خون
فصلنامه پژوهشی
دوره ۱۴ شماره ۴ زمستان ۹۶ (۳۴۵-۳۳۵)

مقاله پژوهشی

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

فرزاد فیروزی جهانتیغ[1]، بهاره فنودی[2]، سهیلا خسروی[3]

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، پیش بینی میزان تقاضای پلاکت خون با مدل‌های شبکه عصبی مصنوعی و آریما، 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 آریما، پیش‌بینی تقاضای روزانه انجام پذیرفت. در انتها با توجه به معیار ارزیابی کارآیی MSE ، نتایج به دست آمده از روش‌های مذکور با هم مقایسه شدند. تحلیل داده‌ها با نرم‌افزارهای MatlabR2016b و Eviews 6 انجام شد.

یافته‌ها

نتایج این مطالعه حاکی از دقت بالای مدل‌های شبکه عصبی و سپس آریما نسبت به روند فعلی سازمان بود. دقت میانگین با توجه به MSE دو مدل مذکور برای انواع پلاکت عبارتند از: O^+ (۰/۰۱۳۲ ± ۰/۰۰۴۸) ، O^- (۰/۰۱۱۵ ± ۰/۰۰۴۱) ، A^+ (۰/۰۲۰۵ ± ۰/۰۰۴۳) ، A^- (۰/۰۱۰۸۵ ± ۰/۰۰۳۳)، B^+(۰/۰۲۲۱ ± ۰/۰۰۸۶) ، B^- (۰/۰۰۴۵ ± ۰/۰۰۰۹) ، AB^+ (۰/۰۱۳۶ ± ۰/۰۰۳۱) و AB^- (۰/۰۰۳۴ ± ۰/۰۰۰۵) که به ترتیب بیانگر میانگین و انحراف معیار خطا می‌باشد.

نتیجه گیری

نتایج این مطالعه نشانگر دقت بالای مدل‌های شبکه عصبی مصنوعی و سپس آریما 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، آریما، انتقال خون

تاریخ دریافت: ۹۶/۴/۱۳
تاریخ پذیرش: ۹۶/۷/۱۷

۱- مؤلف مسئول: PhD مهندسی صنایع ـ استادیار دانشکده مهندسی شهید نیکبخت ـ دانشگاه سیستان و بلوچستان ـ زاهدان ـ ایران ـ کدپستی: ۱۵۹۳۹۱۵۱۱۱
۲- دانشجوی کارشناسی ارشد مهندسی صنایع ـ دانشکده مهندسی شهید نیکبخت ـ دانشگاه سیستان و بلوچستان ـ زاهدان ـ ایران
۳- پزشک عمومی و MPH ـ مرکز تحقیقات انتقال خون ـ مؤسسه عالی آموزشی و پژوهشی طب انتقال خون و پایگاه منطقه‌ای آموزشی انتقال خون زاهدان ـ زاهدان ـ ایران

[Downloaded from bloodjournal.ir on 2026-02-01]

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(۲، ۱). از طرفی برنامه‌ریزی و 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 بالای 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 مراجعه کنندگان 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 وزمانبندی‌ها در زنجیره تامین ، پیش بینی دقیق و اطلاع ازمیزان تقاضا می‌باشد(۵). داشتن اطلاعات دقیق تقاضا به ویژه زمانی که عمر مفید محصول کوتاه است، منجر به تصمیم گیری صحیح در زمینه تامین مقدار سفارش مورد نیاز، کاهش ضایعات منابع، جلوگیری از کمبود وهزینه‌های سلامت می‌شود (۶). لذا توجه به این مسئله امری ضروری در زنجیره تامین می‌باشد. در پژوهش های پیشین، مطالعاتی در زمینه پیش بینی تقاضای خون با مدل‌های ARIMA انجام شده است. امروزه شبکه عصبی مصنوعی(Artifitial Neural Nets = ANN) که یکی از مولفه‌های هوش محاسباتی می‌باشد، جایگاه ویژه ای در حوزه‌های مختلف علوم و تحقیقات یافته‌اند (۷). این شبکه ها به دلیل هوشمند بودن، سرعت بالای پردازش داده‌ها، قابلیت تطبیق با تغییرات محیطی، قابلیت تعمیم و مدلسازی سیستم‌های غیر خطی با پیچیدگی های زیاد از جمله ابزارهای قوی، هوشمند و توانا برای استفاده در مسائل تصمیم‌گیری‌ها مناسب می‌باشند(۹، ۸). روند فعلی برای پیش بینی 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 اریما، جهت پیش بینی میزان تقاضادر 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 آریما، 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 آریما است و توسط

