

یک مدل ریاضی برای پیش‌بینی خواص تخته خرده چوب با کاربرد GMDH (نوعی شبکه عصبی مصنوعی و الگوریتم ژنتیک)

زهرا جهانی لمر^{۱*}، سعید رضا فرخ پیام^۲ و محمد شمسیان^۲

*۱- نویسنده مسئول، کارشناسی ارشد علوم و صنایع چوب و کاغذ، دانشکده منابع طبیعی، دانشگاه زابل

پست الکترونیک: zahrajahani12@yahoo.com

۲- استادیار، عضو هیئت علمی گروه علوم صنایع چوب و کاغذ، دانشکده منابع طبیعی، دانشگاه زابل

تاریخ دریافت: شهریور ۱۳۹۲ تاریخ پذیرش: خرداد ۱۳۹۳

چکیده

در این مطالعه از شبکه عصبی GMDH براساس الگوریتم ژنتیک برای پیش‌بینی خواص فیزیکی و مکانیکی تخته خرده چوب در مقیاس آزمایشگاهی استفاده شد. به منظور تعیین خواص فیزیکی و مکانیکی به وسیله شبکه عصبی GMDH، از مشخصات دمای پرس در ۴ سطح ۱۵۰، ۱۶۰، ۱۷۰ و ۱۸۰ درجه سانتی‌گراد، زمان بسته شدن پرس در ۳ سطح ۲۰، ۱۰ و ۳۰ ثانیه و رطوبت کیک در ۴ سطح ۸، ۱۰، ۱۲ و ۱۴ به عنوان داده‌های ورودی و از خواص فیزیکی و مکانیکی به عنوان داده خروجی استفاده گردید. کارایی مدل‌ها با استفاده از معیارهای میانگین مربعات خطا (MSE)، ریشه میانگین مربعات خطا (RMSE)، میانگین قدر مطلق انحراف (MAD) و ضریب تبیین (R^2) مورد ارزیابی قرار گرفت. نتایج نشان داد که مقادیر MSE، RMSE و MAD برای خواص WA_{24h} ، TS_{2h} ، TS_{24h} ، IB ، MOR و MOR پایین است و خطاهای به دست آمده برای مدل MOE ساخته شده به روش GMDH بسیار بالا می‌باشد. با توجه به مقادیر به دست آمده این مدل مناسب برای پیش‌بینی MOE نیست. مقادیر R^2 به دست آمده از مجموعه آزمون و آموزش برای خواص MOR ، IB ، MOE ، TS_{24h} ، TS_{2h} و WA_{24h} بیشتر از ۰/۹۱ درصد است، که این نشان‌دهنده عملکرد بهتر این مدل‌هاست.

واژه‌های کلیدی: تخته خرده چوب، مدل‌سازی، شبکه عصبی GMDH، خواص فیزیکی و مکانیکی

مقدمه

حساس است. در سال‌های اخیر تمایل زیادی نسبت به بررسی امکان استفاده از سیستم‌های شبکه‌های عصبی مصنوعی به وجود آمده است، این روش به طور گسترده در زمینه چوب در پیش‌بینی هدایت حرارتی از طریق ترکیبات شیمیایی و در به دست آوردن نقاط تعادل هیگروسکوپیک (Avramidis, 2005) و در طبقه‌بندی گونه‌ها با استفاده از اولتراسونیک (Iliadis و Jordan, et al., 1998)، در طبقه‌بندی معایب چوب (Drake and Packianather, 1998)، در طبقه‌بندی ساختارهای چوب با روش‌های غیر مخرب (Mire, et al., 2005) برای تشخیص آناتومی بین گونه‌های با جنس مشابه از روش بیومتری (Fernandez, et al., 2007) در فرایند تولید

تخته خرده چوب از مهمترین فرآورده‌های مرکب چوبی است که با توجه به ضرورت کاربرد چوب‌آلات بی‌کیفیت و کم‌ارزش توسعه یافته است. مدل‌سازی علمی است که به مجموعه فرایندهای مربوط به تنظیم، برگزینی و اعتبارسنجی مدل‌های مورد نیاز جهت نمایش اشیاء و پدیده‌ها در علوم مختلف اطلاق می‌شود. ساخت مدل نیاز به مهارت‌های سطح بالای ریاضی دارد. هدف عمده‌ی مدل‌سازی، تعیین روابط بین متغیرها، تعیین متغیرهای اثرگذار و پیش‌بینی است. انتخاب روش مناسب برای مدل‌سازی و تحلیل داده‌های آزمایشگاهی، مبتنی بر نوع داده‌های موجود بسیار مهم و در مواردی بسیار

ضخامت تخته و دانسیته) با دو روش مدل‌سازی رگرسیون خطی و شبکه عصبی پیش‌بینی کردند. نتایج آنها نشان داد که روش‌های رگرسیونی مقاومت خمشی، مدول الاستیسیته و چسبندگی داخلی تخته خرده چوب را به ترتیب با خطا پیش‌بینی می‌کند. در حالی که شبکه عصبی مصنوعی شبکه عصبی را با خطای کمتری پیش‌بینی می‌کند. بنابراین مقایسه این دو روش نشان داد که استفاده از شبکه عصبی مصنوعی خطای پیش‌بینی را تا حد زیادی کاهش داده است.

هدف از این مطالعه این است که با استفاده از شبکه عصبی GMDH^۱ مبتنی بر الگوریتم ژنتیک، به پیش‌بینی مقاومت‌های فیزیکی و مکانیکی تخته خرده چوب با متغیرهای مؤثر بر ساخت تخته خرده چوب بپردازیم.

مواد و روش‌ها

برای ساخت تخته‌های آزمونی خرده چوب‌های درشت و نرمه صنعتی از کارخانه صنعت شمال واقع در گنبدکاووس تهیه و بعد برای جلوگیری از جذب رطوبت در کیسه‌های پلاستیکی نگهداری شدند. تخته‌های آزمونی مورد نیاز با در نظر گرفتن عوامل متغیر و ثابت بشرح زیر ساخته شدند. عوامل متغیر شامل دمای پرس در چهار سطح ۱۵۰، ۱۶۰، ۱۷۰ و ۱۸۰ درجه سانتی‌گراد و زمان بسته شدن پرس در سه سطح ۱۰، ۲۰ و ۳۰ ثانیه و رطوبت کیک در چهار سطح ۸، ۱۰، ۱۲ و ۱۴ درصد بود. دیگر عوامل ساخت تخته ثابت در نظر گرفته شد که در جدول ۱ فاکتورهای ثابت ساخت تخته خرده چوب‌ها قابل مشاهده است.

خواص فیزیکی شامل جذب آب (WA)^۲ و واکنشیدگی ضخامت (TS)^۳ در دو زمان ۲ و ۲۴ ساعت طبق استاندارد EN-317 و خواص مکانیکی شامل مدول الاستیسیته (MOE)^۴، مقاومت خمشی (MOR)^۵ و چسبندگی داخلی (IB)^۶ به ترتیب طبق استانداردهای EN-310 و EN-319 اندازه‌گیری شدند.

