی انجام شده می توان فهمید که کارهای تحقیقاتی منتشر شده سال به سال، با ابزارهای مختلف محاسبات نرم جهت ارزیابی هدایت حرارتی و ویسکوزیته نانوسیالات با نانو مواد مختلف و سیالات پایه، در حال افزایش است. با این حال ، استفاده از ابزارهای محاسبات نرم در نانوسیالات هنوز در ابتدای حرکت خود است. امید است که این مقاله مروری، بتواند در توسعه مدل های جدید جهت ارزیابی حرارت و ویسکوزیته نانوسیالات کمک کند.

## **فصل سوم**

### **شرح کار و روش آزمایش**

## مقدمه:

در این تحقیق به بررسی و مقایسه ضرایب انتقال حرارت درون مبدلهای حرارتی در دماها و غلظت های مختلف و همچنین شرایط جریانی مغشوش و مقایسه آنها با مدلهای تئوری میپردازیم.

### ۱-۳- اندازه گیری خواص ترموفیزیکی

ضریب هدایت حرارتی نانو سیالات به عنوان توانایی آن ها در انتقال گرما اندازه گیری شد. برای این منظور از یک دستگاه، KD2-Pro (Decagon Devices) استفاده گردید. این دستگاه یک دستگاه تحلیل خواص حرارتی کاملاً قابل حمل آزمایشگاهی است که از روش منبع حرارت خط گذرا برای اندازه گیری ضریب هدایت حرارتی استفاده می کند.

گرانروی نمونه ها با استفاده از دستگاه ویسکومتر چرخشی بروکفیلد (Brookfield, model RVDV-II+ pro, USA و اسپیندل مدل YULA-15) شماره S00 اندازه گیری شد. گرانروی هر یک از نمونه ها در شرایط دمایی ۲۰ تا ۶۰ درجه سانتی گراد و سرعت چرخشی ۲۰۰ دور دقیقه اندازه گیری شد. این ویسکومتر در محل قرار گیری نمونه و اسپیندل، مجهز به یک محفظه استوانه ای دو جداره می باشد که توسط یک دستگاه حمام آب و سیرکولاتور مربوطه، دمای نمونه را تنظیم می کند. لذا در حین اندازه گیری گرانروی، دمای نمونه ثابت باقی می ماند. حمام ها یا پروب های التراسونیک معمولاً برای پراکنده سازی فیزیکی خوشه های نانوذره<sup>۱</sup> استفاده می شوند. پروب های التراسونیک متداولترین روش پایداری سازی در بین روش های عمل آوری فیزیکی است. انرژی صوت در یک سطح التراسونیک 20 kHz و بالاتر، برای یک دوره ی زمانی از پیش تعیین شده مورد استفاده قرار می گیرد و بدین صورت خوشه های نانوذره ای شکسته می شود و نانوذرات در داخل سیال پایه پراکنده می شوند.

<sup>1</sup> nanoparticle clusters

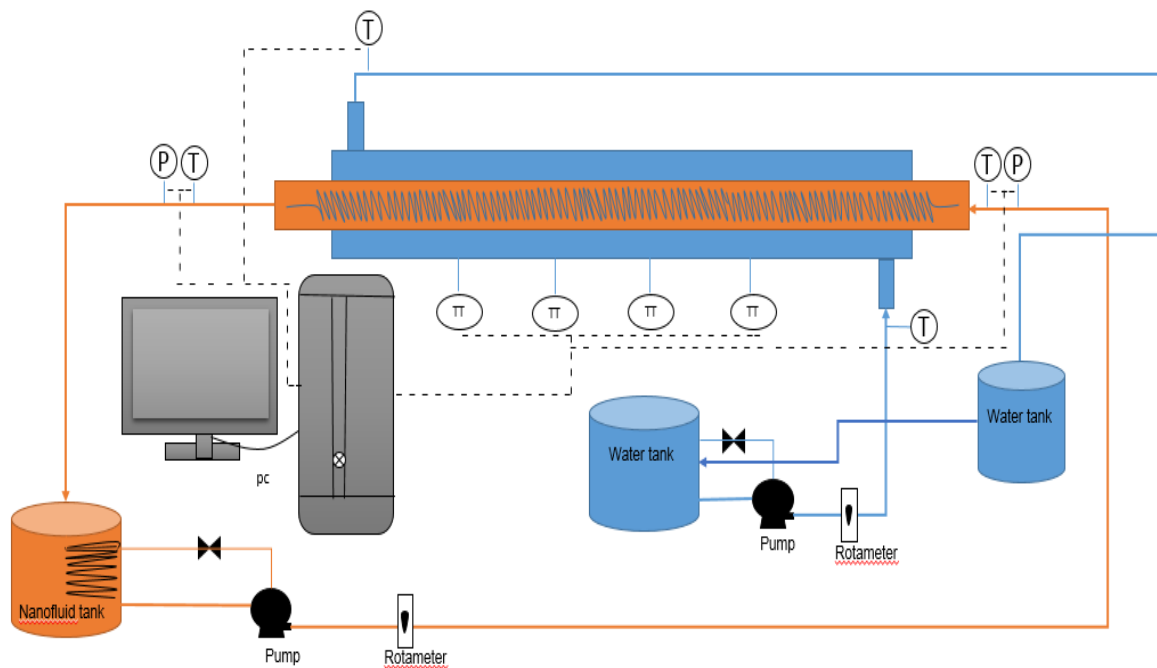


## ۲-۳- تشریح سیستم آزمایشگاهی

اجزای سیستم آزمایشگاهی شامل سه می باشد.

بخش حرارتی، مبدل حرارتی دولوله و بخش سرمایشی. نمودار یک شماتیک و نمای واقعی دستگاه آزمایشگاهی نشان می دهد. بخش گرم به منظور تولید بخار سوپرهیت بوده که از جداسازی کندانس ها در یک درام جداکننده می باشد. بخار از بخش بیرونی لوله مبدل (پوسته) می گذرد. سیستم کولینگ شامل یک مبدل صفحه ای بوده و برج کولینگ به منظور خنک کردن مایع گرم که نانوفلوید می باشد درون لوله استفاده می شود.

از میان آنها، اجزای اصلی مبدل دو لوله ای شامل طول ۲۱۰۰ میلی متر و قطر خارجی ۱۰۰ میلی مترو قطر داخلی ۳۸ میلی متر می باشد.



شکل ۳.۱. دستگاه مربوط به انجام آزمایشات

## ۳-۳- معادلات به کار رفته در آزمایش

معادله زیر نحوه محاسبه میزان گرما را نمایش میدهد.

$$Q = GC_p(T_{co} - T_{ci}) \quad (3.1)$$

برای محاسبه ضریب هدایت حرارتی نیز روشهای گوناگونی وجود دارد و در این معادلات مساحت جانبی  $A = \pi d_i l$  با این فرمول محاسبه میگردد.

$$K = \frac{1.03Q}{A\Delta T_m} = \frac{1.03GC_p(T_{co}-T_{ci})}{A\Delta T_m} \quad (3.2)$$

اختلاف دمای لگاریتمی نیز از اختلاف دمای ماگزیمم و مینیمم محاسبه میگردد.

$$\Delta T_m = \frac{T_{max}-T_{min}}{\ln \frac{T_{max}}{T_{min}}} \quad (3.3)$$

محاسبه اختلاف دمای ماگزیمم و مینیمم نیز از روش زیر میباشد.

$$T_{max} = T_{hi} - T_{co} \quad (3.4)$$

$$T_{min} = T_{ho} - T_{ci}$$

از آنجاییکه  $T_{hi}$  و  $T_{ho}$  به ترتیب دمای ورودی و خروجی طرف داغ هستند، ضریب انتقال حرارت جابه جایی بخار  $h_v$  از رابطه زیر محاسبه می شود

$$h_v = 1.13 \left[ \frac{g\rho^2\lambda^2 r}{n(t_s - t_w)l} \right]^{\frac{1}{4}} \quad (3.5)$$

$$r' = r + 0.68C_p(t_s - t_w) \quad (3.6)$$

علاوه بر این، ضریب انتقال حرارت جابه جایی در طرف سرد نانو سیال  $h_w$ ، ضریب انتقال حرارت کلی ضریب انتقال حرارت جابه جایی، گرما و سیال تحت رابطه بین ضخامت و هدایت گرمایی می تواند بیان شود

$$k = \frac{1}{\frac{1}{h_w} + \frac{\delta_t}{\lambda_t} + \frac{1}{h_v} + \frac{d_i}{d_o}} \quad (3.7)$$

$$h_w = \frac{1}{\frac{1}{k} \frac{\delta_t}{\lambda_t} \frac{d_i}{d_m} - \frac{1}{h_v} \frac{d_i}{d_o}} \quad (3.8)$$

$$Nu = \frac{h_w d}{\lambda}$$

$$Re = \frac{\rho u d}{\mu} \quad (3.9)$$

$$Pr = \frac{\mu C_p}{\lambda} \quad (3.10)$$

$$Nu = 0.023 Re^{0.8} Pr^{0.4} \quad (3.11)$$

از اونجایی که  $\delta_t$  ضخامت لوله،  $\lambda_t$  هدایت گرمایی،  $d_i$  و  $d_o$  و  $d_m$  به ترتیب قطر داخلی و خارجی و میانگین لوله هستند. ضریب دیتوس- بولتر می تواند با استفاده از اعداد پرانتل و رینولدز و ناسلت محاسبه شود.

