

مدلسازی خصوصیات فیزیکی تخته خرده‌چوب ساخته شده از ساقه کلزا با استفاده از شبکه‌های عصبی مصنوعی: ANFIS و RBFN MLP

مرتضی ناظربیان^{*}، سجاد اکبری^۲، حسین کرمانیان^۳، مسعود هاشمی^۴

۱. دانشیار گروه کامپوزیت‌های لیگنوسلولوزی، دانشکده مهندسی انرژی و فناوری‌های نوین، دانشگاه شهید بهشتی، تهران
۲. کارشناس ارشد فراورده‌های چندسازه چوبی، دانشکده منابع طبیعی، دانشگاه زابل، زابل، ایران
۳. استادیار گروه فناوری کاغذ و سلولز، دانشکده مهندسی انرژی و فناوری‌های نوین، دانشگاه شهید بهشتی، تهران
۴. کارشناس ارشد خاک‌شناسی، دانشکده آب و خاک، دانشگاه زابل، زابل، ایران

تاریخ دریافت: ۱۳۹۵/۰۲/۲۹، تاریخ پذیرش: ۱۳۹۴/۰۶/۳۱

چکیده

فاکتورهای مختلفی بر روی خواص اوراق مرکب چوبی تاثیر گذار هستند. بررسی تمامی این فاکتورها تنها اتفاف وقت و انرژی را افزایش می‌دهد، همچنین دقت در برآورد میزان تاثیر متغیرهای انتخاب شده در ساخت به منظور حصول نقطه بهینه از خواص مختلف فراورده‌های مرکب چوبی را کاهش می‌دهد. از این‌رو، لازم است تا از متدهای نوین آماری برای تعیین مدل برآورد کننده نقطه بهینه تولید استفاده نمود. هدف این تحقیق، ارزیابی عملکرد شبکه‌های عصبی مصنوعی در راستای مدل‌سازی خواص فیزیکی تخته خرده‌چوب ساخته شده از ساقه کلزا بود. مدل‌سازی و امکان تخمین خصوصیات فیزیکی تخته خرده‌چوب با استفاده از نسبت ملامین فرمالدئید به اوره فرمالدئید، نسبت ساقه کلزا به صنوبر و مقدار رطوبت کیک به روش‌های شبکه‌های عصبی مصنوعی: ANFIS و RBF MLP بررسی شد. نتایج نشان داد که شبکه عصبی MLP نسبت به شبکه RBFN و ANFIS عملکرد بهتری در زمینه برآورد خصوصیات فیزیکی تخته خرده‌چوب دارد. همچنین نتایج نشان داد که مدل‌های هوش مصنوعی در زمینه پیش‌بینی خصوصیات فیزیکی تخته خرده‌چوب، دقت و توانایی مناسبی دارند. نتایج آنالیز حساسیت نیز نشان داد که در زمینه برآورد TS₂ و WA₂₄ مهم‌ترین پارامتر با تأثیر مثبت در روند مدل‌سازی، مقدار رطوبت کیک است و نسبت ملامین فرمالدئید به اوره فرمالدئید نیز در زمینه مدل‌سازی TS₂₄ و WA₂ مؤثرترین پارامتر است.

واژگان کلیدی: تخته خرده‌چوب، خواص فیزیکی، شبکه‌های عصبی مصنوعی.

مقدمه

عامل‌های تأثیرگذار بر خواص فیزیکی تخته خرده‌چوب هستند. در اغلب موارد، تعیین خواص فیزیکی با توجه به روش‌های ذکر شده در استانداردهای رایج، به تجهیزات و زمان طولانی نیاز دارد. این به معنای تأخیر در تشخیص عیوب در محصول نهایی است [۱].

تلاش‌های فراوانی به منظور ساخت مدل‌هایی در زمینه پیش‌بینی خواص چوب و فراورده‌های آن انجام گرفته است. فریده و نوردین (۲۰۱۲) به معرفی مدلی برای

در فرایند تولید تخته خرده‌چوب، برای تولید محصولات باکیفیت و دارای خواص کاربردی مطلوب، باید فرایند ساخت و فاکتورهای آن در نظر گرفته شود. نوع مواد اولیه، نوع و مقدار رزین و رطوبت کیک از جمله

* نویسنده مسئول، تلفن: ۰۹۱۱۲۹۱۰۸۶۰، ۰۵۴۳۲۲۳۲۶۰۰، فاکس: ۰۵۴۳۲۲۳۲۶۰۰.

Email: morteza17172000@yahoo.com

و زمان ژله‌ای شدن ۴۲ ثانیه، شرکت شیمیایی فارس شیراز) بوده است. پس از خشک شدن تا رطوبت ۳ درصد، ذرات در اون در کیسه‌های پلاستیکی نگهداری شدند. برای ساخت تخته‌های آزمونی، درصد ملامین فرمالدئید به کاررفته در کل رزین در پنج سطح (۲۵، ۱۸/۷۵، ۱۲/۵ و ۰ درصد)، نسبت وزنی ذرات ساقه کلزا با خرده‌چوب صنوبر در پنج سطح (۱۰۰، ۹۳/۷۵، ۸۷/۵، ۸۱/۲۵ و ۷۵ درصد) و رطوبت کیک خرده‌چوب در پنج سطح (۲۲، ۱۸، ۱۴، ۱۰ و ۶ درصد) به عنوان متغیرهای مستقل انتخاب شدند.

