

ارائه مدلی جهت پیش‌بینی تقاضا در زنجیره تامین پلاکت خون با رویکرد شبکه عصبی مصنوعی و مدل‌های آریمما

فرزاد فیروزی جهانتیغ^۱، بهاره فنودی^۲، سهیلا خسروی^۳

چکیده

سابقه و هدف

یکی از مباحث عمده در سیستم‌های بهداشت و درمان جهانی، مسئله بهبود عملکرد زنجیره تامین و عدم قطعیت موجود در تقاضا می‌باشد. هدف مطالعه حاضر، پیش‌بینی میزان تقاضای پلاکت خون با مدل‌های شبکه عصبی مصنوعی و آریمما، در زنجیره تامین سازمان انتقال خون استان سیستان و بلوچستان بود.

مواد و روش‌ها

در این مطالعه کاربردی، داده‌های مربوط به تقاضا برای ۸ نوع پلاکت خون در بازه زمانی سال‌های ۱۳۹۰ لغایت ۱۳۹۴ از مرکز انتقال خون زاهدان جمع‌آوری گردید. سپس با بهره‌گیری از مدل‌های شبکه عصبی مصنوعی و آریمما، پیش‌بینی تقاضای روزانه انجام پذیرفت. در انتها با توجه به معیار ارزیابی کارایی MSE، نتایج به دست آمده از روش‌های مذکور با هم مقایسه شدند. تحلیل داده‌ها با نرم‌افزارهای MatlabR2016b و Eviews انجام شد.

یافته‌ها

نتایج این مطالعه حاکی از دقت بالای مدل‌های شبکه عصبی و سپس آریمما نسبت به روند فعلی سازمان بود. دقت میانگین با توجه به MSE دو مدل مذکور برای انواع پلاکت عبارتند از: O^+ ($0/0132 \pm 0/0048$)، O^- ($0/0115 \pm 0/0041$)، A^+ ($0/0205 \pm 0/0043$)، A^- ($0/01085 \pm 0/0033$)، B^+ ($0/0221 \pm 0/0086$)، B^- ($0/0045 \pm 0/0009$)، AB^+ ($0/0136 \pm 0/0031$) و AB^- ($0/0034 \pm 0/0005$) که به ترتیب بیانگر میانگین و انحراف معیار خطا می‌باشد.

نتیجه‌گیری

نتایج این مطالعه نشانگر دقت بالای مدل‌های شبکه عصبی مصنوعی و سپس آریمما در پیش‌بینی تقاضای پلاکت خون است. لذا استفاده از مدل‌های شبکه عصبی مصنوعی جهت پیش‌بینی تقاضا به جای روش‌های پیش‌بینی آماری رایج در مراکز انتقال خون قابل توصیه می‌باشد.
کلمات کلیدی: پلاکت‌های خون، آریمما، انتقال خون

تاریخ دریافت: ۹۶/۴/۱۳

تاریخ پذیرش: ۹۶/۷/۱۷

۱- مؤلف مسئول: PhD مهندسی صنایع - استادیار دانشکده مهندسی شهید نیکبخت - دانشگاه سیستان و بلوچستان - زاهدان - ایران - کدپستی: ۱۵۹۳۹۱۵۱۱۱

۲- دانشجوی کارشناسی ارشد مهندسی صنایع - دانشکده مهندسی شهید نیکبخت - دانشگاه سیستان و بلوچستان - زاهدان - ایران

۳- پزشک عمومی و MPH - مرکز تحقیقات انتقال خون - مؤسسه عالی آموزشی و پژوهشی طب انتقال خون و پایگاه منطقه‌ای آموزشی انتقال خون زاهدان - زاهدان - ایران

مقدمه

یکی از مباحث عمده در سیستم‌های بهداشت و درمان جهانی، مسئله بهبود عملکرد زنجیره تامین می‌باشد. نظام سلامت به دلیل ارتباط مستقیمی که با سلامتی و جان انسان‌ها دارد، یکی از پیچیده‌ترین و چالش برانگیزترین زنجیره تامین‌ها را داراست. مسایلی از قبیل عدم قطعیت در تقاضا، برنامه‌ریزی برای مدیریت موجودی و سفارش، تاریخ انقضاء و منابع محدود انسانی از جمله چالش‌های اساسی در حوزه سلامت و به ویژه زنجیره تامین خون و فرآورده‌های آن می‌باشند (۱، ۲). از طرفی برنامه‌ریزی مدیریت در زنجیره تامین فرآورده‌های خونی با فسادپذیری بالا، به ویژه پلاکت خون یک مسأله ضروری برای حیات انسان‌ها محسوب می‌شود (۳). پلاکت پرهزینه‌ترین محصول خون است که با دارا بودن عمر مفید ۳ روز و هزینه بالایی تولید و نگهداری تعداد زیادی از آن در مراکز خون مقرون به صرفه نیست. تامین خون از طرف اهداکنندگان اغلب به صورت نامنظم و تقاضا برای فرآورده‌های آن تصادفی است، که این عدم قطعیت موجود در زنجیره تامین پلاکت، تصمیم گیرندگان و کارشناسان این حوزه را در زمان افزایش تقاضای پلاکت و یا کاهش مراجعه‌کنندگان به مراکز جمع آوری خون، با مشکل مواجه ساخته است؛ از طرفی در زمان کاهش تقاضای پلاکت و یا افزایش مراجعه‌کنندگان نیز، محدودیت‌های بسیاری در مورد نگهداری پلاکت‌ها و یا تولید بیش از تقاضای آن وجود دارد. به همین دلیل توجه به مسئله تطابق میزان تولید پلاکت در مراکز خون با تقاضای مورد نیاز بیمارستان‌ها و مراکز درمانی، بسیار حائز اهمیت است (۳، ۴). کوپرا و میندل معتقدند پایه و بنیاد همه برنامه‌ریزی‌ها و زمانبندی‌ها در زنجیره تامین، پیش‌بینی دقیق و اطلاع از میزان تقاضا می‌باشد (۵). داشتن اطلاعات دقیق تقاضا به ویژه زمانی که عمر مفید محصول کوتاه است، منجر به تصمیم‌گیری صحیح در زمینه تامین مقدار سفارش مورد نیاز، کاهش ضایعات منابع، جلوگیری از کمبود و هزینه‌های سلامت می‌شود (۶). لذا توجه به این مسئله امری ضروری در زنجیره تامین می‌باشد. در پژوهش‌های پیشین، مطالعاتی در زمینه پیش‌بینی تقاضای خون با مدل‌های ARIMA

