

مطالعه تطبیقی مدل شبکه عصبی مصنوعی (ANN) و مدل عصبی- فازی وفقی (ANFIS) در پیش‌بینی تقاضای پروانه ساخت (مطالعه موردی: شهرداری زابل)

غلامعلی خمسر: استادیار جغرافیا و برنامه‌ریزی شهری، دانشگاه زابل، زابل، ایران
وحید پاسبان عیسی‌لو: دانشجوی کارشناسی ارشد جغرافیا و برنامه‌ریزی شهری، دانشگاه زابل، زابل، ایران*

چکیده

اطلاع از میزان تقاضای موجود در زمینه صدور پروانه ساخت در هر دوره یکی از مباحث اساسی است که شهرداری‌ها در راه پاسخگویی به تقاضاکنندگان نیازمند آن هستند. عدم اطلاع در این زمینه سبب ایجاد مشکلاتی مانند اتلاف وقت و انرژی، کاهش کارایی و نارضایتی ارباب رجوع و در نهایت فقدان برنامه‌ریزی مدون را سبب می‌شود. با توجه به روند پرنوسان و غیرخطی انگیزه افراد برای ساخت‌وساز و در ادامه تهیه مجوز ساخت از شهرداری و متغیرهای موثر بر آن، مدل‌های غیرخطی و بخصوص شبکه‌های عصبی (ANN) و سیستم استنتاج عصبی فازی تطبیقی (ANFIS) در این امر توفیق بیشتری داشته‌اند. به این منظور ترکیبی از اساسی‌ترین پارامترهای برون بخشی و درون بخشی تاثیرگذار در تصمیم‌گیری افراد برای ساخت‌وساز یعنی جمعیت شهر و نرخ رشد آن، متوسط درآمد و هزینه خانوار شهر (زابل)، تاثیر فصل‌های مختلف سال در قالب عامل دما، میزان تولید ناخالص داخلی (در سطح کلان)، تورم، ونوسانات مربوط به نرخ ارز (به عنوان پارامترهای برون بخشی) و عواملی مانند زمین و قیمت آن، تراکم و نرخ عوارض ساخت و ساز (به عنوان عناصر درون بخشی) در نظر گرفته شده‌اند. در این بین برای مقایسه توانایی آن‌ها نسبت به هم از معیارهای ارزیابی کارایی مدل‌ها مانند (ضریب تعیین)، MAD (میانگین قدر مطلق انحرافات) و RMSE (ریشه میانگین مربع خطا) استفاده شده است. در نهایت ANFIS به دلیل اتکا به ترکیب ((قدرت یادگیری شبکه عصبی و عملکرد منطقی سیستم‌های فازی))؛ با مقدار R^2 (۰/۹۶۵۶)، RMSE (۰/۰۰۲۶)، MAD (۰/۰۰۶۴)، (۰/۰۰۱۸)، (۰/۰۰۶۱) به ترتیب برای آموزش و آزمون، بر روش ANN برتری نشان داده در نتیجه مدل مناسب‌تری برای پیش‌بینی هدف ماست.

واژه‌های کلیدی: تقاضای پروانه ساخت، شبکه عصبی مصنوعی، ANFIS

۱-مقدمه

موجود و تسریع در روند صدور پروانه ساخت هموار و تا حد زیادی اهداف طرح حاضر را تامین کرد.

۱-۱- طرح مسأله

در کشور ما سالانه زمین‌های چشم‌گیری به زیر ساخت‌وساز می‌رود و طبیعتاً شهرداری نیز طبق اختیارات تعریف شده مسئول صدور جواز مربوط به این امر است. در این بین یکی از مشکلات اساسی که شهرداری‌ها در راه پاسخگویی به نیازهای مراجعه کنندگان با آن مواجه هستند، عدم اطلاع دقیق از میزان تقاضای موجود در هر دوره زمانی است. لازم به ذکر است که این موضوع به نوبه خود سبب ایجاد مشکلاتی از جمله عدم آگاهی از تعداد متقاضیان، و به پیرو آن بی‌اطلاعی از میزان خدمات و تسهیلات قابل ارائه در آینده و همچنین فقدان برنامه کنترلی و در نتیجه مجهول ماندن تقاضاهای صورت گرفته در هر دوره زمانی می‌شود.

با توجه به اینکه شهرداری‌ها و سازمان‌های نظام مهندسی ساختمان، مهمترین متولیان ساخت و سازهای شهری هستند عدم وجود هماهنگی‌های تنگاتنگ بین آن‌ها از عوامل اساسی تاثیرگذار در کندی فرایند صدور پروانه ساخت می‌باشد. که این مسأله به نوبه خود میتواند باعث سرگردانی ارباب رجوع و شاید انصراف آن‌ها از طی مراحل قانونی برای ساخت و ساز و در نتیجه شکل گیری ساخت و سازهایی خارج از ضوابط قانونی و خود رو بینجامد.

پر واضح است که ایرادهای موجود در مسیر صدور پروانه های ساختمانی، بیشتر مشکلات اجرایی اند نه اینکه خلاء قانونی در این زمینه وجود داشته باشد. بنابراین، می توان با بهبود نظارت ها و بهره‌وری از مدل‌های نوین در این زمینه راه را برای اجرای قوانین

۱-۲- اهمیت و ضرورت

امروزه مسأله پیش‌بینی و آینده‌نگری یکی از نیازهای مبرم سازمان‌هاست و شهرداری‌ها نیز از این مقوله مستثنی نیستند. شهرداری‌ها با توجه به حجم بالای فعالیت‌هایی که در رابطه با شهر و کارکردهای آن انجام می‌دهند؛ با به کارگیری پیش‌بینی‌های دقیق و علمی‌تر می‌توانند بخش اعظمی از ترافیک کاری خود را کنترل و باعث افزایش بازدهی مطلوب و در عین حال کاهش هزینه‌ها شوند. یکی از موارد اساسی آن پیش‌بینی تقاضای مربوط به پروانه ساخت در شهر می‌باشد که از جمله مسئولیت‌های اساسی شهرداری است که با نیل به این هدف از سویی باعث افزایش کارایی شهرداری و تخمینی از میزان درآمد آینده آن و از سوی دیگر ترتیب اشرادان به تقاضاهای ارباب رجوع در کمترین زمان ممکن می‌شود.

با توجه به اهمیت مسأله‌ی پیش‌بینی در تمام علوم، در دهه‌های اخیر مدل‌ها و روش‌های مختلفی در این رابطه به بازار علم عرضه شده است. از مدل‌سازی-های آماری خطی نظیر مدل خودرگرسیون میانگین-متحرک انباشته^۱ (ARIMA) گرفته تا مدل‌های غیرخطی مانند شبکه‌عصبی مصنوعی^۲ (ANN)، سیستم‌استنتاج‌عصبی‌فازی تطبیقی^۳ (ANFIS) و الگوریتم ژنتیک که مدل‌های اخیر به دلیل دقت بالایی که در پیش‌بینی دارند دارای کاربردهای اساسی در سال‌های اخیر بوده اند.

