

پیش بینی پسماند تولیدی شهر تهران با استفاده از سامانه استنتاج تطبیقی فازی-عصبی و شبکه‌های عصبی

مصنوعی

سجاد نصرالهی سروآغاجی^۱، رضا علیمردانی^{۲*}، محمد شریفی^۳ و محمد رضا تقی زاده یزدی^۴

۱. دانشجوی کارشناسی ارشد، دانشکده مهندسی و فناوری کشاورزی پردیس کشاورزی و منابع طبیعی دانشگاه تهران

۲. استاد، دانشکده مهندسی و فناوری کشاورزی پردیس کشاورزی و منابع طبیعی دانشگاه تهران

۳. استادیار، دانشکده مهندسی و فناوری کشاورزی پردیس کشاورزی و منابع طبیعی دانشگاه تهران

۴. استادیار، دانشکده مدیریت دانشگاه تهران

(تاریخ دریافت: ۱۳۹۴/۶/۲۶ - تاریخ تصویب: ۱۳۹۴/۱۰/۱۹)

چکیده

پیش بینی کمیت تولید، نقش به سزایی در بهینه سازی و برنامه ریزی سامانه مدیریت پسماندهای جامد شهری دارد، اما به علت دینامیک بودن سامانه های مدیریت پسماند، پیچیدگی روابط بین متغیر ورودی و خروجی، در دسترس نبودن و یا ناکافی بودن اطلاعات و همچنین تاثیر عوامل متغیر و غیرقابل کنترل همواره کار مشکلی بوده است. امروزه استفاده از سامانه های هوشمند به عنوان راهکاری نوین در تحلیل مسائل زیست محیطی، گسترش یافته است. در این پژوهش توانایی دو مدل هوشمند شبکه عصبی با تابع آموزش لونیگ مارکوارت و همچنین سامانه استنتاج تطبیقی فازی-عصبی برای تخمین میزان تولید پسماندهای ماهانه شهر تهران مقایسه گردید. برای این منظور از داده های مربوط به جمعیت، الگوهای فصلی، کل بارندگی ماهانه، میانگین دمای ماهانه، ارتفاع از سطح دریا، میانگین رطوبت ماهانه و کل پسماند تولیدی (TSW) این شهر در فاصله زمانی ۱۳۸۹ تا ۱۳۹۴ که به صورت ماهانه مرتب شده بودند، استفاده شد. بعد از آموزش و آزمون مدل های شبکه عصبی و سامانه استنتاج تطبیقی فازی-عصبی نتایج این مدل ها مورد مقایسه قرار گرفت. نتایج به دست آمده از این پژوهش نشان داد که مدل فازی-عصبی با ضریب تعیین ۰/۹۶۳، جذر میانگین مربعات خطا ۰/۰۹۶ و درصد میانگین مطلق خطا ۱/۰۵ نسبت به مدل شبکه عصبی با ضریب تعیین ۰/۸۵۲، جذر میانگین مربعات خطا ۰/۱۳۲ و درصد میانگین مطلق خطا ۱/۱۹ دارای عملکرد بهتری می باشد. همچنین نتایج بررسی دو مدل نشان داد که در هر دو مدل با داده های ورودی الگوهای فصلی، کل بارندگی ماهانه، میانگین دمای ماهانه، میانگین رطوبت ماهانه و کل پسماند تولیدی (TSW) می توان به پیش بینی دقیق تری دست یافت.

واژه های کلیدی: مدیریت پسماندهای جامد شهری، مدل های هوشمند، قوانین فازی، مسائل زیست محیطی

مقدمه

اقدام کرد. یکی از عوامل بسیار مهم در این راستا، شناخت و پیش بینی دقیق جریان پسماندهای جامد شهری^۱ (MSW) می باشد. پیش بینی میزان تولید MSW، مهم ترین و اصلی ترین گام در برنامه ریزی، سازمان دهی، سیاست گذاری، تعیین حجم سرمایه گذاری برای ماشین آلات، اندازه ظروف ذخیره در محل، ایجاد ایستگاه های انتقال، ظرفیت مکان های پردازش، بازیافت، دفع و همچنین عملیاتی کردن سامانه های مدیریت پسماند می باشد (Abbasi et al., 2012; Hyun Il et al., 2011).

تحقیقات زیادی به منظور تخمین نرخ تولید پسماندهای شهری در کوتاه مدت و بلند مدت صورت گرفته است، که از مهم ترین آن ها می توان به روش های سنتی، نظیر آنالیز وزنی-

گسترش کلان شهرها و صنعتی شدن، به ویژه در کشورهای در حال توسعه، با معضلات متعددی مانند رشد روزافزون تولید پسماند روبه رو است که پیامدها و تبعات آن برای دست اندرکاران امور شهری بسیار مشکل ساز شده است، در صورتی که سامانه مدیریت مناسبی به کار گرفته نشود، این مواد باعث آلودگی های زیستی و محیطی زیاد می شوند و سلامت بشر را به خطر می اندازند. با توجه به اینکه سامانه مدیریت پسماندهای جامد شهری یک مقوله چند وجهی است، جهت رسیدن به نقطه ای قابل قبول در این عرصه باید به تدوین برنامه های عملی

بینی غلظت CO بهتر عمل نمود. مدل‌سازی و پیش‌بینی پسماند تولیدی^۵ (WG) با استفاده از مدل تلفیقی تبدیل موجک-فازی عصبی^۶ (Wavelet-ANFIS) و مدل تلفیقی تبدیل موجک-عصبی^۷ (Wavelet-ANN) توسط (Noori et al., 2009b) در شهر تهران مورد مطالعه قرار گرفت. نتایج پیش‌بینی نشان داد که مدل WT-ANFIS نسبت به مدل WT-ANN قابلیت بیشتری در مدل‌سازی و پیش‌بینی دارد. Karaca and Özkaya (2006) از شبکه عصبی برای مدل‌سازی نرخ جریان شیرابه MSW در یکی از محل‌های دفن استانبول ترکیه (Odayeri) استفاده کردند. در این مطالعه، الگوریتم لوبنبرگ مارکوارت به عنوان بهترین الگوریتم انتخاب شد و بعد از تعیین مناسب‌ترین ساختار شبکه عصبی مزایا، معایب و چشم‌اندازها مورد بحث قرار گرفت. (Tiwari et al., 2012) در مطالعه‌ای با استفاده از ANN و ANFIS میزان پسماندهای جامد صنعتی^۸ (ISW) شهر Durg-Bhilai هند را بین سال‌های ۲۰۱۰ تا ۲۰۲۶ پیش‌بینی کردند، نتایج نشان داد که مدل ANFIS دارای عدم قطعیت کمتری است.

