

علوم و تکنولوژی محیط زیست، دوره بیست و دوم، شماره یک، فروردین ماه ۹۹

پیش بینی کمیت پسماند شهری با استفاده از مدل های هوشمند و آنالیز عدم

قطعیت آن ها

مریم عباسی^{*۱}

mary_abbasi@sbu.ac.ir

ملیحه فلاح نژاد^۲

روح الله نوری^۳

مریم میرابی^۴

تاریخ پذیرش: ۹۶/۰۳/۳۱

تاریخ دریافت: ۹۶/۰۲/۰۳

چکیده

زمینه و هدف: اولین قدم برای طراحی سیستم های مدیریت پسماند شهری، آگاهی کامل از کمیت پسماند تولیدی می باشد. پیش بینی کمیت تولید پسماند به دلیل تاثیر عوامل متنوع و خارج از کنترل، یکی از پیچیده ترین مسایل مهندسی می باشد. به همین خاطر، لزوم استفاده از مدل هایی که قابلیت مدل سازی پدیده های پیچیده را دارند، به خوبی روشن می باشد. هدف از این مطالعه، پیش بینی کمیت پسماند با استفاده از مدل های هوشمند، مقایسه عملکرد و آنالیز عدم قطعیت آن ها می باشد

روش بررسی: در این مطالعه، شهر مشهد به عنوان مطالعه موردی انتخاب شد و از سری زمانی تولید پسماند در فاصله زمانی سال های ۱۳۸۰ تا ۱۳۹۰ برای پیش بینی هفتگی استفاده گردید. جهت مدل سازی از مدل های هوشمند شبکه عصبی، ماشین بردار پشتیبان، سیستم استنتاجی تطبیقی نروفازی و کا نزدیک ترین همسایه استفاده گردید. پس از بهینه سازی پارامترهای هر مدل، با استفاده از شاخص های آماری، عملکرد مدل ها مورد مقایسه قرار گرفت. در نهایت، آنالیز عدم قطعیت نتایج مدل سازی با کمک روش مونت کارلو انجام گرفت.

یافته ها: نتایج نشان داد که ضریب اطمینان (R^2) مدل های شبکه عصبی، سیستم استنتاجی تطبیقی نروفازی، ماشین بردار پشتیبان و کا نزدیک ترین همسایه به ترتیب ۰/۶۷، ۰/۶۹، ۰/۷۲ و ۰/۶۴ می باشد. آنالیز عدم قطعیت نیز نتایج این مقایسه را تایید نمود و نشان داد مدل ماشین بردار پشتیبان در بین سایر مدل ها، عدم قطعیت کمتری داشته و نسبت به داده های ورودی کمترین حساسیت را دارد.

*۱- (نویسنده مسوول): استادیار گروه محیط زیست، دانشکده مهندسی عمران، آب و محیط زیست، دانشگاه شهید بهشتی، تهران، ایران.

۲- دکتری گروه مهندسی محیط زیست، دانشکده محیط زیست، دانشگاه تهران، تهران، ایران.

۳- استادیار گروه مهندسی محیط زیست، دانشکده محیط زیست، دانشگاه تهران، تهران، ایران.

۴- استادیار گروه محیط زیست، دانشکده مهندسی عمران، آب و محیط زیست، دانشگاه شهید بهشتی، تهران، ایران.

بحث و نتیجه گیری: مدل‌های هوشمند از توانایی رضایت‌بخشی برای پیش‌بینی کمی پسماند برخوردارند و در بین مدل‌های هوشمند مورد مطالعه، مدل ماشین بردار پشتیبان بهترین نتایج را از خود نشان داد. همچنین، عدم قطعیت نتایج مدل ماشین بردار پشتیبان در بین سایر مدل‌ها، عدم قطعیت کم‌تری برخوردار بود.

واژه‌های کلیدی: پیش‌بینی کمی تولید پسماند، شبکه عصبی مصنوعی، ماشین بردار پشتیبان، کا نزدیک‌ترین همسایه، سیستم استنتاجی تطبیقی نروفازی، آنالیز عدم قطعیت.

Forecasting Municipal Solid Waste Quantity by Intelligent Models and Their Uncertainty Analysis

Maryam Abbasi^{*1}

mary_abbasi@sbu.ac.ir

Malihe Fallah Nezhad²

Rooholah Noori³

Maryam Mirabi³

Accepted: 2017.06.21

Received: 2017.04.23

Abstract

Background and Objective: The first step in design of municipal waste management systems is complete understanding of waste generation quantity. Forecasting waste generation is one of the most complex engineering problems due to the effect of various and out of control parameters on waste generation. Therefore, it is obvious that it is necessary to develop approaches to a model such complex events. The objective of this study is forecasting waste generation quantity using intelligent models as well as their comparisons and uncertainty analysis.

Method: In this study, Mashhad city was selected as a case study and waste generation time series of waste generation in 1380 to 1390 were used for weekly prediction. Intelligent models including artificial neural network, support vector machine, adaptive neuro-fuzzy inference system as well as K-nearest neighbors were used for modelling. After optimizing the models' parameters, models' accuracy were compared by statistical indices. Finally, result uncertainty of the models was done by Mont Carlo technique.

Findings: Results showed that coefficient of determination (R^2) of artificial neural network adaptive neuro-fuzzy inference system, support vector machine, and K-nearest neighbor models were 0.67, 0.69, 0.72 and 0.64 respectively. Uncertainty analysis was also justified the results and demonstrates that support vector machine model had the lowest uncertainty among other models and the lowest sensitivity to input variables.

Conclusion: Intelligent models were successfully able to forecast waste quantity and among the studied models, support vector machine was the best predictive model. Moreover, support vector machine produced the results with the lowest uncertainty the other models.

Keywords: Quantitative Waste Generation Forecasting, Artificial Neural Network, Support Vector Machine, K-nearest Neighbors, Adaptive Neuro-fuzzy Inference System, Uncertainty Analysis.

1- Assistant Professor, Department of Environment, Faculty of Civil Engineering, Water and Environment, Shahid Beheshti University, Tehran, Iran *(Corresponding Author)

2- PhD, Department of Environmental Engineering, Faculty of Environment, University of Tehran, Tehran, Iran

3- Assistant Professor, Department of Environmental Engineering, Faculty of Environment, University of Tehran, Tehran, Iran

4- Assistant Professor, Department of Environment, Faculty of Civil Engineering, Water and Environment, Shahid Beheshti University, Tehran, Iran

مقدمه

نوع پیش‌بینی به منظور برنامه‌ریزی جهت سیستم جمع‌آوری و حمل و نقل و حجم زمین مورد نیاز برای دفن بهداشتی پسماندها در هر روز مورد استفاده قرار می‌گیرد (۲).

