



گزارش اولین دوره رقابت‌های هوش مصنوعی اصفهان (IAI 2023)

پیش بینی تقاضای دارو در همدان

دکتر رضا رمضانی*^۱، احمدرضا گلکارنور^۲، علیرضا اخوان صفائی^۳، حسین باهک^۴، پگاه صبوری^۵ و بهنام صوفی^۶

^۱دانشگاه اصفهان، R.ramezani@eng.ui.ac.ir

^۲دانشگاه اصفهان، Ahmadg77@live.com

^۳دانشگاه اصفهان، Alirezaakhavansafaei@gmail.com

^۴دانشگاه اصفهان، Hossein.bahak@gmail.com

^۵دانشگاه اصفهان، Pegahsaboori.1373147@gmail.com

^۶دانشگاه اصفهان، BehnamSoufi@eng.ui.ac.ir

*سرپرست تیم

چکیده - در زنجیره‌ی تأمین دارویی، موجودی انبار بزرگترین فاکتور در توزیع محصولات دارویی در مراکز درمان و داروخانه‌ها می‌باشد. بنابراین پیش‌بینی میزان تقاضای داروخانه امری اساسی است تا تعادل موثر میان عرضه و تقاضا در موجودی حفظ شود و همچنین هزینه‌ها کمینه شود. در این پژوهش، به بررسی چگونگی پیش‌بینی تقاضای یک داروی خاص در زنجیره‌ی تأمین دارویی پرداخته می‌شود. داده‌های مورد استفاده شامل تاریخچه درخواست تأمین موجودی یک داروی خاص از سمت ۱۲ داروخانه اصلی شهر همدان در طی سال‌های ۲۰۱۹ الی ۲۰۲۳ می‌باشد. در این راستا چالش‌های پیش‌پردازش داده‌های داروخانه، از جمله تمیزکاری داده، ساخت و انتخاب ویژگی‌ها، برچسب‌گذاری دوره کوید ۱۹ و... انجام شد. سپس به کمک ویژگی‌های تقویمی و اقلیمی توسعه یافته، بر روی مدل‌های مختلف یادگیری ماشین و شبکه‌های عصبی عمیق برای پیش‌بینی تقاضای دارویی در بیمارستان آزمایش انجام شد، در نهایت چهار مدل شاخص ارائه شد که از بین آن‌ها دو مدل نهایی برگزیده شد و یک مدل رأی دهنده بر اساس میانگین وزنی دو مدل برگزیده ایجاد شد که میزان تقاضای دارویی بیمارستان‌ها را پیش‌بینی کند سپس این مدل بر داده‌ی تست اعمال شد و نتایج آن ذخیره شد.

کلید واژه - LSTM، یادگیری ماشین، شبکه عصبی، یادگیری ژرف، سری زمانی، پیش‌بینی تقاضا

۱- مقدمه

موقع و با کیفیت تضمین شده موجود باشند. مدیریت ناکارآمد دارو می‌تواند به طور قابل توجهی بر اقتصاد و سلامت تأثیر بگذارد.

مدیریت موثر دارو می‌تواند با کاهش هدررفت و جلوگیری از هزینه‌های غیرضروری، منجر به صرفه‌جویی در هزینه برای نظام بهداشت و سلامت کشور شود. با این حال، مدیریت ناکافی دارو می‌تواند منجر به خطاهای دارویی، واکنش‌های دارویی ناخواسته و افزایش هزینه به دلیل زیاد یا کم بودن موجودی داروها شود. اگر مقدار دارویی که در یک بیمارستان یا داروخانه ذخیره شده است بیشتر از مقدار دارویی است که تجویز می‌شود، دارو ممکن است پیش از ارائه منقضی شود. این پیشامد ممکن است منجر به هزینه ناپایدار برای خرید و ذخیره‌سازی دارو شود و ممکن است عوارض منفی یا تهدیدکننده‌ی جان برای زندگی بیماران ایجاد کند.

زنجیره تأمین دارویی شامل تأمین‌کنندگان، توزیع‌کنندگان، داروخانه‌ها و مصرف‌کنندگان نهایی است. توزیع، پیوند بین تأمین‌کنندگان و داروخانه‌ها است. اگر دارویی در انبار نباشد، از توزیع‌کننده آن را تهیه می‌کند. در این سیستم، موجودی مهمترین دارایی جاری و نقدینگی در عمل توزیع دارو است و اهمیت آن به دلیل رشد تنوع و هزینه داروها رو به افزایش است. از نظر مالی و عملیاتی، مدیریت موثر موجودی نقش بزرگی در عمل توزیع دارو ایفا

تغییرات سریع در بازار سازمان‌ها را مجبور به تطبیق مداوم می‌کند. برای انطباق با این تغییرات، برنامه‌ریزی برای آنچه ممکن است رخ دهد، الزامی است. پیش‌بینی یک عنصر از علم داده است که به شرکت‌ها کمک می‌کند تا آماده‌باشند. یک شرکت که به سرعت به تقاضا واکنش نشان می‌دهد، احتمالاً موفق‌تر خواهد بود. یک کسب و کار با استفاده از پیش‌بینی‌ها می‌تواند بهتر به نیازهای مصرف‌کنندگان پاسخ دهد و تغییرات در تقاضای آن‌ها را پیش‌بینی کند. علاوه بر این، با تخمین سطح آینده تقاضا، شرکت می‌تواند برنامه‌ریزی کرده و ظرفیت و تجهیزات لازم را برای پاسخ سریع به تقاضاهای مشتریان رزرو کند.

برای هر کسب و کار، پیش‌بینی تقاضا در ماه‌های آینده برای حفظ موجودی مناسب امری ضروری است. به ویژه در حوزه کسب و کار داروهای دارویی و نظام سلامت و بهداشت، محدود کردن هدر رفت داروها به دلیل انقضاء آن‌ها امری حیاتی است. مدیریت موثر دارو یک جزء حیاتی از سیستم‌های بهداشت و سلامت است. داروها به عنوان بزرگترین جزء مصرف بودجه در خدمات داروخانه و بیمارستان شناخته می‌شوند. مدیریت دارو به دنبال اطمینان از این است که داروهای لازم همواره در هر زمانی که نیاز است، در نوع مناسب، به



می‌کند.

مدت زمان زیادی مسئله‌ی پیش‌بینی تقاضا متأثر از رویکردهای خطی کلاسیک مثل آریما^۱ بود. مدل آریما [۲] و مدل هولت-وینترز^۲ [۳-۴] دو نمونه از پر استفاده‌ترین رویکردهای خطی کلاسیک هستند. ساریما^۳ [۵] توسعه‌ی مدل آریما است که ویژگی‌های فصلی را نیز مدل می‌کند. مدل‌های تصادفی سری زمانی^۴ [۶] نیز، دارای قابلیت تفسیر مدل و کارایی محاسباتی هستند. با این حال این مدل‌ها فرض‌های ساده سازی زیادی در ارتباط مدل-سازي پیش‌بینی تقاضا انجام می‌دهند که در کاربردهای عملی چندان مناسب عمل نمی‌کنند. با وجود اینکه این مدل‌ها در مسائل سری زمانی شناخته شده تر هستند ولی الگوریتم‌های یادگیری ماشین نیز به عنوان روش‌های جایگزین ظاهر شده اند. الگوریتم‌هایی نظیر درخت تصمیم^۵، ماشین‌های بردار پشتیبان^۶، نزدیک‌ترین همسایه^۷ و... به خصوص در ارتباط با سری زمانی‌های چند متغیره خوب عمل می‌کنند. به طور مثال نشان داده شده است که مدل جنگل تصادفی^۸ در برخی مسائل بهتر از مدل ساریما عمل می‌کند [۷]. علاوه بر این، مدل رگرسیون مدولار به نام پروف^۹ از فیر^{۱۰} [۸] پارامترهای قابل تفسیری ارائه می‌دهد که می‌تواند به وسیله تحلیل‌گران با دانش حوزه‌ای از سری زمانی تنظیم شوند. اکس‌جی‌بوست^{۱۱} نیز نتایج قابل توجهی در مسائل پیش‌بینی ارائه داده است [۸].

