

## فصلنامه علمی-پژوهشی مطالعات اقتصادی کاربردی ایران

سال چهارم، شماره‌ی ۱۶، زمستان ۱۳۹۴

صفحات: ۲۰۵-۲۳۲

# معرفی یک سیستم پیش‌بینی مناسب برای برآورد تقاضای درمان در بیمارستان امام رضا(ع) ارومیه

\*کیومرث شهبازی<sup>۱</sup>

اکبر پیلهور سلطان‌احمدی<sup>۲</sup>

تاریخ پذیرش: ۱۳۹۴/۰۶/۳۱

تاریخ دریافت: ۱۳۹۴/۰۱/۳۱

### چکیده

بیمارستان‌ها وظیفه حفظ سلامت افراد را بر عهده داشته و قسمت اعظم هزینه‌های سلامت را به خود اختصاص می‌دهند. شواهد حاکی از آن است که چشم‌انداز وسیعی برای ارتقاء و انتلای منابع بیمارستان‌ها (مالی و انسانی) وجود دارد. آگاهی و اطلاع از مقدار تقاضای آینده، مدیریت بهینه این منابع و کیفیت خدمات رسانی در حوزه سلامت را تا حد زیادی تضمین می‌نماید. هدف اصلی این مطالعه بررسی مدل‌های خطی (ARIMA) و غیرخطی (شبکه عصبی MLP) در پیش‌بینی تقاضای تعداد افراد بیمار جهت بستری در بیمارستان امام رضا(ع) ارومیه، در بازه‌های زمانی ساعتی، روزانه، هفتگی و ماهانه و همچنین به تفکیک بخش‌های مختلف بیمارستان است. نتایج این پژوهش بیانگر آن است که مدل غیرخطی شبکه‌ی عصبی مصنوعی مبتنی بر الگوریتم MLP، دارای عملکرد بهتری در پیش‌بینی تقاضای درمان (در دوره نمونه) بوده و قادر است پیش‌بینی‌های دقیق‌تری نسبت به مدل ARIMA ارائه دهد. مدل شبکه عصبی MLP با متوسط درصد خطای ۲۴/۹۶٪ نسبت به مدل ARIMA با متوسط درصد خطای کل ۲۶/۷۳٪ دارای قدرت پیش‌بینی بالایی می‌باشد. همچنین نتایج پیش‌بینی‌های بخش کودکان و نوزادان نشان می‌دهد که مدل خطی ARMA دارای قدرت پیش‌بینی بالاتری نسبت به مدل غیرخطی شبکه عصبی MLP می‌باشد که دلیل این ناسازگاری با فرضیه‌های تحقیق را می‌توان در واپیانس پایین داده‌های این بخش جستجو کرد.

**کلیدواژه‌ها:** پیش‌بینی تقاضای درمان، بخش اورژانس، مدل اتورگرسیو میانگین متحرک، مدل شبکه‌های

عصبی

**طبقه‌بندی JEL:** C53, C45, C13, I11

---

Email: k.shahbazi@urmia.ac.ir

۱. دانشیار گروه اقتصاد دانشگاه ارومیه (تویسندۀ مسئول)

Email: pilehvareco90@aol.com

۲. کارشناسی ارشد اقتصاد دانشگاه ارومیه

## ۱. مقدمه

امروزه سازمان‌ها و شرکت‌های فعال در کسب‌وکار با یک محیط رقابتی و دائمً در حال نوسان نسبت به گذشته مواجه هستند (پورتر و استرن<sup>۱</sup>، ۲۰۰۱). در این محیط، افراد با موقعیت‌های تصمیم زیادی روبرو می‌شوند. یکی از این موقعیت‌های تصمیم، نیازمنجی یا پیش‌بینی تقاضا می‌باشد که پیش‌بینی فرآیند برآورد موقعیت‌های ناشناخته است (آرمسترانگ<sup>۲</sup>، ۲۰۰۱). برای موقوفیت در دنیای متغیر امروز، تصمیم‌های سازمان‌های فعال در کسب‌وکار متکی به پیش‌بینی‌های انجام‌شده با حداقل خطا می‌باشد که این امر در گرو داشتن یک سیستم پیش‌بینی مناسب است (آبراهام و لدولتر<sup>۳</sup>، ۱۹۸۶). بنابراین هر سازمانی با داشتن یک سیستم پیش‌بینی مناسب و کم خطأ، به مدیریتش این امکان را خواهد داد که با توجه به آن و با افق دید بازتر، برنامه‌ریزی دقیق‌تری را از نظر کیفی و کمی در راستای کاهش هزینه‌ها انجام دهد. بخش سلامت جامعه و در رأس آن بیمارستان‌ها نیز از این قاعده استثنای نیستند. بیمارستان‌ها جزء پیچیده‌ترین و تخصصی‌ترین واحدهای نظام بهداشتی و درمانی کشور با مجموعه‌ای از نیروهای انسانی، تجهیزات پزشکی پیشرفته و تأسیسات گران قیمت هستند که رسالت تأمین سلامت بیماران و آحاد مردم را بر عهده دارند، از این‌رو، مدیریت منابع موجود در بیمارستان با توجه به اهمیت و نقش بیمارستان‌ها در جامعه، جایگاه ویژه‌ای را در عصر حاضر به خود اختصاص داده‌اند که لازمه آن علاوه بر داشتن دانش مدیریت، توانایی استفاده از ابزارهای نوین تکنولوژیکی است (فیاض‌بخش، ۱۳۸۹). اما بخش سلامت در کشور ما همگام با روند جهانی سلامت، با چالش‌های اساسی در بخش درمان مواجه است، از جمله: نارضایتی پرستاران و پزشکان شاغل در بیمارستان‌ها به خصوص در بخش اورژانس، نبود تخت کافی، ناکافی بودن اعتبارات و استفاده ناکارآمد از منابع موجود، پیشرفت تکنولوژی و تجهیزات پزشکی و هزینه‌های واردۀ از این بابت، عدم دسترسی همه مردم به خدمات درمانی و نارضایتی مردم.<sup>۴</sup> بخش اورژانس بیمارستان نیز به عنوان بخش ورودی بیمارستان هر ساله قریب به سی میلیون بیمار را در سراسر کشور می‌پذیرد. این بخش با انبوی از مراجعین سرپایی مواجه است که به دلایل مختلف، اورژانس را برای درمان خود انتخاب نموده‌اند و انتظار ارائه خدمات به‌موقع و با کیفیت را دارند. با ورود بیمار به بخش اورژانس اگر بیمار نیاز به مراقبت پیشتری داشته باشد، باید بستری شود. مشکل اصلی در این مرحله کمبود تخت بیمارستانی در بخش‌های بستری، جراحی و مراقبت‌های ویژه است که باعث نگهداری بیمار بدهال در بخش اورژانس می‌شود. اما اگر میزان پذیرش در بخش اورژانس ناشناخته باشد، بیمارستان مجبور خواهد بود چگونگی تخصیص پزشکان و پرستاران را برای هر بخش بیمارستان، حدس بزند. یکی از پیامدهای این مشکل، کمبود پزشکان و پرستاران و در نتیجه متوقف شدن پروسه

1. Porter, M. and Stern, S.

2. Armstrong, J. S.

3. Abraham, B. and Ledolter, J.

4. گزارش نهایی چهل و هشتمین اجلاس روسای دانشگاه‌ها، دانشکده‌های علوم پزشکی و خدمات بهداشتی درمانی کشور، سیمای فرهنگ، ۱۳۸۲

پذیرش بیماران از بخش اورژانس به سایر بخش‌های بیمارستان است که این امر باعث ازدحام بیماران بدهال در بخش اورژانس می‌شود که نیاز به کمک‌های فوری پزشکی دارند. این چرخه معیوب ادامه می‌یابد و بیمارستان، بیماران، پرستاران و پزشکان را دچار مشکلات اساسی می‌کند (گارسیا، ۲۰۱۱). از این‌رو، داشتن نوعی از مدل‌های محاسباتی که به‌وسیله آنها بتوان میزان پذیرش بیماران در آینده را با کمترین خطا برآورد کرد برای همه بیمارستان‌های کشور امری ضروری است. همچنین اگر این پیش‌بینی‌ها بخش‌های مختلف بیمارستان را پوشش دهد آنگاه تصمیم‌گیری بر مبنای آن نتیجه بخش تر خواهد بود. بنابراین با توجه به اهمیت مسئله، این سؤال مطرح می‌شود که چگونه می‌توان بیماران مراجعه‌کننده به بخش‌های مختلف بیمارستان را برآورد نماییم؟ لذا در این تحقیق سعی بر این است که مدلی ارائه شود که با کمترین خطا، بیماران مراجعه‌کننده به بخش‌های مختلف بیمارستان را در بازه‌های زمانی خاص، پیش‌بینی نماید تا این که بتوان از این طریق تصمیم‌گیری‌های بهینه و واقعی‌تری را اتخاذ نمود.

ساختار ادامه این مقاله بدین شرح است: ابتدا به بیان ادبیات تحقیق، پیشینه مطالعات تجربی و روش‌شناسی تحقیق پرداخته می‌شود، سپس بخش‌های مختلف بیمارستان و تعداد مراجعه‌کنندگان به این بخش‌ها در قالب جداول و نمودارها بررسی می‌شود و مجموعه آموزشی برای آموزش مدل آورده می‌شود. در ادامه، داده‌های بیمارستانی (تعداد افراد پذیرش‌شده در بخش‌های مختلف بیمارستان) به وسیله مدل‌های خطی و غیرخطی مورد تجزیه و تحلیل قرار گرفته و با معیارهای مختلف خطای پیش‌بینی مقایسه می‌شوند. همچنین به دلیل اهمیت بخش اورژانس در کارکرد مناسب بخش‌های دیگر بیمارستان، نتایج پیش‌بینی و مقایسه روش خطی با روش غیرخطی در پیش‌بینی تقاضای درمان در این بخش به صورت مجزا صورت گرفته است. بخش آخر تحقیق نیز به جمع‌بندی و نتیجه‌گیری اختصاص یافته است.

## ۲. ادبیات تحقیق

پیش‌بینی در شاخه‌های مختلف علوم از قبیل زنجیره تأمین، برنامه‌ریزی حمل و نقل، پیش‌بینی در اقتصاد، مخابرات، تولید، پیش‌بینی هوا و شرایط جوی، زمین‌لرزه، کارایی بازیگران و تیم‌های ورزشی کاربرد دارد (گارسیا، ۲۰۱۱). مقالات فراوانی در اوایل دهه‌ی ۱۹۷۰ میلادی نشان دادند که مدل‌های آماری ساده که هیچ فرضی در مورد ساختار اقتصاد مطرح نمی‌کنند، قادرند متغیرهای اقتصادی را حداقل به خوبی مدل‌های کیتری و در مقیاس بزرگ پیش‌بینی نمایند (به عنوان نمونه نگاه کنید به نلسون، ۱۹۸۲). اولین مدل‌های غیرساختاری در دهه‌ی ۱۹۲۰ با مقالات اسلاتسکی (۱۹۲۷) و یول (۱۹۲۷) ارائه شد. این مقالات بیان می‌کنند که معادلات تفاضلی خطی ساده، چارچوب قوی و مناسبی برای

1. Garcia, K. A.
2. Nelson

مدل‌سازی و پیش‌بینی گستره‌های وسیعی از متغیرهای اقتصادی و سری‌های زمانی مالی فراهم می‌نمایند. بول و اسلاتسکی در مطالعات دیگر به بررسی فرآیندهای میانگین متحرک پرداختند و به این ترتیب نسل جدیدی از مدل‌های سری زمانی به نام ARMA به دایره‌ی مدل‌های غیر ساختاری پیش‌بینی اضافه گردید. تاریخچه‌ای که تاکنون ارائه شد مربوط به پیش‌بینی مبتنی بر مدل‌های خطی بود. به منظور پیش‌بینی متغیرهای اقتصادی، مدل‌های غیرخطی نیز در سال‌های اخیر توجه زیادی را به خود جلب کرده است. مدل‌های غیرخطی در چند دهه‌ی اول قرن بیستم توسعه یافته‌اند. این مدل‌ها در پاسخ به یکی از مشکلات مهم در پیش‌بینی، یعنی شکسته‌های گاه به گاه و تغییرات رژیم در سری زمانی متغیر و ماندگاری طولانی مدت شوک‌های گذشته به وجود آمدند. در این میان، روش‌های هوش مصنوعی توانایی بالایی را در پیش‌بینی و ارائه عملکرد بهتر در مواجهه با مسائل غیرخطی و سایر مشکلات مدل‌سازی سری‌های زمانی نشان داده‌اند. موقوفیت کم‌نظیر شبکه‌های عصبی به عنوان ابزاری قدرتمند به منظور تجزیه و تحلیل داده‌ها در علوم تجربی موجب شد تا توجه اقتصاددانان نیز به این روش مدل‌سازی جلب شود.