تا به حال روش‌های زیادی برای تخمین کمیت زباله ارائه شده است که از مهم‌ترین این روش‌ها می‌توان به روش‌های سنتی نظیر آنالیز وزنی-حجمی و آنالیز توازن مواد و روش‌های جدیدتر مانند رگرسیون خطی چند متغیره، شبکه عصبی مصنوعی و فازی^۱ اشاره کرد. در روش آنالیز وزنی-حجمی با اندازه‌گیری وزن و حجم پسماند، کمیت به‌صورت میانگین اعلام می‌شود. این روش زمانی کارایی دارد که نوسان میزان پسماند مورد نظر کم باشد. در نتیجه برای تخمین پسماند شهری کاربرد ندارد (۳). در روش آنالیز توازن مواد با توجه به مواد ورودی و کلیه فرآیندهای صورت گرفته روی آن، مقدار پسماند تعیین می‌شود. این روش تنها در محدوده‌های با وسعت کم و صنعتی که فرآیند انجام شده روی مواد خام مشخص می‌باشد، کاربرد دارد (۳). در روش رگرسیون چند متغیره با کمک داده‌های تجربی و عوامل مؤثر بر خروجی که در اینجا کمیت پسماند می‌باشد، یک معادله بدست می‌آید. در روش‌های معمول پیش‌بینی تولید پسماند معمولاً از فاکتورهای اقتصادی-اجتماعی و جمعیت به صورت سرانه استفاده می‌شود. مقادیر این سرانه‌ها می‌تواند ثابت باشد یا با زمان تغییر کند. هر کدام از روش‌های ذکر شده دارای محدودیت‌هایی می‌باشند. در روش‌های سنتی به دلیل اینکه میزان تولید جامدات غالباً به عنوان تابعی از فاکتورهایی نظیر آمار جمعیت و عوامل اقتصادی-اجتماعی آن جامعه استوار می‌باشد که به‌صورت ضرایب تولید به ازاء هر نفر محاسبه می‌شود، مشکل اساسی، تغییرپذیری این ضرایب است که برای یک سیستم پویای مدیریت مواد زاید جامد به لحاظ دینامیک بودن آن کارایی خود را از دست می‌دهد (۴). روش‌های رگرسیون خطی چندمتغیره نیز در مواردی که روابط بین ورودی‌ها و خروجی غیرخطی و پیچیده باشد، توان مدل‌سازی پدیده مورد نظر را ندارد (۵). به

امروزه مدیریت پسماند در جهان به عنوان شاخه‌ای از مدیریت محیط‌زیستی به علت وجود منابع متعدد تولید پسماند و نیز وسعت آلودگی محیط‌زیست ناشی از آن، اهمیت ویژه‌ای یافته است. تعیین دقیق کلیه محل‌های تولید زباله و یا انواع و اجزاء آن با توجه به پراکندگی جمعیت و گستردگی صنایع و نیز پیچیدگی‌های تولید پسماند، امری سخت و دشوار باشد. برنامه-ریزی دقیق هر یک از مراحل مدیریت پسماند، نیاز به برآورد دقیق کمیت پسماند تولیدی دارد. این اطلاعات، علاوه بر تجزیه و تحلیل زباله‌های تولید شده، امکان ارائه الگوی مصرف مناسب برای شهرها و صنایع و نیز برنامه‌ریزی دقیق و جامع در مورد مدیریت پسماند را در ابعاد گوناگون میسر می‌سازد.

دانستن میزان تولید پسماند در تدوین استراتژی جمع‌آوری، بازیافت، دفع، تصفیه آن و هزینه‌های مربوطه قطعاً تأثیرگذار خواهد بود. در هر صورت آنچه مسلم است، ارائه برنامه‌ای دقیق در زمینه مدیریت پسماند به تجزیه و تحلیل کمی زایدات بستگی داشته و این مساله امری ضروری برای تحقق اهداف محیط‌زیستی در توسعه پایدار کشور به حساب می‌آید.

موضوع پیش‌بینی کمی تولید پسماند از سال‌ها پیش در کشورهای مختلف جهان از دیدگاه‌های متفاوتی مورد بررسی قرار گرفته است. به طور کلی پیش‌بینی میزان تولید پسماند از لحاظ بازه پیش‌بینی در سه دسته اصلی پیش‌بینی بلندمدت، میان‌مدت و کوتاه‌مدت صورت پذیرفته است. پیش‌بینی بلندمدت پسماند جهت سرمایه‌گذاری‌های وسیع مورد نیاز در طراحی سیستم‌های مدیریت پسماند، انتخاب زمین برای دفن بهداشتی، احداث واحدهای بازیافت و کمپوست صورت می‌پذیرد (۱). پیش‌بینی میان‌مدت، مربوط به نوسانات تولید پسماند در طول سال می‌باشد که می‌تواند به صورت تغییرات فصلی و ماهانه تولید پسماند ارزیابی شود. بر اساس این پیش‌بینی، برنامه‌ریزی جهت انتخاب حجم مخازن ذخیره پسماند و خرید ماشین‌آلات لازم جهت حمل و نقل و جمع‌آوری پسماند صورت می‌گیرد. پیش‌بینی کوتاه‌مدت معمولاً بازه زمانی بین یک ساعت تا یک هفته را پوشش می‌دهد. این

متغیرها، ترتیب قرارگیری آن‌ها و متغیرهای تصمیم حساس می‌باشد. شبکه‌های عصبی که در رده مدل‌های پیوندگرا^۴ می‌باشند، سیستم‌هایی هستند که در آن‌ها تلاش شده است از اصول سازمان‌دهی شناخته شده و یا مورد انتظار در مغز انسان، استفاده شود. شبکه‌های عصبی از تعدادی پردازش‌گر ساده و مستقل به نام نورون تشکیل شده است و این نورون‌ها با یکدیگر از طریق ارتباطاتی وزن‌دار تبادل اطلاعات می‌کنند. قابلیت آموزش شبکه عصبی امکان پیش‌بینی مقادیر متغیر را با دقت بالایی فراهم می‌کند. نوری و همکارانش از داده‌های وزن زباله تولیدی شهر مشهد به صورت هفتگی برای مدل‌سازی شبکه عصبی مصنوعی استفاده کرد. در این پژوهش از چهار روش آموزش شبکه عصبی استفاده شد. در ابتدا ۱۳ متغیر ورودی با استفاده از الگوریتم‌های ذکر شده برای بهینه کردن شبکه عصبی استفاده شد و سپس با استفاده از تکنیک‌های PCA^۵ و GT^۶ تعداد متغیرهای ورودی را کاهش داد. در انتها مقایسه بین عملکرد مدل‌ها انجام شد. نتایج نشان داد که مدل‌های ANN-PCA، ANN-GT، GT-ANN، ANN-PCA نتایج بهتری نسبت به ANN دارند. در این روش پیش‌بینی به دلیل خودهمبستگی متغیرها امکان پیش‌بینی بلندمدت وجود نداشته و تنها برای پیش‌بینی یک یا دو گام زمانی قابلیت پیش‌بینی دارد. قاضی زاده و همکاران (۴) با استفاده از شبکه عصبی پیش‌خور، مدلی برای پیش‌بینی کوتاه مدت پسماند تولیدی شهر مشهد پیشنهاد کرد. بدین منظور از داده‌های پسماند تولیدی شهر مشهد به صورت هفتگی از سال ۲۰۰۴ تا ۲۰۰۷ به عنوان اطلاعات ورودی به شبکه عصبی استفاده کرد. همچنین برای تشخیص اثر هر کدام از داده‌های ورودی بر روی پسماند تولیدی آنالیز حساسیت انجام شد. در آخر ساختارهای مختلف شبکه عصبی برای تولید پسماند شهر مشهد بررسی شد و بهترین آن‌ها از نظر داشتن کمترین خطا و بیشترین ضریب همبستگی انتخاب شد. نتایج تحقیق نشان داد که در بهترین مدل شبکه عصبی سه‌لایه با ۱۶ نورون در لایه مخفی^۲ R^۲ برابر ۰/۷۴ و خطا برابر

عبارتی اکثر مدل‌های کلاسیک پیش‌بینی از قبیل روش میانگین هندسی، منحنی اشباع، رگرسیون حداقل مربعات^۱ و بسط منحنی بر پایه مدل‌های نیمه تجربی بودند. واضح است که در نظر گرفتن تمام فاکتورهای مؤثر بر تولید پسماند تقریباً غیرممکن بوده و نیازمند تعداد زیادی نمونه‌گیری است که تنها می‌تواند برای محدوده مورد مطالعه کاربرد داشته باشد و در ضمن هزینه زیادی دربر می‌گیرد. بنابراین روش‌های پیش‌بینی تولید که نیازمند تعداد کمتری نمونه‌گیری بوده و مربوط به یک منطقه خاص نمی‌باشد و قابلیت ارتباط مستقیم بین داده‌های ورودی و خروجی بدون نیاز به درک کامل از فرآیند تولید را فراهم سازند، در این زمینه لازم می‌باشد.

