مجلة محيط شناسي ،سال سي و پنجم،شمارة ٤٩ بهار٨٨،صفحة ٢٥-٣٠

پيش‌بيني هفتگي زبالة توليدي با استفاده از مدل تركيبي شبكة عصبي و تبديل موجک

روح‌اله نوري[1*]، محمد علي عبدلي[2]، اشكان فرخ‌نيا[3]،آلاله قائمي[4]

١- دانشجوي دكتري مهندسي محيط زيست، دانشگاه تهران

٢- استاد دانشكدة محيط زيست دانشگاه تهران

٣- دانشجوي كارشناسي ارشد سازه‌هاي آبي، دانشگاه تربيت مدرس تهران

۴-كارشناس ارشد مديريت محيط زيست دانشگاه تهران

تاريخ دريافت: ٨۶/١٠/٣ تاريخ پذيرش:٨٧/٧/١٥

چكيده

پيش‌بيني كميت توليد، نقشي اساسي در بهينه‌سازي و برنامه‌ريزي سيستم مديريت مواد زايد جامد شهري دارد. اما به دليل طبيعت ناهمگون و تأثير عوامل متنوع و خارج از كنترل بر توليد، همواره با مشكلات زيادي همراه بوده است. شبكة عصبي مصنوعي اخيراً در بسياري از كاربردهاي مهندسي نظير مهندسي محيط زيست به عنوان ابزاري قدرتمند در مدلسازي مورد توجه قرار گرفته است. در اين تحقيق با توجه به ديناميک و پيچيده بودن سيستم مديريت مواد زايد جامد، از مدل تركيبي شبكة عصبي مصنوعي با تابع آموزش لونبرگ-ماركويت و تبديل موجک (مدل عصبي-موجكي) براي پيش‌بيني كميت توليد هفتگي در شهر تهران استفاده شده است. براي اين منظور از مجموعة زماني توليد اين شهر در فاصله زماني سالهاي ١٣٨٠ تا سه ماهة نخست ١٣٨٥ كه به صورت هفتگي مرتب شده بودند، استفاده شد. بعد از آموزش و تست مدلهاي شبكه عصبي و شبكه عصبي-موجكي نتايج اين مدلها با يكديگر مورد مقايسه قرار گرفت. نتايج به‌دست‌آمده از اين تحقيق نشان مي‌دهد كه استفاده از تبديل موجک در پيش‌پردازش متغيرهاي ورودي، تأثير مثبتي در پيش‌بيني ميزان توليد هفتگي در اين شهر ايجاد كرده، به‌طوري‌كه موجب افزايش چشمگيري در دقت محاسبات مدل شده است. اين بهبود در مورد ضريب همبستگي مدل‌ها (R^2) در مرحلة صحت‌سنجي، از ٠/٥ در مدل شبكة عصبي به ٠/٩ در مدل شبكة عصبي-موجكي است. همچنين معيار قدرمطلق ميانگين خطاي نسبي نيز در مدل شبكه عصبي از ۵/٩٩ درصد به ١/٩٢ درصد در مدل شبكه عصبي-موجكي كاهش پيدا كرده است.

