

مدل‌سازی پیش‌بینی پارامترهای شار و گرفتگی غشاهای نانوکامپوزیت اولترافیلتراسیون PVDF عامل‌دار شده با نانولوله‌های کربنی با استفاده از سیستم‌های شبکه‌های هوشمند

مهران مفخمی مهرآبادی، علیرضا آقایی* و مازیار صهبا یغمایی

پژوهشکده سرامیک، پژوهشگاه مواد و انرژی، کرج، ایران

تاریخ دریافت: ۹۶/۹/۲۳ تاریخ پذیرش: ۹۷/۴/۳۱

چکیده

در این تحقیق عملکرد و خواص ضد گرفتگی و شار غشاهای نانوکامپوزیت پلی وینیلیدن فلوراید (PVDF) با غلظت‌های ۱۵ و ۱۸٪ وزنی که با نانولوله‌های کربنی عامل‌دار شده با گروه‌های اسیدی، بازی و آمین مخلوط شده و با روش وارونگی فازی و حلال نرمال متیل پیرولیدون (NMP) در آزمایشگاه ساخته شده، مورد بررسی قرار گرفت. همچنین تست‌های شار، گرفتگی، زاویه تماس، تخلخل و نرخ پس‌دهی پروتئین انجام شده است. با استفاده از نتایج تست‌های تجربی، مدل‌سازی پارامترهای شار و گرفتگی براساس متغیرهای ورودی که شامل درصد نانوذره، درصد پلیمر، تخلخل و زاویه تماس هستند؛ انجام شد. در این مدل از ۴ سیستم هوشمند شبکه عصبی چند لایه، شبکه عصبی با مدار شعاعی، کمینه مربعات بردار پشتیبان و سیستم هیبریدی تطبیقی عصبی-فازی و ۳ الگوریتم بهینه‌سازی ژنتیک، شبیه‌سازی تبردی و ازدحام ذرات استفاده شده است. نتایج نشان داد که برای هر دو پارامتر شار و گرفتگی، بهترین مدل با توجه به ضریب همبستگی بالا، مدل‌های شبکه عصبی با مدار شعاعی و سیستم هیبریدی تطبیقی عصبی-فازی هستند. در بخش بعدی مدل‌سازی برای به‌دست آوردن مقادیر بهینه (کمترین گرفتگی و ماکزیمم شار) از بهترین مدل‌های ساخته شده برای هر دو خروجی استفاده شد. سپس از الگوریتم ترکیبی از الگوریتم ژنتیک و ازدحام ذرات مقادیر بهینه به‌دست آمد. سپس با استفاده از نتایج بهینه‌سازی برای هر نوع درصد پلیمر (۱۵٪ و ۱۸٪)، غشاها در آزمایشگاه ساخته شده و سپس تست‌های شار، گرفتگی، زاویه تماس و تخلخل انجام شده و نتایج آن با نتایج مدل مقایسه گردید. نتایج نشان داد که غشای نانوکامپوزیت ۰/۰۷٪ وزنی نانولوله کربنی تک دیواره عامل‌دار شده با گروه هیدروکسیل و غشای نانوکامپوزیت ۰/۱۷٪ وزنی نانولوله کربنی تک دیواره عامل‌دار شده با گروه هیدروکسیل به ترتیب بهترین عملکرد را با پلیمرهای ۱۵ و ۱۸٪ وزنی PVDF داشته است.

کلمات کلیدی: غشای نانوکامپوزیت، نانولوله‌های کربنی، مدل‌سازی، شبکه‌های هوشمند، الگوریتم

بهینه‌سازی

مقدمه

پیش‌بینی شار و گرفتگی غشاهای مختلف استفاده شده‌اند. Delgrand و همکارانش [۱] گرفتگی غشاء در طی فرآیندهای میکروفیلتراسیون و اولترافیلتراسیون ترکیبات کلئیدی، پروتئین‌ها و همچنین تصفیه آب‌های شهری و صنعتی را بررسی نمودند که شبکه عصبی استفاده شده مقادیر گرفتگی را با تقریب خوبی مدل نمود. رضوی و همکارانش [۲-۴] مدل‌سازی دینامیکی اولترافیلتراسیون جریان عرضی شیر به منظور پیشگویی شار، مقاومت هیدرولیکی کل و دفع ترکیبات شیر (پروتئین، چربی، لاکتوز، خاکستر و مواد جامد کل) به‌عنوان تابعی از فشار و زمان فرآیند بررسی نمودند که نتایج مدل‌سازی با دقت خوبی با استفاده از تنها یک لایه مخفی و تعداد کمی داده‌های آموزش مقادیر شار، مقاومت هیدرولیکی و نرخ پس‌دهی را پیش‌بینی نمود. در مطالعه دیگری توسط Teodosiu و همکارانش [۵]، پیشگویی شار در طی اولترافیلتراسیون پساب صنعتی انجام گرفت که براساس داده‌های آزمایشگاهی شبکه‌های عصبی مصنوعی به‌طور موفقیت‌آمیزی برای پیش‌بینی شار درغشاهای فیبر توخالی به‌عنوان تابعی از زمان استفاده شد. همچنین Dornier و همکارانش [۶] در مطالعه دیگری پیشگویی گرفتگی غشای میکروفیلتر جریان عرضی محلول‌های صمغ و شربت قند را بررسی نمودند. در این تحقیق اثرهای فشاراعمالی و سرعت خوراک با زمان فیلتراسیون تحت شرایط دما و غلظت خوراک ثابت بررسی شده است که نتایج موفقیت‌آمیزی داشته‌اند. در مطالعه دیگری که توسط موسوی و همکاران [۷] بررسی شد، نشان داد که مدل شبکه عصبی مصنوعی یکی از بهترین مدل‌ها جهت تصفیه آب در فرآیند نانوفیلتراسیون بوده و مدل پیش‌بینی خوبی برای شار و نرخ پس‌دهی در فرآیند تصفیه داشته است.

فرآیندهای غشایی در سال‌های اخیر به‌عنوان روش‌هایی کارآمد برای جداسازی، خالص‌سازی و تصفیه مطرح شده‌اند. از آنجایی که غشاهای آب‌دوست مقاومت به گرفتگی بالاتری نسبت به مواد کاملاً آب‌گریز دارند، افزایش آب‌دوستی غشاهای پلیمری یکی از راهکارهای اساسی برای اصلاح غشاها است. روش‌های مختلفی برای افزایش آب‌دوستی غشاهای پلیمری گزارش شده است. از میان روش‌های اصلاح غشاهای پلیمری، استفاده از نانوساختارهای معدنی [۱] در ساختار غشاها به‌دلیل کارایی بالا و سهولت تطبیق آن با روش‌های متداول ساخت غشاء مورد توجه قرار گرفته‌اند. نانولوله‌های کربنی به‌دلیل ویژگی‌های مطلوبی از قبیل چگالی جرم کم، انعطاف‌پذیری زیاد و برهم‌کنش مؤثر بین پیوندهای نانولوله‌های کربنی و گروه‌های عاملی دارای ویژگی‌های مناسب برای بهبود عملکرد غشاهای پلیمری بوده و مورد توجه بسیاری از محققان قرار گرفته است [۲ و ۳]. با توجه به اینکه متغیرهای زیادی در مدل‌سازی غشاها بر روی هدف اصلی غشا که همان افزایش شار، کاهش گرفتگی و افزایش راندمان جداسازی است، تاثیر می‌گذارند و اینکه رفتار متغیرها لزوماً خطی نبوده و به‌صورت غیر خطی هستند و نیز این متغیرها ممکن است با هم برهم‌کنش داشته و پاسخ‌های این متغیرها متفاوت هستند، لذا از مدل‌سازی بر پایه هوش مصنوعی در این تحقیق استفاده شد که از ۴ سیستم هوشمند شبکه عصبی چند لایه (MLP)^۱، شبکه عصبی با مدار شعاعی (RBF)^۲، کمینه مربعات بردار پشتیبان (LSSVM)^۳، سیستم هیبریدی تطبیقی عصبی-فازی (ANFIS)^۴ و ۳ الگوریتم بهینه‌سازی ژنتیک (GA)^۵، ازدحام ذرات (PSO)^۶ و شبیه‌سازی تیریدی (SA)^۷ برای مدل‌سازی استفاده گردید. شبکه‌های هوشمند به‌خصوص شبکه‌های عصبی مصنوعی به‌طور موفقیت‌آمیزی به منظور مدل‌سازی

1. Multiple Layer Perceptron
2. Radial Basis Function
3. Least Squares Support Vector Machine
4. Adaptive Neuro Fuzzy Inference System
5. Generic Algorithm
6. Particle Swarm Optimization
7. Simulated Annealing

و نوع نانولوله کربنی عامل‌دار برای هر درصد پلیمر که بهترین عملکرد را با پلیمر پلی وینیلیدن فلوراید داشته باشد، به‌دست آمد.