با توجه به توانمندی‌های زیاد مدل‌های شبکه عصبی در زمینه‌های مختلف از جمله موضوعات زیست‌محیطی، این مدل‌ها در سال‌های اخیر در گستره وسیعی به کار گرفته شده‌اند. شبکه‌های عصبی مصنوعی به عنوان بخشی از هوش مصنوعی (AI)، یک مدل ساده و کوچکی از سیستم بیولوژیکی مغز انسان است و با توجه به این تشابه دارای دقت تقریب و قدرت پردازش بالا می‌باشد (Çay et al., 2012; Çay et al., 2013). این مدل برای حل طیف گسترده‌ای از مسائل، از جمله مواردی که با روش‌های سنتی قابل حل نیست، استفاده شده است. یکی از مزایای مدل‌های ANN نسبت به روش‌های متعارف مانند رگرسیون، توانایی یادگیری درمورد سامانه، بدون دانش قبلی از روابط موجود می‌باشد. (Khoshnevisan et al., 2014a, b).

سامانه استنتاج تطبیقی فازی-عصبی یک سامانه هیبریدی است که مرکب از توانایی تصمیم‌گیری منطقی فازی با قابلیت حساب‌گری شبکه عصبی است و سطح پیچیده و بالایی را برای مدل‌کردن و تخمین پیشنهاد می‌کند. این سامانه از مزایای هر دو مدل برخوردار است به این معنی که از خصوصیت آموزش‌پذیری شبکه‌های عصبی و قدرت تصمیم‌گیری بالای سامانه‌های فازی در شرایط عدم اطمینان و قطعیت بهره می‌

جمی، آنالیز توازن مواد و آنالیز شمارش بار (Ghazi Zade and Noori, 2007) و روش‌های نوین مانند رگرسیون خطی چند متغیره (Noori et al., 2009a) اشاره کرد. با این حال، هر کدام از روش‌های ذکر شده محدودیت‌های خاص خود را دارند. به عنوان مثال، روش‌های سنتی عموماً براساس عواملی نظیر آمار جمعیت و فاکتورهای اقتصادی-اجتماعی جامعه استوار می‌باشد، که به صورت ضریب به ازای هر نفر محاسبه می‌شود. مشکل اصلی این روش در این است که این ضرایب ممکن است در بعد زمان تغییر کند و برای یک سامانه مدیریت پسماند به لحاظ دینامیک و پویا بودن آن کارایی خود را از دست دهد (Dyson and Chang, 2005). روش‌های رگرسیون خطی چند متغیره نیز در مواردی که روابط بین ورودی‌ها و خروجی‌ها غیر خطی و پیچیده باشد، توان مدل‌سازی پدیده مورد نظر را ندارد (Noori et al., 2009a; Abdoli et al., 2007).

بنابراین دینامیک بودن سامانه‌های مدیریت پسماند، پیچیدگی روابط بین متغیرهای ورودی و خروجی، در دسترس نبودن و یا ناکافی بودن اطلاعات و همچنین تاثیر عوامل متغیر و غیرقابل کنترل در تولید پسماند محدودیت‌هایی هستند که باعث می‌شوند به دنبال راه‌حل‌های آسان‌تر و در عین حال دقیق برای پیش‌بینی پسماند باشیم. لذا استفاده از روشی جامع‌تر و کامل‌تر ضروری بنظر می‌رسد.

اخیراً، سامانه‌های هوشمند^۱ (AI) به عنوان جایگزین مناسب برای مدل‌های سنتی، در موضوعات مهم زیست‌محیطی مانند آلودگی هوا (Wahab and Alawi, 2008)، آلودگی آب‌های سطحی و زیرسطحی (Yesilnacar et al., 2006; Sahoo et al., 2008) و همچنین مدیریت پسماندهای جامد شهری (Tiwari et al., 2012; Noori et al., 2010a) رواج یافته است.

Akkaya and Demir (2010) در پژوهشی از مدل شبکه عصبی مصنوعی^۲ بر پایه الگوریتم لوبنبرگ مارکوارت^۳ برای پیش‌بینی ارزش حرارتی MSW استفاده کردند، نتایج نشان داد این مدل دارای توانایی بسیار بالا در تعمیم و برآورد ارزش حرارتی MSW می‌باشد. در مطالعه‌ای که پیرامون پیش‌بینی غلظت CO در هوای روزانه شهر تهران با استفاده از دو مدل شبکه عصبی و سامانه استنتاج تطبیقی فازی-عصبی^۴ انجام پذیرفت، Noori et al. (2010b) نشان دادند که شبکه عصبی در پیش

5. Waste generation
6. Wavelet-ANFIS
7. Wavelet-ANN
8. Industrial solid waste

1. Artificial intelligence
2. Artificial neural network
3. Levenberg-Marquardt algorithm
4. Adaptive neuro-fuzzy inference system

۲۷۸۸۹۱۱، ۲۹۷۹۵۹۲، ۲۹۷۳۱۸۵، ۲۹۸۷۲۷۱، ۳۰۶۳۳۳۶ و ۲۸۶۱۴۰۴ تن بوده است که مدیریت این حجم عظیم از پسماندها را شهرداری تهران برعهده دارد. (Tehran Waste Management Organization., 2014) MSW بیش از ۹۷ درصد پسماندهای جامد^۲ (SW) شهر تهران را تشکیل می‌دهد در حالی که حدودا ۳ درصد از آن را دیگر انواع پسماند شامل پسماندهای بیمارستانی (۱ درصد)، صنعتی (۰/۹ درصد) و نخاله‌ها (۰/۶ درصد) تشکیل می‌دهد. سهم پسماندهای خانگی از کل MSW تولیدی شهر تهران حدود ۶۳ درصد می‌باشد (Damghani et al., 2008). بخش عمده‌ای از این پسماندها در مرکز آراد کوه به شکل لندفیل و کمپوست پردازش شده و همچنین مقداری کمی از آن نیز بازیافت و یا تبدیل به بیوگاز می‌شود (Tehran Waste Management Organization., 2014).