كليد واژه

پيش‌بيني هفتگي توليد- شبكة عصبي مصنوعي- شبكة عصبي-موجكي- تهران

سرآغاز

سيستم مديريت مواد زايد جامد كلانشهرهاي كشورهاي در حال توسعه، همواره با مشكلات فرواني روبه‌رو بوده است. ايجاد چنين سيستمي به علت پيچيدگي و طبيعت بسيار ناهمگن توليد زباله و دخالت عوامل غير قطعي در آن مشكلات خاص خود را دارد. از طرفي بي‌توجهي به اين مسئله نيز مي‌تواند سلامت جامعه را با خطرهاي زيادي روبه‌رو كند. يكي از عوامل بسيار مهم در راه‌اندازي صحيح چنين سيستمي، شناخت كميت توليد است، زيرا كميت توليد در تعيين حجم سرمايه‌گذاري براي ماشين آلات، ظروف ذخيره در محل، ايستگاههاي انتقال، ظرفيت دفع، سازماندهي و تشكيلات مناسب، مؤثر است. تا به حال روش‌هاي زيادي براي تخمين نرخ توليد زباله ارائه شده كه از مهم‌ترين اين روش‌ها مي‌توان به روش‌هاي سنتي، نظير آناليز وزني-حجمي و آناليز توازن مواد و روش‌هاي جديدتر مانند رگرسيون خطي چند متغيره (عبدلي و همكاران، ١٣٨۶) و شبكة عصبي مصنوعي (ANN[1]) (جليلي و نوري، ٢٠٠٨) اشاره كرد. هر كدام از روش‌هاي ذكر شده داراي محدوديت‌هايي هستند. براي مثال در روش‌هاي سنتي به دليل اين‌كه ميزان توليد جامدات اغلب به منزلة تابعي از عواملي، نظير آمار جمعيت و عوامل اقتصادي- اجتماعي آن جامعه استوار است، (به صورت ضرايب توليد به ازاي هر نفر محاسبه مي‌شود)، مشكل اساسي، تغييرپذيري اين ضرايب است كه براي

نويسندةمسئول: تلفن: ٠٩٣٧۴٣٢٠۵٢۶ E-mail: roohollahnoori@gmail.com

سيستم پوياي مديريت مواد زايد جامد به لحاظ ديناميك بودن آن كارايي خود را از دست مي‌دهد (جليلي و نوري، ٢٠٠٨). روش‌هاي رگرسيون خطي چند متغيره نيز در مواردي‌كه روابط بين ورودي‌ها و خروجي غيرخطي و پيچيده باشد، توان مدل‌سازي پديدة مورد نظر را ندارد (عبدلي و همكاران، ١٣٨۶). در مدل‌هاي ANN نيز با افزايش تعداد متغيرهاي ورودي، پيچيدگي محاسباتي و حافظه مورد نياز مدل به سرعت افزايش يافته و آموزش مدل مشكل و ناكارامد مي‌شود (Bowden, et al 2005). همچنين در مدل‌سازي پديده‌هاي گذرا با استفاده از اين مدل‌ها نياز به عمل پيش‌پردازش بر روي اطلاعات ورودي، يا خروجي است (Cannas, et al 2006). با وجوداين به دليل توانايي باالاي ANN در مدل‌سازي پديده‌هاي پيچيده و غيرخطي استفاده از آن در سيستم مديريت مواد زايد جامد موفقيت آميز گزارش شده است كه در همين زمينه مي‌توان به مطالعات Liu, et al (2002)(Chi, et al, 2005)، (Karaca, F., Özkaya, B. 2006) (Sahoo, et al. 2006 اشاره كرد. اخيراً استفاده از روش تركيبي مدل شبكة عصبي-موجكي (WNN^2) در مجموعه‌هاي زماني فصلي، به منظور بالا بردن دقت محاسبات در مطالعات مختلف در ديگر زمينه‌هاي زيست محيطي، نظير آلودگي هوا (Sheng, & Li,. 2004) و كيفيت آب (Shujiang, & Henry. 2007) مورد توجه قرار گرفته و منجر به نتايج مطلوب‌تري نيز شده است. اين موضوع در مديريت مواد زايد جامد تا به حال مورد توجه قرار نگرفته و به آن پرداخته نشده است. به همين دليل در اين تحقيق تأثير پيش‌پردازش متغيرهاي ورودي به ANN توسط تبديل موجک (WT^3) بررسي و در قالب مطالعه‌اي موردي، توانايي مدل WNN براي پيش‌بيني توليد هفتگي شهر تهران ارزيابي و با نتايج ANN مورد مقايسه قرار گرفته است. بدين منظور با توجه به آمار و اطلاعات در دسترس و نقش مؤثر الگوهاي فصلي توليد بر ميزان زبالة توليدي، مجموعة زماني هفتگي توليد زبالة تهران در فاصله زماني بين سالهاي ١٣٨٠ تا سه ماهه نخست ١٣٨۵ به عنوان ورودي به هر كدام از مدل‌ها، مورد استفاده قرار گرفت و نتايج به‌دست‌آمده با يكديگر مقايسه شدند.