تهیه غشاء نانو کامپوزیت: برای ساخت غشاهای اولترافیلتراسیون به روش وارونگی فاز، مقدار مشخصی از نانولوله‌های کربنی مختلف براساس تجربیات و مطالعات قبلی (۰/۱، ۰/۲، ۰/۳، ۰/۵) وزنی نسبت به پلیمر (۱۲ و ۱۱) به‌مدت ۳۰ min در حلال نرمال متیل پیرولیدون با استفاده از حمام اولتراسونیک توزیع و سپس پلیمر پلی وینیلیدن فلوراید با ۱۵٪ وزنی در محلول حل می‌گردد. سپس عامل حفره زای پلی وینیل پیرولیدون به مقدار ۱٪ (نسبت به وزن پلیمر) به محلول اضافه می‌گردد. پس از هم‌زدن محلول به‌مدت ۲۴ hr و ایجاد محلول همگن، محلول حاصل به‌مدت ۶ hr در خشک‌کن در دمای ۵۵°C قرار می‌گیرد تا حباب زدایی می‌شود. پس از عبور محلول از بستر شیشه‌ای صاف و رسیدن به دمای محیط، لایه غشا توسط فیلم کش با ضخامت ۱۵۰ μm و با سرعت ثابت بر روی بستر کشیده شده و بلافاصله در حمام انعقاد آب غوطه ور می‌گردد. بعد از حدود ۱۰ min، غشا از حمام آب در آورده شده و در ظرف حاوی آب مقطر نگهداری می‌شود [۱۳-۱۵].

مدل‌سازی با شبکه عصبی مصنوعی برای ایجاد مدل پیش‌بینی کننده گرفتگی (FRR) ۱ و شار

مدل‌سازی پارامتر گرفتگی

کل داده‌های به‌دست آمده از تست‌های مختلف برای شبیه‌سازی پارامتر گرفتگی در آزمایشگاه در جدول ۱ آورده شده است.

همچنین Bowen و همکارانش [۸] شبکه‌های عصبی برای مدل‌سازی میزان شار و زمان فیلتراسیون برای محلول سوسپانسیون سیلیکا تحت شرایط عملیاتی مختلف pH، استحکام یونی و فشار برای محلول خوراک اتانول و اسید استیک را مطالعه نمودند و در اکثر موارد توافق خوبی بین نتایج مدل و نتایج تجربی به‌دست آمده است. صالحی و همکارانش [۹ و ۱۰] مدل‌های شبکه عصبی مصنوعی و سیستم هیبریدی عصبی-فازی را برای پیشگویی شار و نرخ دفع نمک طعام از محلول آب نمک در فرآیند نانوفیلتراسیون بررسی نمودند که از غلظت‌های خوراک، دما و فشارهای مختلف به‌عنوان متغیرهای ورودی استفاده گردید که مدل شبکه عصبی با ۸ نرون و یک لایه مخفی پیشگویی خوبی برای شار و نرخ دفع نسبت به نتایج تجربی نشان داد. همچنین روش هیبرید (ترکیبی از میانگین مربعات و پس انتشار خطا) به‌عنوان روش آموزش در روش ANFIS استفاده گردید که این مدل نیز با دقت خوبی میزان شار و نرخ دفع را با کارایی بالایی نسبت به نتایج تجربی نشان داد. در تحقیق حاضر مدل‌سازی غشاهای نانوکامپوزیت اولترافیلتراسیون پلی وینیلیدن فلوراید با استفاده از نانولوله‌های کربنی عامل‌دار (چند دیواره اسیدی، چند دیواره و تک دیواره بازی و آمینی) که در آزمایشگاه ساخته شده و تست‌های مختلف شار، گرفتگی، زاویه تماس و تخلخل انجام گرفت. سپس با استفاده از ۴ نوع شبکه‌های هوشمند مدل‌سازی انجام گردید و مقایسه بین مدل‌ها انجام و بهترین مدل انتخاب گردید. سپس با استفاده از الگوریتم‌های ترکیبی ژنتیک و ازدحام ذرات با توجه به هدف تحقیق که بیشترین شار و کمترین گرفتگی هستند؛ بهینه‌سازی پارامترها انجام و سپس با استفاده از پارامترهای بهینه، مجدداً غشاها در آزمایشگاه ساخته شده و مقایسه بین مدل و نتایج تجربی صورت گرفت. سپس خطاها محاسبه گردید. با توجه به در نظر گرفتن مینیمم خطا، درصد بهینه

جدول ۱ داده‌های مورد استفاده برای شبیه‌سازی پارامتر گرفتگی

نوع نانولوله کربنی عامل‌دار	پلیمر (%)	نانولوله کربنی عامل‌دار (%)	زاویه تماس ($^{\circ}$)	تخلخل (%)	گرفتگی (%)
نانولوله کربنی چند دیواره اسپیدی	۱۵	۰	۸۷/۲	۶۳	۳۹
	۱۵	۰/۰۵	۸۴/۳۳	۷۲	۴۱
	۱۵	۰/۱	۷۴/۱۷	۷۵	۴۸
	۱۵	۰/۲	۷۵/۳۷	۸۰	۵۲
	۱۵	۰/۳	۷۳/۳۷	۸۱	۴۰
	۱۵	۰/۵	۷۳/۱۳	۷۶	۴۰
	۱۸	۰	۹۳/۷۳	۴۹	۳۴
	۱۸	۰/۰۵	۸۷/۶۳	۶۳	۴۲
	۱۸	۰/۱	۹۰/۲۳	۶۳	۵۵
	۱۸	۰/۲	۸۱/۹۷	۷۲	۶۲
	۱۸	۰/۳	۸۲/۶	۶۸	۵۸
	۱۸	۰/۵	۸۰/۲	۶۶	۵۵
نانولوله کربنی چند دیواره بازی	۱۵	۰	۸۷/۲	۶۳	۳۹
	۱۵	۰/۰۵	۸۴/۳۷	۶۷	۷۴
	۱۵	۰/۱	۷۹/۹	۷۲	۷۰
	۱۵	۰/۲	۸۲/۲۳	۷۳	۶۹
	۱۵	۰/۳	۷۴/۵۷	۷۰	۵۸
	۱۵	۰/۵	۷۱/۷۷	۶۹	۶۰
	۱۸	۰	۹۳/۷۳	۴۹	۳۴
	۱۸	۰/۰۵	۹۰/۸۳	۶۶	۵۳
	۱۸	۰/۱	۸۹/۱۳	۶۷	۶۴
	۱۸	۰/۲	۸۵/۴۷	۶۹	۷۰
	۱۸	۰/۳	۸۳/۱۷	۶۷	۶۴
	۱۸	۰/۵	۸۴/۱۳	۶۵	۵۵
نانولوله کربنی تک دیواره بازی	۱۵	۰	۸۷/۲	۶۳	۳۹
	۱۵	۰/۰۵	۸۵	۷۱	۷۲
	۱۵	۰/۱	۸۴	۷۳	۷۴
	۱۵	۰/۲	۷۹/۸۳	۷۷	۷۰
	۱۵	۰/۳	۷۹/۶	۷۴	۶۹
	۱۵	۰/۵	۸۰	۷۳	۷۰
	۱۸	۰	۹۳/۷۳	۴۹	۳۴
	۱۸	۰/۰۵	۸۱/۶۳	۶۷	۵۸
	۱۸	۰/۱	۸۱/۴	۶۹	۷۲
	۱۸	۰/۲	۴۳/۸۱	۶۹	۷۳
	۱۸	۰/۳	۸۰/۶	۶۴	۶۸
	۱۸	۰/۵	۷۹/۶	۶۲	۶۵
نانولوله کربنی آمیبی	۱۵	۰	۸۷/۲	۶۳	۳۹
	۱۵	۰/۰۵	۷۹/۷۳	۷۳	۴۱
	۱۵	۰/۱	۷۹/۳۷	۷۴	۵۱
	۱۵	۰/۲	۷۸/۱	۷۹	۵۸
	۱۵	۰/۳	۷۴/۵۷	۸۰	۴۳
	۱۵	۰/۵	۷۱/۵۳	۷۵	۴۵
	۱۸	۰	۹۳/۷۳	۴۹	۳۴
	۱۸	۰/۰۵	۸۷/۳۷	۶۳	۴۴
	۱۸	۰/۱	۸۴/۱۳	۶۵	۵۷
	۱۸	۰/۲	۸۳/۶	۷۰	۶۱
	۱۸	۰/۳	۸۱/۲۷	۶۹	۵۷
	۱۸	۰/۵	۷۹/۷۳	۶۷	۵۳

شبکه‌های ساخته شده، مقدار بهینه برای تعداد نرون‌های لایه پنهان برابر با ۱۵ به دست آمد. پس از ساخته شدن شبکه با استفاده مجموعه داده‌های اختصاص داده شده برای آموزش، داده‌های تست نیز به شبکه ارائه شد. عملکرد شبکه MLP ساخته شده در شکل‌های ۱ و ۲ و همچنین پارامترهای آماری مرتبط در جدول ۲ ارائه شده است.

RBF


در این مرحله برای شبیه‌سازی داده‌های واقعی گرفتگی از شبکه عصبی پایه شعاعی استفاده شده است. این نوع شبکه دارای ساختار ثابت سه لایه‌ای است. همانند شبکه MLP، این شبکه دارای ۵ نرون در لایه ورودی و ۱ نرون در لایه خروجی است. در این مقاله، شبکه RBF با استفاده از نرم‌افزار متلب پیاده‌سازی شده است. در پیاده‌سازی نرم‌افزار متلب، این شبکه دارای دو پارامتر تنظیم به نام‌های spread و بیشینه مقدار نرون‌ها است. مقدار بهینه این دو پارامتر منجر به بهترین عملکرد این شبکه می‌شود. برای یافتن مقادیر بهینه از الگوریتم تکاملی ژنتیک بهره گرفته شده است. برای این منظور ابتدا ۵۰ راه حل تصادفی به‌عنوان جمعیت اولیه تعیین شدند. سپس با استفاده از یک تابع سنجش عملکرد (مجذور کمینه مربعات خطا) مورد بررسی قرار گرفتند و به ترتیب عملکرد رتبه‌بندی شدند. سپس شبکه عصبی با استفاده از ابزار خود (تقاطع و جهش) طی ۳۰ نسل، جواب بهینه را حاصل کرد. به این ترتیب پس از بررسی هوشمند و هدفمند تعداد زیادی راه حل، مقدار بهینه برای پارامترهای spread و بیشینه مقدار نرون‌ها به ترتیب برابر با ۰/۵ و ۳۵ به دست آمد. پس از ساخته شدن شبکه با استفاده مجموعه داده‌های اختصاص داده شده برای آموزش، داده‌های تست نیز به شبکه ارائه شد. عملکرد شبکه RBF ساخته شده در شکل‌های ۳ و ۴ و همچنین پارامترهای آماری مرتبط در جدول ۳ ارائه شده است.