با توجه محدودیت روش‌های فوق از روش‌های دیگری نظیر مدل طبقه‌بندی نروفازی و شبکه عصبی در تخمین مقدار پسماند استفاده شد. در تکنیک نروفازی، از ترکیب منطق فازی و شبکه‌های عصبی مصنوعی استفاده می‌شود که در آن از سیستم استنتاج فازی^۲ (FIS) برای مدل کردن پدیده و از قابلیت یادگیری شبکه عصبی به منظور بهینه‌سازی پارامترهای آن استفاده می‌گردد (۶). مرسوم‌ترین دیدگاه توسعه مدل نروفازی، سیستم استنتاجی نروفازی تطبیقی^۳ (ANFIS) می‌باشد که نتایج خوبی را در مدل‌سازی فرآیندهای غیرخطی نشان داده است (۷، ۸). ANFIS مشخصات سیستم را با توجه به داده‌های موجود آموزش دیده و پارامترهای مربوطه را با توجه به معیار خطای مورد نظر تنظیم می‌کند.

تحقیقات زیادی در زمینه استفاده از مدل نروفازی در زمینه‌های مهندسی انجام گرفته است (۶، ۹-۱۱). مزایای مدل نروفازی توانایی شبیه‌سازی سیستم‌های غیرخطی، دقت بالا و زمان کم‌تر ساخت مدل و انجام محاسبات آن می‌باشد (۸، ۱۲). کاربرد مدل نروفازی در زمینه مدیریت پسماند توسط چن در پیش‌بینی کمیت پسماند صورت پذیرفته است (۱۳). این تحقیق نشان داد که دقت این مدل از مدل‌هایی که تا بحال گفته شد، بیش‌تر است. اما این مدل نسبت به انتخاب تعداد

5- Connectionist models
6- Principal component analysis
6- Gamma Test


1- Least Square Regression
2- Fuzzy Inference System
4- Adaptive Neuro-Fuzzy Inference System

روش بررسی

منطقه مورد مطالعه

شهر مشهد یکی از کلان‌شهرهای ایران در شمال شرقی ایران و مرکز استان خراسان رضوی است. شهر مشهد با ۳۲۸ کیلومتر مربع مساحت، دومین شهر پهناور ایران بعد از تهران است. موقعیت شهر مشهد در شکل (۱) نشان داده شده است. براساس سرشماری عمومی نفوس و مسکن سال ۱۳۹۰ این شهر با ۲٬۷۶۶٬۲۵۸ نفر جمعیت، دومین شهر پرجمعیت ایران پس از تهران است.

۳/۱۸٪ بدست آمد. همچنین از مدل ماشین بردار پشتیبان در پیش‌بینی پسماند استفاده شده است (۱۴-۱۶).
 گرچه هنوز مطالعات بیشتری لازم است تا عملکرد مدل‌های هوشمند را در پیش‌بینی تولید پسماند ارزیابی نمود. همچنین بکاربردن نتایج این مدل‌ها در مطالعات عملی نیاز به برآورد عدم قطعیت نتایج دارد که مطالعات محدودی در این زمینه انجام شده است. در این مطالعه، علاوه بر مقایسه عملکرد مدل‌های هوشمند در پیش‌بینی هفتگی تولید پسماند، آنالیز عدم قطعیت نتایج مدل‌سازی نیز صورت گرفته است.



شکل ۱- موقعیت شهر مشهد در کشور ایران

Figure 1- Location of Mashhad city in Iran

تعدادی اجزاء کوچک داده‌پردازی بنام نورون سلول، واحد یا گره تشکیل شده است. ساختار یک شبکه، شامل لایه‌های مختلف به همراه تعدادی نورون مربوطه می‌باشد. اولین لایه هر شبکه را لایه ورودی، لایه آخر را لایه خروجی و لایه‌های میانی را اصطلاحاً لایه‌های پنهان می‌نامند. به‌طور معمول نورون‌های هر لایه به کلیه نورون‌های لایه‌های مجاور از طریق یک رابطه جهت‌دار متصل می‌باشد (۱۷). اطلاعات بین نورون‌ها از طریق این اتصالات منتقل می‌شود. هر یک از این اتصالات دارای مشخصه وزن مختص به خود هستند که در اطلاعات انتقال‌یافته از یک نورون به نورون دیگر ضرب می‌گردند. هر یک از این نورون‌ها، برای محاسبه خروجی خود یک تابع تحریک را که معمولاً غیرخطی است به ورودی‌هایشان، جمع اطلاعات وزن‌دار شده، اعمال می‌نمایند.

طبق آمار موجود در سازمان بازیافت مشهد، متوسط تولید پسماند در سال ۱۳۸۸، ۵۳۰۰۰ تن در ماه می‌باشد که این میزان آمار میزان پسماند جمع‌آوری شده از شهر در محل دفن و پیش از ورود به سیستم تفکیک و بازیافت می‌باشد. محل دفن قدیمی پسماندهای مشهد در جاده خین عرب بود که پس از راه‌اندازی محل دفن بهداشتی جدید مشهد قسمت اعظم پسماندها به این محل منتقل می‌شود. موقعیت محل دفن جدید مشهد واقع در میامی، ۴۵ کیلومتری مشهد می‌باشد. در این پژوهش از داده‌های مربوط به پسماند جمع‌آوری شده از سطح شهر و پیش از پردازش و بازیافت استفاده شده است.

مدل‌سازی تولید پسماند

پیش‌بینی تولید پسمانه به روش شبکه عصبی مصنوعی

یک شبکه عصبی مصنوعی معمولی از چندلایه و هر لایه از

ورودی، تعداد نورون از ۲ تا ۸ تغییر داده شد. برای اجرای کلیه مدل‌ها از جمله شبکه عصبی در این تحقیق از برنامه‌نویسی در نرم‌افزار متلب استفاده شده است و در آن به ترتیب برای دوره آموزش، صحت‌سنجی و تست از حدود ۷۰، ۱۵ و ۱۵ درصد از داده‌های موجود استفاده شده است.

پیش‌بینی تولید پسماند به روش نروفازی

این روش اصولاً مبنای منطق فازی را دارد با این تفاوت که در برآورد پارامترهای مورد نیاز از توانایی شبکه عصبی استفاده می‌کند (۲۰). منطق فازی و تئوری مجموعه‌های فازی جهت توصیف تفکر و استدلال بشری در یک چارچوب ریاضی بکار می‌روند. مدل‌هایی که بر مبنای قواعد فازی هستند، نتایج را به‌طور کیفی مانند زبان طبیعی شرح می‌دهند. مراحل استنتاج فازی که توسط یک سیستم استنتاج فازی انجام می‌شود به شرح ذیل است:

۱- مقایسه متغیر ورودی با توابع عضویت تعریف شده برای آن متغیر برای تعیین درجه عضویت مقدار ورودی (فازی‌سازی)،
 ۲- ترکیب مقادیر عضویت در بخش مقدم برای تعیین قدرت تهییج (وزن) هر قانون، ۳- تولید بخش تالی (اعم از فازی یا حقیقی) هر قانون بر اساس اوزان بدست آمده، ۴- ترکیب بخش‌های بدست آمده از قوانین مختلف برای ساخت یک خروجی حقیقی نهایی.