انجام شده است. امروزه شبکه عصبی مصنوعی (Artificial Neural Nets = ANN) که یکی از مولفه‌های هوش محاسباتی می‌باشد، جایگاه ویژه‌ای در حوزه‌های مختلف علوم و تحقیقات یافته‌اند (۷). این شبکه‌ها به دلیل هوشمند بودن، سرعت بالای پردازش داده‌ها، قابلیت تطبیق با تغییرات محیطی، قابلیت تعمیم و مدل‌سازی سیستم‌های غیر خطی با پیچیدگی‌های زیاد از جمله ابزارهای قوی، هوشمند و توانا برای استفاده در مسائل تصمیم‌گیری‌ها مناسب می‌باشند (۸، ۹). روند فعلی برای پیش‌بینی تقاضای پلاکت در سازمان انتقال خون استان، استفاده از روش میانگین‌گیری می‌باشد که نسبت به تغییرات تقاضا حساس نیست. بنابراین مطالعه حاضر با ارایه مدل‌های کاربردی شبکه عصبی مصنوعی و آریمای جهت پیش‌بینی میزان تقاضا در زنجیره تامین پلاکت سازمان انتقال خون استان سیستان و بلوچستان، سعی در کاهش عدم قطعیت تقاضا دارد که نتیجه آن کاهش ضایعات، هزینه‌های تولید و جلوگیری از کمبود است.

مواد و روش‌ها

معرفی داده‌ها:

مطالعه حاضر از نوع کاربردی بود و به منظور بررسی مدل‌های شبکه عصبی مصنوعی و آریمای داده‌های روزانه مربوط به میزان تقاضای بیمارستان‌ها و مراکز درمانی برای ۸ نوع پلاکت خون (O^+ , O^- , A^+ , A^- , B^+ , B^- , AB^+ , AB^-)، از سازمان انتقال خون استان سیستان و بلوچستان پایگاه منطقه‌ای آموزشی زاهدان جمع‌آوری گردید. با توجه به این که روش نمونه‌گیری تصادفی ساده بود، بنابراین از بین داده‌های روزانه ثبت شده در پایگاه داده سازمان، بازه زمانی سال‌های ۱۳۹۰ لغایت ۱۳۹۴ به صورت تصادفی انتخاب شدند.

مدل ARIMA:

سری زمانی، دنباله‌ای از مشاهدات متوالی است که بر حسب زمان مرتب شده‌اند. مهم‌ترین قدم در تحلیل این سری‌ها، یافتن مدل مناسب می‌باشد، که معروف‌ترین روش یک استراتژی چند مرحله‌ای با نام آریمای است و توسط

(Durbin-watson stat = DW) به کارگرفته شدند. در مرحله بازبینی تشخیص مدل، جهت بررسی کفایت و مناسب بودن مدل انتخابی از آزمون الجانگ - باکس (Ljung-Box) استفاده گردید و در صورتی که مدل انتخابی نامناسب باشد، باید مورد تعدیل و اصلاح قرار گرفته و به مراحل قبل بازگردد. در انتها پس از تشخیص بهترین مدل‌های آریما، به پیش‌بینی میزان تقاضای پلاکت برای دوره بعد پرداخته می‌شود (۸، ۱۴). تمامی تنظیمات مربوط به مدل آریما با نرم افزار Eviews انجام پذیرفت.

مدل شبکه عصبی مصنوعی:

شبکه عصبی شامل شبکه‌ای از عناصر پردازشی ساده به نام نورون است، که می‌تواند رفتار پیچیده کلی تعیین شده‌ای از ارتباط بین عناصر پردازش و پارامترهای عنصر را نمایش دهد. از کنار هم قرار گرفتن مجموعه نورون‌های سطری، یک لایه ایجاد می‌شود و مجموعه چند لایه باهم تشکیل یک شبکه می‌دهد (۱۵).

برای طراحی شبکه عصبی مصنوعی، علاوه بر انتخاب مجموعه‌ای از متغیرهای ورودی، باید ساختمان شبکه‌ای با بهترین پیش‌بینی را با آزمون و خطا شناسایی کرد (۱۶).

در مطالعه حاضر از شبکه عصبی پرسپترون چند لایه (Multi Layer Perceptron = MLP) با قانون یادگیری پس انتشار (Back-Propagation) استفاده شده است (شکل ۱). این شبکه عصبی از سه لایه شامل: لایه ورودی (Input Layer)، لایه مخفی (Hidden Layer) و لایه خروجی (Output Layer) تشکیل شده است که در آن R ، S ، f ، a ، b و W به ترتیب بیانگر تعداد ورودی‌ها (P)، تعداد نورن‌ها (n) در هر لایه، تابع فعال‌سازی، خروجی هر لایه، جمله اریب و بردار وزن‌ها است (شکل ۱) (۱۷).