ابندا با توجه به نیاز این مدل‌ها به داده‌های زیاد، تحقیقات و مدل‌سازی در حوزه اقتصاد با استفاده از شبکه‌های عصبی در بازارهای مالی آغاز شد و در اوخر دهه ۸۰ میلادی مدل‌های مختلف به منظور پیش‌بینی نرخ‌های ارز، قیمت سهام و شاخص‌های مختلف بورس ساخته شد (پورکاظمی و نهادوندی، ۱۳۸۴<sup>۱</sup>). از جمله این کارها می‌توان به پژوهش وايت<sup>۲</sup> (۱۹۸۸)، همچنین پژوهش‌های کاو، وو و وانگ<sup>۳</sup> (۲۰۰۲)، تریپی و توربان<sup>۴</sup> (۱۹۹۲)، بوزارچ<sup>۵</sup> (۱۹۹۳) و هافک و هلمنستین<sup>۶</sup> (۱۹۹۶) اشاره کرد. استفاده از شبکه‌های عصبی برای پیش‌بینی و مدل‌سازی در اقتصاد کلان را می‌توان به دوره پس از انتشار مقاله مشهور خوان و وايت<sup>۷</sup> (۱۹۹۴) نسبت داد.

در واقع، قدرت اصلی شبکه‌های عصبی این است که آنها قادرند برای تحولاتی چون سقوط بازار بورس و شوک‌های نفتی به عنوان انحرافات معنی‌دار از قبول فرض خطی بودن، مدل‌های بهتری بسازند. همچنین در مطالعات هیل و دیگران<sup>۷</sup> (۱۹۹۴)، شبکه‌های عصبی در زمینه پیش‌بینی متغیرهای اقتصاد کلان، بر حسب درصد میانگین قدر مطلق خطا به خوبی مدل‌های آماری استاندارد و یا بهتر از آن‌ها عمل کردند. در کاربردهای سری‌های زمانی، نتایج مقالات پیشنهاد می‌کرد که شبکه‌های عصبی برای پیش‌بینی با افق زمانی طولانی‌تر نتایج دقیق‌تری را به همراه دارد.

1. White

2. Kuo, R. J.; Wu, P. and Wang, C. P.

3. Trippi and Turban

4. Bosarge

5. Haefke and Helmenstein

6. Kuan and White

7. Hill

### ۳. پیشینه مطالعات تجربی

با اینکه بیمارستان‌های کشور با مشکلات عدیده‌ای در بخش نیروی انسانی و نبود یک برنامه‌ریزی منسجم برای استفاده بهینه از منابع، روبرو هستند، ولی تاکنون تحقیق کاربردی برای کاهش مشکلات ذکر شده به ندرت مشاهده می‌شود. همچنین، طبق بررسی‌های به عمل آمده، در رابطه با برآورد و پیش‌بینی تعداد پذیرش بیماران در بیمارستان، هیچ‌گونه مقاله و یا تحقیقی در ایران صورت نگرفته است و این نوع مطالعه کاربردی در حوزه سلامت برای اولین بار در کشور بر روی بیمارستان امام رضا(ع) ارومیه انجام گرفته است.

تنگ، آلمید و فیش وک<sup>۱</sup> (۱۹۹۱)، مدل‌های باکس و جنکینز و شبکه‌های عصبی مصنوعی را برای پیش‌بینی رفت‌وآمد مسافر خط هوایی بین‌المللی، پیش‌بینی فروش ماشین در داخل آمریکا و پیش‌بینی فروش ماشین در خارج از آمریکا بکار بردن و نشان دادند که مدل‌های باکس و جنکینز در کوتاه‌مدت بهتر از شبکه‌های عصبی هستند و در بلندمدت شبکه‌های عصبی مصنوعی بهتر می‌باشد.

مشیری و همکاران<sup>۲</sup> (۱۹۹۹)، در مقاله‌ای، نرخ تورم کانادا را با استفاده از مدل‌های متفاوت شبکه‌های عصبی، یک مدل اقتصادستنجی ساختاری و یک مدل VAR در سه افق زمانی براساس داده‌های ماهانه ۱۹۷۰ تا ۱۹۹۴ مورد مقایسه قرار داده‌اند. مطالعه آنها نشان می‌دهد در پیش‌بینی‌های ایستا، شبکه‌های عصبی نتایجی هم‌سطح یا بهتر از دیگر مدل‌های اقتصادستنجی دارند. جفری، لگان<sup>۳</sup> (۲۰۰۶)، با استفاده از روش شبکه‌های عصبی سعی در پیش‌بینی پذیرش بیمارستانی کرده است. آبورتو و وبر<sup>۴</sup> (۲۰۰۷) یک سیستم هوشمند ترکیبی را با ادغام مدل‌های ARIMA و شبکه عصبی برای پیش‌بینی تقاضا در زنجیره تأمین در یک سوپرمارکت واقع در شیلی ارائه کردند.

لی، جیکسون و همکاران<sup>۵</sup> (۲۰۰۹) با استفاده از پیش‌پردازنده شکایات اصلی (CC<sup>۶</sup>) اقدام به پیش‌بینی تعداد پذیرش بیمارستانی نموده‌اند. آدرس گارسیا، کلبر (۲۰۰۹) اولین بار این نوع تحقیق را در مرکز پزشکی منطقه‌ای هولمز<sup>۷</sup>، واقع در ملبورن فلوریدا<sup>۸</sup> در سال ۲۰۰۹ انجام داده است. در این تحقیق، داده‌های بیمارستانی به وسیله الگوریتم‌های مختلف تجزیه و تحلیل شده‌اند. محقق با معرفی الگوریتم‌های درختی، تصادفی و همچنین به کار بردن رگرسیون شبکه‌های عصبی و روش ARMA، سعی در مقایسه و کاهش خطای پیش‌بینی پذیرش آینده برآمده است و به این نتیجه رسیده است که

1. Tang. Z., Almeida. C. and P. A. Fishwick

2. Moshiri and *et al.*

3. Leegon Jeffrey

4. Aburto, L. and R. Weber

5. Li, J. and *et al.*

6. Chief Complaint

7. Holmes Regional Medical Center

8. Melbourne Florida

استفاده از مدل‌های الگوریتم تصادفی، پیش‌بینی‌های نزدیک‌تر به واقعیت را به دست می‌دهد. کمترین درصد خطای به دست آمده در این مطالعه ۱۶ درصد می‌باشد.

فلورس، جان و دیگران<sup>۱</sup> (۲۰۱۲)، در مقاله‌ای با عنوان تکامل مدل‌های آرما و شبکه عصبی در پیش‌بینی سری‌های زمانی، به مقایسه قدرت پیش‌بینی این مدل‌ها با استفاده از داده‌های مصنوعی سری زمانی پرداخته‌اند. نتایج این تحقیق نشان می‌دهد که قدرت پیش‌بینی مدل غیرخطی شبکه عصبی نسبت به مدل خطی آرما بیشتر می‌باشد. سرمنپنیس، جورجیوس و دیگران<sup>۲</sup> (۲۰۱۲)، در تحقیقی به پیش‌بینی قیمت یورو و تأثیر آن بر تجارت در اتحادیه اروپا، با استفاده از مدل‌های آریما و شبکه عصبی در دوره زمانی ۲۰۰۲–۲۰۱۰ پرداخته‌اند. نتایج این پژوهش نشان می‌دهد که شبکه عصبی (MLP)، نسبت به مدل آریما دارای عملکرد بهتری در پیش‌بینی قیمت یورو داشته است.

ولی‌پور و دیگران<sup>۳</sup> (۲۰۱۲)، در تحقیقی با عنوان مقایسه مدل‌های آرما و شبکه عصبی مصنوعی دینامیک و استاتیک در پیش‌بینی جریان ماهانه ورودی به مخزن سد، قابلیت مدل آرما برای پیش‌بینی جریان ماهانه ورودی مخزن سد را ارزیابی کردند و نتایج به دست آمده را با مدل‌های شبکه عصبی مصنوعی ایستا و پویا، مقایسه کردند. این مقایسه توسط دو شاخص خطا (RMSE و MBE) انجام گرفت. نتایج به دست آمده حاکی از آن است که مدل شبکه عصبی مصنوعی پویا دارای کمترین خطا در پیش‌بینی جریان ماهانه ورودی به مخزن سد می‌باشد، همچنین مدل‌های شبکه عصبی مصنوعی و آریما به ترتیب دارای بهترین عملکرد بودند.

از دیگر موارد، می‌توان به پیش‌بینی تقاضای کوتاه مدت و بلندمدت جریان برق (سیا و ال امین، ۱۹۹۹؛ بکالی، سلورا، برانو و مارواگلیا، ۲۰۰۴)، پیش‌بینی تقاضای استفاده از انرژی (هابس و همکاران<sup>۴</sup>؛ سوزان و همکاران<sup>۵</sup>، ۲۰۰۵)، پیش‌بینی تقاضای توربیسم (لاو<sup>۶</sup>، ۱۹۹۹ و پالمر، مونتانو<sup>۷</sup>، ۲۰۰۶)، پیش‌بینی ورشکستگی ریسک اعتباری (آتیا<sup>۸</sup>، ۲۰۰۱)، پیش‌بینی نرخ مبادلات ارزهای خارجی (هانگ و همکاران<sup>۹</sup>، ۲۰۰۴) و... اشاره نمود. کهزادی و همکاران<sup>۱۰</sup> (۱۹۹۵) در مقاله‌ای، با استفاده از شبکه عصبی مصنوعی پیشخور، به پیش‌بینی قیمت گندم و گاو زنده و مقایسه آن با مدل ARIMA پرداخته‌اند. آنها دریافتند خطای پیش‌بینی مدل شبکه عصبی به ترتیب ۲۷ تا ۵۶ درصد کمتر از مدل ARIMA است. قاسمی و همکاران (۱۳۷۹)، در مقاله‌ای به پیش‌بینی قیمت شیر با استفاده از شبکه

1. Flores, J. J.; Graff, M. and Rodriguez, H.
2. Sermpinis, G.; Dunis, C.; Laws, J. and Stasinakis
3. Valipour, M.; Banhabib, M. E. and Behbahani, S. M. R.
4. Hobbs, B. F and *et al.*
5. Sozen and *et al.*
6. Law
7. Palmer and Montano
8. Atiya, A. F.
9. Huang and *et al.*
10. Kohzadi and *et al.*

عصبی مصنوعی و مدل ARIMA بر اساس داده‌های ماهانه قیمت شیر پرداخته‌اند و به این نتیجه رسیدند که خطای پیش‌بینی مدل شبکه عصبی ۹ تا ۱۳ درصد کمتر از مدل ARIMA است. ابریشمی و همکاران (۱۳۹۳) با استفاده از دو روش ARIMA و شبکه عصبی GMDH به پیش‌بینی تقاضای گاز طبیعی در بخش‌های مختلف اقتصادی ایران پرداخته و به این نتیجه رسیده‌اند که روش شبکه عصبی GMDH و دقت بالاتری نسبت به روش ARIMA در پیش‌بینی تقاضای گاز طبیعی دارد. آقایی (۱۳۸۵)، در مقاله‌ای به پیش‌بینی قیمت فولاد با استفاده از شبکه عصبی مصنوعی و مدل ARIMA پرداخته است. نتایج نشان می‌دهد، شبکه‌های عصبی مصنوعی در زمینه پیش‌بینی قیمت فولاد در مقایسه با روش ARIMA عملکرد بهتری دارند. جعفرنژاد و سلیمانی (۱۳۸۹)، در تحقیقی با استفاده از یک شبکه عصبی مصنوعی چند لایه، سیستمی مقایسه‌ای با روش رایج مورد استفاده در پیش‌بینی (روش باکس-جنکینز) با مدل (ARIMA)، برای پیش‌بینی تقاضای دستگاه سی‌تی‌اسکن ارائه داده‌اند که با توجه به معیار سنجش دقت مدل‌ها یعنی میانگین مجدول خطا (MSE)، مدل شبکه عصبی اثربخشی و کارایی بیشتری را در مقابل با روش آریما در پیش‌بینی از خود نشان داده است. با توجه به مطالعات مختلفی که به بررسی و مقایسه روش‌های خطی و غیرخطی در امر پیش‌بینی متغیرهای سری زمانی پرداخته‌اند، می‌توان عنوان نمود که در تمامی تحقیقات ذکر شده، شبکه‌های عصبی مصنوعی عملکرد بهتری نسبت به روش‌ها و مدل‌های خطی داشته‌اند.

