

## پیش‌بینی مدول خمشی و مدول الاستیسته تخته خرده چوب با استفاده از شبکه عصبی مصنوعی و مقایسه آن با مدل‌های رگرسیونی

### چکیده

امروزه روش‌های مدل‌سازی متعددی برای پیش‌آگاهی و کاهش هزینه‌های تولید برای پیش‌بینی خواص فیزیکی و مکانیکی فرآورده‌های صفحه‌ای استفاده می‌شود. از روش‌های رایج مدل‌سازی می‌توان به روش‌های رگرسیون و شبکه عصبی مصنوعی اشاره کرد. در این تحقیق امکان پیش‌بینی مقادیر مدول گسیختگی (MOR) و مدول الاستیسته خمشی (MOE) تخته خرده چوب با استفاده از شبکه عصبی مصنوعی و رگرسیون خطی ساده و چند متغیره بر اساس مهم‌ترین پارامترهای ساختاری تخته خرده چوب مانند دانسیته در سه سطح (۰/۶۵، ۰/۷، ۰/۷۵ g/cm<sup>3</sup>)، درصد چسب در سه سطح (۸، ۹/۵ و ۱۱٪) و ضریب کشیدگی خرده چوب در سه سطح (۱۳، ۳۰ و ۴۷) بررسی شد. داده‌های آزمایشگاهی و داده‌های پیش‌بینی‌شده با مدل‌های مختلف بر اساس پارامترهای میانگین قدر مطلق خطا (MAPE)، میانگین مربع خطا (MSE) و ضریب تعیین (R<sup>2</sup>) مورد مقایسه و ارزیابی قرار گرفتند. نتایج این مطالعه نشان داد که اگرچه هر دو مدل رگرسیون خطی چندگانه و شبکه عصبی مصنوعی توانایی پیش‌بینی مقادیر MOR و MOE را با دقت بالایی دارند، اما شبکه عصبی مصنوعی نسبت به رگرسیون خطی چندگانه، MOR و MOE تخته خرده چوب را با R<sup>2</sup> بالاتر و MAPE کمتری پیش‌بینی نمود. مقادیر R<sup>2</sup> و MAPE برای شبکه عصبی به ترتیب ۷۷٪ و ۷/۷۲ درصد برای MOR و ۰/۸۶ و ۷ درصد برای MOE به دست آمده آمدند. مقادیر متناظر آن‌ها برای مدل رگرسیون چندگانه به ترتیب ۸/۳ و ۰/۷۳۸، ۹/۰۶ و ۰/۷۸۳ بودند. این مقادیر خطا برای پیش‌بینی مقاومت خمشی تخته خرده چوب از نظر صنعتی و کاربردی رضایت‌بخش است.

**واژگان کلیدی:** تخته خرده چوب، مدول گسیختگی، مدول الاستیسته خمشی، شبکه عصبی مصنوعی، رگرسیون.

محمد عربی<sup>\*۱</sup>

اکبر رستم پور هفتخوانی<sup>۲</sup>

رضا پوربابا<sup>۳</sup>

<sup>۱</sup> استادیار، گروه علوم و صنایع چوب و کاغذ، دانشکده منابع طبیعی، دانشگاه زابل، زابل، ایران

<sup>۲</sup> استادیار، گروه منابع طبیعی، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی، اردبیل، ایران

<sup>۳</sup> دانشجوی دکتری، گروه علوم و صنایع چوب و کاغذ، دانشکده منابع طبیعی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران

مسئول مکاتبات:

[marabi@uoz.ac.ir](mailto:marabi@uoz.ac.ir)

تاریخ دریافت: ۱۴۰۰/۰۳/۰۸

تاریخ پذیرش: ۱۴۰۰/۰۶/۰۳

### مقدمه

تخته خرده چوب، یکی از انواع فرآورده‌های صفحه‌ای است که از مواد لیگنوسلولوزی آغشته به چسب‌های ترموست تحت فشار معین پرس گرم ساخته می‌شود [۱]. متغیرهای مؤثر بر کیفیت تخته خرده چوب را می‌توان در

دو گروه متغیرهای ساختاری (اندازه و شکل هندسی ذرات، نوع و درصد رزین و دانسیته صفحه‌ای تولیدی) و متغیرهای فرآیندی (دما، زمان، فشار و سرعت بسته شدن دهانه پرس) تقسیم‌بندی نمود [۱-۴]. برهم‌کنش پارامترهای ساختاری و فرآیندی نقش اساسی در تعیین کیفیت و هزینه تمام‌شده محصول نهایی ایفا می‌کنند.

پیچیده تعریف‌نشده و رابطه‌های غیرخطی بین داده‌ها را نسبت به روش‌های آماری غیرخطی بهتر و دقیق‌تر آنالیز کند و داده‌های بهتری ارائه دهد [۱۵-۱۴]. اخیراً، مطالعات قابل‌توجهی برای پیش‌بینی خواص فیزیکی و مکانیکی تخته خرده چوب، تخته فیبر نیمه سنگین، تخته تراشه جهت‌دار و LVL با استفاده از شبکه عصبی مصنوعی انجام شده است. Melo و Migue ۲۰۱۶ به پیش‌بینی خواص فیزیکی و مکانیکی تخته خرده چوب با استفاده از شبکه عصبی پرداختند. آن‌ها از دانسیته و درصد چسب به‌عنوان متغیرهای ورودی استفاده کردند و به پیش‌بینی مقاومت خمشی، واکشیدگی ضخامت و چسبندگی داخلی تخته خرده چوب پرداختند [۱۶]. Tiryaki و همکاران ۲۰۱۷ یک برنامه شبکه عصبی و رگرسیون خطی چندگانه برای پیش‌بینی مدول گسیختگی و مدول الاستیسته تخته خرده چوب بر اساس دما، زمان و فشار پرس و همچنین نوع رزین توسعه دادند. نتایج آن‌ها نشان داد که شبکه عصبی و رگرسیون چند-گانه قابلیت بسیار خوبی در پیش‌بینی خواص مکانیکی تخته خرده چوب دارند. همچنین بیان داشتند که شبکه عصبی دقت بیشتری در پیش‌بینی خواص مکانیکی نسبت به رگرسیون خطی چندگانه دارد [۱۷]. Bardak و همکاران ۲۰۱۶ کاربرد شبکه عصبی در پیش‌بینی مقاومت به چسبندگی اتصالات چوبی تحت پرس در شرایط مختلف دمایی (۲۰، ۴۰، ۶۰، ۸۰ درجه سانتی‌گراد) و زمانی (۲، ۴، ۸، ۱۴ و ۲۰ دقیقه) را بررسی کردند. این محققین اذعان داشتند که شبکه عصبی قابلیت بسیار بالایی در پیش‌بینی مقاومت به چسبندگی اتصالات چوبی را با درصد خطای قابل قبولی را دارد [۱۸]. Kaya و همکاران ۲۰۱۹ از تابع توزیع شعاعی در شبکه عصبی برای پیش‌بینی خواص مکانیکی پانل‌های چوبی (امدیاف، تخته خرده چوب، تخته لایه و...) استفاده کردند. ایشان به این نتیجه رسیدند که این تابع توانایی پیش‌بینی خواص مکانیکی کامپوزیت‌های چوبی با دقت ۹۵ درصد را دارد [۱۹]. Palacios و همکاران ۲۰۱۸ چسبندگی داخلی تخته خرده چوب را با استفاده از خواص فیزیکی (واکشیدگی ضخامت، جذب آب و دانسیته تخته) و همچنین مقاومت کششی تخته را با استفاده از شبکه