ابتدا به وسیله ترازوی دیجیتالی با دقیق ۰/۰۱ گرم مقداری خرده‌چوب با ذرات ساقه کلزای مورد نیاز با نسبت معین منطبق بر طرح آزمونی به کاررفته برای هر تیمار توزین و در داخل یک دستگاه چسبزن آزمایشگاهی ریخته و با چسب (۱۰ درصد وزن خشک ماده چوبی و با غلظت ۶۰ درصد) به مدت ۵ دقیقه هم زده شد. پس از شکل دهی دستی و یکنواخت کیک در یک قالب چوبی به ابعاد $35 \times 35 \times 22$ سانتی‌متر و سپس خروج قالب، کیک به دست آمده در داخل دستگاه پرس هیدرولیکی تحت فشار ۱۵ کیلوگرم بر سانتی‌متر مربع و دمای ۱۶۵ درجه سانتی‌گراد به مدت ۶۶۰ ثانیه قرار گرفت. سرعت بسته شدن دهانه پرس $4/5$ میلی‌متر بر ثانیه، ضخامت تخته‌ها ۱۶ میلی‌متر ثابت و دانسیته تخته‌ها برابر $0/65$ گرم بر سانتی‌متر مکعب ثابت شدند. پس از ۶۵ مشروطسازی در اتاق کلیماتیزه در رطوبت نسبی ۶۵ درصد و حرارت 20 ± 2 درجه سانتی‌گراد به مدت دو هفته نمونه‌های آزمون با ابعاد $50 \times 50 \times 16$ میلی‌متر بریده شدند. سپس خواص فیزیکی نمونه‌های آزمون شامل واکنش‌گی ضخامت و جذب آب پس از ۲ و ۲۴ ساعت غوطه‌وری در آب براساس دستورالعمل EN ۳۱۷ [۵] اندازه‌گیری شد. تعداد تیمارها برابر ۱۲۵ با سه تکرار و در مجموع

پیش‌بینی خواص فیزیکی تخته فیبر توسط شبکه عصبی پرسپترون چندلایه پرداختند [۲]. آنها نشان دادند که مدل قادر به پیش‌بینی خواص فیزیکی تخته فیبر با دانسیته متوسط بوده و دارای قابلیت جایگزینی با آزمون‌های رایج آزمایشگاهی به منظور کاهش زمان صرفشده برای اجرای آزمون است. او Sahin (۲۰۱۲) برای پیش‌بینی خواص فیزیکی تخته تراشه جهت دار از شبکه عصبی مصنوعی استفاده کرد [۳]. نتایج نشان داد مدل‌های جذب رطوبت و واکنش‌گی ضخامت برای دیگر کامپوزیت‌های چوبی نیز تعیین‌پذیر است. فرناندز و همکاران (۲۰۰۸) خواص مکانیکی تخته خرده‌چوب را براساس خواص فیزیکی با دو روش مدلسازی رگرسیونی خطی و شبکه عصبی پیش‌بینی کردند [۴]. نتایج نشان داد روش‌های رگرسیونی مقاومت خمی، مدول الاستیسیته و چسبندگی داخلی تخته خرده‌چوب را به ترتیب با خطای بیشتری نسبت به شبکه عصبی پیش‌بینی می‌کنند. هدف این تحقیق، ارزیابی عملکرد شبکه‌های عصبی مصنوعی (RBFN و MLP) و سیستم نوروفازی در راستای مدلسازی خواص فیزیکی تخته خرده‌چوب ساخته شده از ساقه کلزا، و معرفی مؤثرترین ورودی‌ها در روند مدلسازی است.

مواد و روش‌ها

ضایعات ساقه کلزا از مزارع شهرستان شیراز و چوب صنوبر به صورت رشتہ‌چوب صنوبر (پوشال کولر) آماده از کارگاه‌های پوشال‌گیری زاپل تهیه شد. این مواد پس از انتقال به آزمایشگاه با ابعاد مناسب با یک خردکن آزمایشگاهی مدل 20 Retsch AZ 15 ZVK-M خرد شدند. رزین مصرفی نیز چسب اوره فرمالدئید (دانسیته $1/26$ گرم بر سانتی‌متر مکعب، مواد جامد 63 درصد، pH $9/4$ و زمان ژله‌ای شدن 60 ثانیه، شرکت چسب سامد مشهد) و ملامین فرمالدئید (دانسیته $1/24$ گرم بر سانتی‌متر مکعب، مواد جامد $60/1$ درصد، pH $9/4$) معادل

داده های خروجی باید در محدوده بین صفر و ۱ نرمال سازی شوند. از این رو، نرمال سازی مقادیر درون محدوده یکسان برای جلوگیری از ورود داده های با اندازه بزرگ تر نسبت به داده های کوچک تر در راستای یکسان کردن ارزش داده ها بسیار حیاتی است. در مطالعه حاضر، مقیاس بندی داده ها بین محدوده ۰-۱ توسط رابطه (۲) انجام گرفت [۹]:

$$X_{\text{norm}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (2)$$

جایی که X_{norm} مقدار نرمال سازی است، X_{\max} و X_{\min} واقعی اند، به ترتیب مقدار ماکریم و مینیم مجموعه داده هاست.

تفاوت اساسی شبکه های تابع پایه شعاعی^۳ با شبکه های پرسپترون چند لایه، در محاسبه بردار ورودی و نوع تابع محرك است. در این روش اغلب، تابع محرك در لایه میانی تابع گوسین بوده، در حالیکه در لایه خروجی تابع از نوع خطی است. مقدار بهینه پهنای تابع گوسین باید از فرایند آزمون و خطا به دست آید. این شبکه این قابلیت را دارد که برای داده های آموزشی خطایی برابر صفر دهد [۱۰].