با کمک نرم‌افزار MATLAB 2016b ساختارهای متعددی از نوع پرسپترون به منظور پیش‌بینی تقاضا طراحی شد.


از آن جا که میزان تقاضای پلاکت در ایام هفته متفاوت است و این تغییرات روند تاریخی خاصی را طی می‌کنند، بنابراین لازم است تغییرات تقاضا در شبکه لحاظ گردد،

باکس و جنکینز (Box-Jenkins) در سال ۱۹۷۰ ارایه شد (۱۰، ۱۱). یک مدل آریما ترکیب خطی از خطاهای گذشته و مقادیر گذشته یک سری ایستا می‌باشد. این مدل با ۳ پارامتر p ، q و d معرفی می‌شود که به ترتیب عبارتند از: مرتبه مؤلفه اتورگرسیون، مرتبه مؤلفه میانگین متحرک و مرتبه تفاضل‌گیری لازم برای ایستایی و در صورتی که $d=0$ باشد، مدل $ARIMA(p,d,q)$ به مدل $ARMA(p,q)$ تبدیل می‌شود. مدل کلی آریما به صورت معادله (۱) می‌باشد (۱۲، ۱۳):

$$y_t = C + \sum_{i=1}^p \varphi_i y_{t-i} + \sum_{i=1}^q \theta_i u_{t-i} + \varepsilon_t$$

فرمول ۱: مدل کلی آریما

که در آن y_t ، c ، φ_i ($i = 1, \dots, p$)، θ_i ($i = 1, \dots, q$)، u_{t-i} و ε_t به ترتیب نمایانگر سری زمانی، ضریب ثابت، پارامترهای مدل اتورگرسیون، پارامترهای مدل میانگین متحرک، وقفه‌های p ام متغیر وابسته، وقفه‌های q ام خطای گذشته و خطای پیش‌بینی مدل می‌باشد (۱۱). در این پژوهش از روش مدل‌سازی آریما که شامل سه مرحله شناسایی مدل، تخمین و بازبینی تشخیص مدل می‌باشد استفاده شد. در مرحله شناسایی، پس از پردازش و بررسی اطلاعات، باید نسبت به ایستایی (stationary) داده‌ها اطمینان حاصل کرد. لذا ابتدا فرض ایستایی داده‌ها با استفاده از آزمون‌های مرسوم دیکی - فولر تعمیم یافته (Augmented Dicky- Fuller) و فیلپس پرون (Philips-Perron) انجام پذیرفت. جهت شناسایی نوع و مرتبه مدل، نمودارهای خود همبستگی (Autocorrelation = AC) و خود همبستگی جزئی (Partial Autocorrelation = PAC) به کار می‌رود. در مرحله تخمین و آزمون پارامترهای مدل نیز از روش حداقل مربعات (Least Squares = LS) استفاده شد و معنادار بودن ضرایب در سطح اطمینان ۹۵٪ بررسی گردید و سپس جهت انتخاب مدل مناسب معیارهای اطلاعات آکائیک (Akaike info criterion = AIC)، معیار اطلاعات شوارتز (Schwartz criterion = SC)، مجموع مربعات خطا (Sum Square Error = SSE) و آماره دوربین واتسون



شکل ۱: ساختار شبکه عصبی مصنوعی با قانون یادگیری پس انتشار


صفر را رد کرد لذا سری مربوط به پلاکت O^+ دارای ریشه واحد نیست و ایستا می‌باشد. به طور مشابه ایستایی دیگر پلاکت‌ها نیز بررسی شد و کلیه آن‌ها در سطح ایستا بودند، لذا سری‌ها نیاز به تفاضل‌گیری نداشته و مرتبه تفاضل‌گیری برای همه موارد صفر می‌شد ($d=0$)، بنابراین مدل‌های $ARIMA(p,d,q)$ به مدل‌های $ARMA(p,q)$ تبدیل شدند. برای شناسایی نوع و مرتبه مدل مربوط به پلاکت O^+ نمودارهای AC و PAC هر دو دارای روند کاهشی نمایی می‌باشند، لذا مدل مربوط به این نوع پلاکت به $ARMA(p,q)$ بسیار نزدیک است (شکل ۳).

برای بررسی صحت و درستی این موضوع، ترکیبات مختلف از وقفه‌های AR و MA بررسی شد. با توجه به شکل ۳، برای پلاکت O^+ تعداد وقفه‌های $p=1, 2, \dots, 7$ ، $q=1, 2, \dots, 10$ و $d=0$ در نظر گرفته شد که در مجموع شامل ۸۷ مدل می‌باشد. در مرحله تخمین و آزمون پارامترهای تعیین شده، از بین ۸۷ مدل موجود برای پلاکت O^+ ، تنها مدل‌های معنادار را پذیرفتیم. مدل‌هایی معنادار می‌باشند که دو شرط لازم برای پذیرفته شدن را دارند، یعنی هم ضرایب مدل‌ها در بازه $[-1, 1]$ قرار دارند و هم ضرایب آن‌ها معنادار و لذا مخالف صفر می‌باشند ($0.05 < p \leq 0.8$). به این صورت مدل‌های پذیرفته شده و رد شده از هم تفکیک شدند. از میان مدل‌های پذیرفته شده، کوچک بودن معیارهای اطلاعاتی AIC و SC ، مقدار کوچک SSE و نزدیک بودن معیار DW به عدد ۲، مبنای انتخاب