### ۴-۳- آنالیز داده های حاصل از ضریب هدایت حرارتی

در سال های اخیر مواد در ابعاد نانومتر و معلق در مایعات (موسوم به نانو مایع) به جهت خصوصیات برتر حرارتی شان مرتباً مورد تحقیق قرار گرفته اند. یکی از دلایل جذابیت این مواد کاربردهای متعدد آنها مثل خنک کنندگی در اتومبیل، صنایع الکترونیک و یا در فرآیندهای صنعتی که به خاطر کیفیت انتقال حرارتی شان مورد استفاده قرار می گیرند می باشد. نانو ذرات نوعاً دارای ثبات شیمیایی، اکسیدهای فلزی یا کربن به اشکال مختلف ساخته می شوند. ابعاد این ذرات در حدی است که به آن ها خصوصیات منحصر به فردی می بخشد از جمله افزایش انرژی مومنتوم (تکانه حرکتی)، کاهش میل به رسوب و غیره.

روشهای موجود برای اندازه گیری هدایت حرارتی را می توان به دو دسته پایا و گذرا تقسیم نمود. در دسته پایا می توان از صفحه های موازی و پایا، روش سلول استوانه ای نام برد. اما در دسته دیگر روش هایی چون سیم داغ گذرا که خود شامل دو روش سیم داغ گذرا برای فلزات مایع و سیم داغ گذرای کوتاه استفاده کرد. روش دیگر تجزیه و تحلیل ثوابت گرمایی، نوسانات دمایی و روش امگا را می توان اشاره کرد.

با افزودن و تعلیق نانو ذرات می توان بدون تغییر در اندازه ی سطح انتقال حرارت، میزان حرارت منتقل شده را افزایش داد. این بدین معنی است که دیگر نیازی به افزایش سرعت سیال و افزایش سطح نیست که بالتبع کاهش هزینه را در پی خواهد داشت. به علاوه، در طولانی مدت به دلیل وجود انتقال حرارت مطلوب با استفاده از سیال با حجم کمتر، اثرات مخرب سیال بر پمپ ها و دیواره ی مبدل ها کاهش می یابد. از این رو، اثرات جانبی سیال بر تجهیزات کاهش خواهد یافت. همان طور که در نمودار و جدول ۳-۱ دیده می شود

با افزایش غلظت وزنی نانو سیال اکسید تیتانیوم و اکسید نقره در محدوده ۰/۲ تا ۱ درصد وزنی در دما های متفاوت مقدار ضریب هدایت حرارتی روند افزایشی دارد.


جدول ۳-۱. بررسی تاثیر دما بر ضریب هدایت حرارتی و ویسکوزیته

دما (°C)	هدایت حرارتی (W/m.K)		ویسکوزیته (mPa.s)	
	Experimental Data	Reference data	Experimental Data	Reference data
20	0.6	0.5991	0.8	0.82
25	0.61	0.61	0.78	0.784
30	0.614	0.615	0.65	0.65
35	0.625	0.625	0.6	0.59
40	0.63	0.63	0.57	0.56
45	0.635	0.6351	0.48	0.48
50	0.64	0.6401	0.44	0.439
55	0.65	0.648	0.38	0.38
60	0.65	0.65	0.3	0.31

## ۵-۳- نتایج و بحث

### ۵-۳-۱- مورد آب مقطر

در ابتدا آزمایش با استفاده از آب مقطر به عنوان سیال کاری، در طرف سرد انجام شد. این آزمایش به منظور تعیین دقت اندازه گیری برای مقایسه در هنگام استفاده از نانو سیال به جای آب است. نمودار ۲-۳ مقایسه بین ضریب داده شده توسط گنیلینسکی و نتایج تجربی را نشان می دهد. حداکثر انحراف یافته شده ۱۵ درصد است که در محدوده قابل قبول است و نشان می دهد که از روش استفاده شده برای محاسبه داده های آزمایش، می توان برای محاسبه انتقال حرارت نانوسیال استفاده کرد.



نمودار ۳-۲. تاثیر رینولدز بر ضریب انتقال حرارت جابه جایی


این تحقیق با استفاده از غلظت های مختلف  $Al_2O_3$  که شامل ۰.۲۵٪ و ۰.۵٪ غلظت حجمی ، با عدد رینولدز متغیر بین ۲۰۰۰۰ تا ۶۰۰۰۰ انجام شده است. همانطور که در شکل ۳ نشان داده شده است به خاطر شکست جریان متلاطم اثر مقاومت لایه مرزی ، ضریب انتقال حرارت با افزایش عدد رینولدز ، افزایش می یابد. می توان مشاهده کرد که با افزایش غلظت نانوذرات در سیال پایه ، ضریب انتقال حرارت جابه جایی نیز در حال افزایش است.

شکل ۳ (الف) مطالعه مقایسه ای انتقال حرارت جابه جایی بین غلظت های مختلف نانوذرات در دمای ورودی ۴۰ درجه سانتیگراد را نشان می دهد. در غلظت بالاتر انتقال حرارت جابه جایی افزایش قابل توجهی را در مقایسه با غلظت کم نشان می دهد.


حداکثر افزایش ضریب انتقال حرارت همرفتی حدود ۹/۷٪ و ۱۹/۶٪ برای ۰.۲۵٪ و ۰.۵٪ غلظت حجم محاسبه شده است. این افزایش اثر انتقال حرارت را می توان به دلیل افزایش هدایت حرارتی به دلیل افزودن نانوذرات توضیح داد.

در شکل ۳ (ب) نتایج آزمایش نشان داده می شود که دمای ورودی سمت سرد به ۵۰ افزایش یابد. با افزایش درجه حرارت ورودی هدایت حرارتی نانوذرات افزایش یافته و در نتیجه با دمای ورودی ۴۰ °C ،

ضریب انتقال حرارت بهبود قابل توجهی را در دمای ورودی بالاتر نشان می دهد. بیشترین افزایش را می توان در حدود ۱۵٪ و ۲۹٪ به ترتیب برای ۰.۲۵٪ و ۰.۵٪ مشاهده کرد. ویژگی مهم نانوسیالات وابستگی شدید هدایت حرارتی آن به دما است. با مقایسه نتایج از شکل ۴(الف) و ۴(ب) می توان تخمین زد که حداکثر تغییر کلی انتقال حرارت به دلیل تغییر دما به ترتیب ۵.۳٪ و ۴.۴٪ برای ۰.۲۵٪ و ۰.۵٪ در غلظت حجم افزایش یافته است. با توجه به افزایش دمای ورودی، انتقال حرارت جابه جایی افزایش قابل توجهی را نشان داد در حالی که غلظت نانوذرات همچنان ثابت باقی مانده است.



نمودار ۳-۳. (الف) نتایج آزمایش تاثیرات عدد رینولدز و غلظت بر ضریب انتقال حرارت جابجایی





نمودار ۳-۳. (ب) نتایج آزمایش تاثیرات عدد رینولدز و غلظت بر ضریب انتقال حرارت جابجایی.

