

## تخمین نفت زیستی حاصل از پیرولیز مواد زائد: رویکرد شبکه عصبی

محمدحسین آق‌خانی

استاد گروه مکانیک بیوسیستم، دانشگاه فردوسی مشهد  
aghkhani@um.ac.ir

محمدعلی ابراهیمی نیک

استادیار گروه مکانیک بیوسیستم، دانشگاه فردوسی مشهد  
ebrahimi-nik@um.ac.ir

آرمان شاه‌نظری

دانشجوی کارشناسی ارشد مکانیزاسیون - بازیافت و مدیریت  
پسماند، دانشگاه فردوسی مشهد  
arman.shahnazarikarbasaraei@mail.um.ac.ir

عباس روحانی

استادیار گروه مکانیک بیوسیستم  
دانشگاه فردوسی مشهد (نویسنده مسئول)  
arohani@um.ac.ir

هدف این مطالعه، تخمین نفت زیستی حاصل از فرایند پیرولیز مواد زائد بر حسب رطوبت، کربن ثابت، مواد فرار و خاکستر است. از نتایج آزمایشگاهی ۴۱ مطالعه مختلف برای مدل‌سازی استفاده شد. از مدل شبکه عصبی به عنوان یک ابزار سیاست‌گذاری در ارزیابی و پیش‌بینی مقدار درصد نفت زیستی حاصل از مواد زائد طی فرایند پیرولیز استفاده شد. مقادیر بهینه پارامترهای شبکه عصبی به روش آماری تخمین زده شد. نتایج مقایسات در دو شبکه عصبی پرسپترون چند لایه و شبکه عصبی تابع شعاعی نشان داد که شبکه عصبی تابع شعاعی دارای توانایی بیشتری در تخمین نفت زیستی می‌باشد. مقدار ضریب تبیین بین درصد نفت زیستی برآورد شده توسط شبکه عصبی تابع شعاعی و مقدار آزمایشگاهی آنها برابر با ۰/۹۹ شد. نتایج ارزیابی شبکه عصبی نشان داد که آن را می‌توان به عنوان یک ابزار در برآورد درصد تولید نفت زیستی به کار برد و از آن در تصمیم‌گیری‌های مدیریتی تولید نفت زیستی بهره برد.

**واژگان کلیدی:** شبکه عصبی، نفت زیستی، مواد زائد، پرسپترون چند لایه، تابع شعاعی

## ۱. مقدمه

دفع مواد زائد یکی از معضلات اساسی در جوامع بشری امروزی می‌باشد. این مواد، آلودگی‌های زیست‌محیطی را در پی دارند. تبدیل مواد زائد به عنوان یک راه کار سیاست‌گذاری در جهت دستیابی به مواد با ارزش‌تر و حفظ محیط‌زیست می‌باشد. مواد زائد را می‌توان از طریق فرایندهای بیوشیمیایی و ترموشیمیایی به سوخت‌های زیستی و سایر مواد با ارزش تبدیل نمود (شارما و همکاران<sup>۱</sup>، ۲۰۱۵). فرایندهای بیوشیمیایی شامل کمپوست، بیوگاز (هضم بی‌هوازی) و دفن ضایعات می‌باشند. همچنین فرایندهای ترموشیمیایی عبارتند از احتراق مستقیم (زباله‌سوز)، پیرولیز (گرماکافت)، گازیفیکاسیون و پلاسما (عبدالله‌زاده و همکاران، ۱۳۸۹). پیرولیز یک فرایند احتراق جزئی است که در دماهای متوسط و در غیاب اکسیژن (هوا) صورت می‌گیرد (شفیعی، ۱۳۹۴). محصولات این فرایند شامل سه فاز جامد (زغال)، مایع (نفت زیستی) و گاز ( $CO$ ،  $CO_2$ ،  $H_2$ ،  $CH_4$ ) می‌باشند (ابراهیمی‌نیک و همکاران، ۱۳۹۲). مطابق نرخ دمایی فرایند پیرولیز، دو فرایند آهسته (کند) و سریع وجود دارند. در صورتی که زمان مورد نیاز جهت گرم کردن مواد زائد تا درجه حرارت پیرولیز نسبت به زمان تعیین شده برای واکنش پیرولیز بیشتر باشد، فرایند پیرولیز را آهسته می‌نامند (بناجی<sup>۲</sup>، ۲۰۱۴). در پیرولیز سریع، مدت زمان واکنش کمتر از دو ثانیه است. این فرایند در چند سال اخیر بسیار مورد توجه سیاست‌گذاران بخش انرژی جهت تولید نفت زیستی قرار گرفته است. بنابراین در این تحقیق مدل سازی فرایند تولید نفت زیستی بر حسب ویژگی‌های مواد زائد مورد توجه قرار گرفته شده است.

1. sharma et al.
2. Bennadji et al.

ابراهیمی نیک و همکاران (۱۳۹۲) به کمک فرایند پیرولیز سریع، توانستند از بقایای ذرت و اکالیپتوس در یک راکتور بستر سیال، نفت زیستی تولید کنند. نتایج آن‌ها نشان داد که بیشترین مقدار نفت زیستی تولید شده مربوط به چوب اکالیپتوس با ۷۲/۴٪ می‌باشد. نتایج پژوهشی دیگر نشان داد که می‌توان ۳۵/۴٪ نفت زیستی را از لجن فاضلاب در یک راکتور بستر سیال طی فرایند پیرولیز تولید کرد (ارازو و همکاران<sup>۱</sup>، ۲۰۱۷). نتایج خان و همکاران نشان داد که می‌توان از ضایعات پلاستیکی HDPE، ۷۷/۰۳٪ نفت زیستی را طی فرایند پیرولیز تولید کرد (خان و همکاران<sup>۲</sup>، ۲۰۱۶). تحقیقات دیگری نیز در زمینه ارزیابی تولید نفت زیستی از مواد زائد انجام شده است. نتایج آن‌ها نشان می‌دهد که مقدار درصد نفت زیستی تولید شده وابسته به ویژگی مواد زائد است. بنابراین می‌توان به کمک مدل شبکه عصبی به عنوان یکی از روش‌های محاسبات نرم در این زمینه استفاده کرد. شبکه عصبی به عنوان یک گزینه مدل‌سازی در بخش‌های مختلف تولید انرژی استفاده شده است که به تعدادی از آنها اشاره می‌شود.

