

بهبود مدل‌سازی تولید پسماند شهری با استفاده از یادگیری عمیق و مقایسه با مدل‌های هوشمند

شبکه عصبی و ماشین بردار پشتیبان

مریم عباسی^{۱*}، سهیل کریمی درمیان^۲

^۱ نویسنده مسئول: دکتری، دانشکده مهندسی عمران، آب و محیط‌زیست، دانشگاه شهید بهشتی، شهر، ایران. mary_abbasi@sbu.ac.ir

^۲ دانشجوی کارشناسی ارشد، دانشکده مهندسی عمران، آب و محیط‌زیست، دانشگاه شهید بهشتی، شهر، ایران

چکیده

هدف از این پژوهش بررسی و مقایسه عملکرد مدل‌های هوشمند در مدل‌سازی کمی پسماند شهری است. ابتدا مولفه‌های موثر بر تولید پسماند شامل اطلاعات جغرافیایی، اجتماعی، هواشناسی، فرهنگی، اقتصادی بصورت ماهانه و فصلی جمع‌آوری گردید. سپس به مدل‌سازی کمی پسماند شهری در شهر تهران با استفاده از مدل‌های هوشمند شبکه عصبی مصنوعی، ماشین بردار پشتیبان و یادگیری عمیق پرداخته شده و نتایج و خطاهای بدست آمده از آن‌ها مورد بررسی قرار گرفته است. طبق مدل‌سازی‌های انجام شده نتیجه گرفته شد: مدل رگرسیون و شبکه عصبی مصنوعی کمترین R^2 و بیشترین RMSE و MAE را دارند و مدل‌سازی دقیقی انجام نمی‌دهند. بر اساس معیارها و خطاهای بدست آمده این نتیجه حاصل شد که هم در دوره ماهانه و هم در دوره فصلی به ترتیب یادگیری عمیق، مدل ماشین بردار پشتیبان، شبکه عصبی مصنوعی و در آخرین رتبه رگرسیون در مدل‌سازی دقیق عمل کرده‌اند. مدل ماشین بردار پشتیبان و مدل یادگیری عمیق هم در دوره فصلی و هم در دوره ماهانه کمترین خطاها را در بین مدل‌های آزمایش شده دارند. در مدل‌سازی ماهانه ارقام مشاهده شده به ارقام پیش‌بینی شده توسط مدل یادگیری عمیق از دیگر مدل‌ها نزدیک‌ترند و تطابق بیشتری دارند. به علاوه مدل یادگیری عمیق در مدل‌سازی فصلی نیز دقیق‌تر از دیگر مدل‌های آزمایش شده عمل کرده. لازم به ذکر است که الگوریتم یادگیری عمیق در مدل‌سازی فصلی از مدل‌سازی ماهانه دقیق‌تر عمل کرده است؛ زیرا تغییر وزن پسماند بیشتر به صورت فصلی تغییر می‌کند و الگوی فصلی را دنبال می‌کند. طبق منحنی یادگیری نتیجه گرفته شد مدل‌ها در دوره فصلی بهتر عمل می‌کنند و مقدار پیش‌بینی شده و مشاهده شده در مدل‌سازی فصلی بیشتر به هم نزدیک هستند.

واژه‌های کلیدی: مدیریت پسماند، پسماند شهری، مدل‌سازی، یادگیری عمیق، نرخ تولید پسماند، مدیریت اصولی، یادگیری ماشین

۱- مقدمه

افزایش مهاجرت به کلان شهرها در کشورهای در حال توسعه از یک طرف و کمبود زیرساخت‌های مناسب زیست‌محیطی از طرف دیگر، باعث مشکلات زیستی گوناگونی برای این گونه شهرها شده است. یکی از بزرگ‌ترین این مشکلات، مدیریت مواد زائد جامد این گونه شهرها می‌باشد. طرح ریزی سیستم‌های مدیریت پسماند شهری جهت برآورده ساختن افزایش تقاضا برای دفن و تصفیه پسماند، اغلب به فاکتورهای موثری نظیر روش جمع‌آوری، نظارت بر اجرای قوانین و تجهیزات مدیریت پسماند می‌باشد. مدیریت پسماند جامد شهری نقش مهمی در تحقق اهداف توسعه پایدار دارد. شهرنشینی فعلی، رشد سریع جمعیت و توسعه اقتصادی منجر به ایجاد مقادیر زیادی پسماند شهری شده است که نیاز به تصفیه و دفع دارد. سیستم مدیریت مواد زائد جامد کلان شهرها در کشورهای در حال توسعه، همواره با مشکلات فراوانی روبرو بوده است. ایجاد چنین سیستمی به خاطر پیچیدگی و طبیعت بسیار ناممکن تولید پسماند و دخالت عوامل غیر قطعی در آن مشکلات خاص خود را دارد. از طرفی بی‌توجهی به این امر نیز می‌تواند سلامت جامعه را با خطرات زیادی روبرو کند. اولین قدم برای تعیین یک برنامه صحیح و دقیق مدیریت مواد زائد جامد شهری، آگاهی کامل از کمیت و کیفیت از سه جنبه فیزیکی، شیمیایی و بیولوژیکی حائز اهمیت مواد زائد جامد است. آگاهی و شناخت کامل از ویژگی‌های مواد زائد جامد، نقش بسیار مهمی در ارزیابی، طراحی و انتخاب تجهیزات مناسب مربوط به سیستم دفع، بازیافت پسماند و نیز امکان بازیابی مواد و انرژی دارد.

پیش‌بینی کمیت تولید در مواردی که برنامه‌های بازیافتی در اولویت نباشند (بطور مثال در کشورهای توسعه نیافته و در حال توسعه، نسبت به کیفیت تولید می‌تواند از اهمیت بیشتری برخوردار باشد. زیرا این امر با تأثیر مستقیم بر تعیین حجم سرمایه‌گذاری برای ماشین‌آلات، ظروف ذخیره در محل، ایستگاه‌های انتقال، ظرفیت دفع، سازماندهی و تشکیلات مناسب، همراه می‌باشد. در نتیجه توسعه مدلی معتبر برای پیش‌بینی تأثیر همزمان عواملی مانند تغییرات جمعیت، اقتصادی بودن، بازیافت یا بازچرخش روی تولید پسماند می‌تواند در اجرای روش‌های مدیریت پسماند بسیار سودمند باشد.

فرآیندهای مدیریت پسماند معمولاً شامل مولفه‌های فنی، اقلیمی، زیست‌محیطی، جمعیتی، اجتماعی-اقتصادی و قانونی متعددی است. چنین فرآیندهای غیرخطی پیچیده‌ای برای مدل‌سازی، پیش‌بینی و بهینه‌سازی با استفاده از روش‌های مرسوم چالش برانگیز هستند. اخیراً، تکنیک‌های هوش مصنوعی در ارائه رویکردهای محاسباتی جایگزین برای حل مشکلات مدیریت پسماند جامد شتاب بیشتری به دست آورده‌اند. هوش مصنوعی در مقابله با مشکلات نامشخص، یادگیری از تجربه، و مدیریت عدم قطعیت و داده‌های ناقص کارآمد بوده است. مدل‌های هوش مصنوعی مانند شبکه عصبی مصنوعی^۱، سیستم خبره، الگوریتم ژنتیک^۲ و منطق فازی^۳ قابلیت حل مشکلات نامشخص، پیکربندی نقشه‌های پیچیده و پیش‌بینی نتایج را دارند [1].

هر مدل یا شاخه از هوش مصنوعی عملکرد به خصوص خودش را دارد. برای مثال، مدل‌های شبکه عصبی مصنوعی می‌توانند داده‌ها را برای طبقه‌بندی و پیش‌بینی آموزش دهند. علاوه بر این، شبکه عصبی مصنوعی می‌تواند برای مدیریت داده‌های بزرگ در جغرافیای شهری و انجام تحلیل‌های جغرافیایی استفاده شوند. سیستم‌های خبره، مانند منطق فازی، می‌توانند علاوه بر داشتن پایگاه اطلاعاتی، مهارت‌های شناختی و استدلالی انسانی را نیز کسب کنند. این سیستم‌ها یک دستور زبانی ساده دارند که در مدیریت عملیات پیچیده و ویژگی‌های کیفی مهارت دارد [1]. از سوی دیگر، الگوریتم‌های تکاملی، مانند الگوریتم ژنتیک، مفهوم انتخاب طبیعی را برای به دست آوردن نتایج بهینه با انتخاب بهترین داده‌های مناسب برای مدیریت شرایط پیش‌بینی نشده اتخاذ می‌کنند [۲].

باتوجه به پیشرفت فناوری‌های هوش مصنوعی و محدودیت‌های تکنیک‌های محاسباتی مرسوم، مدل‌های مبتنی بر هوش مصنوعی

1 Artificial Neural Network (ANN)

2 Genetic Algorithm (GA)

3 Fuzzy logic (FL)

در حال حاضر تقریباً در تمام زمینه‌های تحصیلی از جمله پزشکی، زبان‌شناسی و مهندسی در میان دیگران گنجانده شده‌اند [2]. قابلیت‌های تکنیک‌های مدل‌سازی هوش مصنوعی در مدیریت داده‌های چند بعدی، نوپز، افزایش زمینه‌های کاربردی هوش مصنوعی را ثابت می‌کند. در زمینه مهندسی محیط زیست، هوش مصنوعی به طور گسترده برای حل مشکلات مربوط به آلودگی هوا، مدل‌سازی تصفیه آب و فاضلاب، شبیه‌سازی اصلاح خاک و آلودگی آب زیرزمینی و همچنین برنامه‌ریزی استراتژی‌های مدیریت پسماند جامد اجرا شده است.