شبکه‌های عصبی بازگشتی^{۱۲} و شبکه‌های عصبی با حافظه کوتاه و بلند مدت^{۱۳}، پس از رشد شبکه‌های عصبی در دهه‌ی اخیر، برای پیش‌بینی داده‌های سری زمانی مورد توجه و استقبال قرار گرفتند. به دلیل ویژگی‌های غیرخطی و غیرپایدار داده‌های این مسائل، از این مدل‌ها برای درک وابستگی‌های زمانی بلند مدت استفاده می‌شود. نتایج پژوهش‌های اخیر اغلب نشان می‌دهند که این مدل‌های شبکه عصبی اغلب از مدل‌های کلاسیک سری زمانی و الگوریتم‌های یادگیری ماشین پیشی گرفته‌اند [۹].

۳- مجموعه داده

داده‌های خام ارائه شده در این چالش شامل میزان تقاضای داروی ۱۲ داروخانه همدان از سال ۲۰۱۹ الی ۲۰۲۳ می‌باشد. این مجموعه داده در جدول ۱ نمایش داده شده است. همانطور که در جدول مشخص است این

جدول ۱: مجموعه داده‌ی در اختیار گذاشته شده

نوع داده	توضیحات	نام ویژگی
عدد صحیح (۱-۱۲)	شاخص فروشنده دارو	نام بیمارستان
عدد صحیح (۱-۷)	شاخص روزهای هفتگی	روز هفته
تاریخ میلادی	تاریخ تقاضای دارو	تاریخ مصرف
عدد	میزان سفارش دارو	تعداد مصرف

¹ ARIMA

² Holt-Winters

³ SARIMA

⁴ Stochastic time series

⁵ Decision Tree

⁶ SVM

⁷ KNN

⁸ Random Forest

⁹ Prophet

¹⁰ FAIR

¹¹ XGBoost

¹² RNN

¹³ LSTM

در حال حاضر، بیشتر تأمین‌کنندگان و توزیع‌کنندگان داروها، تقاضای آینده را به صورت دستی بر اساس تجربیات خود پیش‌بینی می‌کنند. با این حال، هوش مصنوعی و یادگیری ماشین می‌توانند با پیش‌بینی تقاضای داروها با استفاده از سوابق فروش گذشته نقش مهمی در اینجا ایفا کنند. محاسبات پیش‌بینی تقاضای داروها در آینده یک مسئله‌ی خطی نیست. بر اساس [۱]، سه دسته عامل تأثیرگذار بر استفاده آینده از داروها وجود دارند، به عبارت دیگر: عوامل اقتصادی-اجتماعی، عوامل شخصی‌سازی سلامت بیمار، و عوامل مربوط به مؤسسات بهداشتی و دسته پرسنل. توزیع‌کنندگان دارویی اصولاً بر اطلاعات تجربی خود برای برنامه‌ریزی و پیش‌بینی موجودی‌های خود اعتماد می‌کنند. این نوع داده‌ها ویژگی‌های خود را دارد که ممکن است فصلی باشد و تحت تأثیر وقایع ویژه و غیرمنتظره نظیر ویروس‌ها، قطع همکاری با اشخاص و شرکت‌ها، تأخیرهای تولیدکننده، تحریم و غیره قرار گیرد. اغلب چنین شرکت‌هایی پیش‌بینی‌هایی براساس میانگین‌های هفتگی یا ماهیانه تاریخی خود انجام می‌دهند. با این حال، با گذشت زمان و افزایش حجم داده، پیش‌بینی موثر موجودی‌های انبار و تقاضا با در نظر گرفتن روندهای کوتاه‌مدت و بلندمدت، عوامل داخلی و خارجی، و کشف الگوهای خرید داروهای خاص در زمانهای خاص سالانه مشکل است. تولید پیش‌بینی‌های خودکار و موثر یک مسئله آسان نیست. انگیزه اصلی این کار، حمایت از توزیع‌کنندگان است تا بهترین پیش‌بینی خرید محصولات توسط داروخانه‌هایشان برای هر یک از محصولات خود داشته باشند.

در این پژوهش داده‌های تاریخی تقاضای داروخانه‌های شهر همدان در بازه‌ی سال‌های ۲۰۱۹ الی ۲۰۲۳ برای یک محصول دارویی خاص تجزیه و تحلیل می‌شود، تا پس از استخراج ویژگی‌های کافی و غنی سازی دادگان، یک مدل مبتنی بر هوش مصنوعی برای پیش‌بینی نیاز دارویی ارائه شود. بخش‌های پیش روی این گزارش به صورت زیر است:

ادبیات پژوهش در بخش دوم ارائه می‌شود. در بخش سوم، در ارتباط با مجموعه داده و همچنین پیش‌پردازش داده، اکتشاف و انتخاب ویژگی‌ها توضیح داده می‌شود. در بخش چهارم، الگوریتم‌های مختلف بررسی و مدل‌های پیشنهادی در این پژوهش معرفی می‌شوند سپس آزمایش‌ها و عملکرد آنها در بخش پنجم توضیح داده می‌شود. در نهایت جمع بندی و نتیجه‌گیری در بخش ششم ارائه می‌شود.

۲- ادبیات پژوهش

در این بخش کارهای مرتبط برجسته‌ی پیشین مورد بررسی قرار داده می‌شوند. در پژوهش‌های نوین مسئله پیش‌بینی تقاضا به عنوان یک سری زمانی در نظر گرفته شده است و به کمک شبکه‌های عصبی حافظه‌دار برای حل آن اقدام شده است. سری‌های زمانی یکی از متداول‌ترین انواع داده‌ها در زندگی روزمره هستند. منظور از سری زمانی دنباله‌ای مرتب از رکوردها است که ارتباطات زمانی معنا داری با یکدیگر دارند. پیش‌بینی تقاضا یک حوزه عملی از مدل‌سازی و پیش‌بینی سری زمانی است. در مسئله پیش‌بینی تقاضای دارو، میزان تقاضا در هر روز یک رکورد و دنباله‌ی تقاضای دارو در روزهای متوالی به صورت دنباله‌ای از رکوردها، سری زمانی را تشکیل می‌دهد. لازم به ذکر است در برخی از پژوهش‌ها، رویکرد کلاسیک برای حل این مسئله در نظر گرفته شده و مسئله به صورت یک مسئله رگرسیونی ساده سازی می‌شود.



مشخص می‌شود. همچنین ویژگی‌های روز سال و روز ماه، شماره هر روز در به ترتیب سال جاری و ماه جاری را مشخص می‌کند. به عنوان سایر ویژگی‌هایی که می‌توانند بر تقاضا اثر گذار باشند، ویژگی‌های اقلیمی با الهام از [۹] به مجموعه‌ی داده افزوده شدند:

max_temp (دمای بیشترین روز) و min_tem (کمترین دمای روز) و temp (دمای متوسط روز): دما یکی از عوامل مهم در تعیین نیاز به داروها است. برای مثال، در روزهای بسیار گرم ممکن است نیاز به داروهای مرتبط با گرمزایی یا بیماری‌های جلوگیری‌ای افزایش یابد یا در روزهای سرد، تقاضا برای داروهای مرتبط با سرمازدگی یا بیماری‌های تنفسی افزایش می‌یابد. دمای میانگین همچنین به مدل اطلاعاتی ارائه می‌دهد که در تشخیص الگوهای مختلف تقاضا مفید است.

rh (رطوبت نسبی): این ویژگی نشان دهنده درصد رطوبت هوا است. رطوبت هوا نیز ممکن است بر برخی از بیماری‌ها یا شرایط حساسیت‌ها تأثیر گذار باشد. اطلاعات در مورد رطوبت می‌تواند به تفسیر بهتری از الگوهای تقاضا کمک کند.

precip (بارش): این ویژگی نشان دهنده میزان بارش در یک روز است. بارش ممکن است بر برخی از بیماری‌ها یا شرایط سلامتی تأثیر بگذارد. همچنین بر تصمیم عموم مردم مبنی بر مراجعه یا عدم مراجعه به مراکز درمانی مؤثر می‌باشد.

wind_spd (سرعت باد): این ویژگی نیز می‌تواند بر تصمیم عموم مردم مبنی بر مراجعه به مراکز درمانی اثر بگذارد.

solar_rad (تابش خورشید): تابش خورشید ممکن است بر سلامت و نیاز به برخی از داروها تأثیرگذار باشد. این اطلاعات می‌تواند به مدل در تشخیص الگوهای تقاضا کمک کنند.

