

## مدل سازی کارایی فرآیند اولترافیلتراسیون در تصفیه شربت خام چغندر قند به روش شبکه عصبی مصنوعی

تینا شایان<sup>۱</sup>، وحید حکیم زاده<sup>۲\*</sup>، مصطفی شهیدی نوقابی<sup>۳</sup>

۱- دانشجوی کارشناسی ارشد گروه علوم و صنایع غذایی، واحد قوچان، دانشگاه آزاد اسلامی، قوچان، ایران.

۲- استادیار گروه علوم و صنایع غذایی، واحد قوچان، دانشگاه آزاد اسلامی، قوچان، ایران.

۳- دانشیار گروه شیمی مواد غذایی، پژوهشکده علوم و صنایع غذایی، پارک علم و فناوری خراسان رضوی، مشهد، ایران.

(تاریخ دریافت: ۹۷/۰۸/۲۳ تاریخ پذیرش: ۹۸/۰۱/۱۸)

### چکیده

فرآیند اولترافیلتراسیون به عنوان یکی از فرآیندهای غشایی مبتنی بر فشار می‌تواند به عنوان روش نوین، جایگزین روش مرسوم در صنعت قند گردد. در این تحقیق کاهش سختی، افزایش درصد دفع ترکیبات غیرقندی و بهبود خلوص جریان تراوه طی تصفیه شربت خام چغندر با فرآیند اولترافیلتراسیون به روش شبکه عصبی مصنوعی مدل سازی شد. فرآیند اولترافیلتراسیون در سه درجه حرارت ۳۰، ۴۰ و ۵۰ درجه سانتی‌گراد، سه فشار در عرض غشاء ۱، ۲ و ۳ بار در هفت فاصله زمان مساوی از ۱ تا ۶۰ دقیقه انجام شد. بهترین مدل برای کاهش سختی با یک لایه پنهان، تعداد ۱۳ نورون، تابع انتقال تانژانت، قانون یادگیری مومنتوم و درصد داده های ۲۵، ۳۵ و ۴۰ به ترتیب برای آموزش، ارزیابی و آزمون بدست آمد. تغییرات درصد دفع ترکیبات غیرقندی با یک لایه پنهان، تعداد ۱۵ نورون، تابع انتقال تانژانت، قانون یادگیری لوببرگ و اختصاص ۵۰، ۵ و ۴۵ درصد از داده ها برای آموزش، ارزیابی و آزمون مدل کمترین خطا و بیشترین ضریب همبستگی را طی مدل‌سازی داشت. بهبود خلوص جریان تراوه طی اولترافیلتراسیون نیز با یک لایه پنهان، تعداد ۱۸ نورون، تابع انتقال سیگموئید، قانون یادگیری لوببرگ و درصد داده های ۳۵، ۴۰ و ۲۵ برای آموزش، ارزیابی و آزمون بهترین شبکه را ایجاد نمود. همچنین بیشترین ضریب همبستگی بین داده های آزمایشگاهی و مقادیر های پیش بینی شده با مدل برای تغییرات سختی، درصد دفع ترکیبات غیرقندی و خلوص به ترتیب ۰/۹۸۵، ۰/۹۸۵ و ۰/۹۸۵ بدست آمد.

کلیدواژه‌گان: اولترافیلتراسیون، تانژانت، شبکه عصبی مصنوعی، ضریب همبستگی، مدل سازی.

\*مسئول مکاتبات: v.hakimzadeh@yahoo.com

## ۱- مقدمه

حذف ترکیبات غیرقندی و دستیابی به شربتی زلال و صاف در صنعت چغندر قند هدف اصلی در فرآیند تولید شکر درجه یک و ممتاز است. متاسفانه روش مرسوم تصفیه شیمیایی با آهک‌زنی و سپس کربناتاسیون شربت علاوه بر صرف انرژی بالا آلودگی محیط زیست را نیز در پی دارد. همچنین در روش سنتی کاربرد همزمان دمای بالا و قلیایی می‌تواند سبب مشکلاتی همچون تجزیه ساکارز و افت pH شود [۱]. لذا فناوری‌های نوین مانند فرآیندهای غشایی می‌تواند کاربرد گسترده و موفقیت آمیزی در زمینه تصفیه شربت و جداسازی ناخالصی‌ها و ترکیبات رنگی از شربت داشته باشند [۲، ۳، ۴ و ۵]. در بین فرآیندهای غشایی مبتنی بر نیروی محرکه فشار، فرآیند اولترافیلتراسیون یکی از مهمترین آن‌ها است که می‌تواند مواد کلوئیدی با اندازه ملکولی  $0.01-0.2$  میکرون (۱۰۶-۱۰۳ دالتون) را جدا کند [۶ و ۷]. در سال ۱۹۸۴ Hanssen و همکاران فرآیند اولترافیلتراسیون را به عنوان جایگزینی برای تصفیه عصاره خام چغندر قند مورد استفاده قرار دادند و بدین نتیجه رسیدند که با بهره‌گیری از این فرآیند می‌توان به شربت رقیقی با کیفیت مشابه شربت رقیق تولید شده به روش تصفیه سنتی دست یافت [۸]. Misra و همکاران (۲۰۰۰)، جهت بهبود خصوصیات شربت خام نیشکر از فرآیند اولترافیلتراسیون استفاده کردند و مشاهده نمودند که بطور میانگین درجه خلوص شربت  $0.74$  واحد و میزان رنگ در حدود ۶۰ درصد بهبود یافت [۹].