ابزارهای مدیریت ریسک مبتنی بر هوش مصنوعی مانند شبکه عصبی مصنوعی، پرسپترون چند لایه^۱، و مدل‌های سیستم استنتاج عصبی فازی تطبیقی^۲ برای پیش‌بینی غلظت آلاینده‌ها و ذرات معلق اجرا شدند [۳]. علاوه بر این، ثابت شده است که پرسپترون چند لایه یک الگوریتم مدل‌سازی کارآمد برای پیش‌بینی سطوح مونوکسید کربن، ازن و دی‌اکسیدنیترژن در جو است [۴]. از سوی دیگر، سیستم استنتاج عصبی فازی تطبیقی برای پیش‌بینی و بهینه‌سازی فرآیندهای تصفیه‌خانه آب و فاضلاب مفید بوده [۵، ۶]. علاوه بر بهینه‌سازی مقدار منعقد کننده برای حذف کدورت در یک تصفیه‌خانه آب، سیستم استنتاج عصبی فازی تطبیقی به طور موثر تولید متان و مواد جامد فرار پساب یک هاضم بی‌هوازی را در یک تصفیه‌خانه فاضلاب پیش‌بینی کرد [7]. در حال حاضر در زمینه مدیریت پسماند جامد، هوش مصنوعی به طور گسترده برای پیش‌بینی الگوهای تولید پسماند، بهینه‌سازی مسیرهای کامیون جمع‌آوری پسماند، مکان‌یابی امکانات مدیریت پسماند، و شبیه‌سازی فرآیندهای تبدیل پسماند و سایر موارد استفاده می‌شود.

یک پیش‌بینی قابل اعتماد از تولید پسماند جامد شهری باید برای ایجاد یک برنامه مدیریت پسماند جامد پایدار در سطح شهر یا کشور در دسترس باشد. به عنوان مثال، جیسون و همکاران [۸] از یک مدل رگرسیون برای پیش‌بینی تولید پسماند جامد شهری در سراسر شهر نیویورک استفاده کرد و یک مدل مکانی-زمانی را به کار برد. این مدل‌ها به بهبود جمع‌آوری پسماند و توزیع وسایل نقلیه جمع‌آوری پسماند و توسعه استراتژی‌های کاهش پسماند کمک کردند. یک مدل پیش‌بینی تولید پسماند جامد شهری و تحلیل سناریو برای بررسی تأثیر سیاست‌های فعلی پسماند تا سال ۲۰۵۰ در جزایر بالئاریک استفاده شد. نتایج پیش‌بینی شده و سناریویی مشخص کرد که سناریوی خوش‌بینانه مقدار پسماند جامد شهری ارسال شده به محل‌های دفن پسماند را تا ۴۰ درصد کاهش داد و جمع‌آوری انتخابی را ۳۰ درصد افزایش داد [9]. دی فوگیا و همکاران [۱۰] از یک روش اقتصادسنجی مبتنی بر مدل رگرسیون برای برآورد هزینه‌های تاسیسات پسماند در ایتالیا استفاده کردند. نتایج حاصل از این مدل نشان می‌دهد که ایتالیا می‌تواند استفاده از محل دفن پسماند را کاهش دهد و ظرفیت انرژی پسماند را افزایش دهد که منجر به تأثیر مثبت‌تر صرفه‌جویی در هزینه بر مدیریت پسماند می‌شود.

انتخاب یک مدل پیش‌بینی مناسب به اهداف، مدت زمان پیش‌بینی (کوتاه‌مدت، میان‌مدت یا بلندمدت) و در دسترس بودن داده‌ها بستگی دارد. تحلیل رگرسیون خطی یک رویکرد اساسی است که در پیش‌بینی پسماند جامد شهری مفید است [۱۱]. با این حال، برای تولید نتایج ثابت و قابل اعتماد به داده‌های ورودی زیادی نیاز دارد [۱۲]. مدل دیگری که به طور گسترده برای پیش‌بینی پسماند جامد شهری استفاده می‌شود، شبکه عصبی مصنوعی^۳ است. شبکه عصبی مصنوعی یک مدل غیر خطی مبتنی بر ریاضی است. برای تخمین تولید ضایعات هفتگی و ماهانه استفاده شده است و عملکرد خوب و نتایج بهتری نسبت به تحلیل رگرسیون مؤلفه اصلی ارائه می‌دهد [۱۳]. با این وجود، مدل شبکه عصبی مصنوعی به چندین ماه داده تولید پسماند برای پیش‌بینی بلندمدت نیاز دارد [۱۴]. در صورتی که اطلاعات ورودی کافی وجود نداشته باشد، هر دو تحلیل رگرسیون و شبکه عصبی مصنوعی کاربرد محدودی

¹ Multilayer Perceptron (MLP)

² Adaptive Fuzzy Neural Inference System (ANFIS)

³ Artificial Neural Network (ANN)

دارند. هنگام استفاده از داده های محدود، مدل های پیش بینی موجود شامل پویایی سیستم^۱، مدل خاکستری^۲ و منطق فازی است. مدل پویایی سیستم زمانی که در دسترس بودن داده محدود باشد، جایگزین مناسبی را ارائه می دهد. برای شبیه سازی تولید پسماند جامد شهری و ارزیابی جداسازی منبع، ظرفیت تصفیه پسماند و مدیریت هزینه استفاده شده است [۱۵]. مدل سازی پویایی سیستم می تواند برای سیاست گذاران و مدیران بهداشتی مفید باشد تا دیدگاه گسترده ای از مدیریت پسماند ارائه دهند. با این حال، نسبتاً پیچیده است و به پردازش نرم افزار پیشرفته نیاز دارد [۱۶].

یکی از مدل های ریاضی پرکاربرد برای پیش بینی محیطی مدل خاکستری نظریه سیستم خاکستری است که توسط جو لانگ [۱۷] معرفی شد. مزیت مدل خاکستری توانایی آن برای کار با داده های محدود (حداقل چهار نقطه داده مورد نیاز) است. چاهای وهمکارنش^۳ از مدل خاکستری تک متغیره با ۱۶ مجموعه داده سالانه برای پیش بینی تولید پسماند جامد شهری برای ۱۵ سال آینده استفاده کرد. ژانگ و همکاران (۲۰۱۹) همچنین از مدل خاکستری چند متغیره برای پیش بینی تولید پسماند جامد شهری برای پنج سال آینده با استفاده از نه مجموعه داده سالانه استفاده کرد.

رفتار پیچیده یک سیستم را می توان با استفاده از پویایی سیستم مورد آزمایش قرار داد، یک روش مدل سازی محاسباتی برای تفکر سیستمی که توسط فارستر^۴ [۱۹] ایجاد شده است، ما را قادر می سازد تا تعامل بین عناصر یا عوامل مختلف در یک سیستم را بررسی کنیم. این روش در پیش بینی تولید پسماند بر اساس داده های محدود بسیار مؤثر [۲۰، ۲۱] و در بررسی استراتژی های مدیریت پسماند برای جریان پسماند بخصوصی مانند مواد غذایی و بخش های زیست تخریب پذیر پسماندهای جامد شهری در هنگ کنگ (چین) [۲۲] و شهر اویتا (ژاپن) [23]؛ پسماند های ساخت و ساز و تخریب در هنگ کنگ (چین) [۲۴]؛ و ضایعات تجهیزات الکتریکی و الکترونیکی^۵ در چین [۲۵] استفاده شده است. توازن جزیی جرم و انرژی که کارایی فن آوری های تصفیه را برای محاسبه تولید محصول اصلی، انتشار و تلفات ترکیب می کند، در این مدل ها به اندازه کافی در نظر گرفته نمی شود. چنین محدودیت هایی اغلب منجر به پیش بینی نادرست منابع واقعی قابل بازیافت، هزینه ها و منافع اقتصادی و همچنین اثرات محیط زیستی مرتبط با انتشار گازهای گلخانه ای و تلفات غیر عمدی برای محیط می شود. علاوه بر این، مشاهده می شود که این مدل های پویایی سیستم، مکان های خاص هستند که به شدت به ویژگی پسماند، رفتار شهروندان و زیرساخت ها و سیاست های مدیریت پسماند در آن مناطق وابسته هستند. همچنین، ویژگی ها و فرمول بندی مدل به هدف و مرز خاص (به عنوان مثال زمان/دوره و موقعیت جغرافیایی) مطالعه بستگی دارد. این نشان می دهد که مدل ها را نمی توان مستقیماً برای اهداف دیگر یا مطالعات موردی اتخاذ کرد زیرا ممکن است منجر به نتیجه گیری های ناقص شود.

مدل پویایی سیستم جهت سیاست گذاری در زمینه مدیریت پسماند در مطالعات موردی خاص مناطق قبلی نشان داده شده است، که می توان به مدل های بالادست (تولید پسماند)، پایین دست (تصفیه و دفع پسماند) و مدل های هیبریدی بالادست و پایین دست طبقه بندی کرد. برای مدل سازی بالادست، دایسون و چانگ [۲۰] مدل های شبیه سازی پویا را برای پیش بینی تولید پسماند جامد در سن آنتونیو، تگزاس (ایالات متحده آمریکا) با توجه به دستیابی به برآورد بهتری برای ظرفیت تأسیسات بازیابی مواد^۶ در آن منطقه توسعه دادند. این اثر عوامل مختلفی از جمله جمعیت، درآمد خانوار، افراد به ازای هر خانوار، کل درآمد به ازای هر مرکز خدمات و میزان تاریخی تولید شده را در نظر گرفته است. مطالعه اخیر دیگری که توسط سالز من و شارپ [۱۵] در سال ۲۰۱۶ انجام

¹ System Dynamics (SD)

² Gray Model (GM)

³ Chhay, Reyad, Suy, Islam and Mian

⁴ Forrester

⁵ Waste Electrical And Electronic Equipment (WEEE)

⁶ Material Recovery Facilities (MRF)