در این مطالعه با توجه به زیاد بودن تعداد متغیرهای ورودی از خوشه‌بندی فازی کاهشی^۱ جهت خوشه‌بندی استفاده شد (۲۱). در این روش نیاز به بهینه‌سازی پارامتر شعاع I می‌باشد. در این تحقیق از توابع عضویت گوسین استفاده شد و مقدار مناسب I به روش سعی و خطا تعیین گردید. به این منظور اعداد ۰/۱ تا ۰/۹ با افزایش ۰/۰۵ مورد استفاده قرار گرفتند. همچنین مرکز خوشه‌های ساخته شده و شعاع اثر هر یک نیز مشخص گردید. سپس با استفاده از آن‌ها توابع عضویت هر متغیر ورودی مشخص و از ترکیب توابع عضویت متناظر متغیرهای ورودی و ارتباط آن‌ها با متغیر خروجی توسط یک رابطه خطی، قوانین تعریف شدند. پس از آن تصحیح پارامتر-

علاوه بر گره‌های ورودی، یک گره اضافی به نام بایاس با مقدار واحد نیز به کلیه نورون‌های لایه بعد ارتباط داده می‌شود، بدون آن‌که تأثیرپذیری از خروجی نورون‌های لایه قبل داشته باشد. وجود این نورون و وزنی که برای آن محاسبه می‌شود حکم یک مقدار ثابت برای داده‌های ورودی خواهد داشت و موجب جابجایی منحنی فضای ورودی می‌گردد. این مقدار را می‌توان معادل مقدار ثابت در منحنی چندجمله‌ای در نظر گرفت. بنابراین برای حذف آن باید تابع تحریک دارای یک مقدار آستانه‌ای مخالف صفر گردد که معادل یک شیفت ورودی به هر نورون باشد (۱۸).

با توجه به این امر که شبکه پرسپترون چند لایه با الگوریتم پس‌انتشار خطا معمولاً برای حل مسایل مهندسی به خوبی جواب می‌دهد، این روش برای پیش‌بینی کمیت پسماند انتخاب شد. از آنجایی که شبکه عصبی با ساختار و الگوریتم آموزش مختلف منجر به تولید نتایج متفاوت می‌گردد، ابتدا لازم است معماری بهینه شبکه و الگوریتم مناسب آموزش با استفاده از سعی و خطا تعیین شود. ذکر این نکته لازم است که برخی از مراجع به لحاظ تئوریک و عملی تعداد یک لایه پنهان در این نوع شبکه را برای تخمین هر پارامتر غیرخطی و پیچیده کافی دانسته‌اند. بنابراین شبکه عصبی پس‌انتشار یا یک لایه پنهان ساخته شد. تعداد نورون‌های در لایه پنهان شبکه نیز که به عنوان واحدهای محاسباتی شبکه عصبی می‌باشند، لازم است با روند سعی و خطا بدست آیند. البته در انتخاب نورون‌ها باید دقت نمود زیرا تعداد زیاد آن‌ها در لایه پنهان با وجود اینکه انعطاف‌پذیری شبکه را افزایش می‌دهد اما مقدار بسیار زیاد آن ضمن اتلاف زمان و فضا منجر به ناپایداری شبکه گردیده و استفاده از آن‌ها در مراحل بعدی جهت تخمین به‌هنگام پارامتر هدف که در این تحقیق کمیت پسماند است، با مشکل مواجه می‌نماید. همچنین تعداد کم نورون ممکن است نتایج مطلوبی در پی نداشته باشد. به‌طورکلی تعداد نورون‌ها در لایه پنهان با حجم اطلاعات ورودی به شبکه متناسب است. برای تعیین تعداد نورون در لایه پنهان با در نظر داشتن توصیه‌های انجام شده توسط تانگ و همکارانش (۱۹) و با توجه به تعداد متغیر

های مدل (ضرایب رابطه خطی خروجی هر قانون و پارامترهای توابع عضویت) با قرار گرفتن سیستم استنتاج در بطن یک شبکه تطبیقی انجام گردید. تعداد تکرار الگوریتم ترکیبی برای تصحیح پارامترهای مدل و خطای هدف نیز به ترتیب برابر ۳۰ و ۱۰^{-۴} قرار داده شد.

پیش‌بینی تولید پسماند به روش k-نزدیک‌ترین همسایه‌ها^۱

k-نزدیک‌ترین همسایه‌ها، یک روش تشخیص الگوی آماری بدون متغیر است که برای الگوی کمی موجود، k-الگوی مشابه به نام نزدیک‌ترین همسایه‌ها به طور آماری برای تخمین متغیر کمیت مورد نظر استفاده می‌شوند. این روش در تحلیل سری‌های زمانی و پیش‌بینی‌های کمی کاربرد داشته است (۲۲). با در نظر گرفتن مقادیر وابسته جدید، مدل می‌تواند خروجی را بر اساس نمونه‌های k-نزدیک‌ترین همسایه‌ها برآورد کند. این کار با یافتن k-نمونه که در کم‌ترین فاصله از نقطه جستجو قرار دارند، انجام می‌شود. در مسایل رگرسیون، پیش‌بینی‌های مدل بر اساس متوسط‌گیری از خروجی‌های k-نزدیک‌ترین همسایه‌ها انجام می‌شود. انتخاب k در ساختار مدل بسیار مهم است. در واقع، k را می‌توان مهم‌ترین عامل مؤثر در کیفیت پیش‌بینی‌ها دانست. برای هر مساله، مقدار کوچک k می‌تواند منجر به مغایرت بالایی در پیش‌بینی‌ها و مقدار زیاد آن منجر به انحراف پاسخ مدل شود. بنابراین، کما باید آن قدر بزرگ باشد که احتمال عدم طبقه‌بندی را حداقل کند و نسبت به تعداد نمونه‌ها آن قدر کوچک باشد که k-نزدیک‌ترین نقاط به نقطه جستجو، به اندازه کافی نزدیک باشند. مقدار بهینه‌ای برای k وجود دارد که رابطه مناسب را بین تمایل به یک طرف و مغایرت مدل برقرار می‌کند. تخمین k می‌تواند با استفاده از الگوریتم اعتبارسنجی تقاطعی^۲ انجام می‌شود (۲۲).

ارزیابی عدم قطعیت اندازه‌گیری به روش مونت کارلو

روش مونت کارلو در رده الگوریتم‌های محاسباتی است که نتایج آن براساس تکرار نمونه‌های تصادفی بدست می‌آید (۲۳).

الگوریتم مونت کارلو بکار رفته در این تحقیق عبارتست از:
۱- مدل‌سازی تولید پسماند با مدلی که پارامترهای آن بهینه شده است، ۲- ۱۰۰۰ نمونه‌گیری از داده‌های اولیه، ۳- ۱۰۰۰ بار مدل‌سازی بدون تغییر پارامترهای بهینه شده در مرحله قبل، ۴- بدست آوردن بازه اطمینان ۹۵٪ و در نتیجه تخمین عدم قطعیت مدل، ۵- ارزیابی عملکرد مدل از نظر کیفیت نتایج خروجی با شاخص‌های آماری.

پیش‌بینی تولید پسماند به روش ماشین بردار پشتیبان

ماشین بردار پشتیبان^۳ یک مجموعه از متدهای یادگیری با ناظر^۴ است که برای طبقه‌بندی^۵ و رگرسیون استفاده می‌شود. ماشین بردار پشتیبان توسط وپنیک (۲۴) بر پایه تئوری یادگیری آماری معرفی شد. در اصل ماشین بردار پشتیبان یک موجودیت ریاضی است و یک الگوریتم برای ماکزیمم کردن تابع ریاضی با توجه به مجموعه داده شده، می‌باشد. در SVM ماکزیمم کردن حاشیه بین دو کلاس مدنظر است. بنابراین ابرصفحه‌ای را انتخاب می‌کند که فاصله آن از نزدیک‌ترین داده‌ها در هر دو طرف جداکننده خطی، ماکزیمم باشد. اگر چنین ابرصفحه‌ای وجود داشته باشد، به عنوان ابرصفحه ماکزیمم حاشیه^۶ شناخته می‌شود. زمانی که بین ورودی‌ها و خروجی رابطه غیرخطی وجود دارد از تابع کرنل استفاده می‌شود. تابع کرنل یک جداکننده خطی متکی بر ضرب داخلی بردارهاست.