1- Auto Regressive Integrated Moving Average

2- Artificial Neural Network

3- Adaptive Neural Fuzzy Inference System

شبکه‌های عصبی، شبکه‌های عصبی فازی و پیشینه کاربرد آنها

بیشتر ادبیات پیش‌بینی توسط محققانی چون ژانک، پاتوو و هو (۱۹۹۸) با مقاله‌ای با عنوان پیش‌بینی با استفاده از شبکه عصبی مصنوعی، و کاربردهای اخیر توسط سوانسون و وایت، داربلی و اسلمسما، کوی و تکاز (۲۰۰۰) پیش‌بینی‌های کوتاه مدت با استفاده از شبکه عصبی صورت گرفته است. البته علیرغم قدرت و شهرت این مدل‌ها، کارکرد مدل‌های شبکه عصبی در پیش‌بینی تجربی، به صورت ترکیبی است (ژانک و همکاران: ۱۹۹۸). در زمینه داده‌های اقتصادی سوانسن و وایت (۱۹۹۷) عملکرد مدل‌های شبکه عصبی را در پیش‌بینی سری‌های زمانی اقتصاد کلان مطالعه کرده اند. هم‌چنین در ایالات متحده آمریکا، مودی، لوین و ره‌فوس (۱۹۹۳) با تمرکز بر تولید ادغامی در صنعت؛ دریافتند که مدل شبکه عصبی بر مدل خطی در افق‌های ۶ ماهه و بیشتر ارجحیت دارد. تکاز (۲۰۰۱) نشان داد که تولید ناخالص داخلی کانادا در دوره‌های یک ساله توسط شبکه عصبی بهتر از مدل‌های خطی پیش‌بینی می‌شوند. در کاربرد متفاوت دیگری، کوی (۲۰۰۱) مفید بودن مدل شبکه‌های عصبی را در پیش‌بینی متغییر دودویی نشان‌دهنده بحران اقتصادی بررسی می‌کند. در زمینه مطالعات داخلی نیز آقای زمانی و همکارانش (۱۳۹۱) تحقیقی در پیرامون پیش‌بینی درآمد شهرداری تهران با استفاده از شبکه عصبی مصنوعی را انجام دادند که با توجه به اهمیت پیش‌بینی درآمد و هزینه‌های شهرداری در بودجه‌بندی سالانه از دو روش شبکه عصبی (ANN) و روش (SVM) استفاده کردند که نتایج به دست آمده از

در زمینه کاربرد مدل‌های عصبی در پیش‌بینی سری‌های زمانی؛ فهیمی‌فرد (۲۰۰۹)، آذربایجانی و همکاران (۲۰۰۷)، ای‌نس و همکاران (۲۰۰۵)، هروی و همکاران (۲۰۰۴)، اولسن و موسن (۲۰۰۳)، رچ (۲۰۰۲)، مشیری و کامرون (۲۰۰۰)، اثنی عشری (۱۳۸۶)، نجفی و همکاران (۱۳۸۵)، مشیری و مروت (۱۳۸۴)، روشن (۱۳۸۳)، اصفهانیان (۱۳۸۲)، به مطالعه و بررسی پرداخته و نتیجه گرفته‌اند که مدل‌های عصبی و ترکیبی عصبی فازی در مقایسه با مدل‌های خطی از عملکرد بهتری برخوردارند.

۱-۳- هدف تحقیق

با توجه به مسائل فوق، هدف این تحقیق برآورد تقاضای مربوط به پروانه ساخت و ارائه مدل مناسبی برای پیش‌بینی این تقاضا در آینده بوده است تا شهرداری بتواند بر بسیاری از مشکلات فایز آمده و شرایط تصمیم‌گیری را از حالتی نامطمئن به حالتی مطمئن هدایت کند. صرف نظر از تحقیقات صورت گرفته در زمینه پیش‌بینی، هدف این پژوهش، تمرکز بر توسعه روش‌های پیش‌بینی دقیق‌تر و معتبرتر است. با توجه به ناکارآمدی روش‌های رگرسیون خطی چندمتغیره در مدل‌سازی روابطی با ورودی‌ها و خروجی‌ها غیرخطی و پیچیده (بائو پینگ و زنگ کینگ، ۲۰۰۹: ۷۹۳، ۷۹۱؛ چائو و ونگ، ۲۰۱۰: ۹۲، ۱۰۷؛ دینگ و لیانگ، ۲۰۰۸: ۳۳۶۶، ۳۳۶۲) از مدل‌های ANN و ANFIS (هر دو از طیف روش‌های غیرخطی) به صورت مقایسه‌ای استفاده شده است.

ترکیبی پیچیده ای از ANN و FIS می باشد که منطق و درک نقاط ابهام را ضمیمه عملکرد شبکه عصبی می کند.

در این مقاله سعی بر آن بوده است که دو مدل پیش-بینی ANN و ANFIS را بصورت تطبیقی (در رابطه با تصمیم‌گیری های انسانی) بکار برده و در هر مرحله به بررسی نقاط ضعف و قوت هر دو مدل پرداخته و در نهایت به اثبات برتری سیستم استنتاج عصبی فازی تطبیقی نسبت به شبکه عصبی صرف بینجامد.

۱-۴- سوال تحقیق

آیا استفاده ترکیبی از مدل‌های غیرخطی سری زمانی مانند ANN و FIS در قالب ANFIS در رابطه با پیش‌بینی‌های مرتبط با مسائل انسانی می‌تواند منجر به نتیجه مطلوب شوند یا خیر؟

۱-۵- فرضیه تحقیق

به نظر می‌رسد مدل ANFIS به دلیل ترکیب قدرت یادگیری مدل ANN از یک سو و استفاده از منطق و تشکیل پایگاه قانون و داده های فازی از سوی دیگر مدل مناسبتری به منظور پیش‌بینی تصمیم‌گیری های انسانی است.

۱-۶- روش تحقیق

در این تحقیق از روش توصیفی تحلیلی، در کنار داده‌ها و اسناد جمع‌آوری شده از شهرداری زابل در رابطه با تقاضاهای مربوط به پروانه‌ساخت برای دوره زمانی ۹۰/۶/۱ تا ۹۲/۸/۲۹ (به عنوان داده های وابسته)، و داده‌های موجود در سایت مراجع رسمی کشور مانند بانک مرکزی، و مرکز آمار ایران (به عنوان داده های مستقل) همراه با نرم افزارهای متلب (Matlab) و (Excel) استفاده شده است.

روش شبکه عصبی به واقعیت نزدیک تر بوده است. وحید پورشهابی و همکارانش (۱۳۹۰) در پژوهشی با عنوان بررسی منابع درآمدی شهرهای جدید استان سیستان و بلوچستان به بررسی منابع درآمدی شهرداری‌های این شهرها و بررسی چالش‌های پیش روی نظام درآمدی و ارائه راهکارهای رویارویی با آن‌ها پرداخته که در نهایت به این نتیجه رسیده‌اند که این شهرها دارای منابع درآمدی متنوع نمی‌باشند. از سوی دیگر سیدمحمد فهمی فرد و همکاران (۱۳۸۷) در مقاله علمی پژوهشی مقایسه توان پیش‌بینی مدل عصبی فازی با مدل شبکه عصبی ANN در رابطه با پیش‌بینی قیمت هفتگی تخم مرغ به این نتیجه رسیدند که مدل ANFIS در مقایسه با مدل ANN در همه افاق‌های زمانی از کارایی بیشتری برخوردار است. بر طبق مطالعات اخیر بیش از پنجاه درصد مطالعات کاربردی بازرگانی شبکه عصبی گزارش شده، از شبکه های عصبی چند لایه پیش‌خور^۱ (MFNN) با قوانین الگوریتم یادگیری پس انتشارخطا^۲ (BP) استفاده کرده اند. این نوع شبکه عصبی به دلیل کاربردهای گسترده در بسیاری از ابعاد مسایل مربوط به مدیریت، مانند پیش‌بینی اصولی، طبقه‌بندی و مدل‌سازی، بسیار استفاده شده است. (MFNN) برای حل مسایلی که شامل یادگیری ارتباط بین یک مجموعه ورودی‌ها و خروجی‌های مشخصند، مناسب است. که در حقیقت یک تکنیک آموزش باناظر برای یادگیری ارتباطهای بین داده‌ها با استفاده از مجموعه داده های آموزشی است. لازم به یادآوری است که مدل ANFIS شکل