در این تحقیق ۸۰٪ داده‌های بخش مدل‌سازی برای آموزش و ۲۰٪ برای تست شبکه به صورت تصادفی انتخاب شده است. با توجه به اینکه ۴ نوع نانولوله کربنی عامل‌دار مختلف (چند دیواره اسیدی، چند دیواره و تک‌دیواره بازی و آمینی) در ساخت غشاها استفاده گردید و نوع نانولوله را نمی‌توان برای نرم‌افزار متلب تعریف نمود، لذا نوع نانولوله‌ها در مدل‌سازی یکسان در نظر گرفته شد. همان‌طور که مشخص است تعداد داده‌های بخش آموزش شبکه از موارد دیگر بیشتر است، این بدان دلیل است که شبکه براساس این داده‌ها ساخته می‌شود و باید معرف کل داده‌های مورد استفاده باشد. مرحله بعدی در آماده‌سازی داده‌ها نرمال کردن آن‌ها است. پیش از ورود داده‌ها به شبکه هوشمند، تمام داده‌ها در بازه [۱-] نرمال شدند. همسان‌سازی محدوده داده‌ها باعث بهبود عملکرد شبکه‌های هوشمند می‌شود. مرحله بعدی، انتخاب ورودی مناسب برای شبکه هوشمند است. این کار تأثیر زیادی در ساخت شبکه دارد. در حالت کلی ورودی‌هایی که با خروجی ضریب همبستگی بالاتری دارند، باعث ایجاد تخمین‌های بهتری می‌شوند.


MLP

در این مرحله برای شبیه‌سازی از یک شبکه عصبی سه لایه استفاده شد. این شبکه عصبی سه لایه، در لایه ورودی شامل ۵ نرون (درصد پلیمر، درصد نانوذره، زاویه تماس، تخلخل و نرخ پس‌دهی پروتئین) و در لایه خروجی شامل ۱ نرون است. برای هر دو لایه پنهان و خروجی از تابع فعال‌سازی سیگموئید استفاده شد. تابع هدف نیز کمینه مربعات خطا (RMSE)^۱ در نظر گرفته شد. برای یافتن تعداد بهینه نرون‌های لایه پنهان، شبکه‌های عصبی متعددی ساخته شد و عملکرد آن‌ها مورد بررسی قرار گرفت. برای این کار، برای تعداد نرون‌های ۲ تا ۳۰ عدد در لایه پنهان ساخته شد و در نهایت پس از مقایسه نتایج حاصل از

1. Root Mean Square Error





نرخ بازیابی شار تجربی (%)



نرخ بازیابی شار تجربی (%)


شکل ۱ الف) نمودار متقاطع نشان دهنده ضریب همبستگی بین مقادیر پیش بینی شده و داده های واقعی توسط شبکه MLP برای داده های آموزش و تست. و ب) نمودار نشان دهنده خطای نسبی برای داده های آموزش و تست مربوط به شبکه طراحی شده MLP




شکل ۲ مقایسه بین مقادیر پیش بینی شده توسط شبکه MLP با داده های واقعی الف) داده های آموزش و ب) داده های تست

جدول ۲ پارامترهای آماری مربوط به شبکه عصبی MLP

تعداد داده ها	ریشه میانگین مربعات خطا	انحراف استاندارد	انحراف نسبی متوسط	ضریب همبستگی	
۳۶	۲/۵۸۷۵۲۷	۰/۰۴۴۹۶	۲/۸۰۷۰۲۵	۰/۹۶۰۵۹	داده آموزش
۱۲	۵/۸۱۵۵۳۶	۰/۱۰۱۷۹۶	۷/۱۴۹۲۳۶	۰/۷۷۵۵۶۱	داده تست
۴۸	۳/۶۷۱۰۴۷	۰/۰۶۳۷۴۱	۳/۸۹۲۵۷۷	۰/۹۱۷۶۶۲	کل داده ها





نرخ بازیابی شار تجربی (%)



نرخ بازیابی شار تجربی (%)

شکل ۳ الف) نمودار متقاطع نشان دهنده ضریب همبستگی بین داده های واقعی و مقادیر پیش بینی شده توسط شبکه RBF برای داده های آموزش و تست. و ب) نمودار نشان دهنده خطای نسبی برای داده های آموزش و تست مربوط به شبکه طراحی شده RBF.



شکل ۴ مقایسه بین مقادیر پیش‌بینی شده توسط شبکه RBF با داده‌های واقعی RBF (الف) داده‌های آموزش و (ب) داده‌های تست.

جدول ۳ پارامترهای آماری مربوط به شبکه عصبی RBF.

تعداد داده‌ها	ریشه میانگین مربعات خطا	انحراف استاندارد	انحراف نسبی متوسط	ضریب همبستگی	
۳۶	$7/87 \times 10^{-14}$	$1/61 \times 10^{-15}$	23×10^{-14}	۱	داده آموزش
۱۲	۳/۴۰۳۹۳۷	۰/۰۵۳۱۵۶	۴/۱۷۱۷۴۴	۰/۹۳۲۴۶۴	داده تست
۴۸	۱/۷۰۱۹۶۸	۰/۰۲۸۰۲۶	۱/۰۴۲۹۳۶	۰/۹۸۲۹۵۶	کل داده‌ها

گفته می‌شود. همچنین روش دومی که برای آموزش وجود دارد استفاده از الگوریتم بهینه‌سازی به نام الگوریتم بهینه‌سازی ازدحام ذرات است. در این روش ساختار سیستم استنتاج فازی ابتدایی به‌عنوان یک مسئله بهینه‌سازی تلقی می‌شود. اما در تحقیق حاضر از یک روش جدید که ترکیب دو روش یاد شده است برای آموزش استفاده شده است. این روش دارای ۵۰ مرحله است که هر مرحله آن ترکیبی از ۵ مرحله روش هیبرید و ۱ مرحله روش PSO است. هر مرحله از روش هیبرید دارای ۱۰ اگر-آن‌گاه و هر مرحله از روش PSO دارای ۲۰۰ اگر-آن‌گاه است. پس از ساخته شدن شبکه با استفاده از مجموعه داده‌های اختصاص داده شده برای آموزش، داده‌های تست نیز به شبکه ارائه شد. عملکرد شبکه LSSVM ساخته شده در شکل‌های ۵ و ۶ و همچنین پارامترهای آماری مرتبط در جدول ۴ ارائه شده است.

مقایسه مدل‌ها برای پارامتر گرفتگی

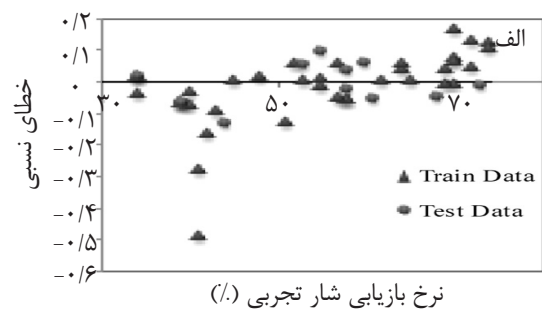

نتایج کلی مدل‌سازی پارامتر گرفتگی در جدول ۶ ارائه شده است. مقایسه مدل‌های مختلف در شکل ۹ آورده شده است.

LSSVM



در این مرحله برای پیش‌بینی مقدار گرفتگی از سیستم هوشمند کمینه مربعات بردار پشتیبان استفاده شده است. این شبکه دارای دو پارامتر تنظیم به نام‌های γ و σ است. مقدار بهینه برای این دو پارامتر با استفاده از الگوریتم شبیه‌سازی تبرید مورد محاسبه قرار گرفتند و به ترتیب برابر با ۱۵/۳۱ و ۶/۶۲ تعیین شدند. پس از ساخته شدن شبکه با استفاده از مجموعه داده‌های اختصاص داده شده برای آموزش، داده‌های تست نیز به شبکه ارائه شد. عملکرد شبکه LSSVM ساخته شده در شکل‌های ۵ و ۶ و همچنین پارامترهای آماری مرتبط در جدول ۴ ارائه شده است.

ANFIS

برای پیش‌بینی مقادیر هدف توسط این روش ابتدا با استفاده از روش Subclast Clustering (SC) یک سیستم استنتاج فازی ابتدایی ساخته شد. در مرحله بعد باید با استفاده از یک روش مناسب این سیستم ابتدایی آموزش داده شود تا بهترین عملکرد را برای مدل فراهم کرد. به‌طور کلی دو روش برای آموزش وجود دارد. روش اول یک روش از پیش تعیین شده توسط نرم‌افزار متلب است که به آن روش هیبرید





شکل ۵ الف) نمودار متقاطع نشان‌دهنده ضریب همبستگی بین مقادیر واقعی و مقادیر پیش‌بینی شده توسط شبکه LSSVM برای داده‌های آموزش و تست و ب) نمودار نشان‌دهنده خطای نسبی برای داده‌های آموزش و تست مربوط به شبکه طراحی شده LSSVM.