بررسی‌های منابع مختلف نشان می‌دهد که محققین توجه ویژه‌ای به مدلسازی فرآیندهای غشایی در صنایع مختلف معطوف داشته‌اند چراکه شبکه‌های عصبی قادر به مدل‌سازی سیستم‌های غیر خطی و پیچیده با تعداد زیادی از داده ورودی و خروجی می‌باشند که در اکثر موارد نتایج قابل قبولی توسط محققان گزارش شده است [۱۰]. به عنوان مثال Masciola و همکاران (۲۰۰۱) در رابطه با گرفتگی غشاء در فرآیند اولترافیلتراسیون در محلول‌های امولسیون‌ی یک مدل تجربی را برای پیشگویی مقدار لایه کیک ایجاد شده با تطابق خوبی از داده‌های تجربی معرفی کردند [۱۱]. شهیدی و همکاران (۲۰۱۱)، پس از بررسی تاثیر دما، اختلاف فشار در عرض غشاء و غلظت بر

نانوفیلتراسیون آب پرس تفاله چغندر قند شار، درصد گرفتگی و درصد دفع ترکیبات مختلف را با شبکه‌های عصبی مصنوعی مدل سازی کردند. نتایج ایشان نشان داد که بهترین پیشگویی طی قانون یادگیری لوبنرگ با تابع انتقال خطی تاثرات و با درصدهای ۵۰، ۲۵ و ۲۵ از کل داده‌ها برای تربیت، ارزیابی و آزمون مدل بدست آمد و خروجی مدل با ضریب همبستگی بالایی با نتایج آزمایشگاهی مطابقت داشت [۱۲]. در سال ۲۰۱۸ نیز Hakimzadeh و همکاران پتانسیل تصفیه شربت خام چغندر به روش الکتروکوکاگولاسیون را با شبکه‌های عصبی مصنوعی مدل سازی کردند. طی این تحقیق نشان داده شد که بهترین قانون یادگیری برای آموزش شبکه در پیش‌گویی سختی، رنگ و خلوص شربت تصفیه شده به روش الکتروکوکاگولاسیون قانون لوبنرگ بود. به طوری که بهترین تابع انتقال برای طراحی شبکه‌های یادگیری با بهترین پیشگویی مقادیر کدورت و خلوص تاثرات و برای رنگ سیگموئید بود و مدل بدست آمده به خوبی قادر بود مقادیر سختی، رنگ و خلوص شربت را تحت شرایط عملیاتی مختلف پیش‌بینی کند چراکه داده‌های حاصل از مدل، همبستگی بالایی را با داده‌های تجربی نشان دادند [۱۳].

همانطور که می‌دانیم کارایی فرآیندهای غشایی به متغیرهای مهمی همچون دما، فشار در عرض غشاء و سرعت جریان بستگی دارد. بنابراین روش‌های مختلف شبیه‌سازی و مدل‌سازی از جمله شبکه‌های عصبی مصنوعی (ANN) می‌تواند به منظور پیشگویی پارامترهای مورد نظر در طراحی و توسعه سیستم‌های غشایی استفاده شود. لذا در این تحقیق به مدلسازی فرآیند اولترافیلتراسیون شربت خام چغندری که یکبار فرآیند میکروفیلتراسیون را به عنوان پیش‌تیمار گذرانده است پرداخته می‌شود.

## ۲- مواد و روش

### ۲-۱- فرآیند غشایی

فرآیند اولترافیلتراسیون تراوه‌ی شربت خام چغندر میکروفیلتر شده، با یک پیلوت مجهز به مادول غشایی مارپیچ صورت گرفت. آزمایشات در سه دمای ۳۰، ۴۰ و ۵۰ درجه سانتیگراد، سه سطح فشار در عرض غشاء ۱، ۲ و ۳ بار و ۷

مشخصات فنی این سیستم غشایی در جدول ۱ آمده است.

فاصله زمانی یکسان در بازه ۱ تا ۶۰ دقیقه (۷۲ آزمایش) بر روی میزان شار، کدورت و رنگ جریان تراوه صورت پذیرفت [۱۴].

**Table 1** Technical features of the Ultrafiltration Pilot for purification of Microfiltrated Raw Sugar Beet Juice

| Max Pressure | Heat tolerance range | pH tolerance range | Effective area      | MWCO   | Module | Membrane composition |
|--------------|----------------------|--------------------|---------------------|--------|--------|----------------------|
| 5 bar        | 5-55 °C              | 2-11               | 0.33 m <sup>2</sup> | 20 KDa | Spiral | Poly Sulfone Amid    |