مواد و روش‌ها

منطقة مورد مطالعه

شهر تهران به‌منزلة كلانشهر، در كوهپايه‌هاي جنوبي رشته كوه البرز گسترده شده است. طي يك دورة ٣٠ ساله (از سال ١٣۴۵ تا ١٣٧۵)، ميانگين بارندگي سالانه ٢۴٠ ميليمتر و ميانگين تعداد روزهاي يخبندان ۴٨ روز در سال براي اين شهر گزارش شده است (بختياري، ١٣٨۵). جمعيت اين شهر نيز مطابق با آخرين آمارگيري، حدود ٨ ميليون نفر است (مركز آمار ايران، ١٣٨۵). در سالهاي اخير افزايش مهاجرت به اين شهر باعث گسترش بي‌رويه آن شده كه يكي از نتايج مضر آن ايجاد مشكل براي سيستم مديريت مواد زايد جامد بوده، به‌طوري‌كه اين شهر، مطابق با گزارش سازمان بازيافت و تبديل مواد، با توليد ٢/٧۵ ميليون تن زباله در سال ١٣٨۴ (٢/۴٢ ميليون تن در سال ١٣٨٠)، هم اكنون بزرگترين مركز توليد زباله در ايران است. مطابق با آمار موجود، ميزان زبالة توليدي شهر تهران از ۴۵٠٠ تا ١٠٠٠٠ تن در روز در حال نوسان است. بنابراين ارائة مدلي مناسب براي تخمين ميزان كميت مواد زايد توليدي و شناخت نوسانات آن مي‌تواند كمک زيادي در برنامه‌ريزي صحيح و تصميم‌گيري ارگان‌هاي مسئول در اين زمينه داشته باشد. براي اين منظور و همچنين تخمين توليد زباله در يک هفته بعد، از مجموعة زماني توليد اين شهر در سالهاي ١٣٨٠ تا سه ماهه نخست ١٣٨۵ كه به صورت هفتگي مرتب شده بودند با ١٢ تأخير زماني به عنوان ورودي به مدل شبكة عصبي و شبكة عصبي-موجكي استفاده شد.

شبكة عصبي مصنوعي

با توجه به مراجع كافي براي ANN Haykin, 1999 Maier &, Dandy. 2000)، در اين تحقيق به توضيحاتي اندک در مورد نوع شبكة مورد استفاده و تقسيم‌بندي متغيرهاي مسئله براي ورود به مدل‌هاي مذكور اشاره مي‌شود. معماري معمول ANN متشكل از سه لايه شامل لاية ورودي، لاية پنهان و لاية خروجي است (شكل شمارة١). يك شبكه مي‌تواند چندين لاية پنهان داشته باشد. به هر حال كارهاي نظري انجام گرفته در اين زمينه نشان داده‌اند كه يك لاية پنهان براي اين گونه مدل‌ها مي‌تواند هر تابع پيچيده و غيرخطي را تقريب زند Cybenko, G.1989,Hornik, et al,. 1989, Zhang, et al. 1998). همچنين نتايج تجربي و عملي نيز اين موضوع را تأييد مي‌كنند (Zhang, et al. 1998). بنابراين در اين تحقيق تلاش شده است تا از شبكه عصبي پرسپترون چند لايه با يك لايه پنهان براي پيش‌بيني توليد استفاده شود. همچنين براي صرفه‌جويي در زمان و جلوگيري از مشكل فوق برازشي در شبكه، طبق توصيه Coulibaly, et al,. 2000) متغيرهاي مورد استفاده به سه دسته شامل دستة نظارت بر آموزش، دستة آموزش و دستة صحت‌سنجي تقسيم شدند. تابع انتقال نيز به عنوان تابع سيگموئيد انتخاب شد كه معمول‌ترين تابع عضويت مورد استفاده در ANN است Maier &, Dandy. (2000).