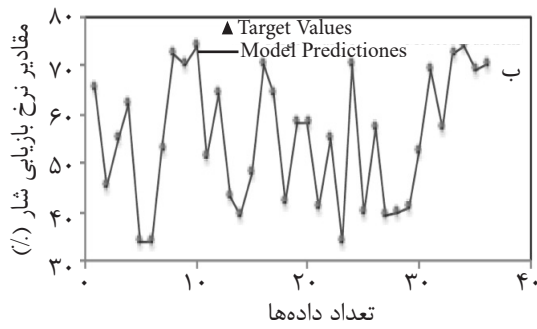
شکل ۶ مقایسه بین مقادیر پیش‌بینی شده توسط شبکه LSSVM با داده‌های واقعی الف) داده‌های آموزش و ب) داده‌های تست.

جدول ۴ پارامترهای آماری مربوط به شبکه عصبی LSSVM

تعداد داده‌ها	ریشه میانگین مربعات خطا	انحراف استاندارد	انحراف نسبی متوسط	ضریب همبستگی	
۳۶	۵/۶۸۶۱۷۸	۰/۱۱۶۶۹۷	۷/۳۶۵۸۱۵	۰/۸۱۹۵۱	داده آموزش
۱۲	۳/۲۲۹۱۷۷	۰/۰۶۵۶۷	۵/۵۱۳۲۰۵	۰/۹۲۶۵۴	داده تست
۴۸	۵/۱۸۲۳۱۳	۰/۱۰۵۶	۶/۹۰۲۶۶۳	۰/۸۳۸۱۴۴	کل داده‌ها



شکل ۷ الف) نمودار متقاطع نشان‌دهنده ضریب همبستگی بین مقادیر واقعی و مقادیر پیش‌بینی شده توسط شبکه ANFIS برای داده‌های آموزش و تست و ب) نمودار نشان‌دهنده خطای نسبی برای داده‌های آموزش و تست مربوط به شبکه طراحی شده ANFIS.




شکل ۸ مقایسه بین مقادیر پیش‌بینی شده توسط شبکه ANFIS با داده‌های واقعی (الف) داده‌های آموزش و (ب) داده‌های تست.

جدول ۵ پارامترهای آماری مربوط به شبکه عصبی ANFIS

تعداد داده‌ها	ریشه میانگین مربعات خطا	انحراف استاندارد	انحراف نسبی متوسط	ضریب همبستگی	
۳۶	$3/13 \times 10^{-15}$	$6/26 \times 10^{-17}$	$2/04 \times 10^{-15}$	۱	داده آموزش
۱۲	۳/۵۳۱۳۵۹	۰/۰۴۸۸۴۵	۴/۰۳۸۹۸۸	۰/۹۶۳۸۳۵	داده تست
۴۸	۱/۷۶۵۶۸	۰/۰۲۸۵۰۶	۱/۰۰۹۷۴۷	۰/۹۸۳۷۲۶	کل داده‌ها

جدول ۶ نتایج کلی مدل‌سازی با استفاده از شیوه‌های مختلف.

تعداد داده‌ها	ریشه میانگین مربعات خطا	انحراف استاندارد	انحراف نسبی متوسط	ضریب همبستگی	داده آموزش	داده تست	کل داده‌ها
شبکه چند لایه	۲/۵۸۷۵۲۷	۰/۰۴۴۹۶	۲/۸۰۷۰۲۵	۰/۹۶۰۵۰۹	داده آموزش	داده تست	۳۶
	۵/۸۱۵۵۳۶	۰/۱۰۱۷۹۶	۷/۱۴۹۲۳۶	۰/۷۷۵۵۶۱	داده آموزش	داده تست	۱۲
	۳/۶۷۱۰۴۷	۰/۰۶۳۷۴۱	۳/۸۹۲۵۷۷	۰/۹۱۷۶۶۲	داده آموزش	داده تست	۴۸
شبکه مدار شعاعی	$87/7 \times 10^{-14}$	$61/1 \times 10^{-15}$	$23/8 \times 10^{-14}$	۱	داده آموزش	داده تست	۳۶
	۳/۴۰۳۹۳۷	۰/۰۵۳۱۵۶	۴/۱۷۱۷۴۴	۰/۹۳۲۴۶۴	داده آموزش	داده تست	۱۲
	۱/۷۰۱۹۶۸	۰/۰۲۸۰۲۶	۱/۰۴۲۹۳۶	۰/۹۸۲۹۵۶	داده آموزش	داده تست	۴۸
شبکه کم‌ترین مربعات پشتیبان	۵/۶۸۶۱۷۸	۰/۱۱۶۶۹۷	۷/۳۶۵۸۱۵	۰/۸۱۹۵۱	داده آموزش	داده تست	۳۶
	۳/۲۲۹۱۷۷	۰/۰۶۵۶۷	۵/۵۱۳۲۰۵	۰/۹۲۶۵۴	داده آموزش	داده تست	۱۲
	۵/۱۸۲۳۱۳	۰/۱۰۵۶	۶/۹۰۲۶۶۳	۰/۸۳۸۱۴۷	داده آموزش	داده تست	۴۸
شبکه هیبرید عصبی-فازی	$3/13 \times 10^{-15}$	$6/26 \times 10^{-17}$	$2/04 \times 10^{-15}$	۱	داده آموزش	داده تست	۳۶
	۳/۵۳۱۳۵۹	۰/۰۴۸۸۴۵	۴/۰۳۸۹۸۸	۰/۹۶۳۸۳۵	داده آموزش	داده تست	۱۲
	۱/۷۶۵۶۸	۰/۰۲۸۵۰۶	۱/۰۰۹۷۴۷	۰/۹۸۳۷۲۶	داده آموزش	داده تست	۴۸



شکل ۹ مقایسه مدل‌های مختلف

۳۲ به‌دست آمد. عملکرد شبکه RBF ساخته شده در شکل‌های ۱۲ و ۱۳ و همچنین پارامترهای آماری مرتبط در جدول ۹ ارائه شده است.

LSSVM

در این مرحله نیز شبیه مراحل مدل‌سازی برای پیش‌بینی پارامتر گرفتگی انجام شد. مقدار بهینه برای دو پارامتر γ و c با استفاده از الگوریتم شبیه‌سازی تبرید مورد محاسبه قرار گرفتند و به‌ترتیب برابر با $1566/22$ و $8/62$ تعیین شدند. عملکرد شبکه LSSVM ساخته شده در شکل‌های ۱۴ و ۱۵ و همچنین پارامترهای آماری مرتبط در جدول ۱۰ ارائه شده است.

ANFIS

در این مدل‌سازی هم شبیه مدل‌سازی برای پیش‌بینی پارامتر گرفتگی انجام شد. این روش دارای ۵۰ مرحله است که هر مرحله آن ترکیبی از ۵ مرحله روش هیبرید و ۱ مرحله روش PSO است. هر مرحله از روش هیبرید دارای ۱۰ اگر-آنگاه و هر مرحله از روش PSO دارای ۲۰۰ اگر-آنگاه است. پس از ساخته شدن شبکه با استفاده از مجموعه داده‌های اختصاص داده شده برای آموزش، داده‌های تست نیز به شبکه ارائه شد. عملکرد شبکه ANFIS ساخته شده در شکل‌های ۱۶ و ۱۷ و همچنین پارامترهای آماری مرتبط در جدول ۱۱ ارائه شده است.

مقایسه مدل‌ها برای پارامتر شار

نتایج کلی مدل‌سازی پارامتر شار در جدول ۱۲ و همچنین مقادیر RMSE در شکل ۱۸ ارائه شده است. بنابراین از جدول ۱۱ با توجه به پارامترهای خطا کاملاً مشخص است که شبکه‌های GA-RBF و ANFIS با توجه به پارامترهای آماری فوق که ضریب همبستگی نزدیک به عدد یک داشته و میانگین مربعات خطای آنها به عدد صفر نزدیک‌تر هستند، از دقت بالاتری نسبت به شبکه‌های دیگر برخوردار هستند.

بنابراین از جدول ۶ و شکل ۹ با توجه به پارامترهای خطا مشاهده می‌شود که شبکه‌های GA-RBF و ANFIS با توجه به پارامترهای آماری فوق که ضریب همبستگی نزدیک به عدد یک داشته و میانگین مربعات خطای آنها به عدد صفر نزدیک‌تر هستند، توانایی و کارایی بسیار بیشتری نسبت به شبکه‌های دیگر از خود نشان داده است.

مدل‌سازی پارامتر شار

کل داده‌های به‌دست آمده از تست‌های مختلف در آزمایشگاه در جدول ۷ آورده شده است. در این حالت نیز ۸۰٪ داده‌های بخش مدل‌سازی برای آموزش و ۲۰٪ برای تست شبکه به‌صورت تصادفی انتخاب شده است. با توجه به اینکه ۴ نوع نانولوله کربنی عامل‌دار مختلف (اسیدی، بازی و آمینی) در ساخت غشاها استفاده گردید و نوع نانولوله را نمی‌توان برای نرم‌افزار متلب تعریف نمود، لذا نوع نانولوله‌ها در مدل‌سازی یکسان در نظر گرفته شد.

