مجله پژوهش و برنامه‌ریزی شهری، سال پنجم، شماره شانزدهم، بهار ۱۳۹۳
دریافت: ۱۳۹۲/٤/۱٤ - پذیرش: ۱۳۹۳/۲/۲۷
صص ٥٤-۳۹

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

غلامعلی خمر: استادیار جغرافیا و برنامه‌ریزی شهری، دانشگاه زابل، زابل، ایران
وحید پاسبان عیسی‌لو: دانشجوی کارشناسی ارشد جغرافیا و برنامه ریزی 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 برنامه‌ریزی‌مدون 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، مدل های 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 شهرو نرخ رشد آن، متوسط درآمد وهزینه خانوار شهر (زابل)، تاثیرفصل‌های مختلف سال در قالب عامل دما، میزان تولید ناخالص‌داخلی(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 وساز (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 شبکه‌عصبی و عملکرد منطقی سیستم‌های فازی)) ؛ با مقدار R^2 (۰/۹٦٥٦، ۰/۹۸۹۹) RMSE(۰/۰۰۲٦، ۰/۰۰٦٤), MAD (۰/۰۰۱۸، ۰/۰۰٦۱) به ترتیب برای آموزش و آزمون، بر روشANN برتری نشان داده در نتیجه مدل مناسبتری برای پیش‌بینی هدف ماست.

واژه‌های کلیدی: تقاضای پروانه ساخت، شبکه عصبی‌مصنوعی، ANFIS

*نویسنده مسؤول: Email: Vahid.Pasban30@gmail.com

۱-مقدمه

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 وتسهیلات 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 وسازهای شهری هستند عدم وجود هماهنگی‌های تنگاتنگ بین آن‌ها از عوامل اساسی تاثیرگذار در کندی فرایند صدور پروانه‌ساخت می‌باشد. که این مسأله به نوبه خود میتواند باعث سرگردانی ارباب‌رجوع و شاید انصراف آن ها از طی مراحل قانونی برای ساخت وساز و در نتیجه شکل گیری ساخت وسازهایی خارج از ضوابط قانونی و خود رو بینجامد.

پر واضح است که ایرادهای موجود در مسیر صدور پروانه های ساختمانی، بیشتر مشکلات اجرایی‌اند نه اینکه خلاء قانونی در این زمینه وجود داشته باشد. بنابراین، می توان با بهبود نظارت ها وبهره‌وری از مدل‌های نوین در این زمینه راه را برای اجرای قوانین موجود و تسریع در روند صدور پروانه ساخت هموار و تا حد زیادی اهداف طرح حاضر را تامین کرد.

۱-۲- اهمیت و ضرورت

امروزه مسأله پیش‌بینی وآینده‌نگری یکی از نیازهای مبرم سازمان‌هاست وشهرداری‌ها نیز از این مقوله مستثنی نیستند. شهرداری‌ها با توجه به حجم بالای فعالیت‌هایی که در رابطه با شهر وکارکردهای آن انجام می دهند؛ با به کارگیری پیش‌بینی های 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 درامد آینده آن و از سوی دیگر ترتیب اثردادن 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 خودرگرسیون‌میانگین-متحرک انباشته[1](ARIMA) گرفته تا مدل‌های غیرخطی مانند شبکه‌عصبی‌مصنوعی [2](ANN)، سیستم‌استنتاج‌عصبی‌فازی تطبیقی [3](ANFIS) والگوریتم 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

در زمینه کاربرد مدلهای عصبی در پیش‌بینی سری‌های زمانی ؛فهیمی‌فرد (۲۰۰۹)، آذربایجانی وهمکاران (۲۰۰۷)، ایـــنس و همکـــاران (۲۰۰۵)، هـــروی و همکـــاران (۲۰۰٤)، اولســـن و موســـن (۲۰۰۳)، رچ (۲۰۰۲)، مشـیری و کـامرون(۲۰۰۰)، اثنـی عشـری (۱۳۸٦)، نجفی و همکاران (۱۳۸۵)، مشیری و مروت (۱۳۸٤)،روشن (۱۳۸۳)، اصفهانیان (۱۳۸۲)، به مطالعه و بررسی پرداخته و نتیجـه گرفتـه‌انـد کـه مـدل‌هـای عصبی و ترکیبی عصبی فازی در مقایسه با مـدل‌هـای خطی از عملکرد بهتری برخوردارند.