## ۲-۵-۳- تاثیر روی عدد ناسلت

شکل ۴-الف) نتایج تجربی عدد ناسلت را در دمای ورودی ۴۰ نشان می دهد. مشاهده می شود که با افزایش غلظت نانوسیالات، عدد ناسلت نیز افزایش می یابد. عدد رینولدز بالاتر نسبت به عدد رینولدز پایین تر تاثیر بسیار برجسته ای در انتقال حرارت دارد. در اعداد رینولدز بالاتر از ۶۰۰۰ عدد ناسلت ۸.۵٪ و ۱۷٪ به ترتیب برای کسر حجمی ۰.۲۵٪ و ۰.۵٪ مشاهده شد.

شکل ۴-ب) نتایج آزمایشی را نشان می دهد که دمای ورودی آب سرد به ۵۰ تغییر می یابد. مشاهده می شود که عدد ناسلت آب در مقایسه با آن در دمای ۴۰ درجه کاهش می یابد. با افزایش درجه حرارت، این اثر را می توان توضیح داد. با افزودن نانوذرات به قسمت سرد، خصوصیات انتقال حرارت آب افزایش می یابد. مشاهده شده است که با افزودن غلظت حجم یکسان در دمای ۴۰ درجه، انتقال گرما در دمای بالاتر از ۵۰ درجه سانتیگراد نسبت به دمای پایین تر پیشرفت بیشتری نشان می دهد. با افزایش عدد رینولدز با بیشترین انتقال حرارت، عدد نوسلت افزایش می یابد و بنابراین عدد ناسلت به ترتیب ۱۱.۷٪ و ۲۴.۵٪ در کسری از حجم ۰.۲۵٪ و ۰.۵٪ مشاهده می شود. تعداد فاکتورهای ارائه شده توسط محقق های مختلف می تواند این پیشرفت را توضیح دهد. مکانیسم احتمالی که به افزایش هدایت حرارتی غیرمعمول کمک می کند، شامل برخورد ذرات، حرکت براونی، ماهیت بالستیک انتقال گرما در نانو و خوشه بندی نانوذرات است. انتقال حرارت در لایه مرزی با افزودن نانوذرات بطور قابل توجهی افزایش می یابد زیرا بمباران مداوم ذرات نانو باعث انتقال بیشتر گرما از مرز به جریان سیال اصلی می شود. جریان مایع در نتیجه افزایش اثر انتقال حرارت و عدد ناسلت را افزایش می دهد.




نمودار ۳-۴. الف و ب) نتایج آزمایشی تغییرات همزمان غلظت و عدد رینولدز بر عدد ناسلت

در اینجا از نانوسیال برای دستیابی به افزایش انتقال حرارت در مبدل حرارتی لوله دوتایی استفاده شده است. این آزمایش با استفاده از آب مقطر انجام شد تا صحت این آزمایش مشخص شود. نتایج حاصل



از آب به عنوان یک مایع خنک کننده با معادله دیتوس و بولتر تأیید شده است. هنگامی که بررسی شود که صحت داده ها در محدوده خطای محدود است ، نانوسیالات به عنوان خنک کننده در سمت سرد اضافه می شوند. غلظت نانو سیالات در کسر حجمی ۰.۲۵٪ و ۰.۵٪ در دمای ورودی مختلف متغیر بود. نتایج حاصل از آزمایشات تجربی نشان دهنده بهبود قابل ملاحظه بر روی آبی هست که حداکثر عدد ناسلت آن تا ۰.۲۵٪ افزایش می یابد. علاوه بر این ، با افزایش دمای ورودی انتقال حرارت نانوسیالات افزوده می شود که وابستگی نانوسیالات به دما را نشان می دهد.

با افزایش عدد رینولدز و مغشوش کردن رینولدز درون لوله از حالت گذرا عبور کرده و لایه مرزی حرارتی را به تاخیر می اندازیم و این موجب افزایش انتقال حرارت و برخورد شدیدتر ملکولها با هم گردیده ولی از طرفی موجب کاهش ضریب اصطکاک میگردد. همانطور که در نمودار ۳-۴ مشاهده میکنید با تغییر رینولدز از ۱۰۰۰۰ به ۲۰۰۰۰ شاهد تغییرات ۱۰۰ درصدی عدد ناسلت میباشیم در حالی که تنها ۲۵ درصد کاهش ضریب اصطکاک را مشاهده میکنید.



نمودار ۳-۴- تغییرات عدد ناسلت با تغییرات عدد رینولدز

## **فصل چهارم**

### **مدلسازی و بررسی نتایج**

## ۴-۱- مقدمه

مهمترین هدف این پژوهش در گام نخست پیشبینی کارایی مبدل های حرارتی با استفاده از روش هوش مصنوعی است. بدین منظور ضرایب انتقال حرارت به کمک شبکههای هوشی چندلایه پیشبینی گردید. از شاخص های آماری متداول مانند میانگین مربعات خطا و ضریب رگرسیون برای محاسبه خطا و میزان دقت مدل شبکه عصبی بهره جستیم.

## ۴-۲- بانک اطلاعاتی

اجزای سیستم آزمایشگاهی شامل سه می باشد.

بخش حرارتی، مبدل حرارتی دولوله و بخش سرمایشی. نمودار یک شماتیک و نمای واقعی دستگاه آزمایشگاهی نشان می دهد. بخش گرم به منظور تولید بخار سوپرهیت بوده که از جداسازی کندانس ها در یک درام جداکننده می باشد. بخار از بخش بیرونی لوله مبدل (پوسته) می گذرد. سیستم کولینگ شامل یک مبدل صفحه ای بوده و برج کولینگ به منظور خنک کردن مایع گرم که نانوفلوید می باشد درون لوله استفاده می شود .

از میان آنها، اجزای اصلی مبدل دو لوله ای شامل طول ۲۱۰۰ میلی متر و قطر خارجی ۱۰۰ میلی مترو قطر داخلی ۳۸ میلی متر می باشد.

پارامترهای زیادی در عملکرد یک مبدل حرارتی موثر هستند. ۴ مورد از مهمترین پارامترهای اثرگذار بر روی عملکرد مبدل حرارتی عبارتند از دمای سیال، غلظت نانوذرات ، دبی ورودی نانوسیال، عدد رینولدز می باشد این متغیرها، بر روی راندمان حرارتی تاثیر گزار هستند. محدوده تغییرات این متغیرهای ورودی و خروجی در جدول زیر ارائه شده است. تعداد کل داده ها جهت مدلسازی ۵۰ است. که این داده ها به صورت تصادفی به ۳ دسته آموزش، صحنه سنجی و تست تقسیم بندی شده اند.

جدول (۴-۱) جدول داده های ورودی و خروجی مدل شبکه عصبی به همراه بازه تغییرات آن

	Parameters	Min	Max
متغیرهای ورودی	دبی (L/min)	۳	۱۲
	دما (°C)	۲۵	۷۰
	عدد رینولدز	۴۰۰۰	۳۰۰۰۰
	غلظت نانوسیال	.1	1
متغیر خروجی	ضرایب انتقال حرارت	۳۰	۲۰۰

نحوه تقسیم بندی داده های تجربی برای ایجاد مدل شبکه عصبی به شکل زیر است.