از این‌رو همواره مطالعات و تلاش‌های گسترده‌ای توسط محققین و صاحبان صنایع برای کنترل این پارامترها متناسب با برنامه تولید و محصول هدف انجام شده است، چراکه به عقیده بسیاری از محققین مهم‌ترین راهکار برای کاهش هزینه و بهبود کیفیت تولید، افزایش دانش کارشناسان نسبت به شبکه پیچیده متغیرهای مؤثر در فرآیند تولید و یافتن رابطه متغیرهای تولید با یکدیگر و با ویژگی‌های کیفی و کمی محصول نهایی است [۵-۶]. مهم‌ترین راهکار برای شناخت رابطه پارامترهای مؤثر در تولید با یکدیگر و باکیفیت محصول نهایی، استفاده از روش‌های مدل‌سازی است که یکی از روش‌های مهم برای تبیین رابطه بین متغیر وابسته و متغیره‌ای مستقل می‌باشد. در سال‌های اخیر تحقیقات زیادی در زمینه‌ی مدل‌سازی و پیش‌بینی خواص فیزیکی و مکانیکی صفحات فشرده چوبی با روش‌های مختلف انجام شده است. از جمله این روش‌ها می‌توان به تکنیک اجزای محدود [۷]، ترکیب شبکه عصبی و الگوریتم ژنتیک [۸-۹] منطق فازی [۱۰]، مدل‌های رگرسیون چند متغیره خطی و غیرخطی [۱۱-۱۳] و شبکه عصبی اشاره کرد. از میان این روش‌ها، رگرسیون خطی چندگانه و شبکه عصبی بیشترین کاربرد را برای پیش‌بینی و کنترل هوشمندانه خواص فیزیکی و مکانیکی صفحات فشرده چوبی داشته‌اند. استفاده از روش‌های آماری و تحلیل رگرسیون برای مدل‌سازی و پیش‌بینی پدیده‌های فیزیکی در مقایسه با شبکه عصبی همواره محدودیت‌هایی را به همراه دارد. از جمله این محدودیت‌ها **محدودیت‌ها** می‌توان به در نظر گرفتن پیش‌فرض برای مدلسازی، نرمال بودن متغیر وابسته، همگن بودن واریانس خطاها، نبود رابطه هم‌خطی بین متغیرهای مستقل و مدل‌سازی روابط پیچیده غیرخطی اشاره کرد [۱۴]. همچنین مدل‌های آماری نسبت به مشاهده‌های گم‌شده و داده‌های پرت حساسیت بیشتری از خود نشان می‌دهند؛ اما شبکه عصبی هیچ فرضیه اولیه‌ای برای داده‌های ورودی و توزیع آماری آن‌ها متصور نیست. قابلیت یادگیری و انطباق شبکه عصبی این امکان را به آن می‌دهد که در صورت مشاهده جدید و یا حذف و آسیب‌دیدگی قسمتی از نورون‌ها، همچنان شبکه پاسخ و پیش‌بینی مناسبی به کاربران ارائه دهد [۱۵]. شبکه عصبی می‌تواند داده‌های

رگرسیون خطی چندگانه و مقایسه آن‌ها با یکدیگر می‌باشد.

### مواد و روش‌ها

در این تحقیق، از چوب صنوبر (*populus alba*) برای ساخت تخته خرده چوب با در نظر گرفتن عوامل متغیر زیر استفاده شد. عوامل متغیر عبارت‌اند از: مقدار چسب در سه سطح ۸، ۹/۵ و ۱۱٪ درصد، دانسیته در سه سطح ۰/۶۵، ۰/۷، ۰/۷۵ g/cm<sup>3</sup> و ضریب کشیدگی ذرات در سه سطح: ۱۳، ۳۰ و ۴۷.

### ساخت تخته‌های آزمایشگاهی

خرده چوب‌های خشک‌شده (حدود ۳ درصد بر اساس وزن خشک) بعد از توزین، داخل یک دستگاه چسبزن آزمایشگاهی (کارگاه مبلمان و فرآورده‌های مرکب چوبی، گروه علوم و صنایع چوب و کاغذ، دانشکده منابع طبیعی دانشگاه تهران) از نوع استوانه‌ای چرخان قرار گرفتند و مخلوط چسب به کمک پیستوله و فشار هوا اسپری شد. خرده چوب‌های چسب‌زنی شده باهدف تنظیم دانسیته موردنظر، توزین و برای تشکیل کیک خرده چوب، در یک قالب چوبی به ابعاد ۴۰×۴۰ سانتی‌متر ریخته به‌طور یکنواخت پخش شدند. کیک خرده چوب در یک پرس آزمایشگاهی از نوع BURKLE با دمای ۱۸۰ درجه سلسیوس، فشار ۲۵ کیلوگرم بر سانتیمتر مربع و زمان پرس ۵ دقیقه فشرده شدند. برای تنظیم ضخامت نهایی تخته از شابلون‌های فلزی ۱۶ میلی‌متری استفاده شد. از آنجاکه از چسب اوره فرمالدهید استفاده‌شده بود، تخته‌ها بعد از خروج از پرس خنک شدند. سرانجام، برای یکنواخت سازی رطوبت تخته‌ها و همچنین متعادل‌سازی تنش‌های داخلی، تخته‌های ساخته‌شده به مدت ۱۵ روز در شرایط استاندارد (رطوبت نسبی ۶۵±۱ درصد و دمای محیط ۲۰±۳ درجه سانتی‌گراد) قرار گرفتند. تغییرات دانسیته تخته‌ها در هر سطح کمتر از ۳ درصد بود. بعداً از چند بار اندازه‌گیری وزن نمونه‌ها و نهایتاً ثابت شدن وزن آن‌ها، نمونه‌های آزمون بر طبق استاندارد EN 310 آماده و مدول گسیختگی نمونه‌های آزمایشی با ماشین آزمایش Instron ۴۴۸۶ در آزمایشگاه فیزیک و مکانیک چوب و

عصبی پیش‌بینی کردند [۲۰]. نتایج این مطالعه نشان داد که در سطح اعتماد ۹۵ درصد تفاوت معنی‌داری بین داده‌های آزمایشگاهی و داده‌های پیش‌بینی‌شده توسط شبکه عصبی وجود نداشت. Nazerian و همکاران ۲۰۱۸ به ترتیب به‌پیش‌بینی خواص خمشی تخته چوب- گچ با استفاده از سطح پاسخ و شبکه عصبی و در سال ۲۰۲۰ پیش‌بینی مقاومت خمشی تخته LVL را با استفاده از شبکه عصبی پرداختند. نتایج آن‌ها نشان داد که شبکه عصبی در مقایسه با پاسخ سطح دقت بالای در پیش‌بینی خواص تخته چوب - گچ را دارد. همچنین شبکه عصبی طراحی‌شده توسط آن‌ها مقاومت خمشی نمونه‌های ساخته‌شده را با درصد خطای کمتر از ۵ درصد و ضریب تعیین بیش از ۰/۹ پیش‌بینی کرد [۲۱-۲۲]. بر اساس بررسی نتایج مطالعات گذشته و همچنین تقسیم‌بندی Lewis (۱۹۸۲) دقت و قدرت شبکه عصبی مصنوعی برای پیش‌بینی خواص فیزیکی و مکانیکی پانل‌های چوبی بسیار بالا و قابل قبول گزارش‌شده است چراکه تقریباً در تمامی این مطالعات میانگین قدر مطلق خطا کمتر از ۱۰ درصد بیان‌شده است [۲۳]. تخته خرده چوب یکی از مهم‌ترین و پرکاربردترین صفحات فشرده چوبی است که در سال‌های اخیر کاربرد زیادی پیدا کرده است. این پانل چوبی در صنعت مبلمان، کابینت، قفسه و پایه کفپوش لمینت کاربرد دارد و در همه این نوع کاربردها تخته خرده چوب تحت بارهای خمشی است [۲۴]؛ بنابراین پیش‌آگاهی و پیش‌بینی ویژگی خمشی تخته خرده چوب برای استفاده آن در محیط‌های مختلف امری مهم و ضروری به نظر می‌رسد. مطالعات اندکی به‌منظور بررسی دقت مدل‌های رگرسیونی و شبکه عصبی و همچنین مقایسه آن‌ها با یکدیگر در شرایط یکسان برای پیش‌بینی خواص فیزیکی و مکانیکی چوب ماسیو [۱۳] و مدول خمشی تخته لایه [۲۱ و ۱۲] انجام شده است. در مورد پیش‌بینی مدول خمشی تخته خرده چوب با استفاده از مدل‌های رگرسیونی و شبکه عصبی در شرایط یکسان و مقایسه آن‌ها با یکدیگر مطالعات چندانی صورت نگرفته است. از این‌رو هدف از این مطالعه، پیش‌بینی هوشمندانه مقادیر مدول خمشی تخته خرده چوب بر اساس ضریب کشیدگی، دانسیته و مقدار رزین با استفاده از شبکه عصبی مصنوعی،