سیستم استنتاج فازی^۴ (ANFIS) بر مبنای تطبیق شبکه تاکنون کاربرد موفقیت آمیزی در زمینه حل مسائل مختلف داشته است [۱۱]. سیستم عصبی- فازی از الگوریتم یادگیری شبکه عصبی جفت شده با استدلال فازی برای برآورد توزیع خروجی به کمک توزیع ورودی بهره می گیرد. سیستم عصبی- فازی به طور معمول با الگوریتم یادگیری هیبرید دگرآموخته (نظرارت شده) برای بهینه سازی پارامترهای خطی و غیرخطی آموزش داده می شود [۱۱]. نمونه ای از ساختار مدل ساخته شده سیستم عصبی فازی در شکل ۲ ارائه شده است.

۳۷۵ تخته ساخته شد. تعداد نمونه برای هر آزمون نیز بعد از اندازه بری ۹ عدد انتخاب شد.

شبکه های عصبی مصنوعی

ساختار شبکه عصبی مصنوعی شامل سه لایه است: لایه ورودی که شامل همه متغیرهای مورد بررسی وارد شده به شبکه به همراه محاسبه وزن هر یک از آنها است، لایه پنهان یا لایه های میانی، که داده های آزمایش هستند، و لایه خروجی، که نتایج به دست آمده شبکه عصبی مصنوعی است [۶]. شبکه های چند لایه پیشخور از مهم ترین ساختارهای شبکه های عصبی مصنوعی است. این شبکه ها شامل مجموعه ای از واحد های حسی (نورون های پایه) هستند که لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی را تشکیل می دهند. این نوع پرسپترون چند لایه^۱ نامیده می شود [۷]. در تحقیق حاضر، برای مدل سازی با استفاده از شبکه های MLP از یک شبکه سه لایه ای پیشخور^۲ استفاده شده است (شکل ۱).

مقادیر نرمال شده که به لایه ورودی منتقل شده است و بعد از آن از لایه ورودی به لایه بعدی که لایه پنهان نامیده می شود، قبل از رسیدن به لایه خروجی شبکه انتشار می یابد. هر نورون در لایه پنهان یا خروجی در وهله اول به عنوان یک محل اتصال جمع عمل می کند که با استفاده از ورودی های معادله (۱) ترکیب می شود و نسبت به لایه قبل تغییر می کند [۸].

$$Y_i = \sum_{j=1}^i X_j W_{ij} + b_j \quad (1)$$

که Y_i ورودی شبکه به نورون j در لایه پنهان، W_{ij} وزن مربوط به نورون i و b_j ورودی نورون j و b_j تحت تأثیر اتصال به نورون j است.

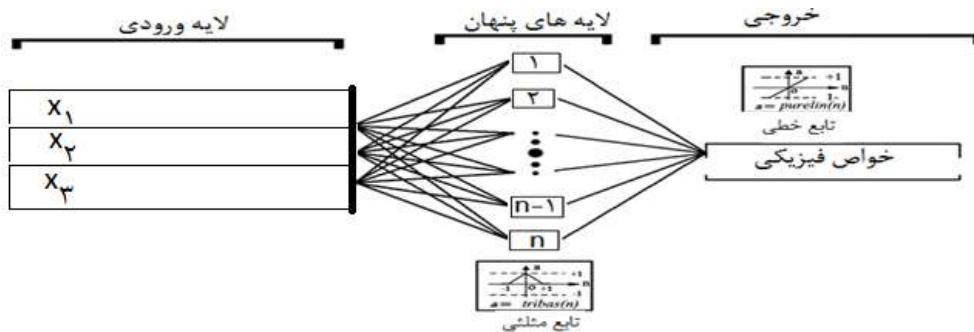
تابع مثالی بین صفر و ۱ است و به منظور روابط غیرخطی استفاده می شود. در نتیجه ورودی و همچنین

3. Radial Basis Function Network

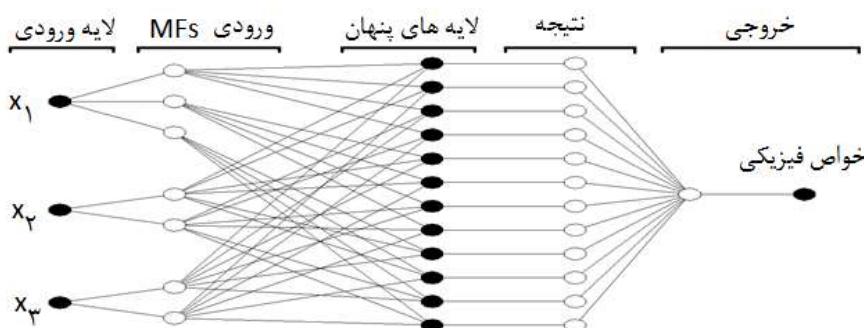
4. Adaptive Network-based Fuzzy Inference System

1. Multiple Layer Perceptron

2. Feedforward



شکل ۱. ساختار شبکه عصبی پرسپترون چندلایه (MLP)



شکل ۲. ساختار مدل ساخته شده سیستم عصبی فازی

توسعة یک روش با فاکتورهای چندورودی با هدف خروجی در مدل های ANN از اهمیت حیاتی برخوردار است [۱۲].