اخیراً مدل‌سازی در زمینه انرژی وسعت زیادی به خود گرفته است. کاظم و فرزانه (۱۳۹۲)، مدلی را به منظور بازیافت انرژی جهت تولید توان بهینه از گاز متان رقیق در معدن زغالسنگ طبس ارائه دادند. شریفیان و رضایی دولت آبادی (۱۳۹۵) نیز مدلی جهت اولویت‌بندی پشیران‌های انرژی‌های نو به کمک رویکرد ترکیبی دلفی، دیمتل و فرایند تحلیل شبکه‌ای - فازی پیشنهاد دادند. بونیکی و همکاران به کمک شبکه عصبی مدلی برای انتشار آمونیاک از فرایند کمپوست لجن فاضلاب ارائه دادند. مدل ارائه شده با پارامترهای فیزیکی و شیمیایی، قادر به پیش‌بینی انتشار آمونیاک با ضریب همبستگی ۰/۹۸ بود (بونیکی و همکاران<sup>۳</sup>، ۲۰۰۲). نتایج آن‌ها نشان داد که پیش‌بینی شبکه عصبی در توصیف انتشار گاز آمونیاک در

1. Arazo et al.
2. Khan et al.
3. Boniecki et al.

کمپوست کارا می‌باشد و PH و نسبت کربن به نیتروژن بیشترین تأثیر را بر انتشار گاز آمونیاک دارند. میکولندریک و همکاران برای مدل سازی فرایند گازیفیکاسیون از زیست توده در گازیفایر بستر ثابت از شبکه عصبی بهره بردند (میکولندریک و همکاران، ۲۰۱۴). نتیجه آنها نشان داد که مدل شبکه عصبی قادر به تخمین پارامترهای فرایند گازیفیکاسیون زیست توده با همبستگی قابل قبول می‌باشد. لیک و همکاران توانایی شبکه عصبی را با روش رگرسیون خطی چند گانه جهت مدل سازی غیر خطی اکولوژیکی مقایسه کردند (لک و همکاران، ۱۹۹۶). نتایج آنها نشان داد که شبکه عصبی بهتر از مدل رگرسیون خطی چند گانه عمل می‌کند.

پیری و همکاران (۱۳۹۵) در تحقیق خود نشان دادند که شبکه عصبی مصنوعی می‌تواند به شکل کارآ، اثر حضور اکسیژن در فرایند گرماکافت ضایعات چوبی را مدل سازی نماید.

نتایج تحقیقات مختلف نشان داد که مقدار نفت زیستی حاصل از مواد زائد در طی فرایند پیرولیز متأثر از چهار عامل کربن ثابت، مواد فرار، رطوبت و خاکستر است (اسداله و همکاران، ۲۰۰۸؛ سوتیباک<sup>۳</sup>، ۲۰۱۳؛ رازاکو<sup>۴</sup>، ۲۰۱۶؛ بوتنگ و همکاران<sup>۵</sup>، ۲۰۰۷). وجود یک ابزار جهت تصمیم‌گیری و سیاست‌گذاری در زمینه تولید نفت زیستی از مواد زائد مختلف ضروری به نظر می‌رسد. اما براساس اطلاعات موجود و دردسترس تقریباً هیچ مدل و رابطه‌ای جهت تخمین مقدار نفت زیستی از مواد زائد وجود ندارد که بتوان به کمک آن قبل از به کارگیری مواد زائد در مورد مقدار نفت زیستی حاصل از آن قضاوت نمود. بنابراین هدف از این تحقیق یافتن رابطه بین متغیرهای مؤثر بر تولید نفت زیستی شامل کربن ثابت، رطوبت، خاکستر و مواد فرار می‌باشد. به منظور رسیدن به این هدف از روش شبکه عصبی مصنوعی استفاده شد.

1. Lek et al.
2. Asadullah et al
3. Suttibak
4. Razaque
5. Boateng et al.

## ۲. روش تحقیق

به منظور ساختن مدل شبکه عصبی مصنوعی و آموزش آن، از نتایج ۴۱ آزمایش تجربی در مطالعات مختلف استفاده شد. منابع مورد استفاده و تعداد داده‌های استفاده شده از هر منبع در جدول ۱ نشان داده شده است. به طور مثال نتایج تحقیق السالم و همکاران نشان داد که پیرولیز مواد زائد با مشخصات کربن ثابت ۱/۵۵ درصد، مواد فرار ۹۹/۲۲ درصد، رطوبت صفر درصد و خاکستر ۱/۱۴ درصد منجر به تولید ۷۴ درصد نفت زیستی خواهد شد (السالم و همکاران<sup>۱</sup>، ۲۰۱۷).

جدول ۱. منابع و تعداد داده‌های مورد استفاده در این تحقیق

تعداد داده	منبع مورد استفاده	تعداد داده	منبع مورد استفاده	تعداد داده	منبع مورد استفاده
۲	Abnisa et al	۱	Araza et al	۱	Boateng et al
۴	Çepeliogullar et al	۲	Ahmad et al	۱	Razzaque
۵	Al-Salem	۲	Sajdak et al	۱	Suttibak
۱۶	Sharuddin	۲	Supramono et al	۱	Asadullah et al
		۲	Jiang et al	۱	Abnisa et al

مأخذ: نتایج تحقیق

در جدول ۲ برخی ویژگی‌های آماری مجموعه داده‌های جمع آوری شده نشان داده شده است. همچنین نوع متغیر و استفاده آن در مدل آورده شده است. به ترتیب، متغیرهای ورودی و خروجی نماینده متغیرهای مستقل و وابسته در مدل سازی می‌باشند. همان‌طور که ملاحظه می‌شود، دامنه تغییرات نفت زیستی تولید شده از فرایند پیرولیز از ۲ تا ۹۷ درصد متغیر است، لذا می‌توان انتظار داشت که مدل استخراج شده بتواند دامنه تغییرات نفت زیستی را پوشش دهد.