مواد مرکب چوبی (Krauss, et al., 1997)، پرس داغ (Schniewind and Halligan, 1974)، کنگره کردن مبلمان (Anderson, 1983)، تاییدگی مواد مرکب چوبی روکش شده (Hong and Suchsland, 1989) در به دست آوردن مقاومت چسبندگی داخلی تخته خرده چوب با پارامترهای تولید (Cook and Chiu, 1993؛ Whittaker and Cook, 1997) و غیره استفاده شده است. Cook و همکاران (۲۰۰۰) خواص مکانیکی تخته خرده چوب را با ترکیب شبکه عصبی و الگوریتم ژنتیک پیش‌بینی کردند و بیان کردند که ترکیب این دو روش پیش‌بینی خواص مکانیکی در تخته خرده چوب را بهبود می‌بخشد و می‌توان چسبندگی داخلی تخته خرده چوب را با دقت ۹۲ درصد پیش‌بینی کرد. در همین زمینه Estolan و همکاران (۲۰۰۹) نشان دادند که مدل ساخته‌شده با شبکه عصبی می‌تواند چسبندگی داخلی تخته خرده چوب را با استفاده از اطلاعات مربوط به دانسیته تخته، محتوای رطوبت، واکنشیدگی ضخامت و جذب آب در محدوده قابل قبولی پیش‌بینی کند. Yapici و همکاران (۲۰۰۹) در تحقیقی که به منظور تعیین مقدار مقاومت خمشی و مدول الاستیسیته فلیک‌برد از منطبق فازی استفاده کردند. آنها برای ایجاد مدل منطبق فازی از تخته‌های صنعتی که به‌طور خاص و به‌صورت مختلط با کاج و صنوبر تولیدشده بودند، استفاده کردند. سپس براساس الگوی منطبق فازی که در Matlab Simulink آماده‌شده بود، مقادیر MOE و MOR پیش‌بینی شدند. نتایج نشان داد که این مدل قادر است MOR را با ۹۵/۲۷ درصد و MOE را با ۹۶/۷۸ درصد پیش‌بینی کند، همچنین بیان داشتند با اختلاط این گونه‌ها میزان دقت این مدل برای پیش‌بینی مقادیر MOE و MOR کاهش می‌یابد. Nirdosha و Setunge (۲۰۰۶) با مدل‌سازی فرایند تولید تخته خرده چوب سه لایه ساخته‌شده با ضایعات کارخانه چوب‌بری پهن‌برگان نشان دادند که مدل به‌دست‌آمده توانایی مناسبی در تعیین رابطه پیچیده پارامترهای تولید و خواص خمشی تخته خرده چوب داشته است، همچنین بیان کردند که استفاده از طرح فاکتوریل دو سطح مصرف ماده اولیه و زمان انجام آزمایش و آنالیز را کاهش داد. طبق نتایج آنان در مورد مقاومت خمشی و مدول الاستیسیته مؤثرترین عامل به ترتیب رطوبت لایه‌های سطحی و درصد هاردنر در لایه میانی بود. Fernandez و همکاران (۲۰۰۸) خواص مکانیکی تخته خرده چوب را براساس خواص فیزیکی آن (جذب آب، واکنشیدگی ضخامت،

- 1- Group Method of Data Handeling
- 2- Water Absorption
- 3- Thickness swelling
- 4- Modulus Of Elasticity
- 5- Modulus of Rupture
- 6- Internal Bond

شبکه عصبی (GMDH)

به‌طور کلی برای مدل کردن سیستم‌های پیچیده‌ای که شامل مجموعه‌ای از داده‌ها با چندین ورودی و یک خروجی می‌باشند می‌توان از چندجمله‌ای‌های (VKG) (رابطه ۶) استفاده نمود.

جدول ۱- فاکتورهای ثابت ساخت تخته خرده چوب

فاکتور	مقدار
جرم مخصوص	0.7 g/cm^3
ضخامت اسمی تخته خرده چوب	۱۶ میلی‌متر
مقدار رزین مصرفی UF	۱۰ درصد وزن خشک خرده چوب‌ها
هاردنر (NH ₄ CL)	۲ درصد بر مبنای وزن خشک چسب
مقدار فشار پرس	35 gr/cm^2
زمان پرس	۳۶۰ ثانیه

$$y = a_0 + \sum_{i=1}^n a_i x_i + \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j + \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n a_{ijk} x_i x_j x_k + \dots \quad \text{رابطه (۱)}$$

شبکه عصبی GMDH دارای ساختار یک شبکه چندلایه و روبه‌جلو است و دربرگیرنده مجموعه‌ای از نرون‌ها است که از پیوند جفت‌های مختلف ورودی از طریق یک چندجمله‌ای درجه دوم به وجود می‌آیند. هر لایه در این شبکه از یک یا چند واحد پردازشگر تشکیل شده است که هر یک از آنها دارای دو ورودی و یک خروجی است. این واحدها عملاً نقش اجزای سازنده مدل را ایفا می‌نمایند و به شکل یک چندجمله‌ای درجه دوم فرض می‌شوند (رابطه ۲).

که در آن $x = (x_1, x_2, \dots, x_n)$ بردارهای ورودی، y خروجی مدل و a_i ها ضرایب چندجمله‌ای می‌باشد. چندجمله‌ای‌های VKG با استفاده از چندجمله‌ای‌های درجه دوم تقریب زده می‌شوند. این چندجمله‌ای‌های درجه دوم براساس ترکیبات دوتایی ورودی‌های شبکه ساخته می‌شوند. الگوریتم GMDH با استفاده از این ایده به‌عنوان روش یادگیری، برای مدل‌سازی سیستم‌های پیچیده معرفی شده است (Ivakhnenko, 1971).

$$\hat{y}_n = a_0 + a_1 x_1 + a_2 x_2 + a_3 x_1 x_2 + a_4 x_1^2 + a_5 x_2^2 \quad \text{رابطه (۲)}$$

بردار ورودی $x = (x_{i1}, x_{i2}, \dots, x_{in})$ براساس رابطه (۲)، باید میانگین مربعات خطا (رابطه ۳) به حداقل برسد.

پارامترهای مجهول الگوریتم GMDH ضرایب چندجمله‌ای رابطه ۲ است. به‌منظور محاسبه مقدار خروجی \hat{y}_i برای هر

$$e = \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad \text{رابطه (۳)}$$

در این معادله $a = \{a_0, a_1, a_2, a_3, a_4, a_5\}$ و ماتریس A مطابق رابطه ۴ است.

$$A = \begin{bmatrix} 1 & x_{1p} & x_{1p} & x_{1p}^2 & x_{1p}^2 & x_{1p} & x_{1p} \\ 1 & x_{2p} & x_{2q} & x_{2p}^2 & x_{2q}^2 & x_{2p} & x_{2q} \\ 1 & x_{np} & x_{nq} & x_{np}^2 & x_{nq}^2 & x_{np} & x_{nq} \end{bmatrix}$$

رابطه (۴)

$$a = (A^T A)^{-1} A^T y$$

رابطه (۵)

پارامترهای ورودی و خروجی مدل به منظور پیش‌بینی خواص فیزیکی و مکانیکی با استفاده از شبکه عصبی GMDH، ۴۸ داده موجود به دو گروه آموزش و آزمون تقسیم گردید. مجموعه آموزش (شامل ۳۸ داده)، برای طراحی ساختار GMDH و مجموعه آزمون (شامل ۱۰ داده) برای برآورد عملکرد شبکه در پیش‌بینی بکار رفته است، به منظور به دست آوردن چند جمله‌ای مناسب برای برآورد مقاومت‌های مکانیکی و فیزیکی نسبت به پارامترهای ورودی، در طراحی ساختار GMDH از جمعیت اولیه ۱۵۰، احتمال (Crossover) ۰/۹ و احتمال جهش (Mutation) ۰/۱ در ۱۰۰ نسل (تکرار) استفاده شد. داده‌های ورودی و خروجی شبکه عصبی در جدول شماره ۱ نمایش داده شده است. برای ارزیابی پیش‌بینی‌ها، معمولاً از خطاهای پیش‌بینی یا توابعی از آنها استفاده می‌شود. در این مطالعه میزان خطای پیش‌بینی خواص فیزیکی و مکانیکی با معیارهای MSE^2 ، $RMSE^3$ ، MAD^4 و R^2 مورد بررسی قرار گرفته است.