۱-۳- هدف تحقیق

با توجه به مسائل فـوق، هـدف ایـن تحقیـق بـراورد تقاضای مربوط به پروانه‌ساخت و ارائه مـدل مناسـبی برای پیش‌بینی ایـن تقاضـا در آینـده بـوده اسـت تـا شهرداری بتواند بر بسیاری از مشکلات فـایق آمـده و شرایط تصمیم گیری را از حالتی نامطمئن بـه حـالتی مطمئن هدایت کند. صرف نظر از تحقیقـات صـورت گرفته در زمینه پیش بینی، هدف ایـن پژوهش،تمرکـز بر توسعه روش های پـیش‌بینـی دقیـق‌تـر و معتبرتـر است. با توجـه بـه ناکارامـدی روش‌هـای رگرسـیون خطی چندمتغیره در مدل‌سازی روابطی بـا ورودی‌هـا وخروجی‌ها غیرخطی و پیچیده (بـائو پینـگ و زنـگ کینگ،۲۰۰۹:۷۹۳.۷۹۱، چـائو و ونـگ۲۰۱۰:۹۲.۱۰۷، دینگ و لیانگ ۲۰۰۸:۳۳٦۲.۳۳٦٦) از مدل‌های ANN و ANFIS(هر دو از طیف روش‌های غیـرخطـی) بـه صورت مقایسه‌ای استفاده شده است.

- شبکه‌های عصبی، شبکه‌های عصبی‌فازی و پیشینه کاربرد آنها

بیشتر ادبیات پیش‌بینی توسط محققانی چـون ژانـک، پاتوو و هو(۱۹۹۸) با مقاله‌ای با عنوان پـیش‌بینـی بـا استفاده از شبکه‌عصـبی‌مصـنوعی، وکاربردهـای اخیـر توسط سوانسون و وایت، داربلی و اسلمسما، کـوی و تکاز(۲۰۰۰) پیش بینی‌های کوتاه مدت بـا اسـتفاده از شبکه‌عصبی صورت گرفته است. البته علیرغم قـدرت و شهرت این مدل‌ها، کارکرد مدل‌های شـبکه عصـبی در پیش‌بینی تجربی، به صورت ترکیبی است (زانک و همکاران:۱۹۹۸).در زمینه داده‌های اقتصادی سوانسـن و وایت (۱۹۹۷) عملکرد مدل‌های شبکه عصبی را در پیش‌بینی سری‌های زمانی اقتصاد کلان مطالعـه کـرده اند. هم‌چنین در ایالات‌متحده‌آمریکا، مـودی، لـوین و ره‌فوس (۱۹۹۳) با تمرکز بر تولید ادغامی در صنعت؛ دریافتند که مدل شبکه‌عصبی بر مـدل خطـی در افـق هـای ٦ ماهـه و بیشـتر ارجحیـت دارد. تکـاز(۲۰۰۱) نشان داد که تولیدناخالص‌داخلی کانـادا در دوره‌هـای یک ساله توسط شبکه‌عصبی بهتر از مدل‌هـای خطـی پیش‌بینی می‌شوند. در کاربرد متفاوت دیگـری، کـوی (۲۰۰۱) مفید بودن مدل شبکه‌های عصبی را در پیش-بینـی متغییـر دودویـی نشـان‌دهنـده بحـران‌اقتصـادی بررسی می‌کند. در زمینه مطالعـات داخلـی نیـز آقـای زمانی وهمکارانش (1391) تحقیقی در پیرامون پیش-بینی درآمد شهرداری تهران با استفاده از شبکه عصبی مصنوعی را انجام دادند که با توجه بـه اهمیـت پـیش بینی درآمد و هزینه های شـهرداری در بودجـه‌بنـدی ســـالانه از دو روش شـــبکه‌عصـــبی (ANN) و روش(SVM) استفاده کردندکه نتایج به دست آمده از

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 فهیمی فرد و همکاران (۱۳۸۷) در مقاله علمی پژوهشی مقایسه توان پیش‌بینی مدل عصبی‌فازی با مدل شبکه‌عصبی ANN در رابطه با پیش‌بینی قیمت هفتگی تخم‌مرغ به این نتیجه رسیداند که مدل ANFIS در مقایسه با مدل ANNدر همه افق‌های زمانی از کارایی بیشتری برخوردار است. بر طبق مطالعات اخیر بیش از پنجاه درصد مطالعات کاربردی بازرگانی شبکه‌عصبی گزارش شده، از شبکه های عصبی چند لایه پیش‌خور[1](MFNN) با قوانین الگوریتم یادگیری پس‌انتشارخطا [2](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 ترکیبی پیچیده ای از ANN و FIS می باشد که منطق و درک نقاط ابهام را ضمیمه عملکرد شبکه‌عصبی می‌کند.