1. Al-Salem et al.


جدول ۲. ویژگی‌های آماری مجموعه داده‌های جمع‌آوری شده

نوع متغیر در مدل	ورودی	ورودی	ورودی	ورودی	خروجی
کمینه	۰/۰۰	۰/۰۰	۲۹/۶۲	۰/۰۰	۲
بیشینه	۱۵/۳۶	۶۷/۹۹	۹۹/۹۰	۲۲/۱۰	۹۷
میانگین	۲/۸۲	۴/۲۲	۸۶/۲۷	۶/۹۵	۴۸/۹۹
انحراف معیار	۴/۳۷	۱۱/۰۸	۱۵/۴۵	۷/۶۸	۲۹/۷۹

مأخذ: نتایج تحقیق

## - شبکه عصبی مصنوعی MLP و RBF

شبکه عصبی برنامه محاسباتی ساده‌ای جهت آزمون داده‌ها و ایجاد یک مدل جدید از ساختار داده‌ها می‌باشند. شبکه عصبی مصنوعی از چندین لایه و هر کدام از لایه‌ها از اجزای کوچک‌تری به نام نرون تشکیل شده‌اند (سلیمانی و همکاران، ۱۳۹۵). شبکه عصبی RBF از سه لایه تشکیل شده است (شکل ۱). لایه اول را لایه ورودی‌ها می‌گویند که در برگیرنده متغیرهای مستقل است. لایه دوم را لایه مخفی می‌نامند که نرون‌ها در این لایه قرار دارند و لایه سوم، لایه خروجی است که نماینده متغیر وابسته مدل می‌باشد.



شکل ۱. ساختار شبکه عصبی RBF استفاده شده در این مطالعه

نوع تابع فعال ساز نرون‌های لایه مخفی گوسی و تابع خطی ساده در لایه خروجی استفاده می‌شود. شبکه RBF فضای ورودی را به یک فضای جدید نگاشت می‌کند. بدین مفهوم که ترکیب خطی از وزن‌های لایه مخفی و ورودی به عنوان خروجی نشان می‌دهد و مطابق رابطه (۱) محاسبه می‌شود.

$$B = \sum_{i=1}^{L_2} w_i \phi(\|x - c_i\|_2) \quad (1)$$

که در آن  $x$  بردار ورودی که مقادیر ویژگی‌های مواد زائد است،  $B$  خروجی مدل و نشان دهنده مقدار نفت زیستی می‌باشد،  $\phi(\cdot)$  تابع پایه،  $\|\cdot\|$  نرم اقلیدسی،  $w_i$  وزن لایه خروجی،  $L_2$  تعداد نرون‌ها یا مراکزها در لایه مخفی و  $c_i$  مراکز RBF در فضای بردار ورودی است. رابطه (۱) را می‌توان به شکل رابطه (۲) نیز بازنویسی کرد.

$$B = \phi^T(x)w \quad (2)$$

خروجی نرون‌ها در لایه مخفی از رابطه غیر خطی (۳) قابل محاسبه است.

$$\phi(x) = e^{-\frac{x^2}{s^2}} \quad (3)$$

که در آن  $s$  پارامتر گسترده‌گی شبکه عصبی RBF می‌باشد.

در این پژوهش از مدل شبکه عصبی پرسپترون چند لایه (MLP) نیز به عنوان یک جایگزین دیگر برای تخمین درصد نفت زیستی بر حسب ویژگی‌های مواد زائد استفاده شد. ساختار MLP تا حدود زیادی شبیه RBF است. در این پژوهش از دو نوع تابع فعال ساز نرون‌ها در لایه مخفی شامل  $\text{logsig}$  (رابطه ۴) و  $\text{tansig}$  (رابطه ۵) استفاده شد.

$$f(\theta) = \frac{1}{1 + e^{-\theta}} \quad (4)$$

$$f(\theta) = \frac{2}{1 + e^{-2\theta}} - 1 \quad (5)$$

که در آن  $\theta$  مجموع وزنی ورودی‌ها به نرونهای لایه مخفی است.

در طول مرحله آموزش، وزن‌های شبکه MLP به کمک رابطه ۶ به روز رسانی می‌شوند.

$$w(n+1) = w(n) - \eta \times \frac{\partial E}{\partial w} \quad (6)$$

که در آن  $w$  وزن‌های شبکه،  $n$  شماره تکرار آموزش،  $E$  خطا و  $\eta$  آهنگ یادگیری شبکه می‌باشد. آموزش شبکه تا جایی ادامه می‌یابد که تغییرات وزن‌های شبکه محسوس نباشد.

برای آموزش شبکه عصبی RBF و MLP از سیزده الگوریتم آموزش مختلف جهت بهینه‌یابی وزن‌های شبکه استفاده شد (جدول ۳). برای آموزش شبکه از ۸۰ درصد تصادفی داده‌ها استفاده شد. اما از آنجا که هر بار انتخاب تصادفی منجر به مقادیر مختلفی از وزن‌های شبکه می‌شود. بنابراین ما در این تحقیق از روش  $k$ -fold برای  $k=5$  و با ۴ تکرار استفاده شد. بدین ترتیب که ۲۰ مجموعه داده مختلف برای آموزش و تست شبکه تولید شد.