برای یافتن مقدار حداقل خطا، از مشتق جزئی رابطه ۳ استفاده می‌شود. با جایگذاری از رابطه ۲ در این مشتق جزئی، یک معادله ماتریسی ($Aa = y$) به دست می‌آید.

یک روش حل برای این معادله ماتریسی ($Aa = y$)، استفاده از روش تجزیه به مقدار تکین (SVD) است. در صورت استفاده از روش SVD مجهول a از رابطه ۵ محاسبه می‌گردد. در رابطه ۵، A^T ترانزپوز ماتریس A است. با استفاده از این روش حل مجهول a در هر حالتی قابل محاسبه خواهد بود. چنانچه ماتریس $(A^T A)$ وارون پذیر نباشد از روش Tikhonov برای حل معادله استفاده خواهد شد. در طراحی شبکه عصبی GMDH، هدف جلوگیری از رشد واگرایی شبکه و نیز مرتبط کردن شکل و ساختار شبکه به یک یا چند پارامتر عددی بوده، به گونه‌ای که با تغییر این پارامتر ساختار شبکه نیز تغییر می‌کند. روش‌های تکاملی مانند الگوریتم ژنتیک کاربرد وسیعی در مراحل مختلف طراحی شبکه‌های عصبی به دلیل قابلیت‌های منحصربه‌فرد خود در پیدا کردن مقادیر بهینه و امکان جستجو در فضاها غیرقابل پیش‌بینی دارند. در این مقاله برای طراحی شکل شبکه عصبی و تعیین ضرایب آن، از الگوریتم ژنتیک استفاده شده است (Hiassat, 2003). برای عمومیت بخشیدن به شبکه‌های عصبی GMDH، باید استفاده از لایه مجاور در ساختن لایه بعد حذف شود و برای ساخت لایه جدید از تمام لایه‌های قبلی (شامل لایه ورودی) استفاده می‌کنند (Nariman-zadeh, et al., 2002).

-
- 1-Singular Value Decomposition
 - 2- Mean Square Error
 - 3 -Root Mean Square Error
 - 4 -Mean Absolute Deviation
 - 5 -Determination Coefficient

جدول ۲- پارامترهای ورودی و خروجی مدل

پارامترهای خروجی			پارامترهای ورودی		
مقاومت‌های مکانیکی			رطوبت کیک (%)	زمان بسته شدن پرس (S)	دمای پرس (C°)
چسبندگی	مقاومت	مدول الاستیسیته	۸	۱۰	۱۵۰
			۱۰	۲۰	۱۶۰
(Mpa) داخلی	خمشی (Mpa)	(Mpa)	۱۲	۳۰	۱۷۰
			۱۴	-	۱۸۰

به منظور تدوین الگو و پیش‌بینی مقاومت‌های فیزیکی و مکانیکی تخته خرده‌چوب، در این مطالعه از برنامه GMDH الگوریتم دسته‌بندی داده‌های عددی، که در آن برای پیدا کردن بهترین مدل از الگوریتم ژنتیک استفاده شده است در نرم‌افزار MATLAB نوشته شده است. رسم نمودارها در Excell ۲۰۰۷ انجام شد.

$$R^2 = 1 - \frac{\sum_{i=0}^M (Y_{i(\text{model})} - Y_{i(\text{actual})})^2}{\sum_{i=1}^M (Y_{i(\text{actual})})^2}$$

$$RMSE = \left[\frac{\sum_{i=0}^M (Y_{i(\text{model})} - Y_{i(\text{actual})})^2}{M} \right]^{1/2}$$

$$MAD = \frac{\sum_{i=0}^M |Y_{i(\text{model})} - Y_{i(\text{actual})}|}{M}$$

$$MSE = \frac{\sum_{i=0}^M (Y_{i(\text{model})} - Y_{i(\text{actual})})^2}{M}$$

رابطه (۶)

جدول ۳ - معادلات چندجمله‌ای از مدل GMDH برای مقاومت‌های فیزیکی و مکانیکی تخته خرده چوب