معیارهای ارزیابی مدل‌ها

چهار شاخص آماری متداول ضریب اطمینان (R^2)، میانگین خطای نسبی^۷ (RME)، ریشه میانگین مربعات خطا^۸ (RMSE) و درصد میانگین خطای نسبی^۹ (MARE) برای سنجش خطای مدل‌های مذکور بکار رفته است.

3 - Support vector machine

4 - Supervised learning

5- Classification

6- Maximum-Margin Hyperplane

7 -Relative Mean Error

8- Root Mean Square Error

9 -Mean Average Relative Error

1- K- Nearest Neighbours

2- Cross Validation

یافته‌ها

وجود دارد. تفاوت این الگوریتم در سرعت و دقت رسیدن به جواب نهایی است. از لحاظ سرعت الگوریتم لونیبرگ-مارکویت سریع‌ترین روش است اما از لحاظ دقت طبیعت مساله بسیار مهم است. به طوری که هر کدام از الگوریتم‌ها ممکن است در حل مساله خاصی بالاترین کارایی را از خود نشان دهند. در اینجا الگوریتم آموزش کاهش شیب، کاهش شیب با ممنوم، سرعت متغیر، سرعت متغیر با ممنوم، پس انتشار ارتجاعی، گرادیان توام فلچر-روز، الگوریتم گرادیان توام پولاک، الگوریتم شروع مجدد، گرادیان توام مقیاس شده و الگوریتم لونیبرگ-مارکویت مورد ارزیابی قرار گرفتند. نتایج مدل‌سازی در جدول (۲) نشان داده است.

بهینه‌سازی مدل شبکه عصبی

نتایج بهینه‌سازی شبکه عصبی برای پسماند تولیدی در شهر مشهد در جدول (۱) آمده است. در مرحله بعد لازم است که پارامترهای شبکه یعنی وزن‌ها و بایاس در مدل شبکه عصبی بهینه شوند. همان‌طور که در جدول (۱) دیده می‌شود شبکه با شش نورون برای شهر مشهد، کم‌ترین خطا و بیش‌ترین هم‌بستگی را هم در مرحله آموزش و هم در مرحله تست دارد. پس از دستیابی به ساختار بهینه شبکه، مدل با الگوریتم‌های مختلف آموزش برای رسیدن به الگوریتم مناسب آموزش تست می‌شود. زیرا الگوریتم‌های مختلفی برای آموزش شبکه عصبی

جدول ۱- خطای شبکه عصبی تک‌لایه با تغییر تعداد نورون در لایه پنهان

Table 1- Error of one-layer neural network by changing neuron number in the hidden layer

تعداد نورون	مرحله آموزش				مرحله تست			
	R ²	MARE	RMSE	RME	R ²	MARE	RMSE	RME
۲	۰/۷۴۷	۳/۰۱۵	۴۰۵۸۷۸	۳۲۹۸۸۱	۰/۵۱۶	۴/۴۵۷	۴۸۸۲۷۴	۵۰۰۴۱۸
۳	۰/۶۶۶	۳/۳۶۷	۴۶۰۸۷۱	۴۳۳۰۷۴	۰/۵۸۸	۴/۱۱۷	۵۸۸۱۵۳	۴۳۶۰۹۱
۴	۰/۷۷۱	۲/۸۳۴	۳۸۳۶۱۵	۳۰۸۷۶۹	۰/۵۹۵	۴/۰۷۱	۵۸۹۶۲۴	۴۳۴۶۵۴
۵	۰/۶۸۷	۳/۲۳۱	۴۵۹۷۸۳	۳۴۸۹۴۰	۰/۵۳۷	۴/۸۶۷	۶۴۸۴۸۷	۵۲۰۹۷۶
۶	۰/۸۰۹	۲/۴۶۵	۳۴۸۲۹۹	۲۶۸۰۷۴	۰/۶۷۱	۳/۸۶۱	۵۳۷۲۲۹	۴۱۱۳۰۱
۷	۰/۷۰۳	۳/۲۵۹	۴۲۵۴۷۴	۳۵۶۱۸۵	۰/۵۷۶	۴/۵۵۵	۴۳۴۵۷۳	۴۹۱۴۷۲
۸	۰/۷۵۳	۲/۹۵۴	۴۰۷۱۸۷	۳۲۱۸۸۸	۰/۴۸۰	۵/۵۲۲	۷۶۰۰۷۱	۵۹۵۸۵۲

جدول ۲- نتایج حاصل از آموزش شبکه عصبی با الگوریتم‌های آموزش مختلف

Table 2- Results of neural network training with different learning algorithms


Epoch No.	Time (s)	مرحله تست		مرحله آموزش		الگوریتم آموزش
		R ²	RMSE	R ²	RMSE	
۲۰۰۰	۱۲/۶۸	۰/۵۵۶	۶۱۵۲۴۷	۰/۵۳۴	۵۴۴۹۰۸	کاهش شیب
۲۰۰۰	۱۲/۷۶	۰/۵۸۳	۵۹۲۱۴۶	۰/۵۸۰	۵۱۶۸۵۷	کاهش شیب با ممنوم
۵۹	۰/۷۰۱	۰/۴۰۳	۷۰۹۱۹۴	۰/۳۶۳	۶۳۵۵۶۸	سرعت متغیر
۷۳	۰/۸۱۳	۰/۴۴۶	۶۸۷۴۸۹	۰/۴۷۷	۵۸۱۵۸۰	سرعت متغیر با ممنوم
۱۸	۰/۴۵۱	۰/۵۶۱	۶۱۵۰۳۰	۰/۶۴۵	۴۷۳۷۷۲	پس انتشار ارتجاعی
۱۸	۰/۵۴۰	۰/۶۲۴	۵۵۹۰۷۵	۰/۶۴۴	۴۷۸۱۹۳	گرادیان توام فلچر
۱۵	۰/۴۹۱	۰/۶۰۷	۵۵۸۸۲۷	۰/۶۶۹	۴۵۸۱۱۷	گرادیان توام پولاک
۱۶	۰/۵۰۳	۰/۵۶۱	۶۰۹۵۴۵	۰/۶۵۶	۴۶۶۴۲۶	شروع مجدد
۱۰	۰/۴۲۴	۰/۶۰۸	۵۵۸۱۹۲	۰/۵۷۵	۵۲۳۴۰۴	گرادیان توام مقیاس شده
۸	۰/۴۰۲	۰/۶۷۱	۵۳۷۲۲۹	۰/۸۰۹	۳۴۸۲۹۴	لونیبرگ-مارکوایت

این الگوریتم از ترکیب الگوریتم‌های آموزش دیگر استفاده می‌کند تا نتایج بهتری تولید کند.

بهینه‌سازی مدل نروفازی

در این تحقیق مقدار بهینه شعاع خوشه‌بندی به روش سعی و خطا تعیین گردید. به این منظور اعداد ۰/۱ تا ۰/۹ با افزایش ۰/۰۵ مورد استفاده قرار گرفتند و در پایان مقدار مناسب r_a مقدار بهینه شعاع خوشه‌بندی برای مدل پیش‌بینی، تعیین گردید که این مقدار برای شهر مشهد برابر ۰/۶۵ بدست آمد. شکل (۲) نتایج مراحل آموزش و تست مدل را نشان می‌دهد.