شد، تأثیر تفکیک از منبع را بر جمع آوری پسماند در بانکوک (تایلند) بررسی کرد. برای مدلسازی پایین دست در سال ۲۰۰۷ با توجه به ترویج شیوه‌های بازیافت خانگی در سوئیس، تأثیر استراتژی‌های مختلف قیمت‌گذاری و انگیزشی را بر رفتار انسانی و اهداف بودجه با استفاده از رویکرد پویایی سیستم بررسی شد [۲۶]. مدیریت پایدار پسماند بر اساس اصول سلسله مراتب پسماند (پیشگیری، استفاده مجدد، بازیافت، بازیافت و دفع) از طریق روش‌های جمع‌آوری و تصفیه مجزا در گذشته به طور گسترده انجام نمی‌شد و از این رو مطالعات قبلی گزینه‌های پردازش جریان‌های مختلف پسماند را در نظر نگرفته‌اند. صوفیان و همکاران [۲۷] تلاش کردند پتانسیل تولید برق و کل تقاضای برق از پسماند جامد در داکا (بنگلادش) را با ارتباط تولید پسماند جامد با جمعیت تخمین بزنند. مطالعات اخیر مدل‌های ترکیبی جامع‌تری را برای بررسی تولید جریان‌های پسماند جمع‌آوری‌شده جداگانه و گزینه‌های تصفیه مرتبط در نظر گرفته‌اند [۲۱، ۲۸، ۲۹]. با در نظر گرفتن گزینه‌های مختلف پردازش پسماند در شهر نیویورک (ایالات متحده آمریکا) می‌توان تأثیر گزینه‌های پیشگیری از تولید پسماند را با استفاده از یک مدل شبیه‌سازی پویا بر نرخ تولید پسماند جامد شهری، ظرفیت باقی مانده دفن پسماند و هزینه یا سود اقتصادی بررسی کرد. این مدل همان اصول و ساختاری را دارد که در ابزار پیش‌بینی پسماند ارزیابی چرخه عمر مدیریت یکپارچه زباله^۲ [۳۰] با گنجاندن یک ماژول تخمین ظرفیت دفن پسماند اضافی و عوامل اجتماعی-اقتصادی و جمعیت شناختی مثل تراکم جمعیت، تولید ناخالص داخلی، امید به زندگی در بدو تولد، نرخ مرگ و میر نوزادان و نیروی کار برای پیش‌بینی میزان تولید پسماند استفاده می‌کند. یک مدل پویایی سیستم را با بهره‌برداری از روابط بین تولید ناخالص داخلی، جمعیت و رفتار جمع‌آوری انتخابی توسعه دادند و اثربخشی اقدامات قانونی را برای مدیریت پسماندهای خانگی در فلاندر (بلژیک) که شامل جمع‌آوری، استفاده مجدد، بازیافت و دفع بود را بررسی کردند. یک مدل پویایی سیستم را برای نمایش سناریوی مدیریت پسماند جامد شهری در آراکونارا (برزیل) برای اهداف برنامه ریزی مالی، متشکل از تولید پسماند و مقصد، جریان‌های بازیافت، ماژول‌های درآمد و هزینه توسعه دادند. شرکت ساستین^۳ دو مدل پویایی سیستم، یعنی مدل‌های بازیافت بسته‌بندی پلاستیکی و پیشگیری از تولید پسماند را در جهت کمک به سیاست‌گذاری در این زمینه برای وزارت محیط زیست، غذا و امور روستایی انگلستان^۴ ایجاد کرده است [۳۱]. اگرچه این مدل‌ها تا سطحی از جزئیات توسعه داده شده‌اند که می‌تواند برای بررسی اثربخشی مداخلات سیاستی (با توجه به کالیبراسیون، آزمایش و اعتبارسنجی بیشتر) مورد استفاده قرار گیرند، اما کاربرد آن‌ها هنوز به جریان‌های پسماند خاص محدود می‌شود. جریان پسماند باقیمانده (یا پسماند‌های عمومی) حاوی مقدار قابل توجهی از مواد است که به طور بالقوه قابل بازیافت یا بازاستفاده هستند، اما اغلب در مطالعات موجود نادیده گرفته می‌شوند. بسیار مهم است که هنگام انجام ارزیابی‌های اولیه، همه جریان‌های پسماند را به صورت جمعی در نظر گرفت تا بتوان پیش‌بینی مطمئن‌تری از عملکرد مدیریت پسماند و پتانسیل بازیافت منابع در سطح منطقه‌ای یا کشوری به دست آورد. نظارت به جریان‌های پسماند خاص بدون ارزیابی کلی‌نگر در سیستم مدیریت پسماند ممکن است منجر به تغییر بار محیط‌زیستی در هنگام در یک منطقه خاص شود و یا ممکن است پتانسیل کامل بازیابی منابع را تضعیف کند.

در حال حاضر تمرکز زیادی بر روی روش‌های یادگیری ماشین در زمینه‌های زیست محیطی [۳۲]، مانند آب [۳۳]، هوا [۳۴]، خاک [۳۵] و انرژی [۳۶] است. در مقایسه با دیگر زمینه‌ها، تحقیقات کمتری در مورد کاربرد یادگیری ماشین و هوش مصنوعی در مدیریت پسماند جامد شهری انجام شده است، در حالی که در صورت انجام مطالعه در مورد مسئله‌ای چون حمل و نقل پسماند می‌توان از طرح‌ها و مسیرهای حمل‌ونقل نامناسب و ناکارآمد که عامل اتلاف منابع انسانی، فیزیکی و مالی زیادی هستند و انتشار گازهای گلخانه‌ای را افزایش می‌دهند جلوگیری کرد [۳۷، ۳۸].

¹ Municipal Solid Waste (MSW)

² Life Cycle Assessment Of Integrated Waste Management

³ Sustain Ltd

⁴ Department for Environment, Food and Rural Affairs (DEFRA)

اخیراً، یادگیری عمیق به عنوان یک روش قدرتمند برای یادگیری خودکار نمایش ویژگی‌ها از داده‌ها ظاهر شده است و به طور گسترده در بسیاری از حوزه‌های مرتبط با علم، تجارت و دولت به کار گرفته شده است [۳۹]. در مطالعه‌ای که توسط ژانگ در سال ۲۰۲۳ برای دسته‌بندی و پیش‌بینی پسماند تولیدی انجام شد، از مدل یادگیری عمیق دوگانه استفاده کردند و به این روش عملکرد بسیار خوبی را در حل مسائل غیرخطی، تغییرات زمانی، چندمنبعی و اهداف چندگانه نشان داده است [۴۰، ۴۱]. همچنین در مطالعه دیگری که در سال ۲۰۲۳ در جهت مدیریت پسماند جامد شهری با استفاده از مدل‌های یادگیری ماشین انجام شده، این مدل‌ها را به عنوان یک راهکار اصلی و اساسی برای بهبود مسیرهای جمع‌آوری، دسته‌بندی و مدیریت پسماندها در جهت افزایش سلامت و بهداشت جامعه دانسته‌اند [۴۲]. این امر نشان‌دهنده این است که، یادگیری عمیق پتانسیل زیادی برای استفاده در زمینه مدیریت پسماند جامد شهری دارد. یادگیری عمیق از جمله مدل‌هایی است که در حل مسائل پیچیده موفق عمل نموده است. با این حال، مفاهیم و شیوه‌های یادگیری عمیق به طور گسترده توسط تحقیقات در مدیریت پسماند جامد شهری مورد استفاده قرار نگرفته است. هدف از این مطالعه، معرفی و مقایسه الگوریتم‌های یادگیری عمیق و همچنین بحث در مورد کاربرد وضعیت یادگیری عمیق، چالش‌ها، فرصت‌های آینده این ابزار در مدیریت پسماند جامد شهری برای برجسته کردن پتانسیل ابزار یادگیری عمیق در زمینه مدیریت پسماند جامد شهری است.

در این مطالعه، شهر تهران به عنوان مطالعه موردی انتخاب شده زیرا یکی از کلان‌شهرهای تولیدکننده عمده پسماند شهری در ایران است. بهبود عملکرد مدل هوشمند پیش‌بینی کمی پسماند با الگوریتم یادگیری عمیق تا به حال در دنیا و کشور بکارنگرفته شده است. وجود یک مدل کارا در تخمین بهره‌وری فن‌آوری‌های تصفیه و پتانسیل بازیافت، هزینه‌ها و سود اقتصادی و همچنین اثرات محیط‌زیستی ضروری است. پسماندهای شهری تمرکز اصلی این مطالعه است، زیرا از ترکیبی از منابع ناهمگن تشکیل شده است که در صورت اجرای روش‌های تفکیک، جمع‌آوری و تصفیه مناسب، به طور بالقوه قابل بازیافت هستند. این مدل مولفه‌های موثر بر تولید پسماند را در نظر می‌گیرد. و با در نظر گرفتن متغیرهای اجتماعی-اقتصادی و محیطی پیش‌بینی دقیقی را امکان‌پذیر می‌سازد. اهداف این مطالعه شامل (الف) ایجاد یک مدل هوشمند جامع جهت مدلسازی میان‌مدت و بلندمدت کمی پسماند (ب) بررسی دقت مدل با استفاده از داده‌های مدیریت پسماند در شهر تهران به عنوان مطالعه موردی و (ج) مقایسه مدل‌های هوشمند موفق بکارگیری شده در مدلسازی پسماند طبق مرور ادبی با الگوریتم یادگیری عمیق می‌باشد.

۲- مواد و روش‌ها

یادگیری عمیق با همان یادگیری ژرف یکی از مباحث جدید در هوش مصنوعی و یادگیری ماشین است. یادگیری عمیق یکی از اشکال تخصصی یادگیری ماشین است. در یادگیری ماشین، فرایند گردشکار با ویژگی مربوط به خود، یعنی استخراج از تصاویر به شکل دستی، آغاز می‌شود. سپس از این ویژگی‌ها برای ایجاد مدلی استفاده می‌شود که قادر است اشیا و وسایل موجود در تصاویر را طبقه‌بندی کند. علاوه بر این، در الگوریتم یادگیری عمیق، جایی که به یک شبکه داده‌های خام، داده شود، وظیفه طبقه‌بندی داده‌ها را نیز به صورت خودکار یاد می‌گیرد و انجام می‌دهد. تفاوت دیگر، در مقیاس الگوریتم یادگیری عمیق با داده‌ها است. یادگیری ماشینی همگرا است. این نوع یادگیری به روش‌هایی اطلاق می‌شود که با اضافه شدن اطلاعات، سطح مشخصی از عملکرد را ایجاد می‌کنند. یکی از ویژگی‌های مثبت الگوریتم یادگیری عمیق این است که با افزایش اندازه، داده‌ها به پیشرفت خود ادامه می‌دهند. در یادگیری ماشین، نوعی طبقه‌بندی را به همراه ویژگی‌های آن به صورت دستی برای مرتب‌کردن تصاویر انتخاب می‌کنید. اما در سیستم یادگیری عمیق، مراحل مدلسازی و همچنین استخراج ویژگی‌ها به صورت خودکار انجام می‌شود. با این کار، ماشین درک بهتری از واقعیت وجودی داده‌ها پیدا کرده و می‌تواند الگوهای مختلف را شناسایی کند. در این تحقیق علاوه بر بررسی میزان تأثیر عوامل مختلف روی تولید پسماند شهری از یادگیری عمیق برای مدلسازی کمی پسماند استفاده می‌گردد.