$F(X_1, X_2) y_1 = 1.21807 + -0.05413x_1 - 0.00937x_2 - 0.00073x_1^2 + 0.00001x_2^2 + 0.00045x_1x_2$ $F(X_1, X_3) y_2 = 12.00945 + 1.64439x_1 + 0.00714x_3 - 0.07328x_1^2 - 0.00618x_3^2 + 0.01972x_1x_3$ $F(X_2, X_1) y_3 = 1.21807 - 0.05413x_2 - 0.00937x_1 - 0.00073x_2^2 + 0.00001x_1^2 + 0.00045x_2x_1$ $F(X_2, y_1) y_4 = -39.56492 + 0.03746x_2 + 4.13700y_1 + 0.00091x_2^2 - 0.00910y_1^2 - 0.01548x_2y_1$ $F(y_2, y_3) y_5 = 1.55894 - 0.07033y_2 - 0.06363y_3 - 0.00148y_2^2 - 0.00162y_3^2 + 0.006431y_2y_3$ $F(y_4, y_5) y_6 = 14.37819 + 3.26024y_4 + a_3 - 3.57484y_5 - 0.57462y_4^2 - 0.42702y_5^2 + 1.03189y_4y_5$	رابطه MOR (۷)
$F(X_2, X_3) y_1 = -2.34971 + 0.03423x_2 - 0.00482x_3 - 0.00009x_2^2 - 0.00024x_3^2 + 0.00009x_2x_3$ $F(X_1, y_1) y_2 = -0.00828 - 1.77541x_1 + 0.92646y_1 - 86.03766x_1^2 - 0.00016y_1^2 + 0.25107x_1y_1$ $F(X_2, y_2) y_3 = 0.00014 + 0.00486x_2 + 0.76013y_2 - 2.35421x_2^2 - 0.00102y_2^2 + 0.10003x_2y_2$	رابطه MOE (۸)
$F(X_1, X_2) y_1 = -5.26153 - 0.10809x_1 + 0.07918x_2 + 0.00177x_1^2 + 0.00025x_2^2 + 0.00037x_1x_2$ $F(y_1, X_1) y_2 = 16.04232 - 51.18167y_1 - 0.29392x_1 + 41.79839y_1^2 + 0.00023x_1^2 + 0.52738y_1x_1$ $F(y_2, X_3) y_3 = 0.20241 + 1.11456y_2 - 0.02842x_3 - 0.52620y_2^2 + 0.00040x_3^2 + 0.02497y_2x_3$	رابطه IB (۹)
$F(X_1, X_3) y_1 = 48.16170 + -0.46660x_1 - 0.17379x_3 - 0.15598x_1^2 - 0.02783x_3^2 + 0.09386x_1x_3$ $F(X_1, X_2) y_2 = -1.03052 + 0.06137x_1 + 0.01261x_2 - 0.001558x_1^2 - 0.00002x_2^2 - 0.00028x_1x_2$ $F(X_1, y_1) y_3 = 5.47720 - 0.37417x_1 - 0.24807y_1 - 0.005931x_1^2 + 0.00286y_1^2 + 0.00934x_1y_1$ $F(X_1, y_2) y_4 = -8.82374 + 0.68932x_1 + 0.37952y_2 - 0.01342x_1^2 - 0.00385y_2^2 - 0.01447x_1y_1$ $F(y_3, y_4) y_5 = 1.76192 + 3.40766y_3 - 2.62409y_4 - 0.01966y_3^2 + 0.06610y_4^2 - 0.040886y_3y_4$	رابطه WA _{2h} (۱۰)
$F(X_2, X_3) y_1 = 1.57263 - 0.1731x_2 + 0.00314x_3 + 0.00005x_2^2 - 0.0004x_3^2 - 0.00000x_2x_3$ $F(X_1, X_3) y_2 = 1.46391 + 0.01105x_1 - 0.01622x_2 + 0.00024x_1^2 + 0.00005x_2^2 - 0.00011x_1x_2$ $F(y_1, y_2) y_3 = 26.66445 - 1.63466x_1 - 0.29531x_3 + 0.02468x_1^2 - 0.00403x_3^2 + 0.041593x_1x_3$ $F(x_1, y_3) y_4 = -43.650399 + 8.61654y_1 - 1.15282x_1 - 0.29246y_1^2 + 0.02468x_1^2 + 0.02660y_1x_1$ $F(y_2, y_3) y_5 = 31.20615 - 8.13611y_2 + 3.84922y_3 + 0.25119y_2^2 - 0.20779y_3^2 + 0.17734y_2y_3$ $F(y_4, y_5) y_6 = -57.34935 + 12.37387y_4 - 2.61294y_5 - 0.16291y_4^2 + 0.47880y_5^2 - 0.64984y_4y_5$	رابطه WA _{24h} (۱۱)
$F(X_1, X_2) y_1 = 1.17591 + 0.00795x_1 - 0.01330x_2 + 0.00009x_1^2 + 0.00004x_2^2 - 0.00007x_1x_2$ $F(X_2, X_3) y_2 = 1.26522 - 0.01408x_2 + 0.00102x_3 + 0.00004x_2^2 - 0.000022x_3^2 - 0.00000x_2x_3$ $F(y_3, X_2) y_3 = -5.36213 + 3.96224y_3 - 1.77100x_2 + 1.75336y_3^2 + 2.18343x_2^2 - 4.00293y_3x_2$ $F(y_3, X_2) y_4 = 2.57395 - 0.19332y_3 + x_2 - 0.021977y_3^2 + 0.00004x_2^2 + 0.00081y_3x_2$	رابطه TS _{2h} (۱۲)
$F(X_1, X_2) y_1 = 41.04658 + 11.92546x_1 - 0.52826x_2 - 0.39276x_1^2 + 0.00308x_2^2 - 0.03611x_1x_2$ $F(X_1, X_3) y_2 = 58.94012 + 4.17518x_1 - 0.67716x_3 - 0.39276x_1^2 + 0.01503x_3^2 + 0.08953x_1x_3$ $F(X_2, y_1) y_3 = 50.08403 + 0.06250x_2 - 1.02779y_1 - 0.0054x_2^2 + 0.01626y_1^2 + 0.00179x_2y_1$ $F(X_3, y_3) y_4 = 26.84007 + 0.37846x_3 - 0.14424y_3 + 0.00272x_3^2 + 0.01130y_3^2 - 0.00456x_3y_3$ $F(y_3, y_4) y_5 = 24.29906 - 2.94964y_3 + 3.04911y_4 + 0.09577y_3^2 + 0.05131y_4^2 - 0.13912y_3y_4$	رابطه TS _{24h} (۱۳)

نتایج

توابع پیش‌بینی برای مقاومت‌های فیزیکی و مکانیکی تخته خرده چوب در جدول ۳ نشان داده شده است.


مقاومت چسبندگی داخلی

طبق این روش مدل IB وابسته به ۳ پارامتر ورودی زمان بسته شدن دهانه پرس، دمای پرس و رطوبت کیک می‌باشد. ساختار پیشنهادی الگوریتم ژنتیک که به‌عنوان ساختار بهینه شبکه‌ی GMDH برای پیش‌بینی مقاومت چسبندگی داخلی در شکل ۱ نشان داده شده است، برای سهولت حد‌نگارش معادلات چندجمله‌ای نرون‌های پنهان شبکه به صورت y_1, \dots, y_n و نرون‌های خروجی به صورت مقاومت IB نام‌گذاری شد. هرکدام از نرون‌های پنهان دارای ژنوم ترکیب ویژه از نماد (a, b, c, \dots) هستند و لازم به ذکر است که در این نرون‌ها a, b و c به ترتیب برابر دمای پرس، رطوبت کیک و زمان بسته شدن دهانه پرس است. برای نمونه، معادله y_1 نخستین لایه پنهان ساختار IB از ترکیب دو ورودی (a, b) و سرانجام مقاومت (IB) از دو نرون (y_2, y_3) تشکیل شده است و ژنوم‌های آنها از ترکیب دو ژنوم قبلی به وجود آمده است؛ با توجه به شکل مربوط می‌توان روابط میان متغیرهای ورودی جهت دستیابی به نرون‌های موجود در لایه‌های پنهان و در نهایت خروجی مدل یا همان IB را دنبال کرد.



شکل ۱- ژنوم مقاومت چسبندگی داخلی

در جدول ۳ و در رابطه‌ی ۹ چندجمله‌ای‌های مربوط به مدل‌های جزئی و مدل نهایی IB نشان داده شده است. معادله چندجمله‌ای به‌دست آمده از شبکه GMDH برای IB بیان‌کننده روابط کمی زمان بسته شدن دهانه پرس، دمای پرس و رطوبت کیک تخته خرده چوب است. در تمام این معادله‌ها x_1, x_2 و x_3 به ترتیب رطوبت کیک تخته خرده چوب، دمای پرس و زمان بسته شدن دهانه پرس است که تمامی متغیرهای ورودی مورد بررسی و عوامل اثرگذاری در ساختار مدل و توسعه آن نقش داشته‌اند. معادلات y_1 تا y_3 توابع ریاضی نرون‌های موجود در لایه‌های پنهان را نشان می‌دهند، به عبارت دیگر معادلات نمایانگر فرمول ریاضی نرون‌های $(y_1(x_1, x_2))$ ، $(y_2(y_1, x_1))$ ، $(y_3(y_2, x_3))$ هستند که خود آنها نیز از لایه‌های ورودی منشأ گرفتند و در نهایت به لایه خروجی مقاومت چسبندگی داخلی که همان $abaaacccc$ است، ختم شدند. همان‌گونه که در شکل ۱ می‌بینید در ژنوم IB اتصال نرون‌ها به لایه مجاور از بین رفته که این حالت سبب افزایش انعطاف‌پذیری مدل و نیز کاهش نرون‌های موجود در لایه پنهان شده است. این حالت را به خوبی می‌توان در مورد نرون $(adaa)$ در لایه پنهان دوم مشاهده نمود. در حقیقت در این حالت ابتدا یک نرون مجازی به اسم (aa) در لایه پنهان اول تشکیل شده و بعد نرون با اتصال به نرون (ad) در همان لایه سبب تشکیل نرون $(adaa)$ در لایه پنهان دوم می‌گردد. به منظور مقایسه بهتر داده‌های آموزش و آزمون، خروجی واقعی و خروجی برآورد شده رسم شده است (شکل ۲). این نمودار توانایی بالای مدل GMDH را در پیش‌بینی خروجی نشان می‌دهد. همچنین داده‌های آزمون با وجود اینکه در فرایند آموزش هیچ نقشی نداشته اما توسط مدل GMDH به خوبی پیش‌بینی شده است. برای طراحی شکل شبکه عصبی و تعیین ضرایب آن از الگوریتم ژنتیک استفاده شده است.