در این مقاله سعی بر آن بوده است که دو مدل پیش-بینیANN 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 شبکه‌عصبی صرف بینجامد.

۱-٤- سوال تحقیق

آیا استفاده ترکیبی از مدل‌های غیرخطی سری زمانی مانند ANN و FIS درقالب ANFIS در رابطه با پیش بینی‌های مرتبط با مسائل انسانی می‌توانند 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.

۱-٦- 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 ۹۰/٦/۱ 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.

[1]-Multi Feed Forward Neural Network
[2]- Back Propagation

۱-۷- معرفی مدل‌های استفاده شده در تحقیق

شبکه‌های عصبی‌مصنوعی (ANN)

مدل ANN از انواع مدل های محاسباتی است که قادر است رابطه میان ورودی‌ها وخروجی‌های یک سیستم هر چند پیچیده و غیرخطی را توسط شبکه ای از گره ها 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 می شوند. ساختار معماری معمول ANN از سه لایه تشکیل می‌شود :لایه‌ورودی که داده ها را در شبکه توزیع می‌کند، لایه‌پنهان که داده ها را پردازش میکند، و لایه‌خروجی که نتایج را استخرج می کند.یک ANN میتواند چندین لایه پنهان داشته باشد.ولی پژوهش‌های تئوریک انجام گرفته در این زمینه نشان‌داده‌اند که با داشتن یک لایه پنهان برای این گونه مدل‌ها میتوان هر تابع پیچیده و غیرخطی را تقریب زد. همچنین نتایج تجربی وعملی نیز این موضوع را تایید میکند(گاپتا و هاما ۲۰۰۳، هامیک و وایت ۱۹۸۹، لیو ۲۰۰۲:۵۰۰). انواع مختلفی از شبکه های 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 استفاه از ناظر است. مدل‌های آموزشی باناظر؛ داده-های آموزشی شامل اطلاعات کامل درباره خصوصیات داده‌ها و نتایج قابل مشاهده است. مدل‌ها می توانند 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) شبکه‌عصبی‌چندلایه‌پیش-خور (MFNN) با قوانین الگوریتم یادگیری پس‌انتشار خطا (BP) را نشان می دهد که با یک لایه پنهان، برای نوع خاصی از پیش‌بینی به کار برده شده است.

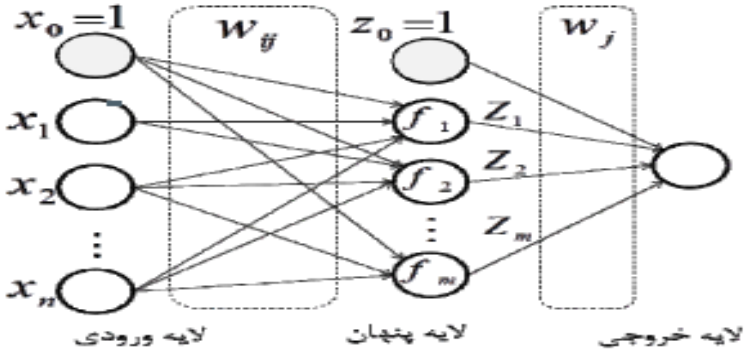

شکل ۱) ساختار شبکه عصبی پیش خور سه لایه

شبکه‌های‌عصبی‌پیش‌خور،کاربردی‌ترین نوع شبکه‌های‌عصبی‌مصنوعی می‌باشند،چرا که این نوع شبکه 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 ۸۵:۱۹۹٤). پیش‌تر در مطالعات مختلف اشاره

شده است کـه چنـین سـاختار شـبکه سـاده‌ای دارای قابلیـت بسـیار بـالایی در نگاشـت میـان ورودی وخروجی بوده وقادر به تخمین هر تابع پیوسته غیـر خطی با دقت مطلوب در صورت استفاده از نرون‌های کـافی در لایـه‌پنهـان مـی‌باشـد (هومیـک ۲۵۷-۱۹۹۱:۲۵۱). خروجی چنـین شـبکه‌ای را میتـوان بـه صورت تابع (۱) نشان داد:

$$y(k) = \sum_{j=1}^{m} w f_i \left(\sum_{j=1}^{n} w_{ij}\, x_i(k) + w_{jo} \right) \quad (1)$$