#### ۴. روش‌شناسی

ویژگی اصلی مدل‌های سری زمانی را می‌توان در بی‌نیازی آنها نسبت به نظریه‌های اقتصادی دانست. این مدل‌ها برخلاف مدل‌های چند متغیره رایج در روش‌های اقتصادسنجی، به صورت ساده و یک متغیره و بر اساس رفتار متغیر مورد نظر در گذشته تحلیل می‌شوند (لیو، ۲۰۱۰). روش‌های مختلفی برای پیش‌بینی متغیرهای سری زمانی وجود دارد. روش ARMA به عنوان یک روش خطی و همچنین شبکه‌های عصبی پیش‌خوانده آموزش دیده با لحاظ پس پراکنی<sup>۱</sup> به عنوان یک روش غیرخطی، روش‌هایی هستند که در این مطالعه استفاده شده‌اند. بنابراین در این مطالعه، هدف مقایسه دقت پیش‌بینی روش خطی در مقابل روش غیرخطی می‌باشد. در بسیاری از متون، مدل‌های ARMA به عنوان پایه تجزیه و تحلیل‌های ریاضی در سری‌های زمانی معرفی شده‌اند (ردی، ۲۰۱۱،<sup>۲</sup>). این مدل ترکیبی از دو مدل می‌باشد که در معادله (۱)، نشان داده شده است.

1. Feed Forward Neural network trained with Back Propagation  
2. T. Agami Reddy

$$AR(X_t) + MA(X_t) = c + \varepsilon_t + \sum_{i=1}^p a_i X_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (1)$$

بخش AR، فرآیند اتورگرسیو را و بخش MA، فرآیند میانگین متحرک را نشان می‌دهد. یکی از مشکلاتی که در مواجهه با سری‌های زمانی مورد مطالعه باید بدان پرداخت، مسأله مانایی داده‌ها می‌باشد. عموماً سری‌های زمانی مانا در عمل وجود ندارند. مدل‌های ARMA، طی سه مرحله ساخته می‌شوند. در مرحله اول تعدادی مدل از بین گروه عمومی مدل‌های ARMA بر اساس معیارهای مربوط، بدون قواعد مشخص و بر اساس قضاوت و تجربه‌ی تحلیلگر شناسایی می‌شوند. مرحله دوم به تخمین و آزمون پارامترهای مدل‌های شناسایی شده می‌پردازد که در اینجا از روش حداقل مربعات خطی استفاده شده است. مرحله سوم، مرحله بازبینی تشخیص مدل (آزمون پسماندها) می‌باشد. در نهایت بعد از تشخیص بهترین مدل، با استفاده از آن به پیش‌بینی مقادیر آینده سری زمانی می‌پردازیم (جدول شماره ۱). روش دومی که در این تحقیق استفاده می‌شود، شبکه عصبی چند لایه پرسپترون (MLP)<sup>۱</sup>، با روش یادگیری پس انتشار<sup>۲</sup> می‌باشد. شبکه عصبی مصنوعی یک سیستم پردازش اطلاعات است که ویژگی‌های عملکردی مشابه شبکه عصبی بیولوژیکی دارد (فاوست، ۱۹۹۴).

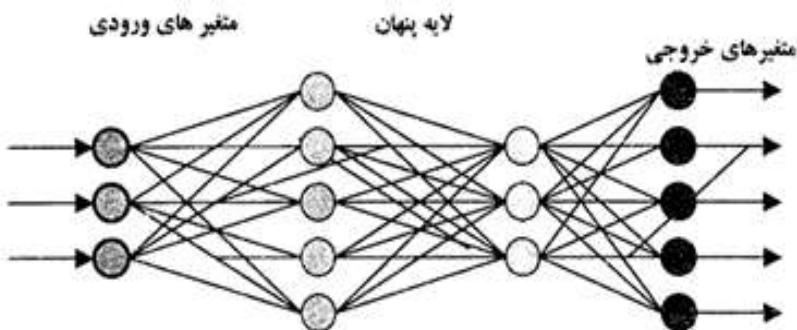
ساختار شبکه MLP، شامل تعدادی گره<sup>۳</sup> با تابع فعالیت (محرك)<sup>۴</sup> مشخص است که در لایه‌های مجزا قرار دارند. هر گره، به واسطه ضریب وزنی خود، خروجی تمامی گره‌های لایه قبلی را تجمعی کرده و از طریق تابع فعالیت به لایه بعدی ارسال می‌کند. شبکه عصبی MLP، دارای یک لایه ورودی<sup>۵</sup>، یک لایه خروجی<sup>۶</sup> و حداقلی یک لایه پنهان<sup>۷</sup> (میانی) است، تعداد گره در هر لایه متغیر است و بستگی به ساختار شبکه و مسئله مورد بررسی دارد. در یک شبکه MLP با یک لایه پنهانی، مقدار خروجی واحد نام از رابطه زیر به دست می‌آید:

$$\hat{y} = \Phi_2(b_0 + \sum_{j=1}^M w_j \Phi_2(b_{j0} + \sum_{s=1}^p x_{is} w_{js})) \quad (2)$$

در این فرمول،  $n$  تعداد الگوهای مشاهدات،  $M$  تعداد گره‌های لایه پنهانی،  $P$  تعداد گره‌های لایه ورودی (معادل تعداد متغیرهای کمکی)،  $w_{js}$  وزن مربوط به ورودی  $x_{is}$  در گره  $j$ ام،

1. Multi-Layer Perceptron
2. Back-Propagation
3. Fausett, L.
4. Nodes
5. Activation Function
6. Input Layer
7. Output Layer
8. Hidden Layer

$w_j$  وزن مربوط به گره  $j$ ام،  $b_0$  و  $b_{j0}$  به ترتیب مقادیر اریبی گره‌های لایه میانی و لایه خروجی و  $\Phi_2$  و  $\Phi_1$  به ترتیب توابع فعالیت لایه خروجی و لایه میانی شبکه هستند. نخستین گام در این روش، معماری شبکه می‌باشد که شامل مراحلی نظری تعیین تعداد لایه‌های پنهان، تعیین تعداد نرون‌های لایه‌های پنهان، تعیین تعداد نرون‌های لایه‌های خارجی، تعیین توابع فعال‌سازی نرون‌ها، نرمال کردن داده‌ها، تعیین داده‌های مربوط به آموزش و تست و در نهایت تعیین معیار عملکرد شبکه می‌باشد (شکل ۱). مرحله دوم در این روش، طراحی الگوریتم می‌باشد. مهم‌ترین موضوعی که شبکه‌های عصبی را از دیگر روش‌های بهینه‌سازی جدا می‌نماید، یادگیری یا آموزش دیدن آن‌ها می‌باشد که بر دو نوع است: یادگیری با ناظر و دیگری یادگیری بدون ناظر. رایج‌ترین الگوریتم، یادگیری برای شبکه‌های چند لایه پیشخور، الگوریتم پس انتشار خطا می‌باشد که یک روش یادگیری با ناظارت است (شکل شماره ۲). مسئله مورد نظر در داخل شبکه انتشار داده می‌شود و بر این اساس هر نرون به صورت منفرد اطلاعات را پردازش می‌کند، سپس با استفاده از یک الگوریتم پس انتشار خطا، بر اساس نتایج حاصله، شبکه را آموزش می‌دهیم تا خطای پیش‌بینی کاهش یابد. در جدول شماره ۱، فرآیند مدل‌سازی، پیش‌بینی و نتیجه‌گیری به وسیله دو روش ARMA و ANN به صورت خلاصه شده توضیح داده شده است.



شکل ۱: ساختار شبکه عصبی



شکل ۲: شبکه عصبی استاندارد پیشخور و یادگیری آن

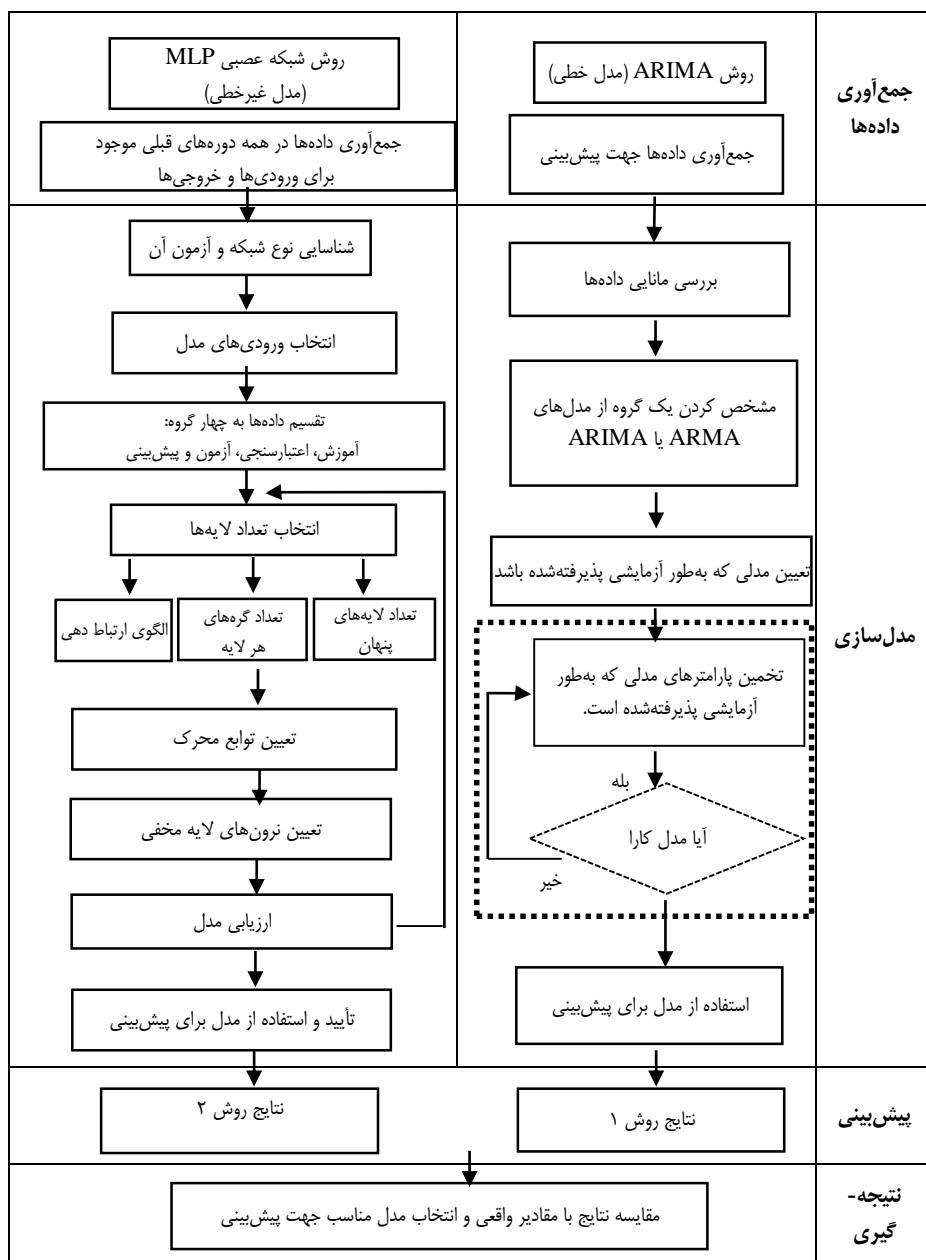
همچنین روش‌های ارزیابی با استفاده از روش اعتبارسنجی متقابل، با معیارهای ارزیابی جذر میانگین مربعات خطأ (RMSE) و میانگین قدر مطلق خطأ (MAE) انجام می‌شود.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n \{Z^*(x_I) - Z(x_I)\}^2} \quad (3)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |Z^*(x_I) - Z(x_I)|$$

که در آنها،  $Z(x_I)$  و  $Z^*(x_I)$  به ترتیب مقدار تخمین زده شده و مقدار واقعی  $Z$  در نقطه  $x_I$  و  $n$  تعداد کل مشاهدات می‌باشد. هر چه مقدار عددی این شاخص‌ها کمتر باشد نشانگر عملکرد بهتر روش بکار رفته در امر پیش‌بینی می‌باشد (ایساک و اسریواستاوا، ۱۹۸۹).