شکل ۲- مقایسه داده‌های واقعی (●) و پیش‌بینی شده (■) IB

رطوبت کیک برای ساختار پیشنهادی الگوریتم ژنتیک برای پیش‌بینی مدول گسیختگی در شکل ۳ نشان داده شده است.

مقاومت خمشی


با توجه به روش GMDH مدل MOR وابسته به ۳ پارامتر ورودی زمان بسته شدن دهانه پرس، دمای پرس و



شکل ۳- ژنوم مقاومت خمشی

تابع پیش‌بینی کننده MOR در جدول ۳ و در رابطه‌ی ۷ قرار دارد. همان‌طور که مشاهده می‌کنید تمامی متغیرهای زمان بسته شدن دهانه پرس، دمای پرس و رطوبت کیک در ساختار مدل آن می‌باشد که این نشان‌دهنده تأثیر فاکتورهای مورد مطالعه در ساختار مدل و توسعه آن می‌باشد. معادلات y_1 تا y_6 توابع ریاضی نرونی موجود در لایه‌های پنهان را نشان می‌دهند، به عبارت دیگر معادلات نمایانگر فرمول ریاضی نرونی‌های $(y_1(x_1, x_2))$, $(y_2(x_1, x_3))$, $(y_3(x_2, x_1))$ هستند که خود آنها نیز از لایه‌های ورودی منشأ گرفته و در نهایت به لایه خروجی مدول گسیختگی که همان aaabbacba است ختم می‌شوند. همچنین شکل ۴ نشان می‌دهد که خطای مدل پیشنهادی GMDH به حد معقولی رسیده و این شبکه قادر است به‌طور صحیح رابطه بین پارامترهای ورودی و خروجی را تشخیص دهد و این بیانگر افزایش دقت و کارایی مدل است.

مورد مطالعه در ساختار مدل و توسعه آن می‌باشد. معادلات y_1 تا y_6 توابع ریاضی نرونی موجود در لایه‌های پنهان را نشان می‌دهند، به عبارت دیگر معادلات نمایانگر فرمول ریاضی نرونی‌های $(y_1(x_1, x_2))$, $(y_2(x_1, x_3))$, $(y_3(x_2, x_1))$ هستند که خود آنها نیز از لایه‌های ورودی منشأ گرفته و در نهایت به لایه خروجی مدول گسیختگی که همان aaabbacba است ختم می‌شوند. همچنین شکل ۴ نشان می‌دهد که خطای مدل پیشنهادی GMDH به حد معقولی رسیده و این شبکه قادر است به‌طور صحیح رابطه بین پارامترهای ورودی و خروجی را تشخیص دهد و این بیانگر افزایش دقت و کارایی مدل است.




شکل ۴- مقایسه داده‌های واقعی (●) و پیش‌بینی شده (■) MOR

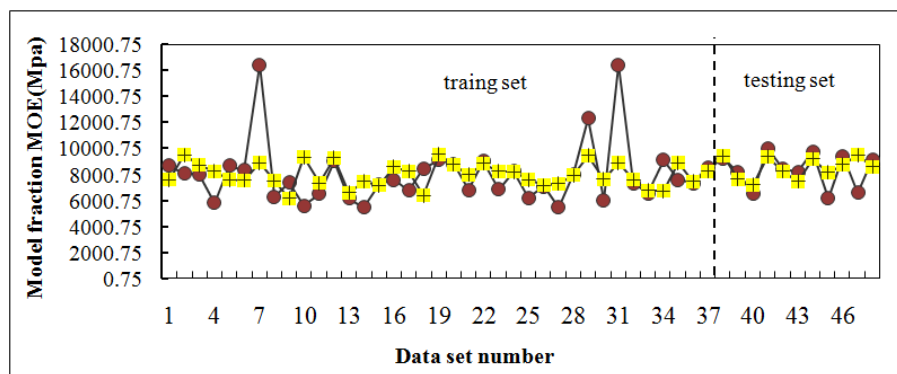
مدول الاستیسیته

در این روش مدل MOE به دست آمده وابسته به ۳ پارامتر ورودی زمان بسته شدن دهانه پرس، دمای پرس و رطوبت کیک است. ساختار الگوریتم ژنتیک مربوط به مدل الاستیسیته در شکل ۵ نشان داده شده است. با توجه به اینکه در این مدل نیز تمامی متغیرهای ورودی مورد بررسی عوامل اثرگذاری در ساختار مدل و توسعه آن نقش داشته‌اند. بنابراین معادلات y_1 تا y_3 توابع ریاضی نرون‌های موجود در لایه‌های پنهان را نشان می‌دهند. به عبارت دیگر

معادلات نمایانگر فرمول ریاضی نرون‌های $(y_1(x_2, x_1))$ ، $(y_2(x_1, y_1))$ ، $(y_3(x_2, y_2))$ هستند که خود آنها نیز از لایه‌های ورودی منشأ گرفته و در نهایت به لایه خروجی مدل الاستیسیته که $bbbbaabc$ است، ختم می‌شوند. به منظور مقایسه بهتر آموزش و آزمون، داده‌های آموزش و آزمون در امتداد هم در شکل ۶ رسم شده است و اختلاف نقاط واقعی و پیش‌بینی شده از خطای مدل پیشنهادی در آن نقطه را نشان می‌دهد.




شکل ۵- ژنوم مدل الاستیسیته



شکل ۶- مقایسه داده‌های واقعی (●) و پیش‌بینی شده (⊕) MOE

واکسیدگی ضخامت بعد از ۲ و ۲۴ ساعت است، در شکل ۷ نشان داده شده است. با توجه به شکل مربوط می‌توان روابط میان متغیرهای ورودی جهت دستیابی به نرون‌های موجود در لایه‌های پنهان و در نهایت خروجی مدل جذب آب بعد از ۲ و ۲۴ ساعت را دنبال کرد.