۲-۱- منطقه مورد مطالعه (شهر تهران)

شهر تهران بزرگ‌ترین شهر و پایتخت ایران، مرکز استان تهران و شهرستان تهران است. سازمان بازیافت و تبدیل مواد شهرداری

تهران، سرانه تولید پسماند روزانه هر شهروند ساکن تهران را ۸۰۰ تا ۸۵۰ گرم اعلام کرده است. همچنین سرانه تولید روزانه پسماند برای هر ایرانی را ۶۰۰ تا ۶۵۰ گرم عنوان شده و این مقدار بسیار بیشتر از استانداردهای جهانی است. به طور کلی در کشور ایران تنها ۸ درصد از پسماندهای شهری بازیافت، کمپوست و مجدداً استفاده می‌شوند و ۹۲ درصد آن دفن می‌شود. از این مقدار دفع، فقط ۲۵ درصد بهداشتی و اصولی است و بقیه آن‌ها غیر بهداشتی دفن می‌شوند. با احتساب جمعیت حدود ۷۰ میلیونی ایران روزانه حدود ۴۷۰۰۰ تن پسماند (۲۳۰۰۰ تن پسماند شهری، ۱۶۰۰۰ تن پسماند روستایی، ۸۰۰۰ تن پسماند صنعتی و حدود ۵۰۰ تن پسماند بیمارستانی) در کشور انباشته، جمع‌آوری و ساماندهی می‌شود [43]. بر اساس اطلاعات موجود، سرانه تولید روزانه پسماند به نسبت جمعیت ساکن شهر تهران در سال ۱۳۸۵ به طور متوسط ۷۴۶ گرم بر نفر بوده است که این رقم برای منطقه ۱۲ معادل ۱۲۰۴ گرم و برای منطقه ۱۴ معادل ۶۰۴ گرم است [۴۴].

بر اساس آمار سال ۱۳۸۵، در کلان شهر تهران بالغ بر ۷۴۴۹/۷ تن در روز انواع پسماند تر و خشک تولید گردیده است. در سال ۱۳۸۵، ۳/۱۰۳٪ معادل ۲۳۱/۱۹ تن در روز در مبدأ تفکیک شده است. در این سال ۹۰۹/۶ تن در روز (۱۲/۲۱٪) از پسماند جامد شهر تهران به کمپوست تبدیل گردیده است. باقیمانده پسماند شهر تهران که معادل ۶۰۶/۳۵ تن (۸۱٪ از کل) می‌باشد، بصورت نیمه بهداشتی دفن شده است. بررسی روند تولید پسماندهای جامد شهر تهران در طول پنج سال گذشته مؤید آن است که نرخ رشد تولید پسماندهای جامد در این شهر برابر ۲/۰۵۵٪ در سال می‌باشد.

در سال‌های ۷۸ و ۸۲ بررسی‌هایی در جهت شناسایی کیفیت پسماندهای شهر تهران انجام گردید [۴۵]. درصد انواع پلاستیک در سال ۸۲ نسبت به سال ۷۸ افزایش نشان می‌دهد. علت این امر، استفاده روز افزون از محصولات پلاستیکی در سبد خانوار است. در خصوص افزایش میزان تولید نایلون و مشما در بافت پسماند شهر تهران نیز می‌توان به گسترش استفاده شهروندان از کیسه‌های پلاستیکی به جای بسته‌بندی‌های مرسوم گذشته از آن جمله پاکت‌های کاغذی و یا زنبیل، اشاره نمود. از سوی دیگر در طی سال‌های یاد شده، شاهد افزایش میزان پت و شیشه در بافت پسماند می‌باشیم که علت این امر افزایش استفاده از این دو ترکیب در بسته‌بندی مایعات بجای شیشه چند بار مصرف می‌باشد.

۲-۲- مدل‌سازی تولید پسماند

فاکتورهای متعددی روی تولید پسماند موثر است. در این مطالعه مولفه زمان شامل سال، ماه و فصل تولید پسماند، مولفه جغرافیایی شامل دمای میانگین، بارندگی، مولفه اقتصادی شامل تولید ناخالص داخلی، درآمد، مولفه فرهنگی شامل جمعیت تحصیل کرده، نرخ بیکاری، جمعیت دانشجوی و مولفه اجتماعی شامل جمعیت، اندازه خانوار، جمعیت مرد و زن انتخاب گردیدند. داده‌ها از سال ۱۳۷۰ تا ۱۳۹۲ از بایگانی ادارات مربوط و شهرداری گردآوری شده است. علت انتخاب این بازه، تغییرکردن بخش‌های استان تهران از سال ۱۳۹۲ می‌باشد. در این مطالعه ارتباط هر یک از فاکتورها و میزان پسماندهای تولیدی به صورت فصلی و ماهانه در سال‌های ۱۳۷۰-۱۳۹۲ جداگانه بررسی شده و در هر بخش با تحلیل و ارزیابی داده‌ها، ارتباط بین عامل مربوطه و وزن پسماند باتوجه به ضریب همبستگی که در شکل نمایش داده شده، ارائه شده است. علت انتخاب این بازه مورد مطالعه، تغییر تقسیمات کشوری از سال ۱۳۹۲ در تهران است. شناسایی شاخص‌های مؤثر، به برنامه‌ریزی بهتر جهت کاهش تولید پسماند، افزایش تفکیک پسماند، افزایش کیفیت جمع‌آوری و کاهش هزینه‌های جمع‌آوری کمک شایانی خواهد کرد. در نهایت، مدل‌سازی کمی پسماند توسط مدل‌های شبکه عصبی مصنوعی، رگرسیون، ماشین بردار پشتیبان و الگوریتم یادگیری عمیق صورت گرفته و عملکرد مدل‌ها مقایسه می‌گردد.

۲-۳- پیش‌بینی تولید پسماند به روش شبکه عصبی مصنوعی

یک شبکه عصبی مصنوعی معمولی از چندلایه و هر لایه از تعدادی اجزاء کوچک داده‌پردازی بنام سلول نرون، واحد یا گره تشکیل شده است. ساختار یک شبکه، شامل لایه‌های مختلف به همراه تعدادی نرون مربوطه می‌باشد. اولین لایه هر شبکه را لایه ورودی، لایه آخر را لایه خروجی و لایه‌های میانی را اصطلاحاً لایه‌های پنهان می‌نامند. 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، صحت سنجی و تست از حدود ۷۰، ۱۵ و ۱۵ درصد از داده‌های موجود استفاده شده است.

۲-۴- پیش‌بینی تولید پسماند به روش رگرسیون، ماشین بردار پشتیبان

ماشین بردار پشتیبان^۱ یکی از روش‌های یادگیری بانظارت است که از آن برای طبقه‌بندی و رگرسیون استفاده می‌کنند. این روش از روش‌های نسبتاً جدیدی است که در سال‌های اخیر کارایی خوبی نسبت به روش‌های قدیمی‌تر برای طبقه‌بندی نشان داده است. مبنای کاری دسته‌بندی‌کننده ماشین بردار پشتیبانی دسته‌بندی خطی داده‌ها است و در تقسیم خطی داده‌ها سعی می‌کنیم خطی را انتخاب کنیم که حاشیه اطمینان بیشتری داشته باشد. حل معادله پیدا کردن خط بهینه برای داده‌ها به وسیله روش‌های QP که روش‌های شناخته شده‌ای در حل مسائل محدودیت دار هستند صورت می‌گیرد.

ماشین بردار پشتیبان یک الگوریتم دسته‌بندی بسیار قدرتمند است. وقتی از آن همراه با الگوریتم‌های جنگل تصادفی و دیگر ابزارهای یادگیری ماشین استفاده کنیم، این الگوریتم می‌تواند مدلی بسیار قابل توجه برای دسته‌بندی داده‌ها ارائه کند. الگوریتم ماشین بردار پشتیبان هنگامی که قدرت پیش‌بینی بالا مورد نیاز باشد یک گزینه بسیار عالی است. تصویرسازی این الگوریتم‌ها کار دشواری محسوب می‌شود، زیرا فرمول‌بندی پیچیده‌ای دارند.

۲-۵- پیش‌بینی تولید پسماند به روش الگوریتم یادگیری عمیق

یادگیری عمیق زیر شاخه‌ای از یادگیری ماشینی است که با الگوریتم‌های الهام گرفته شده از ساختار و عملکرد مغز به نام شبکه‌های عصبی مرتبط است. این یادگیری از شبکه‌های عصبی بزرگ‌تر تشکیل شده است. در یادگیری عمیق، یک مدل کامپیوتری یاد می‌گیرد که طبقه‌بندی را به صورت مستقیم از روی تصاویر، متن یا صدا انجام دهد. مدل‌های این نوع یادگیری می‌توانند به دقت پیشرفته‌ای دست یابند که گاهی اوقات حتی از عملکرد انسانی فراتر می‌رود. این مدل‌ها با استفاده از مجموعه بزرگی از داده‌های برجسب‌گذاری شده و معماری‌های شبکه عصبی که حاوی لایه‌های زیادی هستند، آموزش داده می‌شوند. شبکه‌های عصبی لایه‌های بسیاری دارند؛ درست مانند مغز انسان که از نورون‌ها تشکیل شده است. گفته می‌شود هر شبکه بر اساس تعداد لایه‌هایی که دارد عمیق‌تر است. یک نورون در مغز انسان هزاران سیگنال را از نورون‌های دیگر دریافت می‌کند. در یک شبکه عصبی مصنوعی، سیگنال‌ها بین گره‌ها حرکت می‌کنند. سیستم‌های دیپ لرنینگ به سخت افزار قدرتمندی نیاز دارند زیرا دارای حجم زیادی از داده‌های در حال پردازش هستند که شامل چندین محاسبات پیچیده ریاضی می‌باشد. حتی با استفاده از چندین سخت افزار پیشرفته، آموزش یک شبکه عصبی می‌تواند تا هفته‌ها به طول بی‌انجامد.