فرایند آنالیز حساسیت اطلاعات ارزشمندی را درباره میزان حساسیت مدل به متغیرهای ورودی آن در اختیار طراح و معمار مدل قرار می دهد. با شناسایی حد تأثیر متغیرهای ورودی بر دقت پیش‌بینی مدل، می‌توان متغیرهای کم‌اثر را از شبکه حذف کرد و مدل ساده‌تری را بسط و توسعه داد. در این پژوهش برای آنالیز حساسیت مدل از روش هیل (1998) استفاده شد [۱۳]. به منظور مقایسه مقادیر خصوصیات فیزیکی پیش‌بینی شده توسط مدل‌های به کار گرفته شده با مقادیر اندازه‌گیری شده و همچنین، مقایسه دقت مدل‌های موجود، از پارامترهای ضریب تبیین (رابطه R^2) و ریشه میانگین مربعات خطای (رابطه $RMSE$) استفاده شد:

در این پژوهش، ۷۰ درصد داده‌ها برای آموزش مدل و ۳۰ درصد به عنوان داده‌های آزمون مدل انتخاب شدند. فرایند آموزش که شامل تغییر وزن‌ها بین لایه‌های مختلف در طول زمان آموزش است، انجام گرفت تا جایی که تفاوت بین داده‌های واقعی (برای داده‌های آموزش) و داده‌های پیش‌بینی شده به حداقل برسد. در شبکه عصبی MLP قاعدة آموزشی لونبرگ مارکووات و توابع انتقال مثلثی و تانژانت هایپربولیک برای فرایند آموزش به کار گرفته شدند. تعداد نورون‌ها در لایه پنهان به روش آزمون و خطأ تعیین و برابر ۸ در نظر گرفته شد. مدل‌سازی‌ها با استفاده از نرم‌افزار MATLAB صورت گرفت.

بزرگ‌ترین سودمندی مدل‌های شبکه عصبی دقت و صحت آنهاست، اما فاقد فرایند فیزیکی بوده، مدل‌هایی ضعیف از نوع جعبه سیاه اند که فرایند مدل‌سازی شده را توضیح نمی‌دهند و سودمندی آنها بدون اطلاعات در زمینه اهمیت نسبی پارامترها در سیستم محدود است.

توانایی شبکه عصبی RBF و سیستم نوروفارازی نیز به منظور پیش‌بینی خصوصیات TS_{۲۴} و TS_{۲۶} مناسب بوده و نزدیک به عملکرد شبکه MLP است. اما چنانکه در شکل ۳ نیز مشاهده می‌شود، روش نوروفارازی در زمینه پیش‌بینی WA_{۲۴} بسیار ضعیف عمل کرده است ($RMSE = ۹/۸۳$ و $R^2 = ۰/۳۲$). تفاوت‌ها در نتایج به دست آمده از مدلسازی خصوصیات مورد بررسی توسط روش‌های مورد استفاده در این تحقیق می‌تواند به نوع داده‌های مورد مطالعه و ارتباط آن با ورودی‌های استفاده شده در راستای مدلسازی و حتی تفاوت ساختاری موجود در بین روش‌های مورد استفاده مربوط باشد. با توجه به جدول ۱، در زمینه مدلسازی توسط شبکه عصبی MLP در لایه پنهان تابع مثلثی استفاده شده است، در صورتی که در شبکه عصبی RBFN تابع آموزشی در لایه پنهان، پایه‌ای شعاعی بوده و در سیستم نوروفارازی، نوع تابع عضویت در لایه دوم به‌جز در مورد مدلسازی WA_{۲۴} که مثلثی است، در بقیه موارد، تابع گوسین است. در بین روش‌های به کار گرفته شده برای مدلسازی TS_{۲۶}، TS_{۲۴} شبکه عصبی MLP عملکرد بهتری نشان داده است و همان‌طور که در شکل ۳ مشاهده می‌شود در مرحله آزمون، داده‌های پیش‌بینی شده تطابق بهتری با داده‌های اندازه‌گیری شده دارند و به خوبی توانسته اند مقادیر خصوصیات فیزیکی را تخمین بزنند. همچنین نتایج جدول ۱ به منظور مدلسازی WA_{۲۶} حاکی از آن است که شبکه MLP و سیستم ANFIS در مقایسه با شبکه RBFN عملکرد مناسب‌تری داشته‌اند. این در صورتی است که عملکرد سیستم نوروفارازی نیز نسبت به شبکه عصبی MLP با در نظر گرفتن مقدار ریشه میانگین مربعات خطای (به ترتیب ۳/۳۷ و ۳/۵۸) بهتر است. با این حال، شبکه عصبی MLP با توجه به مقدار $R^2 = ۰/۹۶$ برتری دارد. گفتنی است روش‌های محاسباتی مبتنی بر هوش مصنوعی در لحاظ کردن روابط پیچیده و غیرخطی بین خصوصیات فیزیکی تخته خرده‌چوب و ورودی‌های در نظر گرفته شده برای مدلسازی در این تحقیق بسیار موفق عمل کرده‌اند. پیش‌بینی

$$R^2 = \frac{\sum_{i=1}^N (Z - \hat{Z})}{\sum_{i=1}^N (Z - Z^*)^2} \quad (3)$$

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

که \hat{Z} : مقادیر برآورده در نقطه i ام، Z^* : میانگین مقادیر پیش‌بینی شده و Z : مقادیر مشاهده‌ای برای نقطه i ام و N : تعداد نمونه‌ها است. تجزیه و تحلیل داده‌ها با استفاده از نرم‌افزار اکسل صورت گرفت.

نتایج و بحث

در زمینه پیش‌بینی خصوصیات فیزیکی تخته خرده‌چوب توسط روش‌های هوش مصنوعی (MLP، RBFN و ANFIS) با استفاده از پارامترهای نسبت ملامین فرمالدئید به اوره فرمالدئید (x_1)، نسبت ساقه کلزا به صنوبر (x_2) و مقدار رطوبت کیک (x_3) و امکان مقایسه نتایج این روش‌ها، یک مدل کلی در نظر گرفته شد که در مدل مورد نظر پارامترهای یادشده ورودی شبکه‌ها بوده است. شایان ذکر است که در طی فرایند آموزش مدل‌ها، مناسب‌ترین تعداد نورون‌ها در لایه پنهان و همچنین مناسب‌ترین تابع در زمینه افزایش دقت فرایند یادگیری در نورون‌های لایه پنهان به روش آزمون و خطای انتخاب شد. نتایج مدلسازی‌ها در جدول ۱ آورده شده است.