جدول (۴-۲) تقسیم بندی کل داده های آزمایشگاهی جهت ایجاد مدل شبکه عصبی

Divide data randomly		
training ratio	70%	35 samples
validation ratio	15%	7 samples
test ratio	15%	8 samples

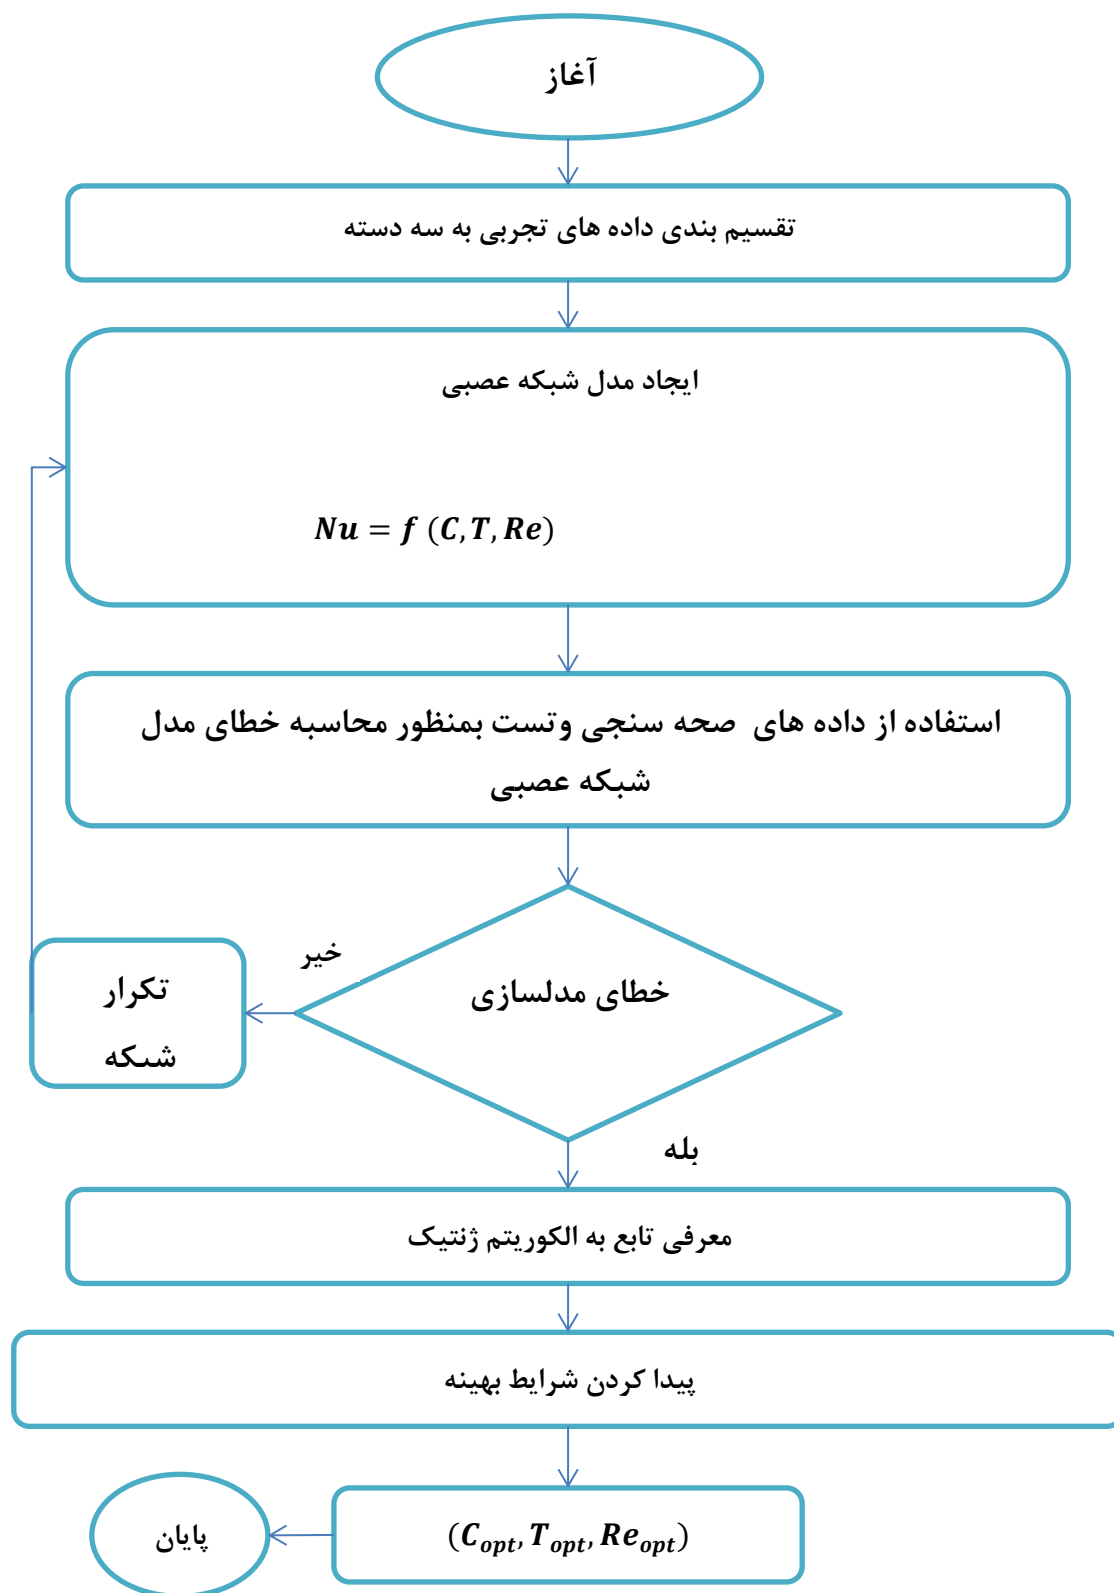
### ۳-۴- روش کار

در این پژوهش، هدف اصلی ساخت مدل شبکه عصبی جهت پیش ضرایب انتقال حرارت می باشد.

در دیاگرام زیر خلاصه های از روش کار ارائه شده است. مطابق شکل ابتدا به کمک داده تجربی ۲ مدل

شبکه عصبی جهت پیش بینی ساخته میشود سپس به کمک الگوریتم ژنتیک بهینه میشود. بدیهی است

بدلیل تک هدفه بودن مساله نیازی به جبهه پارتو نمیباشد.



شکل (۴-۱) مراحل بهینه سازی تابع هدف

پس از ساخت مدل شبکه عصبی، عملکرد و دقت آن در پیش بینی به کمک شاخص های آماری زیر محاسبه میگردد. معادله محاسبه خطا به کمک هر کدام از شاخص های زیر در ادامه ارائه شده است.

جدول (۳-۴) شاخص های آماری مورد استفاده

تعریف	شاخص آماری
میانگین مطلق خطا	$MAE$
میانگین مجذور خطا	$MSE$
جذر میانگین مجذور خطا	$RMSE$
میانگین درصد خطای نسبی	$MAPE$
ضریب همبستگی	$R^2$

$$MAE = \frac{1}{N} \sum_{i=1}^N (t_i - p_i) \quad (1-1)$$

$$MSE = \frac{\sum_{i=1}^N (t_i - p_i)^2}{N} \quad (1-2)$$


$$MAPE = \frac{100}{N} \sum_{i=1}^N \left| \frac{t_i - p_i}{t_i} \right| \quad (1-3)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (t_i - p_i)^2}{N}} \quad (1-4)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (t_i - p_i)^2}{\sum_{i=1}^N (t_i - t_m)^2} \quad (1-5)$$

### ۱-۳-۴- ارائه مدل با استفاده از شبکه عصبی

از شبکه عصبی به عنوان یک ابزار مدلسازی اصلی در پیش بینی عدد ناسلت استفاده شد. غلظت نانوسیال، دمای نانوسیال، عدد رینولدز جزء متغیرهای ورودی به شبکهها، و عدد ناسلت متغیر خروجی مدلسازی میباشد




شکل (۴-۲) متغیرهای ورودی و خروجی مدلسازی به کمک شبکه عصبی

برای مدل شبکه عصبی زیر، تعداد نورونهای لایه مخفی ۱۰ در نظر گرفته شد، ساختار شبکهها مورد بررسی در شکل زیر ۳-۱ آورده شده است. رابطه ریاضی معادل این ساختار به شکل معادله زیر است. در واقع، مدل شبکه عصبی برای محاسبه ضریب انتقال حرارت به شکل زیر است.

$$Nu_{NN} = [LW]_{1 \times 10} \times \tanh \left( [IW]_{10 \times 3} \times \begin{bmatrix} T \\ C \\ Re \end{bmatrix}_{3 \times 1} + [b_1]_{10 \times 1} \right) + [b_2]_{1 \times 1} \quad (۱-۶)$$

در حین آموزش، وزنها و بایاسهای شبکه به طور سیستماتیک به روز شده تا داده خروجی از شبکه عصبی با مقدار تجربی بدست آمده از نتایج آزمایشگاه بر هم منطبق شوند. (منظور از وزن ها ماتریس  $IW$  و  $LW$  و منظور از بایاس ماتریس  $b_1$  و  $b_2$  است) به عبارت دیگر در حین آموزش در تکرارهای مختلف تابع خطا به حداقل میرسد. چنانکه در قبل گفته شد، هدف از مدلسازی به کمک شبکه عصبی، ساخت

سیستمی است که به طور کارآمد قادر به پیش بینی عدد ناسلت به کمک داده های ورودی باشد. زمانیکه تابع خطا به حداقل مقدار خود رسید آموزش شبکه عصبی اتمام می یابد و از این لحظه به بعد از شبکه عصبی میتوان برای پیش بینی متغیر خروجی به کمک متغیرهای ورودی استفاده کرد.