در تـابع فـوق $x_i(k) = [x_1(k), x_2(k), \ldots, x_n(k)]^T$ بـردار متغییرهای ورودی در زمان k و $y(k)$ متغییـر هـدف، w_j ضریب وزن‌دهی به نـرون پنهـان j ام لایـه آخـر، w_o بایـاس لایـه خروجـی، w_{jo} بایـاس لایـه ورودی، w_{ij} ضرایب وزن دهی میـان نـرون j ام لایـه پنهان و ورودی i ام و f_i نیز تابع فعـال‌سـازی غیـر-خطی نرون j ام لایه‌پنهان می‌باشـد.تـابع هـدف بـرای آموزش چنین شبکه‌ای بـه صـورت رابطـه (۲) قابـل تعریف است:

$$f(w) = \frac{1}{M} \sum_{K=1}^{M} (y_k^{real} - y_k^{predict})^2 \quad (۲)$$

در رابطـه فـوق کـه نشـان‌دهنـده میـانگین مجـذور خطاهـای RMSI[1] پـیش‌بینـی مـی‌باشـد، M تعـداد مشـاهدات در زمـان‌هـای مختلـف، y_k^{real} خروجـی حقیقی برای هر ورودی در زمان K و $y_k^{predict}$ نیـز نشان دهنده خروجی شبکه به منظور پیش‌بینی مقـدار خروجی حقیقی در زمان K می‌باشـد. معمـولاً هـدف الگوریتم بهینه‌یابی در چنین مسـائلی، یـافتن ضـرایبی است که منجر به کمینه شدن رابطه فـوق مـی گـردد. الگـوریتم پـس‌انتشـارخطـا(BP) مهمتـرین و پرکاربردترین تکنیک بهینه‌یابی در آموزش شبکه های عصبی محسـوب مـی شـود. ایـن الگـوریتم در سـال ۱۹۸٦ توسـط رامل‌هـارت و مکنـد مطـرح شـد (منهاج،۱۳۸٤). نام پـس انتشـار خطـای یـادگیری بـا توجه به این که خطای محاسبه شده از لایه خروجـی به لایه میانی و نهایتاً به لایه ورودی بازگشت داده می شود، انتخاب شده است. پس از آموزش شبکه عصبی از داده های آزمون **۲**(تصـدیق) ؛ بـه منظـور بررسـی میزان جامعیت شبکه و انتخاب بهترین شبکه آمـوزش دیده؛ استفاده می‌شود(منهـاج وهمکـاران،۱۳۸۹:۲۰۳-۲۲۰). لازم به یادآوری است که الگوریتم پس‌انتشـار-خطا تعمیم یافته قانون دلتا است.

قابلیت‌های شبکه عصبی]

محاسبه یک تابع معلوم

تقریب یک تابع ناشناخته

شناسائی الگو

پردازش سیگنال

یادگیری

شرایط لازم برای یادگیری شبکه‌های عصبی

در داده‌های آموزشی خطا وجود داشته باشد

مـواردی کـه نمونـه‌هـا توسـط مقـادیر زیـادی زوج (ویژگی- مقدار) نشان داده‌شده باشد.

تابع هدف دارای مقادیر پیوسته باشد.

زمان کافی برای یادگیری وجود داشته باشد

[1]- Root Mean Square Error

[2]- Test set

نیاز به تعبیر تابع هدف نباشد (زیرا به سختی می توان 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 انتشارخطابه‌عقب تطبیقی استفاده نمایند (مورگان،۱۹۹۸). سیستم عصبی‌فازی را میتوان به عنوان ترکیبی از ANN و سیستم استنباط فازی ۱(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 یادگری 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 وسیله شبکه‌های عصبی تعیین می شود. 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 می کنیم، 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. شبکه-های عصبی مصنوعی و مدل فازی در بسیاری از زمینه‌های کاربردی استفاده شده‌اند و هر کدام از آن‌ها دارای محاسن و معایبی هستند. بنابرین، با ترکیب موفقیت‌آمیز این دو روش، مدل‌سازی شبکه‌های عصبی‌مصنوعی و فازی، استفاده شده و امروز روی آن کار می شود.