عواملی مثل الگوهای فصلی (هر ۳ ماه برابر با یک فصل) جمعیت، کل بارندگی ماهانه، میانگین دمای ماهانه، ارتفاع از سطح دریا و میانگین رطوبت ماهانه پارامترهایی هستند که در برآورد سرانه پسماند تاثیرگذار هستند. بدین جهت آمار بارندگی، میانگین دما، میانگین رطوبت و اطلاعات جغرافیایی شهر تهران جمع‌آوری و به عنوان ورودی مورد استفاده قرار گرفت و توانایی سامانه فازی-عصبی و شبکه‌های عصبی مصنوعی در پیش‌بینی تولید پسماندهای شهری، با داده‌های ورودی مختلف، بررسی شد.

در این پژوهش، داده‌های آماری ۶ ساله (بین سال‌های ۱۳۸۹ تا ۱۳۹۳) مربوط به کل بارش ماهانه، میانگین دمای ماهانه و متوسط رطوبت ماهانه از ایستگاه هواشناسی فیروزکوه (امین‌آباد) و همچنین اطلاعات مربوط به میزان تولید MSW و SW از سازمان مدیریت پسماند شهر تهران جمع‌آوری شد.

مدل‌سازی نرخ تولید پسماند با استفاده از شبکه‌های عصبی مصنوعی

در این مطالعه، به منظور پیش‌بینی نرخ تولید پسماند با استفاده از شبکه‌های عصبی مصنوعی، ترکیب مناسبی از داده‌های ۷۲ ماهه مربوط به جمعیت، کل بارندگی ماهانه، میانگین دمای ماهانه، ارتفاع از سطح دریا، میانگین رطوبت ماهانه، میزان تولید SW به همراه الگوهای فصلی به عنوان ورودی‌ها و میزان تولید MSW به عنوان مقدار مورد انتظار در نظر گرفته شد. به طور معمول در شبکه‌های عصبی کل داده‌های در دسترس به

گیرد (Khoshnevisan et al., 2014a; Naderloo et al., 2012). در این مدل داده محور، ابتدا رابطه بین متغیرهای ورودی و خروجی توسط فرایند یادگیری پیدا شده و سپس میزان تولید MSW، پیش‌بینی می‌شود.

مدل مزبور از دو الگوریتم پس‌انشار خطا و روش ترکیبی (ترکیبی از روش گرادیان نزولی و روش حداقل مربعات خطا) برای آموزش شبکه استفاده می‌کند که می‌تواند پیچیدگی الگوریتم را کاهش داده و همزمان یادگیری شبکه را بهبود بخشد (Singh et al., 2012)، همچنین سامانه استنتاج فازی مورد استفاده در آن، مدل سوگینو^۱ می‌باشد که برای استخراج قوانین فازی و خروجی سامانه از آن استفاده می‌شود (Khoshnevisan et al., 2014c).

با وجود تحقیقات متعدد در زمینه پیش‌بینی نرخ تولید MSW، هیچ‌یک از منظر پیش‌بینی نرخ تولید براساس چندین ورودی (میزان پسماند تولیدی، اطلاعات مربوط به هواشناسی و جغرافیایی منطقه مورد مطالعه، جمعیت و الگوی فصلی)، مورد بررسی قرار نگرفته است، هدف از این مطالعه بررسی و مقایسه توانایی دو مدل هوشمند ANFIS و ANN با ترکیب ورودی‌های مختلف و در نهایت انتخاب بهترین ترکیب ورودی و ساختار برای پیش‌بینی نرخ تولید پسماندهای جامد شهر تهران می‌باشد.

مواد و روش

منطقه مورد مطالعه

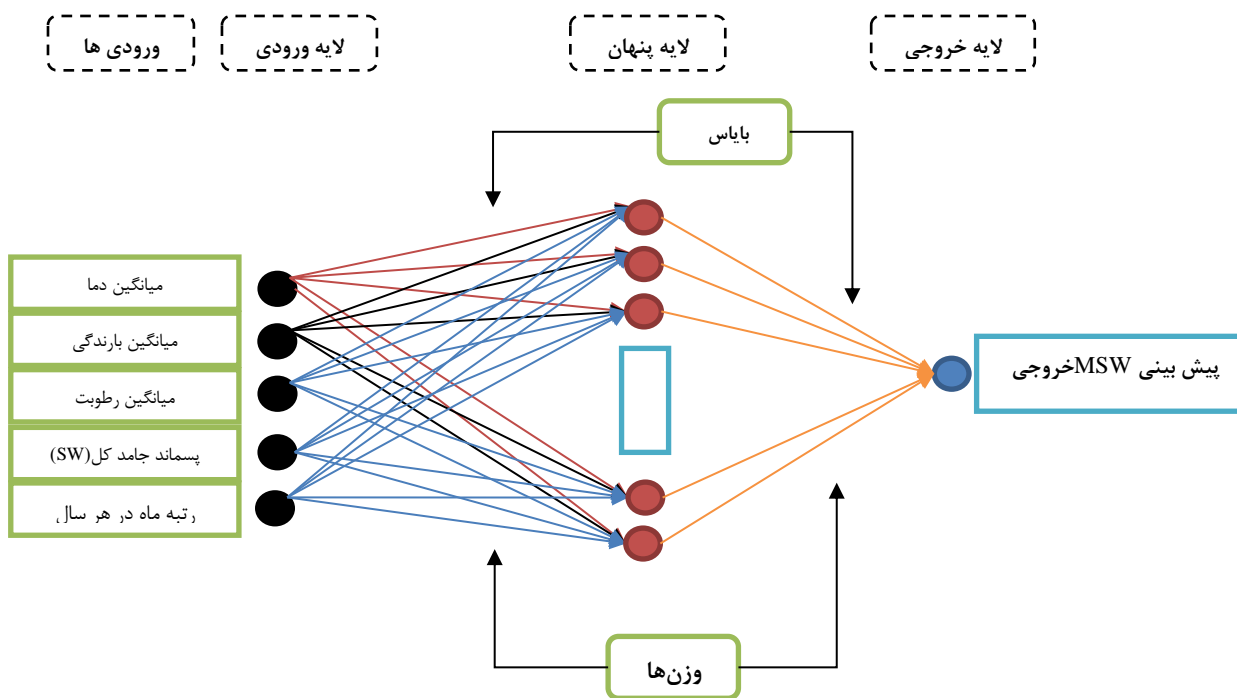
شهر تهران به عنوان پایتخت ایران با جمعیتی حدود ۸ میلیون نفر بین ۳۵ درجه و ۳۱ دقیقه و ۳۵ درجه و ۵۷ دقیقه عرض شمالی و ۵۱ درجه و ۴ دقیقه و ۵۱ درجه و ۴۷ دقیقه عرض شرقی واقع شده است و ارتفاع آن از ۲۰۰۰ متر در مرتفع‌ترین نقاط شمال تا ۱۲۰۰ متر در مرکز و ۱۰۵۰ متر در جنوب متغییر است. این شهر با ۷۳۰ کیلومتر مربع مساحت، میانگین دمای C^{۱۸} و بارش سالانه ۳۱۶-۲۴۵ در نیمه شمالی کشور واقع شده است.