تبديل موجک

طبق تعريف، موجک[۴] يک موج کوچک است که انرژي آن در ناحية کوچکي متمرکز شده و ابزار مناسبي براي بررسي پديده‌هاي گذرا[۵] است. موجک داراي نوسان حداقلي بوده که به سمت صفر نزول مي‌کند و اين نزول مي‌بايد در جهات مثبت و منفي واقع در دامنه‌اش محدود شود. اين مشخصه موجب مي‌شود که موجک انعطاف‌پذير بوده و مانند نوعي تابع رفتار کند.

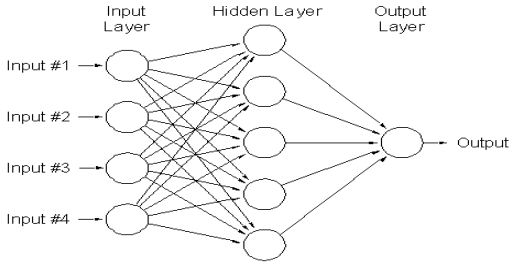

شکل شمارة(۱): شبکة عصبي از نوع Feed forward

تبديل موجک شامل دو قسمت تبديل پيوسته[۶] و تبديل گسسته[۷] موجکي است. تبديل پيوستة موجکي، مشابه تبديل قطعه‌اي فوريه است و براي تابع f(t) به صورت زير تعريف مي‌شود:

$$C(Scale, Position) = \int_{-\infty}^{+\infty} f(t)\psi(Scale, Position)dt \qquad (۱)$$

و يا به بيان ديگر :

$$CWT_S^{\psi}(a,b) = \frac{1}{\sqrt{|a|}}\int_{-\infty}^{+\infty} s(t)\psi^*_{a,b}(t)dt \qquad (۲)$$

رابطة فوق تابعي از دو متغير a و b است که a مبين مقياس[۸] (برابر پريود) و b نشان‌دهندة انتقال[۹] است. علامت * براي نشان دادن مزدوج مختلط استفاده‌شده است. S (t) سيگنال مورد نظر و (t) تابع انتقال بوده و موج مادر[۱۰] ناميده مي‌شود. برخلاف تبديل قطعه‌اي فوريه، در تبديل پيوستة موجکي پهناي تابع موجکي به کار رفته متغير است؛ به طوري‌که براي هر مؤلفه موج مي‌توان عرض مناسبي انتخاب کرد که اين موضوع مهم‌ترين مزيت تبديل موجکي است. مشکل بزرگ تبديل پيوسته موجکي، زمان‌بر بودن آن و همچنين توليد مقدار زيادي اطلاعات است، چرا که در اين نوع تبديل، ضرايب موجکي در هر مقياس ممکن محاسبه مي‌شوند. براي حل اين مشکل، تبديل موجکي فقط براي زيرمجموعه‌اي از "مقياس‌ها و موقعيت‌ها"[۱۱] انجام مي‌شود (تبديل گسسته موجکي). چنانچه مقياس و موقعيت بر پاية توان دو انتخاب شوند (مقياس و موقعيت دوگانه)، تحليل سيگنال بسيار سريع‌تر و با دقت کافي انجام مي‌شود. با اعمال تبديل مذکور، داده‌هاي اوليه موجکي شده و به دو دسته تقسيم مي‌شوند. دستة اول که تقريب[۱۲] ناميده مي‌شوند، داراي فرکانس کم (پريود زياد) بوده و نشان‌دهندة روند کلي داده‌هاي موجودند. اين دسته در محاسبات نقش بسيار مهمي ايفا مي‌کنند. دستة دوم جزئيات[۱۳] نام دارند که فرکانس بالا (پريود کم) دارند و مبين تغييرات محدود در داده‌ها هستند. در شکل شمارة (۲) تجزيه داده‌ها به مجموعه‌هاي ذکر شده نشان داده شده است.

