

پیش بینی میزان نیاز به انتقال خون حین عمل در جراحی فیوژن ستون فقرات با استفاده از یادگیری عمیق

مهرداد مسعودی فر

گروه بیهوشی، دانشکده پزشکی
مرکز تحقیقات بیهوشی و مراقبت‌های ویژه، بیمارستان الزهرا، دانشگاه علوم پزشکی اصفهان، اصفهان، ایران.

مریم میرحسینی

گروه بیهوشی، دانشکده پزشکی
مرکز تحقیقات بیهوشی و مراقبت‌های ویژه، بیمارستان الزهرا، دانشگاه علوم پزشکی اصفهان، اصفهان، ایران.

امیرحسین نجف آبادی پور

دانشکده فنی، دانشگاه جیرفت، جیرفت، ایران.

مهرداد نوروزی

گروه بیهوشی، دانشکده پزشکی
مرکز تحقیقات بیهوشی و مراقبت‌های ویژه، بیمارستان الزهرا، دانشگاه علوم پزشکی اصفهان، اصفهان، ایران.

نویسنده مسئول:

مریم میرحسینی

چکیده:

مقدمه: خونریزی در حین عمل جراحی یکی از مهم‌ترین و خطرناک‌ترین عوارض جراحی فیوژن ستون فقرات است. پیش‌بینی نیاز به تعداد واحدهای پک سل در جراحی فیوژن ستون فقرات می‌تواند به شناسایی بیماران در معرض خطر کمک کرده و همچنین نیاز به ترانسفیوژن و مشکلات مرتبط با آن را کاهش دهد. استفاده از تکنیک‌های قدرتمند یادگیری عمیق می‌تواند به ظرفیت پیش‌بینی بالا منجر شود.

روش‌ها: در این تحلیل، داده‌های ۳۹۴ بیمار که تحت عمل جراحی فیوژن خلفی مهره‌های کمری و توراسیک قرار گرفته‌اند، بررسی شد. ۱۹ ویژگی تأثیرگذار بر تعداد واحدهای پک سل مورد استفاده به‌عنوان ورودی استفاده شد. سپس، الگوریتم‌هایی با استفاده از سه تکنیک نوین یادگیری عمیق برای پیش‌بینی تعداد واحدهای پک سل مورد نیاز در طول عمل جراحی توسعه داده شد.

نتایج: بیماران شرکت‌کننده در این مطالعه بر اساس تعداد واحدهای پک سل تزریق شده به سه دسته تقسیم شدند. نتایج به‌دست‌آمده از سه مدل یادگیری عمیق توسعه‌یافته نشان داد که مدل شبکه عصبی بازگشتی ساده دقیق‌ترین روش را ارائه می‌دهد و مقادیر ریشه میانگین مربعات خطا و ضریب همبستگی به ترتیب ۰.۹۵ و ۰.۹ را در مقایسه با سایر مدل‌ها به‌دست آورد.

نتیجه‌گیری: روش‌های یادگیری عمیق ابزارهای قدرتمندی برای مدل‌سازی و پیش‌بینی دقیق واحدهای انتقال گلبول قرمز هستند. این توانایی به متخصصین بیهوشی و جراحان کمک می‌کند تا پیش‌بینی دقیقی از میزان نیاز به تعداد واحدهای پک سل مورد نیاز قبل از عمل جراحی، با استفاده از ویژگی‌های متعدد داشته باشند.

کلید واژه‌ها: خونریزی، یادگیری عمیق، ترانسفیوژن گلبول‌های قرمز، جراحی فیوژن مهره‌ها

۱. مقدمه

حین عمل، نیاز به انتقال خون دارند. این مسئله یکی از مشکلات شایع در جراحی‌های ستون فقرات است [۷، ۸]. اگرچه انتقال گلبول‌های قرمز ممکن است اکسیژن‌رسانی به بافت‌ها را بهبود بخشد و از کاهش خون‌رسانی به نخاع و اندام‌های حیاتی جلوگیری کند، مطالعات نشان می‌دهند که بین انتقال خون و عوارض پس از عمل ارتباط وجود دارد [۹، ۱۰]. علاوه بر این، کمبود شدید محصولات خونی به یک بحران ملی تبدیل شده است [۹]. شناسایی متغیرهای مرتبط با انتقال خون حین عمل می‌تواند به شناسایی زودهنگام بیماران پرخطر کمک کرده و به بهبود پروتکل‌های موجود برای تخصیص عاقلانه‌تر محصولات خونی منجر شود [۷]. با توجه به پیچیدگی بیماران مبتلا به مشکلات ستون فقرات و شیوع بالای عوارض، مطالعات آماری متعددی در این حوزه انجام شده است.

هوش مصنوعی پیشرفت‌های قابل توجهی در حوزه‌های مختلف، از جمله بیهوشی، داشته است. پتانسیل آن برای تحول در این زمینه از ارائه کمک‌های حین عمل تا بهبود مراقبت‌های ویژه و مدیریت درد سرپایی گسترده است [۱۱-۱۳]. در طول دهه گذشته، یادگیری عمیق^۶ به عنوان ابزاری قدرتمند برای توسعه مدل‌های پیش‌بینی بیمارمحور در جراحی ستون فقرات ظهور کرده است که قابلیت کاربرد و دقت بیشتری را ارائه می‌دهد [۱۴، ۱۵]. توانایی این روش‌ها در پردازش سریع حجم گسترده‌ای از داده‌ها، ساخت مدل‌های انعطاف‌پذیر و درک روابط پیچیده و غیرخطی که اغلب برای مدل‌های رگرسیون سنتی دور از دسترس هستند، محبوبیت روزافزون هوش مصنوعی و یادگیری عمیق را تقویت می‌کند. مطالعات متمرکز بر بیماران ستون فقرات، پتانسیل تکنیک‌های یادگیری عمیق را در دستیابی به طبقه‌بندی خطر پیش از عمل