شکل (۳-۴) ساختار شبکه عصبی جهت پیش بینی عدد ناسلت

#### ۴-۴- نتایج مدل سازی عدد ناسلت به کمک شبکه عصبی

در این قسمت نتایج مدلسازی به کمک شبکه عصبی با نتایج واقعی برای عدد ناسلت با یکدیگر مقایسه میشوند. تعداد کل داده های مورد استفاده در مدلسازی ۵۰ عدد می باشد. که از این تعداد ۷۰٪ آن هابرای آموزش، ۱۵٪ برای نظارت و مابقی برای تست شبکه در نظر گرفته شد. مطابق معادلات ۰ سنجش بعضی از پارامترهای آماری مهم در آموزش، صحت سنجی و تست، برای دادهای ضریب انتقال حرارت محاسبه شده است و در زیر ارائه میگردد.

جدول (۴-۴) شاخص های آماری بدست آمده از مدل

	Training	Validation	Test
<b>MSE</b>	0.0001	0.00019	0.0001
<b>RSME</b>	0.0134	0.01002	0.0101
<b>MAE</b>	0.00899	0.01111	0.0111
<b>MAPE</b>	0.01390	0.01110	0.0056




$R^2$	0.994	0.877	0.995
-------	-------	-------	-------

• عملکرد شبکه‌های عصبی مصنوعی را به شکل متوسط درصد خطا (MPE)، میانگین جذر خطا (MSE)، ریشه‌ی میانگین مجذور خطا (RMSE)، متوسط خطای مطلق (MAE)، ضریب همبستگی ( $R^2$ ) بین مقادیر واقعی و خروجی‌های شبکه عصبی نشان می‌دهد. به طور اختصار، اگر  $MPE$ ،  $R^2$ ،  $MAE$ ،  $MSE$  و  $RMSE$  به ترتیب نزدیک به مقادیر ۰، ۱، ۰، ۰ و ۰ باشند، پیش‌بینی‌های ANN بهترین و دقیق‌ترین حالت ممکن خواهد بود.


در ادامه نتایج مدلسازی عدد ناسلت به ترتیب نشان داده شده است. این نتایج، شامل مقایسه داده‌های واقعی و مدلسازی برای کل داده‌ها، داده‌های آموزش، داده‌های صحنه سنجی و داده‌های تست و همچنین نمودار خطا برای هر ۳ دسته داده (آموزش، صحنه سنجی و تست) است. همچنین نمودار رگرسیون داده‌های مدل و واقعی نیز برای هر ۳ دسته آورده شده است.

#### ۴-۴-۱- نتایج پیش‌بینی مدل برای کل داده‌ها

در نمودار زیر نتایج مدلسازی به کمک شبکه عصبی و نتایج واقعی بصورت مقایسه‌ای برای کل داده‌ها (۵۰ داده) رسم شده است. همانطور که مشاهده می‌کنید رابطه معناداری بین داده‌های تجربی و داده‌های مدلسازی شده وجود دارد که خود بیانگر میزان خطای ناچیز آنها می‌باشد. میزان خطا در پیش‌بینی در نمودار بعدی (۰) نشان داده شده است.



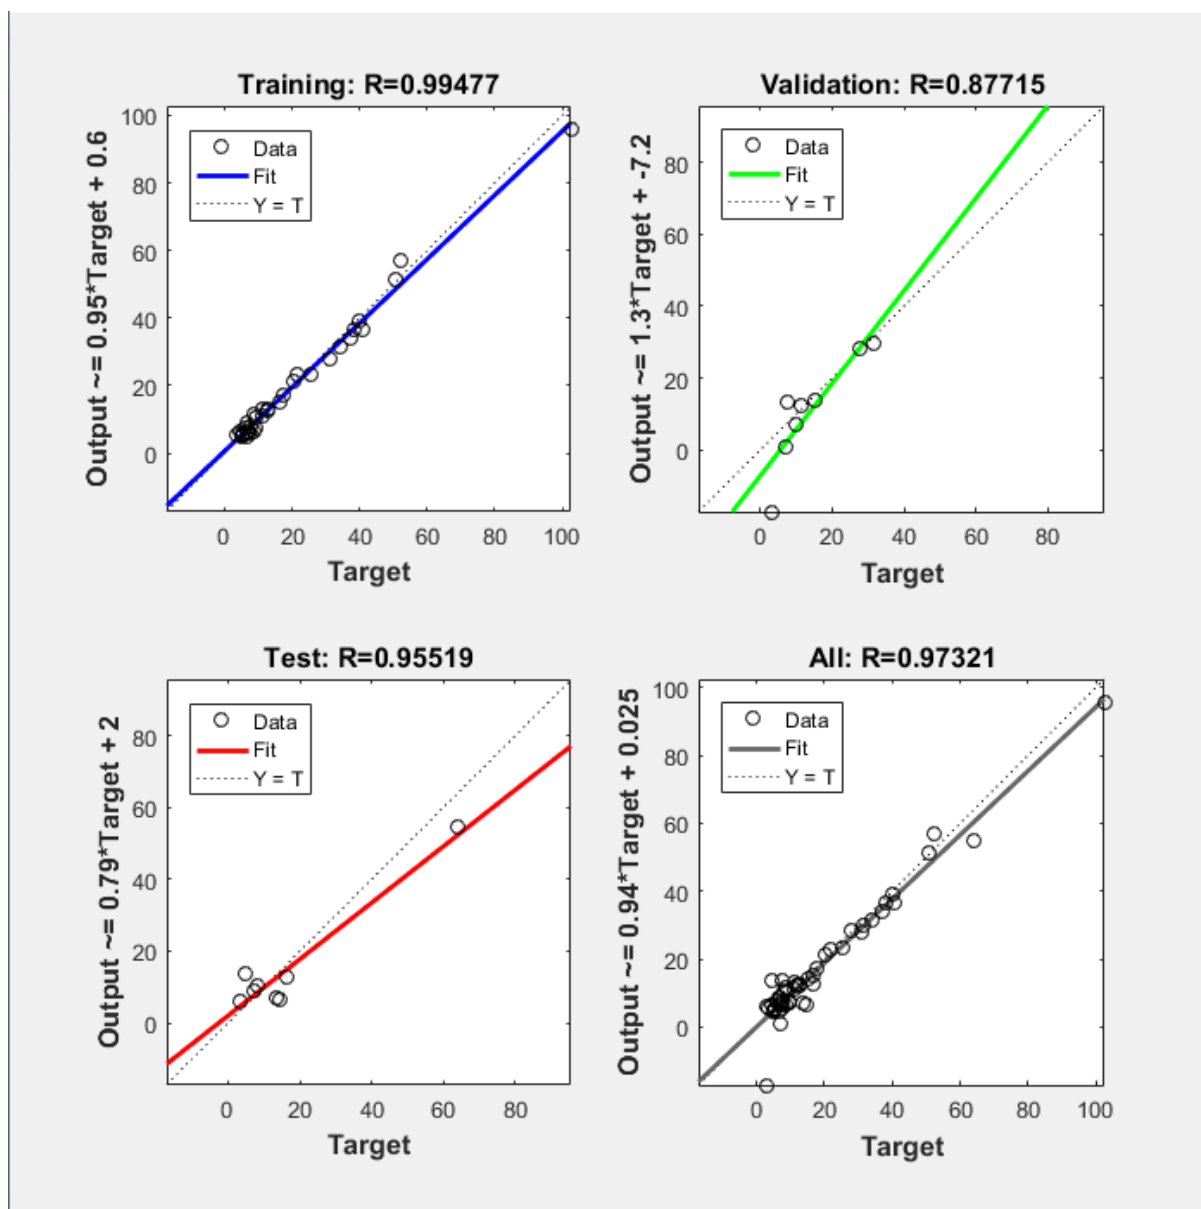
مقایسه نتایج مدل و شبکه برای عدد ناسلت



شکل (۴-۴) درصد خطای بی بعد شده مدلسازی به کمک شبکه عصبی

## ۲-۴-۴- نمودار رگرسیون برای عدد ناسلت

نمودار رگرسیون برای داده های  $Nu_{real}$  و  $Nu_{model}$  رسم شده است. محور افقی داده های واقعی ( $X$ ) و محور عمودی داده های مدلسازی ( $Y$ ) می باشد (منظور از داده مقدار عدد ناسلت ( $Nu$ ) است). در حالت ایده آل، زمانیکه خطای پیش بینی شبکه عصبی صفر است، داده واقعی با داده مدل بر هم منطبقاند ( $Nu_{model} = Nu_{real}$ ) بنابراین نقاط بر روی خط نیمساز ربع اول و سوم ( $Y=X$ ) قرار میگیرند. همانطور که ملاحظه میکنید به دلیل وجود اندکی خطا، داده نسبت به خط  $Y=X$  انحراف دارند. معادله بهترین خط عبورکننده از بین دادهها در شکل های زیر ارائه شده است.