در این تحقیق جهت مدل سازی از شبکه عصبی مصنوعی با نرم افزار نروسولوشن نسخه ۶ استفاده گردید. در این مدل سازی دما، فشار و زمان به عنوان متغیرهای ورودی (مستقل) و شار، رنگ و کدورت به عنوان متغیرهای خروجی (وابسته) انتخاب شد. تعداد کل داده ها ۷۲ عدد بود. مدلسازی بر پایه یک لایه مخفی با تعداد ۲ تا ۲۰ نرون برای توابع انتقال تانژانت هیپربولیک و سیگموئید و قواعد یادگیری لونیگ مارکورات و مونتمو انجام شد. پس از انتخاب بهترین تابع انتقال و قاعده یادگیری و همچنین مناسب ترین تعداد نرون، برنامه برای درصدهای مختلف یادگیری، ارزیابی و آزمون اجرا شد. در مرحله آخر نیز مقادیر اندازه گیری شده به روش تجربی با مقادیر حاصل از آزمون شبکه عصبی مصنوعی مقایسه گردید. ارزیابی مدل ها با استفاده از متغیرهای آماری همچون میانگین مربع خطا (MSE)، میانگین مربع خطای نرمال شده (NMSE)، میانگین خطای مطلق (MAE) و ضریب همبستگی R<sup>2</sup> صورت گرفت و در نهایت حالتی که مقادیر پیش بینی به مقادیر تجربی بسیار نزدیک بودند، به عنوان بهترین مدل انتخاب گردید [۱۶]. در صورت بالا بودن ضرایب همبستگی و به عبارتی سازگاری مقادیر پیش بینی شده و مقادیر تجربی، مدل های انتخابی قابل قبول خواهد بود [۱۷ و ۱۸].

### ۳- نتایج و بحث

جریان تراوه ی حاصل از اولترافیلتراسیون شربت خام میکروفیلتر شده در مقایسه با شربت تصفیه شده به روش مرسوم ۶/۶۵ درصد در میزان سختی، ۴۹/۲۱ درصد در رنگ و ۱/۴۲ درصد در خلوص بهبود یافت که با توجه به پتانسیل بالای تصفیه

### ۲-۲- آزمون ها

درصد خلوص نمونه ها بر اساس مقادیر پلاریمتری و بریکس نمونه ها با استفاده از رابطه ۱ محاسبه گردید.

(۱)

$$\text{Purity} = (\text{Brix}/\text{Pol}) \times 100$$

سختی نمونه ها از طریق تیتراسیون شربت با محلول EDTA در غلظت ۰/۰۲۵ مول بر لیتر طبق دستورالعمل ایکومزا (۲۰۰۰) اندازه گیری گردید. به این صورت که ابتدا حدود ۵۰ میلی لیتر شربت با ۵۰ میلی لیتر آب مقطر مخلوط شد و ۱۰ میلی لیتر محلول بافر به آن اضافه گردید. سپس در حضور معرف اریوکروم بلاک و با EDTA تا رسیدن به رنگ آبی تیتراژ شد. در این حالت اگر n میلی لیتر از EDTA به ازای ۱۰۰ میلی لیتر نمونه شربت مصرف شود، مقدار سختی بر حسب CaO از رابطه ۲ بدست می آید [۱۵]:

(۲)

$$\text{Hardness (According to CaO)} = n \times 1.002$$

برای محاسبه درصد دفع ترکیبات غیر ساکارزی، ابتدا درصد ساکارز (پل) و بریکس جریان تراوه و خوراک اندازه گیری شده و سپس با جاگذاری در رابطه ۳ بدست می آید [۲ و ۴]:

$$\text{Brix} - \text{Pol}_{\text{feed}} \times 100 \quad (۳)$$

$$\text{Non-Sugar Rejection} = [(\text{Brix} - \text{Pol})_{\text{permeate}} / (\text{pol} - \text{Pol}_{\text{feed}})] \times 100$$

### ۳-۳- مدل سازی شبکه عصبی مصنوعی

میکرو / اولترافیلتر شده و شربت تصفیه شده به روش مرسوم را  
ملاحظه نمود [۱۴].

به روش مذکور مدل سازی آن می تواند در پیشگویی خصوصیات  
شربت در سایر شرایط عملیاتی مفید باشد. در جدول ۲ می توان  
خلاصه ای از مقایسه شربت خام، شربت تصفیه شده به روش

**Table 2** Comparison of Some Purification Indexes by Membrane Method and Traditional Method

| Purification Index | Raw Beet Juice | Refined Juice by Micro/Ultra filtration | Refined Juice By Traditional Method |
|--------------------|----------------|---|-------------------------------------|
| Purity             | 70.42          | 91.63                                   | 90.33                               |
| Hardness           | 1017.5         | 750                                     | 803.5                               |
| Color              | 9734           | 2138                                    | 4209                                |

تانژانت تحت قانون یادگیری مومنتوم بر اساس بیشترین ضریب  
همبستگی انتخاب شد. برای تغییرات خلوص نیز تابع انتقال  
تانژانت با قانون یادگیری لونیگ در نرون شماره ۱۵ بهترین  
شبکه با بیشترین ضریب همبستگی را ارائه داد. در حالیکه برای  
درصد دفع ترکیبات غیرقندی نرون شماره ۱۸ با تابع  
انتقال سیگموئید و قانون لونیگ توانست شبکه ای با  
بهترین ضریب همبستگی را طراحی کند.