[Downloaded from bloodjournal.ir on 2026-02-01]

باکس و جنکینز(Box-Jenkins) در سال ۱۹۷۰ ارایه شد (۱۱، ۱۰). 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 اتورگرسیو، مرتبه مؤلفه میانگین متحرک و مرتبه تفاضل‌گیری لازم برای ایستایی و در صورتی که d= ۰ باشد، مدل ARIMA(p,d,q) به مدل ARMA(p,q) تبدیل می‌شود. مدل کلی اریما به صورت معادله(۱) می‌باشد(۱۳، ۱۲):

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

فرمول ۱: مدل کلی آریما

که در آن y_t، c، φ_i $(i = 1, \dots, p)$، $\theta_i (i = 1, \dots, p)$، y_{t-i}، u_{t-i} و ε_t به ترتیب نمایانگر سری زمانی، ضریب ثابت، پارامترهای مدل اتورگرسیو، 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 فیلیپس پرون (Philips-Perron) انجام پذیرفت. جهت شناسایی نوع و مرتبه مدل، نمودارهای خود همبستگی (Autocorrelation =AC)و خود همبستگی جزیی(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 (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 درصورتی که مدل انتخابی نامناسب باشد، باید مورد تعدیل و اصلاح قرار گرفته و به مراحل قبل بازگردد. در انتها پس از تشخیص بهترین مدل‌های اریما، به پیش‌بینی میزان تقاضای پلاکت برای دوره بعد پرداخته می‌شود(۱۴، ۸). 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 هرلایه، تابع فعال‌سازی، خروجی هرلایه، جمله اریب و بردار وزن‌ها است(شکل ۱)(۱۷).

با کمک نرم‌افزار MATLABR2016b 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،

[Downloaded from bloodjournal.ir on 2026-02-01]

