

مدیریت عفونت بعد از آرتروپلاستی: یادگیری ماشین و عمیق به عنوان یک ابزار

دکتر رضا زندی *، دکتر احمد رضا احمدی آبدشتی **، مهندس زهرا احمدی آبدشتی ***

دکتر فرزاد عموزاده ****، شیدا وحیدی *****

چکیده:

زمینه و هدف: امروزه با گسترش دانش بشری، استفاده از ابزارهای هوش مصنوعی، یادگیری ماشین و یادگیری عمیق در علم پزشکی نیز کاربرد یافته است. در مقوله عفونت بعد از آرتروپلاستی هیپ و زانو در ارتوپدی، از یادگیری ماشین و یادگیری عمیق در زمینه ارزیابی اهمیت ریسک فاکتورها، ارزیابی اهمیت معیارهای تشخیصی و پروگنوز و نیز ارزیابی حساسیت پاتوژن ها به آنتی بیوتیک ها استفاده شده است. هم چنین از ابزارهای هوش مصنوعی می توان در زمینه آموزش بیماران و پاسخ به پرسش های شایع بیماران درباره عفونت پری پروستتیک (PJI) نیز استفاده نمود.

مواد و روش ها: در این مطالعه ی روایی، 22 عدد از مقالات ده سال گذشته استخراج شده از پایگاه اطلاعاتی Pubmed را که مربوط به استفاده از هوش مصنوعی و یادگیری ماشین و یادگیری عمیق در PJI بود، بررسی کرده و علاوه بر ذکر موارد بررسی شده توسط هوش مصنوعی (شامل ریسک فاکتورها و معیارهای تشخیص و پروگنوز و آنتی بیوتیک های موثر بر باکتری ها)، مدل های شایع یادگیری ماشین را نیز با حساسیت و ویژگی و دقت مربوطه یادآوری نموده ایم. هم چنین به مطالعه ای درباره استفاده از ChatGPT4 جهت آموزش و پاسخ دهی به بیماران PJI نیز پرداخته ایم.

یافته ها: با توجه به آن که داده های پیچیده و غیرخطی توسط یادگیری ماشین به خوبی و سریع آنالیز می شوند، بهبود قابل توجه در دقت و سرعت مدیریت PJI با یادگیری ماشین حاصل شده است. هم چنین استفاده از یادگیری عمیق دقت را به نسبت یادگیری ماشین بیش تر افزایش داده است. محدودیت های شایع و مشترک مطالعات بیشتر بر گذشته نگر بودن آن ها و هم چنین جمعیت کم مورد مطالعه متمرکز بود.

نتیجه گیری: با توجه به قدرت هوش مصنوعی، یادگیری ماشین و یادگیری عمیق در آنالیز هرچه سریع تر و دقیق تر نسبت به روش های سنتی، استفاده از آن در ابعاد مختلف پزشکی از جمله مدیریت PJI منطقی است.

واژه های کلیدی: یادگیری ماشین، عفونت، آرتروپلاستی هیپ، آرتروپلاستی زانو

نویسنده پاسخگو: دکتر احمد رضا احمدی آبدشتی

تلفن: 02122439784

E-mail: ahmadrezaahmadi@sbmu.ac.ir

* دانشیار گروه جراحی ارتوپدی، مرکز تحقیقات آسیب های اسکلتی عضلانی، دانشگاه علوم پزشکی شهید بهشتی