سیستم یادگیری عمیق به مقادیر زیادی داده نیاز دارد تا بتواند نتایج را به صورت کاملاً دقیق بررسی کند. هنگام پردازش داده‌ها، شبکه‌های عصبی مصنوعی می‌توانند داده‌ها را با پاسخ‌های دریافتی از یک سری سوالات باینری درست یا نادرست که شامل محاسبات ریاضی پیچیده است، طبقه‌بندی کنند. برای مثال: یک برنامه تشخیص چهره با یادگیری عمیق و تشخیص لبه‌ها، تشخیص خطوط چهره و سپس بخش‌های مهم‌تر از چهره، و در نهایت، نمایش کلی چهره کار می‌کند. با گذشت زمان، برنامه خودش به صورت خودکار آموزش می‌بیند. در این صورت برنامه تشخیص چهره با گذشت زمان می‌تواند چهره‌ها را به دقت شناسایی می‌کند. در این تحقیق از برنامه نویسی در پایتون و بکارگیری پکیج‌های numpy, pandas, matplotlib.pyplot استفاده شده است.

۳- نتایج و بحث

۳-۱- بررسی مولفه‌های ورودی و نسبت همبستگی با پسماند

¹ Support vector machines (SVMs)

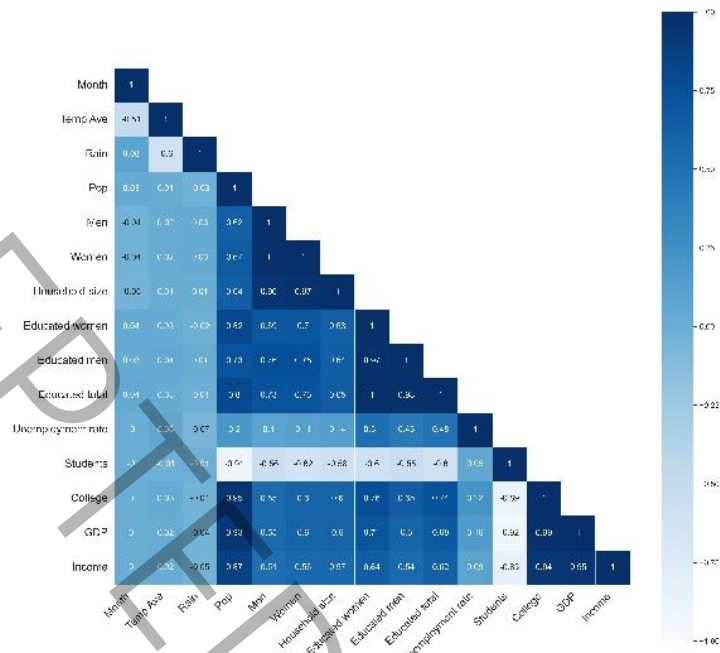
شکل (۱) و (۲) هیت‌مپ همبستگی مولفه‌های موثر بر تولید پسماند به صورت فصلی و ماهانه را نشان می‌دهد که نسبت به ضریب همبستگی از صفر تا یک، از رنگ روشن تا پررنگ رسم شده است. این شکلها به کمک برنامه‌نویسی به وسیله برنامه پایتون بدست آورده شده است. با توجه به این شکلها ضریب همبستگی هرچه به صفر نزدیک‌تر باشد، اثر آن عامل بر تولید پسماند کمتر است و برعکس. در این پژوهش چون داده‌های پژوهش در یک دوره بیست و دو ساله است؛ دوره چهار سال اول را کوتاه مدت، دوازده سال اول را میان مدت و تا آخر بازه دوره را بلند مدت در نظر می‌گیریم. طبق هیت‌مپ شکل (۱) مولفه دمای میانگین در کوتاه مدت اثر بیشتری بر تولید پسماند دارد تا در بلندمدت و میان‌مدت و دلیل آن اثر بیشتر تغییر فصول و دما در کوتاه مدت است.

بدلیل شرایط جوی و کمبود بارش در شهر تهران مولفه بارندگی در کوتاه مدت، میان مدت و بلند مدت تاثیری بر تولید پسماند نداشته است و ضریب همبستگی آن در طول تمام مدت تقریباً نزدیک به صفر است. مولفه سرانه تولید ناخالص داخلی اثر بسیار زیادی بر تولید پسماند به خصوص در طی بلند مدت و بعد از آن در مطالعات کوتاه مدت دارد.

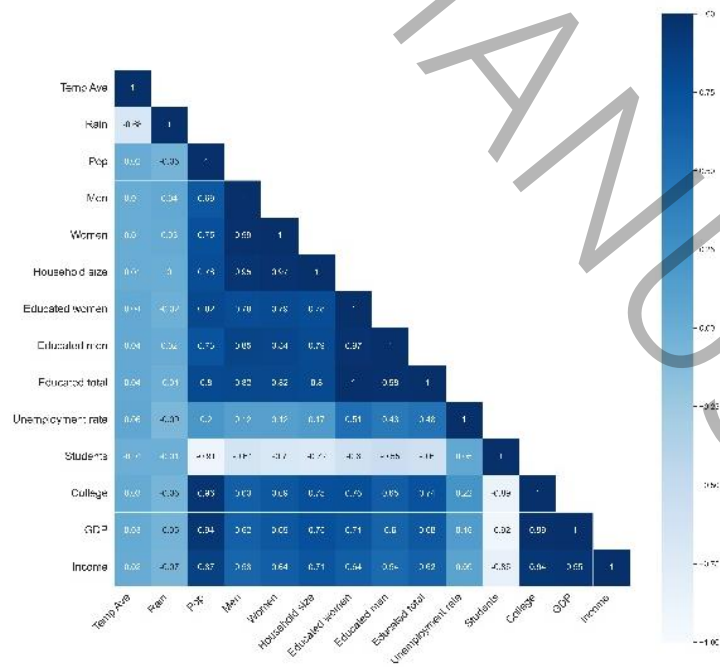
مولفه جمعیت همانند مولفه سرانه تولید ناخالص داخلی تاثیر زیادی بر تولید پسماند به خصوص در بلند مدت دارد. اما مورد اثر تفکیک جنسیتی در تولید پسماند بررسی انجام نشده بود، که آیا جنسیت هم مانند دیگر عوامل در میزان تولید پسماند موثر است یا خیر. این مطالعه نشان می‌دهد که جمعیت زنان در تولید پسماند اثر بیشتری نسبت به جمعیت مردان به خصوص در بلند مدت دارد، به این دلیل که داده‌های جمع‌آوری شده مربوط به پسماند شهری است و زنان مبدا تولید پسماندهای خانگی هستند و مقدار قابل توجهی از پسماندهای شهری را شامل می‌شوند. اندازه خانوار همچون دیگر مولفه‌های جمعیتی بر روی تولید پسماند موثر است و در کوتاه مدت اثر بیشتری دارد زیرا اندازه آن در بلند مدت کمتر تغییر می‌کند.

مولفه جمعیت تحصیل کرده ضریب همبستگی بالایی دارد و تا کنون محققى به اثر این مولفه بر تولید پسماند اشاره نکرده است. در این مولفه نیز می‌توان مانند جمعیت مردم به تفکیک جنسیتی اشاره کرد که زنان تحصیل کرده چون آگاهی بیشتری دارند به تولید پسماند بخصوص پسماند خانگی که مبدا اولیه آن هستند توجه بیشتری می‌کنند و اثر بسیار قابل توجه‌تری نسبت به مردان تحصیل کرده دارند.

مولفه درآمد مهمترین مولفه اقتصادی است و بیشترین تاثیر را در بلند مدت بین مولفهها دارد که دلیل آن را می‌توان این طور بیان کرد که با داشتن درآمد بیشتر، قدرت خرید بالاتر و تمایل به مصرف‌گرایی کالا و تولید پسماند بیشتر است. نرخ بیکاری در کوتاه مدت بر تولید پسماند تاثیر دارد اما در بلند مدت اثری ندارد. جمعیت دانش‌آموزان در بلند مدت کمترین اثر را در بین مولفهها دارد و ضریب همبستگی آن تقریباً صفر است اما در کوتاه مدت و میان مدت بدلیل اینکه یک مولفه جمعیتی است، با تغییر ناگهانی می‌تواند اثر زیادی بر تولید پسماند بگذارد. مولفه جمعیت دانشجویان اثر بسیار زیادی بر تولید پسماند دارد و تاثیر آن از کوتاه مدت به بلند مدت بیشتر می‌شود. زیرا متشکل از دانشجویانی است که بیشتر افراد از دیگر شهرها به شهر تهران برای تحصیل آمده‌اند و یک مولفه جمعیتی را تغییر داده‌اند.