با ترکیب شبکه عصبی و منطق فازی به یک روش آموزش ترکیبی دست پیدا کرده‌ایم که به این صورت عمل می کند؛ 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 می شوند. 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 آن ها تصحیح می شود.

1-Fuzzy Inference System

(۳)

$$Rule1: if\ x\ is\ A_1\ and\ y\ is\ B_1\ then\ f_1 = p_1x + q_1y + r_1$$

ANFIS شبکه تطبیق‌پذیر و قابل آموزشی است که به لحاظ عملکرد کاملاً مشابه سیستم استنتاج فازی است (چـــائو و ونـــگ،۲۰۱۰:۹۲.۱۰۷، دینـــگ و لیانـــگ ۲۰۰۸:۳۳۶۲.۳۳۶۶). برای سادگی کار فـرض میکنـیم که سیستم فازی ما دو ورودی x و y دارد و خروجـی آن f است. حال اگر قوانین بـه صـورت رابطـه زیـر باشند[1].

$$Rule2: if\ x\ is\ A_2\ and\ y\ is\ B_2\ then\ f_2 = p_2x + q_2y + r_2$$

و اگر برای غیرفازی ساز از غیـرفـازی سـاز میـانگین مراکز استفاده کنـیم خروجـی بـه صـورت تـابع زیـر خواهد بود:

(٤)

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

در نهایت سـاختار معـادل ANFIS بـه صـورت زیـر طراحی خواهد شد:

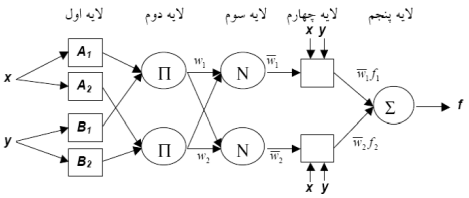

شکل ۲) معماری کلی مدل تطبیقی عصبی- فازی (نبی زاده، ۲۰۱۱).

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

لایه ورودی۲ (ورودی ها از توابـع عضـویت۳ عبـور می کنند).

لایه فازی‌ساز٤ (خروجی این لایه ضرب سیگنال‌های ورودی اســـت کـــه در واقـــع معـــادل قســـمت اگر (f) قوانین است.

لایه قاعده مبنا۵ (خروجی این لایه نزمالیزه شده لایـه قبلی است).

لایه خروجی فـازی٦ (نافـازی سـازی بـا اسـتفاده از روش مرکزثقل).

لایه خروجی۷.

اکنون با طی مراحل بالا یک شبکه تولید می‌شـود کـه معادل سیستم استنتاج فازی سوگنو است. حـال بـرای آموزش چنین شبکه‌ای، ابتدا در لایـه ۱ تمـام قـوانین موجود را تشکیل می‌دهیم. بطور مثال اگـر دو ورودی داشته باشیم که هر کدام ۳ تابع عضویت داشته باشـد، ۹ قانون باید تشکیل دهیم کـه بصـورت زیـر خواهـد بود:

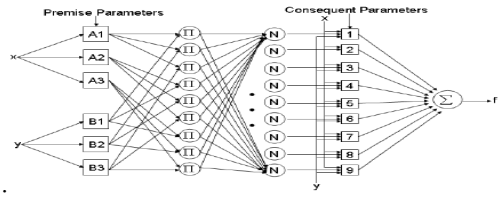

شکل۳) ساختار ANFIS برای حالتی که ۲ ورودی داریم که هر کدام ۳ تابع عضویت دارند

[1]- که در اینجا p_i ، q_i ، r_i پارامترهای خطی مدل تاکاگی سوگنو درجه اول هستند.

2-Input Layer.

[3]- فازی مجموعه‌ای است که درجه عضویت (میزان کوچکی یا بزرگی تعلق عدد در مجموعه) اعضای آن به طور پیوسته در فاصله [۰و۱] 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.

- معیارهای ارزیابی کارایی مدل‌ها

هایکین (١٩٩٤)، به منظور بررسی کارایی مدل های پیش‌بینی سریهای زمانی، معیارهایی را معرفی کرد که نام و فرمول برخی از مهم‌ترین آن‌ها در زیر آمده است.

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

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

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

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

در روابط فوق n ،$\hat{y}_t$ ،y_t و به ترتیب مقدار هدف (مشاهده واقعی)، خروجی مدل و تعداد مشاهدات می‌باشد. واضح است که بهترین مقدار برای R^2 برابر ١ و برای سایر معیارها صفر می‌باشد.