شکل (۴-۵) نمودار رگرسیون داده مدل و داده واقعی


شکل (۴-۵) نشانگر رابطه معنادار بین داده های واقعی در هر سه حالت آموزش تا صحت صنجی با

داده های پیش بینی شده به کمک شبکه عصبی مصنوعی میباشد هر سه مورد ضریب همبستگی

بالای ۹۵ درصد میباشد.

## ۳-۴-۴- نمودار مقایسه ای و هیستوگرام خطا

برای هر سه داده‌ی آموزش صحنه سنجی و تست نمودار واقعی و مدلسازی و هیستوگرام خطا رسم گردیده است. همانطور که در نمودار مشخص است تعداد داده‌های آموزش 35 عدد است. و نتایج مدلسازی تطابق خوبی با داده‌های واقعی دارند میزان خطا ناچیز و دقت مدلسازی مطلوب است. نمودار بعدی که در زیر آن رسم شده است توزیع خطا را در ۱۰ زیربازه نشان می‌دهد و هیستوگرام خطا نامیده می‌شود. نحوه توزیع خطای برای 35 داده به شکل یک زنگوله است. مطابق نمودار هیستوگرام خطا 10 داده خطای در حد صفر دارد همانطور که مشاهده می‌کنید اکثر داده‌های پیش بینی شده در بازه و محدوده خطای صفر هستند و تقارن خوبی بین خطاهای مثبت و منفی موجود است.

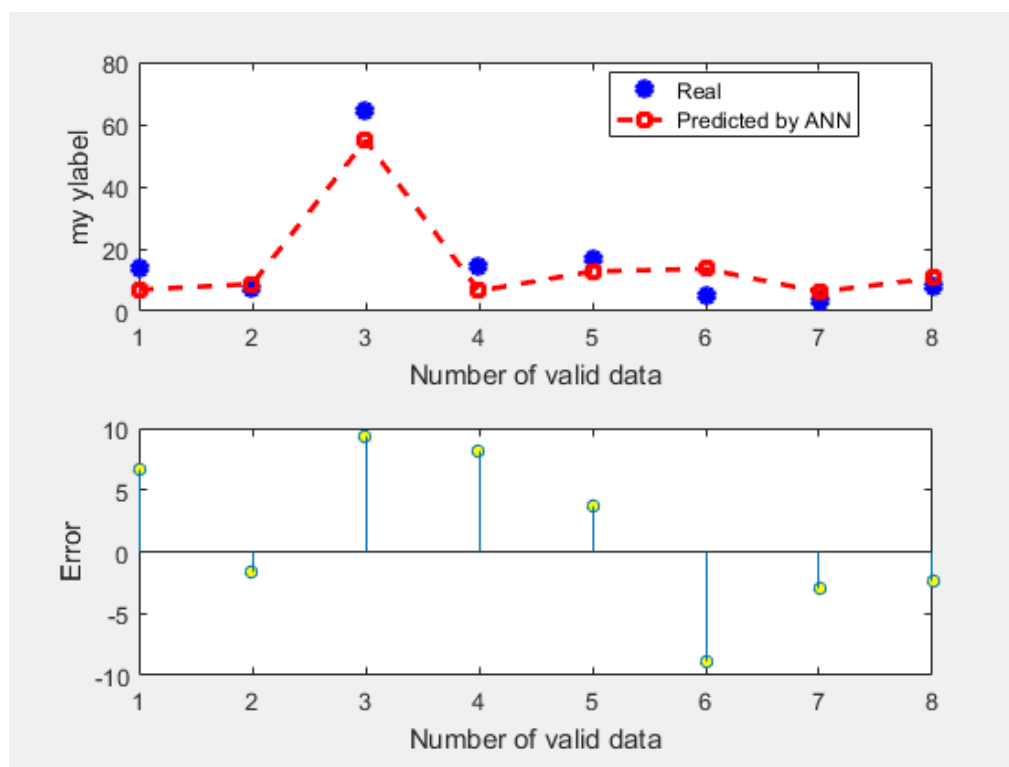


شکل (۴-۶) نمودار مقایسه‌ای داده‌های مدل و داده تجربی برای دسته‌ی آموزش


در ادامه نمودارهای مقایسه ای و هیستوگرام خطا برای داده صحنه سنجی و تست ارائه شده است.

نمودار (۴-۷) نشان می‌دهد که فراوانی خطاها در نزدیکی خطای صفر خیلی بیشتر می‌باشد و

پراکندگی ها بسیار کم می باشد. از طرفی دیگر بیانگر این است که داده های آزمایشگاهی و داده های پیش بینی شده با هم همخوانی کافی داشته و اختلاف ناچیزی مشاهده می گردد.



شکل (۴-۷) نمودار خطا داده های دسته صحنه سنجی



شکل (۴-۸) نمودار میزان انحراف خطا


همانطور که در شکل (۴-۸) مشاهده میکنید بعد از تکرار بیستم دیگر انحراف زیادی مشاهده نمیشود و تعداد کل حدس و خطاها ۲۶ تا میباشد.

#### ۴-۴-۴- نمودار همگرایی در روند آموزش

خطای میانگین مجموع مربعات برای داده آموزش، صحنه سنجی و تست در زیر برای تکرارهای مختلف رسم شده است (محور افقی تعداد تکرار الگوریتم در فرآیند آموزش شبکه است). روند آموزش شبکه عصبی بصورت تکراری است در هر مرحله مقادیر ماتریس وزن و بایاس بگونه ای تغییر میکند تا خروجی شبکه بر مقدار واقعی منطبق شود. رفته رفته خطا کاهش میابد.

مقدار خطا در شروع آموزش (در تکرارهای اولیه) مقدار بزرگی است. در تکرارهای بعدی مقدار خطا روند کاهشی دارد. در تکرار شماره ۱۹ میزان خطا برای داده صحنه سنجی به حداقل مقدار خود میرسد از تکرار ۱۹ تا تکرار ۲۶ میزان خطای صحنه سنجی متوالیاً روند صعودی دارد ولیکن خطای داده آموزش

(training) همچنان رو به کاهش است. برای اینکه مدل عمومیت داشته باشند باید از آموزش بیش از اندازه پرهیز کرد. آموزش بیش از اندازه‌ی منجر به پدیده‌ی  $\text{overfitting}$  می‌گردد بنابراین الگوریتم بصورت پیش فرض، زمانیکه مقدار خطای صحنه سنجی در ۷ تکرار متوالی صعودی باشد دستور توقف میدهد.



شکل (۹-۴) نمودار مقایسه‌ای داده‌های مدل و داده تجربی برای دسته تست

مطابق شکل (۹-۴) الگوریتم در تکرار ۲۲ متوقف شده است زیرا در ۷ تکرار متوالی میزان خطای صحنه سنجی صعودی بوده است. در تکرار ۱۹ کمترین خطای داده صحنه سنجی بدست آمده است بنابراین این تکرار به عنوان جواب مساله انتخاب می‌گردد.