### جدول ۱: فرآیند مدل‌سازی، پیش‌بینی و نتیجه‌گیری روش‌های ARIMA و ANN



منبع: جعفرنژاد، احمد، ۱۳۹۰

## ۵. پذیرش بیماران در بیمارستان

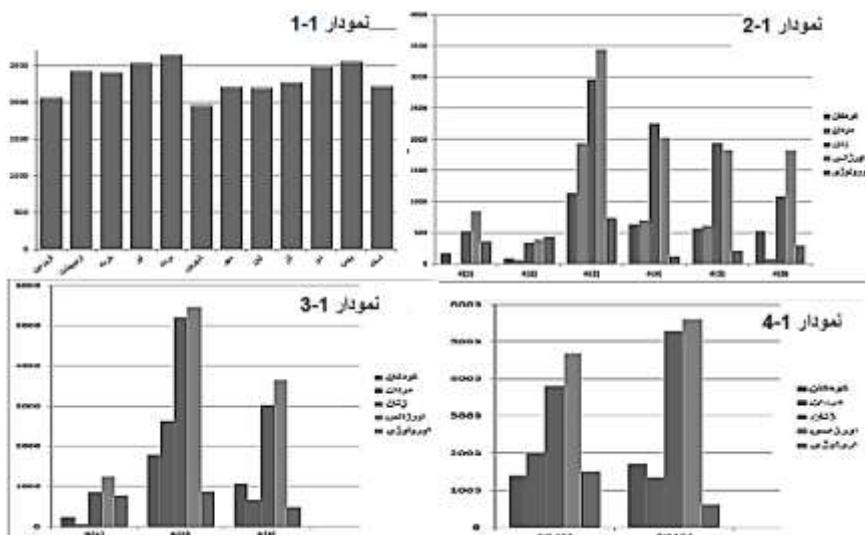
بیمارستان‌ها به طرق مختلفی بیماران را پذیرش می‌کنند. رایج‌ترین روش، پذیرش بیماران به‌وسیله بخش اورژانس می‌باشد. روش دیگری که در پذیرش بیماران در بیمارستان‌ها بکار گرفته می‌شود، پذیرش خارج از بیمارستان می‌باشد که اکثرًا توسط پزشکانی که بیماران را در مطب خود ویزیت می‌کنند صورت می‌گیرد. در جدول شماره ۲، نحوه پذیرش بیماران در بخش‌های مختلف بیمارستان نشان داده شده است. داده‌های مورد استفاده در این پژوهش مربوط به تعداد افراد مراجعه کننده به بیمارستان امام رضا(ع) ارومیه، طی سال ۱۳۹۰ می‌باشد. این داده‌ها به وسیله واحد مدارک پزشکی بیمارستان مذکور اخذ گردیده است و شامل ۱۱ بخش مختلف می‌باشد که با ا gammam بخش‌های مرتبط به هم، پنج بخش اصلی به دست آمده است. در جدول ۲، تعداد تخت‌های بیمارستان، تعداد افراد پذیرش‌شده و درصد پذیرش بیماران به تفکیک بخش‌های مختلف آن مشاهده می‌شود. مجموع تخت‌های بستری با احتساب تخت‌های بخش اورژانس، ۲۷۸ تخت می‌باشد. در سال ۱۳۹۰، حدود ۲۸۰۲۸ نفر در بیمارستان مورد نظر تحت درمان و بستری قرار گرفته‌اند. ملاحظه می‌شود که بیشترین سهم در پذیرش بیماران را بخش اورژانس و مراقبت‌های ویژه بر عهده دارد (۳۶/۹۳٪)؛ این امر نشان‌دهنده اهمیت فوق العاده این بخش در سیستم درمان یک بیمارستان می‌باشد. همچنین اگر پذیرش بیماران را محدود به بخش اورژانس و بخش بیرونی در نظر بگیریم، بخش بیرونی با ۷/۶۳٪ بیشترین سهم را از نظر تعداد افراد پذیرش‌شده در بیمارستان خواهد داشت. بعد از بخش ۴، بیشترین سهم پذیرش بیماران مربوط به بخش سوم می‌باشد که حاکی از بیشتر بودن متقاضیان درمان زن نسبت به متقاضیان درمان مرد در بیمارستان مورد مطالعه است. بخش مردان، کوکان و اوروپلوزی به ترتیب بیشترین تعداد پذیرش را بعد از بخش‌های اورژانس و زنان، به خود اختصاص داده‌اند.

جدول ۲: نحوه پذیرش بیماران و تعداد تخت‌های بستری در بخش‌های مختلف بیمارستان

پذیرش از طبق درمانگاه تخصصی بیمارستان	پذیرش از طبق بخش	پذیرش از طبق خارج از بیمارستان
بخش‌های اصلی بیمارستان		
بخش ۳ جراحی، داخلی و زایمان زنان تعداد تخت‌های بستری ۹۶ تخت تعداد افراد پذیرش شده ۹۰۷۷ نفر درصد افراد پذیرش شده ۳۳/۴	بخش ۲ جراحی و داخلی مردان تعداد تخت‌های بستری ۶۴ تخت تعداد افراد پذیرش شده ۳۳۶۲ نفر درصد افراد پذیرش شده ۱۱/۹۶	بخش ۱ کودکان و نوزادان تعداد تخت‌های بستری ۲۸ تخت تعداد افراد پذیرش شده ۳۱۰۹ نفر درصد افراد پذیرش شده ۱۱/۱
بخش ۵ چشم، حلق، بینی و اروپلوزی و post partom تعداد تخت‌های بستری ۳۸ تخت تعداد افراد پذیرش شده ۲۱۳۰ نفر درصد افراد پذیرش شده ۷/۶	بخش ۴ اورژانس بستری و سریابی و بخش مراقبت‌های ویژه تعداد تخت‌های بستری ۵۲ تخت تعداد افراد پذیرش شده ۱۰۳۵۰ نفر درصد افراد پذیرش شده ۳۶/۹۳	منبع: واحد مدارک پزشکی بیمارستان امام رضا(ع) ارومیه

توزیع فراوانی تعداد بیماران پذیرش شده در بخش‌های پنج گانه بیمارستان و به تفکیک دوره‌های مختلف زمانی در نمودار شماره ۱ مشاهده می‌شود. با توجه به نمودار ۱، در می‌یابیم که توزیع بیماران در طول سال مورد بررسی، به صورت سینوسی می‌باشد، بیشترین مراجعه طی مرداد ماه صورت گرفته است و کمترین مراجعه، طی شهریور ماه می‌باشد. همچنین می‌توان عنوان نمود که حرکت سینوسی این نمودار بیان‌کننده متوسط مدت زمان اشتغال و بیکاری تخت‌های بیمارستانی است، به طوری که از آغاز فروردین‌ماه تا مردادماه، پذیرش بیماران روند صعودی دارد، در شهریورماه این روند نزولی شده و در مهرماه تا بهمن‌ماه روند صعودی ادامه می‌یابد تا در اسفندماه بار دیگر روند نزولی آغاز گردد. بنابراین نتیجه گرفته می‌شود که در طی سال ۱۳۹۰، تخت‌های بیمارستان در اشتغال کامل نبوده‌اند و این تقاضای درمان است که موجب اشتغال یا عدم اشتغال تخت‌های بستری می‌شود. البته نباید از نظر دور داشت که ممکن است در بردهای از زمان، در بخشی ظرفیت خالی برای پذیرش بیمار نباشد که این امر باعث افزایش زمان انتظار در بخش اورژانس یا انتقال بیمار به بیمارستان‌های دیگر شود و در مقابل در بخشی ظرفیت اشباع‌نشده وجود داشته باشد. همچنین نمودارهای شماره ۲، ۳ و ۴، توزیع فراوانی تعداد افراد پذیرش شده در سه بازه زمانی مختلف و در بخش‌های پنج گانه، به ترتیب دوره هشت‌ ساعته، دوره روزانه و دوره هفتگی را نشان می‌دهد.

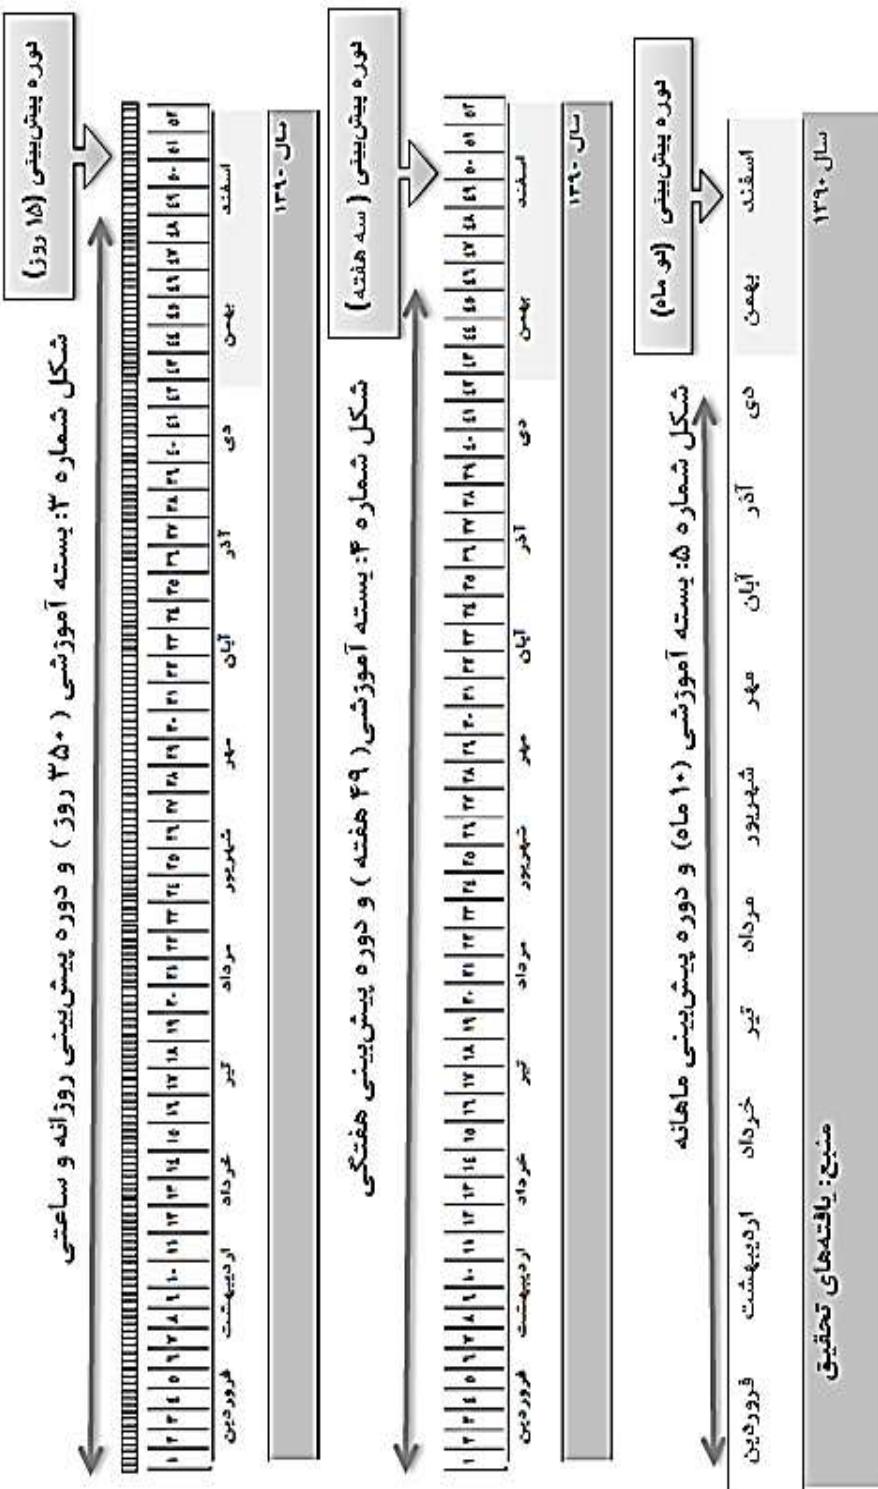
**نمودار ۱: توزیع فراوانی تعداد بیماران پذیرش شده در بازه‌های زمانی مشخص**