- موقعیت کلی شهر

شهر زابل مرکز شهرستان زابل است و در مختصات جغرافیایی ٣١ درجه و ٢ دقیقه عرض شمالی و ٦١ درجه و ٣٩ دقیقه طول شرقی قرار گرفته است. وسعت شهر زابل برابر ٢٠٨٤ هکتار است که ١٣ درصد از وسعت شهرستان را در بر می گیرد. زابل در فاصله زمینی ٢١٠ کیلومتر از زاهدان در جنوب، ١٥٣٨ کیلومتر از تهران در شمال، ٣٦٦ کیلومتر از بیرجند در شمال غرب و ٨٣٤ کیلومتر از مشهد بوده و بدین طریق با مراکز استان‌های همجوار و سایر نقاط ارتباط می‌یابد.

٣- داده‌های تحقیق

متغییرهای مستقل[١]

طبیعتاً در ساخت‌وسازهای مربوط به یک شهر مجموعه عوامل مختلفی می‌توانند تاثیرگذار باشند. این عوامل از متغییرهای 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. بنابرین 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 نگوییم غیر ممکن کاری بس دشوار است.

داده‌هایی که در مرحله آموزش شبکه به عنوان متغییرهای 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).

تورم

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. داده های جمعیتی پس از استخراج از سایت مرکز آمار ایران برای تبدیل به داده‌های هفتگی از درونیابی خطی استفاده شده است.

[١]- متغییری است که متغییر وابسته را به صورت مثبت یا منفی تحت تاثیر قرار می‌دهد، به عبارت دیگر تغییرپذیری یا نوسان در متغییر وابسته به حساب متغییر مستقل گذاشته می شود

از شاخص متوسط درامد و هزینه خانوار نیز به این دلیل استفاده شده است که وضعیت مطلوب آن میل به ساخت مسکن را افزایش می دهد. فصل‌های سال نیز تاثیرات معنادار وملموسی 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 ٤). 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 شاخص های 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 نمی-باشد). داده‌های GDP از طریق وب سایت بانک-مرکزی‌ایران[1] 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 وغیر مستقیمی که بر قیمت مصالح ساختمانی می‌گذارند دارای جایگاه ویژه‌ای در بین داده های ورودی هستند.

- متغییر وابسته

تقاضاهای صورت گرفته مربوط به پروانه ساخت، یا به عبارتی پروانه ساخت¬هایی که شهرداری با رعایت ضوابط مربوطه عرضه کرده است که برای بازه زمانی ۹۰/۱/٦ تا ۹۲/۸/۲۹ به صورت هفتگی جمع آوری شده است.

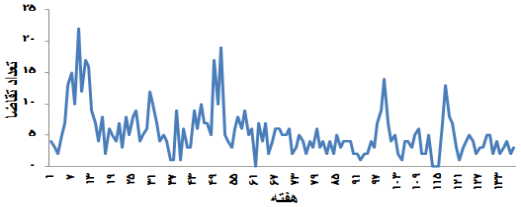

نمودار۱) روند واقعی تقاضای پروانه ساخت‌وساز

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 ثاثیرگذار 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 عصبی‌مصنوعی از تکنیک‌های محاسباتی هوشمند در مدل سازی 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 می-باشند، چرا که شبکه های 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 85:1998) بر این اساس در این مطالعه از شبکه‌های عصبی پیش‌خور (در مقابل سیستم استنتاج فازی-عصبی‌تطبیقی ANFIS) استفاده شده است و به منظور

1- WWW.Cbi.ir

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

$$x_n = \frac{x_i - x_{min}}{x_{max} - x_i} \quad (۵)$$

در رابطه (۵)، x_{min} و x_{max} ،x_n ،x_i به ترتیب نشان‌دهنده مقادیر واقعی، نرمال شده، حداکثر و حد اقل 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.