در این تحقیق با توجه به تأثیرگذار بودن تعداد نرون، نوع تابع و  
قانون یادگیری بر خروجی مدل، شبکه های مختلفی با تعداد ۲ تا  
۲۰ نرون و دو تابع تانژانت و سیگموئید تحت قانون یادگیری  
لونیگ و مومنتوم طراحی شد. همانطورکه در جدول های ۳ تا ۵  
نشان داده شده است خطا و ضریب همبستگی هر نرون با قوانین  
یادگیری و توابع اشاره شده مورد بررسی قرار گرفت. به این  
ترتیب برای سختی شبکه ای با تعداد نرون ۱۳، تابع انتقال

**Table 3** The Best Architectures of ANN in Different of number of Neurons and Transfer Function under Momentum Learning Law for Permeate Hardness during Ultrafiltration of microfiltered Raw Beet Juice.

| Hardness | Momentum       |         |       |       |               |              |              |              |
|----------|----------------|---------|-------|-------|---------------|--------------|--------------|--------------|
|          | No. of Neurons | Sigmoid |       |       | Tangent       |              |              |              |
|          | MSE            | NMSE    | MAE   | r     | MSE           | NMSE         | MAE          | R            |
| 2        | 72.362         | 1.797   | 7.547 | 0.563 | 45.792        | 1.137        | 5.441        | 0.031        |
| 3        | 40.903         | 1.015   | 5.426 | 0.465 | 32.380        | 0.804        | 4.611        | 0.649        |
| 4        | 42.254         | 1.049   | 5.671 | 0.432 | 49.032        | 1.217        | 5.619        | 0.232        |
| 5        | 35.628         | 0.884   | 5.005 | 0.465 | 40.520        | 1.006        | 4.711        | 0.516        |
| 6        | 38.566         | 0.957   | 5.210 | 0.354 | 63.781        | 1.583        | 6.811        | 0.258        |
| 7        | 36.061         | 0.895   | 5.126 | 0.575 | 34.780        | 0.863        | 4.863        | 0.446        |
| 8        | 31.630         | 0.785   | 4.846 | 0.631 | 31.843        | 0.790        | 5.056        | 0.589        |
| 9        | 37.153         | 0.922   | 5.184 | 0.376 | 62.639        | 1.555        | 7.152        | 0.319        |
| 10       | 31.828         | 0.790   | 4.871 | 0.612 | 99.023        | 2.459        | 6.330        | 0.292        |
| 11       | 35.069         | 0.870   | 5.071 | 0.662 | 33.306        | 0.827        | 4.998        | 0.562        |
| 12       | 38.807         | 0.914   | 5.148 | 0.458 | 53.174        | 1.320        | 6.224        | 0.633        |
| 13       | 36.461         | 0.905   | 5.183 | 0.337 | <b>19.698</b> | <b>0.489</b> | <b>3.482</b> | <b>0.733</b> |
| 14       | 35.310         | 0.876   | 5.058 | 0.618 | 67.803        | 1.683        | 6.846        | 0.687        |
| 15       | 35.963         | 0.893   | 5.138 | 0.443 | 66.693        | 1.656        | 6.216        | 0.394        |
| 16       | 34.117         | 0.847   | 5.035 | 0.605 | 94.207        | 2.339        | 6.825        | 0.444        |
| 17       | 35.633         | 0.884   | 5.111 | 0.563 | 28.800        | 0.715        | 4.557        | 0.675        |
| 18       | 30.800         | 0.764   | 4.900 | 0.643 | 155.134       | 3.852        | 8.155        | 0.210        |
| 19       | 34.704         | 0.861   | 5.092 | 0.589 | 177.753       | 4.414        | 8.432        | 0.209        |
| 20       | 32.497         | 0.807   | 4.970 | 0.611 | 94.751        | 2.353        | 8.427        | 0.691        |

**Table 4** The Best Architectures of ANN in Different of number of Neurons and Transfer Function under Levenberg Learning Law for Permeate Purity during Ultrafiltration of microfiltered Raw Beet Juice.

| Purity    | Levenberg      |              |              |              |              |              |              |              |
|-----------|----------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
|           | No. of Neurons | Sigmoid      |              |              | Tangent      |              |              | R            |
|           | MSE            | NMSE         | MAE          | r            | MSE          | NMSE         | MAE          |              |
| 2         | 0.034          | 0.070        | 0.155        | 0.964        | 0.055        | 0.114        | 0.207        | 0.950        |
| 3         | 0.0394         | 0.080        | 0.161        | 0.959        | 0.0388       | 0.079        | 0.162        | 0.959        |
| 4         | 0.035          | 0.072        | 0.17         | 0.964        | 0.037        | 0.076        | 0.143        | 0.964        |
| 5         | 0.035          | 0.073        | 0.142        | 0.965        | 0.154        | 0.314        | 0.348        | 0.829        |
| 6         | 0.020          | 0.042        | 0.112        | 0.983        | 0.024        | 0.049        | 0.116        | 0.976        |
| 7         | 0.028          | 0.058        | 0.138        | 0.970        | 0.039        | 0.079        | 0.158        | 0.959        |
| 8         | 0.025          | 0.051        | 0.134        | 0.974        | 0.037        | 0.075        | 0.146        | 0.964        |
| 9         | 0.033          | 0.068        | 0.143        | 0.966        | 0.029        | 0.061        | 0.119        | 0.973        |
| 10        | 0.030          | 0.061        | 0.121        | 0.969        | 0.018        | 0.038        | 0.102        | 0.980        |
| 11        | 0.023          | 0.048        | 0.118        | 0.977        | 0.031        | 0.064        | 0.129        | 0.968        |
| 12        | 0.019          | 0.040        | 0.102        | 0.980        | 0.050        | 0.103        | 0.185        | 0.970        |
| 13        | 0.039          | 0.081        | 0.174        | 0.960        | 0.025        | 0.052        | 0.127        | 0.974        |
| 14        | 0.022          | 0.045        | 0.130        | 0.978        | 0.059        | 0.121        | 0.217        | 0.955        |
| <b>15</b> | <b>0.027</b>   | <b>0.055</b> | <b>0.132</b> | <b>0.974</b> | <b>0.015</b> | <b>0.032</b> | <b>0.108</b> | <b>0.984</b> |
| 16        | 0.037          | 0.076        | 0.158        | 0.968        | 0.056        | 0.115        | 0.197        | 0.945        |
| 17        | 0.046          | 0.094        | 0.187        | 0.958        | 0.021        | 0.043        | 0.120        | 0.978        |
| 18        | 0.018          | 0.038        | 0.098        | 0.982        | 0.068        | 0.140        | 0.227        | 0.931        |
| 19        | 0.033          | 0.068        | 0.0148       | 0.980        | 0.032        | 0.065        | 0.150        | 0.967        |
| 20        | 0.024          | 0.050        | 0.132        | 0.976        | 0.031        | 0.064        | 0.149        | 0.974        |