¹-Multi Feed Forward Neural Network

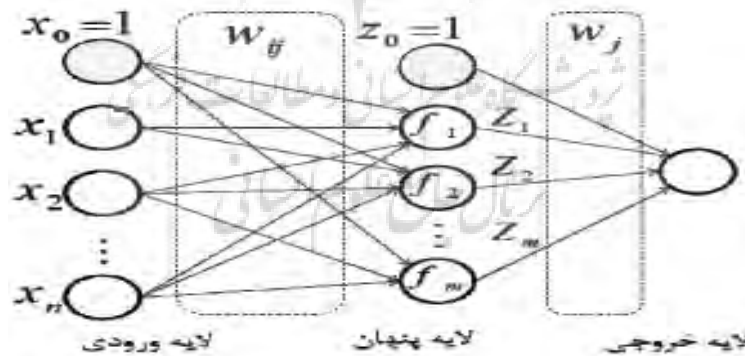
²- Back Propagation

۱-۷- معرفی مدل‌های استفاده شده در تحقیق

شبکه‌های عصبی مصنوعی (ANN)

مدل ANN از انواع مدل‌های محاسباتی است که قادر است رابطه میان ورودی‌ها و خروجی‌های یک سیستم هر چند پیچیده و غیرخطی را توسط شبکه‌ای از گره‌ها که همگی به هم متصل هستند، تعیین نماید. از مهمترین عوامل تعریف ANN به ساختار معماری آن میتوان اشاره کرد. معماری ANN به شکلی است که نرون‌ها در دسته‌هایی که لایه نام دارند مرتبط می‌شوند. ساختار معماری معمول ANN از سه لایه تشکیل می‌شود: لایه ورودی که داده‌ها را در شبکه توزیع می‌کند، لایه پنهان که داده‌ها را پردازش میکند، و لایه خروجی که نتایج را استخراج می‌کند. یک ANN میتواند چندین لایه پنهان داشته باشد. ولی پژوهش‌های تئوریک انجام گرفته در این زمینه نشان داده‌اند که با داشتن یک لایه پنهان برای این گونه مدل‌ها میتوان هر تابع پیچیده و غیرخطی را تقریب زد. همچنین نتایج تجربی و عملی نیز این

موضوع را تایید میکند (گاپتا و هاما ۲۰۰۳، هامیک و وایت ۱۹۸۹، لیو ۲۰۰۲: ۵۰۰). انواع مختلفی از شبکه‌های عصبی مصنوعی با توجه به اهداف تحقیق می‌توانند استفاده شوند که در این تحقیق از شبکه عصبی چندلایه پیش‌خور (MFNN) استفاده شده است. شبکه عصبی چندلایه پیش‌خور، همان‌طور که اشاره شد، مثالی از شبکه عصبی آموزش داده شده با استفاده از ناظر است. مدل‌های آموزشی باناظر؛ داده‌های آموزشی شامل اطلاعات کامل درباره خصوصیات داده‌ها و نتایج قابل مشاهده است. مدل‌ها می‌توانند ارتباط‌های بین این خصوصیات (ورودی-ها) و نتایج (خروجی‌ها) را آموزش دهند. MFNN به صورت تکراری این داده‌ها را تا زمانی که یاد بگیرند چگونه این ارتباط‌ها را به صورت صحیح نشان دهند، آموزش می‌دهد. شکل (۱) شبکه عصبی چندلایه پیش‌خور (MFNN) با قوانین الگوریتم یادگیری پس‌انتشار خطا (BP) را نشان می‌دهد که با یک لایه پنهان، برای نوع خاصی از پیش‌بینی به کار برده شده است.



شکل (۱) ساختار شبکه عصبی پیش‌خور سه لایه

لایه پنهان، و تعداد نرون‌های کافی در لایه پنهان، قادرند هر تابعی را با دقت دلخواه تقریب بزنند (کوان و وایت ۱۹۹۴: ۸۵). پیش‌تر در مطالعات مختلف اشاره

شبکه‌های عصبی پیش‌خور، کاربردی‌ترین نوع شبکه‌های عصبی مصنوعی می‌باشند، چرا که این نوع شبکه با یک لایه پنهان، تابع فعال‌سازی مناسب در

خروجی حقیقی در زمان k می‌باشد. معمولاً هدف الگوریتم بهینه‌یابی در چنین مسائلی، یافتن ضرایبی است که منجر به کمینه شدن رابطه فوق می‌گردد. الگوریتم پس‌انتشارخطا (BP) مهمترین و پرکاربردترین تکنیک بهینه‌یابی در آموزش شبکه‌های عصبی محسوب می‌شود. این الگوریتم در سال ۱۹۸۶ توسط راملهارت و مکنند مطرح شد (منهاج، ۱۳۸۴). نام پس انتشار خطای یادگیری با توجه به این که خطای محاسبه شده از لایه خروجی به لایه میانی و نهایتاً به لایه ورودی بازگشت داده می‌شود، انتخاب شده است. پس از آموزش شبکه عصبی از داده‌های آزمون ۲ (تصدیق)؛ به منظور بررسی میزان جامعیت شبکه و انتخاب بهترین شبکه آموزش دیده؛ استفاده می‌شود (منهاج و همکاران، ۱۳۸۹: ۲۰۳-۲۲۰). لازم به یادآوری است که الگوریتم پس‌انتشار-خطا تعمیم یافته قانون دلتا است.

قابلیت‌های شبکه عصبی]

محاسبه یک تابع معلوم

تقریب یک تابع ناشناخته

شناسایی الگو

پردازش سیگنال

یادگیری

شرایط لازم برای یادگیری شبکه‌های عصبی

در داده‌های آموزشی خطا وجود داشته باشد

مواردی که نمونه‌ها توسط مقادیر زیادی زوج

(ویژگی - مقدار) نشان داده شده باشد.

تابع هدف دارای مقادیر پیوسته باشد.