جدول ۲: مجموعه داده‌های اصلی جهت ارائه به مدل

نام ویژگی	توضیحات	نوع داده
نام بیمارستان	شاخص فروشنده دارو	عدد صحیح
تاریخ مصرف	تاریخ تقاضای دارو	تاریخ میلادی
روز هفته	شاخص روزهای هفتگی	ابجکت
تعداد مصرف	میزان سفارش دارو	عدد
تعطیلات مدارس	تعطیلی = ۱ غیر تعطیلی = ۰	بولین
کرونا	کرونا = ۱، پیک = ۲، غیر کرونا = ۰	بولین
فصل سرما	سرما = ۱ و گرما = ۰	بولین
روز سال	روز سال از ابتدای سال	عدد
روز ماه	روز ماه از ابتدای ماه	عدد
Max_temp	دمای بیشینه روز	عدد
Min_temp	دمای کمینه روز	عدد
Temp	دمای میانگین روز	عدد
RH	رطوبت روز	عدد
Precip	بارش روز	عدد
Wind_spd	وزش باد روز	عدد
Solar_rad	تابش خورشید در روز	عدد
Snow	میزان برف	عدد

مجموعه‌ی داده تنها اطلاعاتی از میزان فروش هر بیمارستان در هر روز خاص در دسترس می‌گذارد. در ادامه در بخش ۳-۱ پیش پردازش مجموعه‌ی داده توضیح داده خواهد شد و در بخش ۳-۲ تحت عنوان غنی سازی مجموعه داده، به توضیح چگونگی گسترش و توسعه مجموعه داده و اکتشاف و انتخاب ویژگی‌های مناسب پرداخته می‌شود.

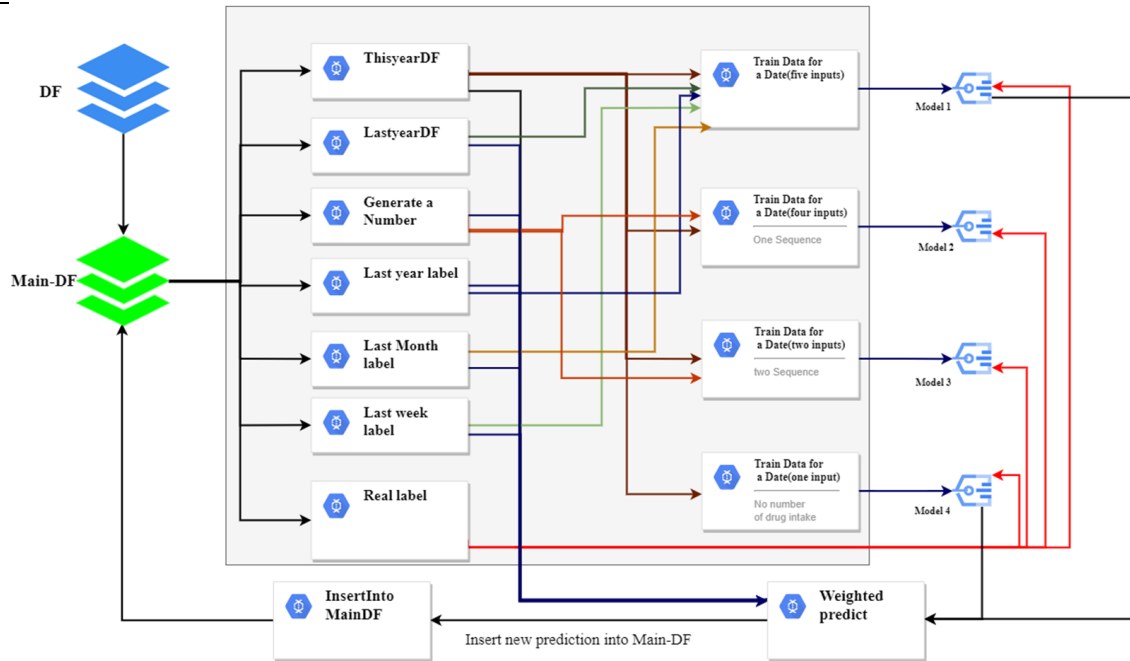
۳-۱- پیش پردازش

به منظور آماده‌سازی دیتاست نهایی برای استفاده در مدل هوش مصنوعی ارائه شده دو مرحله پیش پردازش بر روی دیتاست صورت می‌گیرد. در مرحله نخست دیتاست نویزگیری می‌شود و داده‌های پرت آن با مقدار بیشینه‌ای جایگزین می‌شوند. منظور از حذف داده‌های پرت، داده‌هایی است که به طور ناگهانی جهش قابل توجهی در سری زمانی ایجاد می‌کنند. به طور مثال بیمارستان ۱ به طور متوسط در یک بازه زمانی مشخص تعداد سفارش ۰ الی ۳۰۰ را به ازای هر روز ثبت می‌کند. اما ناگهان در یک روز مقدار سفارش آن ۱۲۰۰ ثبت شده است. جهت جلوگیری از گمراهی مدل این داده، داده پرت در نظر گرفته شد و با مقدار حد بالای سفارشات آن بیمارستان جایگزین شد. همچنین برخی بیمارستان‌ها در برخی روزها چندین سفارش ثبت کرده بودند که جهت جلوگیری از تکرار، تمامی سفارشات هر بیمارستان در هر روز حساب شدند و از تکرار جلوگیری شد. در ادامه، تمامی بیمارستان‌ها باید برای تمامی روزها از اول ۲۰۱۹ تا آخر ۲۰۲۲ یک ردیف داشته باشند و بدین ترتیب، اگر روزی برای یک بیمارستان تعریف نشده بود، آن روز با مقدار مصرف برابر با صفر پر می‌شود. در مرحله دیگر پس از غنی سازی مجموعه داده و اکتشاف ویژگی، ویژگی‌های عددی نرمال‌سازی شدند. هدف از نرمال‌سازی این است که کلیه ویژگی‌ها در بازه‌ی یکسانی قرار بگیرند و مدل‌ها بر حسب مقدارشان رفتار متفاوتی با ویژگی‌های مختلف نداشته باشند.

در مرحله پیش‌پردازش، بیمارستان ۱۳ نیز به بیمارستان‌ها اضافه شد که این بیمارستان، جمع تعداد مصرف دیگر بیمارستان‌ها است. هدف این است که برای بیمارستان ۱۳ یک مدل بصورت جداگانه آموزش ببیند و در نتیجه تعداد مصرف کل شهر همدان در یک روز مشخص توسط مدل بیمارستان ۱۳ قابل پیش‌بینی باشد. همچنین در شکل الف در پیوست، وابستگی بین بیمارستان‌ها و الگوی بین آن‌ها به نمایش در آمده است که می‌توانید آن را بررسی نمایید.