خروجی برای مدل در نظر گرفته شد. با توجه به تجربیات محققین تعداد نورون‌های لایه پنهان ۴ در نظر گرفته شد، زیرا تاکنون قانون مشخصی برای تعیین آن ارائه نشده است. رابطه ریاضی شبکه عصبی MLP به شرح زیر است:

$$Y = g \left( \theta + \sum_{j=1}^m v_j \left[ \sum_{i=1}^n f(W_{ij}X_i + \beta_j) \right] \right) \quad (۳)$$

که در آن Y متغیر وابسته، g تابع فعال‌سازی نورون-های خروجی،  $\theta$  مقدار بایاس نورون‌های خروجی،  $v_j$  مقادیر وزن بین لایه نورون خروجی و نورون‌های پنهان، f تابع فعال‌سازی نورون‌های مخفی،  $w_{ij}$  مقادیر وزن بین لایه نورون ورودی و لایه نورون مخفی،  $X_i$  مقدار ورودی لایه نورون مخفی،  $\beta_j$  مقدار بایاس لایه نورون مخفی است.

در این تحقیق ۷۰٪، ۱۵٪ و ۱۵٪ از داده‌ها به صورت تصادفی به ترتیب برای آموزش، اعتبارسنجی و آزمایش انتخاب شدند. الگوریتم Levenberg-Marquardt برای آموزش داده‌ها انتخاب شد. تابع فعال‌سازی نورون خروجی خطی بود، اما تابع فعال‌سازی نورون مخفی تانژانت سیگموئید هیپربولیک بود که فرمول آن به صورت زیر است:

$$f(x) = \frac{2}{1 + e^{(-2x)}} - 1 \quad (۴)$$

که در آن  $f(x)$  و x مقدار خروجی و ورودی نورون می‌باشند. نمایی از ساختار MLP برای پیش‌بینی MOR و MOE در شکل ۱ ارائه شده است.

### ارزیابی کارایی مدل

برای ارزیابی کارایی مدل دو تا از مهم‌ترین مفیدترین شاخص‌ها MAPE و  $R^2$  است که در این مطالعه برای بررسی میزان خطا و تطابق داده‌های واقعی و پیش‌بینی شده از آن‌ها استفاده شد. یکی از شاخص‌های دیگری که شبکه عصبی نرم‌افزار متلب برای ارزیابی از آن‌ها استفاده می‌کند، میانگین مربعات خطا (MSE) بود. فرمول محاسبه آن‌ها به شرح زیر است:

فرآورده‌های چوبی، گروه علوم و صنایع چوب و کاغذ، دانشکده منابع طبیعی دانشگاه تهران اندازه‌گیری شد. برای هر تیمار سه تخته ساخته شد و از هر تخته سه نمونه برای اندازه‌گیری MOR و MOE تهیه شد.

### مدل‌سازی با رگرسیون خطی ساده و چندگانه

تحلیل رگرسیون با نرم‌افزار SPSS 25 انجام شد. در روش رگرسیون ساده از یک متغیر برای پیش‌بینی MOR و MOE استفاده شد و فرمول آن به شرح زیر بود:

$$Y = b_1X + C \quad (۱)$$

که در آن Y متغیر وابسته شامل MOR یا MOE، X متغیر مستقل شامل دانسیته، ضریب کشیدگی و درصد چسب که به صورت جداگانه و منفرد وارد مدل شدند،  $b_1$  ضریب رگرسیون و C ثابت رگرسیون بود.

اما در رگرسیون خطی چندگانه تمامی متغیرهای مستقل شامل دانسیته، ضریب کشیدگی و درصد چسب هم‌زمان به مدل وارد شدند و فرمول آن به صورت زیر بود:

$$Y = b_1X_1 + b_2X_2 + \dots + b_nX_n + C \quad (۲)$$

که در آن نیز Y متغیر وابسته شامل MOR یا MOE،  $X_1$ ،  $X_2$ ، ...،  $X_n$  متغیرهای مستقل،  $b_1$ ،  $b_2$ ، ...،  $b_n$  ضرایب رگرسیون و C ضریب ثابت رگرسیون بودند.

### مدل‌سازی با شبکه عصبی

پرسپترون چندلایه (MLP) به‌عنوان یکی از پرکاربردترین و رایج‌ترین مدل شبکه عصبی از تولباکس (نوار ابزار) شبکه عصبی نرم‌افزار متلب ورژن ۱۵ برای پیش‌بینی MOR و MOE انتخاب شد. در این مدل، دانسیته تخته خرده چوب، ضریب کشیدگی به‌عنوان مهم‌ترین شاخص اندازه ذرات خرده چوب و درصد چسب مصرفی به صورت هم‌زمان به‌عنوان داده ورودی و MOR و MOE به صورت جداگانه به‌عنوان داده خروجی به مدل وارد شدند. تعداد یک‌لایه ورودی، یک‌لایه پنهان و یک‌لایه

<sup>1</sup> Multi-Layer Perceptron

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left( \frac{|y_{exp.} - y_{pred.}|}{y_{exp.}} \right) 100 \quad \text{رابطه (۵)}$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_{exp.} - y_{pred.})^2 \quad \text{رابطه (۶)}$$

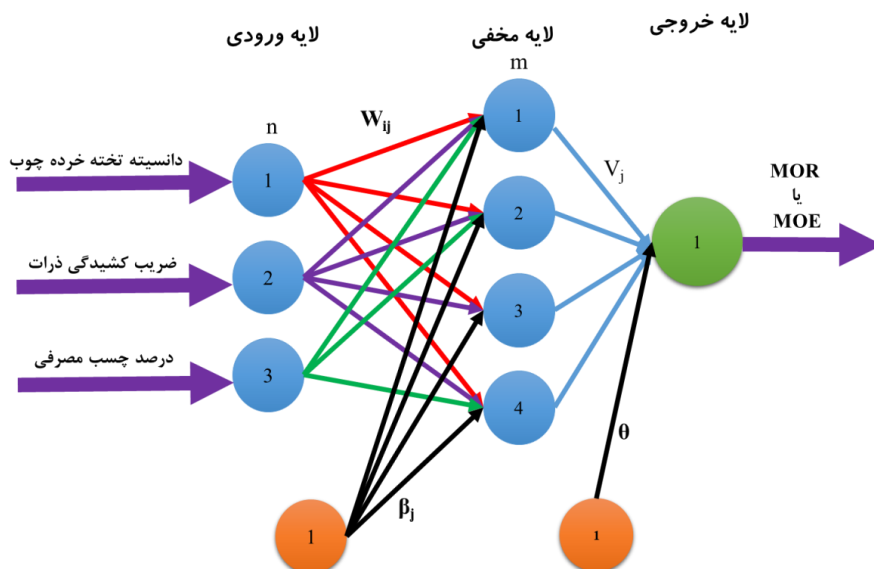

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{exp.} - y_{pred.})^2}{\sum_{i=1}^n (y_{exp.} - \bar{y}_{exp.})^2} \quad \text{رابطه (۷)}$$

داده‌های جدول ۱ مشخص است با افزایش دانسیته تخته، درصد چسب و ضریب کشیدگی خرده چوب MOR و MOE تخته خرده چوب افزایش یافته است. جدول ۲ تجزیه واریانس مربوط به نمونه‌های تخته خرده چوب ساخته شده برای کل نمونه‌ها را نشان می‌دهد.