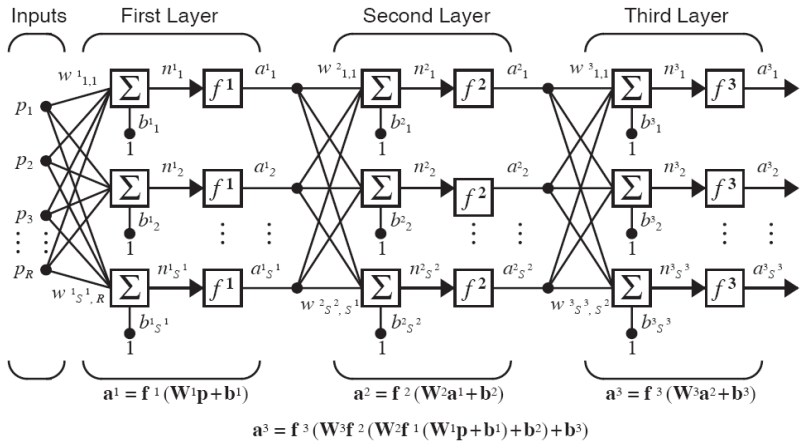

شکل ۱: ساختار شبکه عصبی مصنوعی با قانون یادگیری پس انتشار

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 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= ۰)، 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 وPAC هردو 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 MA وAR بررسی شد. با توجه به شکل ۳ ، برای پلاکت O^+ تعداد وقفه های ۷،...،۲،۱، =p ، ۱۰،...۲،۱ = q و ۰ = d 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 [۱و۱-] قرار دارند و هم ضرایب آن‌ها معنادار و لذا مخالف صفر می‌باشند(۰/۰۵ ≥p) (۸). به این صورت مدل‌های پذیرفته شده و رد شده از هم تفکیک شدند. از میان مدل‌های پذیرفته شده، کوچک بودن معیارهای اطلاعاتیAIC وSC ، مقدار کوچک SSE و نزدیک بودن معیار DW به عدد۲ ، مبنای انتخاب

[Downloaded from bloodjournal.ir on 2026-02-01]

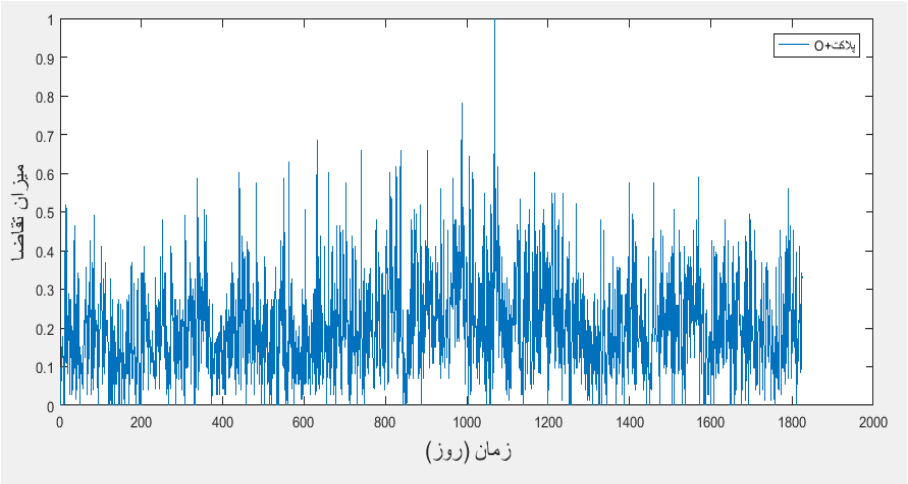

شکل ۲: نمودار سری زمانی برای پلاکت نوع O^+

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 جزیی برای پلاکت نوع O^+

بهترین مدل آریما می‌باشد، که در اینجا مدل (۱،۰،۱) ARIMA برای تمامی معیارهای ذکر شده با دارا بودن AIC = -۱/۲۵۱۹ ، SC = -۱/۲۴۲۹ ، SSE = ۳۰/۳۷۷۹ ، DW = ۱/۹۹۹ ارجح است. برای بررسی صحت این موضوع، تشخیص استقلال پسماند مدل انتخابی توسط آزمون Ljung-Box انجام پذیرفت(۱۸)(جدول۱). در هر سه وقفه ۲۴/۱۲ و ۳۶ مقدار آماره Q محاسبه شده از مقدار کای‌دوی جدول کوچکتر می‌باشد و یا به عبارت دیگر، احتمال آن از سطح اطمینان در نظر گرفته شده بالاتر است، بنابراین همبستگی بین اجزای اخلال مدل وجود ندارد(۱۹). پس مدل (۱،۰،۱) ARIMA صحیح انتخاب شده است و بهترین مدل برای پیش‌بینی پلاکت O^+ می‌باشد(جدول۱). به طور مشابه برای انواع دیگر پلاکت‌ها همین روند طی شده و مدل نهایی برای هر نوع ثبت گردید(جدول۲). 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

[Downloaded from bloodjournal.ir on 2026-02-01]

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 پیش بینی تقاضای انواع پلاکت خون