جدول ۳. الگوریتم‌های آموزش مورد استفاده در شبکه‌های عصبی RBF و MLP

نوع الگوریتم آموزش	تابع استفاده شده در متلب	نشانه
Levenberg–Marquardt backpropagation	Trainlm	T1
Bayesian regularization	Trainbr	T2
Scaled conjugate gradient backpropagation	Trainscg	T3
Resilient backpropagation (Rprop)	Trainrp	T4
Variable learning rate backpropagation	Trainidx	T5
Gradient descent with momentum backpropagation	Traingdm	T6
gradient descent with adaptive learning rate backpropagation	Traingda	T7
Gradient descent backpropagation	Traingd	T8
BFGS quasi-Newton backpropagation	Trainbfg	T9
Powell–Beale conjugate gradient backpropagation	Traincgb	T10
Fletcher–Powell conjugate gradient backpropagation	Traincgf	T11
Polak–Ribiere conjugate gradient backpropagation	Traincgp	T12
One step secant backpropagation	Trainoss	T13

مأخذ: نتایج تحقیق



برای ارزیابی عملکرد شبکه عصبی در مرحله آموزش و تست از معیارهای RMSE، MAPE و ضریب همبستگی بین مقادیر آزمایشگاهی و پیش‌بینی شده ( $R^2$ ) استفاده شد.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{B_d - B_p}{B_d} \right| \times 100 \quad (۴)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (B_d - B_p)^2}{n}} \quad (۵)$$

که در آن،  $B_d$  و  $B_p$  به ترتیب مقادیر واقعی و پیش‌بینی شده از مقدار نفت زیستی حاصل از فرایند پیرولیز می‌باشد. بهترین مدل زمانی است که مقادیر خطا کمترین مقدار و ضریب همبستگی بیشترین مقدار را داشته باشد. برای مقایسه و انتخاب بهترین الگوریتم آموزش از بین ۱۳ الگوریتم آموزش از روش طرح آزمایشی بلوک‌های کامل تصادفی استفاده شد. همچنین برای تجزیه واریانس (ANOVA) از ضریب همبستگی به عنوان معیار عملکردی الگوریتم‌ها استفاده شد. برای مقایسه آماری میانگین عملکردهای الگوریتم‌های آموزشی از روش حداقل مربعات (LSD) استفاده شد. مقدار ۰/۰۵ به عنوان حد بحرانی مقدار p-value در نظر گرفته شد.

### ۳. نتایج و بحث

در ابتدا رابطه بین متغیرها براساس معیار همبستگی بررسی می‌شود. سپس به کمک شبکه عصبی رابطه بین عناصر تشکیل دهنده مواد زائد و درصد نفت زیستی حاصل از آن به روش پیرولیز برآورد می‌شود.

#### ۳-۱ همبستگی بین متغیرها

در جدول ۴ مقادیر همبستگی بین عناصر تشکیل دهنده مواد زائد و مقدار درصد نفت زیستی حاصل از آن و نتیجه معنی داری آنها آورده شده است. همان‌طور که ملاحظه می‌شود، رابطه همبستگی معنی داری بین متغیرهای مستقل (عناصر تشکیل دهنده مواد زائد) و متغیر وابسته

(درصد نفت زیستی) وجود دارد. بنابراین می‌توان رابطه یا مدلی بین متغیرهای مستقل و وابسته ایجاد کرد. در این مطالعه از روش شبکه عصبی برای به‌دست آوردن رابطه مورد نظر استفاده شد.

#### جدول ۴. همبستگی بین عناصر تشکیل دهنده مواد زائد و نفت زیستی


رطوبت	خاکستر	مواد فرار	کربن ثابت
خاکستر	۰/۰۱۴ <sup>NS</sup>		
مواد فرار	-۰/۳۴۴*	-۰/۵۶۹**	
کربن ثابت	۰/۵۴۴*	۰/۰۶۳ <sup>NS</sup>	-۰/۴۳۸**
نفت‌زیستی	-۰/۴۲۲*	-۰/۳۲۵*	۰/۴۶۴**
			-۰/۳۹۵*

\*\*\*, \*\* به ترتیب معنی داری در سطح یک و پنج درصد

مأخذ: نتایج تحقیق

### ۲-۳ بهینه‌یابی پارامترهای شبکه عصبی RBF

پارامتر گستردگی و توپولوژی، دو عامل مهم در عملکرد تخمینی مدل RBF هستند. به کمک طرح فاکتوریل مجموعه‌ای از ترکیب‌های مختلف از این دو پارامتر ایجاد شد. نتیجه به کارگیری آنها در مدل RBF بر حسب ضریب تبیین ( $R^2$ ) بین مقادیر آزمایشگاهی و پیش‌بینی شده در شکل ۲ نشان داده شده است. همان‌طور که نتایج نشان می‌دهد، دو پارامتر مذکور دارای اثرات متقابل بر  $R^2$  شبکه هستند. نتایج موید آن است که هر چه تعداد نرون‌ها بیشتر می‌شود، ضریب تبیین برای مقادیر پارامتر گستردگی در دامنه ۰/۵ تا ۲/۵۰ بیشترین مقدار به‌دست می‌آید. بیشترین مقدار  $R^2$  برای تعداد نرون ۱۱ و مقدار ۱/۸۵ برای پارامتر گستردگی به‌دست آمد.