۳-۲- غنی سازی مجموعه داده

برخلاف مدل‌های تک متغیره مثل پروفت، آریما و ساریما، مدل‌های یادگیری ماشین، به مجموعه غنی از ویژگی‌ها برای آموزش نیاز دارند. بنابراین برای استفاده از این مدل‌ها نیاز به ساخت مجموعه‌ی غنی‌تری از ویژگی‌ها می‌باشد. بدین منظور دو نوع ویژگی برای غنی سازی مجموعه داده مورد استفاده قرار گرفت. نوع اول ویژگی‌های تقویمی بودند که مستقیم از تاریخ استخراج می‌شوند و نوع دوم، ویژگی‌های اقلیمی می‌باشد. ویژگی‌های تقویمی استخراج شده شامل تعطیلات مدارس، کرونا، فصل سرما، روز سال و روز ماه می‌باشند. تعطیلات مدارس با شاخص ۱ در مقابل ۰ برای سایر روزها نمایش داده شد، کرونا نیز با سه شاخص ۰ و ۱ و ۲ به ترتیب معرف روزهای عدم حضور کوید ۱۹، روزهای حضور کوید ۱۹ و روزهای اوج درگیری کوید ۱۹ در ایران می‌باشد. ویژگی فصل سرما نیز معرف فصل‌های سرد سال است و با ۰ و ۱



شکل ۱: شمای کلی مدل‌های ارائه شده و نحوه کارکرد آن‌ها

می‌گرداند. به طور مثال برای ۳۰ ژانویه ۲۰۲۲ و تعداد روز گذشته ۷، میزان تقاضا در ۲۳ ژانویه ۲۰۲۲ را باز می‌گرداند.

- lastYearLabel
- lastMonthLabel
- lastWeekLabel

این توابع تاریخ و نام بیمارستان را دریافت می‌کنند و عدد فروش مربوط به دقیقاً یک سال/ماه/هفته قبل از تاریخ ورودی را برای بیمارستان مشخص شده را باز می‌گرداند.

- realLabel: این تابع تاریخ و نام بیمارستان را دریافت می‌کند و عدد فروش مربوط به تاریخ ورودی را برای بیمارستان مشخص شده را باز می‌گرداند.

توابع آماده سازی داده آموزشی:

- generateTrainDataForADate_XInputs

این توابع داده‌ها را برای آموزش مدل‌ها با استفاده از یک تاریخ زمانی و یک عدد که معرف بیمارستان است آماده می‌کنند.

تابع محاسبه پیش‌بینی:

- Weightedpredict

این تابع برای پیش‌بینی تقاضا استفاده می‌شود و با محاسبه میانگین وزنی از نتایج مدل‌های ۱ و ۴، پیش‌بینی نهایی فروش را محاسبه می‌کند.

در ادامه ۴ مدل ارائه شده توضیح داده می‌شوند. مدل نخست یک رویکرد منطقی با نگاه به توالی زمانی سال جاری و سال پیشین و چند لیبل برجسته دیگر را انجام می‌دهد. مدل ۲ و ۳ به منظور پیش‌بینی یک ساله و بلند مدت برای پیش‌بینی بر اساس داده‌ها با فاصله‌ی یک ساله طراحی شده و مدل ۴ با هدف تمرکز بر ویژگی‌های تقویمی و اقلیمی ساخته شده است.

۱-۴-۱ مدل (last 30ds, last y 30ds, last y, last m, last w)

این مدل دارای ۵ ورودی است که به ترتیب، دنباله سی روز گذشته در سال جاری و سی روز گذشته در سال پیشین و ۳ عدد ثابت که تعداد مصرف در

SNOW (برف): میزان برف نیز می‌تواند بر برخی از بیماری‌ها یا شرایط حساسیت‌ها تأثیر گذار باشد. همچنین ممکن است موجب مسدود شدن دسترسی به مراکز درمانی شود و در کشف برخی الگوهای خاص که پیش از این ممکن نبود یاری رسانی کند و به تفسیر بهتر الگوهای تقاضا کمک کنند. در نهایت مجموعه داده اولیه‌ی ارائه شده در جدول ۱ به مجموعه داده نهایی مطابق با جدول ۲ تبدیل شد.

۴- مدل‌ها

در این بخش چهار مدل مختلف برای پیش‌بینی تقاضای دارو در بیمارستان-های همدان بر اساس مجموعه داده نهایی ایجاد شده در بخش پیشین ارائه می‌شود. شمای کلی این چهار مدل و نحوه کار آن‌ها در شکل ۱ نمایش داده شده است.

توابع کاربردی مختلف برای آماده‌سازی دنباله‌های ورودی و برجسب‌ها از داده‌های اصلی بر اساس زمان‌های مورد نظر تعریف شده‌اند این توابع در شکل ۱ نمایش داده شده‌اند. در ادامه هر کدام جداگانه تشریح شده‌اند:

توابع بازگردانی داده‌های مورد نیاز از پایگاه داده:

- thisYearDF
- lastYearDF


این توابع تاریخ، نام بیمارستان، اندازه توالی را ورودی می‌گیرند و داده‌های توالی پیشین تا (برای تابع دوم، دقیقاً یک سال قبل از) تاریخ مشخص شده برای بیمارستان مورد نظر را باز می‌گرداند. به طور مثال اگر توالی ۳۰ روز برای ۳۰ ژانویه ۲۰۲۲ را دریافت کند، داده‌های ۳۰ روز گذشته از این تاریخ را خروجی می‌دهد و برای تابع دوم، ۱ ام تا ۳۰ ام ژانویه‌ی ۲۰۲۱ باز گردانده می‌شود. همچنین تابع اول یک متغیر ورودی به نام delta دریافت می‌کند که اگر عددی بجز صفر باشد، توالی داده‌ها را از delta روز قبل دریافت می‌کند.

- generateANumber

این تابع تاریخ، نام بیمارستان، تعداد روز گذشته را دریافت می‌کند و میزان تقاضا برای آن بیمارستان خاص در روز مشخص گذشته از روز ورودی را باز



در این مدل بدون اینکه تقاضای مستقیم دارو به عنوان ویژگی نگاه شود، یک شبکه‌ی عصبی بازگشتی با حافظه کوتاه و بلند مدت، دنباله ورودی (شکل ۳) را با تنها اطلاعات تقویمی و اقلیمی بدون میزان مصرف دارو پردازش می‌کند و سپس با استفاده چندین لایه متراکم اقدام به پیش‌بینی میزان تقاضا می‌کند. در نتیجه، این مدل وابسته به تعداد مصرف دارو نیست و تنها ۱۴ صفت از ۱۵ صفت ذکر شده در جدول ۲ را استفاده می‌کند و مزیت آن این است که برای تاریخ‌های دور از امروز، نیاز به پیش‌بینی بازگشتی ندارد.



شکل ۳: شماییک ورودی مدل ۳

نحوه پیاده‌سازی این مدل ۴ در تصاویر پیوست ب، پ، ت، ث قابل مشاهده است.

۴-۵- راه اندازی عملی

برای پیاده‌سازی مدل‌های ساخته شده از سیستم گوگل کولب و گرافیک T4 با ۱۵ گیگابایت حافظه گرافیک استفاده شده است. همچنین هر چهار مدل با اندازه دسته‌ی ۱۲۸ تایی آموزش دیده اند. برای آموزش مدل‌ها، از نرخ آموزش ۰.۰۰۱ استفاده شده است. اما در مدل ۱، این نرخ هر ۱۰۰ ایپاک نصف می‌شود. همچنین به منظور اعتبار سنجی از سه مجموعه‌ی اعتبار سنجی مختلف، کوتاه مدت، میان مدت و بلند مدت استفاده شده و تابع زیان هر مدل جمع وزن‌دار زیان حاصل از این سه مجموعه‌ی اعتبار سنجی طبق فرمول زیر می‌باشد:

$$Loss = L(shortCV) + 1.15 * L(midCV) + 1.3 * L(longCV) \quad (1)$$

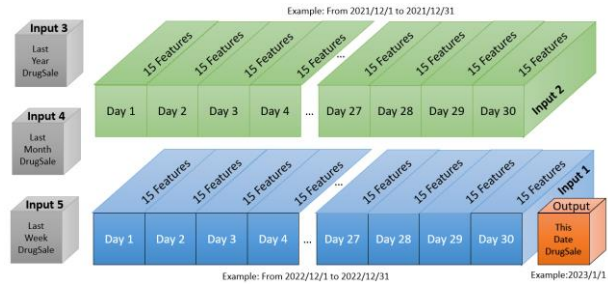
در معادله‌ی (۱) تابع هزینه کل به صورتی محاسبه شده است که پیش‌بینی بلند مدت بیش از میان مدت و پیش‌بینی میان مدت بیش از کوتاه مدت اهمیت داشته باشد. در نهایت هر مدل تا ۴۰۰ ایپاک آموزش داده می‌شود و برای هر بیمارستان، مدل نهایی و مدلی که کمترین زیان را طبق معادله (۱) باز می‌گرداند، ذخیره می‌شوند.