که در آن‌ها  $y_{exp.}$  مقادیر داده‌های واقعی،  $y_{pred.}$  مقادیر داده‌های پیش‌بینی شده،  $\bar{y}_{exp.}$  میانگین مقادیر واقعی و  $n$  تعداد داده‌ها است.

### نتایج و بحث

مقدار MOR و MOE تخته خرده چوب ساخته شده در این مطالعه در جدول ۱ ارائه شده است. همان‌طور که از



شکل ۱- نمایشی از ساختار شبکه عصبی MLP برای پیش‌بینی MOR و MOE تخته خرده چوب

جدول ۱- میانگین مقادیر MOR و MOE در دانسیته، ضریب کشیدگی و درصد چسب مختلف

MOE (MPa)	MOR (MPa)	درصد چسب	ضریب کشیدگی خرده چوب	دانسیته (g/cm <sup>3</sup> )
۱۰۰۵/۴(۱۲۹/۷)	۱۰/۱۹(۰/۵۳۶)*	۸		
۱۰۹۸/۳(۸۶/۶)	۱۱(۰/۹۶۹)	۹/۵	۱۳	
۱۲۰۵/۶(۱۳۱/۷)-	۱۱/۰۷(۲/۶۱۷)	۱۱		
۱۲۶۸/۵(۸۱/۳)	۱۲/۵۶(۱/۱۳۴)	۸		
۱۳۸۹/۷(۹۹/۲)	۱۲/۵۶(۰/۶۶۴)	۹/۵	۳۰	۰/۶۵
۱۴۹۷/۶(۱۲۳/۷)	۱۲/۹۲(۰/۹۹)	۱۱		
۱۴۶۷/۶(۲۴۲/۴)	۱۳/۵۵(۱/۳۴۲)	۸		
۱۵۹۳/۱(۸۴/۲)	۱۳/۸۷(۱/۹۶۲)	۹/۵	۴۷	
۱۷۹۴/۳(۸۷)	۱۴/۷۵(۳/۲۹۳)	۱۱		
۱۲۵۸/۸(۱۴۱/۶)	۱۲/۹۳(۲/۱۴۳)	۸		
۱۲۸۵/۶(۱۰۵/۱)	۱۴/۷۳(۱/۲۳۷)	۹/۵	۱۳	
۱۳۸۲/۲(۱۷۰/۳)	۱۵/۸۵(۰/۹۱۵)	۱۱		
۱۳۴۶/۳(۱۰۶/۶)	۱۳/۲۸(۱/۰۳۳)	۸		
۱۵۲۸/۷(۱۰۷)	۱۵/۵۶(۰/۹۲۶)	۹/۵	۳۰	۰/۷
۱۶۳۲/۹(۹۰/۷)	۱۶/۲۷(۰/۵۰۳)	۱۱		
۱۹۲۳/۳(۷۷/۳)	۱۵/۴(۳/۱۷۹)	۸		
۱۸۳۲/۸(۲۴۹/۷)	۱۶/۰۴(۱/۳۸۹)	۹/۵	۴۷	
۱۹۱۵/۶(۱۲۱/۶)	۱۷/۳۱(۱/۰۲۷)	۱۱		
۱۴۵۱/۳(۸۸/۷)	۱۵/۰۶(۱/۳۱۶)	۸		
۱۹۱۷/۴(۱۱۹/۹)	۱۶/۰۴(۱/۶۳۶)	۹/۵	۱۳	
۱۹۹۱/۸(۱۳۶/۶)	۱۶/۳۴(۰/۹۴۸)	۱۱		
۱۵۲۹/۹(۱۲۳/۹)	۱۶/۱۷(۰/۸۲۳)	۸		
۲۰۵۸/۲(۱۲۳/۸)	۱۸/۶۶(۰/۶۰۳)	۹/۵	۳۰	۰/۷۵
۲۱۷۵/۵(۱۶۷/۴)	۱۹/۱۳(۱/۴۶۸)	۱۱		
۱۹۲۴/۵(۱۸۸/۷)	۱۸/۸۲(۱/۲۴۴)	۸		
۲۲۰۱/۴(۱۳۲/۴)	۲۰/۰۲(۱/۱۹۹)	۹/۵	۴۷	
۲۵۵۳/۸(۳۵۷/۲)	۲۰/۵۹(۱/۴۷)	۱۱		

\* مقادیر داخل پرانتز انحراف معیار داده‌ها را نشان می‌دهند

خمشی تخته خرده چوب می‌گردد. با افزایش ضریب کشیدگی ذرات و درصد چسب، مقادیر MOR و MOE افزایش می‌یابند، اما این افزایش به علت تفاوت در سطح ویژه ذرات همواره خطی به نظر نمی‌رسد، زیرا در شرایط یکسان، ذرات درشت‌تر با داشتن سطح ویژه کمتر، نسبت به ذرات ریزتر مقدار رزین بیشتری دریافت می‌کنند و مقادیر MOR و MOE را بیشتر افزایش می‌دهند [۶].

سایر محققین نیز در مورد تأثیر مثبت دانسیته تخته، درصد چسب و ضریب کشیدگی خرده چوب بر مقادیر MOR و MOE تخته خرده چوب به نتایج مشابهی دست یافتند [۱-۳]. زیرا با افزایش دانسیته مقدار ماده چوبی در واحد حجم افزایش یافته و از حجم فضای خالی موجود در تخته کم می‌شود که باعث افزایش سطح تماس بین ذرات چوب و چسب می‌شود که این امر موجب بهبود مدول

جدول ۲- تجزیه واریانس مربوط به نمونه‌های تخته خرده چوب ساخته شده برای کل نمونه‌ها

منابع تغییرات	IB (MPa)			MOR (MPa)			MOE (MPa)		
	p-value	F	DF	p-value	F	DF	p-value	F	DF
دانسیته (D)	*./۰۰۰	۱۵۰۳ ۱۰۴۱	۲	*./۰۰۰	۲۵۰/۰۸۹	۲	*./۰۰۰	۳۵۱/۱۵۸	۲
ضریب کشیدگی (S)	*./۰۰۰	۲۵۳/۸۵۹	۲	*./۰۰۰	۷۸/۸۵۲	۲	*./۰۰۰	۲۴۱/۸۷۸	۲
درصد چسب (A)	*./۰۰۰	۱۹۳/۷۷۶	۲	*./۰۰۰	۲۹/۱۰۸	۲	*./۰۰۰	۱۰۰/۱۲۷	۲
D*S	*./۰۰۰	۱۳/۰۳۹	۴	*./۰۰۲	۴/۲۴۶	۴	*./۰۱۱	۳/۳۴۹	۴
D*A	*./۰۰۰	۲۲/۱۱۵	۴	*./۰۲۹	۲/۷۴۴	۴	*./۰۰۰	۲۰/۹۱۶	۴
A*S	*./۱۴۸	۱/۷۱۵	۴	۰/۶۶۷ ns	۰/۵۹۵	۴	*./۰۲۳	۲/۸۸۸	۴
D*A*S	۰/۰۹۶	۱/۷۱۷	۸	۰/۶۹۶ ns	۰/۶۹۵	۸	ns/۱۲۱	۱/۶۱۹	۸

\* معنی داری در سطح ۵ درصد، ns: عدم معنی داری، DF: درجه آزادی، MS: میانگین مربعات، P-value یا Sig.: معنی داری

مقایسه شدند. جدول ۳ ضرایب و مقادیر درصد خطا را برای مدل رگرسیون ساده، برای پیش‌بینی هر دو مقدار MOR و MOE نشان می‌دهد.