MLP



در این مرحله شبیه مراحل مدل‌سازی برای پیش‌بینی گرفتگی انجام شد. در این حالت، برای تعداد نرون‌های ۲ تا ۳۰ عدد در لایه پنهان ساخته شد و در نهایت پس از مقایسه نتایج حاصل از شبکه‌های ساخته شده، مقدار بهینه برای تعداد نرون‌های لایه پنهان برابر با ۳ به‌دست آمد. عملکرد شبکه MLP ساخته شده در شکل‌های ۱۰ و ۱۱ و همچنین پارامترهای آماری مرتبط در جدول ۸ ارائه شده است.

RBF



در این مرحله نیز شبیه مراحل مدل‌سازی برای پیش‌بینی گرفتگی انجام شد. برای این منظور ابتدا ۵۰ راه حل تصادفی به‌عنوان جمعیت اولیه تعیین شدند. سپس شبکه عصبی با استفاده از ابزار خود (تقاطع و جهش) طی ۳۰ نسل، جواب بهینه را حاصل کرد. مقدار بهینه برای پارامترهای spread و بیشینه مقدار نرون‌ها به‌ترتیب برابر با $1/08$ و

جدول ۷ داده‌های مورد استفاده در شبیه‌سازی برای پارامتر شار

نوع نانولوله کربنی عامل‌دار	پلیمر (%)	نانولوله کربنی عامل‌دار (%)	زاویه تماس (°)	تخلخل (%)	شار
نانولوله کربنی چند دیواره اسپیدی	۱۵	۰	۸۷/۲	٪۶۳	۱۴۶
	۱۵	۰/۰۵	۸۴/۳۳	٪۷۲	۲۵۳
	۱۵	۰/۱	۷۴/۱۷	٪۷۵	۳۳۸
	۱۵	۰/۲	۷۵/۳۷	٪۸۰	۳۴۴
	۱۵	۰/۳	۷۳/۳۷	٪۸۱	۳۵۶
	۱۵	۰/۵	۷۳/۱۳	٪۷۶	۳۰۴
	۱۸	۰	۹۳/۷۳	٪۴۹	۱۵۳
	۱۸	۰/۰۵	۸۷/۶۳	٪۶۳	۲۴۴
	۱۸	۰/۱	۹۰/۲۳	٪۶۳	۲۶۲
	۱۸	۰/۲	۸۱/۹۷	٪۷۲	۳۴۱
	۱۸	۰/۳	۸۲/۶	٪۶۸	۲۹۸
	۱۸	۰/۵	۸۰/۲	٪۶۶	۲۲۶
نانولوله کربنی چند دیواره بازی	۱۵	۰	۸۷/۲	٪۶۳	۱۴۶
	۱۵	۰/۰۵	۸۴/۳۷	٪۶۷	۲۱۷
	۱۵	۰/۱	۷۹/۹	٪۷۲	۲۸۱
	۱۵	۰/۲	۸۲/۲۳	٪۷۳	۲۶۴
	۱۵	۰/۳	۷۴/۵۷	٪۷۰	۲۵۷
	۱۵	۰/۵	۷۱/۷۷	٪۶۹	۲۳۲
	۱۸	۰	۹۳/۷۳	٪۴۹	۱۵۳
	۱۸	۰/۰۵	۹۰/۸۳	٪۶۶	۲۱۲
	۱۸	۰/۱	۸۹/۱۳	٪۶۷	۳۰۳
	۱۸	۰/۲	۸۵/۴۷	٪۶۹	۳۴۳
	۱۸	۰/۳	۸۳/۱۷	٪۶۷	۲۹۴
	۱۸	۰/۵	۸۴/۱۳	٪۶۵	۲۴۵
نانولوله کربنی تک دیواره بازی	۱۵	۰	۸۷/۲	٪۶۳	۱۴۶
	۱۵	۰/۰۵	۸۵	٪۷۱	۲۳۹
	۱۵	۰/۱	۸۴	٪۷۳	۳۰۵
	۱۵	۰/۲	۷۹/۸۳	٪۷۷	۳۰۳
	۱۵	۰/۳	۷۹/۶	٪۷۴	۲۷۰
	۱۵	۰/۵	۸۰	٪۷۳	۲۲۸
	۱۸	۰	۹۳/۷۳	٪۴۹	۱۵۳
	۱۸	۰/۰۵	۸۱/۶۳	٪۶۷	۲۵۰
	۱۸	۰/۱	۸۱/۴	٪۶۹	۳۴۲
	۱۸	۰/۲	۸۱/۴۳	٪۶۹	۳۶۸
	۱۸	۰/۳	۸۰/۶	٪۶۴	۳۱۰
	۱۸	۰/۵	۷۹/۶	٪۶۲	۲۹۰
نانولوله کربنی آمیننی	۱۵	۰	۸۷/۲	٪۶۳	۱۴۶
	۱۵	۰/۰۵	۷۹/۷۳	٪۷۳	۲۷۰
	۱۵	۰/۱	۷۹/۳۷	٪۷۴	۳۶۵
	۱۵	۰/۲	۷۸/۱	٪۷۹	۳۸۴
	۱۵	۰/۳	۷۴/۵۷	٪۸۰	۳۶۸
	۱۵	۰/۵	۷۱/۵۳	٪۷۵	۳۴۱
	۱۸	۰	۹۳/۷۳	٪۴۹	۱۵۳
	۱۸	۰/۰۵	۸۷/۳۷	٪۶۳	۲۷۵
	۱۸	۰/۱	۸۴/۱۳	٪۶۵	۲۹۳
	۱۸	۰/۲	۸۳/۶	٪۷۰	۳۶۰
	۱۸	۰/۳	۸۱/۲۷	٪۶۹	۳۱۲
	۱۸	۰/۵	۷۹/۷۳	٪۶۷	۲۵۵





شکل ۱۰ الف) نمودار متقاطع نشان‌دهنده ضریب همبستگی بین مقادیر پیش‌بینی شده و داده‌های واقعی توسط شبکه MLP برای داده‌های آموزش و تست و ب) نمودار نشان‌دهنده خطای نسبی برای داده‌های آموزش و تست مربوط به شبکه طراحی شده MLP




شکل ۱۱ مقایسه بین مقادیر پیش‌بینی شده توسط شبکه MLP با داده‌های واقعی الف) داده‌های آموزش و ب) داده‌های تست

جدول ۸ پارامترهای آماری مربوط به شبکه عصبی MLP.

تعداد داده‌ها	ریشه میانگین مربعات خطا	انحراف استاندارد	انحراف نسبی متوسط	ضریب همبستگی	
۳۶	۰/۰۰۱۱۸۸	$۴/۱۵ \times 10^{-6}$	۰/۰۰۰۱۴۷	۱	داده آموزش
۱۲	۲۵/۱۹۴۷۶	۰/۰۸۹۴۹۴	۶/۱۰۲۰۷۴	۰/۹۲۹۹۰۲	داده تست
۴۸	۱۲/۵۹۷۳۸	۰/۰۴۵۱۹۸	۱/۵۲۵۶۲۹	۰/۹۷۰۶۰۳	کل داده‌ها




شکل ۱۲ الف) نمودار متقاطع نشان‌دهنده ضریب همبستگی بین داده‌های واقعی و مقادیر پیش‌بینی شده توسط شبکه RBF برای داده‌های آموزش و تست و ب) نمودار نشان‌دهنده خطای نسبی برای داده‌های آموزش و تست مربوط به شبکه طراحی شده RBF




شکل ۱۳ مقایسه بین مقادیر پیش‌بینی شده توسط شبکه RBF با داده‌های واقعی (الف) داده‌های آموزش و (ب) داده‌های تست

جدول ۹ پارامترهای آماری مربوط به شبکه عصبی RBF

تعداد داده‌ها	ضریب همبستگی	انحراف نسبی متوسط	انحراف استاندارد	ریشه میانگین مربعات خطا	تعداد داده‌ها
۳۶	۰/۹۹۹۶۷۱	۰/۳۰۳۱۱۷	۰/۰۰۴۴۵۷	۱/۲۱۲۸۱۸	داده آموزش
۱۲	۰/۹۹۱۵۹۸	۱/۹۵۲۴۷۵	۰/۰۲۷۱۲۸	۷/۲۸۷۸۱۱	داده تست
۴۸	۰/۹۹۷۰۰۹	۰/۷۱۵۴۵۷	۰/۰۱۳۶۹۳	۳/۷۹۲۲۶۱	کل داده‌ها





شکل ۱۴ الف) نمودار نشان‌دهنده ضریب همبستگی بین مقادیر واقعی و مقادیر پیش‌بینی شده توسط شبکه LSSVM برای داده‌های آموزش و تست و (ب) نمودار نشان‌دهنده خطای نسبی برای داده‌های آموزش و تست مربوط به شبکه طراحی شده LSSVM





شکل ۱۵ مقایسه بین مقادیر پیش‌بینی شده توسط شبکه LSSVM با داده‌های واقعی (الف) داده‌های آموزش و (ب) داده‌های تست

جدول ۱۰ پارامترهای آماری مربوط به شبکه عصبی LSSVM

تعداد داده‌ها	ضریب همبستگی	انحراف نسبی متوسط	انحراف استاندارد	ریشه میانگین مربعات خطا	تعداد داده‌ها
۳۶	۰/۹۹۸۰۰۶	۰/۶۶۲۰۱۸	۰/۰۱۰۹۰۷	۳/۰۲۴۱۰۲	داده آموزش
۱۲	۰/۹۱۹۲۶۲	۴/۴۸۸۴۲۱	۰/۰۷۰۱۸۹	۲۱/۹۳۱۱۸	داده تست
۴۸	۰/۹۷۳۷۳۱	۱/۶۱۸۶۱۸	۰/۰۳۵۳۵۷	۱۱/۲۷۴	کل داده‌ها