یک روش جراحی به نام فیوژن ستون فقرات اتصال دائمی بین دو یا چند مهره ایجاد می‌کند [۱]. این درمان معمولاً در ناحیه کمری (لومبار) انجام می‌شود، اگرچه سایر سطوح ستون فقرات مانند ناحیه گردنی (سرویکال) و قفسه سینه (توراسیک) نیز ممکن است تحت این جراحی قرار گیرند. سه تکنیک جراحی مختلف برای این روش استفاده می‌شود: فیوژن خلفی^۱، فیوژن قدامی^۲ و فیوژن خلفی-قدامی^۳. از جمله مواردی که نیاز به فیوژن ستون فقرات را ایجاد می‌کنند، می‌توان به ناهنجاری‌های ستون فقرات ناشی از شرایطی مانند فلج مغزی^۴، بیماری‌های عصبی-عضلانی، اسکولیوز، تروما، تومورهای مهره‌ای، آسیب‌های مکانیکی ناشی از بی‌ثباتی ستون فقرات و برخی جراحی‌های مجدد اشاره کرد [۲-۴]. در حالی که چندین تکنیک جراحی برای فیوژن بین مهره‌ای وجود دارد، فیوژن بین مهره‌ای خلفی کمری^۵ به دلیل دسترسی کارآمد و میدان جراحی مناسب، رایج‌ترین روش مورد استفاده است [۵].

خونریزی یکی از عوارض مهم حین جراحی فیوژن ستون فقرات است که خطرات حین و پس از عمل را افزایش داده و ممکن است موفقیت کلی جراحی را به خطر بیندازد [۲، ۴، ۶]. شدت این عارضه به عوامل مختلفی از جمله نوع بیهوشی، ماهیت آسیب، روش فیوژن، تخصص جراح و ویژگی‌های خاص بیمار بستگی دارد. خونریزی بیش از حد در جراحی فیوژن کمری یکی از نگرانی‌های اصلی است [۲]. در حال حاضر، جراحی فیوژن ستون فقرات کمری در میان ۱۰ جراحی برتری قرار دارد که به دلیل خونریزی

1. Posterior fusion
2. Anterior fusion
3. Posterior-Anterior fusion
4. Cerebral Palsy
5. Posterior Lumbar Interbody Fusion (PLIF)

6. Deep Learning (DL)

کار گرفته شده است. نوآوری این مطالعه در بررسی مدل قدرتمند شبکه عصبی بازگشتی ساده برای پیش‌بینی تعداد دقیق واحدهای خون مورد نیاز است. علاوه بر این، مطالعه تأثیر ویژگی‌های مختلف بر نیاز به انتقال خون و تحلیل داده‌های پرت^{۱۱} را نیز شامل می‌شود. با استفاده از الگوریتم‌های پیش‌بینی، شناسایی بیماران پرخطر و کاهش عوارض احتمالی امکان‌پذیر می‌شود که به برنامه‌ریزی جراحی کارآمدتر و مؤثرتر کمک می‌کند.

۲. مواد و روش‌ها

۲.۱. جمع‌آوری داده‌ها

این مطالعه مورد تأیید هیئت بررسی نهادی^{۱۲} مربوطه قرار گرفت و رضایت‌نامه کتبی آگاهانه از تمامی افراد شرکت‌کننده، نماینده قانونی، والدین یا سرپرستان قانونی افراد زیر سن قانونی دریافت شد، یا هیئت بررسی نهادی الزام اخذ رضایت‌نامه کتبی را لغو کرد (تاریخ تأیید هیئت بررسی نهادی: ۱۴۰۲/۰۲/۰۵). با در نظر گرفتن ضرورت حفظ و رعایت محرمانگی اطلاعات بیماران و اصول اخلاقی مرتبط، بدیهی است که مجری ملزم به رعایت محرمانگی موارد فوق می‌باشد. بر اساس کد اخلاقی، این مطالعه مورد تأیید کمیته اخلاق بیمارستان الزهرا، دانشگاه علوم پزشکی اصفهان، به شماره MUI.MED.REC.1402.053 قرار گرفت. داده‌های این مطالعه از پرونده‌های ۵۹۹ بیمار که در بازه زمانی بهمن ۱۳۹۷ تا اسفند ۱۴۰۱ تحت عمل جراحی فیوژن کم‌ری و توراسیک در اتاق عمل بیمارستان الزهرا قرار گرفته بودند، استخراج شد. از میان این بیماران، ۲۰۳ نفر به دلیل نقص در پرونده‌هایشان از مطالعه حذف شدند. در این مطالعه، ۳۹۴ مجموعه داده شامل ویژگی‌های