شکل ۲. تغییرات  $R^2$  شبکه RBF بر حسب دو عامل تعداد نرون‌ها در لایه مخفی ( $L_2$ ) و مقادیر پارامتر گستردگی (s)


نوع الگوریتم آموزش نیز یکی دیگر از پارامترهای بسیار مؤثر بر عملکرد تخمینی شبکه عصبی RBF در سه مرحله کاری شبکه شامل آموزش، تست و کل می‌باشد. در این مطالعه از ۱۳ نوع الگوریتم رایج در آموزش شبکه عصبی RBF استفاده شد. برای مقایسه عملکرد الگوریتم‌های آموزش از طرح آزمایشی بلوک‌های کامل تصادفی استفاده شد. به ترتیب الگوریتم‌های آموزشی و مجموعه داده‌های مختلف نشان دهنده تیمارها و بلوک‌های آزمایشی هستند. از آنجا که عملکرد شبکه وابسته به مجموعه داده‌های استفاده شده در مرحله آموزش است. به کمک روش  $k$ -fold cross validation به ازای  $k=5$  با ۴ تکرار، بیست مجموعه داده مختلف برای آموزش و تست شبکه تولید شد. به منظور افزایش دقت مقایسه الگوریتم‌های آموزش به روش طرح آزمایشی از مجموعه داده‌ها به عنوان بلوک استفاده شد. نتیجه تجزیه واریانس ضریب تبیین برای سه مرحله آموزش، تست و کل شبکه با استفاده از ۱۳ الگوریتم آموزش و ۲۰ مجموعه داده مختلف در جدول ۵ آورده شده است. همان‌طور که نتایج معنی داری نشان می‌دهد، P-value در تمام موارد کمتر از ۰/۰۱ شده است. بنابراین اثر نوع الگوریتم آموزش و مجموعه داده‌ها در هر سه مرحله در سطح یک درصد معنی دار شده است.

جدول ۵. نتیجه تجزیه واریانس  $R^2$  الگوریتم‌های آموزش RBF در قالب طرح بلوک‌های کامل تصادفی

کل		تست		آموزش				
p-value	MS	p-value	MS	p-value	MS	DF	منبع تغییرات	
۰/۰۰	۰/۹۱	۰/۰۰	۰/۹۱	۰/۰۰	۱/۲۲	۱۲	الگوریتم آموزش (تیمار)	
۰/۰۰	۰/۱۶	۰/۰۰	۰/۴۴	۰/۰۰	۰/۱۴	۱۹	مجموعه داده‌ها (بلوک آزمایشی)	
						۲۲۸	خطا	
						۲۵۹	کل	

مأخذ: نتایج تحقیق

در شکل ۳ (a)، (b) و (c) نتیجه مقایسه عملکرد الگوریتم‌های آموزشی بر حسب  $R^2$  به روش حداقل اختلاف معنی دار (LSD) آورده شده است. الگوریتم‌هایی که با حروف مشترک مشخص شده‌اند، اختلاف معنی داری با یکدیگر ندارند. همان‌طور که نتایج نشان می‌دهد، عملکرد الگوریتم‌های آموزشی در سه مرحله آموزش، تست و کل متفاوت از یکدیگر هستند. به طور مثال، الگوریتم‌های آموزشی T1 و T2 در مرحله آموزش با یکدیگر اختلاف معنی داری ندارند ولی در مرحله تست با یکدیگر اختلاف معنی داری دارند. در مقابل، مقایسه T2 و T3 نشان داد که این دو الگوریتم در مرحله آموزش با هم اختلاف معنی داری دارند ولی در مرحله تست با هم اختلاف معنی داری ندارند. در حالت کلی، از بین سیزده الگوریتم تنها الگوریتم آموزش trainbr با اختلاف معنی داری نسبت به بقیه عملکرد بهتری در هر سه مرحله داشت، بنابراین از آن برای آموزش و ساخت شبکه RBF استفاده شد.



شکل ۳. مقایسه عملکرد الگوریتم‌های آموزشی ( $R^2$ ) به روش LSD

برای سه مرحله آموزش (a)، تست (b) و کل (c)

### ۳-۳ بهینه یابی پارامترهای شبکه عصبی MLP

تعداد لایه‌های مخفی، تعداد نرون‌ها در لایه مخفی، نوع تابع فعال ساز نرون‌ها در لایه مخفی و نوع الگوریتم آموزش فاکتورهای مهم در مدلسازی به کمک شبکه عصبی MLP می‌باشد. مشابه روش به کاررفته در بهینه یابی شبکه RBF برای پیدا کردن شبکه عصبی MLP نیز استفاده شد. نتایج طرح آزمایشی مقایسه میانگین ضریب تبیین ۱۳ نوع الگوریتم آموزشی نشان داد که

trainlm بهترین نوع روش آموزش MLP است. همچنین نتایج ما نشان داد که MLP با یک لایه مخفی و ۱۵ نرون در آن بهترین نتیجه را می‌تواند به وجود آورد. به علاوه نوع تابع فعال‌ساز tansig به عنوان مناسب‌ترین تابع در نرون‌های لایه مخفی استفاده شد.

### ۳-۴. ارزیابی و مقایسه مدل‌های شبکه عصبی MLP و RBF

در مراحل قبلی مقدار بهینه پارامتر گسترده‌گی، تعداد نرون‌ها در لایه مخفی و نیز نوع الگوریتم آموزش برای هر دو نوع شبکه عصبی MLP و RBF پیدا شد. در جدول ۶، مقادیر میانگین و انحراف معیار شاخص‌های عملکردی مدل‌های MLP و RBF شامل RMSE، MAPE و  $R^2$  برای اندازه ۸۰ درصد مجموعه آموزش آورده شده است. همان‌طور که قبلاً نتایج نشان داد، نوع مجموعه آموزش اثر معنی‌داری بر عملکردی شبکه عصبی دارد. یعنی عملکرد شبکه در مرحله آموزش و تست وابسته به نوع مجموعه داده‌هایی است که در مرحله آموزش شبکه عصبی استفاده می‌شود. علاوه بر این، اندازه مجموعه آموزش نیز عامل تأثیرگذار دیگر است. در صورتی که شبکه عصبی بتواند عملکرد خوبی با اندازه کوچک‌تر از مجموعه داده‌های آموزش داشته باشد، آنگاه شبکه از ویژگی تعمیم‌پذیری خوبی برخوردار است. همان‌طور که نتایج نشان می‌دهد، متوسط و بهترین نتیجه عملکردی شبکه عصبی RBF بهتر از MLP شده است. ضعیف بودن عملکرد MLP در مقایسه با RBF می‌تواند به سبب ناکافی بودن مجموعه داده‌های آموزش و نیز وابستگی آن به مقادیر وزن‌های تصادفی اولیه در شروع آموزش باشد. مقدار ضریب تبیین بین مقادیر آزمایشگاهی و پیش‌بینی شده توسط شبکه عصبی در هر دو مرحله آموزش و تست RBF برابر با ۰/۹۹ شده است، ولی این مقدار برای مدل MLP برابر با حدود ۰/۸۵ شده است. پایین بودن مقدار انحراف معیار شاخص‌های عملکردی RBF در مقایسه با MLP نشان می‌دهد که مدل RBF پایدارتر از MLP است. لذا می‌توان بیان نمود که RBF بهتر از MLP قادر به پیش‌بینی نفت زیستی بر حسب متغیرهای مستقل (ویژگی‌های مواد زائد) می‌باشد. بنابراین در ادامه تنها به آوردن نتایج شبکه عصبی RBF اکتفا خواهیم کرد.