شکل ۱۶ الف) نمودار متقاطع نشان‌دهنده ضریب همبستگی بین مقادیر واقعی و مقادیر پیش‌بینی شده توسط شبکه ANFIS برای داده‌های آموزش و تست و ب) نمودار نشان‌دهنده خطای نسبی برای داده‌های آموزش و تست




شکل ۱۷ مقایسه بین مقادیر پیش‌بینی شده توسط شبکه ANFIS با داده‌های واقعی الف) داده‌های آموزش و ب) داده‌های تست

جدول ۱۱ پارامترهای آماری مربوط به شبکه عصبی ANFIS

تعداد داده‌ها	ضریب همبستگی	انحراف نسبی متوسط	انحراف استاندارد	ریشه میانگین مربعات خطا	تعداد داده‌ها
داده آموزش	۱	$1/9 \times 10^{-4}$	$2/59 \times 10^{-4}$	$6/48 \times 10^{-4}$	۳۶
داده تست	۰/۹۸۱۰۰۲	۲/۷۰۵۳۸۴	۰/۰۳۶۳۷۶	۱۰/۹۸۴۵۴	۱۲
کل داده‌ها	۰/۹۹۳۸۶۹	۰/۶۷۶۳۴۶	۰/۰۱۸۶۸۳	۵/۴۹۲۲۷۲	۴۸

جدول ۱۲ نتایج کلی مدل‌سازی با استفاده از شیوه‌های مختلف

تعداد داده‌ها	ریشه میانگین مربعات خطا	انحراف استاندارد	انحراف نسبی متوسط	ضریب همبستگی	داده آموزش	شبکه چند لایه
۳۶	۰/۰۰۱۱۸۸	$4/15 \times 10^{-6}$	۰/۰۰۰۱۴۷	۱	داده آموزش	شبکه چند لایه
۱۲	۲۵/۱۹۴۷۶	۰/۰۸۹۴۹۴	۶/۱۰۲۰۷۴	۰/۹۲۹۹۰۲	داده تست	
۴۸	۱۲/۵۹۷۳۸	۰/۰۴۵۱۹۸	۱/۵۲۵۶۲۹	۰/۹۷۰۶۰۳	کل داده‌ها	
۳۶	۱/۲۱۲۸۱۸	۰/۰۰۴۴۵۷	۰/۳۰۳۱۱۷	۰/۹۹۹۶۷۱	داده آموزش	شبکه مدار شعاعی
۱۲	۷/۲۸۷۸۱۱	۰/۰۲۷۱۲۸	۱/۹۵۲۴۷۵	۰/۹۹۱۵۹۸	داده تست	
۴۸	۳/۷۹۲۲۶۱	۰/۰۱۳۶۹۳	۰/۷۱۵۴۵۷	۰/۹۹۷۰۹	کل داده‌ها	
۳۶	۳/۰۲۴۱۰۲	۰/۰۱۰۹۰۷	۰/۶۶۲۰۱۸	۰/۹۹۸۰۰۶	داده آموزش	شبکه کم‌ترین مربعات پشتیبان
۱۲	۲۱/۹۳۱۱۸	۰/۰۷۰۱۸۹	۴/۴۸۸۴۲۱	۰/۹۱۹۲۶۲	داده تست	
۴۸	۱۱/۲۷۴	۰/۰۳۵۳۵۷	۱/۶۱۸۶۱۸	۰/۹۷۳۷۳۱	کل داده‌ها	
۳۶	$6/48 \times 10^{-4}$	$2/59 \times 10^{-4}$	$1/9 \times 10^{-4}$	۱	داده آموزش	شبکه هیبرید عصبی-فازی
۱۲	۱۰/۹۸۴۵۴	۰/۰۳۶۳۷۶	۲/۷۰۵۳۸۴	۰/۹۸۱۰۰۲	داده تست	
۴۸	۵/۴۹۲۲۷۲	۰/۰۱۸۶۸۳	۰/۶۷۶۳۴۶	۰/۹۹۳۸۶۹	کل داده‌ها	



شکل ۱۸ مقایسه مدل‌های مختلف

مشهود است.

نتایج به‌دست آمده از ساخت مجدد غشا در آزمایشگاه با استفاده از نتایج بهینه به‌دست آمده از مدل و محاسبه خطاها

با استفاده از نتایج شبیه‌سازی برای هر نوع درصد پلیمر (۱۵٪ و ۱۸٪) غشاهای نانوکامپوزیت با استفاده از نانولوله‌های کربنی (چند دیواره اسیدی، چند دیواره بازی و تک دیواره بازی) مجدداً در آزمایشگاه ساخته شده و سپس تست‌های شار، گرفتگی، زاویه تماس و تخلخل انجام گردید. جهت مقایسه نتایج مدل با نتایج تجربی با توجه به اینکه نوع نانولوله کربنی را در مدل‌سازی نمی‌توان در نرم‌افزار متلب تعریف نمود، لذا نتایج خروجی از مدل برای همه نانولوله کربنی مختلف در هر درصد پلیمر یکسان در نظر گرفته شد و سپس نتایج آن با نتایج مدل مقایسه و خطاها به شرح جدول ۱۴ محاسبه گردید. با توجه به در نظر گرفتن مینیمم خطا، ۰/۰۷٪ وزنی نانولوله کربنی تک دیواره بازی برای غشای نانوکامپوزیت پلیمری ۱۵٪ PVDF و ۰/۱۹٪ وزنی نانولوله کربنی تک دیواره بازی برای غشای پلیمری ۱۸٪ PVDF بهترین عملکرد را داشته است.

یافتن شرایط بهینه پارامترهای آزمایشگاهی

در این بخش هدف به‌دست آوردن مقادیر بهینه برای شرایطی است که طی آن گرفتگی به کمینه خود برسد و همزمان مقادیر شار نیز بالا باشد. برای این کار از بهترین مدل‌های ساخته شده برای هر دو خروجی استفاده خواهد شد. یک الگوریتم ترکیبی از ژنتیک و ازدحام ذرات کار یافتن مقادیر بهینه را انجام می‌دهد. از مجذور کمینه مربعات خطای مربوط به هر سه پارامتر به‌عنوان تابع هدف استفاده شده است. نزدیک شدن پارامتر گرفتگی به کمترین مقدار نسبت به ماکزیمم شدن مقدار شار دارای اهمیت بیشتری در نظر گرفته شده است. یکی از پارامترها نوع پلیمر است. در مسئله حال حاضر از دو نوع پلیمر استفاده شده است. به همین علت یافتن مقادیر بهینه در دو حالت پلیمر PVDF ۱۵٪ و PVDF ۱۸٪ انجام گرفته است. در ابتدا جمعیتی تصادفی از پاسخ‌ها محتمل به تعداد ۳۰۰ مورد ایجاد شد. سپس بعد از ۵۰ نسل به شرایط بهینه همگرا می‌شود. تابع هدف مقدار مجذور کمینه مربعات پارامتر گرفتگی و شار در نظر گرفته شده است. شرایط بهینه هر دو پلیمر جهت به حداقل رسیدن گرفتگی و حداکثر رسیدن شار در جدول ۱۳

جدول ۱۳ مقادیر بهینه پیش‌بینی شده

درصد پلیمر	درصد نانوذره	زاویه تماس (درجه)	درصد تخلخل	درصد میزان پس‌دهی پروتئین	درصد نرخ بازیابی شار	میزان شار (کیلوگرم/ساعت/مترمربع)
۱۵	۰/۰۷۲۴۳۵۶۴	۸۸/۱۳۶۷۱۰۹۷	۰/۸۲۴۷۷۲۴	۹۹/۶۵۲۵۴۶۷	۷۸/۰۶	۲۶۷/۳
۱۸	۰/۱۹۱۳۲۴۵۶	۷۹/۹۰۷۹۰۶۶۴	۰/۷۸۴۷۳۴	۹۹/۷۴۶۳۴۵۴۲۸	۶۸/۳۱	۴۰۱/۱

جدول ۱۴ نتایج تست‌های مدل و اعداد تجربی

PVDF %۱۸			PVDF %۱۵			نوع غشا
%۰/۱۹ نانولوله تک دیواره بازی	%۰/۱۹ چند دیواره اسیدی	%۰/۱۹ چند دیواره بازی	%۰/۰۷ تک دیواره بازی	%۰/۰۷ چند دیواره اسیدی	%۰/۰۷ نانولوله چند دیواره بازی	
۴۰/۱/۱	۴۰/۱/۱	۴۰/۱/۱	۲۶۷/۳	۲۶۷/۳	۲۶۷/۳	شار مدل
۳۶۵	۳۴۱	۳۵۰	۲۶۱	۲۴۰	۲۵۹	شار اندازه‌گیری شده
۱۰	۱۵	۱۳	۲	۱۰	۳	درصد خطا
۶۸/۳	۶۸/۳	۶۸/۳	۷۸	۷۸	۷۸	گرفتگی مدل
۷۰	۶۲	۷۴	۷۳	۵۱	۷۰	گرفتگی اندازه‌گیری شده
۲	۹	۸	۶	۳۴	۱۰	درصد خطا
۷۹/۹	۷۹/۹	۷۹/۹	۸۸/۱	۸۸/۱	۸۸/۱	زاویه تماس مدل
۸۰	۸۲	۸۴	۸۲	۷۵	۸۱	زاویه تماس اندازه‌گیری شده
۰	۳	۵	۷	۱۵	۸	درصد خطا
۷۸/۴	۷۸/۴	۷۸/۴	۸۲/۴	۸۲/۴	۸۲/۴	تخلخل مدل
۷۲	۶۸	۶۹	۷۵	۷۰	۷۲	تخلخل اندازه‌گیری شده
۸	۱۳	۱۲	۹	۱۵	۱۳	درصد خطا