۵- نتایج

در مرحله‌ی تست و اعتبار سنجی، دو مدل ۲ و ۳ نتایج مناسبی حاصل نکردند؛ اما حضور آن‌ها در بخش ۴، علی‌رغم مدل‌های فراوان ناموفقی که در گزارش ارائه نشدند (شامل مدل‌های چند بیمارستانی و مدل‌های یادگیری ماشین سنتی نظیر رگرشن و مدل‌هایی که همبستگی بیمارستان‌ها را در نظر می‌گرفتند و...) این بود که تمرکز این دو مدل بر داده‌های با فاصله‌ی یک سال زمانی از روز هدف بود و در واقع پاسخ‌گوی این سوال بودند که آیا می‌توان با اطلاعات فعلی میزان تقاضا در یک سال آینده را پیش‌بینی کرد یا خیر. بنابراین در مدل نهایی ارائه شده تنها از مدل ۱ و ۴ استفاده شد. برای ارزیابی مدل ۱ و ۴ هر یک با دو طول توالی یک هفته و یک ماه مطابق با تنظیمات بخش ۴-۵ آموزش داده شدند که منجر به ۴ مدل می‌شود. نتایج این مدل‌ها به صورت وزن‌دار برای پیش‌بینی آینده میانگین‌گیری شد که وزن‌های آن به صورت تجربی و با آزمون و خطا حاصل شدند. نتایج مدل‌ها برای بیمارستان ۱

تاریخ‌های متفاوت را نمایش می‌دهند. شمای این مدل در شکل ۲ نمایش داده شده است.

بصورت خلاصه، این مدل یاد می‌گیرد که بر اساس تعداد مصرف روزهای گذشته و سال پیش و مشخصات آب و هوایی آن روزها، پیش‌بینی کند که بیمارستان مورد نظر در تاریخ ذکر شده، به چه مقدار دارو نیاز دارد. از آنجایی که این مدل به مقدار مصرف دارو در روزهای گذشته وابسته است، اگر تاریخ دوری از مدل خواسته شود مجبور است بصورت بازگشتی روزهای قبل را پیش‌بینی کند تا به روز خواسته شده برسد. در این مدل تمامی ۱۵ صفت ذکر شده در جدول ۲ در سری توالی‌ها استفاده شده است.



شکل ۲: شماییک ورودی مدل ۲

۴-۲- مدل ۲ (last y 30dys, last y, last y+m, last y+w)

این مدل تنها از یک دنباله ورودی به صورت توالی استفاده می‌کند و علاوه بر این سه ورودی دیگر نیز دارد که شامل میزان تقاضا (سال، ماه و هفته گذشته) هستند. توالی و برچسب‌ها مشابه توضیحات مدل ۱ توسط شبکه‌های بازگشتی با حافظه کوتاه و بلند مدت و شبکه متراکم پردازش می‌شوند. در این مدل تمامی ۱۵ صفت جدول ۲ در سری توالی ذکر شده استفاده شده است. مزیت این مدل این است که به داده‌های روز قبل وابسته نیست و بر اساس داده‌های سال قبل پیش‌بینی می‌کند.

۴-۳- مدل ۳ (last y ±30dys, last y, last y±m, last y±w)

این مدل، یک مدل بهبود یافته از مدل ۲ است و با نگاه دوطرفه به توالی پیشین و آتی از یک سال گذشته‌ی تاریخ هدف، بیشتر بر روی شناسایی الگوها از فواصل زمانی در سال گذشته تمرکز دارد. دو دنباله شامل سی روز پیشین و سی روز آتی از یک سال قبل تاریخ هدف، به همراه برچسب‌های سال گذشته و برچسب‌های هفته و ماه گذشته به لایه‌های یک شبکه‌ی عصبی دوطرفه بازگشتی با حافظه کوتاه و بلند مدت وارد می‌شوند. این مدل دارای هفت ورودی است که شامل دو توالی، برچسب سال گذشته و برچسب‌های هفته و ماه گذشته‌ی (و آتی) سال پیشین تاریخ هدف و هستند. در این مدل شبکه دوطرفه بازگشتی با حافظه کوتاه و بلند مدت توالی‌ها را پردازش کرده و شبکه متراکم سایر ورودی‌ها را دریافت کرده در نهایت خروجی دو مدل ترکیب شده و به یک شبکه‌ی دیگر با لایه‌های متراکم برای پیش‌بینی نهایی داده می‌شوند. در این مدل نیز تمامی ۱۵ صفت جدول ۲ در سری توالی‌ها استفاده شده است.

۴-۴- مدل ۴

این مدل به‌طور کامل بر روی عوامل خارجی و الگوهای زمانی تمرکز می‌کند،

جدول ۳: نحوه وزن‌دهی مدل‌ها برای تولید خروجی

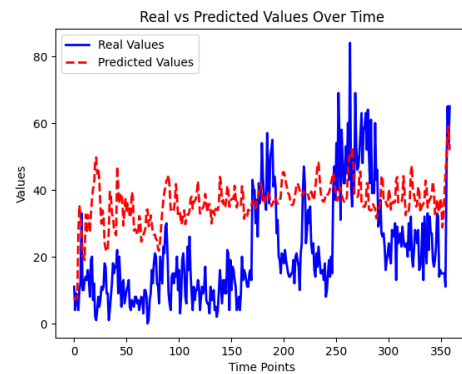
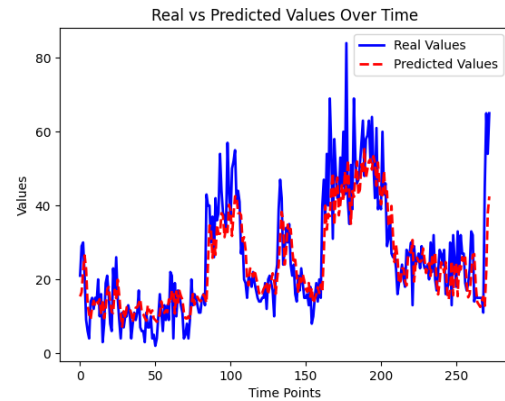
نام بیمارستان	مدل ۱ ۴۰۰ ایپاک	مدل ۱ بالاترین صحت	مدل ۴ ۴۰۰ ایپاک	مدل ۴ بالاترین صحت
۱	۰.۴۵	۰.۳	۰.۱	۰.۱۵
۲	۰.۴۵	۰.۴	۰.۱	۰.۰۵
۳	۰.۵	۰.۱۵	۰.۱۵	۰.۲
۴	۰.۵۵	۰.۳	۰.۱	۰.۰۵
۵	۰.۳۵	۰.۴	۰.۲	۰.۰۵
۶	۰.۶۵	۰.۲۵	۰.۱	۰
۷	۰.۵۵	۰.۲۵	۰.۱	۰.۱
۸	۰.۵	۰.۳۵	۰.۱	۰.۰۵
۹	۰.۳	۰.۵	۰.۱	۰.۱
۱۰	۰.۳	۰.۲	۰.۳۵	۰.۱۵
۱۱	۰.۶	۰.۲۵	۰.۱	۰.۰۵
۱۲	۰.۴	۰.۵	۰.۱	۰
۱۳	۰.۴۵	۰.۳۵	۰.۱	۰.۱