بهبودیافته نشان داده‌اند [۱۶]. شناسایی بیماران پرخطر فرصتی را فراهم می‌کند تا با بهینه‌سازی پیش از عمل یا تغییر در برنامه‌ریزی جراحی، نرخ انتقال خون و عوارض مرتبط با آن کاهش یابد [۴]. شبکه‌های عصبی مصنوعی^۷ که از پیشرفته‌ترین الگوریتم‌های کامپیوتری هستند، در پیش‌بینی‌های جراحی ستون فقرات اثربخش بوده‌اند [۱۷، ۱۸]. در بیشتر مطالعات انجام‌شده در این حوزه، پیش‌بینی دقیق تعداد پک‌های سلولی مورد نیاز حین جراحی بررسی نشده است [۱۰، ۱۹]. با وجود نتایج امیدوارکننده، مطالعات کمی از الگوریتم‌های یادگیری عمیق برای آموزش مدل‌ها و شناسایی متغیرهای پرخطر مرتبط با واحدهای انتقال گلبول‌های قرمز در جراحی فیوژن ستون فقرات استفاده کرده‌اند. عدم بررسی این مسئله در مطالعات پیشین از آن جهت حائز اهمیت است که محدودیت منابع خونی در بیمارستان‌ها و عوارض انتقال خون، مسائل مهمی هستند که می‌توان با پیش‌بینی دقیق‌تر تعداد واحدهای خونی مورد نیاز قبل از عمل، آن‌ها را حل کرد. تمرکز مطالعات پیشین بیشتر بر این بوده است که آیا بیماران به طور کلی در حین یا پس از جراحی به خون نیاز دارند یا خیر.

با توجه به اهمیت پیش‌بینی و مدیریت واحدهای گلبول‌های قرمز فشرده مورد نیاز برای بهبود نتایج جراحی فیوژن ستون فقرات، این مطالعه قصد دارد با استفاده از تکنیک‌های پیشرفته یادگیری عمیق، شکاف تحقیقاتی مهمی را پر کند و واحدهای خونی لازم را به طور دقیق پیش‌بینی نماید. مدل‌های مورد استفاده در این مطالعه شامل شبکه عصبی کانولوشنال^۸، واحد بازگشتی دروازه‌دار^۹ و شبکه عصبی بازگشتی ساده^{۱۰} هستند. برای اعتبارسنجی مدل بهینه، ترکیبی از روش‌های تحلیل خطای گرافیکی و آماری به

7. Artificial Neural Networks (ANN)

8. Convolutional Neural Network (CNN)

9. Gated Recurrent Unit (GRU)

10. Simple Recurrent Neural Network (SimpleRNN)

11. Outlier

12. Institutional Review Board (IRB)

۲.۲. مدل‌سازی

شبکه عصبی پیچشی یک مدل یادگیری عمیق است که برای یادگیری خودکار و تطبیقی سلسله‌مراتب فضایی ویژگی‌ها از داده‌های ورودی طراحی شده است. این مدل به‌ویژه در پردازش داده‌های ساختاریافته به‌صورت شبکه‌ای مؤثر است، زیرا از لایه‌های پیچشی استفاده می‌کند که داده‌های ورودی را در نواحی کوچک و محلی اسکن می‌کنند. شبکه عصبی پیچشی شامل چندین لایه، از جمله لایه‌های پیچشی، لایه‌های تجمیع^{۱۵} و لایه‌های کاملاً متصل^{۱۶} است که به آن امکان می‌دهند الگوهای پیچیده و روابط میان داده‌ها را شناسایی کند [۲۰]. لایه‌های پیچشی ویژگی‌های مرتبط را استخراج می‌کنند، در حالی که لایه‌های تجمیع با کاهش ابعاد داده‌ها، کارایی مدل را افزایش می‌دهند. این ساختار باعث می‌شود که شبکه عصبی پیچشی در حل مسائل رگرسیون عملکرد بسیار خوبی داشته باشد.

واحد بازگشتی دروازه‌دار یک نوع شبکه عصبی بازگشتی است که برای مدل‌سازی وابستگی‌های داده‌های ترتیبی طراحی شده است. این مدل دارای مکانیزم‌های دروازه‌ای، از جمله دروازه به‌روزرسانی^{۱۷} و دروازه تنظیم مجدد^{۱۸} است که به مدل اجازه می‌دهد جریان اطلاعات را کنترل کرده و تعیین کند که در هر گام زمانی چه اطلاعاتی حفظ یا فراموش شوند. این معماری به واحد بازگشتی دروازه‌دار کمک می‌کند تا بر مشکل ناپدید شدن گرادیان^{۱۹} غلبه کرده و وابستگی‌های طولانی‌مدت را یاد بگیرد. واحد بازگشتی دروازه‌دار علاوه بر کارایی محاسباتی بالا، عملکردی قابل مقایسه با مدل‌های پیچیده‌تر ارائه می‌دهد [۲۱].

مدل شبکه عصبی بازگشتی ساده نوعی شبکه عصبی

جمعیت‌شناختی زیر جمع‌آوری شد:

- جنسیت (مرد، زن)
 - سن (بر حسب سال)
 - وزن بدن (کیلوگرم)
 - قد (سانتی‌متر)
 - شناسه جراح
 - سطح جراحی
 - سابقه جراحی ستون فقرات قبلی
 - تعداد سطوح جراحی شده
 - رده‌بندی انجمن بیهوشی آمریکا^{۱۳}
 - بیماری‌های همراه (دیابت، فشار خون بالا، بیماری قلبی، بیماری مزمن انسدادی ریه)
 - نسبت نرمال شده بین‌المللی^{۱۴}
 - زمان پروترومبین (بر حسب ثانیه)
 - سطح هموگلوبین (g/L)
 - هماتوکریت (%)
 - شمارش پلاکت
 - زمان ترومبوپلاستین نسبی (بر حسب ثانیه)
 - تعداد واحدهای تزریق شده خون (پک سل)
- روش‌های استخراج داده‌ها شامل بازیابی مبتنی بر سیستم و جمع‌آوری دستی بود. این مطالعه تمامی بیماران ۱۸ سال و بالاتر با نمرات رده‌بندی انجمن بیهوشی آمریکا از ۱ تا ۴ را شامل می‌شد. جدول ۱ توزیع آماری این ویژگی‌ها را ارائه می‌دهد.