جدول ۶. متوسط و انحراف معیار عملکرد شبکه‌های عصبی RBF و MLP

نوع مدل		آموزش			تست		
		RMSE	MAPE	R <sup>2</sup>	RMSE	MAPE	R <sup>2</sup>
RBF	$\bar{x} \pm std$	۷/۸۴±۳/۶۸	۱۶/۴۶±۱۹/۲۹	۰/۹۱±۰/۰۷	۷/۴۴±۶/۷۶	۲۳/۷۷±۴۲/۷۵	۰/۸۸±۰/۱۶
	بهترین نتیجه	۰/۸۵	۰/۵۰	۰/۹۹	۱/۹۳	۱/۳۶	۰/۹۹
MLP	$\bar{x} \pm std$	۱۲/۲۵±۱۰/۱۲	۳۸/۲۴±۲۱/۱۱	۰/۸۸±۰/۲۱	۲۱/۴۵±۱۲/۲۱	۴۰/۰۳±۳۰/۲۱	۰/۷۶±۰/۵۶
	بهترین نتیجه	۵/۳۴	۴۰/۱۲	۰/۸۵	۵/۹۵	۴۱/۷۱	۰/۸۴

مأخذ: نتایج تحقیق

در جدول ۷، مقادیر میانگین، واریانس، چولگی و کشیدگی دو مجموعه داده آزمایشگاهی و پیش‌بینی شده نفت زیستی توسط مدل RBF آورده شده است. همچنین نتیجه وجود اختلاف معنی دار از لحاظ مقادیر میانگین، واریانس و توزیع آماری دو مجموعه داده آزمایشگاهی و پیش‌بینی شده در دو مرحله آموزش و تست نشان داده شده است. فرض صفر دلالت بر مشابه بودن دو مجموعه داده از لحاظ میانگین، واریانس و توزیع آماری دارد. نتایج نشان می‌دهد که اختلاف معنی داری بین میانگین، واریانس و توزیع آماری دو مجموعه داده آزمایشگاهی و پیش‌بینی شده نفت زیستی توسط مدل RBF وجود ندارد. بنابراین شبکه عصبی RBF قادر به تولید مجموعه داده‌های پیش‌بینی شده با حداکثر شباهت و بدون اختلاف معنی دار در سطح معنی داری یک درصد با مجموعه داده‌های آزمایشگاهی شد.

## جدول ۷. مقایسه مقادیر برخی پارامترهای آمار توصیفی

## مقادیر آزمایشگاهی و پیش‌بینی شده توسط RBF


مرحله	میانگین	p-value	واریانس	p-value	کشیدگی	چولگی	p-value
آموزش	Ev	۴۴/۰۲	۷۸۴/۰۲	۰/۹۹	۱/۸۱	۰/۰۶	۰/۹۹
	Pv	۴۴/۰۱	۷۷۸/۷۹	۰/۹۹	۱/۷۵	۰/۰۳	۰/۹۹
تست	Ev	۶۹/۵۲	۸۸۹/۸۶	۰/۹۹	۳/۹۳	-۱/۴۷	۰/۹۹
	Pv	۶۹/۵۶	۹۰۴/۶۰	۰/۹۹	۳/۸۴	-۱/۴۱	۰/۹۹

Ev و Pv به ترتیب مقادیر آزمایشگاهی و پیش‌بینی شده نفت زیستی توسط مدل

مأخذ: نتایج تحقیق

در شکل ۴، پراکنندگی و چگونگی توافق دو مجموعه داده آزمایشگاهی و پیش‌بینی شده توسط مدل RBF برای اندازه ۸۰ درصد آموزش شبکه نشان می‌دهد. همان‌طور که نتایج نشان می‌دهد، توافق و همبستگی بسیار خوبی بین دو مجموعه داده وجود دارد. زیرا در دو مرحله آموزش و تست، ضریب تبیین برابر با ۰/۹۹ شده است و نیز به ترتیب شیب و عرض از مبدا خط مابین دو مجموعه داده نزدیک به یک و نزدیک به صفر است.





شکل ۴. پراکندگی مقادیر آزمایشگاهی درصد نفت زیستی و پیش‌بینی شده توسط RBF

### ۳-۵ تحلیل حساسیت

نتیجه تحلیل حساسیت متغیرهای مستقل شامل عناصر تشکیل دهنده مواد زائد بر تخمین مقدار درصد نفت زیستی به کمک مدل RBF در جدول ۸ آورده شده است. در تحلیل حساسیت می‌توان تأثیر هر یک از متغیرهای مستقل بر متغیر خروجی مدل بررسی کرد. اگر حذف هر یک از متغیرها از مجموعه متغیرهای ورودی باعث کاهش بیشتر در عملکرد مدل شود آنگاه آن متغیر تأثیر بیشتر بر تخمین متغیر خروجی خواهد داشت. نتایج تحلیل حساسیت نشان می‌دهد که به ترتیب عناصر تشکیل دهنده آنالیز تقریبی مواد زائد شامل کربن ثابت، رطوبت، خاکستر و مواد فرار بیشترین تا کمترین تأثیر را بر مقدار تخمینی درصد نفت زیستی حاصل از پیرولیز مواد زائد دارد. البته لازم به یاد آوری است که مطابق نتایج همبستگی (جدول ۴) رابطه بین تمام این عناصر با درصد نفت زیستی معنی دار می‌باشد.