بر مبنای جدول (۲) می‌توان مشاهده نمود که مدل‌های توسعه‌یافته برای پیش‌بینی کمیت پسماند در مشهد از مقادیر مطلوب هم‌بستگی و همچنین خطا در مرحله آموزش و تست برخوردار بوده و نتایج برخی از مدل‌ها تقریباً نزدیک به یکدیگر است. به هر حال با بررسی بیشتر مشخص می‌شود که عملکرد مدل با الگوریتم لونیبرگ-مارکوایت، بطور قابل توجهی از بقیه بهتر بوده است. دلیل این موضوع این است که الگوریتم لونیبرگ-مارکوایت که بنا به وزن‌های بدست آمده تابع انتقال را به گونه‌ای تغییر می‌دهد که تابع کارایی افزایش یابد. به عبارتی



شکل ۲- نتایج مراحل آموزش و تست مدل نروفازی

Figure 2- Results of training and test of neuro-fuzzy model

بهینه‌سازی مدل ماشین برداری پشتیبان

خطا در مرحله یادگیری و تست برای هر یک مدل‌ها محاسبه شده که نتایج آن برای شهر مشهد در جدول (۳) نشان داده شده است. همان‌طور که مشاهده می‌شود تابع شعاعی منجر به ساخت مدلی با کم‌ترین خطا و بیش‌ترین هم‌بستگی برای پیش‌بینی کمیت پسماند هم در شهر مشهد شده است.

همان‌طور که توضیح داده شد، وظیفه تابع کرنل در مدل ماشین برداری پشتیبان کاهش فضای داده‌های محاسباتی است. توابع کرنلی که به‌طور عمده مورد استفاده قرار گرفتند شامل تابع خطی، چند جمله‌ای، شعاعی و سیگموئید. بنابراین باید در ابتدا تابع کرنل مناسب را انتخاب نمود. حداقل مربعات


جدول ۳- تعیین بهترین تابع کرنل برای مدل ماشین بردار پشتیبان

Table 3- Determination of the best kernel function for SVM model


مرحله تست		مرحله آموزش		تابع کرنل
R^2	MSE	R^2	MSE	
۰/۶۱۶	$۲/۷۵ \times ۱۰^{۱۱}$	۰/۶۹۵	$۲/۲۲ \times ۱۰^{۱۱}$	خطی
۰/۶۸۳	$۶/۹۵ \times ۱۰^{۱۱}$	۰/۷۶۲	$۶/۷۲ \times ۱۰^{۱۱}$	چند جمله ای
۰/۷۲۱	$۱/۹۹ \times ۱۰^{۱۱}$	۰/۸۶۵	$۳/۵۰ \times ۱۰^{۱۰}$	شعاعی
۰/۶۰۴	$۲/۸۸ \times ۱۰^{۱۱}$	۰/۶۲۴	$۲/۶۲ \times ۱۰^{۱۱}$	سیگموئید

دو مرحله‌ای استفاده می‌شود. در این روش ابتدا در یک شبکه سه بعدی بزرگ که در آن γ از رنج $0/001$ تا $0/5$ ، C از رنج $0/1$ تا 300 و ϵ از رنج $0/0001$ تا $0/5$ متغیر است، یک ناحیه با کم‌ترین خطا را جستجو می‌کنیم. سپس با توجه به ناحیه بهینه بدست آمده در مرحله قبل در یک شبکه دو بعدی کوچک‌تر به دنبال مقادیر دقیق بهینه می‌گردیم. نتایج جستجوی شبکه‌ای برای شهر مشهد در شکل (۳) آمده است. همان‌طور که در این شکل مشخص است مقادیر بهینه برای مدل پیش‌بینی کمیت پسماند شهر مشهد $(0/09, 0/04, 270)$ $(\gamma, \epsilon, C) =$ بدست آمده است.

تابع کرنل شعاعی خود دارای ثابتی به نام γ است که با دو ثابت مدل ماشین بردار پشتیبان شامل کنترل ظرفیت (C) و تنظیم کننده (ϵ) به‌طور غیرمستقیم وابسته می‌باشند. ثابت C هرچه بزرگ‌تر باشد، حساسیت بیشتری نسبت به خطا دارد. به عبارتی آموزش مدل با هدف کمینه‌سازی خطا انجام می‌شود اما عمومیت مدل کاهش می‌یابد. از طرفی اگر ثابت کنترل ظرفیت کوچک در نظر گرفته شود، امکان کمینه‌سازی حاشیه با خطا فراهم می‌شود و عمومیت مدل افزایش پیدا می‌کند ولی ممکن است خطای مدل افزایش یابد. بنابراین باید تعادلی برقرار نمود که علاوه بر افزایش دقت مدل، عمومیت آن کاهش نیابد. برای رسیدن مقادیر بهینه این پارامترها از روش جستجوی شبکه‌ای



(الف)



(ب)

شکل ۳- نتایج بهینه‌سازی مدل ماشین بردار پشتیبان (الف) ضریب اطمینان (ب) میانگین مربعات خطا

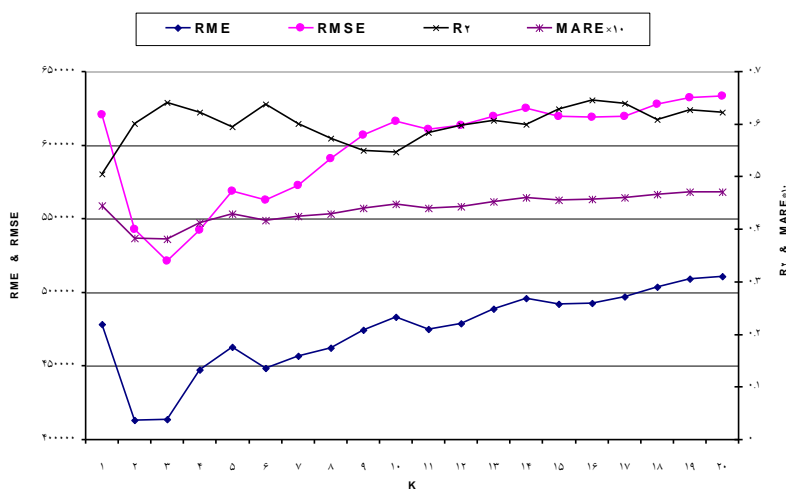
Figure 3- Results of optimizing SVM model a) coefficient of determination b) mean square error

پیش‌بینی کوتاه‌مدت پسماند با مدل k -نزدیک‌ترین

همسایه‌ها

پارامترهای موثر در مدل k -نزدیک‌ترین همسایه‌ها، انتخاب روش اندازه‌گیری فاصله همسایگی و k می‌باشد. در این جا به دلیل اینکه متغیرهای مستقل و متغیر وابسته از جنس وزن پسماند هستند، بهترین رابطه اندازه‌گیری فاصله همسایگی،

رابطه سیتی بلاک می‌باشد که قدرمطلق اختلاف داده تست با آموزش است. البته نتیجه سعی و خطا این نظر را تایید نمود. نتایج بهینه‌سازی k در شکل (۴) آورده شده است. کم‌ترین خطا و بیش‌ترین ضریب هم‌بستگی برای شهر مشهد در k برابر ۳ اتفاق می‌افتد.