لذا لایه ورودی، مربوط به اطلاعات سری زمانی تقاضا در زمان‌های قبل می‌باشد. لایه خروجی، میزان تقاضای پلاکت روزانه را پیش‌بینی می‌کند. لایه مخفی (پنهان) شامل تعداد مناسبی نورون می‌باشد که این نورون‌ها بر مبنای کمترین میزان میانگین مربعات خطا (MSE) انتخاب می‌شود. از مجموع داده‌های موجود در بازه زمانی فوق برای هر نوع پلاکت، ۷۰٪ داده‌ها برای آموزش ($Training$) شبکه عصبی، ۱۵٪ برای اعتبارسنجی ($Validation$) و ۱۵٪ دیگر برای آزمون ($Test$) شبکه استفاده گردیده است. تنظیمات مربوط به تابع محرک ($Transfer Function$) در لایه مخفی و لایه خروجی برای هر نوع پلاکت به ترتیب تابع سیگموئید ($Sigmoid$) و تابع خطی ($Purelin$) می‌باشد.

یافته‌ها

نمودار سری زمانی مورد استفاده در مدل آریما جهت پیش‌بینی تقاضای پلاکت خون نوع O^+ در شکل ۲ نشان داده شده است. به دلیل زیاد بودن انواع پلاکت و محدودیت فضا، در این مقاله تنها محاسبات مربوط به پلاکت نوع O^+ آورده شده است و بقیه محاسبات به طور مشابه می‌باشد. ابتدا ایستایی سری‌ها توسط آزمون‌های دیکی فولر و فیلیپس پرون برای پلاکت O^+ محاسبه شد. مقدار قدر مطلق آماره t در هر دو آزمون به ترتیب ۱۱/۳۴۷ و ۴۱/۶۸۷ می‌باشد که از مقدار بحرانی آزمون (۲/۸۶۲) در سطح اطمینان ۹۵٪ بیشتر است. بنابراین می‌توان فرض



شکل ۲: نمودار سری زمانی برای پلاکت نوع O^+

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob
		1	0.174	0.174	55.262	0.000
		2	0.151	0.125	97.169	0.000
		3	0.126	0.085	126.31	0.000
		4	0.099	0.052	144.28	0.000
		5	0.093	0.048	160.16	0.000
		6	0.110	0.067	182.54	0.000
		7	0.145	0.098	220.85	0.000
		8	0.094	0.030	237.21	0.000
		9	0.085	0.024	250.62	0.000
		10	0.081	0.025	262.79	0.000
		11	0.037	-0.019	265.27	0.000
		12	0.036	-0.009	267.64	0.000
		13	0.072	0.036	277.23	0.000
		14	0.073	0.030	287.06	0.000
		15	0.008	-0.042	287.19	0.000
		16	0.035	0.001	289.41	0.000
		17	0.056	0.031	295.29	0.000
		18	0.049	0.024	299.66	0.000
		19	0.064	0.034	307.16	0.000
		20	0.071	0.033	316.54	0.000

شکل ۳: نمودار خود همبستگی و خود همبستگی جزئی برای پلاکت نوع O^+

بنابراین همبستگی بین اجزای اخلاص مدل وجود ندارد (۱۹). پس مدل $ARIMA(1,0,1)$ صحیح انتخاب شده است و بهترین مدل برای پیش‌بینی پلاکت O^+ می‌باشد (جدول ۱). به طور مشابه برای انواع دیگر پلاکت‌ها همین روند طی شده و مدل نهایی برای هر نوع ثبت گردید (جدول ۲). برای انتخاب مناسب‌ترین مدل شبکه عصبی برای پیش‌بینی تقاضای پلاکت، معماری‌های متفاوتی از شبکه با تعداد لایه‌های پنهان (بین ۲ تا ۱۵ نورون)، ۱۳ متغیر ورودی و ۱ متغیر خروجی بررسی شدند و در نهایت مدلی با کمترین


بهترین مدل آریمای می‌باشد، که در اینجا مدل $(1,0,1)$ $ARIMA$ برای تمامی معیارهای ذکر شده با دارا بودن $SSE = 30/3779$ ، $SC = -1/2429$ ، $AIC = -1/2519$ ، $DW = 1/999$ ارجح است. برای بررسی صحت این موضوع، تشخیص استقلال پسماند مدل انتخابی توسط آزمون $Ljung-Box$ انجام پذیرفت (۱۸) (جدول ۱). در هر سه وقفه ۲۴/۱۲ و ۳۶ مقدار آماره Q محاسبه شده از مقدار کای دوی جدول کوچکتر می‌باشد و یا به عبارت دیگر، احتمال آن از سطح اطمینان در نظر گرفته شده بالاتر است،

جدول ۱: آزمون Ljung-Box برای تشخیص پسماند مدل ARIMA(1,0,1) برای پلاکت نوع O⁺

مدل	وقفه	آماره Q	کای دو	درجه آزادی	p-value
ARIMA (۱,۰,۱)	۱۲	۱۴/۳۴۸	۱۴/۷	۹	۰/۰۹۹
	۲۴	۲۶/۸۴۰	۲۷/۱	۲۱	۰/۱۶۸
	۳۶	۳۵/۴۳۷	۳۵/۸	۳۳	۰/۳۴۰