در زمینه تخمین خصوصیات فیزیکی تخته خرده‌چوب با استفاده از مدل پیشنهادی، مشخص شد که شبکه عصبی MLP به منظور مدلسازی TS_{۲۶} با بیشترین مقدار $R^2 = ۰/۹۶$ و RMSE = ۲/۷۲ نسبت به دیگر روش‌ها کمترین میزان $RMSE = ۲/۷۲$ (ANFIS و RBFN) عملکرد بهتری دارد (جدول ۱). همچنین شبکه عصبی MLP در خصوص مدلسازی TS_{۲۴} و WA_{۲۶} با بیشترین مقادیر ضریب تبیین، به ترتیب ۰/۹۸ و ۰/۹۷ و کمترین خطای، به ترتیب ۳/۳۶ و ۲/۷۸ توانسته است نسبت به دیگر روش‌های مدلسازی، به خوبی این خصوصیات را نیز پیش‌بینی کند (جدول ۱). با این حال،

خرده‌چوب بهوسیله مدل رگرسیونی را به ترتیب ۰/۷۹ و ۰/۶۹ گزارش کردند [۱۳].

در جدول ۲ برخی از آماره‌های مربوط به داده‌های اندازه‌گیری شده و پیش‌بینی شده در مرحله آزمون توسط روش‌های مورد بررسی آورده شده است. مطالعه و بررسی دقیق این آماره‌ها نیز به طور کلی بیانگر برتری شبکه عصبی MLP در راستای مدلسازی و تخمین خصوصیات فیزیکی مورد مطالعه است. چنان‌که مشاهده می‌شود، دامنه MLP پراکشن داده‌های به کار گرفته شده در شبکه عصبی در اکثر موارد بیشتر است و اختلاف انحراف معیار داده‌های پیش‌بینی شده با داده‌های اندازه‌گیری شده در بیشتر موارد کمترین است.

خواص فیزیکی تخته خردکوب با خطای کمتر از ۱۵ درصد پذیرفتنی است [۱۰]. بر این اساس، مقادیر RMSE برای WA_{۲۴} و WA_۲ (جدول ۱) با توجه به محدوده پراکشن داده‌ها برای خواص مورد نظر (جدول ۲)، کمتر از ۱۵ درصد است که عملکرد مناسب روش‌های مدلسازی را نشان می‌دهد.

فرناندز و همکاران (۲۰۱۲) برای پیش‌بینی MOR و MOE تخته لایه بهوسیله شبکه عصبی به ترتیب R^2 برابر با ۰/۷۳ و ۰/۶۶ به دست آوردند [۴]. در مطالعه‌ای مشابه مقدار R^2 به دست آمده بهوسیله مدل رگرسیونی برای پیش‌بینی MOR و MOE به ترتیب ۰/۵۱ و ۰/۴۷ است [۲]. همچنین دمیرکیر و همکاران (۲۰۱۳) مقدار R^2 به دست آمده برای پیش‌بینی MOR و MOE تخته

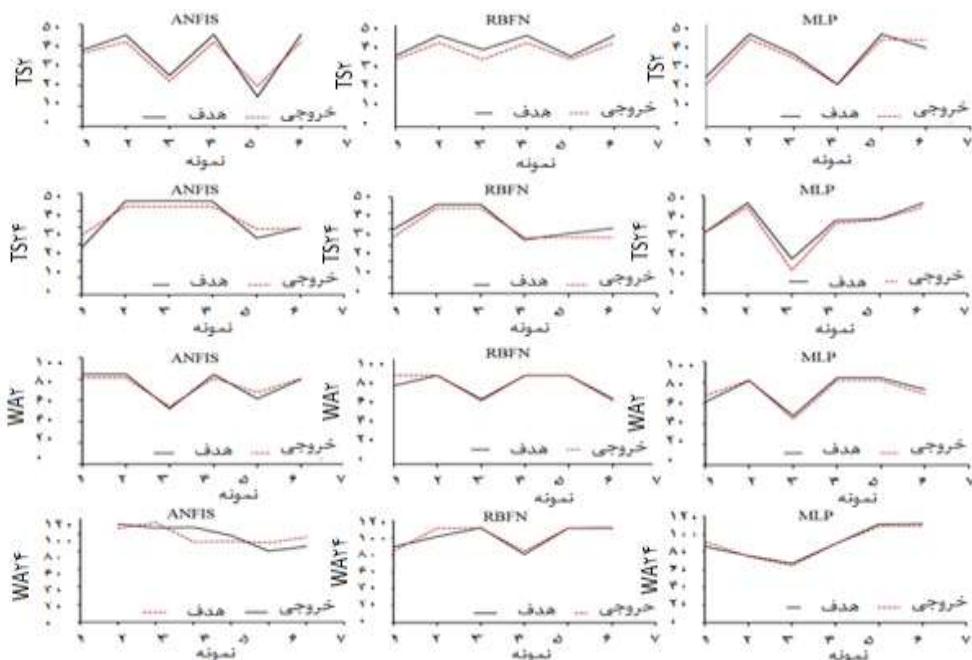
جدول ۱. خصوصیات شبکه‌های عصبی RBF و ANFIS برای مدل‌های پیشنهادی به منظور مدلسازی خواص فیزیکی