زمان کافی برای یادگیری وجود داشته باشد

شده است که چنین ساختار شبکه ساده‌ای دارای قابلیت بسیار بالایی در نگاشت میان ورودی و خروجی بوده و قادر به تخمین هر تابع پیوسته غیر خطی با دقت مطلوب در صورت استفاده از نرون‌های کافی در لایه پنهان می‌باشد (هومیک ۲۵۷-۱۹۹۱:۲۵۱). خروجی چنین شبکه‌ای را میتوان به صورت تابع (۱) نشان داد:

$$y(k) = \sum_{j=1}^m w_j f_j \left(\sum_{i=1}^n w_{ij} x_i(k) + w_{j0} \right) \quad (1)$$

در تابع فوق بردار $x_i(k) = [x_1(k), x_2(k), \dots, x_n(k)]^T$

متغیرهای ورودی در زمان k و $y(k)$ متغیر هدف،

w_j ضریب وزندهی به نرون پنهان i ام لایه آخر،

w_{j0} بایاس لایه خروجی، w_{j0} بایاس لایه

ورودی، w_{ij} ضرایب وزن دهی میان نرون i ام لایه

پنهان و ورودی i ام و f_i نیز تابع فعال‌سازی غیر-

خطی نرون i ام لایه پنهان می‌باشد. تابع هدف برای

آموزش چنین شبکه‌ای به صورت رابطه (۲) قابل تعریف است:

$$f(w) = \frac{1}{M} \sum_{k=1}^M (y_k^{\text{real}} - y_k^{\text{predict}})^2 \quad (2)$$

در رابطه فوق که نشان‌دهنده میانگین مجذور

خطاهای (RMSI) پیش‌بینی می‌باشد، M تعداد

مشاهدات در زمان‌های مختلف، y_k^{real} خروجی

حقیقی برای هر ورودی در زمان k و y_k^{predict} نیز

نشان دهنده خروجی شبکه به منظور پیش‌بینی مقدار

²- Test set

¹- Root Mean Square Error

وسيله شبکه‌های عصبی تعیین می‌شود. بنابراین، خصوصیات هر دو مدل فازی و عصبی در ANFIS نهفته است.

به طور کلی، شبکه عصبی مصنوعی برای مقصودی که ما از آن استفاده می‌کنیم، توانایی بالایی در توسعه یک مدل در زمان منطقی را ندارد. از طرف دیگر، مدل‌سازی فازی برای کاربرد ادغام تصمیمات از تغییرهای متفاوت نیازمند یک رویکرد برای یادگیری از تجربیات (داده‌های جمع‌آوری شده) است. شبکه‌های عصبی مصنوعی و مدل فازی در بسیاری از زمینه‌های کاربردی استفاده شده‌اند و هر کدام از آنها دارای محاسن و معایبی هستند. بنابراین، با ترکیب موفقیت‌آمیز این دو روش، مدل‌سازی شبکه‌های عصبی مصنوعی و فازی، استفاده شده و امروز روی آن کار می‌شود.

با ترکیب شبکه عصبی و منطق فازی به یک روش آموزش ترکیبی دست پیدا کرده‌ایم که به این صورت عمل می‌کند؛ در هر دوره آموزش، هنگام حرکت رو به جلو، خروجی‌های گره‌ها به صورت عادی تا لایه آخر محاسبه می‌شوند و سپس شاخص‌های نتیجه توسط روش کمترین مجموع مربعات خطا محاسبه می‌شوند. در ادامه، پس از محاسبه خطا در بازگشت رو به عقب نسبت خطا بر روی شاخص‌های شرط پخش شده و با استفاده از روش شیب نزولی خطا، مقدار آن‌ها تصحیح می‌شود.

نیاز به تعبیر تابع هدف نباشد (زیرا به سختی می‌توان وزن‌های یادگرفته‌شده توسط شبکه را تعبیر نمود)

سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) این مدل که توسط یانگ در سال ۱۹۹۶ بسط یافت، اجازه می‌دهد که سیستم‌های فازی در مباحث آموزش پارامترها، از الگوریتم آموزش انتشارخطابه عقب تطبیقی استفاده نمایند (مورگان، ۱۹۹۸). سیستم عصبی فازی را میتوان به عنوان ترکیبی از ANN و سیستم استنباط فازی (FIS) تعریف کرد. به این ترتیب الگوریتم‌های یادگیری شبکه عصبی برای تعیین شاخص‌های FIS استفاده می‌شود. یک جنبه مهم این است که سیستم درباره قوانین <> اگر... آنگاه << فازی، تفسیر بیشتری ارائه دهد، زیرا براساس سیستم فازی، برگرداننده مفاهیم علمی مبهم است. به دلیل استفاده شبکه‌های عصبی- فازی از دانش نظام ادراکی فازی و توانایی یادگیری آن، نظام عصبی- فازی قادر به مدل سازی دقیق عدم اطمینان و بی‌دقتی درونی داده‌ها به منظور استفاده از توانایی یادگیری شبکه‌های عصبی - فازی است. اگر چه عملکرد سیستم‌های عصبی- فازی متأثر از دامنه مسأله است، اغلب در مقایسه با شبکه عصبی صرف، نتایج بهتری را ارائه می‌دهد. یکی دیگر از مزایای شبکه‌های عصبی- فازی در مقایسه با شبکه عصبی، توان استدلال آن با استفاده از قواعد منطقی در حالات خاص است. مدل ANFIS دربرگیرنده دو مدل شبکه‌های عصبی و مدل فازی می‌باشد. بخش فازی رابطه بین ورودی و خروجی را برقرار نموده و پارامترهای مربوط به توابع عضویت بخش فازی به

لایه ورودی ۲ (ورودی‌ها از توابع عضویت ۳ عبور می‌کنند).


لایه فازی‌ساز ۴ (خروجی این لایه ضرب سیگنال‌های ورودی است که در واقع معادل قسمت ۴) اگر قوانین است.

لایه قاعده مبنا ۵ (خروجی این لایه نرمالیزه شده لایه قبلی است).

لایه خروجی فازی ۶ (نافازی سازی با استفاده از روش مرکز ثقل).

لایه خروجی ۷.

اکنون با طی مراحل بالا یک شبکه تولید می‌شود که معادل سیستم استنتاج فازی سوگنو است. حال برای آموزش چنین شبکه‌ای، ابتدا در لایه ۱ تمام قوانین موجود را تشکیل می‌دهیم. بطور مثال اگر دو ورودی داشته باشیم که هر کدام ۳ تابع عضویت داشته باشد، ۹ قانون باید تشکیل دهیم که بصورت زیر خواهد بود:



شکل ۳) ساختار ANFIS برای حالتی که ۲ ورودی داریم که هر کدام ۳ تابع عضویت دارند

2-Input Layer.

۳- فازی مجموعه‌ای است که درجه عضویت (میزان کوچکی یا بزرگی تعلق عدد در مجموعه) اعضای آن به طور پیوسته در فاصله [۰،۱] است و هر عددی از این فاصله یک درجه عضویت است

$$f: R \rightarrow [0,1]$$

4- Fuzzification Layer.

5- Rule Base Layer.

6- Fuzzy Outputs.

7- Output Layer.

(۳)

$$Rule: \text{if } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ then } f_1 = p_1x + q_1y + r_1$$

شبکه تطبیق‌پذیر و قابل آموزشی است که به لحاظ عملکرد کاملاً مشابه سیستم استنتاج فازی است (چائو و ونگ، ۲۰۱۰:۲۰۷، ۹۲، دینگ و لیانگ ۲۰۰۸:۳۳۶۶، ۳۳۶۲). برای سادگی کار فرض می‌کنیم که سیستم فازی ما دو ورودی x و y دارد و خروجی آن f است. حال اگر قوانین به صورت رابطه زیر باشند!


$$Rule: \text{if } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ then } f_1 = p_1x + q_1y + r_1$$

و اگر برای غیرفازی ساز از غیرفازی ساز میانگین مراکز استفاده کنیم خروجی به صورت تابع زیر خواهد بود:

(۴)

$$f = \frac{w_1f_1 + w_2f_2}{w_1 + w_2} = \frac{\bar{w}_1f_1 + \bar{w}_2f_2}{\bar{w}_1 + \bar{w}_2} \quad \text{st} \quad \bar{w}_1 = \frac{w_1}{w_1 + w_2}, \bar{w}_2 = \frac{w_2}{w_1 + w_2}$$

در نهایت ساختار معادل ANFIS به صورت زیر طراحی خواهد شد:



شکل ۲) معماری کلی مدل تطبیقی عصبی- فازی (نبی زاده، ۲۰۱۱).