منبع: یافته‌های تحقیق

## ۶. مجموعه آموزشی برای آموزش مدل

در آموزش شبکه عصبی، هرچه مشاهدات کامل‌تر باشد، آنچه انتزاع شده است صحیح‌تر می‌باشد. شبکه عصبی آنچه مشاهده می‌کند را در قالب پارامترهای درونی خود به خاطر می‌سپارد. در واقع، تکرار هر یک از مشاهدات سبب تغییر پارامترهای درونی شبکه در جهت حفظ روابط حاکم بر مشاهدات می‌باشد. در این مطالعه از شبکه عصبی MLP استفاده شده است. برای آموزش این شبکه، معمولاً<sup>۳</sup> از الگوریتم پس انتشار (BP) استفاده می‌شود. در این تحقیق بسته به نوع پیش‌بینی، مجموع آموزشی مختلفی از داده‌های بیمارستانی مورداستفاده قرار گرفته است. در پیش‌بینی‌های ساعتی و روزانه، بسته آموزشی ۳۵۰ روزه‌ای تدارک دیده شده است که شبکه عصبی با الگوریتم MLP با استفاده از این بسته آموزشی اقدام به پیش‌بینی تعداد بیماران هر بخش در بازه ۱۵ روزه‌ی آخر سال کرده است (شکل شماره ۳). بسته آموزشی مورداستفاده در پیش‌بینی به صورت هفت‌های، شامل ۴۹ هفته، به ترتیب از هفته اول فروردین ماه تا پایان هفته اول اسفندماه می‌باشد (شکل شماره ۴). در نهایت در پیش‌بینی ماهانه، همان طوری که در شکل ۵ مشاهده می‌شود، بسته آموزشی مشکل از ده ماه اول سال بوده که برای پیش‌بینی دو ماه آخر سال، شبکه عصبی MLP را آموزش داده است.



## ۷. نتایج تحقیق

اولین قدم در ارائه یک پیش‌بینی مناسب برای متغیر موردنظر در مدل‌های خطی (ARMA)، بررسی مانایی متغیرها می‌باشد. لازم به ذکر می‌باشد که آزمون مانایی فقط در مدل‌های خطی کاربرد داشته و برای استفاده از مدل‌های غیرخطی نظری شبکه عصبی، کاربردی ندارد. در این تحقیق برای مشخص نمودن مانایی متغیرها از آزمون KPSS استفاده شده است. جدول شماره (۳)، نتایج آزمون ریشه واحد را برای متغیرهای یادشده به تفکیک بخش‌ها و بازه‌های زمانی ارائه می‌نماید. همچنین، با توجه به نتایج جدول (۳)، می‌توان نوع مدلی که در هر دوره زمانی و در هر بخش بیمارستانی بکار رفته را مورد بررسی قرار داد. بهترین مدل با توجه به معیار AIC، انتخاب شده است. در جدول (۴) مدل‌های مناسب ARMA و یا ARIMA بر اساس پارامترهایی مانند: p (تعداد جملات فرآیند خود توضیح)، q (تعداد جملات فرآیند میانگین متحرک) و d (تعداد دفعات لازم تفاضل گیری به منظور مانا شدن سری) به صورت ARIMA (p,d,q) نشان داده شده است. از بین تخمین‌های موجود، ۳۷ مورد به روش ARIMA و ۳۳ مورد به روش ARMA می‌باشد. کلیه تخمین‌های بخش ۱ که شامل ۱۴ تخمین با دوره‌های زمانی متفاوت است با مدل ARMA تخمین زده شده‌اند.

جدول ۳: نتایج آزمون ریشه واحد KPSS

بخش ۵	بخش ۴	بخش ۳	بخش ۲	بخش ۱	بازه زمانی / بخش
I(·)	I(·)	I(·)	I(·)	I(·)	۴-۴
I(۱)	I(·)	I(·)	I(۱)	I(·)	۸-۸
I(۱)	I(۱)	I(·)	I(·)	I(·)	۸-۱۲
I(۱)	I(·)	I(۱)	I(۱)	I(·)	۱۲-۱۶
I(۱)	I(۱)	I(·)	I(۱)	I(·)	۱۶-۲۰
I(۱)	I(·)	I(·)	I(۱)	I(·)	۲۰-۲۴
I(۱)	I(·)	I(·)	I(۱)	I(·)	۲۴-۸
I(۱)	I(۱)	I(۱)	I(۱)	I(·)	۸-۱۶
I(۱)	I(۱)	I(·)	I(۱)	I(·)	۱۶-۲۴
I(۱)	I(۱)	I(·)	I(·)	I(·)	۲۴-۱۲
I(۱)	I(·)	I(۱)	I(۱)	I(·)	۱۲-۲۴
I(۱)	I(۱)	I(۱)	I(۱)	I(·)	روزانه
I(۱)	I(·)	I(۱)	I(۱)	I(·)	هفتگی
I(۱)	I(۱)	I(·)	I(۱)	I(·)	ماهانه

منبع: یافته‌های تحقیق

## جدول ۴: مدل‌های بکار رفته در پیش‌بینی با توجه به الگوی خطی ARIMA(p,d,q)

بخش ۵	بخش ۴	بخش ۳	بخش ۲	بخش ۱	بخش / بازه زمانی
(۳۰,۰,۳) ARMA	(۴۰,۰,۴) ARMA	(۵۰,۰,۵) ARMA	(۱۰,۰,۱) ARMA	(۵۰,۰,۴) ARMA	۲۴-۴
(۵,۱,۴) ARIMA	(۵,۰,۰,۵) ARMA	(۴۰,۰,۴) ARMA	(۳,۱,۴) ARIMA	(۴,۰,۰,۴) ARMA	۴-۸
(۵,۱,۵) ARIMA	(۳,۱,۵) ARIMA	(۵,۰,۰,۵) ARMA	(۴,۰,۰,۴) ARMA	(۱,۰,۰,۲) ARMA	۸-۱۲
(۵,۱,۵) ARIMA	(۳,۰,۰,۳) ARMA	(۳,۰,۱,۵) ARIMA	(۵,۰,۱,۳) ARIMA	(۳,۰,۰,۴) ARMA	۱۲-۱۶
(۴,۱,۵) ARIMA	(۵,۱,۰,۴) ARIMA	(۲,۰,۰,۴) ARMA	(۳,۰,۱,۵) ARIMA	(۵,۰,۰,۵) ARMA	۱۶-۲۰
(۵,۰,۱,۵) ARIMA	(۳,۰,۰,۳) ARMA	(۵,۰,۰,۴) ARMA	(۵,۰,۱,۴) ARIMA	(۴,۰,۰,۳) ARMA	۲۰-۲۴
(۳,۱,۱,۴) ARIMA	(۴,۰,۰,۴) ARMA	(۳,۰,۰,۴) ARMA	(۳,۰,۰,۴) ARIMA	(۴,۰,۰,۴) ARMA	۲۴-۸
(۵,۰,۱,۵) ARIMA	(۵,۰,۱,۰,۲) ARIMA	(۵,۰,۱,۰,۴) ARIMA	(۴,۰,۱,۰,۵) ARIMA	(۳,۰,۰,۵) ARMA	۸-۱۶
(۵,۰,۱,۵) ARIMA	(۳,۰,۱,۰,۲) ARIMA	(۴,۰,۰,۰,۴) ARMA	(۴,۰,۱,۰,۵) ARIMA	(۴,۰,۰,۰,۴) ARMA	۱۶-۲۴
(۰,۰,۰,۰,۲) ARIMA	(۰,۰,۰,۰,۳) ARIMA	(۳,۰,۰,۰) ARMA	(۳,۰,۰,۰,۰) ARMA	(۵,۰,۰,۰,۰) ARMA	۲۴-۱۲
(۴,۰,۱,۴) ARIMA	(۴,۰,۰,۰,۴) ARMA	(۵,۰,۱,۰,۵) ARIMA	(۴,۰,۱,۰,۵) ARIMA	(۵,۰,۰,۰,۵) ARMA	۱۲-۲۴
(۵,۰,۱,۵) ARIMA	(۴,۰,۱,۰,۳) ARIMA	(۴,۰,۱,۰,۵) ARIMA	(۵,۰,۱,۰,۴) ARIMA	(۳,۰,۰,۰,۳) ARMA	روزانه
(۵,۰,۱,۴) ARIMA	(۴,۰,۰,۰,۵) ARMA	(۳,۰,۰,۰,۴) ARIMA	(۵,۰,۱,۰,۲) ARMA	(۲,۰,۰,۰,۳) ARMA	هفتگی
(۱,۰,۰,۰,۲) ARIMA	(۱,۰,۰,۰,۵) ARIMA	(۵,۰,۰,۰,۳) ARMA	(۱,۰,۰,۰,۱) ARIMA	(۲,۰,۰,۰,۳) ARMA	ماهانه

منبع: یافته‌های تحقیق

در جدول (۴)، نتایج حاصله از پیش‌بینی مدل‌های خطی ARIMA و ARMA، با معیارهای جذر میانگین مجدد خط (RMSE) و متوسط میانگین خط (MAE)، نشان داده شده است. با توجه به این جدول، در می‌باییم که شاخص‌های خط در دوره‌های زمانی مختلف، در مقایسه با یکدیگر تفاوت بسیاری دارند. علت این تفاوت بسیار زیاد، به تفاوت زمانی آنها و همچنین تفاوت حجم مراجعه بیمارها در دوره‌های مختلف زمانی مربوط می‌شود. برای مثال، شش دوره چهار ساعته همراه با دوره‌های هشت ساعته، دوازده ساعته و روزانه در بخش‌های مختلف از نظر خطای پیش‌بینی تفاوت چندانی با هم ندارند اما با دوره‌های هفتگی و ماهانه تفاوت بسیاری دارند. به طور متوسط، چهار ساعت دوم از نظر خطای پیش‌بینی کمترین و دوره زمانی ماهانه از نظر خطای پیش‌بینی، بیشترین خط را

دارا می‌باشند. همچنین به طور متوسط مدل‌های تخمین زده شده بخش دوم دارای کمترین خطای پیش‌بینی و مدل‌های تخمین زده شده سوم دارای بیشترین خطای پیش‌بینی می‌باشند. کمترین خطای پیش‌بینی، به تفکیک بخش و دوره زمانی مربوط به بخش دوم با دوره زمانی هشت ساعت اول و بیشترین خطای حاصله مربوط به بخش سوم با دوره زمانی ماهانه می‌باشد.