شکل ۱: مولفه‌های موثر بر تولید پسماند به صورت ماهانه
 Fig.1. Effective parameters on monthly waste generation

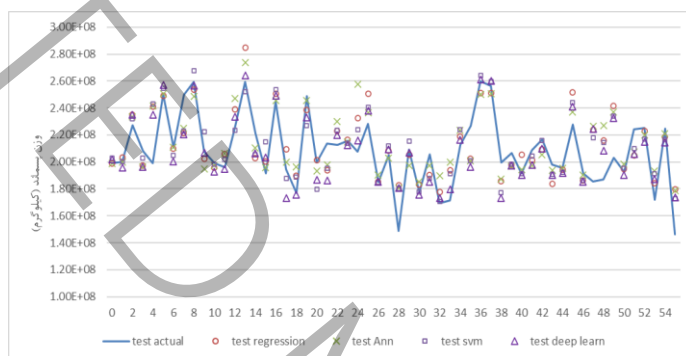


شکل ۲: همبستگی مولفه‌های موثر بر تولید پسماند به صورت فصلی
 Fig. 2. Effective parameters on seasonal waste generation

۳-۱ مدل‌سازی کمی پسماند شهری در شهر تهران با استفاده از مدل‌های هوشمند

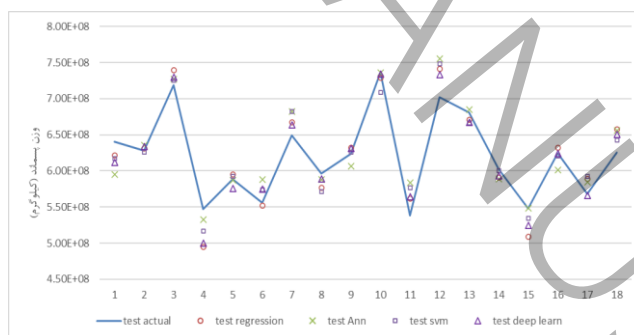
۳-۱-۱ مدل‌سازی ماهانه تولید پسماند

شکل (۳) و (۴) سری زمانی مقادیر واقعی و مدل‌سازی شده را نشان می‌دهد. همانطور که مشخص است، مدل بر پایه الگوریتم یادگیری عمیق در تخمین پیک تولید پسماند عملکرد بهتری نسبت سایر مدل‌ها نشان داد. برآورد دقیق ماکزیمم تولید پسماند در تخمین سلول دفن و هزینه جمع‌آوری پسماند بسیار موثر است. بنابراین، بکارگیری این مدل تخمین بهتری نسبت سایر مدل‌های هوشمند در اختیار تصمیم‌گیران قرار خواهد داد.



شکل ۳: مدل‌سازی تولید ماهانه پسماند شهر تهران

Fig.3. Modelling of monthly waste generation in Tehran city



شکل ۴: مدل‌سازی تولید فصلی پسماند شهر تهران

Fig.4. Modelling of seasonal waste generation in Tehran city

شکل (۵) مقدار پیش‌بینی شده و مشاهده شده مدل‌های رگرسیون، شبکه عصبی مصنوعی، ماشین بردار پشتیبانی و یادگیری عمیق را نشان می‌دهد و جدول (۱) مقدار خطاهای مدل‌سازی‌های مذکور که شامل MAE^2 , $RMSE^3$, R^{21} هستند را نمایش می‌دهد که

1 R-squared

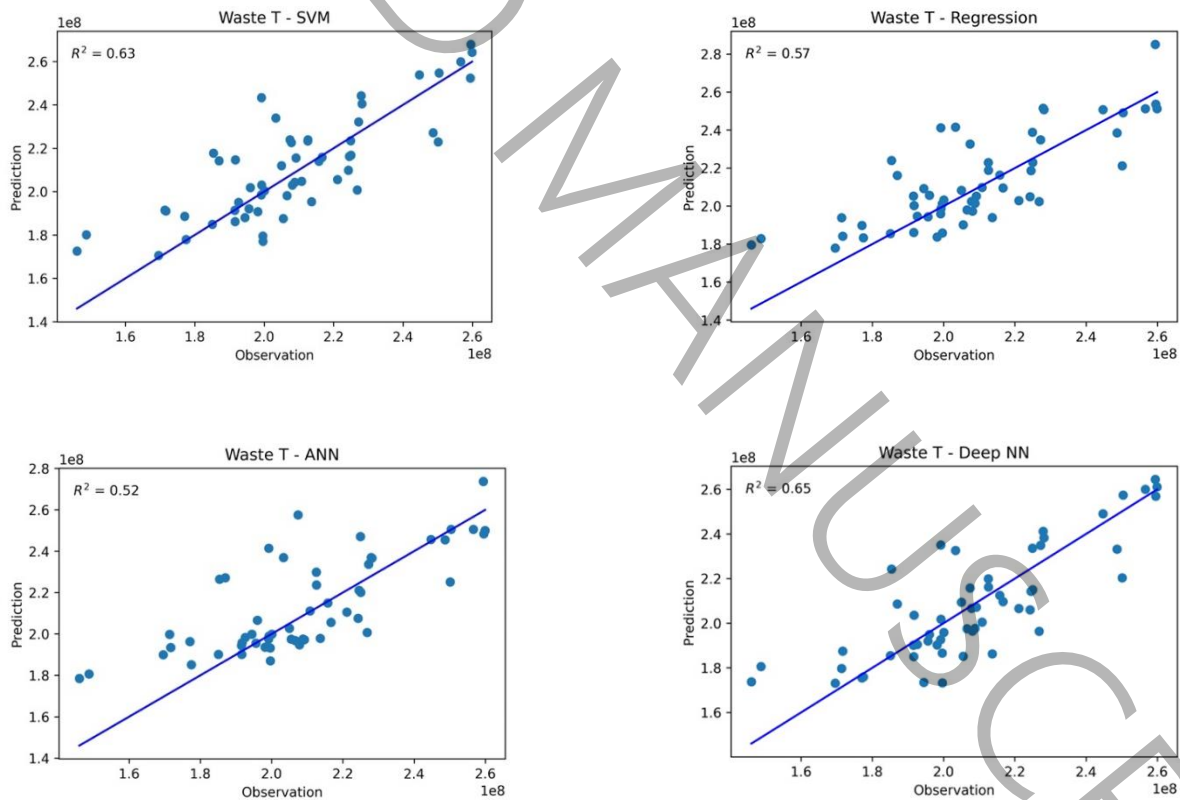
2 Mean absolute error

3 root-mean-square error

مقدار آن‌ها را از ماکزیمم به مینیمم با پررنگ به کم‌رنگ هایلایت شده است. در این شکلها هرچه نقاط به خط نیمساز نزدیک‌تر باشد و یا منطبق بر آن باشد، نشان دهنده انطباق بیشتر اعداد پیش‌بینی شده توسط مدل و مشاهدات است. نقاطی که بالای نیمساز قرار دارند بیش از اندازه‌ی واقعی تخمین زده شده‌اند و نقاطی که زیر نیمساز قرار دارند کمتر از حد واقعی محاسبه شده‌اند.

طبق اطلاعات بدست آمده از مدل‌سازی‌ها، مدل یادگیری عمیق بیشترین R^2 و مدل شبکه عصبی مصنوعی کمترین مقدار R^2 را دارد. برای یک مجموعه داده مشترک در مدل‌سازی، R^2 بالاتر و نزدیک به یک نشان دهنده دقت بالاتر مدل است و یعنی مقدار نتایج پیش‌بینی شده با مشاهده شده نزدیک به هم هستند. RMSE و MAE هرچه بیشتر باشند دقت مدل پایین‌تر است و برعکس. مدل شبکه عصبی مصنوعی دارای کمترین R^2 و بیشترین RMSE و MAE است و همچنین از شکل (۵) پراکندگی نقاط نسبت به خط نیمساز مشخص است؛ بنابراین این مدل کمترین دقت را در مدل‌سازی برای داده‌های این پژوهش دارد.

مدل رگرسیون بعد از شبکه عصبی مصنوعی کمترین R^2 و بیشترین RMSE و MAE را دارد اما دقت آن از مدل قبلی بیشتر است و نقاط شکل آن به خط نیمساز نزدیک‌تر است. مدل بردار ماشین بردار پشتیبانی نزدیک‌ترین خطاها را با مدل یادگیری عمیق دارد ولی نقاط پیش‌بینی شده در مدل یادگیری عمیق به خط نیمساز نزدیک‌تر هستند و دارای R^2 بالاتر و RMSE و MAE کمتر است. در نتیجه مدل یادگیری عمیق دقیق‌ترین و نزدیک‌ترین نتیجه را برای مدل‌سازی این داده‌ها بدست می‌آورد.



شکل ۵: مقدار پیش‌بینی شده نسبت مقدار واقعی تولید ماهانه پسماند شهر تهران
Fig. 5. Predict to observe plot of monthly waste generation Tehran city

جدول ۱: دقت مدل تولید ماهانه پسماند شهر تهران

Table 1. Model performance for monthly waste generation in Tehran city

$(R^2)^1$	RMSE ²	MAE ³	Metric
0.566	169	129	Regression
0.517	178	130	ANN
0.628	156	119	SVM
0.646	152	114	Deep NN