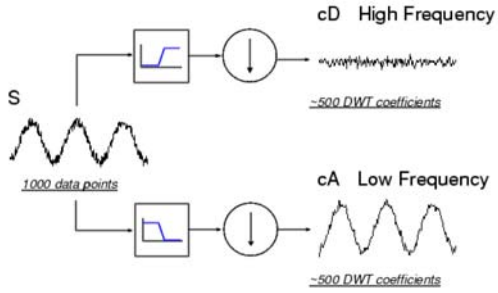

شکل شمارة(۲): تجزة موج اوليه به امواج ثانويه تقاريب و جزئيات

تا به حال موجک‌هاي زيادي معرفي و در مسائل مختلف استفاده شده‌اند که موجک هار[۱۴] يکي از ساده‌ترين انواع آنهاست. در اين تحقيق با توجه به مزاياي ذکر شده براي تبديل گسستة موجکي از اين نوع تبديل استفاده شده است. همچنين موجک ((S+P(4,4)) نيز با توجه به نتايج مطلوب آن در مطالعات قبلي به عنوان موجک مناسب انتخاب شده است (Calder bank, et al. 1997).

معيارهاي مورد استفاده براي ارزيابي نتايج

براي مقايسة نتايج خروجي مدل‌ها، ۴ معيار آماري متداول استفاده شد که عبارتند از: ضريب همبستگي R^2، ميانگين خطاي مطلق (MAE[15])، ريشه ميانگين مربعات خطا (RMSE[16]) و شاخص ميانگين قدرمطلق خطاي نسبي (AARE[17]). بهترين عملکرد مدل بر اساس معيار R^2، مقدار يک را به‌همرا دارد و براي ساير معيارها صفر است. اما، اين شاخص‌ها مبين متوسطي از خطا در عملکرد مدل‌اند و اطلاعاتي در مورد توزيع خطا را در نتايج ارائه نمي‌کنند. بدين منظور روش تحليل آستانة خطا (TS[18])(Jain, & Indurthy,. 2003) ؛ (Jain, & Ormsbee, 2004 نيز مورد استفاده قرار گرفت. شاخص TS_X براي مقدار x% از پيش‌بيني‌ها، نشان‌دهندة توزيع خطا در مقادير پيش‌بيني شده براي هر مدل است. اين شاخص که برحسب درصد تعريف مي‌شود براي مقادير مختلف قدرمطلق خطاي نسبي (ARE[19]) ارائه مي‌شود. مقدار TS براي x% از پيش‌بيني‌ها طبق رابطة زير به‌دست مي‌آيد:

$$TS_X = \frac{Y_X}{n} \times 100 \qquad (۳)$$

که در آن Y_X تعداد میزان زبالهٔ هفتگي پيش‌بيني‌شده (از کل تعداد n) براي هر مقدار مطلق خطاي نسبي کمتر از x% است.

بحث و نتايج (واسنجي مدل شبکهٔ عصبي)

ابتدا هر کدام از متغيرها قبل از ورود به شبکهٔ عصبي لازم است استاندارد شوند که در اين تحقيق از رابطهٔ (۴) استفاده شد (Rajurkar, et al. 2004).

$$N = 0.8 \times \frac{(X_i - MIN_{X_i})}{(MAX_{X_i} - MIN_{X_i})} + 0.1 \qquad (۴)$$