شکل ۴- خطای مدل KNN با تغییر K

Figure 4- Error of KNN model by changing K

مقایسه نتایج مدل‌های هوشمند

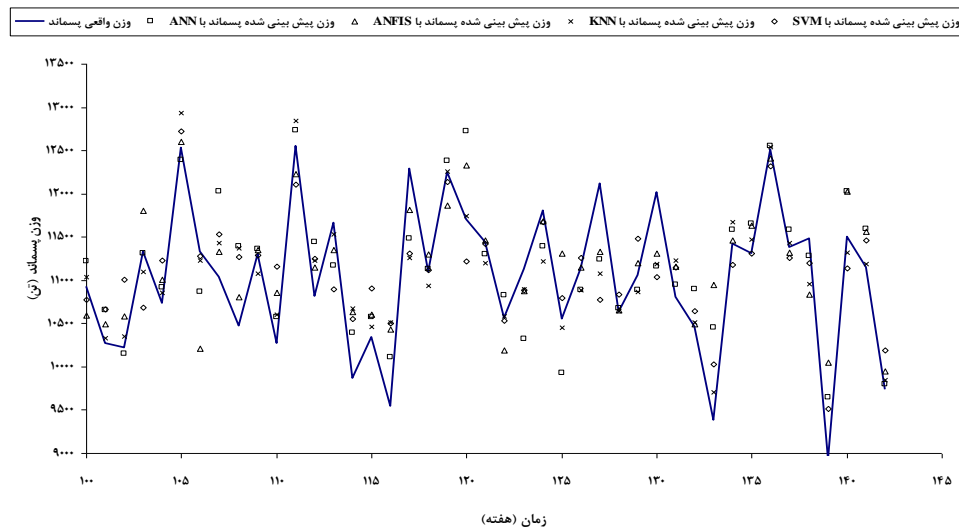
جهت مقایسه نتایج دوره آزمایش مدل‌های هوشمند از ضریب تشخیص، خطا و زمان مدل‌سازی مدل بهینه استفاده شد که در جدول (۴) آورده شده است. شکل (۵) نیز مشاهدات را نسبت به نتایج مدل‌های مختلف هوشمند مورد مطالعه در دوره آزمایش نشان می‌دهد. همان‌طور که در جدول (۴) دیده می‌شود، مدل SVM کم‌ترین خطا و بیش‌ترین ضریب تشخیص را داراست. این نشان می‌دهد که مدل SVM برای پیش‌بینی پدیده‌های طبیعی هم‌چون تولید پسماند بسیار کاراست. خطا و ضریب تشخیص مدل‌ها برای شهر تهران گرچه

قابل قبول است، مقدار آن پایین می‌باشد. برای افزایش کارایی مدل‌های هوشمند از روش‌های بهینه‌سازی استفاده می‌شود که در ادامه به آن پرداخته می‌شود. در رابطه با توانایی پیش‌بینی کمی پسماند توسط مدل‌های هوشمند، همان‌طور که در شکل (۵) نشان داده شده است، ضعف مدل‌ها بیش‌تر در پیش‌بینی مقادیر پیک پسماند می‌باشد. به‌طوری‌که مدل KNN بدترین عملکرد را به‌طور متوسط از خود نشان داده است و مقادیر پیش‌بینی شده توسط مدل SVM انطباق بیش‌تری با مقادیر مشاهده شده دارد. مدل ANFIS و مدل KNN نتایج قابل قبولی را نشان دادند.

جدول ۴- مقایسه خطای پیش‌بینی و زمان محاسبه مدل‌های هوشمند در مرحله تست

Table 4- Comparison of errors and calculation times of intelligent models in the test stage

آماره مدل	RME	R ²	MARE	RMSE	RME
ANN	۲۰۲۲۲۴۰	۰/۶۷۱	۰/۰۳۹	۵۳۷۲۲۹	۴۱۱۳۰۱
ANFIS	۲۰۶۵۲۱۴	۰/۶۸۹	۰/۰۳۸	۵۳۴۳۵۱	۴۱۳۵۹۷
SVM	۱۷۲۳۵۷۲	۰/۷۲۱	۰/۰۳۱	۴۵۰۷۴۷	۳۲۶۴۸۹
KNN	۲۰۵۹۳۵۵	۰/۶۴۱	۰/۰۳۸	۵۲۱۴۹۳	۴۱۳۸۵۳



شکل ۵- نتایج مدل‌های هوشمند در مرحله تست

Figure 5- Results of intelligent model in the test stage

ارایه متوسط پیش‌بینی جریان در هر هفته و مقایسه بیشتر دو مدل، از ۱۰۰۰ پیش‌بینی انجام شده توسط مدل‌ها برای هر هفته میانگین گرفته شد. شاخص‌های خطاستجی کمیت پسماند پیش‌بینی شده و مشاهداتی برای میانگین خروجی هر مدل پیش‌بینی محاسبه شد که در جدول (۵) نشان داده شده‌اند. در این جدول همچنین شاخص‌های ارزیابی عدم قطعیت شامل فاکتور D و درصد داده‌های مشاهده شده در پهنای باند اطمینان آورده شده است.

آنالیز عدم قطعیت مدل‌های هوشمند

همان‌طور که ذکر شد، یکی از اهداف مهم این تحقیق بررسی و تخمین عدم قطعیت در خروجی مدل‌های هوشمند می‌باشد که روش مونت کارلو مینا قرار داده شده است. نتایج ۱۰۰۰ بار پیش‌بینی کمیت پسماند مدل‌های منتخب هوشمند و حدود اطمینان ۹۵٪ مدل‌های پیش‌بینی شبکه عصبی، نروفازی، ماشین برداری پشتیبان و k-نزدیک‌ترین همسایه‌ها برای هفته آینده در شکل (۶) نشان داده شده است. همچنین به منظور

علت کاهش اریب در نتایج خروجی مدل‌ها باشد. بر این اساس در مورد مدل‌های SVM، ANFIS و ANN، میانگین هر هفته به عنوان بهترین پیش‌بینی می‌باشد.

نتیجه گیری

آگاهی از کمیت پسماند تولیدی یکی از عوامل مهم و اثرگذار در سیستم مدیریت مواد زاید جامد می‌باشد. تاکنون بررسی‌هایی در زمینه پیش‌بینی میزان تولید پسماند صورت گرفته اما کارایی مدل‌های هوشمند مختلف مورد بررسی قرار نگرفته است. با وجود اینکه مدل‌های هوشمند توانایی پیش‌بینی پدیده‌های پیچیده را دارد، اما نتایج این مدل‌ها دارای قطعیت نیست و استفاده از نتایج این مدل‌ها نیاز به آنالیز عدم قطعیت دارد. در این تحقیق برای تخمین میزان تولید پسماند شهری متغیرهای موثر بر تولید پسماند برای دوره‌ی ۱۳۷۹ تا ۱۳۸۸ به صورت هفتگی جمع‌آوری شد. ساختار بهینه مدل شبکه عصبی، نروفازی، ماشین بردار پشتیبان و k-نزدیک‌ترین همسایه‌ها برای پیش‌بینی کوتاه‌مدت کمیت پسماند ارایه گردید. بهینه‌سازی ساختار مدل‌ها با روش سعی و خطا انجام گرفت. برای ارزیابی عملکرد مدل‌ها از آماره‌های مختلف بهره گرفته شد تا دقیق‌ترین مدل تعیین گردد. مدل‌های جعبه‌ای و نیمه‌جعبه‌ای هوشمند یک مشکل عمده دارند و آن این است که نمی‌توان با روش‌های معمول آماری مقدار قطعیت نتایج مدل را تخمین زد. در این‌جا با روش مونت کارلو عدم قطعیت مدل‌ها بدست آمد که دست‌آورد ارزنده این تحقیق به‌شمار می‌رود. عدم قطعیت هر کدام از مدل‌ها به روش تخمین خروجی آن بستگی داشت. بطوریکه روش‌هایی که کاملاً تصادفی هستند مانند شبکه عصبی و KNN عدم قطعیت زیادی داشتند ولی روش‌های قانونمند نروفازی و SVM قوام زیادی داشتند و SVM بیشترین قطعیت را داشت. در حال حاضر، مطالعات مشابهی در زمینه پیش‌بینی کمیت پسماند توسط مدل‌های هوشمند وجود دارد. مقایسه مطالعات موجود با این تحقیق نشان می‌دهد، همانند مطالعات قبل مدل‌های هوشمند به‌طور قابل قبولی توانایی پیش‌بینی کمی پسماند را