۲-۱-۳- مدل سازی تولید فصلی پسماند

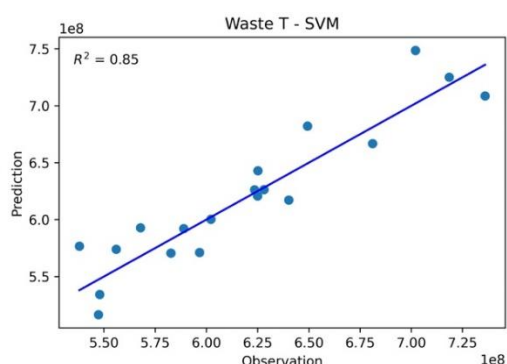
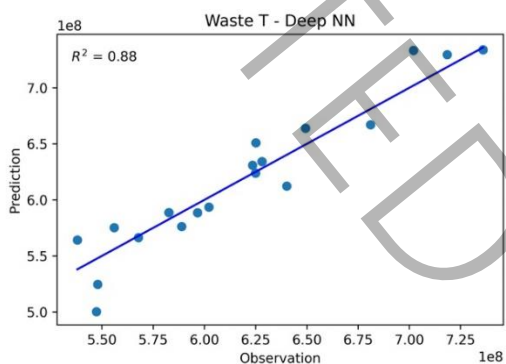
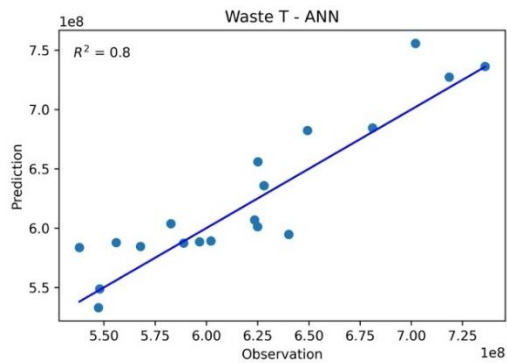
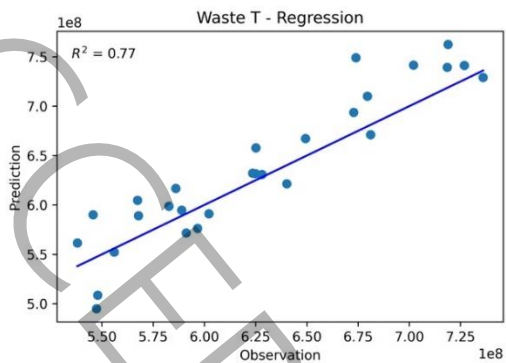
در این بخش مدل سازی فصلی مدلهایی که در بخش قبل بررسی شد، ارزیابی می شود و مدل ها بر حسب خطاها و نتایج دقیق تر رتبه بندی می شوند. داده های فصلی جمع بندی و میانگین داده های ماهانه هستند؛ بنابراین نقاط کمتری در شکل (۶) داریم و بررسی فاصله این نقاط با نیمساز راحت تر است. طبق شکل (۶) مدل رگرسیون و شبکه عصبی مصنوعی نقاط بالای خط نیمساز بیشتری از دو مدل دیگر دارند که این نقاط نشان دهنده این است که ارقامی که مدل بدست آورده بیش از حد پیش بینی شده است. بر اساس مقایسه جدول ۱ و ۲ همه ی مدل ها در داده های فصلی دارای R^2 بیشتری از بخش قبل دارند. جدول ۲ نشان می دهد که مدل یادگیری عمیق همچنان بیشترین R^2 را دارد و بعد از آن به ترتیب ماشین بردار پشتیبانی، شبکه عصبی مصنوعی و در آخر رگرسیون کمترین R^2 را دارد. مدل رگرسیون در مدل سازی فصلی کمترین R^2 و بیشترین RMSE و MAE را دارد. شبکه عصبی مصنوعی در مدل سازی فصلی از مدل رگرسیون نتایج واقعی تری بدست آورده است و خطای کمتری دارد در صورتی که در مدل سازی ماهانه برعکس بود. مدل ماشین بردار پشتیبانی و یادگیری عمیق همانند مدل سازی ماهانه بهترین و نزدیک ترین نتایج را بدست آورده اند و همچنان یادگیری عمیق از دیگر مدل ها بهتر عمل کرده است. شکل (۷) منحنی یادگیری مدل سازی را نمایش می دهد. منحنی های خطا در شکل مدل سازی فصلی تطابق زیادی دارند. ولی در مدل سازی ماهانه فاصله و اختلاف زیادی دارند. پس می توان نتیجه گرفت مدل سازی فصلی عملکرد بهتری داشته است و نتایج دقیق تر و با خطای کمتر را نشان داده است

جدول ۲: دقت مدل تولید فصلی پسماند شهر تهران

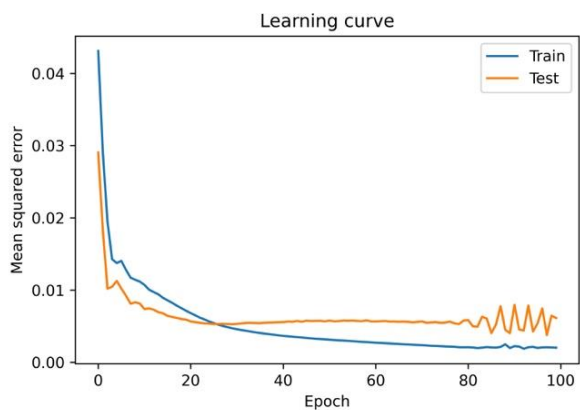
Table 2. Model performance for seasonal waste generation in Tehran city

R^2	RMSE	MAE	Seasonal metrics
0.765	292	240	Regression
0.803	253	198	ANN
0.847	223	182	SVM
0.884	194	154	Deep NN

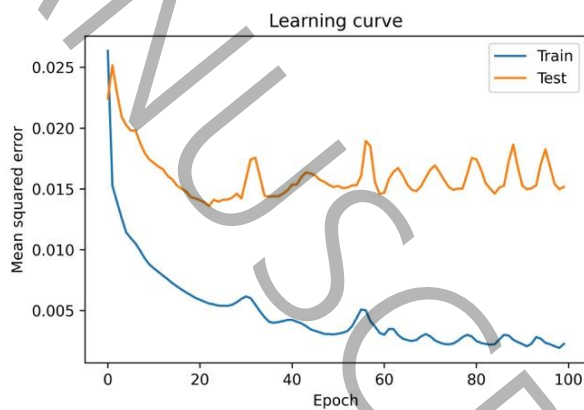
¹ R-squared² root-mean-square error³ Mean absolute error



شکل ۶: مقدار پیش‌بینی شده نسبت مقدار واقعی تولید فصلی پسماند شهر تهران
 Fig. 6. Predict to observe plot of seasonal waste generation Tehran city



مدل سازی فصلی



مدل سازی ماهانه

شکل ۷: منحنی یادگیری مدل سازی نتیجه‌گیری مدل سازی ماهانه و مدل سازی فصلی
 Fig.7. Learning curve of monthly and seasonal modelling

با توجه به اینکه مدل حاضر تحت تاثیر پارامترهای ورودی به مدل و الگوی تغییرات تولید پسماند امکان مقایسه نتایج بصورت کامل امکانپذیر نیست. در تحقیقات مشابه که هدف آن پیش‌بینی تولید پسماند با سایر مدل‌های هوشمند بود، خطای مدل شبکه عصبی مشابه مطالعه حاضر کمترین دقت را داشت [۴۶]. همچنین، مدل مطالعه شده اخیر نسبت مدل‌های مطالعه شده قبلی نظیر ماشین بردار پشتیبان، نروفازی، رگرسیون دقت بیشتری نشان داد.

۴- نتیجه‌گیری

در این مطالعه، یک مدل جامع با جهت مدلسازی ماهانه و فصلی تولید پسماند ارائه گردید. جهت ارزیابی مدل از اطلاعات شهر تهران استفاده شد. فاکتورهای متعددی روی تولید پسماند موثر است. در این مطالعه مولفه زمان شامل سال، ماه و فصل تولید پسماند، مولفه جغرافیایی شامل دمای میانگین، بارندگی، مولفه اقتصادی شامل تولید ناخالص داخلی، درآمد، مولفه فرهنگی شامل جمعیت تحصیل کرده، نرخ بیکاری، جمعیت دانشجوی و مولفه اجتماعی شامل جمعیت، اندازه خانوار، جمعیت مرد و زن انتخاب گردیدند. داده‌ها از سال ۱۳۷۰ تا ۱۳۹۲ از بایگانی ادارات مربوط و شهرداری گردآوری شده است. علت انتخاب این بازه، تغییر کردن بخش‌های استان تهران از سال ۱۳۹۲ می‌باشد. در این فصل ارتباط هر یک از فاکتورها و میزان پسماندهای تولیدی به صورت فصلی و ماهانه در سال‌های ۱۳۷۰-۱۳۹۲ جداگانه بررسی شده و در هر بخش با تحلیل و ارزیابی داده‌ها، ارتباط بین عامل مربوطه و وزن پسماند بانوجه به ضریب همبستگی که در شکل نمایش داده شده؛ ارائه شده است. علت انتخاب این بازه مورد مطالعه، تغییر تقسیمات کشوری از سال ۱۳۹۲ در تهران است. شناسایی شاخص‌های مؤثر، به برنامه‌ریزی بهتر جهت کاهش تولید پسماند، افزایش تفکیک پسماند، افزایش کیفیت جمع‌آوری و کاهش هزینه‌های جمع‌آوری کمک شایانی خواهد کرد. در نهایت، مدل سازی کمی پسماند توسط مدل‌های شبکه عصبی مصنوعی، رگرسیون، ماشین بردار پشتیبان و الگوریتم یادگیری عمیق صورت گرفته و عملکرد مدل‌ها مقایسه گردید.

این مطالعه نشان داد، منحنی‌های خطا در شکل مدل‌سازی فصلی تطابق زیادی دارند و فصلی عملکرد بهتری نسبت به مدل سازی ماهیانه داشته و نتایج دقیق‌تر و با خطای کمتر را نشان داده است. در مدل سازی فصلی مدل ماشین بردار پشتیبانی و یادگیری عمیق همانند مدل سازی ماهانه بهترین و نزدیک‌ترین نتایج را بدست آورده‌اند. اما شبکه عصبی مصنوعی در مدل سازی فصلی از مدل رگرسیون نتایج واقعی‌تری بدست آورده است و خطای کمتری دارد در صورتی که در مدل سازی ماهانه مدل رگرسیون نتایج واقعی‌تری را نشان می‌داد. در نهایت می‌توان نتیجه گرفت الگوریتم یادگیری عمیق نسبت به سایر مدل‌های هوشمند توانایی بیشتری در پیش‌بینی کمیت پسماند دارد و دقیق‌ترین و نزدیک‌ترین نتیجه را برای مدل سازی این داده‌ها بدست می‌آورد. پیشنهاد می‌شود در تحقیقات آتی برای بدست آوردن نتایج دقیق‌تر و کاهش خطا استفاده از مدل‌های جدیدتر و یا مدل‌های هوشمند که اخیراً معرفی شده استفاده شود. همچنین برای بهینه کردن مدل از الگوریتم مورچگان و زنبور عسل استفاده شود و عوامل دیگری که می‌توان برای بهبود مدل بررسی کرد، ارزیابی شوند مانند دیگر شاخصه‌های اقتصادی، جمعیت توریست، قیمت کالاها، نرخ تورم، سبک زندگی و یا تاثیر پاندمی‌ها مانند ویروس کرونا، عوامل غیرمترقبه مانند آتش‌سوزی، سیل و زلزله. با استفاده از مدل سازی به وسیله مدل یادگیری عمیق میزان تولید پسماند در حوادث آینده مانند زلزله در شهر تهران را پیش‌بینی کرد و راهکارهای موثر مدیریت پسماند در زمان وقوع را پیدا کرد. در این پژوهش عوامل موثر به صورت خطی در نظر گرفته شده‌اند، می‌توان برای بررسی بیشتر اثرات عوامل را به صورت غیرخطی در نظر گرفت.