15. Pooling
16. Fully Connected
17. Update Gate
18. Reset Gate
19. Vanishing Gradient Problem

13. American Society of Anesthesiologists (ASA)
14. International Normalized Ratio (INR)

۲.۴. تشخیص داده‌های پرت

داده‌های پرت^{۲۲} نقاطی هستند که به‌طور قابل‌توجهی از الگوی کلی مجموعه داده‌ها فاصله دارند و معمولاً در داده‌های واقعی مشاهده می‌شوند. وجود داده‌های پرت می‌تواند دقت و قابلیت اطمینان مدل‌های پیش‌بینی‌کننده را کاهش دهد، بنابراین شناسایی و مدیریت آن‌ها در طول توسعه مدل امری حیاتی است. یکی از روش‌های مؤثر برای تشخیص داده‌های پرت، رویکرد نفوذ^{۲۳} است، که ارزیابی می‌کند یک مشاهده خاص تا چه اندازه بر مدل برازش‌شده تأثیر می‌گذارد. این روش با محاسبه میزان انحراف مدل از داده‌های واقعی، نقاطی را که به‌طور قابل‌توجهی بر پارامترهای مدل تأثیر می‌گذارند، شناسایی می‌کند [۲۴]. زمانی که مقادیر نفوذ از یک آستانه مشخص فراتر بروند، آن مشاهدات به‌عنوان نقاط با نفوذ بالا^{۲۴} طبقه‌بندی می‌شوند. این نقاط معمولاً با افزایش عدم قطعیت همراه هستند، زیرا می‌توانند به‌طور نامتناسبی بر نتایج تحلیل تأثیر بگذارند. با شناسایی و مدیریت مناسب داده‌های پرت، استحکام مدل افزایش یافته و پیش‌بینی‌ها و تفاسیر دقیق‌تری از داده‌های اصلی ارائه می‌شود.

بازگشتی است که برای پردازش داده‌های ترتیبی استفاده می‌شود. این مدل دارای یک حالت مخفی^{۲۰} است که در هر گام زمانی با دریافت ورودی جاری و حالت مخفی قبلی به‌روزرسانی می‌شود، و این امر به آن اجازه می‌دهد وابستگی‌های درون‌توالی را ثبت کند. با این حال، مدل شبکه عصبی بازگشتی ساده در معرض مشکلاتی مانند ناپدید شدن گرادیان قرار دارد، که می‌تواند کارایی آن را در پردازش توالی‌های طولانی محدود کند. این مدل از نظر محاسباتی کارآمد است و عمدتاً در مسائل رگرسیون توالی‌های کوتاه کاربرد دارد [۲۲].

۲.۳. تحلیل حساسیت

تحلیل حساسیت یک فرآیند اساسی در مدل‌سازی است، زیرا بررسی می‌کند که چگونه تغییرات در ورودی‌های مدل می‌توانند منجر به تغییرات در خروجی‌های آن شوند. این موضوع به‌ویژه از این جهت مهم است که عدم قطعیت در پارامترهای ورودی می‌تواند به‌طور قابل‌توجهی بر عدم قطعیت نتایج مدل تأثیر بگذارد. از طریق تحلیل حساسیت، می‌توان همبستگی بین ورودی‌ها و خروجی‌های مدل را ارزیابی کرد، که این امر در شناسایی خطاها یا ناهماهنگی‌های احتمالی در ساختار مدل مفید است. یک روش قابل‌اعتماد برای انجام تحلیل حساسیت، تحلیل فاکتور ارتباطی^{۲۱} است [۲۳]. این فاکتور نشان‌دهنده قدرت رابطه بین یک ورودی و خروجی مدل است: مقدار بالاتر فاکتور ارتباطی نشان‌دهنده تأثیر آن بیشتر ورودی بر نتایج مدل می‌باشد.

22. Outliers
23. Leverage Approach
24. High Leverage Points

20. Hidden State
21. Relevancy Factor Analysis

۳. نتایج

۳.۱. توسعه مدل

ریشه میانگین مربعات خطا مرکزی به‌عنوان یک معیار نسبی نسبت به نقطه مرجع کلی محاسبه شد. یک سیستم پیش‌بینی ایده‌آل توسط نقطه‌ای با مقدار ضریب همبستگی برابر ۱ در نمودار تیلور نشان داده می‌شود. برای مدل شبکه عصبی بازگشتی ساده توسعه‌یافته در این مطالعه، مقادیر به‌دست‌آمده به شرح زیر بودند:

- انحراف معیار: ۱.۶۶
- ریشه میانگین مربعات خطا: ۰.۹۵
- ضریب همبستگی: ۰.۹

برای مقایسه مدل‌ها، شکل ۲ فراوانی تجمعی ریشه میانگین مربعات خطا را در تمامی مدل‌ها نمایش می‌دهد. نتایج نشان می‌دهند که حدود ۹۰٪ از پیش‌بینی‌های واحدهای خون تزریق شده، توسط مدل‌های توسعه‌یافته شبکه عصبی بازگشتی ساده و شبکه عصبی پیچشی دارای ریشه میانگین مربعات خطا کمتر از ۲٪ هستند. در مقابل، مدل واحد بازگشتی دروازه‌دار نرخ ضریب همبستگی ۶۵٪ را نشان می‌دهد. این یافته‌ها برتری مدل شبکه عصبی بازگشتی ساده پیشنهادی را نسبت به سایر مدل‌ها در پیش‌بینی تزریق خون تأیید می‌کنند. نتایج ارائه‌شده در اشکال ۱ و ۲ برای رتبه‌بندی مدل‌های توسعه‌یافته بر اساس دقت آن‌ها استفاده شده‌اند.