همان طوری که در شکل ۲ مشاهده می‌شود، ساختار ANFIS شامل ۵ لایه به قرار زیر است:

۱- که در اینجا p_i, q_i, r_i پارامترهای خطی مدل تاکاگی سوگنو درجه اول هستند.

- معیارهای ارزیابی کارایی مدل‌ها

هایکین (۱۹۹۴)، به منظور بررسی کارایی مدل‌های پیش‌بینی سریهای زمانی، معیارهایی را معرفی کرد که نام و فرمول برخی از مهم‌ترین آن‌ها در زیر آمده است.

$$R^2 = 1 - \frac{\sum (y_t - \hat{y}_t)^2}{\sum y_t^2} \quad \text{مجذور ضریب همبستگی:}$$

$$MAD = \frac{\sum |y_t - \hat{y}_t|}{n} \quad \text{میانگین قدر مطلق انحرافات:}$$

$$MSE = \frac{\sum (y_t - \hat{y}_t)^2}{n} \quad \text{میانگین مربع خطا:}$$

$$RMSE = \sqrt{\frac{\sum (y_t - \hat{y}_t)^2}{n}} \quad \text{ریشه میانگین مربع خطا:}$$

در روابط فوق n ، \hat{y}_t و y_t به ترتیب مقدار هدف (مشاهده واقعی)، خروجی مدل و تعداد مشاهدات می‌باشد. واضح است که بهترین مقدار برای R^2 برابر ۱ و برای سایر معیارها صفر می‌باشد.

- موقعیت کلی شهر

شهر زابل مرکز شهرستان زابل است و در مختصات جغرافیایی ۳۱ درجه و ۲ دقیقه عرض شمالی و ۶۱ درجه و ۳۹ دقیقه طول شرقی قرار گرفته است. وسعت شهر زابل برابر ۲۰۸۴ هکتار است که ۱۳ درصد از وسعت شهرستان را در بر می‌گیرد. زابل در فاصله زمینی ۲۱۰ کیلومتر از زاهدان در جنوب، ۱۵۳۸ کیلومتر از تهران در شمال، ۳۶۶ کیلومتر از بیرجند در شمال غرب و ۸۳۴ کیلومتر از مشهد بوده و بدین طریق با مراکز استان‌های همجوار و سایر نقاط ارتباط می‌یابد.

۳- داده‌های تحقیق

متغیرهای مستقل ۱

طبیعتاً در ساخت و سازهای مربوط به یک شهر مجموعه عوامل مختلفی می‌توانند تاثیرگذار باشند. این عوامل از متغیرهای تاثیرگذار در سطح منطقه تا سطح کشور و حتی جهانی را می‌تواند در برگیرد؛ که هم عوامل انسانی و هم عوامل طبیعی در این امر تاثیر گذارند. بنابراین برای رسیدن به یک شبیه سازی و در نهایت پیش‌بینی نزدیک به واقعیت، ما با طیف گسترده‌ای از مجموعه عوامل تاثیرگذار روبرو هستیم که شناسایی و ثبت آن‌ها اگر نگوئیم غیر ممکن کاری بس دشوار است.

داده‌هایی که در مرحله آموزش شبکه به عنوان متغیرهای مستقل استفاده شده‌اند به قرار زیر است:

- جمعیت شهر و تغییرات مربوط به آن در بازه زمانی مورد نظر

متوسط درآمد و هزینه خانوار شهر (زابل)

فصل‌های مختلف مربوط به سال (که در قالب میزان دما تاثیر گذاشته‌اند).

تولید ناخالص داخلی (GDP).


نورم

نوسانات مربوط به نرخ ارز (دلار)

تاثیر جمعیت به عنوان یکی از داده‌های ورودی (گره ورودی) شبکه طراحی شده، بر تقاضاهای صورت گرفته کاملاً مشخص است. داده‌های جمعیتی پس از استخراج از سایت مرکز آمار ایران برای تبدیل به داده‌های هفتگی از درونیابی خطی استفاده شده است.

۱- تغییری است که متغیر وابسته را به صورت مثبت یا منفی تحت تاثیر قرار می‌دهد، به عبارت دیگر تغییرپذیری یا نوسان در متغیر وابسته به حساب متغیر مستقل گذاشته می‌شود

بازه زمانی ۹۰/۱/۶ تا ۹۲/۸/۲۹ به صورت هفتگی جمع آوری شده است.



نمودار ۱) روند واقعی تقاضای پروانه ساخت و ساز

نتایج و بحث‌ها

- مدل‌سازی و پیش‌بینی تقاضای پروانه ساخت با استفاده از ANN

با توجه به این نکته که ساخت‌وسازهای مربوط به شهر همواره در حال رشد بوده و عوامل تاثیرگذار بر تقاضای آن دارای روند غیرخطی بوده و بشدت در نوسان می‌باشند، بنابراین، استفاده از الگوهای هوشمند غیرخطی در مدل‌سازی های تقاضای پروانه ساخت اجتناب‌ناپذیر است. شبکه عصبی مصنوعی از تکنیک‌های محاسباتی هوشمند در مدل‌سازی فرایندهای غیرخطی است که در سال‌های اخیر به موازات پیشرفت‌های ابزار محاسبات و پردازش اطلاعات، از جایگاه پر اهمیتی برخوردار گشته و در علوم مختلف دارای پیشرفت‌های روز افزون و نتایج مطلوبی بوده است. شبکه‌های عصبی پیش‌خور، کاربردی‌ترین نوع شبکه‌های عصبی مصنوعی می‌باشند، چرا که شبکه‌های عصبی پیش‌خور با یک لایه پنهان، تابع فعال‌سازی مناسب در لایه پنهان و تعداد نرون‌های کافی در لایه پنهان، قادرند هر تابعی را با دقت دلخواه تقریب بزنند (کوان و وایت، 91: 1998). بر این اساس در این مطالعه از شبکه‌های عصبی پیش‌خور (در مقابل سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) استفاده شده است و به منظور

از شاخص متوسط درآمد و هزینه خاتوار نیز به این دلیل استفاده شده است که وضعیت مطلوب آن میل به ساخت مسکن را افزایش می‌دهد. فصل‌های سال نیز تاثیرات معنادار و ملموسی در حجم ساخت‌وسازها ایفا می‌کنند، به این شکل که در ماه‌های دارای دمای هوا و شرایط جوی مطلوب به صورت فاحشی افزایش پیدا میکند (شکل ۴). GDP (تولید ناخالص داخلی) نیز نشان دهنده میزان ثروت موجود در یک کشور بوده و بالا رفتن آن یکی از علایم گسترش احتمالی رفاه و بالا رفتن سطح رفاه در جامعه است و یکی از شاخص‌های مهم در نشان دادن رونق اقتصادی است، که این رونق؛ اثر محسوسی در بالا بردن انگیزه ساخت‌وساز در بین مردم خواهد داشت (ولی مهمترین ضعف این شاخص این است که نشان دهنده نحوه توزیع ثروت در میان اقشار مختلف نمی‌باشد). داده‌های GDP از طریق وب سایت بانک مرکزی ایران ۱ در کمترین بازه زمانی (فصلی) استخراج شده و برای تطبیق با داده‌های مورد نیاز هفتگی از درون یابی خطی استفاده شده است. تورم و نوسانات مربوط به نرخ ارز نیز به دلیل تاثیرات مستقیم و غیر مستقیمی که بر قیمت مصالح ساختمانی می‌گذارند دارای جایگاه ویژه‌ای در بین داده‌های ورودی هستند.