روزانه حدود ۷۵۰۰ تن (۲/۵ میلیون تن در سال) پسماند در شهر تهران تولید می‌شود که ۲۴ درصد از کل پسماندهای تولیدی کشور را تشکیل می‌دهد، بر طبق آخرین آمار سازمان مدیریت پسماند (۱۳۹۳) میانگین سالانه پسماندهای تولیدی شهر تهران بین سال‌های ۱۳۸۹ تا ۱۳۹۴ به ترتیب برابر

به طوری که نرون ها (عناصر پردازش) داده های خام را از لایه ورودی به لایه پنهان و سپس از لایه (لایه های) پنهان به لایه خروجی ارسال می کنند، به عبارتی دیگر، خروجی ها از طریق پردازش داده های خام در لایه ورودی و پنهان با توجه به بایاس، وزن ها، توابع جمع و توابع فعال سازی اختصاصی بدست می آیند، البته باید توجه داشت که فرآیند پردازش بر روی داده ها در لایه ورودی با لایه های دیگر فرق دارد. وزن ها مقادیری هستند که بین سلول های شبکه عصبی (نرون ها) ارتباط برقرار می کنند.

سه مجموعه آموزشی، اعتبارسنجی و آزمون تقسیم می شوند. مجموعه آموزشی توسط الگوریتم یادگیری برای تخمین وزن های شبکه، مجموعه اعتبارسنجی در حین آموزش به منظور آموزش صحیح شبکه و مجموعه آزمون برای ارزیابی دقت پیش بینی شبکه آموزش دیده، مورد استفاده قرار می گیرند. در این مطالعه، ۷۰ درصد داده ها به عنوان داده های آموزشی، ۱۵ درصد داده های اعتبارسنجی و ۱۵ درصد نیز جهت آزمون مدل انتخاب شدند.

عموما شبکه عصبی از سه نوع لایه به نام های لایه ورودی، یک یا چند لایه پنهان و لایه خروجی تشکیل می شود.



شکل ۱- ساختار شبکه عصبی مصنوعی با یک لایه پنهان

مناسب در عملکرد شبکه عصبی بسیار موثر است. توابع فعال سازی مختلفی از جمله توابع پله ای^۱، آستانه ای^۲، سیگموئید^۳ و تانژانت هیپربولیک^۴ به منظور پردازش خروجی های نرون وجود دارد که از انواع مهم و پرکاربرد آنها می توان به تانژانت سیگموئید^۵ (رابطه ۲) و لوجستیک سیگموئید^۶ (رابطه ۳) اشاره کرد.

$$f(\text{net}_j) = \frac{1}{1 + \exp(-\text{net}_j)} \quad (\text{رابطه ۲})$$

تابع جمع خروجی خالص هر نرون را محاسبه می کند، تابع جمع در این مطالعه از طریق رابطه (۱) بدست می آید.

$$\text{net}_j = \sum_{i=1}^n (w_{ij}x_i + w_{bj}) \quad (\text{رابطه ۱})$$

که در آن:

net_j : خروجی خالص نرون j ام، w_{ij} : وزن اختصاص داده شده به نرون j ام با ورودی خام i ام، x_i : ورودی خام i ام و w_{bj} : بایاس اختصاص داده شده به نرون j ام می باشد.

عموما تابع فعال سازی یک رابطه خطی بین ورودی و خروجی ایجاد می کند، بعلاوه، انتخاب یک تابع فعال سازی

1. Step function
2. Threshold function
3. Sigmoid function
4. Hyperbolic tangent function
5. Tangent sigmoid
6. logistic sigmoid