منبع	Inputs	MLP Structure					
		Neurons Hidden Layers	HLTF	OLTF	Best epoch	RMSE	R^2
TS _۲	(کلزا:صنوبر×رطوبت)MF:UF	۹	Tribas	Purlin	۶	۲/۲۲	۰/۹۴
TS _{۲۴}	(کلزا:صنوبر×رطوبت)MF:UF	۱۲	Tribas	Purlin	۶	۳/۳۶	۰/۹۸
WA _۲	(کلزا:صنوبر×رطوبت)MF:UF	۱۱	Tribas	Purlin	۶	۳/۵۸	۰/۹۴
WA _{۲۴}	(کلزا:صنوبر×رطوبت)MF:UF	۵	Tribas	Purlin	۷	۲/۷۸	۰/۹۷
RBFN Structure							
Physical properties	Inputs	Neurons Hidden Layers	Spread	Max neuron	RMSE	R^2	
TS _۲	(کلزا:صنوبر×رطوبت)MF:UF	۲	۰/۸	۲۰	۳/۲۷	۰/۹۵	
TS _{۲۴}	(کلزا:صنوبر×رطوبت)MF:UF	۲	۰/۳	۴	۳/۶۶	۰/۹۴	
WA _۲	(کلزا:صنوبر×رطوبت)MF:UF	۲	۱	۶	۴/۱۹	۰/۸۸	
WA _{۲۴}	(کلزا:صنوبر×رطوبت)MF:UF	۲	۰/۱	۶	۴/۷۱	۰/۸۸	
ANFIS Structure							
Physical properties	Inputs	Optimizat ion method	Output MFtype	Input MFtype	Fis. type	RMSE	R^2
TS _۲	(کلزا:صنوبر×رطوبت)MF:UF	Hybrid	Constant	GaussMF	Sugeno	۳/۴۵	۰/۹۷
TS _{۲۴}	(کلزا:صنوبر×رطوبت)MF:UF	Hybrid	Constant	GaussMF	Sugeno	۴/۴۷	۰/۹۷
WA _۲	(کلزا:صنوبر×رطوبت)MF:UF	Hybrid	Constant	GaussMF	Sugeno	۳/۳۷	۰/۹۶
WA _{۲۴}	(کلزا:صنوبر×رطوبت)MF:UF	Hybrid	Constant	TriMF	Sugeno	۹/۸۳	۰/۳۲

* در جدول، OMF (Input Membership Function) IMF (Output Layer Function) OLF (Hidden Layer Function) HLF (Function) و LIF (Input Layer Function) است.

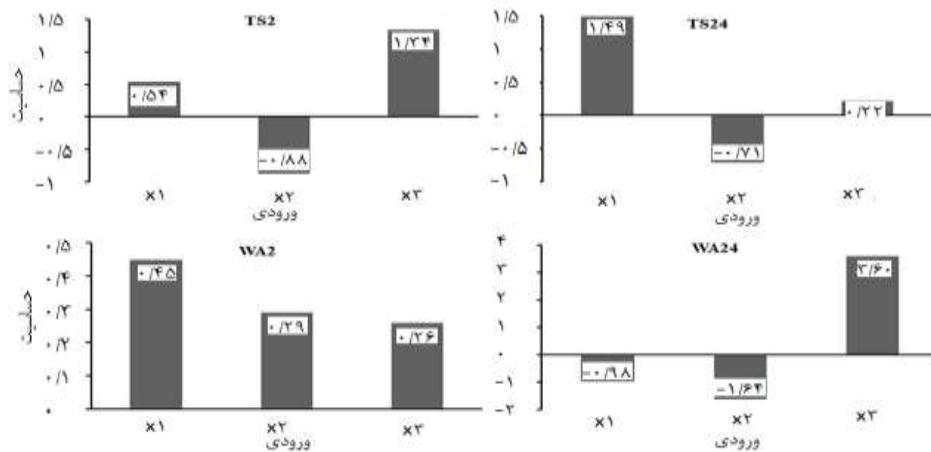
جدول ۱. آماره های مربوط به داده های استفاده شده از روش های مدلسازی در مرحله آزمون خواص فیزیکی تخته