جدول ۲: بهترین مدل‌های ARMA جهت پیش‌بینی تقاضای انواع پلاکت خون

نوع پلاکت	بهترین مدل	MSE	پارامترهای مدل
O ⁺	ARMA(۱,۱)	۰/۰۱۶۶	$y_t = ۰/۲۰۵ + ۰/۹۲۳y_{t-1} - ۰/۸۲۰ U_{t-1} + ۰/۱۳۳$
O ⁻	ARMA(۴,۴)	۰/۰۱۴۴	$y_t = ۰/۰۷۲ - ۰/۴۶۲y_{t-1} - ۰/۰۷۴ y_{t-2} + ۰/۴۲۹ y_{t-3} + ۰/۹۱۱y_{t-4} + ۰/۴۹۶ U_{t-1} + ۰/۱۴۷ U_{t-2} - ۰/۳۶۸ U_{t-3} - ۰/۸۴۸U_{t-4} + ۰/۱۲۲$
A ⁺	ARMA(۵,۳)	۰/۰۲۳۶	$y_t = ۰/۱۷۸ - ۰/۳۱۳y_{t-1} + ۰/۴۳۶ y_{t-2} + ۰/۹۷۶ y_{t-3} - ۰/۰۹۵y_{t-4} - ۰/۰۸۳y_{t-5} + ۰/۴۳۲U_{t-1} - ۰/۲۶۴ U_{t-2} - ۰/۹۲۱ U_{t-3} + ۰/۱۶۰$
A ⁻	ARMA(۱,۱)	۰/۰۱۳۲	$y_t = ۰/۰۴۴ + ۰/۸۴۶y_{t-1} - ۰/۷۸۲U_{t-1} + ۰/۱۱۶$
B ⁺	ARMA(۲,۲)	۰/۰۲۸۲	$y_t = ۰/۱۹۴ - ۰/۱۰۷y_{t-1} + ۰/۸۶۷ y_{t-2} + ۰/۲۴۰ U_{t-1} - ۰/۷۵۵ U_{t-2} + ۰/۱۷۴$
B ⁻	ARMA(۱,۱)	۰/۰۰۵۲	$y_t = ۰/۰۲۲ + ۰/۸۹۴y_{t-1} - ۰/۸۲۱U_{t-1} + ۰/۰۷۳$
AB ⁺	ARMA(۱,۱)	۰/۰۱۵۹	$y_t = ۰/۰۷۸۲ + ۰/۹۰۵y_{t-1} - ۰/۸۲۸U_{t-1} + ۰/۱۲۸$
AB ⁻	ARMA(۱,۱)	۰/۰۰۳۸	$y_t = ۰/۰۱۹ - ۰/۹۷۲y_{t-1} + ۰/۹۸۴U_{t-1} + ۰/۰۶۲$

شکل ۴: معماری مدل شبکه عصبی (۱۳:۷:۱) برای پلاکت نوع O⁺

جدول ۳: بهترین مدل شبکه عصبی برای انواع پلاکت خون بر حسب معیار MSE

مشخصات	O ⁺	O ⁻	A ⁺	A ⁻	B ⁺	B ⁻	AB ⁺	AB ⁻
معماری شبکه	(۱۳:۷:۱)	(۱۳:۵:۱)	(۱۳:۸:۱)	(۱۳:۵:۱)	(۱۳:۷:۱)	(۱۳:۹:۱)	(۱۳:۸:۱)	(۱۳:۵:۱)
MSE	۰/۰۰۹۸	۰/۰۰۸۶	۰/۰۱۷۵	۰/۰۰۸۵	۰/۰۱۶۰	۰/۰۰۳۹	۰/۰۱۱۴	۰/۰۰۳۰



شکل ۵. مقایسه روش‌های بیان شده برای پیش‌بینی پلاکت نوع O+

بیشتر مطابق با روند واقعی داده‌ها انجام می‌دهد.

بحث

مطالعه حاضر با به کارگیری مدل‌های کاربردی شبکه عصبی مصنوعی و آریمما، سعی در پیش‌بینی دقیق میزان تقاضا و متعاقباً کاهش عدم قطعیت موجود در آن دارد. در ابتدا برای مدل‌سازی با روش آریمما، پس از بررسی فرض ایستایی داده‌ها توسط آزمون‌های دیکی فولر و فیلپس پرون، هر ۸ نوع پلاکت خون در سطح ایستادند و مرتبه تفاضل‌گیری آن‌ها صفر بود. در مرحله تعیین نوع و مرتبه مدل با استفاده از نمودارهای AC و PAC و ترکیب مناسب تعداد وقفه‌ها، تعداد کل مدل‌های موجود برای هر نوع پلاکت محاسبه گردید. در مرحله تخمین و آزمون پارامترها از میان کل مدل‌های موجود، تنها مدل‌های معنادار که هم ضرایب آن‌ها در بازه $[-1, 1]$ و هم $p \leq 0.05$ پذیرفته شدند.

سپس از میان مدل‌های پذیرفته شده با توجه به معیارهای AIC، SC، SSE، DW و آزمون Ljung-Box بهترین مدل آریمما برای هر نوع پلاکت مشخص گردید (جدول ۲). در ادامه ساختارهای متعدد شبکه عصبی پرسپترون چند لایه برای هر نوع پلاکت، با تغییر تعداد نورون‌های لایه پنهان از ۵ تا ۱۵ نورون، ۱۳ متغیر ورودی، ۱ متغیر خروجی و استفاده از ۷۵٪ داده‌ها برای فرآیند آموزش شبکه و ۱۵٪ داده‌ها برای آزمون شبکه مورد ارزیابی قرار گرفت و مدلی با کمترین میزان MSE به عنوان

مقدار MSE انتخاب گردید (جدول ۳). معماری مدل شبکه عصبی (۱۳:۷:۱) برای پلاکت نوع O⁺ در شکل ۴ نشان داده شده است.