در این مطالعه MOE و MOR تخته خرده چوب توسط مدل رگرسیون خطی ساده، رگرسیون خطی چندگانه با استفاده از نرم‌افزار SPSS ۲۵ و شبکه عصبی مصنوعی به کمک MATLAB 15 پیش‌بینی و با یکدیگر

جدول ۳- ضرایب رگرسیون ساده برای پیش‌بینی MOR و MOE با پیش‌بینی کننده‌های دانسیته، ضریب کشیدگی و درصد چسب و ارزیابی آنها براساس خطا

ویژگی	متغیر مستقل	ثابت	ضریب	شاخص ارزیابی				معنی داری
				R <sup>2</sup>	R	MSE	MAPE	
	دانسیته (D)	-۲۲/۴۰۷	۵۳/۷۳۸	۰/۷۱۸۷۲۴۲	۴/۵۰۴۲۸۲	۱۱/۸۶۲۸۹	۰/۰۰۰	
MOR (MPa)	ضریب کشیدگی (S)	۱۲/۵۴۷	۰/۰۸۹	۰/۱۶۲۸۸۳	۷/۷۹۹۶۸۸۸	۱۶/۸۰۳۵۵۱	۰/۰۰۰	
	درصد چسب (A)	۱۲/۵۴۷	۰/۰۸۹	۰/۰۵۸۴۷۹۵	۸/۷۷۲۳۷۲۶	۱۷/۰۷۷۴۷۱	۰/۰۰۰	
	دانسیته (D)	-۲۶۲۶/۹۱۴	۶۰۹۲/۹۶۱	۰/۳۹۱۵۴۳۲	۹۶۱۵۱/۴۱۷	۱۶/۳۸۰۸۴۵	۰/۰۰۰	
MOE (MPa)	ضریب کشیدگی (S)	۱۱۸۶/۲۰۲	۱۵/۰۶۵	۰/۲۷۶۷۱۴۲	۱۱۴۲۹۷/۲۶	۱۶/۵۲۲۲۶	۰/۰۰۰	
	درصد چسب (A)	۵۹۱/۸۶۸	۱۱۰/۱۳۶	۰/۱۱۵۱۳۹۱	۱۳۹۸۳۰/۱۹	۱۹/۷۵۰۸۷۵	۰/۰۰۰	

MOE توسط مدل رگرسیون خطی ساده رضایت‌بخش نیست. معادلات رگرسیون خطی چندگانه (معادله ۱ و ۲) به ترتیب برای MOR و MOE با استفاده از نرم‌افزار SPSS به دست آمدند. در معادله ۱ و ۲، D، A و S به ترتیب دانسیته، ضریب کشیدگی ذرات و درصد چسب می‌باشند. نتایج مربوط به درصد میانگین قدر مطلق خطا و ضریب تعیین داده‌های آزمایشگاهی و داده‌های پیش‌بینی شده توسط رگرسیون چندگانه در جدول ۴ بیان شده است.

بر اساس نتایج جدول ۳، رگرسیون خطی تک متغیره تنها با در نظر گرفتن دانسیته تخته به‌عنوان متغیر مستقل قابلیت پیش‌بینی مقدار MOR تخته خرده را با ضریب تعیین ۰/۵۱ و میانگین قدر مطلق خطا ۱۱/۸۶ دارد. Lewis ۱۹۸۲ نیز به نتایج مشابهی رسیدند [۲۳]. مدل رگرسیون خطی ساده با متغیر مستقل درصد چسب و یا ضریب کشیدگی، هرچند درصد خطای کمتر از ۲۰ درصد دارد اما ضریب تعیین بسیار پایینی از خود نشان داده است. بنابراین می‌توان گفت که پیش‌بینی مقادیر MOR و

$$MOR = 53/738D + 0/603A + 0/089S - 30/796 \quad (1)$$

$$MOE = 6092/961D + 110/136A + 15/65S - 4125/161 \quad (2)$$

جدول ۴- ضرایب رگرسیون چندگانه برای پیش‌بینی MOR و MOE برحسب دانسیته، ضریب کشیدگی و درصد چسب، و ارزیابی آنها

ویژگی	ضرایب	Sig.	VIF	MAPE	MSE	R	R <sup>2</sup>
MOR (MPa)	ثابت	۰/۰۰۰	-۳۰/۷۹۶				
	دانسیته (D)	۰/۰۰۰	۱/۰۰۰	۸/۳۰	۲/۴۴	۰/۸۵۹	۰/۷۳۸
	ضریب کشیدگی (S)	۰/۰۰۰	۱/۰۰۰				
	درصد چسب (A)	۰/۰۰۰	۱/۰۰۰				
MOE (MPa)	ثابت	۰/۰۰۰	-۴۱۲۵/۱۶۱				
	دانسیته (D)	۰/۰۰۰	۱/۰۰۰	۹/۰۶	۳۴۲۲۸/۷۸	۰/۸۸۵	۰/۷۸۳
	ضریب کشیدگی (S)	۰/۰۰۰	۱/۰۰۰				
	درصد چسب (A)	۰/۰۰۰	۱/۰۰۰				

افزایش می‌دهند. دلیل این اتفاق به سطح ویژه کمتر و توزیع مناسب‌تر چسب در سطح و بین ذرات خرده چوب-های درشت‌تر برمی‌گردد [۵-۶]؛ بنابراین افزایش مقاومت خمشی تخته خرده چوب، با افزایش هم‌زمان ضریب کشیدگی و درصد چسب همواره خطی نیست. همین امر می‌تواند علت ضریب تعیین کمتر و خطای بیشتر در پیش‌بینی مقادیر MOR و MOE تخته خرده چوب با مدل‌های رگرسیون خطی شود. برای مدل‌سازی با شبکه عصبی مصنوعی، داده‌های آزمایشگاهی به سه دسته تقسیم شدند. حدود ۷۰ درصد داده‌ها برای آموزش، ۱۵ درصد برای اعتبارسنجی و ۱۵ درصد داده برای آزمایش مدل شبکه عصبی مصنوعی در نظر گرفته شدند.

مدول خمشی تخته خرده چوب‌های آزمایشگاهی با استفاده از مدل رگرسیون خطی چندگانه بر اساس مقدار چسب، ضریب کشیدگی و دانسیته با دقت خوبی پیش‌بینی شدند. به طوری که مقدار MAPE، MSE و R<sup>2</sup> به ترتیب، ۸/۳۰، ۲/۴۴ و ۰/۷۳ برای پیش‌بینی MOR و ۹/۰۶، ۳/۴۲ و ۰/۷۸ برای پیش‌بینی MOE به دست آمد (جدول ۵). با توجه به تقسیم‌بندی Lewis ۱۹۸۲، دقت مدل رگرسیون چندگانه برای پیش‌بینی MOR و MOE تخته خرده چوب تحت شرایط این مطالعه بالا است (میانگین قدر مطلق درصد خطا کمتر از ۱۰ درصد). با افزایش یکسان درصد چسب، خرده چوب‌های با ضریب کشیدگی بالاتر، مقادیر مدول خمشی تخته خرده چوب را نسبت به خرده چوب‌های با ضریب کشیدگی کمتر، بیشتر

جدول ۵- ارزیابی مدل شبکه عصبی بر اساس مقادیر خطا و R و R<sup>2</sup> برای پیش‌بینی MOR و MOE برحسب دانسیته، ضریب