**جدول ۵: خطای پیش‌بینی مدل خطی ARIMA و ARIMA به تفکیک بخش‌های بیمارستان**

بخش ۵		بخش ۴		بخش ۳		بخش ۲		بخش ۱		بخش	
MAE	RMSE	بازه زمانی / خطای پیش‌بینی									
۱/۰۶	۱/۲۶	.۰/۸۶	۱/۱۲	۱/۲	۱/۳۶	---	---	.۰/۶	۰/۹۲	۲۴-۴	
.۰/۹۳	۱/۰۳	.۰/۹۳	۱/۰۹	.۰/۶	۰/۷۷	.۰/۳۳	.۰/۵۷	---	---	۴-۸	
۱/۴	۱/۷۷	۲/۹۳	۴/۰۸	۲/۸	۳/۴۵	۳	۳/۴۷	۱/۳۳	۱/۵۲	۸-۱۲	
.۰/۳۳	.۰/۸۵	۳/۴	۷/۹۶	۲/۱۳	۲/۷۳	۱/۶۶	۲/۰۵	۱	۱/۲۸	۱۲-۱۶	
.۰/۴۶	۱/۱۲	۲/۲	۲/۸۸	۱/۰۶	۱/۵۵	۱/۶۶	۱/۲۶	۱/۲۶	۱/۵۲	۱۶-۲۰	
.۰/۸	۱/۰۲	۲/۰۶	۲/۴۹	۱/۲	۱/۶۳	---	---	.۰/۹۳	۱/۳۱	۲۰-۲۴	
۱/۳۳	۱/۵	۱/۳۳	۱/۸۲	۱/۶	۱/۸۶	.۰/۳۳	.	.۰/۸	.۰/۹۶	۲۴-۸	
۱/۲۶	۱/۰۲	۵/۶۶	۸/۸	۴	۴/۹۲	۴/۳۳	۵/۲۹	۱/۲۶	۱/۷۷	۸-۱۶	
۱/۰۶	۱/۵۲	۳/۴۶	۳/۹۸	۲/۱۳	۲/۱۹	۱/۰۶	۱/۲۶	۱/۵	۱/۷۷	۱۶-۲۴	
۱/۶۶	۱/۹۸	۳/۶۶	۴/۲۲	۳/۱۳	۴/۰۲	۳/۴۶	۳/۹۸	۱/۳۳	۱/۵۲	۲۴-۱۲	
۱/۳	۱/۹	۵/۴	۸/۶۳	۴/۲۶	۵/۲	۲/۰۶	۲/۶۷	۲/۵۳	۲/۸۷	۱۲-۲۴	
۲/۲	۲/۸۴	۷/۶	۹/۵۲	۵/۲	۶/۴	۴/۷۳	۲/۶۷	۲/۶۶	۳/۰۳	روزانه	
۸	۱۲/۱۹	۴۰/۱۳	۴۷/۵۷	۳۸	۴۲/۲	۱۹	۱۹/۱۲	۸/۳۳	۹/۱۸	هفتگی	
۱۳۲	۱۴۱/۸	۴۸	۵۶/۶	۱۲۴	۱۴۸/۶	۱۷	۲۲/۶۷	۱۴/۵	۱۷/۹	ماهانه	

منبع: یافته‌های تحقیق

جدول (۶) نیز، نتایج حاصله از پیش‌بینی مدل غیرخطی شبکه عصبی با الگوریتم MLP، با معیارهای جذر میانگین مجذور خطا (RMSE)<sup>۱</sup> و متوسط میانگین خطا (MAE) را نشان می‌دهد. با کمی دقت در این جدول متوجه می‌شویم که خطاهای پیش‌بینی در روش شبکه عصبی، تفاوت چندانی با یکدیگر ندارند و علت آن را می‌توان در غیرخطی بودن این روش جستجو نمود به طور متوسط، چهار ساعت دوم از نظر خطای پیش‌بینی، کمترین دوره زمانی ماهانه از نظر خطای پیش‌بینی، بیشترین خطای دارای می‌باشند. همچنین به طور متوسط مدل‌های تخمین زده شده در بخش دوم دارای کمترین خطای پیش‌بینی و مدل‌های تخمین زده شده در بخش چهارم دارای بیشترین خطای پیش‌بینی می‌باشند. کمترین خطای پیش‌بینی، به تفکیک بخش و دوره زمانی مربوط به بخش دوم با دوره زمانی هشت ساعت اول و بیشترین خطای حاصله مربوط به بخش چهارم با دوره زمانی هفتگی می‌شود. جهت

1. Root Mean Square Error

بررسی قدرت عملکرد مدل شبکه عصبی با الگوریتم MLP و مدل ARIMA، متوسط خطاهای پیش‌بینی با شاخص‌های RMSE و MAE را با یکدیگر مقایسه می‌کنیم. این مقایسه به تفکیک بخش‌های مختلف بیمارستان در جدول ۷ مشاهده می‌شود. بر طبق نتایج به دست آمده، متوسط خطای ARIMA به دست آمده در مدل شبکه عصبی به مراتب کمتر از متوسط خطای به دست آمده در مدل‌های ARIMA می‌باشد؛ البته در تخمین‌های بخش اول (کودکان و نوزادان)، متوسط خطای به دست آمده از مدل ARIMA کمتر از مدل شبکه عصبی می‌باشد که این امر ممکن است به علت واریانس کمتر داده‌های این بخش باشد (جدول ۸)؛ به نوعی می‌توان استنباط نمود که هر چقدر انحراف داده‌ها از میانگین آنها کمتر باشد و پراکنش داده‌ها حول میانگین نسبتاً ثابت باشد، مدل خطی در امر پیش‌بینی نسبت به مدل غیرخطی کاراتر عمل می‌نماید، نمودار شماره ۲، نیز در راستای پشتیبانی از این استنباط ترسیم شده است. همان‌طوری که مشاهده می‌شود، پراکنش داده‌ها در بخش ۱ نسبت به سایر بخش‌ها باثبات‌تر می‌باشد. همه‌ی مدل‌های برآورده شده به تفکیک دوره زمانی در بخش اول به صورت مدل‌های ARMA بوده‌اند، به عبارت بهتر، داده‌های بخش اول مانا بوده که بیان‌کننده میانگین ثابت و نیز واریانس ثابت (و غیروابسته به زمان) بوده که این امر، علت کاهش خطای مدل‌های خطی ARMA نسبت به مدل‌های غیرخطی شبکه‌های عصبی می‌باشد. بنابراین می‌توان بیان کرد که به‌طورکلی مدل شبکه عصبی با الگوریتم MLP، به مراتب دارای قدرت بیشتری نسبت به مدل‌های خطی ARIMA و ARMA در پیش‌بینی تقاضای درمان بیمارستان موردمطالعه می‌باشد. همچنین در صورت پراکندگی کمتر داده‌ها، ممکن است مدل‌های خطی نتیجه بهتری نسبت به مدل‌های غیرخطی داشته باشند. کمترین خطای متوسط مربوط به تخمین‌های بخش ۱ می‌باشد و بیشترین خطای متوسط در بین بخش‌های پنج‌گانه بیمارستان، مربوط به بخش اورژانس است که علت آن به حجم بیشتر داده‌های این بخش و واریانس بالای آن دانست.

جدول ۶: خطای پیش‌بینی مدل غیرخطی شبکه عصبی با الگوریتم MLP به تفکیک بخش‌های بیمارستان

بخش ۵		بخش ۴		بخش ۳		بخش ۲		بخش ۱		بخش
MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	بازه زمانی / خطای پیش‌بینی
۱/۴۶	۲/۱۹	۱/۲۶	۱/۷۶	۱/۲	۱/۷۱	----	----	۰/۶	۰/۹۲	۲۴-۴
۱/۲۶	۱/۵۶	۱	۱/۲۳	۰/۹۳	۱/۲	۰/۴۶	۰/۶۷	----	----	۴-۸
۱/۵۳	۱/۹	۵/۵۳	۶/۹	۲/۹۳	۳/۵۷	۳/۵۳	۴/۷۳	۲/۷۳	۳/۰۹	۸-۱۲
۰/۴	۰/۹	۴/۲	۸/۲	۲/۸	۳/۵۷	۲/۰۶	۳/۵	۱/۴	۱/۶۹	۱۲-۱۶
۰/۶۶	۱/۲۶	۲/۶	۳/۰۴	۲/۶	۳/۲۵	۱/۴۶	۱/۷۱	۱/۷۳	۲/۷۸	۱۶-۲۰
۰/۴۶	۰/۸۵	۲/۲۶	۲/۹۲	۱/۴۶	۱/۷۸	----	----	۱	۱/۲۸	۲۰-۲۴
۲/۲	۲/۸۵	۲	۲/۴۷	۲/۱۳	۲/۶۵	۰/۲۶	۰/۵	۱/۱۳	۱/۸۴	۲۴-۸
۲/۱۳	۲/۷۸	۵	۸/۶	۳/۵۳	۴/۷	۳	۳/۷۶	۲/۶	۳/۲۵	۸-۱۶
۱	۱/۴۳	۳/۰۶	۳/۸۲	۲/۴	۲/۸۲	۱/۴	۱/۷۷	۲/۲۶	۲/۵	۱۶-۲۴
۱/۳۳	۱/۹	۳/۲۶	۴/۲۸	۵/۶۶	۶/۶۱	۲/۷۳	۳/۰۸	۱/۵۳	۲/۰۱	۲۴-۱۲
۱/۵۳	۲/۴۳	۶/۲	۷/۶۴	۳/۸۶	۴/۹۵	۳/۲۶	۳/۹۹	۳/۶	۴/۶۶	۱۲-۲۴
۴/۲	۵/۶	۷/۵۳	۱۰/۴	۸	۱۰/۹۱	۵/۳	۶/۷۱	۵/۲	۶/۱۳	روزانه
۶/۶۶	۹/۹	۲۳	۲۴/۵۵	۱۶	۱۷/۹	۷/۲۱	۸/۴۸	۴/۹	۴/۹	هفتگی
۲۳	۲۳/۱۹	۱۸/۵	۲۶/۱۶	۱۱/۵	۱۳/۷	۷/۵۳	۸	۱۷/۲	۲۳/۷	ماهانه

منبع: یافته‌های تحقیق

جدول ۷: متوسط خطای پیش‌بینی MAE و RMSE در مدل‌های ANN و ARIMA

بخش ۵		بخش ۴		بخش ۳		بخش ۲		بخش ۱		بخش
RMSE										
ANN	ARIMA									
۴/۱۹	۱۲/۳	۷/۹۹	۱۱/۴۸	۵/۶۷	۱۶/۲۲	۳/۹	۵/۴۱	۴/۴۸	۳/۱۲	
MAE										
ANN	ARIMA									
۳/۴۱	۱۰/۹۷	۶/۱	۹/۱۳	۴/۶۴	۱۳/۸۸	۳/۱۸	۴/۸۳	۳/۵۳	۲/۷۱	

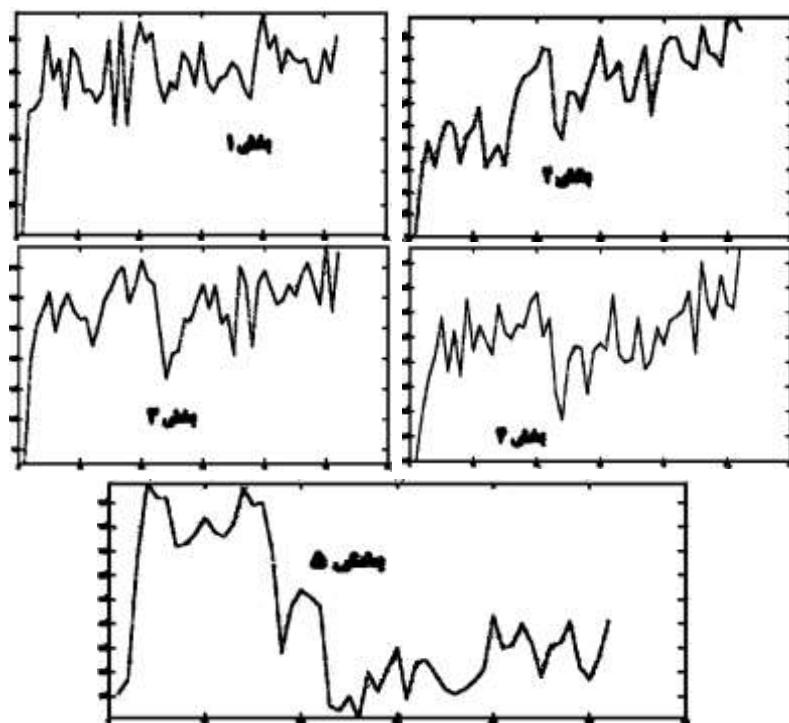
منبع: یافته‌های تحقیق

جدول ۸: واریانس و نوع توزیع داده‌های بیمارستان به تفکیک بخش‌های مختلف

نوع توزیع سری	واریانس	بخش‌های بیمارستان
توزیع نرمال	۳/۵۰	بخش ۱
توزیع غیر نرمال	۴/۷۸	بخش ۲
توزیع نرمال	۶/۲۲	بخش ۳
توزیع غیر نرمال	۹/۰۷	بخش ۴
توزیع غیر نرمال	۵/۴۴	بخش ۵

منبع: یافته‌های تحقیق

نمودار ۲: پراکنش داده‌های بیمارستانی به تفکیک بخش‌های مختلف



با توجه به شاخص‌های خطا و مقایسه داده‌های پیش‌بینی شده با داده‌های اصلی، می‌توان درصد خطای پیش‌بینی را به تفکیک هر بخش و در دوره‌های زمانی مشخص به دست آورد. در جدول (۹) درصدهای خطا به تفکیک بخش‌ها و دوره‌های زمانی مشاهده می‌شود. بیشترین درصد خطای حاصله در بخش پنجم و دوره زمانی ماهانه حدود ۱۱۶٪ و کمترین درصد خطای حاصله مربوط به بخش دوم، دوره زمانی ماهانه حدود ۱۰٪ می‌باشد. همچنین بیشترین درصد خطای مربوط به تخمین‌های مدل ARIMA و کمترین درصد خطای مربوط به مدل شبکه عصبی MLP است.