نتایج به دست آمده نشان می‌دهد که دقت پیش‌بینی مدل‌های فوق با توجه به معیار MSE در شبکه عصبی بالاتر از سایر روش‌ها می‌باشد (جدول ۲ و ۳ و شکل ۵). همان‌طور که مشاهده می‌شود، شبکه عصبی برخلاف روش ARIMA و روند فعلی سازمان، نسبت به تغییرات موجود در روند تقاضا بسیار حساس بوده و پیش‌بینی را با دقت بالاتری انجام می‌دهد (شکل ۵). در همه گروه‌های پلاکت، به استثناء نوع AB⁻ که در آن هر دو مدل ANN و ARIMA دقت تقریباً یکسانی داشتند، در باقی گروه‌ها برتری روش ANN نسبت به ARIMA ثابت شد. دقت میانگین مربوط به MSE دو مدل ANN و ARIMA، برای انواع پلاکت عبارتند از: O⁺ (0.0048 ± 0.0132)، O⁻ (0.0041 ± 0.0115)، A⁺ (0.0043 ± 0.0205)، A⁻ (0.0033 ± 0.0108)، B⁺ (0.0086 ± 0.0221)، B⁻ (0.0009 ± 0.0045)، AB⁺ (0.0031 ± 0.0136)، AB⁻ (0.0005 ± 0.0034) که عدد اول بیانگر میانگین خطا و عدد دوم نشان‌دهنده انحراف معیار خطای دو مدل می‌باشد. با توجه به دقت میانگین پایین ذکر شده مشخص می‌شود که هر دو مدل ANN و ARIMA با دقت خوبی پیش‌بینی تقاضا را انجام می‌دهند اما باز هم با توجه به ماهیت ذاتی و قابلیت یادگیری تطبیقی و تعمیم شبکه عصبی مصنوعی، این روش تغییرات تقاضا را بهتر لحاظ نموده و پیش‌بینی را

جدول ۴: مقایسه میزان MSE روش‌های مذکور

نوع پلاکت	میزان MSE		
	روند فعلی سازمان	ARIMA	ANN
O ⁺	۰/۱۶۳	۰/۰۱۶۶	۰/۰۰۹۸
O ⁻	۰/۵۴۱	۰/۰۱۴۴	۰/۰۰۸۶
A ⁺	۰/۸۲۱	۰/۰۲۳۶	۰/۰۱۷۵
A ⁻	۰/۳۳۵	۰/۰۱۳۲	۰/۰۰۸۵
B ⁺	۰/۶۶۹	۰/۰۲۸۲	۰/۰۱۶۰
B ⁻	۰/۳۰۳	۰/۰۰۵۲	۰/۰۰۳۹
AB ⁺	۰/۵۴۵	۰/۰۱۵۹	۰/۰۱۱۴
AB ⁻	۰/۲۹۲	۰/۰۰۳۸	۰/۰۰۳۰

مدل بهینه انتخاب گردید (جدول ۳). نتایج MSE روش‌های مذکور در جدول ۴ ادغام شده است.

نتایج به دست آمده نشانگر دقت بالای مدل‌های شبکه عصبی مصنوعی و سپس آریمای نسبت به روند فعلی سازمان می‌باشد. در همه گروه‌های پلاکت، به استثناء نوع AB⁻ که در آن دو مدل ANN و ARIMA دقت تقریباً یکسانی داشتند، در باقی گروه‌ها برتری روش ANN نسبت به ARIMA و روند فعلی ثابت شد (جدول ۴). دقت میانگین با توجه به MSE برای دو مدل ANN و ARIMA نیز نمایانگر دقت پایین و کارایی خوب این دو مدل در پیش‌بینی میزان تقاضا می‌باشد، که عبارتند از: O⁺ (۰/۰۰۴۸ ± ۰/۰۱۳۲)، O⁻ (۰/۰۱۱۵ ± ۰/۰۰۴۱)، A⁺ (۰/۰۰۴۳ ± ۰/۰۲۰۵)، A⁻ (۰/۰۱۰۸۵ ± ۰/۰۰۳۳)، B⁺ (۰/۰۰۸۶ ± ۰/۰۲۲۱)، B⁻ (۰/۰۰۴۵ ± ۰/۰۰۰۹)، AB⁺ (۰/۰۰۳۱ ± ۰/۰۱۳۶)، AB⁻ (۰/۰۰۳۴ ± ۰/۰۰۰۵). همان‌طور که ذکر شد، روند فعلی برای پیش‌بینی تقاضای پلاکت در سازمان انتقال خون استان استفاده از روش میانگین‌گیری می‌باشد، که یکی از معایب استفاده از این روش حساس نبودن آن نسبت به تغییرات تقاضا است. در واقع این روش تغییرات تقاضا را در گذشته دور و نزدیک یکسان در نظر می‌گیرد که این مسأله در شکل ۵ کاملاً مشهود است (۲۰). روش آریمای با وجود این که مانند روند فعلی سازمان سیر خطی را طی می‌کند اما عملکرد بهتری نسبت به روند فعلی سازمان دارد (شکل ۵ و جدول ۴). در میان روش‌های مذکور، روش

شبکه عصبی مصنوعی حساسیت بالاتری را نسبت به تغییرات تقاضا و روند واقعی داده‌ها نشان می‌دهد (شکل ۵). علت این امر ماهیت و ویژگی‌های منحصر به فرد روش شبکه عصبی مصنوعی به خصوص قابلیت یادگیری تطبیقی و تعمیم آن می‌باشد، که پس از آموزش، شبکه می‌تواند در مقابل یک ورودی آموزش داده نشده قرار گیرد و یک خروجی مناسب ارائه نماید (۷).