- متغییر وابسته

تقاضاهای صورت گرفته مربوط به پروانه ساخت، یا به عبارتی پروانه ساخت‌هایی که شهرداری با رعایت ضوابط مربوطه عرضه کرده است که برای

در رابطه (۵)، x_i ، x_{max} ، x_{min} و x_n به ترتیب نشان‌دهنده مقادیر واقعی، نرمال شده، حداکثر و حداقل داده‌های تحت بررسی می‌باشند. مقادیر حداکثر و حداقل مربوط به متغیرهای تحت بررسی (در سال‌های ۹۱، ۹۰ و هشت ماهه نخست سال ۹۲) در جدول (۱) نشان داده شده است.

انجام پیش‌بینی و در واقع گرفتن خروجی از شبکه، برای آموزش و هم‌گرایی سریع‌تر و دقت بیشتر شبکه ابتدا ورودی‌های آن (داده‌ها) با استفاده از تکنیک **Min - Max** به داده‌های نرمال در بازه [۰،۱] تبدیل می‌شوند.

$$x_n = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (5)$$

جدول (۱) مقادیر حداکثر و حداقل متغیرهای مورد بررسی (در دوره زمانی ۹۰/۱/۶ تا ۹۲/۸/۲۹)

متغیر	x_{min} (ل)	x_{max} (ل)
جمعیت	۱۳۷۷۲۲ (۹۰)	۱۵۶۱۷۹ (۹۱)
متوسط درآمد (ریال)	۱۰۰۳۹۱۶۶۶ (۹۰)	۱۲۳۶۷۰۶۱۹ (۹۱)
متوسط هزینه (ریال)	۸۶۰۲۰۲۲۲ (۹۰)	۱۱۱۹۷۶۴۱۲ (۹۱)
دما (درجه سانتی‌گراد)	۶-	۴۸ ^۰
تولید ناخالص داخلی (میلیارد ریال)	۵۵۸۶۳۰/۰۰۰۰ (۹۰)	۵۵۳۶۰۲/۰۰۰۰
تورم	۲۱/۵ (۹۰)	۳۴/۵ (۹۲/۸/۲۹)
نوسانات نرخ ارز- دلار- (ریال)	۱۰۳۸۴ (۹۰)	۲۴۸۲۱ (۹۲)

منابع: بانک مرکزی، سایت مرکز آمار، سایت مرکز هواشناسی کشور

۸۰ درصد در برابر ۲۰ درصد و یا ۷۰ درصد در برابر ۳۰ درصد انتخاب نموده‌اند. البته انتخاب هر قاعده بستگی به نوع مسأله و محدودیت داده‌ها دارد. اما تحقیقات مختلف نشان داده است که هر چه تعداد نمونه‌های آموزشی افزایش یابد، عملکرد شبکه در زمینه پیش‌بینی، بهبود می‌یابد (زانک و همکاران: ۱۹۹۸). در این مطالعه نیز با توجه به محدودیت داده‌ها از ۷۰ درصد مشاهدات (۹۱ مشاهده) برای آموزش و ۲۰ درصد آن (۳۹ مشاهده) برای تصدیق استفاده شده است. به منظور تعیین تعداد نرون‌های مورد نیاز در لایه پنهان نیز از ترکیبی از روش‌های موجود استفاده شده است. به این ترتیب، با استفاده از تابع (۶) تعداد نرون‌ها در لایه پنهان تعیین می‌شود

پس از مرحله نرمال‌سازی، تصادفی نمودن داده‌ها انجام می‌شود. نتیجه این مرحله، داشتن مجموعه‌ای از ورودی‌ها و خروجی‌هاست که در آن، دسته‌های ورودی و خروجی دارای نظام خاصی نیستند. پس از پایان تصادفی نمودن داده‌ها، میزان اطلاعاتی که باید در فرایند آموزش شبکه استفاده شود مشخص می‌شود (فرجام‌نیا و همکاران: ۱۳۶۸) بر این اساس، بخشی از داده‌ها برای آموزش (train) و بخشی دیگر برای آزمون (test) شبکه در نظر گرفته می‌شود.^۲

اکثر محققان، نمونه‌های آموزش و تصدیق را به ترتیب با یکی از قاعده‌های ۹۰ درصد در مقابل ۱۰ درصد،

^۱- Randomizing

^۲- به منظور تصادفی نمودن داده‌های مربوط به آموزش و آزمون از دستور dividerand در نرم‌افزار مطلب استفاده شده است.

هفته آینده، از وقفه ۴ داده های نرمال استفاده شد. همچنین برای این افق زمانی، ساختار شبکه انتشار برگشتی پیش‌خور، با ۱۰۰ تکرار و نرخ آموزش ۰/۰۱ طراحی گردید. نهایتاً برای بررسی کارایی این مدل، با استفاده از معیارهای ارزیابی مدل‌ها، داده های خروجی هر شبکه با داده‌های واقعی مقایسه شد. جدول ۲ خلاصه‌ای از این نتایج را نشان می‌دهد.

$$N^h = \frac{1}{T} (N^t + N^o) + \sqrt{m} \quad (6)$$

$$16 = \frac{1}{T} (7 + 1) + \sqrt{137}$$

در تابع (۶)، N^h ، N^t ، N^o و m به ترتیب برابر با تعداد نرون‌ها در لایه پنهان، ورودی، خروجی و تعداد مشاهدات می‌باشد. پس از تعیین ساختار شبکه و مجموعه ورودی‌های آن، شبکه برای آموزش آماده می‌شود به منظور بررسی کارایی این مدل در پیش‌بینی سری‌های زمانی مورد نظر برای افق زمانی ۴

جدول ۲) کارایی مدل ANN در پیش‌بینی سری زمانی تقاضای پروانه ساخت

ANN		نمایش هندسی پیش‌بینی تقاضای پروانه ساخت (برای بازه زمانی ۹۰/۱/۶ تا ۹۲/۸/۲۹)	
مقادیر واقعی			
پیش‌بینی			
ساختار ۱-۲-۳-۴-۶-۷			
R^2	آموزش	۰/۹۵۳۳	
ج	آزمون	۰/۹۱۹۱	
MAD	آموزش	۰/۰۱۶۰	
	آزمون	۰/۰۶۵۰	
RMSE	آموزش	۰/۰۱۸۰	
	آزمون	۰/۰۷۳۰	

مآخذ: یافته‌های تحقیق

آزمون واقعی با مقادیر بخش آزمون پیش‌بینی شده یا خروجی این مدل می‌باشد. ساختار شبکه طراحی شده نیز به گونه‌ای می‌باشد که اولین عدد از سمت چپ نشان دهنده تعداد ورودی‌ها و آخرین عدد نشان دهنده تعداد خروجی بوده و اعداد بین آن‌ها نشان دهنده تعداد گره‌ها و نرون‌های موجود در هر گره می‌باشد.