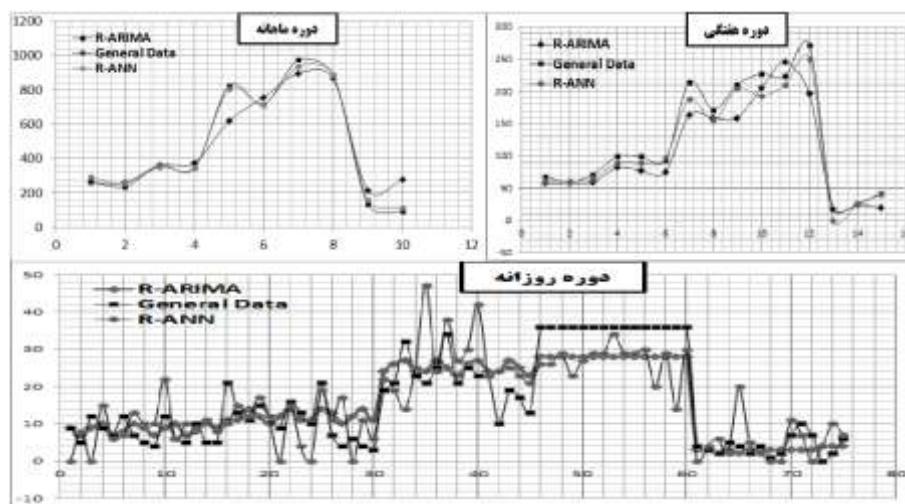
جدول ۹: متوسط درصد خطای پیش‌بینی به تفکیک بخش‌ها و روش‌های پیش‌بینی

بخش‌های بیمارستان	ARIMA	ANN
بخش ۱	۲۸/۵۵	۳۲/۴
بخش ۲	۲۴/۵۷	۲۱/۹
بخش ۳	۲۰/۲۷	۱۶/۹۴
بخش ۴	۱۴/۷۴	۱۱/۷۳
بخش ۵	۴۵/۵۵	۴۱/۸۴
متوسط درصد کل	۲۶/۷۳	۲۴/۹۶

منبع: یافته‌های تحقیق

برای ارائه یک نمای کلی‌تر و مقایسه درصدهای خطای بخش‌ها و مدل‌های بکار رفته در این مطالعه، متوسط درصد خطای پیش‌بینی‌های صورت گرفته به تفکیک بخش و مدل بکار رفته در جدول (۸) مشاهده می‌شود. در بین متوسط خطای پیش‌بینی مدل شبکه عصبی، بخش اورژانس با بالاترین واریانس در داده‌ها ( $9/07\%$ )، دارای کمترین متوسط خطای پیش‌بینی ( $11/73\%$ ) می‌باشد که نشان‌دهنده قدرت بالای پیش‌بینی این مدل در محیط‌های پر نوسان می‌باشد. بیشترین خطای متوسط نیز مربوط به مدل ARIMA در بخش پنجم است ( $45/55\%$ ). در نهایت با توجه به متوسط درصد کل پیش‌بینی‌ها، مدل شبکه عصبی MLP با  $24/96\%$  نسبت به مدل ARIMA با متوسط خطای کل  $26/73\%$ ، دارای قدرت پیش‌بینی بالای می‌باشد. در ادامه، برای مقایسه قدرت پیش‌بینی روش‌های مورد استفاده در این مطالعه، نمودارهای (۳)، تمام بخش‌های بیمارستان را به تفکیک دوره‌های زمانی مختلف و به صورت مقایسه داده‌های واقعی با داده‌های پیش‌بینی شده مدل‌های ARIMA و شبکه عصبی MLP نشان می‌دهند. همان‌طوری که در این نمودارها مشاهده می‌شود، داده‌های پیش‌بینی شده به روش شبکه عصبی MLP، نتایج قابل قبول‌تری نسبت به داده‌های پیش‌بینی شده به وسیله روش ARIMA به دست می‌دهد.

**نمودار ۳: نتایج پیش‌بینی و مقایسه داده‌های اصلی بخش‌های پنج گانه با پیش‌بینی مدل‌های ARIMA و شبکه عصبی**

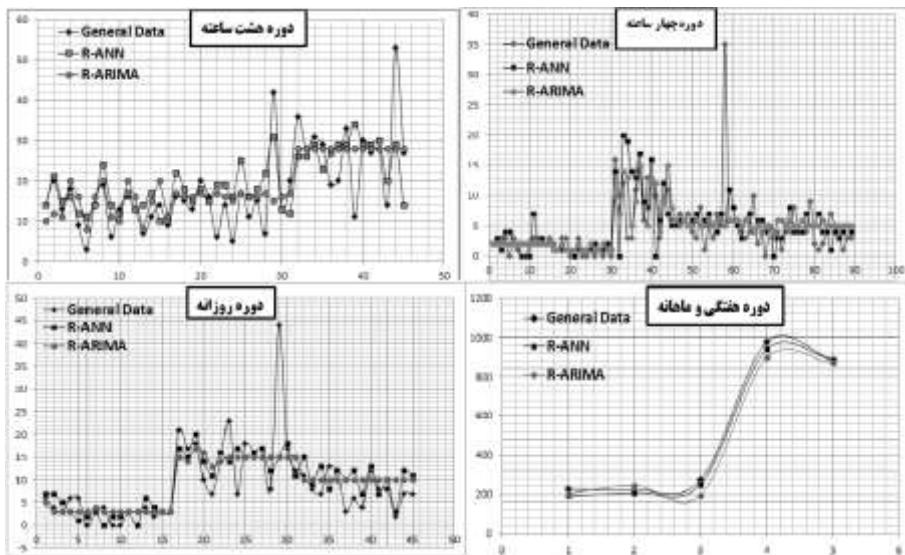


#### ۱-۷. بررسی نتایج پیش‌بینی در بخش اورژانس

بخش اورژانس به دلیل کارکرد ویژه‌اش در بیمارستان همواره دارای بیشترین مراجعه بیماران سرپایی و بیماران اورژانسی می‌باشد، به همین دلیل اطلاع از تقاضای درمان آینده در این بخش از اهمیت بالایی نسبت به دیگر بخش‌های بیمارستان برخوردار است. همچنین ساماندهی مناسب بخش اورژانس می‌تواند

رضایت پرسنل بیمارستان و بخش بزرگی از متخصصیان درمان را به همراه داشته باشد. در نهایت، کارکرد مناسب بخش اورژانس می‌تواند در کارکرد مناسب بخش‌های دیگر بیمارستان نقش بسزایی داشته باشد. با توجه به اهمیت بخش اورژانس در سیستم سلامت یک جامعه، در این بخش به بررسی نتایج بهدست آمده در بخش اورژانس می‌پردازیم. طبق نتایج بهدست آمده از پیش‌بینی‌های مدل‌های ARIMA و شبکه عصبی در بخش اورژانس و با توجه به خطاها حاصله در این پیش‌بینی‌ها، مشاهده می‌شود که مدل شبکه عصبی MLP از قدرت پیش‌بینی بسیار بالایی نسبت به مدل خطی ARIMA برخوردار است، به طوری که در خطای RMSE، استفاده از شبکه عصبی، خطای پیش‌بینی را به اندازه  $4/30\%$  و در خطای MAE به اندازه  $18/33\%$  بهبود بخشیده است؛ علت این موضوع می‌تواند در پراکندگی بالای داده‌های بخش اورژانس نهفته باشد، با توجه به نمودارهای (۴) و مشاهده روند پر نوسان داده‌های واقعی در آن‌ها، صحت دلیل برتری مدل‌های غیرخطی در برابر مدل‌های خطی را نمی‌توان رد نمود. از طرف دیگر، مدل‌های غیرخطی در مقایسه با مدل‌های خطی قادر به تخمین موارد غیرخطی متعدد در داده‌ها بوده و یک چارچوب محاسبه‌ای انعطاف‌پذیر برای دامنه وسیعی از مسائل غیرخطی می‌باشند، مقایسه روند داده‌های واقعی با داده‌های پیش‌بینی شده بخش اورژانس، با استفاده از مدل‌های ARIMA و شبکه عصبی MLP، در نمودارهای (۴)، به خوبی نشان می‌دهد که شبکه‌های عصبی پیش‌بینی‌های بسیار بهتری را در مقایسه با روش خطی ARIMA به دست می‌دهد.

**نمودار ۴: نتایج پیش‌بینی و مقایسه داده‌های اصلی بخش اورژانس با داده‌های پیش‌بینی مدل‌های ARIMA و شبکه عصبی**



### نتیجه‌گیری

مهمنترین هدف این مطالعه، معرفی یک مدل پیش‌بینی مناسب برای برآورد تقاضای درمان در بیمارستان مورد مطالعه می‌باشد، مدل شبکه عصبی MLP، به عنوان یک مدل غیرخطی، با متوسط خطای پیش‌بینی ۲۵٪ در کل بخش‌ها و حدود ۱۲٪ در بخش اورژانس، می‌تواند یک مدل مناسب و ایده‌آل پیش‌بینی برای بیمارستان مذکور باشد. همچنین طبقه‌بندی و بررسی داده‌های بیمارستان به صورت جداول و نمودارها، بر حسب بازه‌های زمانی به تفکیک بخش‌های مختلف بیمارستان می‌تواند در جهت رسیدن به بینش کلی از وضعیت تقاضای درمان بیمارستانی، بسیار سودمند بنماید. همچنین نتایج پیش‌بینی‌های بخش ۱، نشان می‌دهد که مدل خطی ARMA دارای قدرت پیش‌بینی بالاتری نسبت به مدل غیرخطی شبکه عصبی MLP می‌باشد که دلیل این ناسازگاری با فرضیه‌های تحقیق را می‌توان در واریانس پایین داده‌های این بخش جستجو کرد. بنابراین می‌توان بیان کرد که در صورت پراکندگی کمتر داده‌ها، ممکن است مدل‌های خطی نتیجه بهتری نسبت به مدل‌های غیرخطی داشته باشند. اما در حالت کلی مدل شبکه عصبی با الگوریتم MLP، به مراتب دارای قدرت بیشتری نسبت به مدل‌های خطی ARMA و ARIMA در پیش‌بینی تقاضای درمان بیمارستان موردمطالعه می‌باشد.

در نهایت با توجه به اهمیت بخش اورژانس در سیستم سلامت یک جامعه، به بررسی نتایج به دست آمده در بخش اورژانس پرداخته‌ایم. طبق نتایج به دست آمده از پیش‌بینی‌های ARIMA و شبکه عصبی در بخش اورژانس و با توجه به خطاهای حاصله در این پیش‌بینی‌ها، مشاهده شد که مدل شبکه عصبی MLP از قدرت پیش‌بینی بسیار بالایی نسبت به مدل خطی ARIMA برخوردار است، به طوری که در خطای RMSE استفاده از شبکه عصبی، خطای پیش‌بینی را به اندازه ۳۰/۴٪ و در خطای MAE به اندازه ۱۸/۳٪ بهبود بخشیده است؛ علت این موضوع می‌تواند در پراکندگی بالای داده‌های بخش اورژانس نهفته باشد، همچنین به عنوان شاخص دیگری جهت مقایسه قدرت پیش‌بینی مدل‌ها، مدل شبکه عصبی MLP با متوسط درصد خطای ۹۶/۲۶٪ نسبت به مدل ARIMA با متوسط درصد خطای کل ۷۳/۲۶٪، دارای قدرت پیش‌بینی بالایی می‌باشد. اما با همه این اوصاف، یک بیمارستان به عنوان یک بنگاه عام‌المنفعه، برای رسیدن به شرایط مناسب در جهت تصمیم‌گیری‌های علمی بر اساس خروجی‌های این نوع از سیستم‌های پیش‌بینی، باید یک برنامه منسجم و یک سیستم انعطاف‌پذیر را در رأس امور خود قرار دهد و مهمترین جنبه این سیستم، تصمیم‌گیری مدیران آن بر پایه اطلاعات علمی و همچنین تولید این اطلاعات توسط واحدهای تعریف شده در این سیستم می‌باشد.