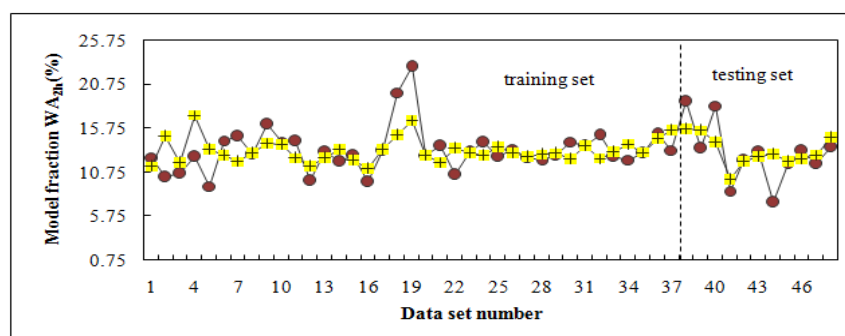
پیش‌بینی جذب آب بعد از ۲ و ۲۴ ساعت تخته خرده چوب طبق روش GMDH مدل WA_{2h} و WA_{24h} به دست آمده وابسته به ۳ پارامتر ورودی زمان بسته شدن دهانه پرس، دمای پرس و رطوبت کیک است. ساختار الگوریتم ژنتیک که به عنوان ساختار بهینه شبکه عصبی برای پیش‌بینی



شکل ۷- ژنوم جذب آب بعد از ۲ و ۲۴ ساعت

داده‌شده که در آن معادلات از y_1 تا y_6 توابع ریاضی نرون‌های موجود در لایه‌های پنهان را نشان می‌دهد. این معادله‌ها نمایانگر فرمول ریاضی نرون‌های $(y_1(x_2, x_3))$ ، $(y_2(x_1, x_3))$ ، $(y_3(y_1, y_2))$ ، $(y_4(x_1, y_2))$ و $(y_5(y_2, y_3))$ و $(y_6(y_4, y_5))$ است. شکل ۸ مقایسه بهتر داده‌های آزمون و آموزش برای مقاومت‌های WA_{2h} و WA_{24h} را نشان می‌دهد که در اینجا تطابق داده‌های آزمون با داده‌های واقعی نشان‌دهنده کارایی بهتر مدل است.

y_1 تا y_5 توابع ریاضی نرون‌های موجود در لایه‌های پنهان را به مقاومت WA_{2h} در جدول ۳ و در معادله ۱۰ نشان می‌دهد، به عبارت دیگر معادلات نمایانگر فرمول ریاضی نرون‌های $(y_1(x_2, x_3))$ ، $(y_2(x_1, x_3))$ ، $(y_3(y_1, y_2))$ و $(y_4(x_1, y_2))$ و $(y_5(y_2, y_3))$ هستند که خود آنها نیز از لایه‌های ورودی منشأ گرفته و در نهایت به لایه خروجی مدول گسیختگی که همان $aaacaaab$ است، ختم می‌شوند. معادله مربوط به WA_{24h} در جدول ۳ و در رابطه ۱۰ نشان




شکل ۸- مقایسه داده‌های واقعی (●) و پیش‌بینی شده (✚) جذب آب بعد از ۲ و ۲۴ ساعت


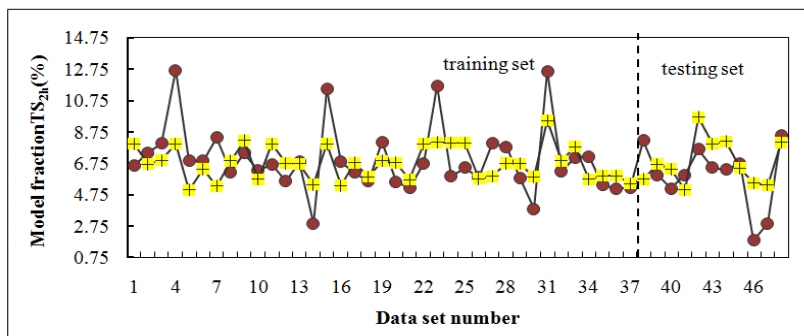
معادلات نمایانگر فرمول ریاضی نرون‌های $y_1(x_1, x_2)$ هستند که خود آنها نیز از لایه‌های ورودی منشأ گرفته و در نهایت به لایه خروجی TS_{24h} که همان $abbcbbbbb$ است، ختم می‌شوند؛ و معادلات y_1 تا y_5 توابع ریاضی نرون‌های موجود در لایه‌های پنهان مدل TS_{24h} را در جدول ۳ و در رابطه‌های ۱۳ نشان می‌دهد. این معادله‌ها نمایانگر فرمول ریاضی نرون‌های $y_1(x_1, x_2)$ ، $y_2(x_1, x_3)$ ، $y_3(x_2, y_1)$ ، $y_4(x_3, y_3)$ و $y_5(y_3, y_4)$ است؛ در نهایت به لایه خروجی که همان $bbabccac$ است، ختم می‌شوند.

پیش‌بینی واکشیدگی ضخامت بعد از ۲ و ۲۴ ساعت تخته خرده چوب

طبق روش GMDH مدل TS_{2h} و TS_{24h} به دست آمده و وابسته به ۳ پارامتر ورودی زمان بسته شدن دهانه پرس، دمای پرس و رطوبت کیک است. ساختار ژنوم برای پیش‌بینی واکشیدگی ضخامت بعد از ۲ و ۲۴ ساعت در شکل ۹ نشان داده شده است که نشان می‌دهد تمامی متغیرهای ورودی عوامل اثرگذاری در ساختار مدل و توسعه آن نقش داشته‌اند. معادلات مربوط به مدل TS_{2h} در جدول ۳ و در رابطه ۱۲ نشان داده شده است. به عبارت دیگر



شکل ۹- ژنوم واکشیدگی ضخامت بعد از ۲ و ۲۴ ساعت



شکل ۱۰- مقایسه داده‌های واقعی (●) و پیش‌بینی شده (■) واکشیدگی ضخامت بعد از ۲ و ۲۴ ساعت چوب

برآورد شده مدل واکنش‌دهی ضخامت بعد از ۲ و ۲۴ ساعت حتی در برخی نقاط همپوشانی دارند.

در شکل ۱۰ مقایسه‌ی بین داده‌های آموزشی و آزمایش برآورد شده توسط شبکه عصبی با روش GMDH نشان داده شده است، این نمودار نشان می‌دهد که مقادیر واقعی و

جدول ۴- شاخص‌های آماری مدل شبکه‌های عصبی GMDH در پیش‌بینی خواص مکانیکی و فیزیکی تخته خرده چوب