معرفی شد. همانطور که در شکل ۵ نیز دیده می‌شود مدل ۱ نتیجه‌ی بسیار خوبی داشته است در صورتی که مدل ۴ تنها در برخی نقاط توانایی پیش‌بینی دقیق را داشته است. دلیل استفاده از میانگین وزن‌دار این دو مدل در خروجی نهایی این استدلال است که مدل چهار تنها توانایی پیش‌بینی بر اساس عوامل تقویمی و اقلیمی را دارد و از آنجایی که این عوامل (همانطور که در مقدمه اشاره شد) تنها یکی از سه عامل موثر بر میزان تقاضا هستند، و با توجه به نتایج مشخص است که عوامل تقویمی و اقلیمی بخش کوچکی از رفتار بیمارستان‌ها را مدل کرده‌اند و رفتار اخیر بازار در فواصل زمانی گذشته اثر بیشتری داشته است. بنابراین از روش رأی دهی بر روی مدل‌های ۱ و ۴ برای پیش‌بینی خروجی استفاده شد. لذا با توجه به توضیحات داده شده، مدل ۴ وزن بسیار کمتری در میانگین‌وزنی نهایی خواهد داشت، به طوری که به طور متوسط وزن مدل ۱ در تصمیم نهایی ۰.۸ و وزن مدل ۴ برابر با ۰.۲ می‌باشد. همچنین عدم موفقیت مدل‌های ۲ و ۳ منجر به این نتیجه‌گیری می‌شود که تناوب سالانه در تکرار رفتار بیمارستان‌ها وجود ندارد و این مسئله با مقایسه رفتار بیمارستان‌ها در سال‌های پایانی نیز بررسی و اثبات شد که از ارائه نمودارهای آن در گزارش صرف نظر شده است.

۷- کارهای آینده

به عنوان ایده برای کارهای آینده می‌توان به استفاده از شبکه‌های عصبی پیچشی بر روی شبکه عصبی بازگشی با حافظه کوتاه و بلند مدت در کنار شبکه‌های توجه اشاره کرد. همچنین در بررسی‌های انجام شده در ارتباط بین بیمارستان‌ها کشف شد که برخی از بیمارستان‌ها همبستگی بالایی با یکدیگر دارند. در مدل‌هایی که در این پژوهش پیاده سازی شد، اعمال این همبستگی‌ها منجر به افت عملکرد شد و در این فرصت کم امکان ارائه مدلی که از این همبستگی‌ها به درستی استفاده کند نبود. همچنین از آنجایی که ارتباط موثری از نظر تاریخی پیدا نشد، پیدا کردن برهه‌های زمانی از گذشته که رفتار مشابه داشته اند می‌تواند یکی از محورهای تحقیقات آتی باشد. پیاده‌سازی مدلی که بتواند این اطلاعات ارزشمند را در کنار معماری‌های پیچیده‌تر شبکه عصبی پیاده سازی کند نیازمند زمان قابل توجهی بود که امید می‌رود در پژوهش‌های آتی مورد توجه محققان قرار گیرد.

در شکل ۵ قابل مشاهده است. شکل ۵ نتیجه پیش‌بینی با توالی‌های ۳۰ روزه برای بیمارستان ۱ را نمایش می‌دهد. نتایج دیگر بیمارستان‌ها داخل کد آموزش مدل‌ها قابل مشاهده است و الگویی مانند بیمارستان ۱ دارند.



شکل ۵: پیش‌بینی مدل ۱ بیمارستان ۱ در بالا، مدل ۴ بیمارستان ۱ در پایین

در ادامه، پس از بررسی نتیجه مدل‌ها برای هر بیمارستان، طبق جدول ۳ وزن‌دهی مناسبی برای هر کدام تهیه شده و با استفاده از این وزن‌ها، در تابع `weightedPredict` مدل شروع به پیش‌بینی می‌کند. لازم به ذکر است این وزن‌ها برای دیتاست تست در نظر گرفته شده‌اند و در دنیای واقعی، شما می‌توانید بر اساس نیازتان مدل ۱ را با تعریف دلتای مناسب و سایز توالی مناسب آموزش دهید و از آن استفاده کنید. مدل ۴ به منظور کاهش نویز توالی پیش‌بینی در داده تست استفاده شده است و در دنیای واقعی، مدل یک بهترین نتیجه را با داشتن تعداد مصرف روزهای قبل می‌دهد. در صورتی که نیازمند مدلی باشید که بجای تولید توالی از روز قبل لیبل، توالی را از هفته گذشته تولید کند می‌توانید با جایگذاری دلتا برابر با ۷، مدل سفارشی خود را آموزش داده و با کمترین خطای ممکن از آن استفاده کنید.

۶- نتیجه‌گیری

در این پژوهش داده‌های میزان تقاضای تأمین یک داروی خاص توسط ۱۲ بیمارستان شهر همدان استفاده شد، تا یک مدل برای پیش‌بینی تقاضای دارویی در سطح بیمارستان و شهر ارائه شود که توانایی پیش‌بینی بلند مدت و کوتاه مدت را داشته باشد. بدین منظور در گام نخست به پیش‌پردازش و گسترش مجموعه‌ی داده و اکتشاف ویژگی‌ها پرداخته و سپس چند مدل براساس داده‌های جاری (مدل ۱)، داده‌های سال گذشته (مدل ۲ و ۳) و داده‌های اقلیمی و تقویمی (مدل ۴) طراحی شدند که نتایج آن‌ها در بخش ۵



- [5] C. Hamzacebi, "Improving artificial neural networks' performance in seasonal time series forecasting", *Inf. Sci.*, vol. 178, no. 23, pp. 4550- 4559, Dec. 2008.
- [6] D. Ge, Y. Pan, et al. "Retail supply chain management: a review of theories and practices". *J. of Data, Inf. and Manag.* 1, 45-64 (2019).
- [7] D. Grzegorz, "Short-Term Load Forecasting Using Random Forests", *IEEE Conf. on Intelligent Systems*, 2014.
- [8] S.J. Taylor, and B. Letham (2018), "Forecasting at Scale", *The American Statistician*, 72:1, 37-45.
- [9] Almentero, B. K., Li, J., & Besse, C. (2021, November). Forecasting pharmacy purchases orders. In *2021 IEEE 24th International Conference on Information Fusion (FUSION)* (pp. 1-8). IEEE.

منابع

- [1] D. Koala, Z. Yahouni, G. Alpan, and Y. Frein, "Factors influencing Drug Consumption and Prediction Methods," in *CIGI-Qualita :Conférence Internationale Génie Industriel QUALITA - Grenoble*, 2021, pp. 1-8, [Online].
- [2] G. Box, G.M. Jenkins, G.C. Reinsel and G., Ljung, "Time series analysis: forecasting and control". John Wiley & Sons. 2015.
- [3] C.C. Holt, "Forecasting seasonals and trends by exponentially weighted moving averages", *Inter. J. of Forecasting*, Vol. 20, Issue 1, January- March 2004, pp.5-10.
- [4] P.R. Winters, "Forecasting sales by exponentially weighted moving averages", *Management Science*, Vol.6, No.3, Apr., 1960, pp. 324-342.