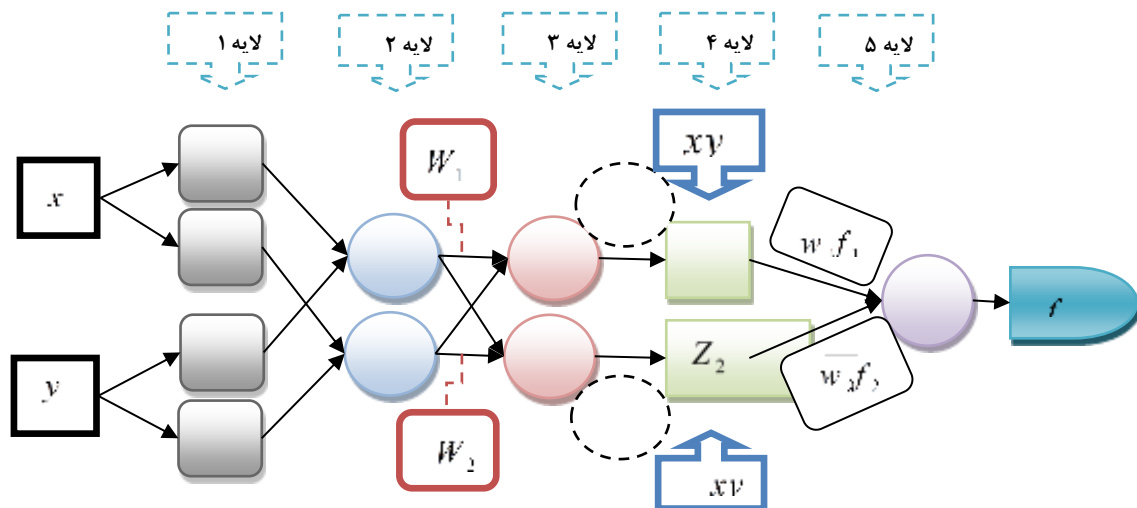
آموزشی، ۱۵ درصد داده‌های اعتبارسنجی و ۱۵ درصد نیز جهت آزمون مدل انتخاب شدند. همچنین به صورت تجربی ترکیب مناسبی از داده‌های ۷۲ ماهه بعد از آزمون و تکرارهای متعدد به عنوان ورودی و میزان تولید MSW به عنوان مقدار خروجی استفاده شد. عموماً یک ساختار ANFIS شامل ۵ لایه (مطابق شکل ۲) با تعدادی متغییر ورودی است که هر ورودی دو یا چند تابع عضویت دارد. در لایه اول (ورودی) میزان تعلق هر ورودی به بازه های مختلف فازی توسط کاربر مشخص می شود. با ضرب مقادیر ورودی هر گره در یکدیگر، وزن قانون ها در لایه دوم بدست می آید. در لایه سوم عمل محاسبه وزن نسبی قوانین انجام می شود. لایه چهارم، لایه قوانین است که از انجام عملیات بر روی سیگنال های ورودی به این لایه حاصل می شود. لایه آخر، لایه خروجی شبکه می باشد که هدف آن حداقل نمودن اختلاف خروجی به دست آمده از شبکه و خروجی واقعی است.

$$f(\text{net}_j) = \frac{2}{1 + \exp(-2\text{net}_j)} - 1 \quad (\text{رابطه ۳})$$

در نهایت به منظور افزایش دقت پیش‌بینی، همراه با آموزش شبکه با استفاده از داده‌های خام، چندین ساختار با اعمال تنظیماتی از جمله تغییر تعداد لایه پنهان (شبکه با یک، دو و سه لایه پنهان مورد ارزیابی قرار گرفت)، تعداد نرون در هر لایه (بین ۱ - ۴۰ نرون)، نوع الگوریتم آموزش و تابع فعال سازی به صورت تجربی مورد ارزیابی قرار گرفت. برنامه با توابع فعال سازی و تعداد لایه‌های پنهان مختلف توسط نرم افزار MATLAB نسخه ۷۰۱ (R2012a) نوشته شد و از بین ساختارهای مختلف، بهترین شبکه انتخاب گردید.

مدل سازی نرخ تولید پسماند با استفاده از سامانه استنتاج تطبیقی فازی - عصبی (ANFIS)

در بخش مدل سازی نرخ تولید پسماند با استفاده از ANFIS نیز همانند شبکه عصبی، ۷۰ درصد داده ها به عنوان داده‌های



شکل ۲- ساختار یک سامانه استنتاج تطبیقی فازی-عصبی

به دو گروه (یکی ۲ و دیگری ۳ عضوی) تقسیم و هر کدام وارد یک شبکه ANFIS شدند. در نهایت، ارزش های پیش بینی شده مربوط به ANFIS ۱ و ۲ وارد ANFIS شماره ۳ شد تا مقدار تولید پسماند خروجی پیش بینی شود.

ارزیابی عملکرد مدل های ANFIS و ANN

سه معیار جذر میانگین مربعات خطا^۲ (RMSE)، ضریب همبستگی^۳ (R²) و درصد میانگین مطلق خطا^۴ (MAPE) مطابق روابط (۴)، (۵) و (۶) جهت ارزیابی دقت و توانایی هر

محدودیت اصلی در توسعه یک سامانه استنتاج تطبیقی فازی-عصبی مربوط به تعداد ورودی ها می باشد، اگر تعداد ورودی‌ها بیش از پنج باشد در این صورت زمان محاسبات و تعداد قوانین افزایش یافته و مدل با شکست مواجه خواهد شد. در یک ساختار استاندارد دو، سه، چهار و نهایتاً پنج متغیر ورودی به شبکه وارد شده و یک خروجی مناسب استخراج می‌شود (Khoshnevisan et al., 2015). در نهایت جهت پیدا کردن بهترین ساختار از ترکیب ورودی های مختلف ساختار^۱ مربوط به شکل ۳ توسعه داده شد. در این ساختار، پنج ورودی

2. Root mean square error
3. Correlation coefficient
4. Mean absolute percentage error

1. Structure


$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (P_j - A_j)^2} \quad (\text{رابطه ۶})$$

که در آن: P_j و A_j به ترتیب مربوط به مقادیر پیش بینی شده و واقعی در ماه j ام و n تعداد کل داده های خام می باشد.