فورچ و کاپلیو (۲۰۱۶) در پژوهش خود به پیش‌بینی تقاضای ماهانه خون در مرکز خون نیویورک پرداختند. با استفاده از مدل‌های MA، ES، ARMA و VARMA روش بهینه برای پیش‌بینی تقاضای ماهانه خون را تعیین کردند، نتایج نشان داد دقت مدل‌های ARMA و سادگی این روش نسبت به VARMA، بهترین مدل جهت پیش‌بینی تقاضای خون می‌باشد (۶). فیلو و همکاران (۲۰۱۳) جهت بهبود برنامه‌ریزی و ایجاد روند موجودی متعادل، به پیش‌بینی تقاضا برای توزیع اجزای خون یک زنجیره تامین پرداختند. آن‌ها برای پیش‌بینی اجزای خون از مدل‌های BJ-SARIMA استفاده نمودند. مدل‌های BJ-SARIMA نشان‌دهنده مدل تک متغیره ضربی فصلی از روش BOX-Jenkins و ARIMA است.

نویسندگان مقاله معتقدند استفاده از مدل‌های BJ-SARIMA به جای روش‌های سنتی میانگین متحرک با وقفه هفته‌ای، کارایی و دقت برنامه‌ریزی‌ها را بهبود می‌دهد (۲۱). فیلو و همکاران (۲۰۱۲) در پژوهش خود با

مرکز را محاسبه نمود. مطالعه حاضر را می‌توان با سایر روش‌های شبکه عصبی، شبکه عصبی پویا (NARX)، شبکه عصبی فازی (ANFIS)، و هم چنین ترکیب این شبکه با الگوریتم‌های فرا ابتکاری نیز بررسی کرد. در مواردی که رابطه میان تقاضاهای انواع پلاکت (نوع پلاکت جایگزین) مطرح باشد، به خصوص در بیمارستان‌ها که این جایگزینی‌ها بسیار بیشتر است، می‌توان از مدل‌های پیش‌بینی چند متغیره VARMA استفاده نمود.

نتیجه‌گیری

نتایج این مطالعه نشانگر دقت بالای مدل‌های شبکه عصبی مصنوعی و سپس آریمای در پیش‌بینی تقاضای پلاکت خون می‌باشد. لذا استفاده از این مدل‌ها و به ویژه مدل شبکه عصبی مصنوعی به دلیل حساسیت بالاتر آن نسبت به تغییرات تقاضا، جهت پیش‌بینی تقاضا به جای روش‌های پیش‌بینی آماری رایج در مراکز انتقال خون توصیه می‌شود.

تشکر و قدردانی

در پایان از آقای دکتر صانعی مقدم و پرسنل محترم سازمان انتقال خون استان سیستان و بلوچستان که ما را در انجام این مطالعه یاری دادند، صمیمانه تشکر و قدردانی می‌نمایم.

ارایه یک ابزار محاسباتی، به پیش‌بینی تقاضای اجزای خون در زنجیره تامین پرداختند. در این مطالعه به جای اتخاذ روش میانگین متحرک بر پایه هفته‌ای، یک مدل پارامتری پیچیده‌تر بر اساس BOX-Jenkins پیشنهاد شد. نتایج این مقاله بر بهتر بودن روش اتخاذ شده نسبت به میانگین متحرک تاکید دارد (۲۲). در مقایسه با تحقیقات فیلو و همکاران (۲۰۱۳ و ۲۰۱۲) و کاپلیو و همکاران (۲۰۱۶) که پیش‌بینی تقاضای خون را با روش‌های خطی آماری و مدل‌های BOX-Jenkins انجام داده‌اند، مطالعه حاضر با بهره‌گیری از مدل‌های ARIMA و به ویژه شبکه عصبی مصنوعی به پیش‌بینی دقیق‌تر میزان تقاضای پلاکت پرداخته و نتایج نشان می‌دهد که هر دو مدل از دقت بالایی برخوردارند و به ویژه شبکه عصبی مصنوعی حساسیت بالاتری نسبت به تغییرات تقاضا و روند تاریخی موجود در داده‌ها دارد. بنابراین از آن جایی که هر چه پیش‌بینی تقاضا دقیق‌تر باشد، میزان عدم قطعیت موجود در تقاضا کاهش می‌یابد، لذا این روش‌ها می‌توانند جایگزین مناسبی به جای روش‌های رایج در مرکز انتقال خون باشند و میزان تقاضا را با دقت بهتری پیش‌بینی نمایند.

مدل‌های نهایی و پارامترهای موجود در این پژوهش صرفاً برای مرکز خون مورد مطالعه می‌باشد. نتایج این مطالعه برای سایر مراکز خون قابل استفاده نیست و تنها می‌توان با تعمیم این مدل‌ها به دیگر مراکز، نتایج خاص هر

References:

- 1- Stanger SH, Yates N, Wilding R, Cotton S. Blood Inventory Management: Hospital Best Practice. Transfus Med Rev 2012; 26(2): 153-63.
- 2- Privett N, Gansalvez D. The top ten global health supply chain issues: perspectives from the field. Operations Research for Health care 2014; 3(4): 226-30.
- 3- Scott AJ. Dynamic Location- allocation system: Some basic planning strategies. Environment and planning 2011; 3(1): 73-82.
- 4- Arabzadeh E, Shirazi M, Qomi SM. [Presenting a multi-period optimization model for planning the production and distribution of blood platelets in probable conditions]. The International Conference on New Research in Industry and Mechanical Engineering 2015.
- 5- Chopra S, Meindl P. Supply Chain Management: Strategy, Planning, and Operation, Pearson. 3rd ed. New Jersey: Upper Saddle River; 2013. p. 128.
- 6- Fortsch SM, Khapalova EA. Reducing Uncertainty in demand for blood. Operations Research for Health 2016; 9: 16-28.
- 7- Menhaj MB. [Computational Intelligence Fundamentals of Neural Networks]. 1st ed. Tehran; Amirkabir University of Technology publication; 2008. p. 21-38.
- 8- Jafar Nezhad A, Soleimani M. Demand forecast for medical equipment (CT scan) based on artificial neural networks and the ARIMA method. Journal of Economic Research and Policies 2011; 19(57): 171-198. [Article in Farsi]
- 9- Fausett L. Fundamentals of neural networks: architectures, algorithms, and applications. USA: Prentice-Hall; 1994. p. 33.