- مدل‌سازی و پیش‌بینی تقاضای پروانه ساخت با استفاده از ANFIS

سمت راست جدول فوق نمایش هندسی مقادیر واقعی (Target) و پیش‌بینی شده یا خروجی (output) سری زمانی مورد بررسی را توسط مدل ANN نشان می‌دهد به طوری که مدل فوق به ازای داده های آموزشی (Train) و آزمون واقعی، مقادیر پیش‌بینی شده یا خروجی ANN را که خود نیز دارای دو بخش آموزش و آزمون می‌باشد، ارائه کرده است. همچنین سمت چپ این جدول نشان دهنده بهترین ساختار طراحی شده این مدل برای وقفه ۴ هفته آتی و مقادیر معیارهای ارزیابی حاصل از مقایسه داده‌های بخش

مدلهای مختلفی با توابع عضویت مختلف (trimf,gaussmf,gauss2mf) و با تعداد توابع عضویت متفاوت مورد مقایسه قرار گرفت و در نهایت نوع gauss2 با شبکه عصبی انتشار برگشتی پیش‌خور، تابع فعال سازی logsig و تکرار ۱۰۰ طراحی گردید. نهایتاً برای بررسی کارایی این مدل، با استفاده از معیارهای ارزیابی مدل‌ها، داده‌های خروجی هر مدل با داده‌های واقعی مقایسه شد. جدول (۳) خلاصه‌ای از این نتایج را نشان می‌دهد:

به منظور بررسی کارایی این مدل در پیش‌بینی سری زمانی مذکور برای افق زمانی ۴ هفته آینده، از الگوریتم آموزشی هیبریدی برای تعیین پارامترهای تابع عضویت سیستم استنتاج فازی از نوع سوگنوی یک خروجی استفاده شد و به منظور آموزش پارامترهای تابع عضویت سیستم استنتاج فازی مجموعه مفروض داده‌های ورودی - خروجی، ترکیب روش‌های حداقل مربعات و شیب نزولی انتشار برگشتی به کار گرفته شد. برای افق مورد نظر،

جدول (۳) کارایی مدل ANFIS در پیش‌بینی سری زمانی تقاضای پروانه ساخت

ANFIS		
نمایش هندسی پیش‌بینی تقاضای پروانه ساخت (برای بازه زمانی ۹۰/۱/۶ تا ۹۲/۸/۲۹)		
ساختار ۱۰۰-۴-gauss2		
R^2	آموزش	۰/۹۸۹۹
	آزمون	۰/۹۶۵۶
MAD	آموزش	۰/۰۰۱۸
	آزمون	۰/۰۰۶۱
RMSE	آموزش	۰/۰۰۲۶
	آزمون	۰/۰۰۶۴

مأخذ: یافته‌های تحقیق

مقادیر معیارهای ارزیابی حاصل از مقایسه داده‌های بخش آزمون واقعی با مقادیر بخش آزمون پیش‌بینی شده یا خروجی این مدل می‌باشد. سمت چپ این جدول نشان دهنده مقادیر معیارهای ارزیابی و ساختار مدل ANFIS برای افق زمانی ۴ هفته آتی می‌باشد. ساختار شبکه‌های طراحی شده به گونه‌ای می‌باشد که گزاره اول از سمت چپ نشان دهنده نوع تابع عضویت و اعداد بعدی به ترتیب نشان دهنده تعداد تابع عضویت و تکرار می‌باشد. همان طور که جدول فوق نشان می‌دهد، این مدل در

سمت راست جدول فوق نمایش هندسی مقادیر واقعی (Target) و پیش‌بینی شده یا خروجی (output) سری زمانی مورد بررسی را توسط مدل ANFIS نشان می‌دهد، به طوری که همانند مدل ANN مدل ANFIS نیز به ازای داده‌های آموزشی (Train) و آزمون (Test) واقعی، مقادیر پیش‌بینی شده یا خروجی ANFIS را که خود نیز شامل دو بخش آموزش و آزمون می‌باشد، ارائه کرده است. همچنین سمت چپ این جدول نشان دهنده بهترین ساختار طراحی شده مدل ANFIS افق زمانی ۴ هفته آتی و

دوره زمانی ۹۰/۱/۶ تا ۹۲/۸/۲۹ جمع آوری و نسبت به تجزیه و تحلیل و طبقه‌بندی آن‌ها (به صورت تعداد تقاضاهای هفتگی، مساحت زیربنای ساخته شده و مساحت کل استفاده شده) آن‌ها اقدام شد. از سوی دیگر داده‌های ورودی به صورت ترکیبی از اساسی‌ترین پارامترهای برون بخشی و درون بخشی تاثیرگذار در تصمیم‌گیری افراد برای ساخت‌وساز یعنی جمعیت شهرو نرخ رشد آن، متوسط درآمد و هزینه خانوار شهری (زابل)، تاثیر فصل‌های مختلف سال در قالب عامل دما، میزان تولید ناخالص داخلی (در سطح کلان)، تورم، ونوسانات مربوط به نرخ ارز (به عنوان پارامترهای برون بخشی) و عواملی مانند زمین و قیمت آن، تراکم و نرخ عوارض ساخت و ساز (به عنوان عناصر درون بخشی) در نظر گرفته شده و وارد محیط شبکه شده و مورد آموزش قرار گرفتند که در نهایت سیستم استنتاج عصبی فازی تطبیقی (ANFIS) با $R^2 = (0.9656, 0.9899)$ مشخص شد که عملکرد بهتری نسبت به شبکه عصبی مصنوعی صرف دارد نتایج تحقیق نشان‌گر آن است که شبکه‌های عصبی فازی تطبیقی از لحاظ تمامی معیارهای عملکرد بر روش ANN برتری دارد. نتایج تجربی این تحقیق و تحقیقات مشابه نشان داده‌اند که ترکیب شبکه‌های عصبی مصنوعی و منطق فازی و ایجاد شبکه‌های عصبی فازی تطبیقی موفقیت آمیز بوده و باعث کاهش قابل توجه در خطای پیش‌بینی شده است که عمده دلیل آن ویژگی‌های چشمگیرش در همگرایی سریع، دقت بالا و توانایی تقریب تابع قوی می‌باشد. علاوه بر این، از آنجا که سیستم شبکه‌های عصبی فازی نیازمند داده‌های صریح و قطعی نبوده و نمونه بزرگی از داده‌ها را نیاز

پیش‌بینی سری زمانی برای چهار هفته آتی از کارایی بیشتری برخوردار است.

با توجه به این که شبکه عصبی فازی تطبیقی (ANFIS) نسبت به روش عصبی صرف (ANN) در هر سه معیار ارزیابی عملکرد برتری دارد، از این روش برای پیش‌بینی تقاضای پروانه ساخت برای ماه آینده (۴ هفته آتی) استفاده می‌شود. مقادیر پیش‌بینی برای این مدت در جدول (۴) نشان داده شده است.