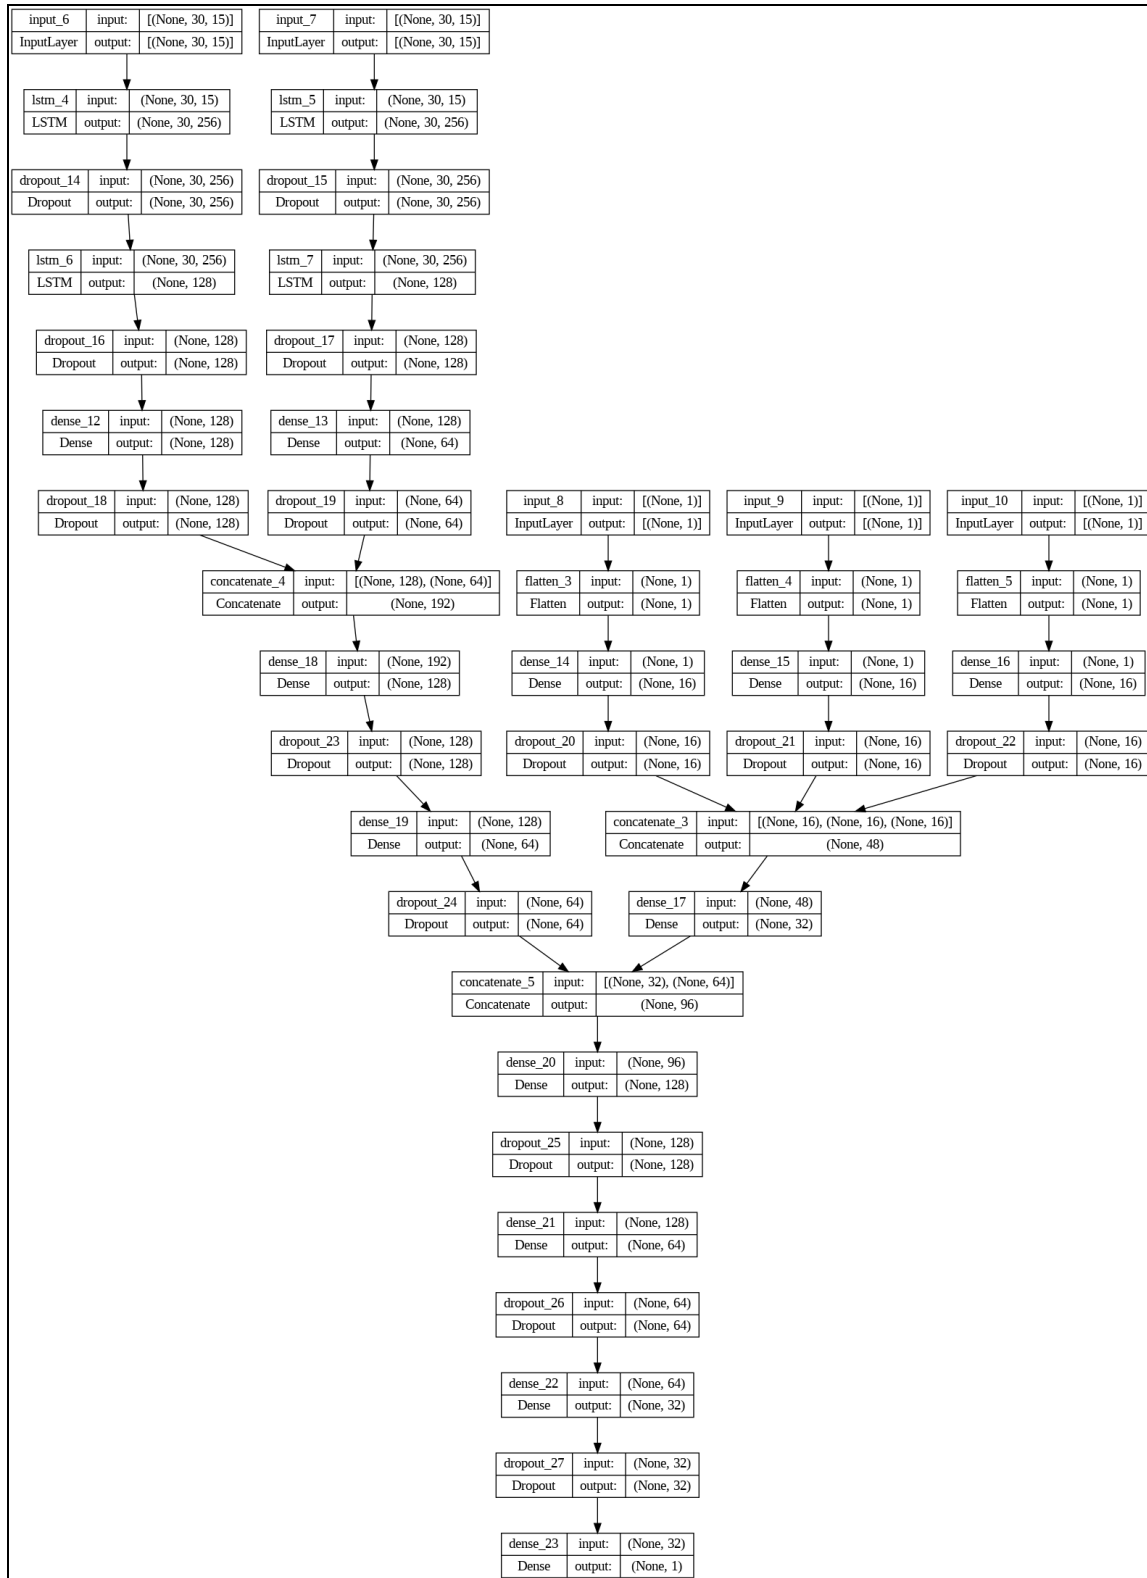


پیوست

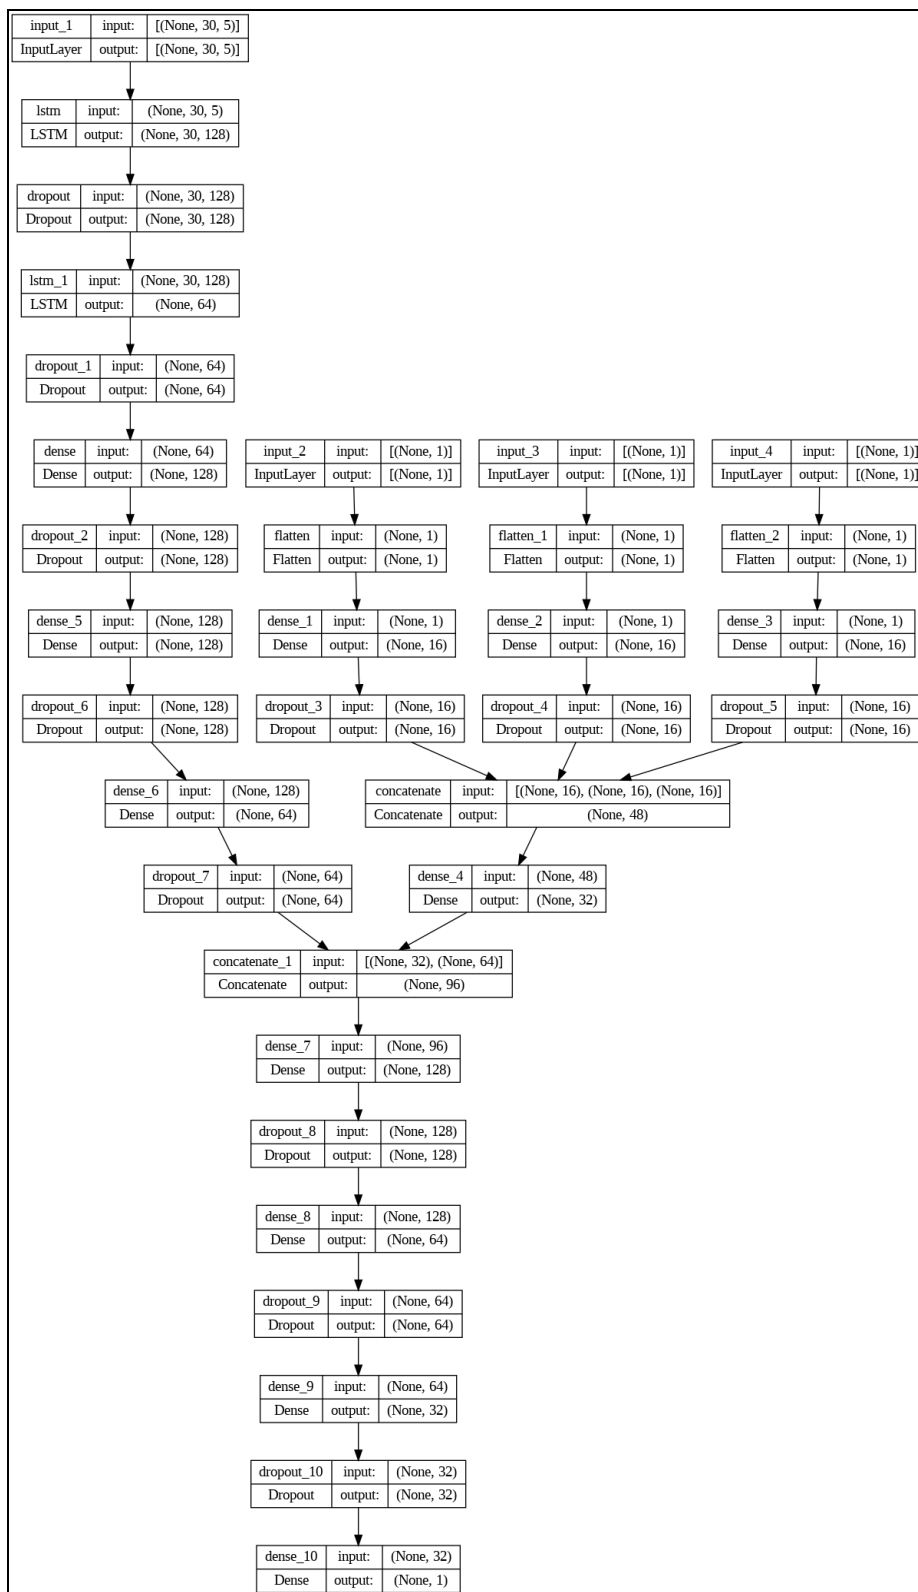
Correlation between Hospitals' Sales



شکل الف: وابستگی بیمارستان‌ها به یکدیگر بر اساس تعداد درخواست دارو. هرچه وابستگی بین دو بیمارستان مثبت‌تر باشد، آن دو بیمارستان بیشتر به هم مرتبط‌اند. با توجه به وابستگی موجود بین بعضی از