- 10- Box GE, Jenkins GM, Reinsel GC, Ljung GM. Time Series Analysis: Forecasting and Control. 5th ed. New Jersey: John Wiley & Sons; 2016. p. 94.
- 11- Saadat A, Mokhtarpour M, Norouzi Z, Salehi H. The Usage of S-Plus in Statistical Analysis. 1st ed. Isfahan: Jihad University Publication; 2010. p. 112-20. [Persian]
- 12- Javan A, Zamani M, Ghanbari A, Beyari L. Demand forecast and seasonal storage of natural gas during the fifth development plan using Neural Network and ARIMA. Journal of Energy Economics 2012; 9(34): 49-70. [Article in Farsi]
- 13- Ahrabi F, Khosravinejad A. Inventory Control. 1st ed. Tehran: Noore Elm and Economic Sciences University; 2012. p. 296-8. [Persian]
- 14- Abrishami H. Applied Econometrics and New Approaches. 1st ed. Tehran: Tehran University; 2001. p. 161-24. [Persian]
- 15- Fathi M, Osgoe FZ. Matlab Programming With GUI and Special Toolboxes: Curve Fitting-Neural Network-Optimization-Fuzzy logic-Image processing. 1st ed. Tehran: Nashreloom; 2016. p. 524-37. [Persian]
- 16- Golestani SH, Gorhini M, Abbasi F. Comparison of the ability to predict VAR, ARMA and neural networks models: OPEC's global oil demand. J Environ Energy 2012; 1(12): 145-68. [Article in Farsi]
- 17- Kia M. Neural Networks in MATLAB. 1st ed. Tehran: Kian Rayaneh Sabz Publication; 2008. p. 42-3. [Persian]
- 18- Moradi A. The Usage EvIEWS In Econometrics. 3rd ed. Tehran: Jihad University Publication; 2009. p. 48-50. [Persian]
- 19- Raskhi S, Samimi A, Ersi Z, Sharazi M. Exchange rate fluctuation and fluctuations in stock returns in Iran: using multivariate GARCH. Quarterly Journal of Economics 2012; 10(2): 99-118. [Article in Farsi]
- 20- Filho OS, Carvalho MA, Cezarino W, Silva R, Salviano G. Demand Forecasting for Blood Components Distribution of a Blood Supply Chain. IFAC Proceedings Volumes 2013; 46(24): 565-71.
- 21- Hassanpour J, Poor Moeid S. [Inventory Control]. 2nd ed. Tehran: Azadeh Publication; 2012. p. 531-5.
- 22- Filho OS, Cezarino W, Salviano GR. A Decision-making Tool for Demand Forecasting of Blood Components. IFAC Proceedings Volumes 2012; 45(6): 1499-1504.

Original Article

A Demand Forecasting Model for the Blood Platelet Supply Chain with Artificial Neural Network Approach and Arima Models

Firouzi Jahantigh F.¹, Fanoodi B.¹, Khosravi S.^{2,3}

¹Shahid Nikbakht Engineering College, University of Sistan and Baluchestan, Zahedan, Iran

²Blood Transfusion Research Center, High Institute for Research and Education in Transfusion Medicine, Tehran, Iran

³Zahedan Educational Regional Blood Transfusion Center, Zahedan, Iran

Abstract

Background and Objectives

One of the major issues in global healthcare systems is the issue of improving supply chain performance and uncertainties in demand. The aim of this study is to forecast blood platelet demand with artificial neural network and Arima Models in the blood transfusion supply chain in Sistan and Baluchistan province.

Materials and Methods

In this applied study, the data on demand for 8 types of blood platelets were collected from the Zahedan Blood Center between 2011 and 2015. Then, using artificial neural network models and ARIMA models, daily demand forecasts were made. Then, according to MSE performance evaluation criteria, the results of the above-mentioned methods were compared. The data were analyzed by MetlabR2016b and Eviews 6 softwares.

Results

The results of this study indicate the high accuracy of neural network models followed by Arima compared to that calculated in the current profile of IBTO. The average accuracy according to MSE of the two models for platelet types are: O⁺ (0.0132±0.0048), O⁻ (0.0115 ± 0.0041), A⁺ (0.0205 ± 0.0043), A⁻ (0.0108 ± 0.0033), B⁺ (0.0221 ± 0.0086), B⁻ (0.0045 ± 0.0009), AB⁺ (0.0136 ± 0.0031), AB⁻ (0.0034 ± 0.0005) which represent the mean and standard deviation of the error, respectively.

Conclusions

The results of this study indicate the high accuracy of artificial neural network models followed by Arima in predicting blood platelet demand. Therefore, using artificial neural network models for prediction of demand is recommended instead of common statistical prediction methods in blood centers.

Key words: Blood Platelets, Arima, Blood Transfusion

Received: 4 Jul 2017

Accepted: 9 Oct 2017

Correspondence: Firouzi Jahantigh F., PhD in Industrial Engineering. Assistan Professor of Shahid Nikbakht Engineering College, University of Sistan and Baluchestan.
Postal Code: 1593915111, Zahedan, Iran. Tel: (+98854) 22344518; Fax: (+98854) 88905011
E-mail: firouzi@eng.usb.ac.ir