$$RNN > CNN > GRU$$

در این مطالعه، ۳۹۴ مجموعه داده برای مدل‌سازی و پیش‌بینی واحدهای پک سل مورد استفاده قرار گرفت. مدل یادگیری عمیق توسعه‌یافته شامل ۱۹ ویژگی به‌عنوان ورودی، مطابق با بخش جمع‌آوری داده‌ها بود، در حالی که متغیر هدف، تعداد واحدهای تزریق شده خون در حین عمل جراحی بود. این داده‌ها با استفاده از سه روش مختلف مورد تحلیل قرار گرفتند:

- شبکه عصبی پیچشی (CNN)
 - واحد بازگشتی دروازه‌دار (GRU)
 - شبکه عصبی بازگشتی ساده (RNN)
- برای تمامی مدل‌ها، ۷۰٪ داده‌ها برای آموزش و ۳۰٪ برای آزمون در نظر گرفته شد. به‌منظور جلوگیری از تجمع داده‌های محلی، تقسیم داده‌ها به مجموعه‌های آموزشی و آزمایشی به‌صورت تصادفی انجام شد.

۳.۲. ارزیابی صحت و دقت مدل‌های توسعه‌یافته

شکل ۱ از نمودار تیلور^{۲۵} برای تحلیل دقت و اعتبار گرافیکی مدل‌ها استفاده می‌کند. این نمودار با ادغام متغیرهای آماری مختلف، نمایش واضح‌تری از پیش‌بینی واحدهای تزریق شده خون ارائه می‌دهد. برای ارزیابی اختلاف بین داده‌های پیش‌بینی‌شده و واقعی، از معیارهای آماری زیر برای هر سه مدل شبکه عصبی پیچشی، واحد بازگشتی دروازه‌دار و شبکه عصبی بازگشتی ساده استفاده شده است:


- انحراف معیار^{۲۶}
- ریشه میانگین مربعات خطا^{۲۷}
- ضریب همبستگی^{۲۸}

25. Taylor's Diagram

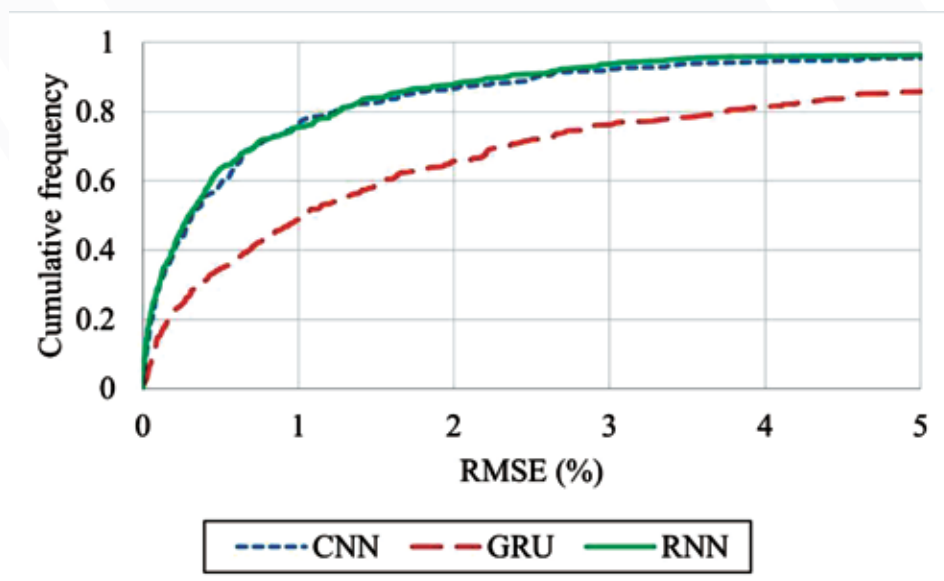
26. Standard Deviation (SD)

27. Root Mean Square Error (RMSE)

28. Correlation Coefficient (R2)



شکل ۱. نمودار تیلور مدل های توسعه یافته.



شکل ۲. فراوانی تجمعی در برابر ریشه میانگین مربعات خطا (RMSE) برای تمامی مدل های توسعه یافته.