جدول ۱) مقادیر حداکثر و حداقل متغییرهای مورد بررسی (در دوره زمانی ۹۰/۱/٦ تا ۹۲/۸/۲۹)

متغییر	$(سال)^x min$	$(سال)^x max$
جمعیت	(۹۰) 137722	(۹۱) ۱۵٦۱۷۹
متوسط درآمد (ریال)	(۹۰) ۱۰۰۳۹۱٦٦٦	(۹۱) ۱۲۲٦۷۰٦۱۹
متوسط هزینه (ریال)	(۹۰) ۸٦۰۲۰۲۲۲	(۹۱) ۱۱۱۹۷٦٤۱۲
دما (درجه سانتی گراد)	^{0} -٦	۴۸^{0}
تولید ناخالص داخلی(میلیارد ریال)	(۹۰) ۵۵۸٦۳۰/۰۰۰۰	۵۵۳٦۰۲/۰۰۰۰
تورم	(۹۰) ۲۱/۵	(۹۲/۸/۲۹) ۳٤/۵
نوسانات نرخ ارز- دلار- (ریال)	(۹۰) ۱۰۳۸٤	(۹۲) ۲٤۸۲۱

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

پس از مرحله نرمال سازی، تصادفی نمودن[1] داده‌ها انجام می‌شود. نتیجه این مرحله، داشتن مجموعه‌ای از ورودی‌ها و خروجی‌هاست که در آن، دسته های 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(فرجام نیا و همکاران:۱۳٦۸) بر این اساس، بخشی از داده‌ها برای آموزش(train) و بخشی دیگر برای آزمون(test) شبکه در نظر گرفته می‌شود[2].

اکثر محققان، نمونه‌های آموزش وتصدیق را به ترتیب با یکی از قاعده‌های ۹۰ درصد در مقابل ۱۰ درصد، 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 نرون های مورد نیاز در لایه پنهان نیز از ترکیبی از روش‌های موجود استفاده شده است. به این ترتیب، با استفاده از تابع (٦) تعداد نرون‌ها در لایه پنهان تعیین می‌شود

[1]- Randomizing

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

$$N^h = \frac{1}{2}\left(N^i + N^o\right) + \sqrt{m} \quad (6)$$

$$۱۶ = \frac{1}{2}(۷ + ۱) + \sqrt{۱۳۷}$$

در تابع (٦)، N^h ، N^i ، 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 می شود به منظور بررسی کارایی این مدل در پیش-بینی سری‌های زمانی مورد نظر برای افق زمانی ٤ هفته آینده، از وقفه ٤ 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.

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

ANN		نمایش هندسی پیش‌بینی تقاضای پروانه ساخت (برای بازه زمانی ۹۰/۱/٦ تا ۹۲/۸/۲۹)
مقادیر واقعی ----------		
پیش بینی ----------		
ساختار ۱-۱-۲-۳-٤-٦-۷		
R^2	آموزش	۰/۹۵۳۳
ج	آزمون	۰/۹۱۹۱
MAD	آموزش	۰/۰۱٦۰
	آزمون	۰/۰٦۵۰
RMSE	آموزش	۰/۰۱۸۰
	آزمون	۰/۰۷۳۰

مآخذ: یافته‌های تحقیق

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 ٤ هفته آتی و مقادیر معیارهای ارزیابی حاصل از مقایسه داده‌های بخش 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 تعدادگره‌ها و نرون‌های موجود در هر گره می‌باشد.

– مدل‌سازی و پیش‌بینی تقاضای پروانه ساخت با استفاده از ANFIS

به منظور بررسی کارایی این مدل در پیش بینی سری زمانی مذکور برای افق زمانی ٤ هفته آینده، از الگوریتم آموزشی هیبریدی برای تعیین پارامتر های 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، مدلهای مختلفی با توابع عضویت مختلف (trimf,gaussmf,gauss2mf) و با تعداد توابع عضوت 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، داده های خروجی هر مدل با داده‌های واقعی مقایسه شد. جدول (۳) خلاصه‌ای از این نتایج را نشان می‌دهد:

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

ANFIS		نمایش هندسی پیش‌بینی تقاضای پروانه ساخت (برای بازه زمانی ۹۰/۱/٦ تا ۹۲/۸/۲۹)
مقادیر واقعی ---------- پیش بینی ----------		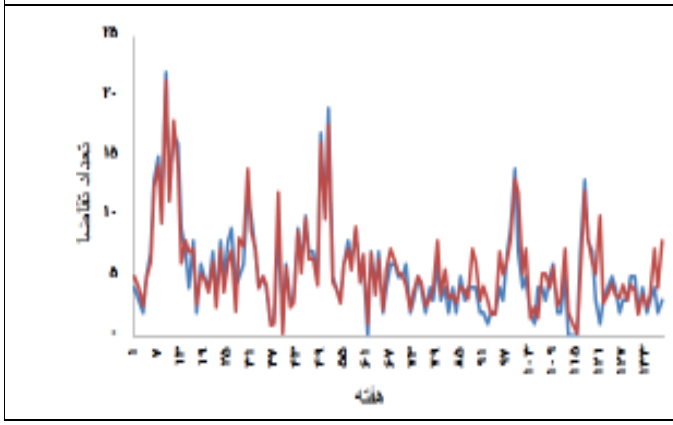
ساختار ۱۰۰-٤-gouss2		
R^2	آموزش	۰/۹۸۹۹
	آزمون	۰/۹٦٥٦
MAD	آموزش	۰/۰۰۱۸
	آزمون	۰/۰۰٦۱
RMSE	آموزش	۰/۰۰۲٦
	آزمون	۰/۰۰٦٤