**Table 5** The Best Architectures of ANN in Different of number of Neurons and Transfer Function under Levenberg Learning Law for Permeate Non-sugar rejection during Ultrafiltration of microfiltered Raw Beet Juic.

| Non-sugar Rej % | Levenberg      |              |              |              |         |       |       |              |
|-----------------|----------------|--------------|--------------|--------------|---------|-------|-------|--------------|
|                 | No. of Neurons | Sigmoid      |              |              | Tangent |       |       | R            |
|                 | MSE            | NMSE         | MAE          | r            | MSE     | NMSE  | MAE   |              |
| 2               | 60.601         | 0.308        | 6.297        | 0.848        | 68.905  | 0.350 | 6.315 | 0.820        |
| 3               | 60.282         | 0.306        | 5.947        | 0.856        | 72.286  | 0.367 | 6.055 | 0.813        |
| 4               | 50.738         | 0.258        | 5.665        | 0.880        | 61.274  | 0.076 | 6.717 | 0.914        |
| 5               | 52.968         | 0.269        | 5.681        | 0.859        | 104.415 | 0.531 | 7.890 | 0.757        |
| 6               | 14.599         | 0.074        | 2.943        | 0.965        | 8.263   | 0.042 | 2.410 | 0.983        |
| 7               | 50.442         | 0.256        | 5.220        | 0.895        | 24.416  | 0.124 | 3.970 | 0.940        |
| 8               | 11.080         | 0.056        | 2.733        | 0.975        | 59.001  | 0.300 | 5.266 | 0.870        |
| 9               | 34.482         | 0.175        | 5.225        | 0.941        | 22.046  | 0.112 | 3.613 | 0.950        |
| 10              | 36.801         | 0.187        | 5.369        | 0.936        | 20.011  | 0.101 | 3.351 | 0.954        |
| 11              | 11.442         | 0.058        | 2.516        | 0.970        | 16.808  | 0.085 | 3.253 | 0.956        |
| 12              | 7.265          | 0.036        | 2.055        | 0.983        | 15.683  | 0.079 | 3.424 | 0.961        |
| 13              | 16.644         | 0.084        | 3.119        | 0.967        | 16.302  | 0.082 | 2.728 | 0.963        |
| 14              | 17.422         | 0.088        | 3.366        | 0.957        | 35.580  | 0.181 | 4.764 | 0.944        |
| 15              | 30.856         | 0.157        | 4.136        | 0.926        | 10.624  | 0.054 | 2.812 | <b>0.977</b> |
| 16              | 63.292         | 0.322        | 6.284        | 0.868        | 64.738  | 0.329 | 6.780 | 0.840        |
| 17              | 60.135         | 0.306        | 6.101        | 0.873        | 23.847  | 0.121 | 4.302 | 0.949        |
| <b>18</b>       | <b>8.121</b>   | <b>0.041</b> | <b>2.202</b> | <b>0.985</b> | 47.707  | 0.242 | 5.830 | 0.871        |
| 19              | 18.793         | 0.095        | 3.596        | 0.974        | 13.837  | 0.070 | 2.602 | 0.967        |
| 20              | 26.652         | 0.135        | 3.598        | 0.940        | 19.646  | 0.099 | 3.274 | 0.955        |

## ۳-۱- بررسی درصدهای مناسب آموزش،

## ارزیابی و آزمون شبکه

همچنین در این بررسی، با تغییر درصد داده های اختصاص داده شده برای آموزش، ارزیابی و آزمون، بهترین طراحی شبکه از نظر ضریب همبستگی بالا و خطای کم مورد بررسی قرار گرفت. به

این ترتیب که ابتدا بهترین درصد داده ها برای یادگیری با بیشترین ضریب همبستگی انتخاب شد. سپس با مشخص شدن بهترین درصد داده ها برای یادگیری، درصد های بهینه نیز برای ارزیابی و آزمون (جداول ۶ تا ۸) درمورد سختی، خلوص و درصد دفع ترکیبات غیرقندی بدست آمد.