جدول ۸. نتایج تحلیل حساسیت عناصر تشکیل دهنده مواد زائد

در تولید نفت زیستی به کمک مدل RBF

متغیرهای ورودی	RMSE	MAPE	R <sup>2</sup>	آموزش	تست
همه	۰/۸۵	۰/۵۰	۰/۹۹	۱/۹۳	۱/۳۶
همه بجز رطوبت	۱۴/۴۹	۶۰/۷۵	۰/۷۳	۹/۴۹	۵/۴۵
همه بجز خاکستر	۷/۰۸	۴/۸۲	۰/۹۳	۶/۹۹	۸/۱۰
همه بجز مواد فرار	۵/۱۵	۵/۵۲	۰/۹۷	۶/۱۴	۷/۷۶
همه بجز کربن ثابت	۱۸/۴۵	۷۷/۷۲	۰/۵۵	۱۳/۴۸	۲۱/۱۸

مأخذ: نتایج تحقیق

#### ۴. نتیجه گیری

در این تحقیق مجموعه داده‌هایی از نتایج ۴۱ آزمایش از مطالعات مختلف جمع‌آوری شد. نتایج تحلیل همبستگی نشان داد که بین مقدار درصد نفت زیستی تولید شده و عناصر تشکیل دهنده مواد زائد شامل رطوبت، خاکستر، مواد فرار و کربن ثابت همبستگی معنی‌داری وجود دارد. بنابراین لزوم وجود رابطه‌ای برای تخمین و ارزیابی نفت زیستی از هر نوع مواد زائد بالقوه ضروری به نظر می‌رسد. لذا در این تحقیق از دو نوع شبکه عصبی RBF و MLP بدین منظور استفاده شد. مقادیر بهینه تعداد نرون‌ها در لایه مخفی و نیز الگوریتم آموزش و سایر پارامترهای شبکه عصبی به روش طرح آزمایشات و آماری پیدا شد. نتایج ارزیابی شبکه‌های عصبی نشان داد که مدل RBF را می‌توان با اطمینان در تخمین درصد نفت زیستی به کار برد. زیرا در تمام موارد مقدار ضریب تبیین بین مقادیر درصد نفت زیستی آزمایشگاهی و پیش‌بینی شده برابر با ۰/۹۹

شد. نتایج تحلیل حساسیت مدل RBF نیز نشان داد که به ترتیب کربن ثابت، رطوبت، خاکستر و مواد فرار بیشترین تأثیر بر مقدار درصد نفت زیستی حاصل از پیرولیز مواد زائد دارد. در انتها براساس نتایج و تجربه حاصل از این پژوهش می‌توان پیشنهاد کرد که مجموعه داده‌های بزرگ‌تری برای آموزش و تست شبکه عصبی فراهم شود تا قابلیت تعمیم پذیری مدل‌ها افزایش یابد. همچنین از سایر روش‌های محاسبات نرم برای تخمین نفت زیستی بر حسب ویژگی‌های مواد زائد استفاده و با شبکه‌های عصبی مقایسه شود. البته به دست آوردن رابطه ریاضی و تئوری بین متغیرهای مستقل و وابسته نیز می‌تواند جنبه کاربردی بیشتری داشته باشد. به کمک مدل‌های استخراج شده می‌توان پتانسیل تولید نفت زیستی را از مواد زائد مختلف ارزیابی کرد و در مورد اقتصادی بودن آن سیاست و تصمیم مناسبی اتخاذ نمود.

## منابع

- ابراهیمی نیک، م، ع.؛ حیدری، آ. و ح. یونسی (۱۳۹۲)، "تولید نفت زیستی از پیرولیز سریع بقایای ذرت و چوب اکالیپتوس در رآکتور بستر سیال"، نشریه ماشین‌های کشاورزی، جلد ۴، شماره ۲، صص ۲۳۵-۲۲۶.
- پیری، ا. و ع. م. نیکبخت (۱۳۹۵)، "مطالعه فرآیند گرماکافت بستر ثابت روی چوب هرس درختان شهری در جو اکسایشی"، مهندسی بیوسیستم/ایران، دوره ۷۴، شماره ۱، صص ۴۹۹-۴۹۳.
- سلیمانی ایوری، س، ع.؛ فدوی امیری، م، ر. و ح. مروی (۱۳۹۵)، "تولید سیگنال مصنوعی زلزله به کمک مدلی جدید در فشرده‌سازی و آموزش شبکه‌های عصبی مصنوعی"، مجله مدل‌سازی در مهندسی، سال چهاردهم، شماره ۴۶.
- شریفیان، ا. و ح. رضایی دولت آبادی (۱۳۹۵)، "ارائه مدلی به منظور رتبه‌بندی پیشران‌های استراتژیک انرژی تجدیدپذیر با استفاده از رویکرد ترکیبی دلفی، دیمتل و تحلیل شبکه‌ای (فازی)"، فصلنامه پژوهش‌های سیاست‌گذاری و برنامه‌ریزی انرژی، سال دوم، شماره ۲، صص ۱۶۷-۱۴۳.

شفیعی ده‌آبادی، ع. (۱۳۹۴)، "زباله‌سوزی و استحصال انرژی از زباله جامد شهری"، مرکز مطالعات و برنامه‌ریزی شهر تهران، گزارش ۳۳۲.