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

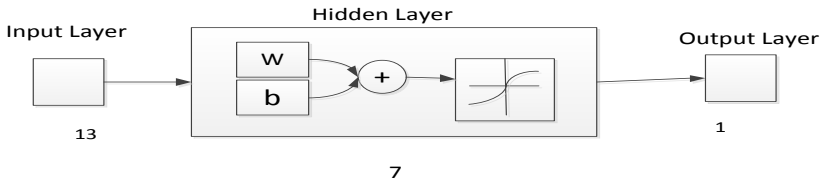

شکل ۴: معماری مدل شبکه عصبی(۱:۷:۱۳) برای پلاکت نوع O^+

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	(۱:۷:۱۳)	(۱:۵:۱۳)	(۱:۸:۱۳)	(۱:۵:۱۳)	(۱:۷:۱۳)	(۱:۹:۱۳)	(۱:۸:۱۳)	(۱:۵:۱۳)
MSE	۰/۰۰۹۸	۰/۰۰۸۶	۰/۰۱۷۵	۰/۰۰۸۵	۰/۰۱۶۰	۰/۰۰۳۹	۰/۰۱۱۴	۰/۰۰۳۰

[Downloaded from bloodjournal.ir on 2026-02-01]

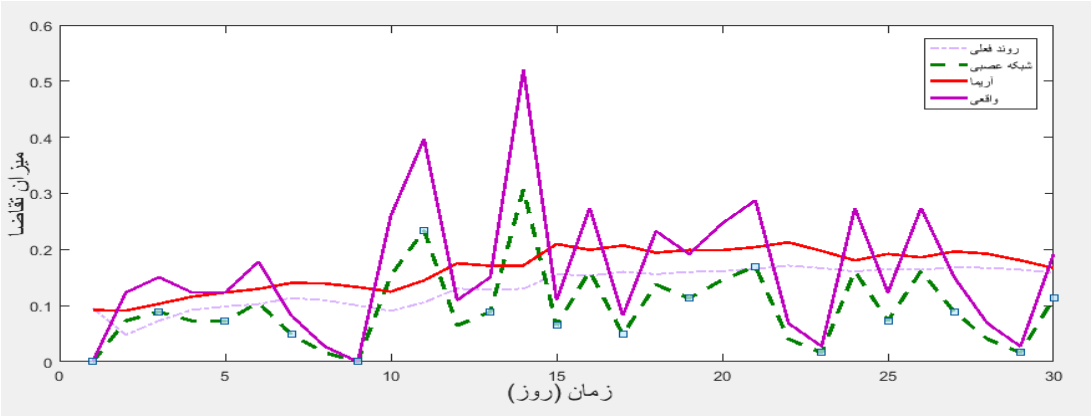

شکل ۵. مقایسه روش‌های بیان شده برای پیش بینی پلاکت نوع+ O

مقدار MSE انتخاب گردید(جدول۳). معماری مدل شبکه عصبی(۱:۷:۱۳) 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 جداول(۲ و ۳)و شکل(۵). همان طور 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(شکل۵). 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^+ (۰/۰۰۴۸ ± ۰/۰۱۳۲)، O^- (۰/۰۰۴۱ ± ۰/۰۱۱۵)، A^+ (۰/۰۰۴۳ ± ۰/۰۲۰۵) ، A^- (۰/۰۰۳۳ ± ۰/۰۱۰۸۵)، B^+ (۰/۰۰۸۶ ± ۰/۰۲۲۱) ، B^- (۰/۰۰۰۹ ± ۰/۰۰۴۵)، AB^+ (۰/۰۰۳۱ ± ۰/۱۳۶) ، AB^- (۰/۰۰۰۵ ± ۰/۰۰۳۴) 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 بیشتر مطابق با روند واقعی داده‌ها انجام می‌دهد.