۳.۳. دامنه کاربرد مدل

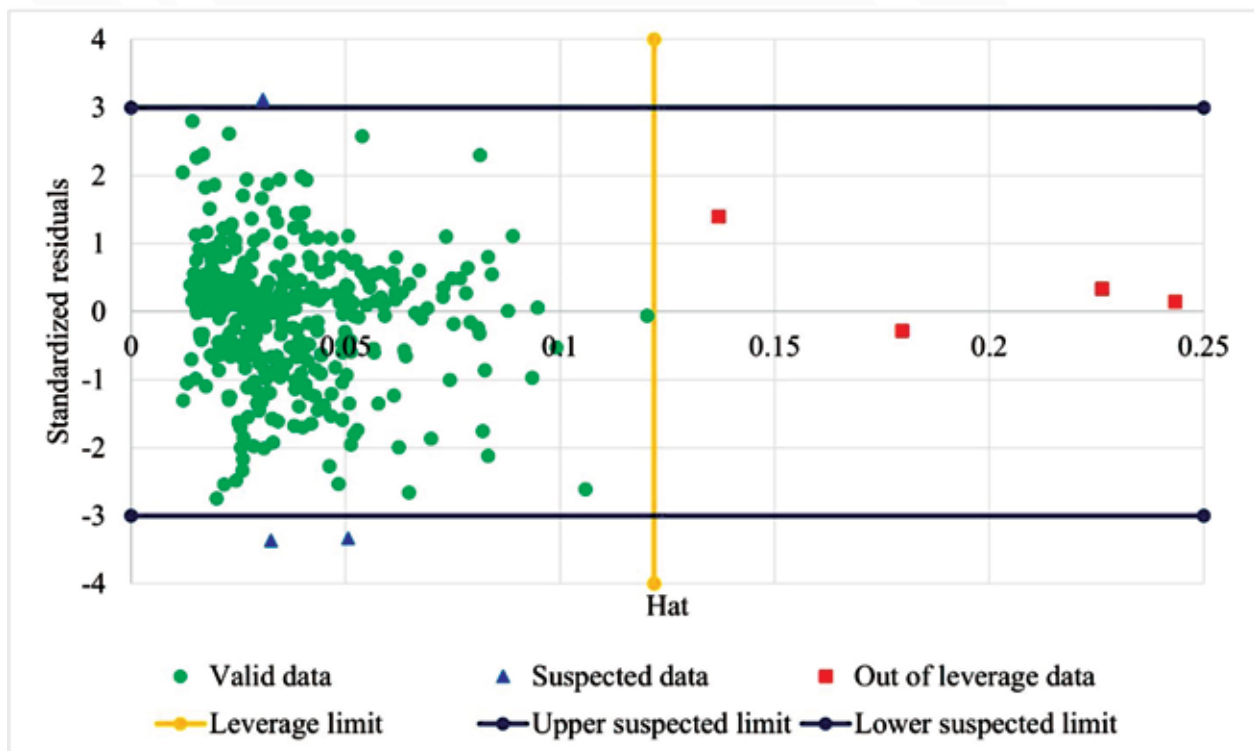
بیشتر نقاط پیش بینی شده در دامنه قابل قبول مدل (0/12) آماری و قابلیت اطمینان بالای مدل را تأیید می کند. حدود ۹۸/۲۲٪ از پیش بینی ها در این محدوده قابل قبول جای

شکل ۳ داده های پرت شناسایی شده توسط مدل شبکه عصبی بازگشتی ساده توسعه یافته را در مجموعه داده ای شامل ۳۹۴ پیش بینی برای تزریق خون نمایش می دهد.

شکل ۴ مقادیر فاکتور ارتباطی را برای پارامترهای ورودی نمایش می‌دهد. این موضوع نشان می‌دهد که تغییر در مقدار هر ورودی بر ترانسفیوژن پک سل تأثیر می‌گذارد. در میان ۱۹ پارامتر ورودی، متغیرهای شناسه جراح، زمان ترومبوپلاستین نسبی، بیماری مزمن انسدادی ریه، سطح جراحی و بیماری قلبی کمترین تأثیر را بر ترانسفیوژن پک سل دارند.


می‌گیرند. با این حال، وجود برخی داده‌های پرت اجتناب‌ناپذیر است، اما با توجه به حجم بالای داده‌های استفاده‌شده در توسعه مدل، می‌توان از آن‌ها چشم‌پوشی کرد. نقاطی که در خارج از $R < -3$ یا $R > 3$ قرار می‌گیرند، به‌عنوان نفوذ نامطلوب^۱ طبقه‌بندی می‌شوند، بدون در نظر گرفتن مقدار \hat{h} آن‌ها. هرچند که این نقاط ممکن است همچنان مقادیر پیش‌بینی‌شده دقیقی باشند، اما موقعیت آن‌ها خارج از محدوده مدل احتمالاً ناشی از حجم زیاد داده‌ها است.

1. Bad High Leverage



شکل ۳. داده‌های پرت در خروجی‌های حاصل از مدل شبکه عصبی بازگشتی ساده توسعه‌یافته.


شکل ۴ مقادیر فاکتور ارتباطی را برای پارامترهای ورودی نمایش می‌دهد. این موضوع نشان می‌دهد که تغییر در مقدار هر ورودی بر انتقال خون تأثیر می‌گذارد. در میان ۱۹ پارامتر ورودی، متغیرهای شناسه جراح، زمان ترومبوپلاستین نسبی، بیماری مزمن انسدادی ریه، سطح جراحی و بیماری قلبی کمترین تأثیر را بر انتقال خون دارند.



شکل ۴. فاکتور ارتباطی برای تأثیر ویژگی‌ها بر تعداد واحدها ترانسفیوژن پک سل.

شکل ۵ داده‌های ۳۹۴ بیمار را نمایش می‌دهد، به طوری که هر بیمار در محور افقی (شماره پرونده) نشان داده شده است و محور عمودی اختلاف بین تعداد واحدهای واقعی و پیش‌بینی شده خون برای هر بیمار را طبق پیش‌بینی مدل یادگیری عمیق شبکه عصبی بازگشتی ساده نشان می‌دهد. داده‌ها به سه گروه تقسیم شده‌اند:

- بیماران که ۰ تا ۳ واحد پک سل دریافت کرده‌اند، با رنگ سبز نشان داده شده‌اند که نشان‌دهنده سطوح خطای پایین‌تر است؛
- بیماران که ۴ تا ۷ واحد پک سل دریافت کرده‌اند، با رنگ آبی نمایش داده شده‌اند؛
- بیماران که ۸ تا ۱۱ واحد پک سل دریافت کرده‌اند، با رنگ قرمز نمایش داده شده‌اند که نشان‌دهنده سطوح خطای بالاتر است.



شکل ۵. نمودارهای توزیع خطا برای مدل شبکه عصبی بازگشتی ساده.