منبع	MLP			RBFN			ANFIS		
	اندازه گیری شده	پیش بینی شده	اندازه گیری شده						
TS ₂	میانگین	۳۷/۷۶	۳۳/۵۸	۴۰/۶۴	۳۷/۵۷	۳۵/۴۳	۳۳/۸۷	۳۳/۸۷	۳۳/۸۷
	حداکثر	۴۵/۱۵	۴۲/۵۷	۴۵/۱۵	۴۱/۷۳	۴۵/۱۵	۴۱/۷۲	۴۱/۷۲	۴۱/۷۲
	حداقل	۲۰/۸۲	۲۰/۳۴	۳۴/۹۳	۳۴/۴۲	۱۴/۵۹	۱۹/۷۷	۱۹/۷۷	۱۹/۷۷
	واریانس	۱۰/۷/۵۹	۱۱۷/۲۴	۲۵/۵۵	۲۰/۷۰	۱۶۵/۵۷	۱۰/۵/۳۳	۱۰/۵/۳۳	۱۰/۵/۳۳
	انحراف میانگین	۱۰/۳۷	۱۰/۸۳	۵/۰/۵	۴/۰/۵۵	۱۲/۸۷	۱۰/۲۶	۱۰/۲۶	۱۰/۲۶
TS _{۲۴}	میانگین	۴۳/۴۹	۴۱/۰/۳	۴۳/۸۱	۴۰/۹۰	۴۴/۷۳	۴۵/۱۵	۴۵/۱۵	۴۵/۱۵
	حداکثر	۵۵/۶۱	۵۳/۱۶	۵۵/۶۵	۳۵/۱۵	۵۵/۶۶	۵۲/۲۹	۵۲/۲۹	۵۲/۲۹
	حداقل	۲۱/۴۴	۱۴/۳۷	۳۳/۷۱	۳۷/۷۸	۲۸/۰/۷	۳۵/۴۹	۳۵/۴۹	۳۵/۴۹
	واریانس	۱۶۴/۹۷	۲۰/۹/۷۶	۸۹/۷۵	۸۹/۹۵	۱۵۶/۳۳	۶۲/۹۶	۶۲/۹۶	۶۲/۹۶
	انحراف میانگین	۱۲/۸۴	۱۴/۴۸	۹/۴۷	۹/۴۸	۱۲/۵۰	۷/۹۴	۷/۹۴	۷/۹۴
WA _۲	میانگین	۷۲/۱۷	۷۱/۱۸	۷۵/۳۵	۷۶/۴۷	۷۴/۶۵	۷۴/۲۴	۷۴/۲۴	۷۴/۲۴
	حداکثر	۸۴/۵۰	۸۲/۳۹	۸۴/۵۰	۸۴/۴۷	۸۴/۵۱	۸۱/۱۳	۸۱/۱۳	۸۱/۱۳
	حداقل	۴۷/۵۲	۴۴/۵۵	۶۱/۸۳	۶۰/۴۸	۵۲/۵۵	۵۴/۱۶	۵۴/۱۶	۵۴/۱۶
	واریانس	۲۲۳/۸۷	۲۱۷/۶۴	۱۲۰/۶۴	۱۵۲/۴۷	۱۹۴/۵۴	۱۲۶/۱۴	۱۲۶/۱۴	۱۲۶/۱۴
	انحراف میانگین	۱۴/۹۶	۱۴/۷۵	۱۰/۹۸	۱۲/۳۹	۱۳/۹۵	۱۱/۲۳	۱۱/۲۳	۱۱/۲۳
WA _{۲۴}	میانگین	۹۰/۰/۸	۸۹/۶۳	۱۰۰/۹۲	۱۰۲/۳۳	۹۸/۷۲	۹۸/۳۸	۹۸/۳۸	۹۸/۳۸
	حداکثر	۱۱۱/۶۲	۱۰/۸/۹۳	۱۱۱/۶۲	۱۱۱/۴۶	۱۱۱/۵۹	۱۱۲/۹۹	۱۱۲/۹۹	۱۱۲/۹۹
	حداقل	۶۶/۸۰	۶۴/۷۵	۸۰/۷۵	۸۴/۰/۷	۸۰/۷۵	۹۰/۱۴	۹۰/۱۴	۹۰/۱۴
	واریانس	۳۵۵/۹۰	۳۱۶/۷۷	۱۷۵/۳۳	۲۰۰/۴	۱۶۲/۷۷	۸۸/۲۹	۸۸/۲۹	۸۸/۲۹
	انحراف میانگین	۱۸/۳۳	۱۷/۸۰	۱۳/۲۴	۱۴/۱۴	۱۲/۷۶	۹/۴۰	۹/۴۰	۹/۴۰

شکل ۳. مقایسه خروجی شبکه های ANFIS، RBFN و MLP با مقادیر اندازه گیری شده TS_۲، TS_{۲۴}، WA_۲ و WA_{۲۴} تخته

این تحقیق برای تمامی خصوصیات انجام گرفت و مقادیر ضریب حساسیت متغیرهای ورودی به روش هیل محاسبه شد. نتایج آنالیز حساسیت در شکل ۴ نشان داده شده است.

آنالیز حساسیت خصوصیات فیزیکی تخته خرده‌چوب نسبت به متغیرهای ورودی با استفاده از روش هیل برای نتایج شبکه عصبی MLP به عنوان بهترین روش مدلسازی در



شکل ۴. نتایج تحلیل حساسیت متغیرهای استفاده شده برای مدلسازی TS2، TS24، WA2 و WA24- X₁: نسبت ملامین فرمالدئید به اوره فرمالدئید، X₂- نسبت ساقه کلزا به صنوبر، X₃- مقدار رطوبت کیک

نتیجه‌گیری

مدلسازی و امکان تخمین خصوصیات فیزیکی تخته خرده‌چوب با استفاده از نسبت ملامین فرمالدئید به اوره فرمالدئید، نسبت ساقه کلزا به صنوبر و مقدار رطوبت کیک به روش‌های شبکه‌های عصبی مصنوعی (MLP) و RBF و سیستم نوروفازی ارزیابی و براساس مدل‌های غیرخطی تخمین زده شد. نتایج نشان داد که شبکه عصبی MLP نسبت به شبکه RBFN و سیستم نوروفازی عملکرد به نسبت بهتری در زمینه برآورد خصوصیات فیزیکی تخته خرده‌چوب دارد. نتایج نشان داد به طور کلی مدل‌های هوش مصنوعی با استفاده از متغیرهای مورد بررسی می‌توانند پیش‌بینی خوبی از میزان خصوصیات فیزیکی تخته خرده‌چوب به دست دهد.

نتایج آنالیز حساسیت نیز نشان داد که در زمینه برآورد TS₂ و WA₂₄ مهم‌ترین پارامتر با تأثیر مثبت در روند مدلسازی، مقدار رطوبت کیک بوده و نسبت ملامین فرمالدئید به اوره فرمالدئید نیز در زمینه مدلسازی TS₂₄ و

نتایج آنالیز حساسیت (Sensitivity analysis)

این بود که در خصوصیات مدلسازی TS₂ و WA₂₄ مهم‌ترین پارامتر ورودی در زمینه برآورد تغییرات این خصوصیات مقدار رطوبت کیک (X₃) است که اثر آن مثبت بوده است. با این حال، حساسیت ورودی‌های X₁ و X₂ در برآورد WA₂₄ منفی است، در صورتی که حساسیت ورودی X₁ در زمینه برآورد TS₂ مثبت است و حساسیتی که ورودی X₂ در زمینه مدلسازی WA₂ نشان داده است منفی است. این حالت بیانگر رابطه معکوس بین این ورودی با TS₂ است. اما در زمینه برآورد TS₂₄ و WA₂ مهم‌ترین پارامتر ورودی X₁ است که تأثیر مثبت در روند مدلسازی داشته است. ورودی‌های X₂ و X₃ نیز در زمینه برآورد WA₂ به ترتیب اهمیت، کاهش نشان داده‌اند. این در صورتی است که این دو ورودی در خصوصیات برآورد TS₂₄ اثرهای متفاوتی نشان داده‌اند، به طوری که ورودی X₂ تأثیر منفی داشته و ورودی X₃ تأثیر مثبت جزئی از خود نشان داده است که بیانگر کمترین تأثیر در زمینه برآورد TS₂₄ است.