شبکه مورد استفاده قرار گرفت (Pahlavan et al., 2012,) (Najafi et al., 2009):

$$R^2 = 1 - \left(\frac{\sum_{j=1}^n (P_j - A_j)^2}{\sum_{j=1}^n A_j^2} \right) \quad (\text{رابطه ۴})$$

$$MAPE = \frac{1}{n} \sum_{j=1}^n \left(\frac{|P_j - A_j|}{A_j} \times 100 \right) \quad (\text{رابطه ۵})$$



شکل ۳- بهترین ساختار مربوط به ANFIS برای پیش بینی MSW

نتایج و بحث

و تابع خطی^۱ همراه با تعداد مختلف از لایه های پنهان و همچنین تعداد مختلف نرون در هر لایه، به کار گرفته شد. عملکرد ساختارهای مختلف شبکه عصبی برای پیش بینی میزان MSW، در جدول ۱ آورده شده است. بهترین ساختار شامل یک لایه ورودی با ۵ نرون، یک لایه پنهان با ۱۴ نرون و همچنین لایه خروجی با یک نرون می باشد. همانطور که در جدول ۱ مشخص شده است، الگوریتم لونیگ مارکوات بهترین نتیجه را ارائه داده است. ضریب تعیین (تستی و کلی)، جذر میانگین مربعات خطا (تستی و کلی) و درصد میانگین مطلق خطا (تستی و کلی) بهترین ساختار شبکه به ترتیب ۰/۹۰۱، ۰/۸۲۵، ۰/۰۷۱، ۰/۱۳۲، ۰/۴۰ و ۱/۱۹ می باشد، که نشان می دهد شبکه عصبی میزان تولید MSW با ورودی های مختلف را به خوبی می تواند پیش بینی کند.

آنالیز داده های تجربی و همچنین به کارگیری ترکیب های مختلف (ترکیب ها به صورت ۷ تایی، ۶ تایی، ۵ تایی و ... در نظر گرفته شدند) از داده های ورودی در دو سامانه هوشمند (ANFIS و ANN)، نشان داد که با استفاده از پارامترهای کل بارندگی ماهانه، میانگین دمای ماهانه، میانگین رطوبت ماهانه، کل پسماند تولید شده ماهانه به همراه رتبه ماهها در هر سال (به ترتیب ماه اول سال رتبه ۱، ماه دوم رتبه ۲، ... و ماه آخر رتبه ۱۲) می توان به یک پیش بینی دقیق تری رسید.

ارزیابی شبکه های عصبی مصنوعی


چندین مدل شبکه عصبی با ساختار و الگوریتم های یادگیری مختلف آموزش و توسعه داده شدند و عملکرد آنها جهت پیدا کردن بهترین شبکه ارزیابی شد. به صورت تجربی، توابع فعال سازی مختلفی از جمله لجستیک سیگموئید، تانژانت سیگموئید

1. Purelin function

جدول ۱- عملکرد الگوهای مختلف شبکه عصبی برای پیش بینی میزان تولید MSW

تابع فعال سازی	الگوریتم یادگیری	تعداد نرون در لایه پنهان	ضریب همبستگی (R^2)		جذر میانگین مربعات خطا (RMSE)		درصد میانگین مطلق خطا (MAPE)	
			تستی	کلی	تستی	کلی	تستی	کلی
Tansig	Trainlm	۱۴	۰/۹۰۱	۰/۸۵۲	۰/۰۷۱	۰/۱۳۲	۰/۴۰	۱/۱۹
Logsig	Trainlm	۱۲	۰/۸۲۱	۰/۷۵۲	۰/۲۴۲	۰/۶۰۱	۰/۶۵	۱/۶۸

جذر میانگین مربعات خطا (تستی و کلی) و درصد میانگین مطلق خطا (تستی و کلی) بهترین ساختار شبکه به ترتیب ۰/۹۸۵، ۰/۹۶۳، ۰/۰۵۳، ۰/۰۹۶، ۰/۱۲ و ۱/۰۵ می باشد، که نشان می دهد مدل ANFIS بهتر از ANN می تواند میزان MSW خروجی را پیش بینی کند.



شکل ۴- مقایسه مقدار پسماند واقعی و پیش بینی شده در بهترین ساختار مدل ANFIS

مقایسه دو مدل ANFIS و ANN

در پایان نتایج حاصل از مدل ANFIS با مدل ANN مقایسه و مشاهده شد که مدل ANFIS به خاطر استفاده از قوانین فازی، دارای قابلیت بیشتری نسبت به مدل‌های ANN در پیش بینی میزان تولید MSW می باشد. نتایج به دست آمده از این پژوهش با نتایج (Zare and Khaki, 2012) مطابقت دارد. ایشان نیز در پیش بینی خواص مکانیکی پیش آلیاژ مولیبدن فشرده و گرم به این نتیجه رسیدند که روش استنتاجی فازی-عصبی از دقت بالاتری نسبت به روش شبکه عصبی برخوردار است.

ارزیابی سامانه های استنتاج تطبیقی فازی-عصبی

جهت رسیدن به بهترین نتیجه، یک نوع ساختار ANFIS (شکل ۳) با ۶ مرحله اجرا و ۴ تنظیم عمده شامل نوع توابع عضویت ورودی و خروجی، تعداد توابع عضویت ورودی و خروجی، الگوریتم یادگیری و تعداد دوره^۱ در هر اجرا مورد ارزیابی قرار گرفت. در این مطالعه، از الگوریتم یادگیری ترکیبی برای تعیین رابطه بین متغیر ورودی و خروجی استفاده شد. یکی از تنظیمات بسیار مهم مربوط به تعداد توابع عضویت می باشد به طوری که تعداد توابع عضویت، تعداد کل پارامترها در ساختار شبکه را مشخص می کند و باید کمتر از تعداد داده های جفت شده آموزش باشد.

بهترین عملکرد برای این ساختار (شکل ۳) در جدول ۲ نشان داده شده است. در این ساختار، Psigmf (حاصلضرب دو تابع عضویت حلقوی) و linear (خطی) به ترتیب به عنوان توابع عضویت ورودی و خروجی انتخاب شدند. همانطور که ملاحظه می شود، تعداد داده های آموزش جفت شده ۵۴ می باشد، بنابراین تعداد توابع عضویت برای مدل های با دو ورودی (۳ و ۲ ANFIS) ۳،۳ و برای مدل با سه ورودی (۱ ANFIS) ۲،۲،۲ انتخاب شد. بر همین اساس، تعداد کل پارامترها برابر با ۴۵، ۴۵ و ۵۱ به دست آمده است که نشان دهنده دقت بالای مدل می باشد.