در رابطهٔ (۴) X_i متغيرنام، MIN_{X_i} و MAX_{X_i} به ترتيب حداقل و حداکثر مقدار متغيرنام و N نيز مقادير استاندارد شده است. با استفاده از اين رابطه، محدودهٔ هر متغير بين ۰/۱ تا ۰/۹ قرار مي‌گيرد. بعد از استاندارد کردن ۱۲ متغير اوليه و با تغيير تعداد نرون‌ها در لايهٔ پنهان شبکه، مدل‌هاي متفاوتي از پيش‌بيني توليد ايجاد شد که در نهايت با توجه به معيارهاي مورد بررسي در اين تحقيق، مدل با ۵ نرون در لايهٔ پنهان به منزلهٔ بهترين مدل در اين مرحله برگزيده شد (ساختار ۱-۵-۱۲). نتايج مراحل آموزش (شامل دو دسته نظارت بر آموزش و دستهٔ آموزش) و صحت سنجي اين مدل در جدول شمارهٔ (۱) و شکل‌هاي شمارهٔ (۳ و ۴) نشان‌داده‌شده است.

واسنجي مدل شبکهٔ عصبي - موجکي

در اين بخش ابتدا موجک مناسب ((S+P(4,4)) انتخاب شد. سپس با اعمال تبديل روي داده‌ها، ضرايب تقريب و جزئيات آنها استخراج و داده‌ها موجکي شدند. در مرحلهٔ بعد، مدل مناسب شبکهٔ عصبي تعيين شد و براي ارزيابي نهايي، مجددا داده‌ها غيرموجکي[۲۰] شدند. در اين مرحله نيز با توجه به معيارهاي ارزيابي، مدل با ۳ نرون در لايهٔ پنهان به‌عنوان مدل بهينه پيش‌بيني توليد زباله انتخاب شد. نتايج نهايي مراحل آموزش (شامل دو دسته نظارت بر آموزش و دستهٔ آموزش) و صحت سنجي اين مدل در جدول شمارهٔ (۱) و شکل‌هاي شمارهٔ (۳و۴) نشان‌داده‌شده است.

جدول شمارهٔ(۱): نتايج آموزش و صحت سنجي مدل‌هاي ANN و WNN

معيار مورد بررسي	مرحله آموزش		مرحله صحت سنجي	
	ANN	WNN	ANN	WNN
RMSE	۲۳٦٥/۳۳	٦٤۹/۸۴۶	۳۹۰۱/۷۷	۱۳۵۵/۷۹
MAE	۱۸۵۷/۷۵	٦۳۷/۲٦	۳۱۰٤/۲۷	۹۸۷/۳۵
AARE	۳/۸۱%	۱/۳۳%	۵/۹۹%	۱/۹۲%
R^2	0.51	0.94	0.4	0.91