همان‌طور که در شکل (۶) مشاهده می‌شود، در تمام زمان‌های پیش‌بینی شبکه SVM دارای عدم قطعیت کم‌ترین در مقادیر خروجی بوده و این امر درحالی بوده که با وجود کاهش قابل توجه عرض باند اطمینان ۹۵٪ آن نسبت به سایر مدل‌ها، تعداد داده‌های مشاهداتی که در این باند قرار گرفته‌اند، نیز نسبت به مدل‌های دیگر کاهش نشان می‌دهد. با توجه به شاخص عرض متوسط باند اطمینان بدست آمده (جدول (۵)) مشاهده می‌شود که شبکه KNN حساسیت بیش‌تری به ای دسته آموزش دارد، چنان‌چه حتی در مقادیر کم پسماند که توقع وجود عدم قطعیت کمی در پیش‌بینی آن‌ها می‌رود، KNN باند اطمینان بزرگ و نامناسبی را برآورد نموده است. مدل نروفازی هم باند اطمینان کوچکی را ایجاد نموده است ولی کاهش تعداد داده‌های مشاهداتی در باند اطمینان کاهش چشمگیری نمی‌کند. عدم قطعیت مدل نروفازی و ماشین بردار پشتیبان به خصوص در نواسانات کم واقع‌بینانه است ولی کاهش درصد تعداد داده‌های مشاهده شده در باند اطمینان نروفازی نسبت به SVM قابل توجه می‌باشد. نکته قابل توجه دیگری که با توجه به جدول (۵) به آن برمی‌خوریم، کاهش عرض باند اطمینان ۹۵٪ شبکه عصبی و KNN با افزایش افق پیش‌بینی می‌باشد که این امر برخلاف اصول احتمالاتی بوده و نشان می‌دهد که شبکه عصبی و KNN در پیش‌بینی‌های بلندمدت دارای ضعف و نوعی بی‌تفاوتی به داده‌ها می‌باشد در حالی که این نقیصه در مدل SVM و نروفازی کم‌تر به چشم می‌آید و این مدل‌ها روند منطقی‌تری را در عدم قطعیت پیش‌بینی‌های خود نشان می‌دهد.

همان‌طور که در جدول (۵) مشاهده می‌شود، پیش‌بینی‌های انجام شده توسط مدل‌های اولیه SVM، ANFIS و ANN و میانگین ۱۰۰۰ تکرار همان مدل‌ها نزدیک به هم می‌باشد که این امر نشان‌دهنده پایداری این مدل‌ها می‌باشد. تنها در مدل KNN تفاوت چشم‌گیر میان نتایج مدل اولیه و میانگین ۱۰۰۰ پیش‌بینی رانشان می‌دهد. هر چند پیش‌بینی‌های حاصل از میانگین شبیه‌سازی‌ها بجز KNN نسبت به نتایج مدل‌های منفرد کمی بهتر بوده‌اند که علت این امر می‌تواند به

- networks. Proceedings of the IFSA. World Congress 41991. pp. 82-6.
7. Aqil M, Kita, I., Yano A, Nishiyama S, 2007a. A comparative study of artificial neural networks and neuro-fuzzy in continuous modeling of the daily and hourly behaviour of runoff. *Journal of Hydrology*; Vol: 337, pp. 22-34.
 8. Aqil M, Kita I, Yano A, Nishiyama S, 2007b. Analysis and prediction of flow from local source in a river basin using a neuro-fuzzy modeling tool. *Journal of Hydrology Environmental Management*; Vol: 85, pp. 215-23.
 9. Wang XX, Chen, S., Lowe, D., Harris, C.J., 2006. Artificial neural networks based on principal component analysis input selection for quantification in overlapped capillary electrophoresis peaks. *Chemom Intell Lab Syst* Vol: 82, pp. 165-175.
 10. Akcayol MA, 2004. Application of adaptive neuro-fuzzy controller for SRM. *Advances in Engineering Software*; Vol: 35(3-4), pp. 129-37.
 11. Chang FJ, Chang, Y.T., 2006. Adaptive neuro-fuzzy inference system for prediction of water level in reservoir. *Advances in Water Resources*; Vol: 29(1), pp. 1-10.
 12. Nayak PC, Sudheer, K.P., Rangan, D.M., Ramasastri, K.S., 2004. A neuro-fuzzy computing technique for modeling hydrological time series. *Journal of Hydrology*; Vol: 291, pp. 1-17.
- دارد. گرچه، یافته‌های این مطالعه اطلاعات بیشتری را در زمینه مقایسه مدل‌های هوشمند و آنالیز عدم قطعیت نتایج این مدل‌ها و بررسی کارایی مدل KNN در پیش‌بینی کمی پسماند فراهم می‌آورد.
- مراجع
1. Dyson B, Chang N, 2005. Forecasting municipal solidwaste generation in a fast-grow in urban region with system dynamics modeling. *Waste Management*; Vol: 25, pp. 669-79.
 2. Noori R, Abdoli MA, Farokhnia A, Abbasi M, 2009. Results uncertainty of solid waste generation forecasting by hybrid of wavelet transform-ANFIS and wavelet transform-neural network. *Expert Syst Appl*; Vol: 36(6), pp. 9991-9.
۳. عبدلی، م.ع. مدیریت مواد زائد جامد: انتشارات سازمان بازیافت و تبدیل مواد، ۱۳۷۰.
4. Jalili GZM, Noori R, 2008. Prediction of municipal solid waste generation by use of artificial neural network: A case study of Mashhad. *Int J Environ Res*; Vol: 2(1), pp. 13-22.
۵. عبدلی، م.ع.، نوری، ر.، جلیلی، م.، صالحیان، ا.، پیش‌بینی زباله تولیدی تهران با استفاده از شبکه عصبی مصنوعی و روش‌های آماری چندمتغیره. سومین همایش ملی پسماند؛ تهران، ۱۳۸۶. ص. ۶۱-۷۲.
6. Jang JSR, Gulley, N. Rule extraction using generalized neural

18. Benardos PG, Vosniakos GC, 2007. Optimizing feedforward artificial neural network architecture. *Engineering Applications of Artificial Intelligence*; Vol: 20(3), pp. 365-82.
19. Tang Z, Fishwick PA, 1993. Feedforward neural nets as models for time series forecasting. *ORSA journal on computing*; Vol: 5(4), pp. 374-85.
20. Buragohain M, Mahanta C, 2008. A novel approach for ANFIS modelling based on full factorial design. *Applied Soft Computing*; Vol: 8(1), pp. 609-25.
21. Chiu SL, 1994. model identification based on cluster estimation. *Journal of Intelligent and Fuzzy Systems*; Vol: 2(3), pp. 267-78.
22. Yakowitz S, 1987. Nearest-neighbour methods for time series analysis. *Journal of Time Series Analysis*; Vol: 8(2), pp. 235-47.
23. Ulam s ,1949 .The Monte Carlo method. *Journal of the American Statistical Association*; Vol: 44 (247), pp. 335-41.
24. Vapnik V. *Nature of Statistical Learning Theory*. Springer. 1995.
13. Chen HW, Chang N-B, 2000. Prediction analysis of solid waste generation based on grey fuzzy dynamic modeling. *Resources, Conservation and Recycling*; Vol: 29, pp. 1-18.
14. Abbasi M, Abduli MA, Omidvar B, Baghvand AY, Forecasting Municipal Solid waste Generation by Hybrid Support Vector Machine and Partial Least Square Model. *Vol: (7)*, pp. 27-33.
15. Abbasi M, Abduli MA, Omidvar B, Baghvand A, 2014. Results uncertainty of support vector machine and hybrid of wavelet transform-support vector machine models for solid waste generation forecasting. *Environmental Progress & Sustainable Energy*; Vol: 33(1), pp. 220-8.
16. Abbasi M, El Hanandeh A, 2016. Forecasting municipal solid waste generation using artificial intelligence modelling approaches. *Waste Management*; Vol: 56, pp. 13-22.
17. Abbass HA, 2002. An evolutionary artificial neural networks approach for breast cancer diagnosis. *Artificial Intelligence in Medicine*; Vol: 25(3), pp. 265-81.