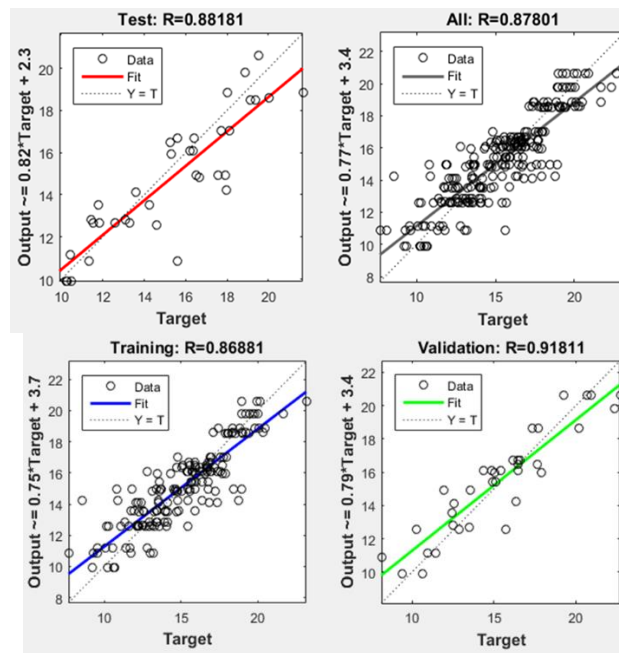
کشیدگی و درصد چسب

ویژگی	داده‌ها	MAPE	MSE	R	R <sup>2</sup>
MOR (MPa)	آموزش		۲/۰۸	۰/۸۶۹	۰/۷۵۵
	اعتبارسنجی		۲/۰۴	۰/۹۱۸	۰/۸۴۳
	آزمایش		۲/۵۰	۰/۸۸۲	۰/۷۷۸
	کل داده‌ها	۷/۷۲	۲/۱۴	۰/۸۷۸	۰/۷۷۱
MOE (MPa)	آموزش		۲۰۶۹۶	۰/۹۳۲	۰/۸۶۸
	اعتبارسنجی		۲۶۱۴۸	۰/۹۳۵	۰/۸۷۵
	آزمایش		۱۶۱۶۱	۰/۹۳۵	۰/۸۷۳
	کل داده‌ها	۷	۲۰۸۳۱	۰/۹۳۲	۰/۸۶۸

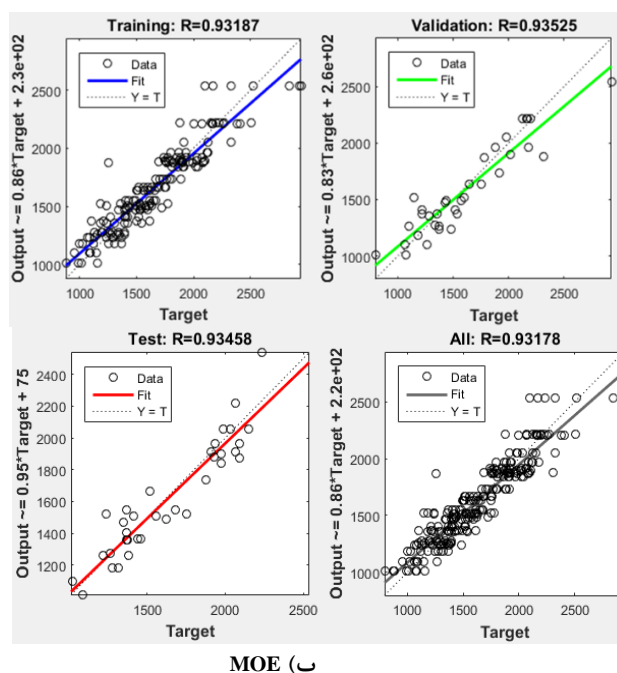


کل داده‌ها برای MOE، ۰/۹۳۲، ۰/۹۳۵، ۰/۹۳۵ و ۰/۹۳۲ می‌باشد. در هر دو مدل شبکه عصبی و رگرسیون خطی چندگانه مقدار MOE با درصد خطای کمتر و ضریب تعیین بیشتری پیش‌بینی شد. شبکه عصبی مصنوعی از قابلیت الگوریتم یادگیری ماشین بهره می‌برد. بر اساس این الگوریتم، شبکه عصبی قادر است که بر اساس تجربه‌ها و آموزش‌های قبلی عملکرد خود را بهبود ببخشد. در صورت یادگیری صحیح، الگوی طراحی و انتخاب‌شده قادر است که برای مشاهدات جدید نیز پاسخ درست را تخمین بزند. همچنین در صورت تغییر داده‌ها، برنامه تولیدشده توانایی تطبیق‌پذیری با شرایط جدید را دارد. همین دو فاکتور تعمیم‌پذیری و تطبیق‌پذیری، شبکه عصبی مصنوعی را نسبت به سایر روش‌های مدل‌سازی متمایز می‌کند و این امکان را فراهم می‌کند تا نسبت به سایر روش‌های مدل‌سازی نتایج بهتری را ارائه دهد [۱۴-۱۵].

بر اساس نتایج جدول ۵ مقادیر میانگین مطلق درصد خطا بین تمام داده‌های آزمایشگاهی و داده‌های مورد استفاده برای آموزش، اعتبارسنجی و آزمایش کمتر از ۸ درصد است. مقادیر میانگین مطلق درصد خطا برای کل داده‌ها در شبکه عصبی مصنوعی به ترتیب برای پیش‌بینی MOR و MOE، ۷/۸۲ و ۷ درصد است. ضریب تعیین بالا و درصد خطای پایین بین داده‌های آزمایشگاهی و داده‌های پیش‌بینی‌شده نشان می‌دهد که شبکه عصبی مصنوعی نسبت به مدل‌های رگرسیونی قابلیت بسیار بهتری برای پیش‌بینی مقاومت خمشی تخته خرده چوب دارد. شکل ۲ مقادیر R برای MOR و MOE را برای داده‌های آموزش، اعتبارسنجی و آزمایش در شبکه عصبی نشان می‌دهد. مقدار R برای MOR در هر یک از داده‌های آموزش، اعتبارسنجی و آزمایش و کل داده‌ها به ترتیب ۰/۸۶۹، ۰/۹۱۸، ۰/۸۸۲ و ۰/۸۷۸ می‌باشد. همچنین مقدار R برای داده‌های آموزش، اعتبارسنجی و آزمایش و



الف) MOR




MOE (ب)


شکل ۲- برازش داده‌های MOR و MOE با شبکه عصبی مصنوعی و ارتباط داده‌های واقعی و داده‌های پیش‌بینی شده در داده‌های آموزش، اعتبارسنجی و آزمایش

تخته خرده چوب مثل دانسیته، اندازه ذرات و درصد چسب وجود دارد. کنترل اندازه ذرات و تأثیر آن برای خواص مکانیکی تخته خرده چوب نسبت به متغیرهای فرآیندی آن سخت‌تر و پیچیده‌تر به نظر می‌آیند [۱۲]؛ اما درباره پیش‌بینی خواص پانل‌های چوبی مثل چوب ماسیو، تخته لایه و تخته خرده چوب بر اساس متغیرهای فرآیندی مطالعات بیشتری صورت گرفته است. Fernandez و همکاران ۲۰۱۲ مقادیر  $R^2$  را برای پیش‌بینی MOR و MOE تخته لایه با استفاده از شبکه عصبی و رگرسیون خطی به ترتیب ۰/۷۳ و ۰/۶۶ و ۰/۵۱ و ۰/۴۷ گزارش کردند [۱۲]. Eslah و همکاران ۲۰۱۲ مقدار  $R^2$  را برای پیش‌بینی MOR و MOE تخته خرده چوب با استفاده از رگرسیون خطی به ترتیب ۰/۷۹ و ۰/۶۹ گزارش کردند [۱۲].