۴. بحث

در این مطالعه، داده‌های ۳۹۴ بیمار که تحت عمل جراحی فیوژن خلفی کمری و توراسیک قرار گرفته بودند، مورد تجزیه و تحلیل قرار گرفت. ۱۹ ویژگی تأثیرگذار از طریق تحلیل فاکتور ارتباطی شناسایی شد. با استفاده از این ویژگی‌ها، سه مدل نوین یادگیری عمیق توسعه و مقایسه شدند. نتایج به‌دست‌آمده از نمودارهای تیلور و تحلیل‌های فراوانی تجمعی نشان داد که مدل شبکه عصبی بازگشتی ساده عملکرد بهتری نسبت به مدل‌های واحد بازگشتی دروازه‌دار و شبکه عصبی پیچشی در پیش‌بینی واحدهای پک سل مورد نیاز برای بیماران داشت. این عملکرد برتر را می‌توان به توانایی شبکه عصبی بازگشتی ساده در شبیه‌سازی الگوهای ترتیبی و وابستگی‌ها در داده‌ها نسبت داد. در داده‌های بیهوشی و مراقبت‌های ویژه به‌ویژه برای

این مطالعه از الگوریتم‌های نوین یادگیری عمیق برای پیش‌بینی تعداد واحدهای پک سل مورد نیاز در طول عمل جراحی ستون فقرات استفاده کرده است. بررسی ادبیات موجود نشان می‌دهد که اگرچه مطالعات قبلی پیش‌بینی انتقال خون در زمینه‌های مختلف جراحی را مورد بررسی قرار داده‌اند، هیچ‌کدام به‌طور خاص بر پیش‌بینی تعداد دقیق واحدهای پک سل مورد نیاز تمرکز نکرده‌اند. استفاده از ابزارهای قدرتمند یادگیری عمیق برای پیش‌بینی نیاز به انتقال خون در حین عمل جراحی امری ضروری است، زیرا این امر به صرفه‌جویی در منابع خون، کاهش هزینه‌ها، و اطمینان از دسترس بودن به موقع واحدهای پک سل در طول عمل کمک می‌کند.

واحد (که با رنگ قرمز نشان داده شده‌اند)، خطای پیش‌بینی بزرگتری داشتند. این افزایش خطا ممکن است به دلیل تغییرات بیشتر در ویژگی‌های بالینی بیماران نیازمند حجم بالاتر خون باشد که مدل ممکن است در شبیه‌سازی آن‌ها با چالش مواجه شود.

۵. نتیجه‌گیری

این مطالعه مدل‌های نوین یادگیری عمیق را برای پیش‌بینی تعداد پک سل مورد نیاز در جراحی‌های ستون فقرات توسعه و ارزیابی کرد، که این کار با استفاده از ویژگی‌های مختلف پیش‌عملیاتی برای بهبود تخصیص منابع و افزایش اثربخشی هزینه‌ها در مراقبت‌های جراحی‌انجام گرفت. در میان مدل‌های آزمایش‌شده، مدل شبکه عصبی بازگشتی ساده عملکرد برتری از خود نشان داد، که احتمالاً به دلیل توانایی آن در شبیه‌سازی وابستگی‌های ترتیبی در داده‌های بیماران است، که برای پیش‌بینی دقیق نیاز به خون حیاتی است. یافته‌های این مطالعه پتانسیل الگوریتم‌های یادگیری عمیق را در بهینه‌سازی استراتژی‌های انتقال خون نشان می‌دهد و در نهایت باعث بهبود نتایج بیماران و مدیریت منابع در محیط‌های بالینی می‌شود.

با این حال، باید برخی از محدودیت‌ها نیز مورد توجه قرار گیرد، مانند استفاده از داده‌های یک مرکز و محدود بودن اطلاعات بیماران که ممکن است قابلیت تعمیم نتایج را محدود کند. تحقیقات آینده باید بر استفاده از داده‌های چندمرکزی و جمعیت بیمار بزرگتر تمرکز کنند تا دقت و کاربرد مدل تقویت شود. علاوه بر این، یکپارچه‌سازی ویژگی‌های بالینی گسترده‌تر می‌تواند عملکرد مدل را بهبود بخشد و راه را برای مدل‌های پیش‌بینی قوی‌تر در مراقبت‌های بهداشتی هموار کند.

پیش‌بینی نیازهای درون‌عملی رابطه‌های زمانی و ترتیبی ظریف بین ویژگی‌ها اغلب وجود دارد که مدل‌های شبکه عصبی بازگشتی ساده به‌ویژه در شبیه‌سازی آن‌ها توانمند هستند.

اگرچه مدل‌های واحد بازگشتی دروازه‌دار نیز برای داده‌های ترتیبی طراحی شده‌اند، اما نسبت به مدل‌های شبکه عصبی بازگشتی ساده استاندارد از معماری ساده‌تری استفاده می‌کنند که ممکن است توانایی آن‌ها را در شبیه‌سازی وابستگی‌های پیچیده در مجموعه داده‌های کوچکتر یا تخصصی محدود کند. در مقابل، شبکه‌های عصبی پیچشی عمدتاً برای شناسایی الگوهای فضایی به‌کار می‌روند و در شبیه‌سازی وابستگی‌های زمانی کمتر مؤثر هستند، زیرا فاقد ساختار بازگشتی هستند که به طور ذاتی در شبکه‌های عصبی بازگشتی ساده وجود دارد. این ساختار بازگشتی به شبکه‌های عصبی بازگشتی ساده امکان می‌دهد که اطلاعات را در طول زمان حفظ کنند و آن‌ها را به‌ویژه برای پیش‌بینی نیازهای پزشکی که ممکن است وابسته به دنباله‌ای از داده‌های مربوط به بیمار باشند، مناسب می‌سازد.