**Table 6** The Best Percentage of Data to Prediction of Hardness values of Permeate Flow for learning, validation and testing of ANN.


| Training Data (%) | Validation Data (%) | Testing Data (%) | MSE          | NMSE         | MAE          | R            |
|-------------------|---------------------|------------------|--------------|--------------|--------------|--------------|
| 25                | 5                   | 70               | 186.612      | 0.995        | 5.020        | 0.182        |
| 25                | 10                  | 65               | 193.631      | 0.983        | 4.744        | 0.238        |
| 25                | 15                  | 60               | 18.686       | 0.652        | 3.678        | 0.656        |
| 25                | 20                  | 55               | 18.211       | 0.616        | 3.551        | 0.682        |
| 25                | 25                  | 50               | 16.007       | 0.531        | 3.291        | 0.765        |
| 25                | 30                  | 45               | 13.491       | 0.463        | 2.889        | 0.775        |
| <b>25</b>         | <b>35</b>           | <b>40</b>        | <b>9.715</b> | <b>0.309</b> | <b>2.694</b> | <b>0.892</b> |
| 25                | 40                  | 35               | 17.038       | 0.515        | 3.402        | 0.766        |
| 25                | 45                  | 30               | 22.789       | 0.669        | 4.205        | 0.633        |
| 25                | 50                  | 25               | 20.404       | 0.506        | 3.699        | 0.756        |
| 25                | 55                  | 20               | 17.094       | 0.444        | 3.260        | 0.814        |
| 25                | 60                  | 15               | 13.139       | 0.365        | 2.674        | 0.820        |
| 25                | 65                  | 10               | 13.893       | 0.301        | 2.975        | 0.857        |
| 25                | 70                  | 5                | 23.726       | 0.508        | 4.384        | 0.758        |

**Table 7** The Best Percentage of Data to Prediction of Purity values of Permeate Flow for learning, validation and testing of ANN.

| Training Data (%) | Validation Data (%) | Testing Data (%) | MSE          | NMSE         | MAE          | R            |
|-------------------|---------------------|------------------|--------------|--------------|--------------|--------------|
| <b>50</b>         | <b>5</b>            | <b>45</b>        | <b>0.015</b> | <b>0.032</b> | <b>0.099</b> | <b>0.985</b> |
| 50                | 10                  | 40               | 0.021        | 0.046        | 0.121        | 0.978        |
| 50                | 15                  | 35               | 0.032        | 0.071        | 0.145        | 0.968        |
| 50                | 20                  | 30               | 0.069        | 0.139        | 0.184        | 0.954        |
| 50                | 25                  | 25               | 0.032        | 0.065        | 0.135        | 0.973        |
| 50                | 30                  | 20               | 0.031        | 0.071        | 0.129        | 0.963        |
| 50                | 35                  | 15               | 0.031        | 0.061        | 0.132        | 0.968        |
| 50                | 40                  | 10               | 0.037        | 0.179        | 0.162        | 0.949        |
| 50                | 45                  | 5                | 0.041        | 0.138        | 0.166        | 0.960        |

**Table 8** The Best Percentage of Data to prediction of Non-sugar rejection values of Permeate Flow for learning, validation and testing of ANN.

| Training Data (%) | Validation Data (%) | Testing Data (%) | MSE           | NMSE         | MAE          | R            |
|-------------------|---------------------|------------------|---------------|--------------|--------------|--------------|
| 35                | 5                   | 60               | 102.261       | 0.532        | 7.810        | 0.686        |
| 35                | 10                  | 55               | 92.519        | 0.450        | 5.733        | 0.768        |
| 35                | 15                  | 50               | 25.356        | 0.139        | 3.454        | 0.938        |
| 35                | 20                  | 45               | 23.722        | 0.135        | 3.814        | 0.939        |
| 35                | 25                  | 40               | 36.537        | 0.216        | 4.647        | 0.913        |
| 35                | 30                  | 35               | 32.312        | 0.179        | 4.205        | 0.933        |
| 35                | 35                  | 30               | 20.036        | 0.101        | 3.569        | 0.951        |
| <b>35</b>         | <b>40</b>           | <b>25</b>        | <b>16.263</b> | <b>0.082</b> | <b>3.413</b> | <b>0.971</b> |
| 35                | 45                  | 20               | 45.952        | 0.231        | 4.926        | 0.911        |
| 35                | 50                  | 15               | 83.160        | 0.461        | 7.329        | 0.770        |
| 35                | 55                  | 10               | 79.761        | 0.442        | 7.535        | 0.753        |
| 35                | 60                  | 5                | 36.979        | 0.127        | 3.755        | 0.965        |

**Fig 1** The correlation coefficient between experimental values and predicted values by the model for the hardness, purity and Non-sugar rejection.

همانطور که در جداول ۶ تا ۸ دیده شد، بهترین ضریب همبستگی در پیش بینی سختی توسط شبکه با اختصاص دادن ۲۵ درصد از داده ها برای آموزش، ۳۵ درصد برای ارزیابی شبکه و ۴۰ درصد برای آزمون شبکه بدست آمد. همچنین بهترین مدل برای پیش بینی خلوص با درصدهای ۵، ۵۰ و ۴۵ از داده ها برای آموزش، ارزیابی و تست بدست آمد. در حالی که بهترین ضریب همبستگی مدل برای پیشگویی درصد دفع ترکیبات غیرقندی مربوط به ۳۵، ۴۰ و ۲۵ درصد از داده ها به ترتیب برای آموزش، ارزیابی و آزمون بود.