نکویی برازش داده‌های واقعی در مقابل داده‌های پیش‌بینی شده با مدل رگرسیون خطی چندگانه و شبکه عصبی در شکل ۳ نشان ارائه شده است. همان‌طور که در این شکل مشخص است مقادیر پیش‌بینی شده MOE تطابق بهتری با مقادیر داده‌های واقعی دارند. محققین زیادی اقدام به پیش‌بینی خواص فیزیکی و مکانیکی چوب ماسیو و سایر فراورده‌های مهندسی شده چوب با استفاده از شبکه عصبی کرده‌اند. همه این محققین از پارامترهای آماری MAPE و MSE و  $R^2$  به‌عنوان شاخص‌های اصلی مقایسه بین داده‌های آزمایشگاهی و داده‌های پیش‌بینی شده استفاده کردند. نتایج به‌دست‌آمده در این مطالعات با نتایج این محققین تطابق خوبی دارد [۹، ۱۲-۱۱، ۲۴]. اطلاعات اندکی در مورد پیش‌بینی مقادیر MOR و MOE تخته خرده چوب با استفاده از شبکه عصبی و رگرسیون با در نظر گرفتن پارامترهای ساختاری



MOR (الف)




MOE (ب)


شکل ۳- تطابق داده‌های واقعی با داده‌های پیش‌بینی شده با مدل رگرسیون چندگانه و شبکه عصبی

است. دقت پیش‌بینی مدل‌ها برای پیش‌بینی خواص مواد بر مبنای میانگین قدر مطلق خطا (MAPE) عبارت‌اند از: کمتر از ۱۰٪ خطا (دقت پیش‌بینی بالا)، بین ۱۰٪ تا ۲۰٪ درصد خطا (دقت پیش‌بینی خوب) و بین ۲۰٪ تا ۵۰٪ درصد خطا (دقت پیش‌بینی منطقی) [۲۳]. بر مبنای این دسته‌بندی می‌توان این نتیجه گرفت که اگرچه دقت مدل‌های رگرسیونی و شبکه عصبی استفاده‌شده در این مطالعه، نسبت به مطالعات قبلی ذکرشده بالاتر ذکرشده است، اما مطابق تقسیم‌بندی Lewis ۱۹۸۲ نتایج این مطالعه درصد خطای کمی از خود نشان دادند؛ بنابراین با توجه به هزینه و زمان لازم برای انجام آزمایش‌های تجربی، استفاده از شبکه عصبی نسبت به مدل‌های رگرسیونی تکنیک کارآمدتری برای تخمین و پیش‌بینی خواص فیزیکی و مکانیکی تخته خرده چوب است.

در مطالعه دیگری Kurt and Karayilmazlar ۲۰۱۹ مقدار MOE تخته خرده چوب را با استفاده از شبکه عصبی ۰/۸۷ بیان کردند [۲۴]. نتایج این مطالعه نشان داد که  $R^2$  برای MOR و MOE تخته خرده چوب به ترتیب ۰/۷۷ و ۰/۸۶ برای مدل‌های رگرسیونی و ۰/۸۷ و ۰/۹۳ برای شبکه عصبی است. بنابراین دقت مدل‌های رگرسیونی و شبکه عصبی در این مطالعه نسبت به مطالعات ذکرشده بالاتر است. در این مطالعه ۲۷ تیمار، برای هر تیمار ۳ تکرار، هر تکرار ۳ نمونه آزمونی و در مجموع ۲۴۳ داده آزمایشگاهی موردبررسی قرار گرفت. تعداد بالای داده‌های آزمایشگاهی، به‌خصوص در فرایند شبکه عصبی که می‌توان به‌اندازه کافی داده آزمایشگاهی در فرایند آموزش شبکه به کار گرفت، به بالا رفتن دقت مدل‌های رگرسیونی و شبکه عصبی نسبت به مطالعات گذشته کمک کرده



MOR (الف)



MOE (ب)

شکل ۴- نمودار کارایی و عملکرد شبکه عصبی برحسب دوره (epoch) برای داده‌های آموزش، اعتبار سنجی و آزمایش

پیش‌بینی MOR و MOE همگرایی خوبی بین عملکرد پیش‌بینی داده‌های آموزش، اعتبار سنجی و آزمایش برحسب MSE وجود دارد.

### نتیجه‌گیری

نتایج این مطالعه نشان داد که:

به ترتیب افزایش دانسیته، ضریب کشیدگی و درصد چسب بیشترین افزایش را بر مقدار MOR و MOE تخته خرده چوب دارند.

رگرسیون تک متغیره تنها با در نظر گرفتن دانسیته تخته به‌عنوان متغیر مستقل قابلیت پیش‌بینی مقادیر MOR و MOE تخته خرده چوب را با ضریب تبیین ۰/۵۱ و میانگین قدر مطلق خطا ۱۱/۸۶ برای MOR و ضریب تعیین ۰/۳۹ و میانگین قدر مطلق خطا ۱۶/۳۸ برای

مشکل عمده در آموزش شبکه‌های عصبی مشکل Overfitting است. این مشکل زمانی به وجود می‌آید که شبکه عصبی فقط روی داده‌ها آموزشی عملکرد مناسب و خوبی دارد و برای سایر مجموعه داده‌ها نتایج خوبی ارائه نمی‌کند. شکل ۴ استفاده از نمودار کارایی پیش‌بینی برحسب دوره (epoch) را برای شبکه عصبی نشان می‌دهد. در شبکه عصبی محاسبه زمانی متوقف می‌شود که خطای ناشی از داده‌های اعتبارسنجی طی شش دوره متوالی بدون تغییر باشد. همان‌طور که مشاهده می‌شود برای پیش‌بینی MOR و MOE به ترتیب بعد از ۲۹ و ۱۴ دوره، در شش دوره متوالی بعدی خطا ثابت بوده و پیش‌بینی و پردازش داده‌ها متوقف شده است. با توجه به این نمودار مشخص می‌شود که شبکه به‌خوبی آموزش، اعتبار سنجی و آزمایش شده است، طوری که در دوره‌های ۲۹ و ۱۴ برای

انتقال تانژانت سیگموئید و تابع یادگیری لونبرگ-مارکوارت، نسبت به مدل‌های رگرسیونی ضریب تعیین بالاتر و درصد خطای کمتری را از خود نشان داد. مطابق نتایج این مطالعه و نتایج سایر محققین شبکه عصبی مصنوعی در مقایسه با مدل‌های رگرسیونی در پیش‌بینی خواص مکانیکی صفحات فشرده چوبی همواره نتایج بهتری از نقطه نظر پارامترهای آماری نشان داده است؛ بنابراین می‌توان نتیجه گرفت که شبکه عصبی یکی از بهترین گزینه‌ها برای پیش‌آگاهی و پیش‌بینی خواص مکانیکی صفحات فشرده مانند تخته خرده چوب به شمار می‌آید.

MOE دارد که بر اساس تقسیم‌بندی لوپس (۱۹۸۲) مقادیر درصد خطای پیش‌بینی خوب است اما مقادیر ضریب تبیین آن بسیار پایین است.

رگرسیون چند متغیره با استفاده از دانسیته، ضریب کشیدگی و درصد چسب بر اساس تقسیم‌بندی Lewis ۱۹۸۲ قابلیت پیش‌بینی بسیار خوبی برای پیش‌بینی مدول خمشی تخته خرده چوب دارد (خطای زیر ۱۰ درصد).