جدول (۴) پیش‌بینی تقاضای پروانه ساخت برای ماه آتی بر مبنای شبکه‌های عصبی فازی تطبیقی (ANFIS)

هفته	تعداد تقاضا	مساحت زیر بنا (متر)	مساحت کل بنا (متر)
۱	۳	۷۵۳	۹۴۱
۲	۷	۸۹۲	۱۰۶۸
۳	۲	۶۴۳	۵۳۸
۴	۵	۸۳۹	۱۸۶۶

۴- نتیجه‌گیری و پیشنهادها

هدف این تحقیق برآورد تقاضای مربوط به پروانه ساخت‌های صورت گرفته از شهرداری زابل و ارائه مدل مناسبی برای این تقاضا در آینده است، تا شهرداری بتواند بر بسیاری از این مشکلات فائق آمده و شرایط تصمیم‌گیری را از حالتی نامطمئن به حالتی مطمئن تبدیل کند. صرف نظر از تحقیقات صورت گرفته در زمینه پیش‌بینی، هدف این تحقیق تمرکز بر توسعه روش‌های پیش‌بینی دقیق‌تر و معتبرتر است. به این منظور از طیف روش‌های غیر خطی از دو مدل شبکه عصبی (ANN) و سیستم استنتاج عصبی فازی تطبیقی (ANFIS) استفاده شده و از لحاظ سه معیار عملکرد، $RMSI$ ، MAE و R^2 با هم مقایسه شدند. بدین منظور در این تحقیق درخواست‌های صورت گرفته از شهرداری (به عنوان خروجی مدل) برای

- Chua, L.H.C., & Wong, T.S.W. (2010). Improving event-based rainfall-runoff modeling using a combined artificial neural network-kinematic wave approach. *Journal of Hydrology*, 390, 92-107.
- Ding, w., & Liang, D. (2008). Fourier series and ANFIS-based modeling and prediction for switched reluctance motor. *Electrical Machines and Systems*, 2008. ICEMS 2008. International Conference, 3362 - 3366.
- Karaca, F., & Ozkaya, B. (2006). A neural network-based model for controlling leachate flow-rate in a municipal solid waste landfill site. *Environmental Modelling & Software*, 21, 1190-1.
- Li, H., Guo, C., Yang, S.X., & Jin, H. (2006). Hybrid Model of WT and ANFIS and Its Application on Time Series Prediction of Ship Roll Motion. *Computational Engineering in Systems Applications*, IMACS Multiconference, 1, 333 - 337.
- Nuno, A.L., Arcay, B., Cotos J.M., & Varela, J. (2005). Optimisation of fishing predictions by means of artificial neural networks, anfis, functional networks and remote sensing images. *Expert Systems with Applications*, 29, 356-363.
- Wei, M., Bai, B., Sung, A.H., Liu, Q., Wang, J., & Cather, M.E. (2007). Predicting injection profiles using ANFIS. *Information Sciences*, 177, 4445-4461.
- Gupta, M.M., Jin, L., & Homma, L. (2003). *Static and Dynamic Neural Networks*, Book.
- Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feed forward networks are universal approximators. *Neural Networks*, 2, 359-366.
- Liu, Z.F., Liu, X.P., Wang, S.W., & Liu, G.F. (2002). Recycling strategy and a recyclability assessment model based on an artificial neural network. *Journal of Materials Processing Technology*, 129, 500-506.
- Hornik, K. (1991); "Approximation Capabilities of Multilayer Feedforward Networks"; *Neural Networks*, 4: 251-257.
- Kuan, C.M., and H. White (1994); "Artificial neural networks: An econometric ندارد، می‌تواند پیش‌بینی خوبی از مسئولیت‌ها و فعالیت‌های آتی شهرداری ارائه دهد و اطمینان دهد که این روش نسبت به روش‌های کلاسیک پیش‌بینی مناسب‌تر است.
- منابع**
- منه‌اج، محمد باقر، (۱۳۸۴)، مبانی شبکه‌های عصبی، دانشگاه صنعتی امیر کبیر، تهران.
- منه‌اج، محمد باقر؛ کاظمی، عالیه؛ شکوری گنجوی، حامد؛ مهرگان، محمد رضا و تقی زاده، محمد (۱۳۸۹)، پیش‌بینی تقاضای انرژی بخش حمل‌ونقل با استفاده از شبکه عصبی: مطالعه موردی در ایران‌پژوهش‌های مدیریت در ایران ۲۰۳ تا ۲۲۰.
- فرجام‌نیا، ایمان؛ ناصری، محسن و احمدی، سید محمد مهدی (۱۳۶۸)؛ > پیش‌بینی قیمت نفت با دو روش ARIMA و شبکه‌های عصبی مصنوعی <؛ فصل‌نامه پژوهش‌های اقتصادی ایران، ۱۶۱، ۳۲ تا ۱۸۳.
- زمانی، رضا. (۱۳۹۱): پیش‌بینی درآمدهای شهرداری تهران با استفاده از شبکه‌های عصبی مصنوعی (روش MLP)، رساله دکتری، مالیه مدیریت شهری.
- پورشهبابی، وحید. سارانی، سعید رضا. دهمرده‌زاده، شمس. (۱۳۹۰): بررسی منابع درآمدی شهرهای جدید استان سیستان و بلوچستان، دانشگاه آزاد اسلامی واحد زاهدان.
- Bao-ping, C., & Zeng-qiang, M. (2009). Short-Term Traffic Flow Prediction Based on ANFIS. *Communication Software and Networks*, 2009. ICCSN '09. International Conference, 791, 793.

- Zhang, G., Patuwo, B.E., and M.Y. Hu (1998); "Forecasting with artificial neural network: The state of art"; *International Journal of Forecasting*, 14: 35-62.
- Haykin, S. (1994), *Neural Networks: a Comprehensive Foundation*. Macmillan, New York.
- perspective"; *Econometric Reviews*, 13: 1-91.
- Morgan, G. C. (1998), *Fuzzy logic*, Routledge Encyclopedia of Philosophy, 3, first edition, Craig, E. Routledge, London.
- Gupta, M.M., Jin, L., & Homma, L. (2003). *Static and Dynamic Neural Networks*. Book.
- Radulovic, J.J., & Rankovic, V.M. (2009). Application of RBF neural network and ANFIS for electromagnetic field prediction around the power lines. *Telecommunication in Modern Satellite, Cable, and Broadcasting Services*, 2009. TELSIKS '09. 9th International Conference, 457 - 460.
- Stephen L. Chiu (1994). Fuzzy model identification based on cluster estimation. *Journal of Intelligent and Fuzzy Systems*, 2, 267-278.
- Zhang, G., Patuwo, B. E., & Hu, M. Y., (1998), "Forecasting with artificial neural networks: the state of the art", *International Journal of Forecasting*, 14 35- 62.
- Darbellay, G. A., & Slama, M., (2000), "Forecasting the short-term demand for electricity: do neural networks stand a better chance", *International Journal of Forecasting*, 16 71- 83.
- Swanson, N. R., & White, H., (1997), "Forecasting economic time series using adaptive versus nonadaptive and linear versus nonlinear econometric models", *International Journal of Forecasting*, 13, 439-461.
- Moody, J., Levin, U., & Rehfuss, S., (1993) "Predicting the US index of industrial production", *Neural Network World*, 3 791-794.
- Tkacz, G., (2001), "Neural network forecasting of Canadian GDP growth", *International Journal of Forecasting*, 17, 57-69.
- Qi, M., (2001), Predicting US recessions with leading indicators via neural network models. *International Journal of Forecasting*, 17, 383-401.
- Kuan, C.M., and H. White (1994); "Artificial neural networks: An econometric perspective"; *Econometric Reviews*, 13: 89-91.