شکل ۴، همبستگی بین داده های واقعی و پیش بینی شده در بهترین ساختار ANFIS را نشان می دهد. نتایج مربوط به بهترین ساختار و اجرا ANFIS در جدول ۳ آورده شده است، همانطور که ملاحظه می شود، در اجرای ۱۶ سه شبکه ANFIS با ترکیب Psigmf، Linear و hybrid به ترتیب به عنوان تابع عضویت ورودی، تابع عضویت خروجی و الگوریتم یادگیری بهترین پیش بینی را داشته است. ضریب تعیین (تستی و کلی)،

1. Epoch

جدول ۲- عملکرد الگوهای مختلف مدل فازی-عصبی برای پیش بینی میزان تولید MSW

اجرا ۶-۱	شماره انفیس در هر اجرا	نوع تابع عضویت (MF)		نوع تابع عضویت ورودی (MF)*		تعداد تابع عضویت (Number of MF)	الگوریتم یادگیری	ضریب همبستگی (R ²)		جذر میانگین مربعات خطا (RMSE) خطا		درصد میانگین مطلق خطا (MAPE)	
		ورودی	خروجی	ورودی	خروجی			تستی	کلی	تستی	کلی	تستی	کلی
۱	ANFIS3	Trimf	Linear	Gbell	Trimf	۳،۳	Hybrid	۰/۸۶۲	۰/۹۰۱	۰/۱۵۳	۰/۲۸۹	۰/۴۰	۱/۲۶
۲	ANFIS3	Trimf	Linear	Gbell	Gbell	۳،۳	Hybrid	۰/۸۹۶	۰/۹۰۳	۰/۱۸۳	۰/۲۳۱	۰/۲۹	۱/۲۵
۳	ANFIS3	Gbell	Linear	Gbell	Gbell	۳،۳	Hybrid	۰/۶۰۲	۰/۸۵۲	۰/۲۴۱	۰/۳۳۹	۰/۴۶	۱/۳۶
۴	ANFIS3	Trimf	Linear	Gauss	Trimf	۳،۳	Hybrid	۰/۹۱۲	۰/۹۰۲	۰/۱۴۲	۰/۲۶۸	۰/۳۶	۱/۲۳
۵	ANFIS3	Gauss	Linear	Gauss	Gauss	۳،۳	Hybrid	۰/۸۹۷	۰/۹۰۱	۰/۱۵۶	۰/۲۹۳	۰/۳۲	۱/۱۳
۶	ANFIS3	Psigmf	Linear	Psigmf	Psigmf	۳،۳	Hybrid	۰/۹۸۵	۰/۹۶۳	۰/۰۵۳	۰/۰۹۶	۰/۱۲	۱/۰۵

جدول ۳- اطلاعات مربوط به بهترین عملکرد ANFIS

ANFIS3	ANFIS2	ANFIS1	مشخصات ANFIS
۳۳	۳۳	۳۲	تعداد گره ها
۲۶	۲۶	۲۹	تعداد پارامترهای خطی
۱۹	۱۹	۲۲	تعداد پارامترهای غیرخطی
۴۵	۴۵	۵۱	تعداد کل پارامترها
۵۴	۵۴	۵۴	تعداد داده های آموزش جفت شده
۱۸	۱۸	۱۸	تعداد داده های تست جفت شده
۸	۸	۷	تعداد قوانین فازی

نتیجه گیری کلی

معمولا در شبکه های ANN از داده های ورودی و خروجی با مقادیر بسیار دقیق به منظور مدل سازی استفاده می شود، در واقع این مدل برای موقعیت های مانند سامانه های تولید و پردازش به ویژه سامانه های دفع پسماندهای شهری که داده ها بسیار مبهم و ناپایدار هستند، از دقت و قدرت پردازش کمتری برخوردار است ولی در مقابل سامانه ANFIS قادر است چنین داده هایی را با قابلیت بیشتری مدل سازی کند. همچنین با افزایش تعداد ورودی ها در مدل ANFIS به بیش از ۴ ورودی، ترکیب های متفاوتی از ورودی ها در شبکه های مختلف ANFIS استفاده شده و در نهایت وارد ANFIS نهایی می شود تا خروجی را با دقت بسیار بالایی پیش بینی کند، در حالی که در شبکه های عصبی معمولا با افزایش تعداد ورودی ها سرعت و دقت پیش بینی دچار افت می شود. البته ذکر این نکته ضروری هست که تغییر ماهیت داده های ورودی و خروجی و نوع مسئله ممکن است منجر به نتیجه متفاوت و برعکسی شود.

نهایتا با توجه به نتایج به دست آمده و همچنین قابلیت تعمیم آن برای شرایط مدیریت پسماند شهرهای دیگر به نظر می رسد مطالعه حاضر می تواند راهنمای مناسبی برای شهرداری ها در امر تصمیم گیری و برنامه ریزی های آینده باشد.

سپاسگزاری

از زحمات مهندس سعید مرادکیا که در تکمیل اطلاعات مورد نیاز نهایت همکاری را با ما داشتند، صمیمانه سپاس گزاریم.

اختصارات

MSW	پسماندهای جامد شهری
TSW	کل پسماند تولیدی
AI	سامانه های هوشمند
ANN	شبکه عصبی مصنوعی
ANFIS	استنتاج تطبیقی فازی-عصبی