بیمارستان‌ها، مدلی با معماری شکل ج در پیوست‌ها پیاده‌سازی شد که متاسفانه نتیجه مثبتی نداشت.



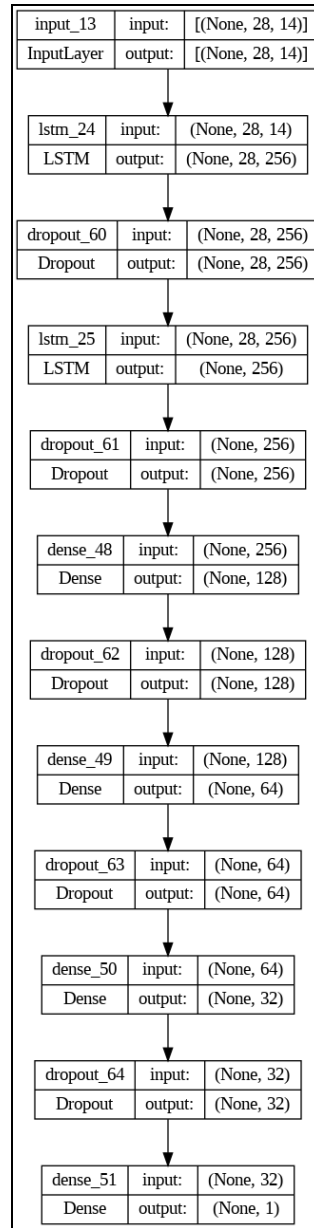
شکل ب: معماری مدل ۱



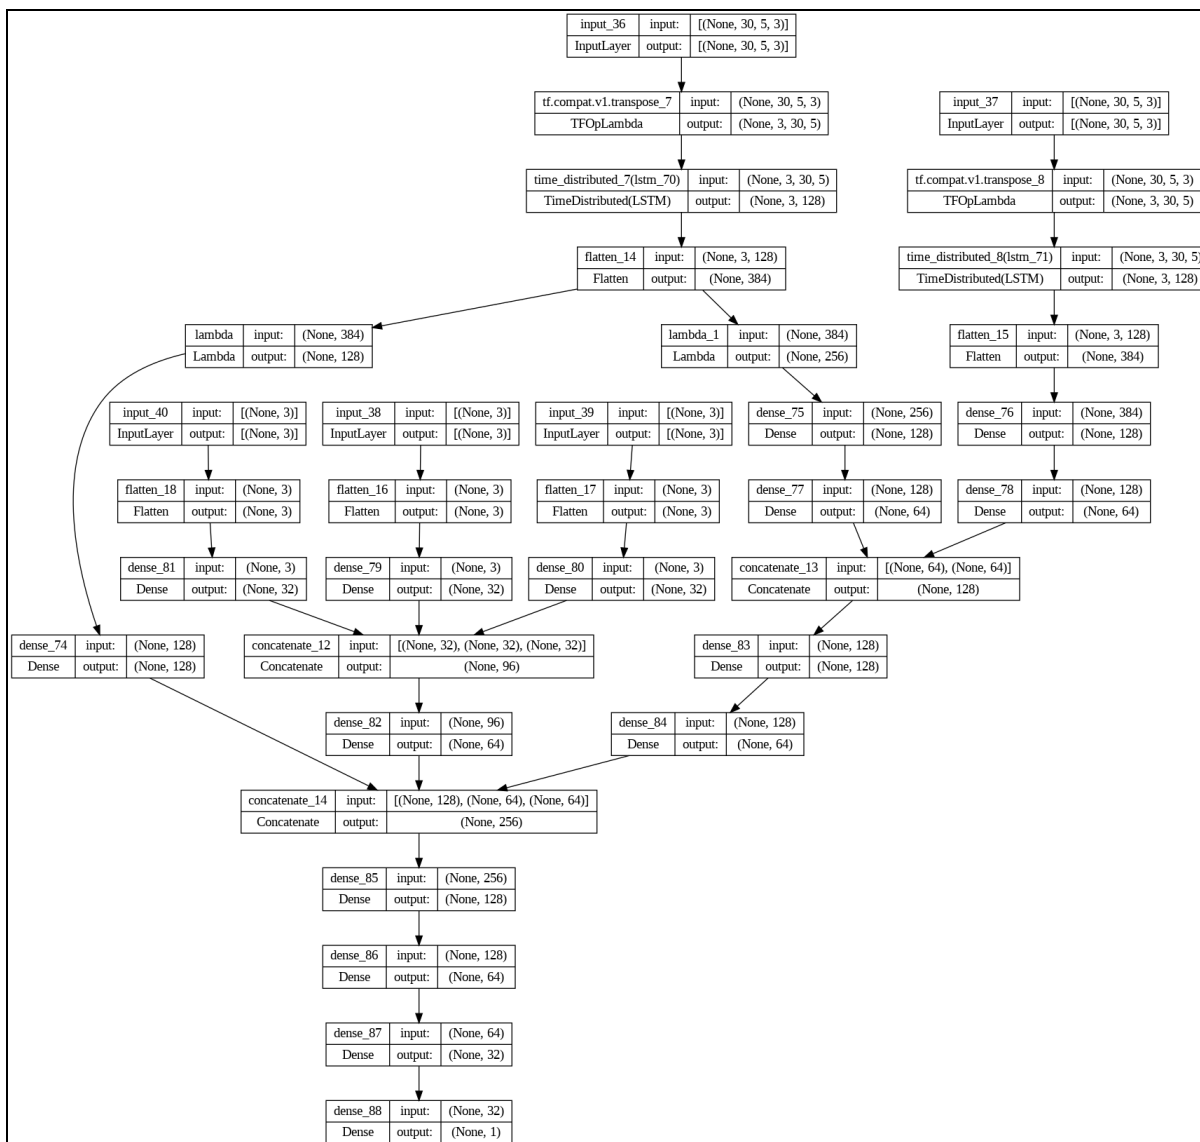
شکل پ: معماری مدل ۲



شکل ت: معماری مدل ۳



شکل ۴: معماری مدل ۴



شکل ج: معماری مدل ۱ با چندین بیمارستان ورودی - ناموفق