عبدالله‌زاده، ر.؛ شاه‌علی، ع.ع. و س. واسعی (۱۳۸۹)، "بررسی روش‌های استحصال انرژی از پسماند و شناسایی گزینه مناسب برای ایران"، پنجمین همایش ملی مدیریت پسماند.

کاظم، س. و ه. فرزانه (۱۳۹۲)، "مدلسازی سیستم بازیافت انرژی جهت تولید توان بهینه از گاز متان رقیق در معدن زغالسنگ طبس ایران"، فصلنامه پژوهش‌های سیاستگذاری و برنامه‌ریزی انرژی، سال یکم، شماره ۱، صص ۷۸-۵۷.

Abnisa F., Daud W.M.A. and J.N. Sahu (2014), "Pyrolysis of mixtures of palm shell and Polystyrene: An Optional Method to Produce a High-grade of Pyrolysis Oil", *Environmental Progress & Sustainable Energy*, 33(3), pp. 1026-1033.

Abnisa F., Wan Daud W.M.A., S. Jaya Narayan (2010), "Optimization and Modeling of Bio-oil Production from Palm Shell by Pyrolysis Using Response Surface Methodology".

Ahmad I., Khan M.I., Khan H., Ishaq M., Tariq R., Gul K. and W. Ahmad (2015), "Pyrolysis Study of Polypropylene and Polyethylene into Premium Oil Products" *International journal of green energy*, 12(7), pp. 663-671.

Al-Salem S.M., Antelava A., Constantinou A., Manos G. and A. Dutta (2017), "A Review on Thermal and Catalytic Pyrolysis of Plastic Solid Waste (PSW)", *Journal of Environmental Management*, No. 197, pp. 177-198.

Arazo R.O., Genuino D.A.D., M.D.G. de Luna and S.C. Capareda (2017), "Bio-oil Production from Dry Sewage Sludge by Fast Pyrolysis in an Electrically-heated Fluidized Bed Reactor", *Sustainable Environment Research*, 27(1), pp. 7-14.

Asadullah M., Rahman M.A., Ali M.M., Motin M.A., Sultan M.B., Alam M.R. and M.S. Rahman (2008), "Jute Stick Pyrolysis for Bio-oil Production in Fluidized Bed Reactor", *Bioresource Technology*, 99(1), pp. 44-50.

Bennadji H., Smith K., Serapiglia M.J. and E.M. Fisher (2014), "Effect of Particle Size on Low-temperature Pyrolysis of Woody Biomass", *Energy & Fuels*, 28(12), pp. 7527-7537.

Boateng A.A., Daugaard D.E., Goldberg N.M. and K.B. Hicks (2007), "Bench-scale Fluidized-bed Pyrolysis of Switchgrass for Bio-oil Production", *Industrial & Engineering Chemistry Research*, 46(7), pp. 1891-1897.

Boniecki P., Dach J., Pilarski K. and H. Piekarska-Boniecka (2012), "Artificial Neural Networks for Modeling Ammonia Emissions Released from Sewage Sludge Composting", *Atmospheric Environment*, No. 57, pp. 49-54.

Çepeliogullar Ö. And A.E. Pütün (2013), "Thermal and Kinetic Behaviors of Biomass and Plastic Wastes in Co-pyrolysis", *Energy conversion and management*, No. 75, pp. 263-270.

**Jiang H., Zhang M., Chen J., Li S., Shao Y., Yang J. and J. Li** (2017), "Characteristics of Bio-oil Produced by the Pyrolysis of Mixed Oil Shale Semi-coke and Spent Mushroom Substrate", *Fuel*, No. 200, pp. 218-224.

**Khan M.Z.H., Sultana M., Al-Mamun M.R. and M.R. Hasan** (2016), "Pyrolytic Waste Plastic Oil and Its Diesel Blend: Fuel Characterization" *Journal of environmental and public health*.

**Lek S., Delacoste M., Baran P., Dimopoulos I., Lauga J. and S. Aulagnier** (1996), "Application of Neural Networks to Modelling Nonlinear Relationships in Ecology", *Ecological Modelling*, 90(1), pp. 39-52.

**Mikulandrić R., Lončar D., Böhning D., Böhme R. and M. Beckmann** (2014), "Artificial Neural Network Modelling Approach for a Biomass Gasification Process in Fixed Bed Gasifiers" *Energy Conversion and Management*, No.87, pp.1210-1223.

**Razzaque M.A.** (2016), "Development and Assessment of a Fast Pyrolysis Reactor for Bio-oil, Syngas and Bio-char Production from Biomass Residues (Doctoral dissertation, University of Nottingham).

**Sajdak M., Muzyka R., Hrabak J. and K. Słowik** (2015), "Use of Plastic Waste as a Fuel in the Co-pyrolysis of Biomass: Part III: Optimisation of the Co-pyrolysis Process", *Journal of Analytical and Applied Pyrolysis*, No. 112, pp. 298-305.

**Sharma A., Pareek V. and D. Zhang** (2015), "Biomass Pyrolysis- a Review of Modeling", Process Parameters and Catalytic Studies, *Renewable and Sustainable Energy Reviews*, Vol. 50, pp.1081-1096.

**Sharuddin S.D.A., Abnisa F., Daud W.M.A.W. and M.K. Aroua** (2016), "A Review on Pyrolysis of Plastic Wastes", *Energy Conversion and Management*, No.115, pp.308-326.

**Supramono D., Kusrini E. and H. YUANA** (2016), "Yield and Composition of Bio-oil from Co-Pyrolysis of Corn Cobs and Plastic Waste of HDPE in a Fixed Bed Reactor", *Journal of the Japan Institute of Energy*, 95(8), pp. 621-628.

**Suttibak S.** (2013), "Characterization of Bio-oil Produced Obtained Fast Pyrolysis of Groundnuts Shell", *International Journal of Biosciences (IJB)*, 3(7), pp. 82-89.