References

[۱] K. Yetilmezsoy, B. Ozkaya, M. Cakmakci, Artificial intelligence-based prediction models for environmental engineering, *Neural Network World*, 21(3). (۲۰۱۱)

[۲] S.A. Kalogirou, Use of genetic algorithms for the optimal design of flat plate solar collectors. (۲۰۰۳)

- [۳] S. Roy, Prediction of particulate matter concentrations using artificial neural network, *Resour. Environ*, 2(2) (2012) 30-36.
- [۴] E. Agirre-Basurko, G. Ibarra-Berastegi, I. Madariaga, Regression and multilayer perceptron-based models to forecast hourly O₃ and NO₂ levels in the Bilbao area, *Environmental Modelling & Software*, 21(4) (2006) 430-446.
- [۵] M. Cakmakci, Adaptive neuro-fuzzy modelling of anaerobic digestion of primary sedimentation sludge, *Bioprocess and Biosystems Engineering*, 3.۳۵۷-۳۴۹ (۲۰۰۷) .
- [۶] M.-G. Chun, K.-C. Kwak, J.-W. Ryu, Application of ANFIS for coagulant dosing process in a water purification plant, in: *FUZZ-IEEE'99. 1999 IEEE International Fuzzy Systems. Conference Proceedings (Cat. No. 99CH36315)*, IEEE, 1999, pp. ۱۷۴۸-۱۷۴۳ .
- [۷] H. Niska, A. Serkkola, Data analytics approach to create waste generation profiles for waste management and collection, *Waste Management*, 77 (2018) 477-485.
- [۸] N.E. Johnson, O. Ianiuk, D. Cazap, L. Liu, D. Starobin, G. Dobler, M. Ghandehari, Patterns of waste generation: A gradient boosting model for short-term waste prediction in New York City, *Waste management*, 62 (2017) 3-11.
- [۹] C. Estay-Ossandon, A. Mena-Nieto, Modelling the driving forces of the municipal solid waste generation in touristic islands. A case study of the Balearic Islands (2000–2030), *Waste management*, 75 (2018) 70-81.
- [۱۰] G. Di Foggia, M. Beccarello, Designing waste management systems to meet circular economy goals: The Italian case, *Sustainable Production and Consumption*, 26 (2021) 1074-1083.
- [۱۱] C. Ghinea, E.N. Drăgoi, E.-D. Comăniță, M. Gavrilăscu, T. Câmpean, S. Curteanu, M. Gavrilăscu, Forecasting municipal solid waste generation using prognostic tools and regression analysis, *Journal of environmental management*, 182 (2016) 80-93.
- [۱۲] J.S. Armstrong, Evaluating forecasting methods, *Principles of forecasting: A handbook for researchers and practitioners*, (2001) 443-472.
- [۱۳] R. Noori, M. Abdoli, M.J. Ghazizade, R. Samieifard, Comparison of neural network and principal component-regression analysis to predict the solid waste generation in Tehran, *Iranian Journal of Public Health*, 38(1) (2009) 74-84.
- [۱۴] M. Ali Abdoli, M. Falah Nezhad, R. Salehi Sede, S. Behboudian, Longterm forecasting of solid waste generation by the artificial neural networks, *Environmental Progress & Sustainable Energy*, 31(4) (2012) 628-636.
- [۱۵] P. Sukholthaman, A. Sharp, A system dynamics model to evaluate effects of source separation of municipal solid waste management: A case of Bangkok, Thailand, *Waste management*, 52 (2016) 50-61.
- [۱۶] S. Xiao, H. Dong, Y. Geng, X. Tian, C. Liu, H. Li, Policy impacts on Municipal Solid Waste management in Shanghai: A system dynamics model analysis, *Journal of Cleaner Production*, 262 (2020) 121366.
- [۱۷] D. Ju-Long, Control problems of grey systems, *Systems & control letters*, 1(5) (1982) 288-294.
- [۱۸] L. Chhay, M.A.H. Reyad, R. Suy, M.R. Islam, M.M. Mian, Municipal solid waste generation in China: Influencing factor analysis and multi-model forecasting ,*Journal of Material Cycles and Waste Management*, 20 (2018) 1761-1770.
- [۱۹] J.W. Forrester, Industrial dynamics: a major breakthrough for decision makers, *Harvard business review*, 36(4) (1958) 37-66.

- [٢٠] B. Dyson, N.-B. Chang, Forecasting municipal solid waste generation in a fast-growing urban region with system dynamics modeling, *Waste management*, 25(7) (2005) 669-679.
- [٢١] N. Kollikkathara, H. Feng, D. Yu, A system dynamic modeling approach for evaluating municipal solid waste generation, landfill capacity and related cost management issues, *Waste management*, 30(11) (2010) 2194-2203.
- [٢٢] C. Lee, K. Ng, C. Kwong, S. Tay, A system dynamics model for evaluating food waste management in Hong Kong, China, *Journal of Material Cycles and Waste Management*, 2.٤٥٦-٤٣٣ (٢٠١٩) ١
- [٢٣] M.A. Babalola, A system dynamics-based approach to help understand the role of food and biodegradable waste management in respect of municipal waste management systems, *Sustainability*, 11(12) (2019) 3456.
- [٢٤] T.M. Mak, P.-C. Chen, L. Wang, D.C. Tsang, S. Hsu, C.S. Poon, A system dynamics approach to determine construction waste disposal charge in Hong Kong, *Journal of cleaner production*, 241 (2019) 118309.
- [٢٥] Q. Guo, E. Wang, Y. Nie, J. Shen, Profit or environment? A system dynamic model analysis of waste electrical and electronic equipment management system in China, *Journal of Cleaner Production*, 194 (2018) 34-42.
- [٢٦] S. Ulli-Ber, D.F. Andersen, G.P. Richardson, Financing a competitive recycling initiative in Switzerland, *Ecological economics*, 62(3-4) (2007) 727-739.
- [٢٧] M. Sufian, B. Bala, Modelling of electrical energy recovery from urban solid waste system: The case of Dhaka city, *Renewable energy*, 31(10) (2006) 1573-1580.
- [٢٨] D. Inghels, W. Dullaert, An analysis of household waste management policy using system dynamics modelling, *Waste management & research*, 29(4) (2011) 351-370.
- [٢٩] A.C.H. Pinha, J.K. Sagawa, A system dynamics modelling approach for municipal solid waste management and financial analysis, *Journal of Cleaner Production*, 269 (2020) 122350.
- [٣٠] J. Den Boer, E. Den Boer, J. Jager, LCA-IWM: A decision support tool for sustainability assessment of waste management systems, *Waste management*, 27(8) (2007) 1032-1045.
- [٣١] R. Freeman, L. Jones, M. Yearworth, J.-Y. Cherruault, Systems thinking and system dynamics to support policy making in Defra—project final report. (٢٠١٤) ,
- [٣٢] S. Zhong, K. Zhang, M. Bagheri, J.G. Burken, A. Gu, B. Li, X. Ma, B.L. Marrone, Z.J. Ren, J. Schrier, Machine learning: new ideas and tools in environmental science and engineering, *Environmental Science & Technology*, 55(19) (2021) 12741-12754.
- [٣٣] V. Sagan, K.T. Peterson, M. Maimaitijiang, P. Sidike, J. Sloan, B.A. Greeling, S. Maalouf, C. Adams, Monitoring inland water quality using remote sensing: Potential and limitations of spectral indices, bio-optical simulations, machine learning, and cloud computing, *Earth-Science Reviews*, 205 (2020) 103187.
- [٣٤] C. Bellinger, M.S. Mohamed Jabbar, O. Zaïane, A. Osornio-Vargas, A systematic review of data mining and machine learning for air pollution epidemiology, *BMC public health*, 17 (2017) 1-19.
- [٣٥] Z.M. Yaseen, An insight into machine learning models era in simulating soil, water bodies and adsorption heavy metals: Review, challenges and solutions, *Chemosphere*, 277 (2021) 130126.
- [٣٦] A.I. Dounis, C. Caraiscos, Advanced control systems engineering for energy and comfort management in a building environment—A review, *Renewable and Sustainable Energy Reviews*, 13(6-7) (2009) 1246-1261.

[٣٧]X.C. Nguyen, T.P.Q. Tran, T.T.H. Nguyen, D.D. La, V.K. Nguyen, T.P. Nguyen, X. Nguyen, S. Chang, R. Balasubramani, W.J. Chung, Call for planning policy and biotechnology solutions for food waste management and valorization in Vietnam, *Biotechnology Reports*, 28 (2020) e00529.

[٣٨]K.G. Roberts, B.A. Gloy, S. Joseph, N.R. Scott, J. Lehmann, Life cycle assessment of biochar systems: estimating the energetic, economic, and climate change potential, *Environmental science & technology*, 44(2) (2010) 827-833.

[٣٩]Y. LeCun, Y. Bengio, G. Hinton, Deep learning, *nature*, 521(7553) (2015) 436-444.

[٤٠]H. Zhang, H. Cao, Y. Zhou, C. Gu, D. Li, Hybrid deep learning model for accurate classification of solid waste in the society, *Urban Climate*, 49 (2023) 101485.

[٤١]A. Xu, H. Chang, Y. Xu, R. Li, X. Li, Y. Zhao, Applying artificial neural networks (ANNs) to solve solid waste-related issues: A critical review, *Waste Management*, 124 (2021) 385-402.

[٤٢]M.T. Munir, B. Li, M. Naqvi, Revolutionizing municipal solid waste management (MSWM) with machine learning as a clean resource: Opportunities, challenges and solutions, *Fuel*, 348 (2023) 128548.

[٤٣]O.B. Sara, Mathematical modeling to predict residential solid waste generation, *Waste Management*, 28 (2008) 7-13.

[٤٤]G.Z.M. Jalili, R. Noori, Prediction of municipal solid waste generation by use of artificial neural network: A case study of Mashhad, *Int. J. Environ. Res.*, 2(1) (2008) 13-22.

[٤٥]H. Adeli, X. Jiang, Neuro-Fuzzy logic model for Free Way Work Zone Capacity Estimation, *Jornal of Transportation Engineering*, 129 (2002) 484-493.

[٤٦]M. Abbasi, M.N. Rastgoo, B. Nakisa, Monthly and seasonal modeling of municipal waste generation using radial basis function neural network, *Environmental Progress & Sustainable Energy*, 38(3) (2019) e13033.