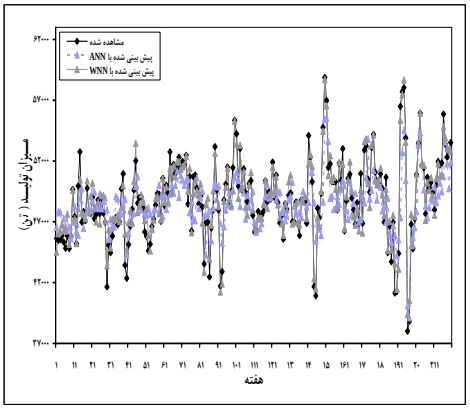

شکل شمارهٔ(۳): نتايج مرحلهٔ آموزش شبکه براي دو مدل ANN و WNN

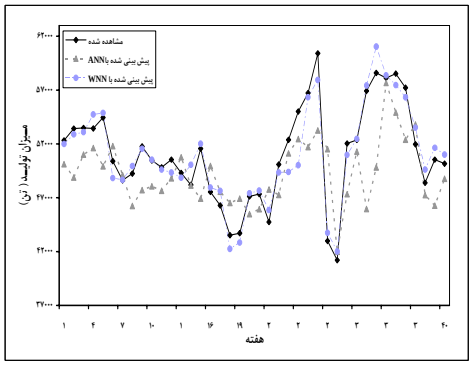

شکل شمارهٔ(۴): نتايج مرحلهٔ صحت‌سنجي شبکه براي دو مدل ANN و WNN

ارزيابي دو مدل

در اين تحقيق براي گزينش مدل برتر از بين مدل‌هاي ANN و WNN، از نمودار پراکندگي قدرمطلق مقادير خطاي نسبي استفاده شد. نتايج اين تحليل در شکل شمارهٔ (۵) براي مرحلهٔ صحت‌سنجي هر دو مدل مشهود است. با توجه به اين نمودار مي‌توان تشخيص داد که خطاي هر درصد از پيش‌بيني‌هاي انجام شده توسط دو مدل، به چه ميزان است. براي مثال با توجه به شکل شمارهٔ(۵) مي‌توان گفت که ARE براي تست مدل ANN کمتر از ۲۰ درصد است، درحالي‌که اين مقدار براي مدل WNN حدود ۹ درصد است. ۷۵ درصد پيش‌بيني‌هاي مدل ANN درمرحلهٔ تست داراي خطاي کمتر از ۸/۳ درصدند، درحالي‌که در مدل WNN اين خطا برابر ۲/۵ درصد است. پس با توجه به اين مطلب، مدل ايجاد شده توسط WNN با يك لايهٔ پنهان شامل ۳ نرون، به‌منزلهٔ مدل برگزيده براي پيش‌بيني هفتگي توليد در شهر تهران، انتخاب مي‌شود.

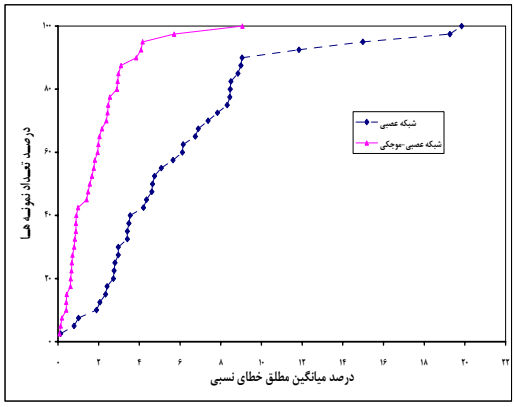

شكل شمارة(۵): تحليل آستانة خطاي مطلق نسبي براي دو مدل ANN و WNN

نتيجه‌گيري

با توجه به اهميت پيش بيني كميت توليد در مديريت مواد زايد جامد، هدف از اين مقاله ارائة مدلي مناسب براي اين منظور بود. بااين‌هدف و با توجه به پيچيده بودن فيزيک مسئلة توليد زباله و دخيل بودن عوامل متعدد و متغير در آن، از تركيب شبكة عصبي مصنوعي و تبديل موجک (شبكة عصبي-موجكي) كه قادر به مدل‌سازي پديده‌هاي پيچيده و غير خطي است، استفاده شد و نتايج به‌دست‌آمده از اين مدل با نتيجه شبكة عصبي مقايسه شد. نتايج به‌دست‌آمده حاكي از تأثير مهم پيش‌پردازش متغيرهاي ورودي به شبكة عصبي توسط موجک است. به‌نحوي‌كه با استفاده از شبكة عصبي-موجكي دقت محاسبات نسبت به مدل شبكة عصبي به طور چشمگيري بهبود يافت. مطالعات انجام شده در اين مقاله مي‌تواند مكمل طرح‌هاي تحقيقاتي پيش‌بيني در سيستم مديريت مواد زايد جامد كشور باشد و استفاده از آن به‌دين منظور پيشنهاد مي‌شود.

يادداشت‌ها

1- Artificial Neural Networks
2- Wavelet-Neural Network
3- Wavelet Transform
4- Wavelet
5- Non-Stationary
6- Continence Wavelet Transform
7- Discrete Wavelet Transform
8- Scale
9- Translation
10- Mother Wavelet
11- Scales & Positions
12- Approximations
13- Details
14- Haar Wavelet
15- Mean Absolute Error
16- Root Mean Square Error
17- Average Absolute Relative Error
18- Threshold Statistic
19- Absolute Relative Error
20- Ant wavelet

منابع مورد استفاده

بختياري، س. ۱۳۸۵. اطلس كامل تهران. مؤسسة جغرافيايي و كارتوگرافي گيتاشناسي، تهران.