### ۳-۲- بررسی همبستگی مقادیر آزمون شده

#### توسط شبکه با داده های آزمایشگاهی

شکل ۱ نمودار همبستگی داده های تجربی (آزمایشگاهی) با داده های پیش بینی شده (مدل) توسط شبکه عصبی مصنوعی را نشان می دهد. نتایج حاصله از بررسی این نمودارها نشان داد که مقادیر آزمون شده ی سختی، خلوص و درصد دفع ترکیبات غیرقندی توسط مدل به ترتیب با ضرایب ۰/۹۷۱، ۰/۹۷۱ و ۰/۹۷۱ با مقادیر آزمایشگاهی همبستگی داشتند.

دفع ترکیبات آب پرس تفاله چغندر قند با فرآیند نانوفیلتراسیون مهمترین عامل ایجاد کننده روی حساسیت مدل را دما عنوان کردند [۱۲].




Fig 2 The sensitivity of the models for prediction of hardness, purity, and Non-sugar rejection

### ۳-۳- تعیین حساسیت مدل به داده های ورودی

در این بررسی در نهایت حساسیت مدل ها نسبت به متغیرهای عملیاتی یا همان داده های ورودی مورد ارزیابی قرار گرفت که بر اساس شکل ۲ بیشترین حساسیت مدل برای پیشگویی سختی و درصد دفع ترکیبات غیرقندی مربوط به دما و برای پیشگویی خلوص مربوط به زمان بود. در این رابطه می توان گفت که در دماهای بالا به دلیل افزایش ضریب نفوذ در غشاء و همچنین انبساط حفرات غشاء عبور ترکیبات مختلف از غشاء بیشتر می شود. اما چون فرآیند غشایی مذکور به صورت سیرکولاسیون مستقیم صورت گرفت لذا با گذشت زمان و غلیظ شدن بیشتر ترکیبات ناخالصی در خوراک ورودی بر روی خلوص تاثیرگذار بود [۱۹]. شهیدی و همکاران (۲۰۱۱) نیز طی مدل سازی درصد

Table 9 The general results of Modeling by ANN for ultrafiltration of microfiltered raw beet sugar juice

| Independent parameter   | Hidden layer | Number of neurons | Transfer Function | Learning law | Percentage of data for learning, validation and testing | Correlation coefficient |
|-------------------------|--------------|-------------------|-------------------|--------------|---|-------------------------|
| Hardness                | 1            | 13                | Tangent           | Momentum     | 25/35/40  | 0.892                   |
| Purity                  | 1            | 15                | Tangent           | Levenberg    | 50/5/45   | 0.985                   |
| Non-sugar Rejection (%) | 1            | 18                | Sigmoid           | Levenberg    | 35/40/25  | 0.985                   |

با ضریب همبستگی مناسب ۰/۹۸۵ مدل و توسط شبکه آن پیشگویی شد (جدول ۹).

### ۴- نتیجه گیری

نتایج مدل سازی فرآیند اولترافیلتراسیون شربت خام چغندر میکروفیلتر شده در تصفیه شربت خام چغندر قند نشان داد که اگر تغییرات سختی تحت قانون یادگیری مومنتوم و با تابع انتقال تانژانت با تعداد نورون ۱۳ و با ۲۵، ۳۵ و ۴۰ درصد داده ها به ترتیب برای آموزش ارزیابی و آزمون مورد استفاده قرار گیرد بیشترین ضریب همبستگی (۰/۸۹۲) را خواهد داشت در حالیکه برای تغییرات خلوص قانون یادگیری لونیبرگ و تابع انتقال تانژانت در تعداد نورون ۱۵ بهترین شبکه را با ۵۰، ۵ و ۴۵ درصد داده ها به ترتیب برای آموزش، ارزیابی و آزمون (R = ۰/۹۸۵) طراحی کرد. تغییرات درصد دفع ترکیبات غیرقندی نیز با قانون یادگیری لونیبرگ و تابع انتقال سیگموئید در نورون شماره ۱۸ و با ۴۰، ۳۵ و ۲۵ درصد از داده ها برای آموزش، ارزیابی و آزمون

### ۵- منابع

- [1] Djuri, M., Gyura, J. and Zavargo, Z. 2004. The analysis of process variables influencing some characteristics of permeate from ultra and nanofiltration in sugar beet processing. *Desalination* 169 167-183.
- [2] Balakrishnan, M., Dau, M. and Bhagat, J. 2000. Ultrafiltration for juice purification in plantation white sugar manufacture. *International Sugar Journal* 102, 21-25.
- [3] Hinkova, A., Bubnik, Z., Kadlec, P. and Pridal, J. 2002. Potentials of separation membranes in the sugar industry. *Separation and Purification Technology* 26, 101-110.