شکل ۵ توزیع خطای پیش‌بینی تعداد واحدهای تزریق شده خون را در گروه‌های مختلف بیماران با استفاده از شبکه عصبی بازگشتی ساده نشان می‌دهد. نتایج نشان می‌دهند که بیمارانی که واحدهای خون کمتری دریافت کرده‌اند (۰-۳) خطای پیش‌بینی کمتری نشان دادند، که با نشانگرهای سبز رنگ نمایش داده شده‌اند. این موضوع نشان می‌دهد که مدل شبکه عصبی بازگشتی ساده دقت بالاتری در پیش‌بینی مقدار خون، در مواردی که نیاز به خون کم‌تر است، دارد، که احتمالاً به دلیل رابطه‌ی پایدارتر بین ویژگی‌های مدل و نتایج در این محدوده است. در مقابل، بیماران که حجم بالاتری از خون دریافت کرده‌اند، به‌ویژه کسانی که در محدوده ۸-۱۱

منابع:

1. Aleinik, A.Y., S.G. Mlyavykh, and S. Qureshi, Lumbar Spinal Fusion Using Lateral Oblique (Pre-psoas) Approach (Review). *Sovrem Tekhnologii Med*, 2021. 13(5): p. 70-81.
2. Hashemiyazdi, S.H., et al., Comparative study of the effect of two different doses of remifentanyl on bleeding control in lumbar fusion surgery: A randomized clinical trial. *Ann Med Surg (Lond)*, 2022. 82: p. 104761.
3. Cai, Y.F., et al., The effect of platelet-rich plasma on the fusion rate and clinical outcome of spinal fusion surgery: A systematic review and meta-analysis. (1932-6203 (Electronic)).
4. Mikhail, C., et al., Minimizing Blood Loss in Spine Surgery. *Global Spine J*, 2020. 10(1 Suppl): p. 71s-83s.
5. Hajijafari, M., et al., Surgical bleeding in patients undergoing posterior lumbar inter-body fusion surgery: a randomized clinical trial evaluating the effect of two mechanical ventilation mode types. *Eur J Med Res*, 2023. 28(1): p. 114.
6. Wong, J., et al., Tranexamic Acid Reduces Perioperative Blood Loss in Adult Patients Having Spinal Fusion Surgery. *Anesthesia & Analgesia*, 2008. 107(5).
7. Ristagno, G., et al., Red Blood Cell Transfusion Need for Elective Primary Posterior Lumbar Fusion in A High-Volume Center for Spine Surgery. *J Clin Med*, 2018. 7(2).
8. Szpalski, M., R. Gunzburg, and B. Sztern, An overview of blood-sparing techniques used in spine surgery during the perioperative period. *Eur Spine J*, 2004. 13 Suppl 1(Suppl 1): p. S18-27.
9. De la Garza Ramos, R., et al., Rates, Risk Factors, and Complications of Red Blood Cell Transfusion in Metastatic Spinal Tumor Surgery: An Analysis of a Prospective Multicenter Surgical Database. *World Neurosurg*, 2020. 139: p. e308-e315.
10. Raman, T., et al., Decision Tree-based Modelling for Identification of Predictors of Blood Loss and Transfusion Requirement After Adult Spinal Deformity Surgery. *Int J Spine Surg*, 2020. 14(1): p. 87-95.
11. Gong, K.D., et al., Predicting Intensive Care Delirium with Machine Learning: Model Development and External Validation. *Anesthesiology*, 2023. 138(3): p. 299-311.
12. Hashimoto, D.A., et al., Artificial Intelligence in Anesthesiology: Current Techniques, Clinical Applications, and Limitations. *Anesthesiology*, 2020. 132(2): p. 379-394.
13. Wang, Y., et al., Predicting postoperative delirium after microvascular decompression surgery with machine learning. *J Clin Anesth*, 2020. 66: p. 109896.

14. Lee, N.J., J.M. Lombardi, and R.A. Lehman, Artificial Intelligence and Machine Learning Applications in Spine Surgery. *Int J Spine Surg*, 2023. 17(S1): p. S18-s25.
15. Ward, A., et al., Prediction of Prolonged Opioid Use After Surgery in Adolescents: Insights From Machine Learning. *Anesthesia & Analgesia*, 2021. 133(2).
16. Hornung, A.L., et al., Artificial intelligence in spine care: current applications and future utility. *Eur Spine J*, 2022. 31(8): p. 2057-2081.
17. Durand, W.M., et al., Artificial intelligence clustering of adult spinal deformity sagittal plane morphology predicts surgical characteristics, alignment, and outcomes. *Eur Spine J*, 2021. 30(8): p. 2157-2166.
18. Kim, J., et al., Prediction of Recurrence in Pyogenic Vertebral Osteomyelitis by Artificial Neural Network Using Time-series Data of C-Reactive Protein: A Retrospective Cohort Study of 704 Patients. *Spine (Phila Pa 1976)*, 2021. 46(18): p. 1207-1217.
19. De la Garza Ramos, R., et al., An Artificial Neural Network Model for the Prediction of Perioperative Blood Transfusion in Adult Spinal Deformity Surgery. *J Clin Med*, 2022. 11(15).
20. LeCun, Y., et al., Backpropagation applied to handwritten zip code recognition. *Neural computation*, 1989. 1(4): p. 541-551.
21. Cho, K., Learning phrase representations using RNN encoder-decoder for statistical machine translation. *arXiv preprint arXiv:1406.1078*, 2014.
22. Elman, J.L., Finding structure in time. *Cognitive science*, 1990. 14(2): p. 179-211.
23. Sobol, I.M., Global sensitivity indices for nonlinear mathematical models and their Monte Carlo estimates. *Mathematics and computers in simulation*, 2001. 55(1-3): p. 271-280.
24. Barnett, V., *Outliers in statistical data*. John Wiley & Sons google schola, 1994. 2: p. 705-708.