REFERENCES

- Abbasi, M., Abduli, M., Omidvar, B., and Baghvand, A. (2012). Forecasting municipal solid waste generation by hybrid support vector machine and partial least square model. *International Journal of Environmental Research*, 7, 27-38.
- Abdoli, MA., Noori, R., Jalili, M., and Salehian, A. (2007). Forecasting of Tehran waste production using artificial neural networks and multivariate statistical methods. In: *Proceedings of 3th National Congress on Waste Management*, 21-22 Oct., Environmental Protection Agency, Tehran, Iran, pp. 61-72. (In Farsi)
- Akkaya, E., and Demir, A. (2010). Predicting the heating value of municipal solid waste-based materials: An artificial neural network model. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 32, 1777-1783.
- Cay, Y., Cicek, A., Kara, F., and Sağıroğlu, S. (2012). Prediction of engine performance for an alternative fuel using artificial neural network. *Applied Thermal Engineering*, 37, 217-225.
- Çay, Y., Korkmaz, I., Çiçek, A., and Kara, F. (2013). Prediction of engine performance and exhaust emissions for gasoline and methanol using artificial neural network. *Energy*, 50, 177-186.
- Damghani, AM., Savarypour, G., Zand, E., and Deihimfard, R. (2008). Municipal solid waste management in Tehran: Current practices, opportunities and challenges. *Waste management*, 28, 929-934.
- Dyson, B., and Chang, NB. (2005). Forecasting municipal solid waste generation in a fast-growing urban region with system dynamics modeling. *Waste management*, 25, 669-679.
- Hyun Il, P., Borinara, P., and Hong, K. (2011). Geotechnical considerations for end-use of old municipal solid waste landfills. *International Journal of Environmental Research* 5, 573-584.
- Jalili Ghazi Zade, M., and Noori, R. (2007). Prediction of municipal solid waste generation by use of artificial neural network: A case study of Mashhad. *International Journal of Environmental Research*, 2, 13-22.
- Karaca, F., and Özkaya, B. (2006). NN-LEAP: A

- neural network-based model for controlling leachate flow-rate in a municipal solid waste landfill site. *Environmental Modelling & Software*, 21, 1190-1197.
- Khoshnevisan, B., Rafiee, S., Omid, M., and Mousazadeh, H. (2014a). Development of an intelligent system based on ANFIS for predicting wheat grain yield on the basis of energy inputs. *Information processing in agriculture*, 1, 14-22.
- Khoshnevisan, B., Rafiee, S., Omid, M., and Mousazadeh, H. (2014b). Prediction of potato yield based on energy inputs using multi-layer adaptive neuro-fuzzy inference system. *Measurement* 47, 521-530.
- Khoshnevisan, B., Rafiee, S., and Mousazadeh, H. (2014c). Application of multi-layer adaptive neuro-fuzzy inference system for estimation of greenhouse strawberry yield. *Measurement*, 47, 903-910.
- Khoshnevisan, B., Rafiee, S., Iqbal, J., Shamshirbande, S., Omid, M., Anuarf, N., and Abdul Wahab, A. (2015). A Comparative Study between Artificial Neural Networks and Adaptive Neuro-fuzzy Inference Systems for Modeling Energy Consumption in Greenhouse Tomato Production-A Case Study in Isfahan Province. *Journal of Agricultural Science and Technology*, 17, 49-62.
- Naderloo, L., Alimardani, R., Omid, M., Sarmadian, F., Javadikia, P., Torabi, MY., and Alimardani, F. (2012). Application of ANFIS to predict crop yield based on different energy inputs. *Measurement*, 45, 1406-1413.
- Najafi, G., Ghobadian, B., Tavakoli, T., Buttsworth, D., Yusaf, T., and Faizollahnejad, M. (2009). Performance and exhaust emissions of a gasoline engine with ethanol blended gasoline fuels using artificial neural network. *Applied Energy*, 86, 630-639.
- Noori, R., Abdoli, MA., Farokhnia, A., and Ghaemi, A. (2009a). Prediction of weekly solid waste by using of neural network and hybrid of wavelet. *Journal of Environmental Studies*, 35(49), 25-30. (In Farsi)
- Noori, R., Abdoli, MA., Farokhnia, A., and Abbasi, M. (2009b). Results uncertainty of solid waste generation forecasting by hybrid of wavelet transform-ANFIS and wavelet transform-neural network. *Expert Systems with Applications*, 36, 9991-9999.
- Noori, R., Karbassi, A., and Sabahi, MS. (2010a). Evaluation of PCA and Gamma test techniques on ANN operation for weekly solid waste prediction. *Journal of Environmental Management*, 91, 767-771.
- Noori, R., Hoshyaripour, G., Ashrafi, K., and Araabi, BN. (2010b). Uncertainty analysis of developed ANN and ANFIS models in prediction of carbon monoxide daily concentration. *Atmospheric Environment*, 44, 476-482.
- Pahlavan, R., Omid, M., and Akram, A. (2012). Energy input-output analysis and application of artificial neural networks for predicting greenhouse basil production. *Energy*, 37, 171-176.
- Sahoo, G., Ray, C., and De, Carlo E. (2006). Use of neural network to predict flash flood and attendant water qualities of a mountainous stream on Oahu, Hawaii. *Journal of Hydrology*, 327, 525-538.
- Shojaeefard, M., Etghani, M., Tahani, M., and Akbari, M. (2012). Artificial Neural Network Based Multi-Objective Evolutionary Optimization of a Heavy-Duty Diesel Engine. *International Journal of Automotive Engineering*, 2(4), 206-215 (In Farsi)
- Singh, R., Kainthola, A., and Singh, T. (2012). Estimation of elastic constant of rocks using an ANFIS approach. *Applied Soft Computing*, 12, 40-45.
- Tehran Waste Management Organization. (2014). Statistics report on 2014. Tehran Municipality, Iran. Retrieved January 12, 2014, from <http://pasmand.tehran.ir/Default.aspx?alias=pasm.and.tehran.ir/en>.
- Tiwari, MK., Bajpai, S., and Dewangan, U. (2012). Prediction of industrial solid waste with ANFIS model and its comparison with ANN model-A case study of Durg-Bhilai twin city India. *International Journal of Engineering and Innovative Technology (IJEIT)*, 6, 192-201.
- Wahab, SA., and Alawi, SM. (2008). Prediction of sulfur dioxide (so₂) concentration levels from the mina al-fahal refinery in oman using artificial neural networks. *American Journal of Environmental Sciences*, 4, 473.
- Yesilnacar, MI., Sahinkaya, E., Naz, M., and Ozkaya, B. (2008). Neural network prediction of nitrate in groundwater of Harran Plain, Turkey. *Environmental Geology*, 56, 19-25.
- Zare, M., and Khaki, JV. (2012). Prediction of mechanical properties of a warm compacted molybdenum prealloy using artificial neural network and adaptive neuro-fuzzy models. *Materials & Design*, 38, 26-31.