اقدامات اولیه برای بیمارستان مورد مطالعه در جهت رسیدن به یک سیستم کارآمد که جنبه‌های مدیریت نوین را در برگیرد می‌تواند شامل موارد زیر باشد: تجهیز واحد مدارک پزشکی بیمارستان

مذکور به مدل پیش‌بینی شبکه عصبی MLP و گستردگی کردن بسته‌های آموزشی آن و استفاده از مدل‌های خطی در داده‌هایی که واریانس بسیار پایین‌تری دارند؛ ایجاد واحد جدیدی با عنوان واحد اقتصاد سلامت در بیمارستان امام رضا(ع) ارومیه و تجزیه و تحلیل نتایج پیش‌بینی‌ها در این واحد و همچنین ارائه راهکارها و پیشنهاد سیاست‌گذاری‌های مدیریتی؛ استفاده از مطالعات مکمل برای ارائه افق تصمیم‌گیری مدیریتی در سطح مدیریت بخش‌ها و مدیریت بیمارستان در رابطه با پرسنل بیمارستان و متقدضیان درمان؛ بالا بردن تکنولوژی نرم‌افزاری در واحد مدارک پزشکی؛ آموزش کارکنان واحد مدارک پزشکی جهت کار با نرم‌افزارهای تخصصی به ویژه در مبحث اقتصادسنجی و پیش‌بینی متغیرها؛ به کارگیری بهینه‌ی پرسنل بیمارستان به ویژه در زمان‌های پیک تقاضای بستری؛ توسعه عمرانی و ساخت افزاری متناسب بیمارستان همگام با ارائه پیش‌بینی‌های سالانه و روند تغییرات تقاضای درمان در بخش‌های مختلف بیمارستان؛ ایجاد پایگاه داده‌ای توسط واحد مدارک پزشکی و همچنین پر کردن خلاً اطلاعاتی به ویژه در بخش‌های مراقبت‌های ویژه مانند: ICU، ...؛ ایجاد تناسب بین دوره‌های زمانی پیش‌بینی‌ها با شیفت‌های کاری پرستاران و پزشکان؛ تعریف برنامه‌های کوتاه‌مدت، میان‌مدت و بلندمدت بر اساس اطلاعات و تحقیقات علمی و همچنین سنجهش بازدهی برنامه‌ها؛ ایجاد هماهنگی‌های لازم بین مدیران، کارکنان، پرستاران و پزشکان جهت کاربردی کردن نتایج پیش‌بینی‌ها به ویژه در بازه‌های زمانی کوتاه‌تر؛ بسط و گسترش این نوع تحقیقات در حوزه پیش‌بینی تعداد متقدضیان درمان بر حسب نوع بیماری جهت برآورد امکانات لازم برای پاسخگویی سریع‌تر و خدمات بهتر؛ استفاده از این نوع پیش‌بینی‌ها به خصوص در بخش تقاضای دارو و تجهیزات پزشکی پر مصرف و در نهایت، انجام مطالعات مشابه در دیگر بیمارستان‌ها جهت اتخاذ سیاست‌گذاری‌های کلان وزارت بهداشت با شناخت تقاضای درمان آینده‌ی شهرستان‌ها و استان‌ها. این نوع تحقیقات با توجه به رشد روز افرون نیازهای بشری، جهت دسترسی به امکانات بهداشتی و درمانی و منابع محدود در اختیار بخش سلامت جامعه، ضروری می‌باشد. بسط و گسترش علم اقتصاد سلامت و وارد شدن آن به عنوان واحدی مهم در بیمارستان‌ها و انتخاب مدیرانی با درک اقتصادی می‌تواند در پاسخگویی به این نیازها، به صورت بسیار بهینه عمل نماید.

## منابع

- آقایی، کیومرث و پورمیری، بهروز (۱۳۸۵): پیش‌بینی روند قیمت فولاد با استفاده از شبکه‌های عصبی مصنوعی و مقایسه نتایج آن با روش آریما، *فصلنامه بررسی‌های اقتصادی*، دوره ۳، شماره ۱: ۴-۵.
- آین‌نامه نحوه تأسیس و اداره بیمارستان‌ها، شماره نامه ۵۷۳۴، تاریخ ۱۳۷۶/۵/۲۱.
- ابریشمی، حمید؛ جبل عاملی، فرخنده؛ ابوالحسنی، معصومه و جوان، افشین (۱۳۹۳): عملکرد دو روش ARIMA و شبکه عصبی GMDH در پیش‌بینی تقاضای گاز طبیعی در بخش‌های مختلف (ایران-۱۳۸۹-۱۳۸۰)، *فصلنامه مطالعات اقتصادی کاربردی ایران*، سال سوم، شماره ۱۲: ۳۳-۵۷.
- جعفرنژاد، احمد و محسن سلیمانی (۱۳۹۰): پیش‌بینی تقاضای تجهیزات پزشکی بر اساس شبکه‌های عصبی مصنوعی و روش ARIMA، *فصلنامه پژوهش‌ها و سیاست‌های اقتصادی*، سال نوزدهم، شماره ۵۷: ۳-۴.
- فیاض‌بخش، احمد (۱۳۸۹): بررسی آگاهی و نگرش مدیران ارشد و میانی در امکان استفاده از مدیریت کیفیت فرآگیر در بیمارستان، *مجله تحقیقات سلامت*، شماره ۳: ۵-۸.
- قاسمی، عبدالرسول؛ اسد پور، حسن و شاصادقی، مختار (۱۳۷۹): کاربرد شبکه عصبی در پیش‌بینی سری‌های زمانی و مقایسه آن با مدل آریما، *پژوهشنامه بازرگانی*، ۲۰: ۱۴-۸۷.
- گزارش نهایی چهل و هشتمنی اجلاس رؤسای دانشگاه‌ها، دانشکده‌های علوم پزشکی و خدمات بهداشتی درمانی کشور. سیمای فرهنگ، ۱۳۸۲.
- Abraham, B. and Ledolter, J. (1986); Forecast functions implied by autoregressive integrated moving average models and other related forecast procedures. *International Statistical Review/ Revue Internationale de Statistique*, 51-66.
- Aburto, L. and Weber, R. (2007); Improved supply chain management based on hybrid demand forecasts. *Applied Soft Computing*, 7(1), 136-144.
- Armstrong, J. S. (2001); *Principles of forecasting: a handbook for researchers and practitioners* (Vol. 30): Springer Science & Business Media.
- Atiya, A. F. (2001); Bankruptcy prediction for credit risk using neural networks: A survey and new results. *Neural Networks, IEEE Transactions on*, 12(4), 929-935.
- Bosarge, W. (1993); Adaptive processes to exploit the nonlinear structure of financial markets. *Neural Networks in Finance and Investing*. Probes Publishing, 371-402.
- Fausett, L. V., & Hall, P. (1994); *Fundamentals of neural networks: architectures, algorithms, and applications* (Vol. 40): Prentice-Hall Englewood Cliffs.
- Flores, J. J., Graff, M., & Rodriguez, H. (2012); Evolutive design of ARMA and ANN models for time series forecasting. *Renewable Energy*, 44, 225-230.
- Garcia, K. A. (2011); Using a Randomized Regression Approach to Estimate Hospital Admissions to Reduce Emergency Department Holding. Citeseer.
- Hæke, C. and Helmenstein, C. (1996); Neural networks in the capital markets: An application to index forecasting. *Computational Economics*, 9(1), 37-50.
- Hill, T.; Marquez, L.; O'Connor, M. and Remus, W. (1994); Artificial neural network models for forecasting and decision making. *International Journal of Forecasting*, 10(1), 5-15.
- Hobbs, B. F., Helman, U., Jitprapaikulsarn, S., Konda, S. and Maratukulam, D. (1998); Artificial neural networks for short-term energy forecasting: Accuracy and economic value. *Neurocomputing*, 23(1), 71-84.

- Huang, W.; Lai, K. K.; Nakamori, Y. and Wang, S. (2004); Forecasting foreign exchange rates with artificial neural networks: a review. *International Journal of Information Technology & Decision Making*, 3(01), 145-165.
- Isaaks, E. H. and Srivastava, R. M. (1989); An introduction to applied geostatistics.
- Kohzadi, N., Boyd, M. S., Kaastra, I., Kermanshahi, B. S. and Scuse, D. (1995); Neural networks for forecasting: an introduction. *Canadian Journal of Agricultural Economics/Revue canadienne d'agroéconomie*, 43(3), 463-474.
- Kuan, C. M., and White, H. (1994); Artificial neural networks: an econometric perspective\*. *Econometric Reviews*, 13(1), 1-91.
- Kuo, R. (2001); A sales forecasting system based on fuzzy neural network with initial weights generated by genetic algorithm. *European Journal of Operational Research*, 129(3), 496-517.
- Kuo, R. J.; Wu, P. and Wang, C. (2002); An intelligent sales forecasting system through integration of artificial neural networks and fuzzy neural networks with fuzzy weight elimination. *Neural networks*, 15(7), 909-925.
- Law, R. and Au, N. (1999); A neural network model to forecast Japanese demand for travel to Hong Kong. *Tourism Management*, 20(1), 89-97.
- Ledolter, J. (1989); The effect of additive outliers on the forecasts from ARIMA models. *International Journal of Forecasting*, 5(2), 231-240.
- Lee, T. H.; White, H. and Granger, C. W. (1993); Testing for neglected nonlinearity in time series models: A comparison of neural network methods and alternative tests. *Journal of Econometrics*, 56(3), 269-290.
- Leegon, J.; Jones, I.; Lanaghan, K. and Aronsky, D. (2006); Predicting hospital admission in a pediatric emergency department using an artificial neural network. Paper presented at the AMIA Annual Symposium Proceedings.
- Li, J.; Guo, L. and Handly, N. (2009); Hospital admission prediction using pre-hospital variables. Paper presented at the Bioinformatics and Biomedicine, 2009. BIBM'09. IEEE International Conference on.
- Liu, Y.; Wang, D. and Ding, F. (2010); Least squares based iterative algorithms for identifying Box-Jenkins models with finite measurement data. *Digital Signal Processing*, 20(5), 1458-1467.
- Moshiri, S. and Cameron, N. E. (1999); Neural network versus econometric models in forecasting inflation. *Journal of forecasting*, 19.
- Moshiri, S.; Cameron, N. E. and Scuse, D. (1999); Static, dynamic, and hybrid neural networks in forecasting inflation. *Computational Economics*, 14(3), 219-235.
- Nelson, C. R. and Plosser, C. R. (1982); Trends and random walks in macroeconomic time series: some evidence and implications. *Journal of monetary economics*, 10(2), 139-162.
- Palmer, A.; Montano, J. J. and Sese, A. (2006); Designing an artificial neural network for forecasting tourism time series. *Tourism Management*, 27(5), 781-790.
- Porter, M. and Stern, S. (2001); Location matters. *Sloan Management Review*, 42(4), 28-36.
- Reddy, T. A. (2011); Applied data analysis and modeling for energy engineers and scientists: Springer Science & Business Media.

- Sermpinis, G.; Dunis, C.; Laws, J. and Stasinakis, C. (2012); Forecasting and trading the EUR/USD exchange rate with stochastic Neural Network combination and time-varying leverage. *Decision Support Systems*, 54(1), 316-329.
- Sözen, A.; Arcaklioğlu, E. and Özkanmak, M. (2005); Turkey's net energy consumption. *Applied Energy*, 81(2), 209-221.
- Tang, Z.; de Almeida, C. and Fishwick, P. A. (1991); Time series forecasting using neural networks vs. Box-Jenkins methodology. *Simulation*, 57(5), 303-310.
- Trippi, R. R. and Turban, E. (1992); *Neural Networks in Finance and Investing: Using Artificial Intelligence to Improve Real World Performance*: McGraw-Hill, Inc.
- Valipour, M.; Banihabib, M. E. and Behbahani, S. M. R. (2013); Comparison of the ARMA, ARIMA, and the autoregressive artificial neural network models in forecasting the monthly inflow of Dez dam reservoir. *Journal of Hydrology*, 476, 433-441.
- White, H. (1988); Economic prediction using neural networks: The case of IBM daily stock returns. Paper presented at the Neural Networks, 1988, IEEE International Conference on.
- “MATLAB Tutorial”, <http://www.mathworks.com>.