نتیجه‌گیری

به اینکه ۴ نوع نانولوله کربنی عامل‌دار مختلف (اسیدی، بازی و آمینی) در ساخت غشاها استفاده گردید و نوع نانولوله را نمی‌توان برای نرم‌افزار متلب تعریف نمود، لذا نوع نانولوله‌ها در مدل‌سازی یکسان در نظر گرفته شد. همان‌طور که شکل‌ها و جداول نشان می‌دهند هر یک از مدل‌ها با نسبتی مشخص توانایی لازم برای پیش‌بینی مقادیر شار و گرفتگی برای غشاهای نانوکامپوزیت را دارا هستند لذا برخی از آنها برای پیش‌بینی پارامترهای فوق برای غشاها پیشنهاد می‌شود. با توجه به ضریب همبستگی به‌دست آمده برای هر سیستم و اینکه ضریب همبستگی نزدیک به عدد یک دقت خوبی

در تحقیق حاضر، غشاهای اولترافیلتراسیون PVDF با دو غلظت ۱۵ و ۱۸٪ به روش وارونگی فاز و با استفاده از حلال NMP در آزمایشگاه ساخته شد. در ادامه برای بهبود خواص آبدوستی و کاهش گرفتگی این غشاها از نانولوله‌های کربنی (چند دیواره اسیدی، چند دیواره و تک دیواره بازی و آمینی) با غلظت‌های مختلف ۰/۰۵، ۰/۱، ۰/۲، ۰/۳ و ۰/۵ وزنی نسبت به وزن پلیمر استفاده شد. نتایج مدل‌سازی با استفاده از ۴ سیستم هوشمند شبکه عصبی چند لایه، شبکه عصبی پایه شعاعی، کمینه مربعات بردار پشتیبان و شبکه هیبرید عصبی-فازی انجام گرفت. با توجه

برای هر نوع درصد پلیمر، غشاهای نانوکامپوزیت (با نانولوله‌های کربنی عامل‌دار چند دیواره اسیدی، چند دیواره بازی و تک دیواره بازی) در آزمایشگاه مجدداً ساخته شده و سپس تست‌های شار، گرفتگی، زاویه تماس و تخلخل انجام شده و نتایج تجربی با نتایج مدل مقایسه و خطاها محاسبه گردید لذا به دلایل قبلی نتایج خروجی از مدل برای همه نانولوله‌های کربنی فوق در هر درصد پلیمر یکسان در نظر گرفته شد و سپس نتایج آن با نتایج مدل مقایسه و خطاها محاسبه گردید. با توجه به در نظر گرفتن مینیمم خطا، غشای نانوکامپوزیت ۰/۰۷٪ وزنی نانولوله کربنی تک دیواره عامل‌دار شده با گروه هیدروکسیل و غشای نانوکامپوزیت ۰/۱۹٪ وزنی نانولوله کربنی تک دیواره عامل‌دار شده با گروه هیدروکسیل به ترتیب بهترین عملکرد را با پلیمرهای ۰/۱۵٪ وزنی و ۰/۱۸٪ وزنی PVDF داشته است.

برای شبکه‌های هوشمند است (برای پارامتر گرفتگی مقدار R^2 به ترتیب برای مدل‌های GA-RBF و ANFIS برابر ۰/۹۸۲ و ۰/۹۸۳) و همچنین با توجه به اینکه پارامتر میانگین مربعات خطا نزدیک به عدد صفر مناسب برای شبکه است، لذا برای پارامترهای شار و گرفتگی می‌توان نتیجه گرفت که بهترین مدل، مدل GA-RBF و ANFIS هستند. در بخش بعدی مدل‌سازی برای به دست آوردن مقادیر بهینه (بیشترین گرفتگی و ماکزیمم شار) از بهترین مدل‌های ساخته شده برای هر دو خروجی استفاده شد و سپس از الگوریتم ترکیبی از الگوریتم ژنتیک و ازدحام ذرات مقادیر بهینه به دست آمد. برای پلیمر PVDF ۰/۱۵٪ مقدار بهینه نانوذره ۰/۰۷٪ با مقدار شار $267/3 \text{ L/m}^2\text{h}$ ، گرفتگی ۰/۷۸، زاویه تماس 88° و تخلخل ۸۲٪ و برای پلیمر PVDF ۰/۱۸٪ مقدار بهینه نانوذره ۰/۱۹٪ با مقدار شار $401/1 \text{ L/m}^2\text{h}$ ، گرفتگی $68/3$ ٪، زاویه تماس $79/9^\circ$ و تخلخل ۷۸٪ به دست آمد. سپس با استفاده از نتایج پارامترهای بهینه

مراجع

- [1]. Delgrange N., Cabassud C., Cabassud M., Durand-Bourlier L. and Lain J. M., "Neural network for prediction of ultrafiltration transmembrane pressure—application to drink water," *Journal of Membr. Sci.*, Vol. 150, Issue 111, pp. 111-123, 1998.
- [2]. Razavi S. M. A., Mortazavi S. A. and Mousavi S. M., "Dynamic modeling of milk ultrafiltration by artificial neural network," *Journal of Membr. Sci.*, Vol. 220, p. 47, 2003.
- [3]. Razavi S. M. A., Mousavi S. M. and Mortazavi S. A., "Dynamic prediction of milk ultrafiltration performance, A neural network approach," *J. Chem. Eng. Sci.*, Vol. 58, p. 4185, 2003.
- [4]. Razavi S. M., Mortazavi S. A., Mousavi S. M., "Application of neural networks for crossflow milk ultrafiltration simulation," *Internat. Dairy J.*, Vol. 14, p. 69, 2004.
- [5]. Teodosiu C., Pastravanu D. and Macoveanu M., "Neural network model for ultrafiltration and backwashing," *Water Research*, Vol. 34, p. 4371, 2000.
- [6]. Dornier M., Decloux M., Trystram G. and Lebert A., "Dynamic modeling of crossflow microfiltration using neural networks," *Journal of Membr. Sci.*, Vol. 98, p. 263, 1999.
- [7]. Mousavi M., Avami A., "Modeling and simulation of water softening by nanofiltration using artificial neural network," *Iran. J. Chem. Eng.*, Vol. 25, p. 37, 2006.
- [8] Bowen W. R., Jones M. G. and Yousef H. N. S., "Prediction of the rate of crossflow membrane ultrafiltration of col

- loids: a neural network approach*,” J. of Chem. Eng. Sci., Vol. 53, p. 3793, 1998.
- [9]. Salehi v. and Razavi S. M. A., “*Modeling of waste brine nanofiltration process using artificial neural network and adaptive neuro- fuzzy inference system*,” Desaln. and Water Treat., Vol. 57, p. 14369, 2016.
- [10]. Razavi F. and Razavi S. M. M. A., “*Dynamic modeling of flux and total hydraulic resistance in nanofiltration treatment of regeneration waste brine using artificial neural networks*,” Desaln. and Water Treat., Vol. 41, No. 3, p. 95, 2012.
- [11]. Vatanpour V., Madaeni S. S., Moradian R., Zinadini S. and Astinchap B., “*Fabrication and characterization of novel antifouling nanofiltration membrane prepared from oxidized multiwalled carbon nanotube/polyethersulfone nanocomposite*,” J. Membr. Sci., Vol. 375, p. 284, 2011.
- [12]. Vatanpour V., Esmaeili M. and Farahani M. H., “*Fouling reduction and retention increment of polyethersulfone nanofiltration membranes embedded by amine-functionalized multi-walled carbon nanotubes*,” J. of Membr. Sci., Vol. 466, p. 70, 2014.
- [13]. Zhang X., Lang W. Z., Yan X., Lou Z.-Y. and Chen v., “*Influences of the structure parameters of multi-walled carbon nanotubes(MWNTs) on PVDF/PFSA/O-MWNTs hollow fiber ultrafiltration membranes*,” J. of Membr. Sci., Vol. 499, p. 179,2016.
- [14]. Madaeni S. S., Zinadini S. and Vatanpour V. , “*Convective flow adsorption of nickel ions in PVDF membrane embedded with multi-walled carbon nanotubes and PAA coating*,” Separ. and Puri. Tech., Vol. 80, p. 155, 2011.
- [15]. Majeed S., Fierro D., Buhr v., Wind J., Du B., Boschetti-de-Fierro A. and Abetz V., “*Multi-walled carbon nanotubes (MWCNTs) mixed polyacrylonitrile (PAN) ultrafiltration membranes*,” J. of Membr. Sci., Vol. 403–404, p. 101, 2012.



Modeling the Prediction of Flux and Fouling Parameters of PVDF Nanocomposite Ultrafiltration Membranes with Carbon Nanotubes using Artificial Intelligence Networks

Mehran Mofakhami, Alireza Aghaei*, and Maziar Sahba Yaghmaee

Material and energy research center- Karaj-Iran

a-aghaei@merc.ac.ir

DOI: 10.22078/pr.2018.2937.2374

Received: February/12/2018

Accepted: July/22/2018

INTRODUCTION

Membrane processes have been proposed in recent years as efficient methods for separation and purification. Since the hydrophilicity membranes with functional carbon nanotube have higher resistance to fouling than hydrophobic materials, the increase in hydrophilicity of polymer membranes is one of the basic solutions for membrane modification. In addition, carbon nanotubes have been considered by many researchers because of their desirable properties such as low mass density, high flexibility and effective interaction between carbon nanotube bonds and functional groups which have the proper properties to improve the performance of polymer membranes. Moreover, four intelligent systems (MLP, RBF, LSSVM, and ANFIS) and three optimization algorithms (GA, PSO, and SA) for modeling flux and fouling parameters have been

used by us. Artificial neural networks have been successfully used to prevent membrane fouling during microfiltration and ultrafiltration of colloidal compounds, proteins as well as urban and industrial water treatment [1-5].