** جراح ارتوپدی، مرکز تحقیقات آسیب های اسکلتی عضلانی، دانشگاه علوم پزشکی شهید بهشتی

*** کارشناس ارشد مهندسی برق و الکترونیک، افزارهای میکرو و نانو الکترونیک، دانشکده مکانیک، برق و کامپیوتر،

دانشگاه علوم و تحقیقات تهران

**** دانشیار گروه جراحی ارتوپدی، دانشگاه علوم پزشکی شهید بهشتی

***** دانشجوی دکتری آموزش و ارتقاء سلامت، دانشگاه علوم پزشکی شهید بهشتی

تاریخ وصول: 1403/08/19

تاریخ پذیرش: 1404/01/09

زمینه و هدف

یکی از رایج‌ترین اعمال جراحی بر روی مفاصل هیپ و زانو، آرتروپلاستی است. در یکی از آخرین مطالعات انجام شده در کشور آلمان، در گروه سنی 70 سال به بالا، میزان آرتروپلاستی اولیه هیپ، 1/1 درصد (در سال‌های 2007 و 2014) و میزان آرتروپلاستی اولیه زانو، 0/7 درصد در سال 2007 و 0/6 درصد در سال 2014 بود. در سال 2014، شیوع جراحی به نسبت کل جمعیت برای لگن، 0/26 درصد و برای زانو 0/19 درصد بود. در سال 2014، در گروه سنی 70 سال به بالا، میزان آرتروپلاستی‌های تجدید نظر (Revision) (از جمله اصلاح بدون تعویض) برای لگن 0/19 درصد و برای زانو 0/10 درصد بود.¹ درد، عملکرد، تغییرات رادیولوژیکی و درمان محافظه کارانه ناموفق، مهم‌ترین مواردی هستند که ما را به سمت تصمیم‌گیری برای آرتروپلاستی کامل هیپ (Total Hip Arthroplasty - THA) یا زانو (Total Knee Arthroplasty - TKA) سوق می‌دهند.² شایع‌ترین عوارض داخل بیمارستانی در بیماران THA شکستگی (0/6%) و ترومبوز ورید عمقی (Deep Vein Thrombosis - DVT) (0/6%) است؛ در حالی که در بیماران TKA، میزان DVT 1/4% و حوادث قلبی 0/8% شایع‌ترین هستند. همچنین، شایع‌ترین عوارض پس از ترخیص در بیماران THA و TKA، جراحی مجدد به دلیل خونریزی، نکروز زخم، عفونت زخم یا علل دیگر می‌باشد.³ در این میان یکی از چالش‌های مهم بعد از این دو عمل، عفونت است. به طوری که بروز کلی SSI (Surgical Site Infection) بعد از آرتروپلاستی کامل اولیه هیپ، بین 0/2% و 2/2% و میزان عفونت مفصل عمیق یا اطراف پروتز PJI (Peri-prosthetic Joint Infection) در THA و TKA، بین 0/3% تا 1/9 می‌باشد. شیوع عفونت در موارد تجدید نظر حتی تا 10 درصد افزایش می‌یابد.⁴ عوامل خطری وجود دارد که با افزایش خطر PJI مرتبط هستند و شامل موارد جنس مرد، سن کمتر، دیابت نوع II، چاقی کلاس II، فشار خون بالا، هیپوآلبومینمی، وضعیت تغذیه قبل از عمل و شاخص توده بدن، آرتربت روماتوئید، استئوآرتریت پس از ضربه، تزریق داخل مفصلی قبل از TKA، جراحی قبلی مولتی‌لیگامان زانو، استروئید درمانی قبلی، مصرف کنونی تنباکو، موارد دو طرفه، مدت اقامت بیش از 35 روز،

بازسازی سطح مفصلی پتلا (Patellar Resurfacing)، زمان جراحی طولانی، استفاده از تزریق خون، تغییرپذیری بالاتر گلوکز بعد از عمل می‌باشند. از ذکر سایر موارد به علت اهمیت کمتر، پرهیز می‌کنیم.⁵ در سال 2018، اجماعی جهت تشخیص PJI صورت گرفت و طی آن کرایتریاهایی بر اساس نتایج کشت مایع سینوویال، وجود سینوس ترکت در محل عمل، CRP (C-Reactive Protein) و ESR (Erythrocyte Sedimentation Rate)، آلفا دیفنسین، PMN (Poly Morpho Nucler) و D-dimer هیستولوژی و وجود چرک سر عمل، تدوین شد؛ اما با این حال مواردی از بیماران به تشخیص قطعی نمی‌رسند.⁶ جهت درمان PJI، اصلی‌ترین اقدامات شامل دبریدمان، آنتی‌بیوتیک، شست و شو با حفظ ایمپلنت (Debridement, Antibiotics and Irrigation with implant Retention - DAIR) و در مواردی جراحی تجدید نظر یک یا دو مرحله‌ای است.⁷⁻⁹ موفقیت درمان در PJI با انتخاب استراتژی درمانی مناسب، نوع بیمار و عوامل عفونت غیر قابل تغییر، مرتبط است. تصمیم‌گیری بین رشته‌ای گامی حیاتی برای مدیریت PJI می‌باشد.¹⁰