شاخص آماری	R^2	MAD	MSE	RMSE	واحد	نوع مقاومت
داده‌های آموزش	۰/۹۷۷۹۵	۰/۰۶۶۱۱۹	۰/۰۰۷۲۱۶	۰/۰۸۴۹۴۷	Mpa	IB
داده‌های آزمون	۰/۹۲۵۷۲۳	۰/۱۲۶۹۳۳	۰/۰۲۳۵۵۱	۰/۱۵۳۴۶۳	Mpa	IB
داده‌های آموزش	۰/۹۳۲۹۹۹	۱۳۸۶/۸۸۲	۴۷۴۹۹۳۸	۲۱۷۹/۴۳۵	Mpa	MOE
داده‌های آزمون	۰/۹۷۸۲۳۵	۹۴۲/۱۴۸۱	۱۵۱۶۱۱۴	۱۲۳۱/۳۰۶	Mpa	MOE
داده‌های آموزش	۰/۹۹۱۸۲۸	۱/۵۷۴۱۱	۴/۰۸۵۵۶۰۳	۲/۰۲۱۲۸۸	Mpa	MOR
داده‌های آزمون	۰/۹۸۲۱۲۶	۲/۷۶۶۲۶۴	۱۰/۰۸۰۹۷	۳/۱۷۵۰۵۵	Mpa	MOR
داده‌های آموزش	۰/۹۴۰۹۹۷	۱/۴۲۵۱۹۵	۳/۱۵۵۷۴	۱/۷۷۶۴۴	%	TS _{2h}
داده‌های آزمون	۰/۹۱۳۳۲۴	۱/۵۰۰۴۸۲	۳/۱۸۳۱۸۱	۱/۷۸۴۱۴۷	%	TS _{2h}
داده‌های آموزش	۰/۹۶۷۳۶۶	۷/۷۲۷۰۸۸	۱۰/۲۰۷۹۶	۱۰/۱۰۳۴۵	%	TS _{24h}
داده‌های آزمون	۰/۹۷۵۰۵۲	۷/۵۵۹۸۰۶	۷۷/۰۷۵۸۴	۸/۷۷۹۲۸۵	%	TS _{24h}
داده‌های آموزش	۰/۹۴۰۹۹۷	۱/۴۲۵۱۹۵	۳/۱۵۵۷۴	۱/۷۷۶۴۴	%	WA _{2h}
داده‌های آزمون	۰/۹۱۳۳۲۴	۰/۵۰۰۴۸۲	۳/۱۸۳۱۸۱	۱/۷۸۴۱۴۷	%	WA _{2h}
داده‌های آموزش	۰/۹۴۷۶۱۵	۵/۲۳۱۸۱۸	۴/۹۲۲۶۷	۶/۹۲۲۶۲	%	WA _{24h}
داده‌های آزمون	۰/۹۱۳۵۸۶	۵/۵۸۴۳۹۹	۴۸/۳۵۱۳۹	۶/۹۵۳۵۱۶	%	WA _{24h}

درستی برای مجموعه داده آزمون که در آموزش شبکه استفاده نشده‌اند، تولید کند.

برای مدل‌های MOR، TS_{2h} و WA_{2h} مقادیر خطاهای RMSE، MSE و MAD در داده‌های آموزش و آزمون کمتر از مقدار ذکر شده است و مقادیر RMSE و MAD برای مدل‌های TS_{24h} و WA_{24h} نیز در داده‌های آموزش و آزمون خیلی کمتر از ۱۵٪ است. این بدان معنی است که شبکه‌ی GMDH را می‌توان به‌عنوان مناسب‌ترین روش برای به دست آوردن اطلاعات مقاومت‌های MOR، IB، TS_{24h}، TS_{2h}، WA_{2h} و WA_{24h} استفاده کرد. در جدول ۴ مقادیر RMSE، MSE و MAD برای مدل الاستیسیته بسیار زیاد است. با توجه به مقدارهای به‌دست آمده این مدل مناسب برای پیش‌بینی مدل الاستیسیته نیست.

با توجه به جدول ۴ مقادیر R^2 به‌دست آمده از مجموعه آزمون و آموزش برای خواص IB، MOR، MOE، TS_{24h}، TS_{2h}، WA_{2h} و WA_{24h} بیشتر از ۰/۹۱ درصد است و این بیانگر دقت و برازش مدل‌ها برای تعیین این خواص است. همان‌طور که در جدول ۴ مشاهده می‌شود مقادیر R^2 بیشتر به‌دست آمده از مجموعه آزمون و آموزش برای همه خواص فیزیکی و مکانیکی و مقادیر RMSE، MSE و MAD کمتر بیانگر کارایی بیشتر این مدل‌هاست. همان‌طور که ملاحظه می‌شود حداقل مقادیر خطاهای RMSE، MSE و MAD در داده‌های آموزش به ترتیب برابر ۰/۰۰۷، ۰/۰۸ و ۰/۰۶ و برای داده‌های آزمون ۰/۰۲، ۰/۱۵ و ۰/۱۲ است. مقادیر کمتر ذکر شده نشان‌دهنده این است که شبکه‌ی GMDH از پیش‌گویی خوبی برای تعیین IB برخوردار است و این شبکه به بهترین حالت به قابلیت تعمیم دست یافته است. قابلیت تعمیم شبکه به این معنا است که شبکه بتواند خروجی‌های

بحث

در این پژوهش بهترین نتایج با تعداد ۲ لایه مخفی به دست آمد، زیرا مشاهده شد که افزایش تعداد لایه‌های پنهان موجب کاهش محسوس خطای مدل‌سازی می‌گردد. ولی معادلات پیچیده‌تری را برای مدل‌های ساخته شده نتیجه می‌دهد که منجر به افزایش پیچیدگی‌های شبکه و کاهش کارایی معادلات می‌شود و در حالت کمتر از دو لایه پنهان نیز خطای شبکه بالاتر می‌رود. Nariman-zadeh و همکاران (۲۰۰۵) اعلام نمودند که تعداد نرون‌ها در لایه پنهان به تعداد ورودی‌های شبکه وابسته و شبکه کارا تر است که بتواند با تعداد نرون‌های کمتر خروجی را براساس ورودی مدل کند.

آماره‌ها نشان دادند که در بین مقادیر واقعی و پیش‌بینی شده این شاخص‌ها از لحاظ آماری اختلاف معنی‌داری وجود ندارد؛ بنابراین میانگین در محدوده متغیرهای ورودی بوده و داده‌ها در دسترس و به‌طور دقیق پیش‌بینی شده است که این تأکیدی بر توانایی مدل ارائه شده توسط شبکه GMDH در پیش‌بینی این شاخص‌ها براساس متغیرهای ورودی است. درصد R^2 برای خواص IB، MOR، WA_{24h} و WA_{2h} ، TS_{2h} ، TS_{24h} ، MOE بیشتر از ۰/۹۱ درصد می‌باشد که این بیانگر دقت مدل شبکه عصبی است. علاوه بر این، در مجموعه اعتبارسنجی مقادیر بالاتر از مقدار ۰/۷ درصد مطابق استاندارد (AENOR, 2001) ۲-۳۲۶-EN است. نتایج R^2 به دست آمده توسط شبکه‌ی GMDH با تحقیقات انجام شده با روش شبکه‌ی عصبی مصنوعی توسط دیگران در جهان مطابقت دارد (Yapici, et al., 2009؛ Fenandez, et al., 2008). با توجه به اینکه در ساخت تخته خرده چوب ۱۵٪ خطا قابل قبول در نظر گرفته می‌شود، بنابراین بیشتر از آن غیر قابل قبول می‌باشد (Cook, 1977؛ Chiu and ۱۹۷۷؛ Malinov, et al., 2001). از آنجایی که مدل MOE قادر به انجام پیش‌بینی با خطای زیاد است در نتیجه این مدل مناسب برای تعیین MOE نیست. اگرچه با داشتن تعداد پارامترهای ورودی بیشتر مرتبط با مقدار پارامتر مورد پیش‌بینی این امکان وجود دارد که بتوان به پاسخ‌های با دقت بیشتر دست یافت (Sha, 2007). اما ارائه ضریب تبیین بالا و میزان خطای پایین برای خواص IB، MOR، WA_{24h} ، WA_{2h} ، TS_{2h} ، TS_{24h} در این تحقیق تأییدی بر قابلیت و کارایی زیاد روش مدل‌سازی

GMDH در صنایع چوب است. در نهایت با روش‌های نوین مدل‌سازی می‌توان خواص فرآورده‌های چوبی را با انتخاب مناسب پارامترهای مؤثر و تعداد داده‌های زیاد، با نظر گرفتن کاهش هزینه و صرفه‌جویی در وقت پیش‌بینی نمود.