عبدلي، م.ع.، نوري، ر.، جليلي، م.، صالحيان، ا. ۱۳۸۶. پيش‌بيني زبالة توليدي تهران با استفاده از شبكة عصبي مصنوعي و روش‌هاي آماري چندمتغيره. سومين همايش ملي پسماند، تهران، صفحات ۷۲-۶۱.

Bowden, G.J., G.C. Dandy, H.R Maier, .2005. Input determination for neural network models in water resources applications. Part 1—background and methodology. Journal of Hydrology, 301: 75-92.

Calder bank, R., et al .1997. Lossless Image Compression using Integer to Integer Wavelet Transforms. ICIP IEEE Press, vol. 1, pp. 596-599.

Cannas, B., et al .2006. Data preprocessing for river flow forecasting using neural networks: Wavelet transforms and data partitioning. Physics and Chemistry of the Earth, 31: 1164-1171.

Chi, Y., et al .2005. HCl emission characteristics and BP neural networks prediction in MSW/coal co-fired fluidized beds. Journal of Environmental Sciences, 17: 699-704.

Coulibaly, P., F. Anctil, B. Bobee, .2000. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. Journal of Hydrology, 230: 244-257.

Cybenko, G.1989. Approximation by superposition of a sigmoidal function. Math. Control Signals Syst., 2: 303–314.

Haykin, S., (1999). Neural networks: A comprehensive foundation. 2nd ed., Prentice Hall., New Jersey.

Hornik, K., M. Stinchcombe, H. White, .1989. Multilayer feed forward networks are universal approximates. Neural Networks, 2: 359 – 366.

Jain, A., S.K.V.P. Indurthy .2003. Comparative analysis of event based rainfall-runoff modeling techniques-deterministic, statistical, and artificial neural networks. Journal of Hydrologic Engineering ASCE, 8: 93–98.

Jain, A., L.E. Ormsbee, .2004. An evaluation of the available techniques for estimating missing fecal coliform data. J. Am. Water Resour. Assoc., 40: 1617–1630.

Jalili, M., R. Noori, .2008. Prediction of Municipal Solid Waste Generation by Use of Artificial Neural Network: A Case Study of Mashhad. Internatinal Journal of Environmental Research.

Liu, Z.F., et al .2002. Recycling strategy and a recyclability assessment model based on an artificial neural network. Jour.of Materials Processing Technology, 129: 500–506.

Karaca, F., B. Özkaya, .2006. NN-LEAP: A neural network-based model for controlling leach ate flow-rate in a municipal solid waste landfill site. Environmental Modeling & Software, 21: 1190-1197.

Maier, H.R., G.C. Dandy,. 2000. Neural networks for the prediction and forecasting of water resources variables: a review of modeling issues and applications. Journal of Hydrology, 15: 101-124.

Rajurkar, M.P., U.C. Kothyarib, U.C. Chaube,. 2004. Modeling of the daily rainfall-runoff relationship with artificial neural network. Journal of Hydrology, 285: 96–113.

Sahoo, G.B., C. Ray, E.H. DeCarlo,. 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.

Sheng, T.L., Li, Y.S. 2004. Data mining to aid policy making in air pollution management. Expert Systems with Applications, 27: 331–340.

Shujiang, K., L. Henry, .2007. Wavelet analysis of hydrological and water quality signals in an agricultural watershed. Journal of Hydrology, 338: 1– 14.

Zhang, G., B.E. Patuwo, Hu, M.Y. 1998. Forecasting with artificial neural networks: the state of the art. Int. J. Forecasting, 14: 35– 62.

http://www.sci.org.ir/portal/faces/public/census85/census85.natayej/census85.agetownship.