خصوصیات فیزیکی تخته خردبچوب نشان می دهد که WAs مؤثرترین پارامتر است. این نتایج، تأثیر زیاد پارامترهای مورد نظر را در خصوصیات مدلسازی باید در مطالعات بعدی بیشتر در نظر گرفته شوند.

References

- [1]. Lin, H.C., and Huang, J.C. (2004). Using Single Image Multi-Processing Analysis Techniques to Estimate the Internal Bond Strength of Particleboard. Taiwan Journal of Forest Science, 19(2): 109-17.
- [2]. Faridah, S.I., and Nordin, A.B. (2012). Neural Network Modeling for Fiberboard Proper-ties Prediction, Wseas 13th Cimmacs, Latest Advances in Systems Science and Computational Intelligence. pp: 104-108.
- [3]. Ozsahin, S. (2012). ANN for Modeling MA and TS of OSB. 7(1): 1053-1067.
- [4]. Fernandez, G., Esteban, F., Palacios L.G., Navarro, P.N., and Conde, M. (2008). Prediction of standard particleboard mechanical properties utilizing an artificial neural network and subsequent comparison with a multivariate regression model. Investigacion Agraria-sistemas Y Recursos Forestales, 17(2): 87-178.
- [5]. European Standard EN 317. (1993). Particleboards and fiberboards, determination of swelling in thickness after immersion. European Standardization Committee, Brussels.
- [6]. Smith, M. (1993). Neural networks for statistical modeling: Thomson Learning.
- [7]. Haykin, S. (1999). Neural networks: A comprehensive foundation. NJ. Prentice-Hall Inc. Englewood Cliffs.
- [8]. Jorjani, E., Chehreh Chelgani, S., and Mesroghli, S. (2008). Application of artificial neural networks to predict chemical desulfurization of Tabas coal. Fuel, 87(12): 2727-34.
- [9]. Chung, C.H., Chiang, Y.M., and Chang, F.J. (2012). A spatial neural fuzzy network for estimating pan evaporation at ungauged sites. Hydrology and Earth Systems Science, 16; 255-266.
- [10]. Kemp, C., Perfors, A., and Tenenbaum, J. (2007). Learning overhypotheses with hierarchical Bayesian models. Developmental Science, 10:307-321.
- [11]. Jain, S.K., Nayak, P.C., and Sudheer, K.P. (2008). Models for estimating evapotranspiration using artificial neural networks, and their physical interpretation. Hydrological Processes, 22: 2225-2234.
- [12]. Hill, M.C. (1998). Methods and guidelines for effective model calibration, U.S. Geol. Surv. Water Resources Investigation Report, 90 pp.
- [13]. Demirkir, C., Ozsahin, S., Aydin. I., and Colakoglu, G. (2013). Optimization of some panel manufacturing parameters for the best bonding strength of plywood. International Journal of Adhesive, 46:14-20.

Modeling the Physical Properties of Particleboard from Canola (*Brassica napus*) Stalks by Using MLP, RBFN and ANFIS Artificial Neural Network

M. Nazerian*; Assoc. Prof., Department of Lignocellulosic Composites, Faculty of Energy Engineering and New Technology, Shahid Beheshti University, I.R. Iran

S. Akbari; M.Sc., Wood and Paper Science and Technology, University of Zabol, Zabol, I.R. Iran

H. Kermaniany; Assist. Prof., Department of Cellulose and Paper Technology, Faculty of Energy Engineering and New Technology, Shahid Beheshti University, I.R. Iran

M. Hashemi; M.Sc., Department of Soil Scince, University of Zabol, Zabol, I.R. Iran

(Received: 22 September 2016, Accepted: 18 May 2016)

ABSTRACT

Different factors influence on the properties of wood composite panels. Evaluating all of these factors not only increases waste of time and energy but also decreases accuracy in estimation of influence value of selected factors in manufacturing panels in order to obtain optimum point of different properties of wood composite panels. Hence, application of a new statistical method is necessary for determination of model estimating production's optimum point. This study was aimed to evaluate the artificial neural networks performance to model the physical properties of the particleboard made of canola stalks particles. The physical properties of the particleboard were modeled and estimated using different weight ratios of melamine formaldehyde to urea formaldehyde, canola stalks to poplar particles and mat moisture content through MLP, RBFN and ANFIS artificial neural networks. The results showed that MLP neural network has better performance than RBFN and ANFIS neural networks to estimate the physical properties of the particleboard. The results also showed that the artificial intelligence models have a proper precision and ability to predict the particleboard's physical properties. The results of the sensitivity analysis also showed that for estimating TS_2 and WA_{24} , the most important parameter was mat moisture content with a positive effect on the modeling, and melamine formaldehyde to urea formaldehyde ratio was also the most effective parameter for estimating TS_{24} and WA_2 .

Keywords: Particleboard, Physical properties, Artificial neural network.

* Corresponding Author, Email: morteza17172000@yahoo.com, Tel:09112910860