مآخذ: یافته های تحقیق

سمت راست جدول فوق نمایش هندسی مقادیر واقعی(Target) و پیش‌بینی شده یا خروجی(output) سری زمانی مورد بررسی را توسط مدل ANFIS نشان می دهد، 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 ٤ هفته آتی و مقادیر معیارهای ارزیابی حاصل از مقایسه داده‌های بخش آزمون واقعی با مقادیر بخش آزمون پیش بینی شده یا خروجی این مدل می‌باشد. سمت چپ این جدول نشان دهنده مقادیر معیارهای ارزیابی و ساختار مدل ANFIS برای افق زمانی ٤ هفته آتی می‌باشد. ساختار شبکه‌های طراحی شده به گونه‌ای می باشد 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 می دهد، این مدل در

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 (٤ هفته آتی) استفاده می‌شود. مقادیر پیش‌بینی برای این مدت در جدول (٤) نشان داده شده است.

جدول (٤) 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	۹٤۱
۲	۷	۸۹۲	۱۰٦۸
۳	۲	٦٤۳	۵۳۸
٤	۵	۸۳۹	۱۸٦٦

٤- 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 وشرایط تصمیم گیری 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 عصبی‌فازی تطبیقی (ANFIS) استفاده شده و از لحاظ سه معیار عملکرد R^2 ، MAE و RMSE با هم مقایسه شدند. بدین منظور در این تحقیق درخواست های صورت گرفته از شهرداری (به عنوان خروجی مدل) برای دوره زمانی ۹۰/۱/٦ تا ۹۲/۸/۲۹ جمع آوری و نسبت به تجزیه و تحلیل و طبقه‌بندی آن ها (به صورت تعداد تقاضاهای هفتگی، مساحت زیربنای ساخته شده و مساحت کل استفاده شده) آن ها اقدام شد. از سوی دیگر داده های 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 وهزینه خانوارشهری (زابل)، تاثیرفصل‌های 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 وساز (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 R2=(۰/۹٦۵٦، ۰/۹۸۹۹) مشخص شد که عملکرد بهتری نسبت به شبکه عصبی مصنوعی صرف داردنتایج 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 داده-اند که ترکیب شبکه‌های عصبی مصنوعی و منطق فازی و ایجاد شبکه‌های عصبی فازی تطبیقی موفقیت آمیز بوده و باعث کاهش قابل توجه در خطای پیش-بینی 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 شبکه های عصبی فازی نیازمند داده‌های صریح و قطعی نبوده و نمونه بزرگی از دادها را نیاز

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، (۱۳۸٤)، مبانی شبکه های 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.

فرجام نیا،ایمان؛ناصری،محسن و احمدی،سیدمحمد مهدی (۱۳٦۸) ؛< پیش بینی قیمت نفت با دو روش ARIMA و شبکه‌های عصبی مصنوئی > ؛ فصل نامه پژوهش‌های اقتصادی ایران، ۳۲،۱٦۱تا ۱۸۳.

زمانی، رضا.(۱۳۹۱): پیش بینی درآمدهای شهرداری تهران با استفاده از شبکه های عصبی مصنوعی(روش MLP)، رساله دکتری، مالیه مدیریت شهری.

پورشهابی، وحید. سارانی، سعید رضا. دهمرده‌زاده، شمسی.(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.

Chua, L.H.C., & Wong, T.S.W. (2010). Improving event-based rainfall–runoff modeling usinga 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

perspective"; Econometric Reviews, 13: 1-91.

Morgan, G. C. (1998), Fuzzy logic, Routlendge 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, 173, 383-401.

Kuan, C.M., and H. White (1994); "Artificial neural networks: An econometric perspective"; Econometric Reviews, 13: ۸۹-91.

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.