بحث

مطالعه حاضر با به کارگیری مدل‌های کاربردی شبکه عصبی مصنوعی و آریما، سعی در پیش‌بینی دقیق میزان تقاضا و متعاقباً کاهش عدم قطعیت موجود در آن دارد. در ابتدا برای مدلسازی با روش آریما، پس از بررسی فرض ایستایی داده‌ها توسط آزمون‌های دیکی فولر و فیلیپس پرون، هر ۸ نوع پلاکت خون در سطح ایستا شدند و مرتبه تفاضل‌گیری آن‌ها صفر بود. در مرحله تعیین نوع و مرتبه مدل با استفاده از نمودارهای AC و PAC و ترکیب مناسب تعداد وقفه ها، 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 [۱و۱-] و هم ($p\leq$ ۰/۰۵) پذیرفته شدند.

سپس از میان مدل‌های پذیرفته شده با توجه به معیارهای AIC، SC، SSE، DW و آزمون Ljung-Box بهترین مدل آریما برای هر نوع پلاکت مشخص گردید(جدول۲). در ادامه ساختارهای متعدد شبکه عصبی پرسپترون چند لایه برای هر نوع پلاکت، با تغییر تعداد نورون‌های لایه پنهان از ۵ تا ۱۵نورون، 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

[Downloaded from bloodjournal.ir on 2026-02-01]

جدول ۴: مقایسه میزان MSE روش‌های مذکور

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

مدل بهینه انتخاب گردید(جدول۳). نتایج MSE روش‌های مذکور در جدول ۴ ادغام شده است.

نتایج به دست آمده نشانگر دقت بالای مدل‌های شبکه عصبی مصنوعی و سپس آریما 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(جدول۴). 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^- (۰/۰۰۴۱ ± ۰/۰۱۱۵) ، A^+ (۰/۰۰۴۳ ± ۰/۰۲۰۵) ، A^- (۰/۰۰۳۳ ± ۰/۰۱۰۸۵) ، B^+ (۰/۰۰۸۶ ± ۰/۰۲۲۱) ، B^- (۰/۰۰۰۹ ± ۰/۰۰۴۵) ، AB^+ (۰/۰۰۳۱ ± ۰/۰۱۳۶)، AB^- (۰/۰۰۰۵ ± ۰/۰۰۳۴). همان طور 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 درگذشته دور و نزدیک یکسان در نظر می‌گیرد که این مسأله در شکل ۵ کاملاً مشهود است(۲۰). روش آریما با وجود این که مانند روند فعلی سازمان سیر خطی را طی می‌کند اما عملکرد بهتری نسبت به روند فعلی سازمان دارد(شکل۵ و جدول۴). 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، کارآیی و دقت برنامه‌ریزی‌ها را بهبود می‌دهد(۲۱). فیلو و همکاران (۲۰۱۲) در پژوهش خود با

[Downloaded from bloodjournal.ir on 2026-02-01]

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 و۲۰۱۲) 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 روش ها می‌توانند جایگزین مناسبی به جای روش‌های رایج در مرکز انتقال خون باشند و میزان تقاضا را با دقت بهتری پیش بینی 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 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 بیمارستان ها 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 آریما 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 می‌نماییم.

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.

[Downloaded from bloodjournal.ir on 2026-02-01]

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, Osgoee FZ. Matlab Programming With GUI and Special Toolboxes: Curve Fitting-Neural Network-Optimization-Fuzzy logic-Image processing. 1st ed. Tehran: Nashreoloom; 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.

[Downloaded from bloodjournal.ir on 2026-02-01]

Sci J Iran Blood Transfus Organ 2018; 14(4): 335-345

Original Article

A Demand Forcasting 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]

[1]*Shahid Nikbakht Engineering College, University of Sistan and Baluchestan, Zahedan, Iran*
[2]*Blood Transfusion Research Center, High Institute for Research and Education in Transfusion Medicine, Tehran, Iran*
[3]*Zahedan 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 followd 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*

[Downloaded from bloodjournal.ir on 2026-02-01]