## ۴-۵- نتیجه گیری:

با افزودن و تعلیق نانوذرات می‌توان بدون تغییر در اندازه‌ی سطح انتقال حرارت، میزان حرارت منتقل شده را افزایش داد. این بدین معنی است که دیگر نیازی به افزایش سرعت سیال و افزایش سطح نیست که بالتبع کاهش هزینه را در پی خواهد داشت. به علاوه، در طولانی مدت به دلیل وجود انتقال حرارت مطلوب با استفاده از سیال با حجم کمتر، اثرات مخرب سیال بر پمپ‌ها و دیواره‌ی مبدل‌ها کاهش می‌یابد. از این‌رو، اثرات جانبی سیال بر تجهیزات کاهش خواهد یافت. همان‌طور که در نمودار و جدول ۴-۱ دیده می‌شود با افزایش غلظت وزنی نانو سیال اکسید تیتانیوم و اکسید نقره در محدوده ۰/۲ تا ۱ درصد وزنی در دماهای متفاوت مقدار ضریب هدایت حرارتی روند افزایشی دارد. ویژگی مهم نانوسیالات وابستگی شدید هدایت حرارتی آن به دما است.

در اینجا از نانوسیال برای دستیابی به افزایش انتقال حرارت در مبدل حرارتی لوله دوتایی استفاده شده است. این آزمایش با استفاده از آب مقطر انجام شد تا صحت این آزمایش مشخص شود. نتایج حاصل از آب به عنوان یک مایع خنک کننده با معادله دیتوس و بولتر تأیید شده است. هنگامی که بررسی شود که صحت داده‌ها در محدوده خطای محدود است، نانوسیالات به عنوان خنک کننده در سمت سرد اضافه می‌شوند. غلظت نانو سیالات در کسر حجمی ۰/۲۵٪ و ۰/۵٪ در دمای ورودی مختلف متغیر بود. نتایج حاصل از آزمایشات تجربی نشان دهنده بهبود قابل ملاحظه بر روی آبی هست که حداکثر عدد ناسلت آن تا ۰/۲۵٪ افزایش می‌یابد. علاوه بر این، با افزایش دمای ورودی انتقال حرارت نانوسیالات افزوده می‌شود که وابستگی نانوسیالات به دما را نشان می‌دهد.

با افزودن نانوذرات به قسمت سرد، خصوصیات انتقال حرارت آب افزایش می‌یابد. مشاهده شده است که با افزودن غلظت حجم یکسان در دمای ۴۰ درجه، انتقال گرما در دمای بالاتر از ۵۰ درجه سانتیگراد نسبت به دمای پایین‌تر پیشرفت بیشتری نشان می‌دهد. با افزایش عدد رینولدز با بیشترین انتقال حرارت، عدد نوسلت افزایش می‌یابد و بنابراین عدد ناسلت به ترتیب ۱۱/۷٪ و ۲۴/۵٪ در کسری از حجم ۰/۲۵٪ و ۰/۵٪ مشاهده می‌شود. در ابتدا آزمایش با استفاده از آب مقطر به عنوان سیال کاری، در طرف سرد انجام شد. این آزمایش به منظور تعیین دقت اندازه‌گیری برای مقایسه در هنگام استفاده از نانو سیال به جای آب است.

در این پژوهش، هدف اصلی ساخت مدل شبکه عصبی جهت پیش‌ضرایب انتقال حرارت



میباشد. چهار مورد از مهمترین پارامترهای اثرگذار بر روی عملکرد مبدل حرارتی عبارتند از دمای سیال، غلظت نانوذرات، دبی ورودی نانوسیال، عدد رینولدز میباشد این متغیرها، بر روی راندمان حرارتی تاثیر گزار هستند. مهمترین هدف این پژوهش در گام نخست پیشبینی کارایی مبدل های حرارتی با استفاده از روش هوش مصنوعی است. بدین منظور ضرایب انتقال حرارت به کمک شبکههای هوشی چندلایه پیشبینی گردید و برای مدل شبکه عصبی زیر، تعداد نورونهای لایه مخفی ۱۰ در نظر گرفته شد در ضمن

تعداد کل داده های مورد استفاده در مدلسازی ۵۰ عدد می باشد. که از این تعداد ۷۰٪ آن ها برای آموزش، ۱۵٪ برای نظارت و مابقی برای تست شبکه در نظر گرفته شد. نتایج نشان داد که رابطه معنادار بین داده های واقعی در هر سه حالت آموزش تا صحت صنجی با داده های پیش بینی شده به کمک شبکه عصبی مصنوعی وجود دارد و در هر سه مورد ضریب همبستگی بالای ۹۵ درصد میباشد.

برای هر سه داده ای آموزش صحه سنجی و تست نمودار واقعی و مدلسازی و هسیتوگرام خطا در صورتی که تعداد داده های آموزش 35 عدد است نشان داد که نتایج مدلسازی تطابق خوبی با داده های واقعی دارند میزان خطا ناچیز و دقت مدلسازی مطلوب است. نمودار توزیع خطا را در ۱۰ زیربازه نشان داده شد که نحوه توزیع خطای برای 35 داده به شکل یک زنگوله است. مطابق نمودار هسیتوگرام خطا 10 داده خطای در حد صفر دارد همانطور که مشاهده میکنید اکثر داده های پیش بینی شده در بازه و محدوده خطای صفر هستند و تقارن خوبی بین خطاهای مثبت و منفی موجود است .

## ۴-۶- پیشنهادات:

ماشین پشتیبان بردار ابزاری ارزشمند برای پیش بینی هر دو خواص ترموفیزیکی نانوسیالات و عملکرد حرارتی آنها در کاربردهای صنعتی است. علاوه بر این، ماشین پشتیبان بردار می تواند برای

مقایسه نتایج آزمایشگاهی یا عددی به دست آمده از طریق روش های مختلف و سپس تحلیل تغییرپذیری زیاد نتایج منتشر شده مورد استفاده قرار گیرند.

شبکه های عصبی مصنوعی در ترکیب با الگوریتم های چندهدفه مانند ژنتیک، می توانند برای یافتن طراحی بهینه سیستم های حرارتی شامل نانوسیالاتی که عملکرد آن ها به تعداد زیادی از پارامترهای هندسی و عملیاتی وابسته است مورد استفاده قرار گیرند.

راندمان نانوسیالات براساس قوانین اول و دوم ترمودینامیک می تواند محاسبه گردد.

- [1] S.U.S. Choi, J.A. Eastman, Measuring of thermal conductivity of fluids containing oxide nanoparticles, *J. Heat Transfer* 121 (1999) 280–289.
- [2] S.K. Das, N. Putra, W. Roetzel, Temperature dependence of thermal conductivity for nanofluids, *ASME J. Heat Transfer* 125 (2003) 567–574.
- [3] J.H. Lee, K.S. Hwang, S.P. Jang, B.H. Lee, J.H. Kim, S.U.S. Choi, C.J. Choi, Effective viscosities and thermal conductivities of aqueous nanofluids containing low volume concentrations of Al<sub>2</sub>O<sub>3</sub> nanoparticles, *Int. J. Heat Mass Transfer* 51(2008) 2651–2656.
- [4] S.W. Kang, Wei-Chiang Wei, Sheng-Hong Tsai, Shih-Yu Yang, Experimental investigation of silver nano fluid on heat pipe thermal performance, *Appl. Thermal Eng.* 26 (17) (2006) 82–90.
- [5] M.S. Liu, M.C.C. Lin, C.Y. Tsai, C.C. Wang, Enhancement of thermal conductivity with Cu for nanofluids using chemical reduction method, *Int. J. Heat Mass Transfer* 49 (17–18) (2006) 3028–3033.
- [6] S.M.S. Murshed, K.C. Leong, C. Yang, Thermophysical and electro kinetic properties of nano fluids—a critical review, *Appl. Therm. Eng.* 28 (2008) 2109–2125.
- [7] R.S. Vajjha, D.K. Das, Experimental determination of thermal conductivity of three nanofluids and development of new correlations, *Int. J. Heat Mass Transfer* 52 (2009) 4675–4682.
- [8] M.-S. Liu, M.C.-C. Lin, C.Y. Tsai, C.-C. Wang, Enhancement of thermal conductivity with Cu for nanofluids using chemical reduction method, *Int. J. Heat Mass Transfer* 49 (2013) 3028–3033, 2006, *International Journal of Thermal Sciences*, Vol. 66, pp. 82–90.
- [9] Dinesh Mehta, A.K. Tania, Nitesh M. Jha, Nimit M. Patel, *Int. J. Adv. Eng. Technol.* 3 (2012) 49–54.
- [10] M.H. Pirahmadian, Azadeh Ebrahimi, Theoretical investigation heat transfer mechanism in nanofluids and the effects of clustering on thermal conductivity, *Int. J. Biosci. Biochem. Bioinformatics* 2 (2012) 90–94.
- [11] H. Karimi, Fakheri Yousefi, Mahmood Reza Rahimi, Correlation of viscosity in nanofluids using genetic algorithm-neural network (GA-NN), *World Acad. Sci. Eng. Technol.* 5 (2011) 400–407.
- [12] H. Salehi, S. Zeinali Heris, M. Koolivand Salooki, S.H. Noei, Designing a neural network for closed thermosyphon with nanofluid using a genetic algorithm, *Braz. J. Chem. Eng.* 28 (2011) 157–168.
- [13] M. Tajik Jamal-Abadi, A.H. Zam Zamian, Optimization of thermal conductivity of Al<sub>2</sub>O<sub>3</sub> nanofluid by using ANN and GRG methods, *Int. J. Nanosci. Nanotechnol.* 9 (2013) 177–184.
- [14] Ali Sadollah, Azadeh Ghadimi, Ibrahim H. Metselaar, Ardeshir Bahreininejad, Prediction and optimization of stability parameters for titanium dioxide nanofluid using response surface methodology and artificial neural networks, *Sci. Eng. Compos. Mater.* (2013) 1–12.
- [15] Hojjat, M., Etemad, S.Gh, Bagheri, R., Thibault, J., 2011 Thermal Conductivity of