شبکه عصبی مصنوعی پرسپترون با سه ورودی (دانسیته، ضریب کشیدگی و درصد چسب)، یک‌لایه پنهان و یک‌لایه خروجی (MOR و MOE) و همچنین تابع

## منابع

- [1] Doosthosei, K., 2001. Wood Composite Materials Manufacturing, Applications. Tehran university press, 648 p.
- [2] Godwald, J., Barbu, M.C., Petutschnigg, A., Křišťák, L., and Tudor, E.M., 2021. Oversized Planer Shavings for the Core Layer of Lightweight Particleboard. *Polymers*, 13(7), p.1125.
- [3] Laskowska, A., and Mamiński, M., 2020. The properties of particles produced from waste plywood by shredding in a single-shaft shredder. *Maderas. Ciencia y tecnología*, 22(2), 197-204.
- [4] Ferrandez-Villena, M., Ferrandez-Garcia, C. E., Garcia-Ortuño, T., Ferrandez-Garcia, A., and Ferrandez-Garcia, M. T., 2020. The influence of processing and particle size on binderless particleboards made from *Arundo donax L. rhizome*. *Polymers*, 12(3), 696.
- [5] Arabi, M., Faezipour, M. and Gholizadeh, H., 2011 Reducing resin content and board density without adversely affecting the mechanical properties of particleboard through controlling particle size. *Journal of Forestry Research*, 22 (4), 659-664.
- [6] Arabi, M., Faezipour, M., Layeghi, M. and Enayati, A.A., 2011 Interaction analysis between slenderness ratio and resin content on mechanical properties of particleboard. *Journal of forestry research*, 22 (3), 461-464.
- [7] Ahmed, S.A., Adamopoulos, S., Li, J., and Kovacicova, J., 2020. Prediction of mechanical performance of acetylated MDF at different humid conditions. *Applied Sciences*, 10(23), p.8712.
- [8] Ismail, F.S., Bakar, N.A., and Alam, S., 2013. Multi-output hybrid GA-NN with adaptive mechanism. In *Proceedings of the 2013 International Conference on Applied Mathematics and Computational Methods*. pp. 232-237.
- [9] Jahanilomer, Z., Farrokhpayam, S.R., and Shamsian, M., 2014. A mathematical model to predict particleboard properties using the GMDH-type neural network and genetic algorithm. *Iranian Journal of Wood and Paper Science Research*, 29(3), 376-389.
- [10] Valarmathi, T.N., Palanikumar, K., Sekar, S., and Latha, B., 2020. Investigation of the effect of process parameters on surface roughness in drilling of particleboard composite panels using adaptive neuro fuzzy inference system. *Materials and Manufacturing Processes*, 35(4).469-477.

- [11] Eslah, F., Enayati, A.A., Tajvidi, M., and Faezipour, M.M., 2012. Regression models for the prediction of poplar particleboard properties based on urea formaldehyde resin content and board density. 14(6).1321-1329.
- [12] Fernández, F. G., de Palacios, P., Esteban, L. G., Garcia-Iruela, A., Rodrigo, B. G., and Menasalvas, E., 2012. Prediction of MOR and MOE of structural plywood board using an artificial neural network and comparison with a multivariate regression model. *Composites Part B: Engineering*, 43(8), 3528-3533.
- [13] Tiryaki, S., and Aydın, A., 2014. An artificial neural network model for predicting compression strength of heat treated woods and comparison with a multiple linear regression model. *Construction and Building Materials*, 62, 102-108.
- [14] Hagan MT., 1995. *Neural network design*, PWS, USA;
- [15] Anderson, J.A., 1995. *An introduction to neural networks*. MIT press.
- [16] Melo, R. R. D., and Miguel, E. P., 2016. Use of artificial neural networks in predicting particleboard quality parameters. *Revista Árvore*, 40(5), 949-958.
- [17] Tiryaki, S., Aras, U., Kalaycıoğlu, H., Erişir, E., and Aydın, A., 2017. Predictive models for modulus of rupture and modulus of elasticity of particleboard manufactured in different pressing conditions. *High Temperature Materials and Processes*, 36(6), 623-634.
- [18] Bardak, S., Tiryaki, S., Nemli, G., and Aydın, A., 2016. Investigation and neural network prediction of wood bonding quality based on pressing conditions. *International Journal of Adhesion and Adhesives*, 68, 115-123.
- [19] Kaya, A. İ., İlkucar, M., and Çifci, A., 2019. Use of Radial Basis Function Neural Network in Estimating Wood Composite Materials According to Mechanical and Physical Properties. *Erzincan Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 12(1), 116-123.
- [20] Palacios, P., Fernández, F. G., García-Iruela, A., González-Rodrigo, B., and Esteban, L. G., 2018. Study of the influence of the physical properties of particleboard type P2 on the internal bond of panels using artificial neural networks. *Computers and electronics in agriculture*, 155, 142-149.
- [21] Nazerian, M., Kamyabb, M., Shamsianb, M., Dahmardehb, M., and Kooshaa, M., 2018. Comparison of response surface methodology (RSM) and artificial neural networks (ANN) towards efficient optimization of flexural properties of gypsum-bonded fiberboards. *Cerne*, 24(1), 35-47.
- [22] Nazerian, M., Razavi, S. A., Partovinia, A., Vatankhah, E., and Razmpour, Z., 2020. Prediction of the Bending Strength of a Laminated Veneer Lumber (LVL) Using an Artificial Neural Network. *Mechanics of Composite Materials*, 56(5), 649-664.
- [23] Lewis, C. D., 1982: *Industrial and business forecasting methods*. Butterworths Publishing, London.
- [24] Kurt, R., and Karayilmazlar, S., 2019. Estimating Modulus of Elasticity (MOE) of Particleboards Using Artificial Neural Networks to Reduce Quality Measurements and Costs. *Drvna industrija: Znanstveni časopis za pitanja drvne tehnologije*, 70(3), pp.257-263.

## Prediction of the flexural strength of particleboard using artificial neural network modeling in comparison with regression models

### Abstract

Today, several modeling methods have been developed to predict the physical and mechanical properties of wood-based panel products, cost-efficiently. Two common modeling methods include regression and artificial neural networks (ANN). In this study, the possibility of predicting the modulus of rupture (MOR) and modulus of elasticity (MOE) of particleboard by simple and multiple linear regression and ANN models were evaluated based on the structural parameters including density in three levels (0.65, 0.7, and 0.75 g/cm<sup>3</sup>), slenderness ratio of particles in three levels (47, 30, and 13), and adhesive percent in three levels of (8, 9.5, and 11%). experimental and predicted data by different models were compared and assessed with several criteria including mean absolute percentage error (MAPE), mean squared error (MSE), and coefficient of determination (R<sup>2</sup>). The results revealed that although both multiple linear regression and artificial neural network models were able to predict MOR and MOE values with acceptable accuracy, but ANN model predicted them with higher R<sup>2</sup> and lower MAPE than the multiple linear regression model. The value of MAPE and R<sup>2</sup>, for prediction of MOR and MOE by ANN model were 7.72% and 0.77, and 7% and 0.86, respectively. The corresponding value for the multiple regression model were 8.3% and 0.738, and 9.06% and 0.783, respectively. These levels of error are industrially and practically satisfactory for the prediction of flexural strength in particleboard.

**Keywords:** Particleboard, Modulus of Rupture, Modulus of Elasticity, Artificial neural network, Multiple linear regression.

**M. Arabi**<sup>1\*</sup>  
**A. Rostampour Haftkhani**<sup>2</sup>  
**R. Pourbaba**<sup>3</sup>

<sup>1</sup> Assistant Professor, Department of Wood Science and Technology, Faculty of Natural Resources, University of Zabol, Zabol, Iran

<sup>2</sup> Assistant prof. of Wood Science and Technology, Department of natural resources, Faculty of agriculture and natural resources, University of Mohaghegh Ardabili, Ardabil, Iran

<sup>3</sup> Ph.D. student, Department of Wood and Paper Science and Technology, Faculty of Natural Resources, College of Agriculture & Natural Resources, University of Tehran, Karaj, I.R. Iran

Corresponding author:  
[marabi@uoz.ac.ir](mailto:marabi@uoz.ac.ir)

Received: 2021/05/29  
Accepted: 2021/08/25