PREPARATION OF NANOCOMPOSITE MEMBRANE

For manufacturing ultrafiltration membranes by phase inversion, a certain amount of nanotubes based on previous experiences and studies (0.05, 0.1, 0.2, 0.3, 0.5 wt.% compared to polymer)[6-7] has been distributed for half an hour in normal methylpyrrolidone solvent using ultrasonic bath and then Polyvinylidene fluoride polymer with a 15 wt.% (compared to the weight of the polymer) is solved in solution. Then cavity-causing polymer of polyvinylpyrrolidone in the amount of 1 wt.% (compared to the weight of the polymer) for pitting is added to the solution. After stirring the

solution for 24 hours, it is placed in an oven of 55 °C for de-bubbling for 6 hours. After passing of the solution through a smooth glass substrate to reach ambient temperature, membrane layer thickness by a video cache with a thickness of 150 micrometers and at a constant speed was spread on the bed and immediately, immersed in the coagulation bath water. After about 10 minutes, the membrane is removed from the water bath and stored in a container which contains distilled water.

MODELING

In this paper, modeling using artificial intelligence networks has been used to create a predictive model of fouling and flux parameters that uses 4 smart networks and three optimization algorithms.

FOULING PARAMETER MODELING:

In this research, 80% of the modeling data for training and 20% for network testing were selected randomly.

MLP MODELING:

At this stage, a 3-layer neural network was used to simulate . This three-layer neural network contains 5 neurons in the input layer and 1 neuron in the output layer. For both hidden and output layers, the tansig activation function was used. The objective function was also considered as the least mean squared error (LMSE). To find the optimal number of hidden neurons, several neural networks have been constructed and their function has been investigated. To do this, a neuron number of 2 to 30 has been hidden in the layer, and finally, after comparing the results of the constructed networks, the optimal value for the number of hidden layer neurons has been 15. After the network has been built using the data set devoted to training, test data has been also provided to the network. The function of the MLP network has been constructed, and the function is shown in Figures 1 and 2. In addition, the related statistical parameters have been presented in Table 1.





Figure 1: (a) The cross-sectional graph shows the correlation coefficient between predicted values and actual data by the MLP network for training and testing data. (b) The graph shows the relative error for the training and testing data for the MLP designed network.




Figure 2: Comparison between the values predicted by the MLP network with actual data (a) training data, (b) test data.

Table 1: Statistical Parameters for the MLP Neural Network.

N	RMSE	STD	AARD	R ²	
36	2.587527	0.04496	2.807025	0.960509	Training data
12	5.815536	0.101796	7.149236	0.775561	Test data
48	3.671047	0.063741	3.892577	0.917662	Total data

The modeling which has been achieved for other networks RBF, LSSVM, and ANFIS is similar to the above table and figures.

Comparison of Models for fouling Parameters are

following in Table 2. Modeling which has been simulated are similar to fouling parameter.

Comparison of the models with each other for finding the flux parameter are shown in Table 3.

Table 2: General results of modeling using different methods.

		R ²	AARD	STD	RMSE	N
MLP	Train data	0.960509	2.807025	0.04496	2.587527	36
	Test data	0.775561	7.149236	0.101796	5.815536	12
	All data	0.917662	3.892577	0.063741	3.671047	48
GA-RBF	Train data	1	8.23E-14	1.61E-15	7.87E-14	36
	Test data	0.932464	4.171744	0.053156	3.403937	12
	All data	0.982956	1.042936	0.028026	1.701968	48
LSSVM	Train data	0.81951	7.365815	0.116697	5.686178	36
	Test data	0.92654	5.513205	0.06567	3.229177	12
	All data	0.838147	6.902663	0.1056	5.182313	48
Conjugate-ANFIS	Train data	1	2.04E-15	6.26E-17	3.13E-15	36
	Test data	0.963835	4.038988	0.048845	3.531359	12
	All data	0.983726	1.009747	0.028506	1.76568	48

Table 3: General outcomes of modeling using different methods.

		R ²	AARD	STD	RMSE	N
MLP	Train data	1	0.000147	4.15E-06	0.001188	36
	Test data	0.929902	6.102074	0.089494	25.19476	12
	All data	0.970603	1.525629	0.045198	12.59738	48
GA-RBF	Train data	0.999671	0.303117	0.004457	1.212818	36
	Test data	0.991598	1.952475	0.027128	7.287811	12
	All data	0.99709	0.715457	0.013693	3.792261	48
LSSVM	Train data	0.998006	0.662018	0.010907	3.024102	36
	Test data	0.919262	4.488421	0.070189	21.93118	12
	All data	0.973731	1.618618	0.035357	11.274	48
Conju- gate- ANFIS	Train data	1	1.9E-14	2.59E-16	6.48E-14	36
	Test data	0.981002	2.705384	0.036376	10.98454	12
	All data	0.993869	0.676346	0.018683	5.492272	48

FIND OPTIMAL LABORATORY PARAMETERS

In this section, the goal is to obtain optimal values for the conditions at which the fouling reaches its minimum, while the flux values are high. For this, the best models made last season for both outputs will be used. Moreover, a combination of genetic and particle swarm algorithms is

working to find optimal values. At first, a random population of 300 responses was possible. Then, after 50 generations, it converges to optimal conditions. The target function is the least squared FRR and flux. Finally, convergence to the optimal values for the 15% PVDF membrane and 18% PVDF membrane are shown in Table 4.

Table 4: Estimated optimal values.

polymer	nanoparticle %	contact angle	porosity	BSA Rejection	FRR%	(Flux(L/m ² .hr
15	0.069212835	88.13671097	0.72680354	81.7703366	100.00	252.7
18	0.171222113	79.90790664	0.75124799	98.86853228	63.47	454.2

CONCLUSIONS

In the present study, PVDF ultrafiltration membranes with two concentrations of 15 and 18% have been prepared by phase inversion using NMP solvent. In order to improve the hydrophilic properties and to reduce the fouling of these membranes, various acidic, basic, and amine carbon nanotubes with different concentrations have been used. The modeling results have been performed using four artificial intelligence networks. Finally, using optimization algorithms, the optimal parameters have been obtained according to the goals of the most flux and the

minimum fouling for both PVDF (15 wt.% and 18 wt.%) polymers. The overall outcomes of this research can be summarized as follows: For modeling flux and fouling parameters, four intelligent multi-layer neural network (MLP), radial basic function (RBF), least squared support vector machine (LSSVM) and adaptive neuro fuzzy interference systems (ANFIS) have been used. Errors have been calculated and compared with each other for each neural network system. According to the correlation coefficient obtained for each system and the correlation coefficient (> 0.85) is a good accuracy for neural networks, it can be

concluded that for flux and fouling parameters, the best model are GA-RBF and Conjugate-ANFIS. In the next section, modeling has been used to obtain the optimal values of the best models which have been made for both outputs. Afterward, by using the combination of genetic algorithm with particle swarm optimization algorithm, optimal values have been obtained.

Finally, for 15% PVDF polymer, optimum nanoparticle content is 0.6% with flux 252.7% L/m²h, 100% fouling, 88° contact angle and 73% porosity; moreover, for 18% PVDF polymer, optimum nanoparticle content is 0.17% with flux volume 454.2 L/m²h, fouling 63.5%, contact angle 80° and porosity 75%.

REFERENCES

- [1]. Delgrange N., Cabassud C., Cabassud M., Durand-Bourlier L. and Lain J. M., "Neural network for prediction of ultrafiltration transmembrane pressure—application to drink water," *Journal of Membr. Sci.*, Vol. 150, pp. 111, 1998.
- [2]. Razavi S. M. A., Mortazavi S. A. and Mousavi S. M., "Dynamic modeling of milk ultrafiltration by artificial neural network," *Journal of Membr. Sci.*, Vol. 220, pp. 47, 2003.
- [3]. Razavi S. M. A, Mousavi S. M. and Mortazavi S. A., "Dynamic prediction of milk ultrafiltration performance, A neural network approach," *J. Chem. Eng. Sci.*, Vol. 58, pp. 4185, 2003.
- [4]. Razavi S. M., Mortazavi S. A., Mousavi S. M., "Application of neural networks for crossflow milk ultrafiltration simulation," *Internat. dairy J.*, Vol. 14, pp. 69, 2004.
- [5]. Teodosiu C., Pastravanu D. and Macoveanu M., "Neural network model for ultrafiltration and backwashing," *Water Research*, Vol. 34, pp. 4371, 2000.
- [6]. Dornier M., Decloux M., Trystram G. and Lebert A., "Dynamic modeling of crossflow microfiltration using neural networks," *Journal of Membr. Sci.*, Vol. 98, pp. 263, 1999.
- [7]. Mousavi M., Avami A., "Modeling and simulation of water softening by nanofiltration using artificial neural network," *Iran. J. Chem. Eng.*, Vol. 25, pp. 37, 2006.
- [8]. Bowen W. R., Jones M. G. and Yousef H. N. S., "Prediction of the rate of crossflow membrane ultrafiltration of col loids: a neural network approach," *J. of Chem. Eng. Sci.*, Vol. 53, pp. 3793, 1998.