منابع مورد استفاده

- Avramidis, S. and Iliadis, L. 2005. Predicting wood thermal conductivity using artificial neural networks. Classification of wood species by neural network analysis of ultrasonic signals. Ultrasonic. 36: 219-222.
- Amanifard, N., Nariman-Zadeh, N., Borji, M., Khalkhali, A. and Habibdoust, A. 2007. Modelling and Pareto Optimization of Heat Transfer and Flow Coefficients in Microchannels Using GMDH Type Neural Networks and Genetic Algorithms, Energy Conversion and Management. 49: 311-325.
- Atashkari, K., Nariman-Zadeh, N., Golcu, M., Khalkhali, A. and Jamali, A. 2007. Modelling and Multi-Objective optimization of a Variable Valve-Timing Spark-Ignition Engine Using Polynomial Neural Networks and Evolutionary Algorithms, Energy Conversion and Management. 48(3) 1029-1041.
- Asociación Española De Normalización (AENOR), 2001. Tableros derivados de la madera. Determinación del contenido de humedad. Standard UNE-EN 322. Madrid, España.
- Cook, D.F., Whittaker, A.D. 1992. Neural network models for prediction of process parameters in wood products manufacturing. In: Proceedings of the 1st industrial engineering research conference. Chicago (IL), May, p. 209-11.
- Cook, D.F., Ragsdale, C.T., Major R.L. 2000. Combining a neural network with a genetic algorithm for process parameter optimization. Eng Appl Artif Intell 13, 391-396.
- Cook, D.E. and Chiu, C. C. 1997. Predicting the Internal Bond Strength of Particleboard, Utilizing a Radial Basis Function Neural Network. Engng Applic. Artif. Intell. 10(2): 171-177.
- Drake, P.R. and Packianather, M.S. 1998. A decision tree of neural networks for classifying images of wood veneer. Int Journal Adv Manuf Technol, 14: 280-285.
- Esteban, L.G., Fernandez, F.G., Palacios, P., and Rodrigo, B.G. 2010. Use of ANN as a predictive method to determine moisture resistance of particle and fiber boards under cyclic testing conditions. (UNE-EN 321) Wood and Fiber Science, 42(3): 1-11.
- EN 317. 1993. Particleboard and Fiberboards. Determination of Swelling in Thickness after Immersion in Water. European Committee for Standardization, Brussels, Belgium.
- EN 319. 1993. Determination of Tensile Strength Perpendicular to the Plane of the Board. European Committee for Standardization, Brussels, Belgium.
- EN 310. 1993. Wood Based Panels. "Determination of Modulus of Elasticity in Bending and Bending

- Jordan, R., Afeeney, F., Nesbitt, N., Evertsen, J.A. 1998. Classification of wood species by neural network, pp: 985.
- Krauss G, Kindangen JI, Depecker P. 1997. Using artificial neural networks to predict interior velocity coefficients. *Build Environ.* 32(4):295-303.
- Mier R., Garcia J.L., Diez M.R., Fernandez-Golfin J.I. and Hermosoe E. 2005. Aplicacion de redes neuronales a la clasificacion visual de madera estructural. Comparación con otros métodos de clasificación. IV Congreso Forestal Espanol, 26-30.
- Nariman-zadeh, N., A. Darvizeh, M. and Gharababaei, H. 2002. Modelling of Explosive Cutting Process of Plates Using GMDH Type Neural Network and Singular Value Decomposition *Journal of Materials Processing Technology.* 128 (1-3): 80- 87.
- Nirdosha, G. and Setunge, S. 2006. Formulation and process modeling of particleboard production using hardwood saw mill wastes using experimental design. *Composite Structures.* 75: 520-523.
- Suchsland, O., X. Hong. 1989. Model analysis of flakeboard variables. *Forest Prod. J.* 41(11/12):55-60.
- Yapici, F., Ozcifci, A., Akbulut, T. and Bayir, R. 2009. Determination of modulus of rupture and modulus of elasticity on flake board with fuzzy logic classifier. *Mater. Des.* 30: 2269-2273.
- Strength". European Committee for Standardization, Brussels, Belgium.
- Fernandez, G.F., Esteban L.G. DE., Palacios, P., Navarro, N. and Conde, M. 2008. Prediction of standard particleboard mechanical properties utilizing an artificial neural network and subsequent comparison with a multivariate regression model. *Invest. Agrar.Sist. Rec. For.* 17(2): 178-187.
- Fernandez, G.F., Esteban L.G. DE., Palacios, P. and Casaus GA. 2007. Use of an artificial neural network to differentiate the wood of *Juniperus cedrus* Webb & Bertel and *Juniperus. canariensis* Guyot. Pan-American IAWA Meeting 2007, San Luis Potosi, México, July 15-20.
- Hiassat, M., Abbod, M. and Mort, N. 2003. Using Genetic Programming to Improve the GMDH in Time Series Prediction, *Statistical Data Mining and Knowledge Discovery*, Edited by Hamparsum Bozdogan, Chapman and Hall CRC, PP. 257-268.
- Halligan, A.F., and Schniewind, A.P. 1974. Prediction of particleboard mechanical properties at various moisture contents. *Wood Science Technology.* 8(1): 68-78.
- Ivakhnenko, A.G. 1971. Polynomial Theory of Complex Systems. *IEEE Transactions on Systems, Man, and Cybernetics.* 364-378.

A mathematical model to predict particleboard properties using the GMDH-type neural network and genetic algorithm

Z. Jahaniomer^{1*}, S.R. FarrokhPayam² and M. Shamsian²

1*- Corresponding author, M.Sc., Department of Wood and Paper Science &Technology, Faculty of Natural Resources, University of Zabol, Iran, Email:zahrajahani12@yahoo.com

2-Assistant Professor, Department of Wood and Paper science &Technology, Faculty of Natural Resources, University of Zabol, Iran

Received: Sep., 2013

Accepted: June, 2014

Abstract

In this study, GMDH neural network based on genetic algorithm was used to predict the physical and mechanical properties of laboratory made particleboard. To predict the mechanical and physical properties of particleboard we used input parameters such as neural network including press closing time (10,20 and 30 seconds), moisture content of the mat (8,10,12 and 14%) and press temperature (150,160,170 and 180°C) as the input data and the output data was the physical and mechanical properties. The efficiency of these techniques was evaluated with statistical criteria of mean square error (MSE), root mean square error, (RMSE), mean absolute deviation (MAD) and the correlation coefficient (R^2). Results showed that the value of MSE, RMSE and MAD for MOR, IB, TS_{24h} , TS_{2h} , WA_{2h} and WA_{24h} is low. Errors obtained for the MOE model were very high. According to the results obtained, this model is not the appropriate for prediction of MOE. R^2 values from the test and training set properties for MOR, IB, MOE, TS_{24h} , TS_{2h} , WA_{2h} and WA_{24h} was more than 0.91%, which reflects that the performance of these models is better.

Key words: Particleboard, modeling, GMDH-type neural network, physical mechanical properties.