- non-Newtonian nanofluids: experimental data and modeling using neural network, *Int. J. Heat Mass Transfer*, 54,5-6,1017–1023.
- [16] M.A. Ariana, B. Vaferi, G. Karimi, Prediction of thermal conductivity of alumina water-based nanofluids by artificial neural networks, *Powder Technol.* (2015)1–10.
- [17] M. Mohanraj, S. Jayaraj, C. Muraleedharan, Applications of artificial neural networks for thermal analysis of heat exchangers-a review, *Int. J. Thermal Sci.*90 (2015) 150–172.
- [18] A. Azari, S. Marhemati, Model for thermal conductivity of nanofluids using a general hybrid GMDH neural network technique, *Int. J. Nanosci. Nanotechnol.*11 (2015) 71–82.
- [19] M.H. Esfe, Somchai Wongwises, Ali Naderi, Amin Asadi, Mohammad Reza Safaei, Hadi Rostamian, Mahidzal Dahari, Arash Karimipour, Thermal conductivity of Cu/TiO<sub>2</sub>–water/EG hybrid nanofluid: experimental data and modeling using artificial neural network and correlation, *Int. Commun. Heat Mass Transfer* 66 (2015) 100–104.
- [20] M.H. Esfe, Seyfolah Saedodin, Nima Sina, Masoud Afrand, Designing an artificial neural network to predict thermal conductivity and dynamic viscosity of ferromagnetic nanofluid, *Int. Commun. Heat Mass Transfer* (2015) 1–8.
- [21] R. Kavitha, P.C. Mukesh Kumar, A review on nanofluids thermal properties determination using intelligent techniques or soft computing tools, *Int. J. Scientific Res. Development* 3 (10) (2015) 463–465.
- [22] M.H. Esfe, Seyfolah Saedodin, Ali Naderi, Ali Alirezaie, Arash Karimipour, Somchai Wongwises, Marjan Goodarzi, Mahidzal bin Dahari, Modeling of thermal conductivity of ZnO-EG using experimental data and ANN methods, *Int. Commun. Heat Mass Transfer* 63 (2015) 35–40.
- [23] S. Khosrojerdi, M. Vakili, M. Yahyaei, K. Kalhor, Thermal conductivity modelling of graphenenanoplatelets/deionized water nanofluid by MLP neural network and theoretical modelling using experimental results, *Int. Commun. Heat Mass Transfer* 74 (2016) 11–17.
- [24] R. Aghayari, Heydar Maddah, Ali Reza Faramarzi, Hamid Mohammadiun, Mohammad Mohammadiun, Comparison of the experimental and predicted data for thermal conductivity of iron oxide nanofluid using artificial neural networks, *Nanomed Res. J.* 1 (1) (2016) 15–22.
- [25] M. Vafaei, Masoud Afrand, Nima Sina, Rasool Kalbasi, Forough Sourani, Hamid Teimouri, Evaluation of thermal conductivity of MgO-MWCNTs/EG hybrid nanofluids based on experimental data by selecting optimal artificial neural networks, *Physica E: Low-dimensional Systems and Nanostructures* 85 (2016)90–96.
- [26] R. Kavitha, P.C. Mukesh Kumar, Investigation of hidden pattern of thermal properties for nano fluids using machine learning techniques, *Int. J. Innovative Res. Explorer* 5 (2) (2016) 13–21.
- [27] N. Zhao, Zhiming Li, Experiment and artificial neural network prediction of thermal conductivity and viscosity for alumina-water nanofluids, *Materials (Basel)* 10 (5) (2017) 552.
- [28] I.O. Alade, Tajudeen A. Oyehan, Idris K. Popoola, Sunday O. Olatunji, Bagudu Aliyu, Modeling thermal conductivity enhancement of metal and metallic oxide nanofluids using support vector regression, *Adv. Powder Technol.* 29 (1)(2016) 157–167.
- [29] R. Kavitha, P.C. Mukesh Kumar, A comparison between MLP and SVR models in prediction of thermal properties of nano fluids, *J. Appl. Fluid Mech.* 11 (Special Issue) (2018) 7–14.
- [30] R. Kavitha, P.C. Mukesh Kumar, Soft computational modeling and regression analysis for thermal properties of nanofluids, *Int. J. Rapid MaNufacturing* 8 (3)(2019) 243–258.

[31] H. Maddah, Reza Aghayari, Mohammad Hossein Ahmadim, Mohammad Rahimzadeh, Nahid Ghasemi, Prediction and modeling of MWCNT/Carbon (60/40)/SAE 10 W 40/SAE 85 W 90(50/50) nanofluid viscosity using artificial neural network (ANN) and self-organizing map (SOM), J. Therm. Anal. Calorim.134 (3) (2018) 2275–3228.

## اختصارات

اختصارات زیر در این تحقیق استفاده می شوند:

$C_p$	specific heat, $J \cdot K^{-1} \cdot kg^{-1}$
$C_k, C_m$	coefficients related to the dynamic viscosity and thermal conductivity, respectively,-
$d_{np}$	average nanoparticle diameter, nm
$h$	heat transfer coefficient, $W \cdot m^{-2} \cdot K^{-1}$
$k$	thermal conductivity, $W \cdot m^{-2} \cdot K^{-1}$
$\dot{m}, \dot{V}$	mass and volumetric flow rates, $kg \cdot s^{-1}$ and $m^3 \cdot s^{-1}$
$Mo$	Mouromtseff Number,-
$Ns$	dimensionless entropy generation,-
$Nu$	Nusselt Number,-
$PE$	performance parameter,-
$Re$	Reynolds Number,-
$T$	temperature, K
$\delta P, \delta T$	pressure drop (Pa) and temperature difference (K)
$\eta$	overall efficiency, -

$\varphi$	volume fraction, -
$\mu$	dynamic viscosity, Pa·s
$\rho$	density, kg·m <sup>-3</sup>
$bf$	base fluid
$nf$	Nanofluid
$np$	Nanoparticles
ANN	artificial neural network
EG	ethylene-glycol
MWC NT, SWCN T	multi-, single-wall carbon nanotube
PEC	performance evaluation criterion,-
PG	propylene-glycol
vol.	refers to proportions in terms of volume
W	Water
wt.	refers to proportions in terms of mass



Non\_governmental Energy institute of Higher Education

Thesis to receive a master's degree "M.Sc :

Mechanical engineering majoring in energy conversion

Title:

to provide a reliable model to estimate the overall  
heat transfer coefficient inside the shell and pipe  
heat exchanger by MATLAB software

Supervisor :

Dr.Hamid Madah

Dr. Yasi

By:

Mohamad Mahdi Karimi