- [13] Zarifpoor, M. & Hakimzadeh, V. 2018. Investigating of artificial neural network potential to predict the properties of refined raw sugar beet juice by electrocoagulation process. *Ukrainian Food Journal. Volume 7. Issue 4: 682-691.*
- [14] Hakimzadeh, V., Razavi, S.M.A., & Pirouzifard, M.K. 2006. The potential of microfiltration and ultrafiltration process in purification of raw sugar beet juice. *Desalination*, 200: 520–522.
- [15] ICUMSA .2000. The determination of calcium in sugar products by EDTA titration. *Method GS8/2/3/4-9.*
- [16] Razavi, S.M.A. Mousavi, S. M and Mortazavi, S. A. 2003. Dynamic prediction of milk ultrafiltration performance: a neural network approach. *Chemical Engineering Science*, 58 4185–4195
- [17] Salehi, F. and Razavi, S.M.A. 2012. Dynamic modeling of flux and total hydraulic resistance in nano filtration treatment of regeneration waste brine using artificial neural network. *Desalination and Water Treatment*, 41: 95-104.
- [18] Movagharnejad K., Nikzad, M. (2007). Modeling of tomato drying using artificial neural network. *Comput. Electron*: 78-85.
- [19] Hakimzadeh, V., Mousavi, S.M. Elahi, M. and Razavi, S.M.A. 2017. Purification of Raw Cane Sugar by Micellar-Enhanced Ultrafiltration Process Using Linear Alkylbenzene Sulphonate (LAS). *Journal of Food Processing and Preservation*. 41(3).
- [4] Ghosh, A.M., and Balakrishnan, M. 2003. Pilot demonstration of sugarcane juice ultrafiltration in an India sugar factory. *Journal of Food Engineering* 58, 143-150.
- [5] Gyura, J. Šereš, Z. Eszterle, M. 2005. Influence of operating parameters on separation of green syrup colored matter from sugar beet by ultra- and nanofiltration. *Journal of Food Engineering*. 66, 89–96.
- [6] Vern, C. 1995. The beet sugar factory in the future. *International Sugar Journal*. 97, 310-314.
- [7] Hamachi, M, Gupta, B.B. and Ben Aim, R. 2003. Ultrafiltration: a means for decolorization of cane sugar solution. *Separation and Purification Technology*, 30, 229-239.
- [8] Hanssens, T.R., Vannispén, J.G. M., Koerts, K. and Nie, L.H.de. 1984. Ultrafiltration an alternative for raw juice purification in the beet sugar industry. *Zuckerind*, 109, 16-24.
- [9] Misra, S.N., Balakrishnan, M. and Ghosh, A.M. 2000. Improvement in clarified juice characteristics through ultrafiltration. *Proc. S.T.A.I.*, 62, 28-36.
- [10] Delgerange, N., Cabassud, C., Cabassud, M., Durand-Bourlier, L., and Lain, J.M. 1998. Neural network for prediction of ultrafiltration transmembrane pressure application to drink water. *Journal of Membrane Science*, 150, pp. 111–123.
- [11] Masciola, D. A. Viadero, R.C and Reed, B.E. 2001. UF flux prediction for oil-in-water emulsions: Anal Series Resistance. *Journal of Membrane Science*. 184 197.
- [12] Shahidi Noghabi, M. Razavi, S.M.A and Mousavi, S. M. 2012. Prediction of permeate flux and ionic compounds rejection of sugar beet press water nanofiltration using artificial neural networks. *Desalination and Water Treatment*, 44:1-3, 83-91.

## Modeling the Efficiency of Ultrafiltration Process in Purification of Microfiltered Raw Sugar Beet juice by Artificial Neural Network

Shayan, T. <sup>1</sup>, Hakimzadeh, V. <sup>2\*</sup>, Shahidi Noghabi, M. <sup>3</sup>

1. M.Sc. student of department of food science and technology, Quchan Branch, Islamic Azad University, Quchan, Iran.
2. Assistant professor of department of food science and technology, Quchan Branch, Islamic Azad University, Quchan, Iran.
3. Associate Professor of Department of food chemistry, Research institute of food science and technology (RIFST), Mashhad, Iran.

(Received: 2018/11/14 Accepted:2019/04/07)

The ultrafiltration process as one of the membrane processes based on pressure can replace with the conventional method (liming-carbonation) as a new method in sugar industry. In this research, reduction of hardness, increasing the non-sugar rejection components and improving the purity of permeate flow were modeled during the treatment of raw beet syrup with ultrafiltration by artificial neural network. The ultrafiltration process was carried out at three temperatures of 30, 40 and 50 ° C, three pressures in the membrane 1, 2 and 3 times in eight intervals of equal time of 1 to 60 minutes. The best model for reduction of hardness was obtained with a hidden layer, the number of 13 neurons, the tangent transfer function, the momentum learning law, and the percentage of data 25, 35, and 40 for training, evaluation, and test, respectively. The variation of non-sugar rejection compounds with a hidden layer, 15 neurons, tangent transfer function, Levenberg learning law, and assigning 50, 5 and 45 percent of the data to training, evaluating and testing with the least error and the highest correlation coefficient during modeling. Improvement of the purity of permeate flow during ultrafiltration with a hidden layer, 18 neurons, sigmoid transfer function, Levenberg learning law and data percentages 35, 40 and 25 for training, evaluation, and testing created the best network. Also, the highest correlation coefficient between laboratory data and predicted values with the model was obtained for hardness variation, non-sugar rejection compounds and purity, 0.892, 0.985 and 0.985 respectively.

**Keywords:** Correlation Coefficient, Neural network, Modeling, Tangent, Ultrafiltration.

---

\*Corresponding Author: Email Address: [vhakimzadeh@yahoo.com](mailto:vhakimzadeh@yahoo.com)