از طرفی گسترش دانش بشری در هوش مصنوعی و آموزش ماشین (Machine learning - ML)، دریچه‌ای تازه در ارزیابی ریسک عفونت، تشخیص، درمان و پیش‌آگهی مبتلایان به PJI، گشوده است. هدف هوش مصنوعی نزدیک شدن رفتار ماشین به الگوریتم‌های ذهن انسان است.¹¹ در واقع یادگیری ماشین، یک مقلد ذهن انسان می‌باشد که به چهار زیرگروه نظارتی (Supervised)، غیرنظارتی (Unsupervised)، نیمه نظارتی (Semi - Supervised) و تقویتی (Re-Inforcement)، تقسیم می‌شود. یادگیری ماشین می‌تواند از داده‌ها استفاده نماید تا الگوریتم‌هایی با ویژگی‌ها (Features) و وزن‌های (Weights) جدید و مختلف بسازد. در نوع نظارتی، داده‌ها و نتایج، هر دو، در دو گروه به ماشین داده می‌شوند. گروه اول، گروه آموزشی (Training Set) و گروه دوم گروه تست (Test) است؛ طی آن الگوریتمی ساخته می‌شود که کامپیوتر قادر خواهد بود با داده‌هایی که از آن آموزش دیده، ارتباطات بین داده‌های بعدی را بیابد و هدف خاصی را پیش‌بینی کند.

که یادگیری عمیق به عنوان ابزاری قدرتمند برای تحلیل کلان داده ها ظهور کرده است و مزایای قابل توجهی نسبت به روش های سنتی یادگیری ماشین ارائه می دهد.¹⁷ در مقاله روایی پیش رو علی رغم این که درباره مدل ها و الگوریتم های رایج آموزش ماشین و عمیق در پژوهش های مرتبط با موضوع PJI صحبت خواهیم کرد، به کاربرد آن در بالین بیماران نیز خواهیم پرداخت.

مواد و روش ها

پرسش اصلی در این مقاله، شامل دو مورد است. اول آن که یادگیری ماشین در فرآیند منتج به PJI و پس از وقوع آن چه جایگاهی می تواند داشته باشد و دوم آن که انواع رایج مدل ها و الگوریتم های یادگیری ماشین در این مورد چیست.

در این مقاله، کلید واژه های Total Knee Arthroplasty, Total Hip Arthroplasty, Machine Learning, Infection Replacement, Artificial Intelligence، در پایگاه Pubmed را طی ده سال گذشته جست و جو نمودیم و مرتبط ترین آن ها پس از غربال گری از طریق خواندن تیترو و چکیده توسط متخصص ارتوپدی، جهت مطالعه انتخاب شدند.

یافته ها

1- پیش بینی (Prediction)

یکی از فواید استفاده از ML، بهبود دقت (Accuracy) در پیش بینی یک بیماری یا عارضه بر اساس یادگیری ریسک فاکتورهاست و مزیت آن بر مدل های آماری قدیمی علاوه بر افزایش دقت، پیش بینی داده های دیده نشده (Unseen Data) می باشد، در حالی که مدل های آماری صرفاً ارتباطات بین متغیرها و اهمیت آن ها را پیش بینی می کنند.¹⁸

در قسمت پیش بینی PJI، می توان از مدل اتوپروگنوز استفاده نمود. این مدل، سوء تغذیه، دمانس، بدخیمی و بیماری ریوی انسدادی مزمن (Chronic Obstructive Pulmonary Disease - COPD) و پوشش بیمه را به عنوان ریسک فاکتور PJI، در نظر می گیرد.¹⁹

برخلاف یادگیری نظارت شده، هدف یادگیری غیرنظارتی، شناسایی الگوها در یک مجموعه داده است که نتایج مشخصی برای آن از پیش تعیین نشده است. یادگیری نیمه نظارتی، ترکیبی از دو یادگیری قبل است. به ویژه برای مجموعه داده هایی که حاوی داده های برچسب دار و بدون برچسب هستند (یعنی همه ویژگی ها وجود دارند، اما همه ویژگی ها دارای اهداف مرتبط نیستند) مفید است. این حالت، معمولاً زمانی رخ می دهد که برچسب گذاری تصاویر، زمان بر یا هزینه بر باشد. یادگیری نیمه نظارتی اغلب برای تصاویر پزشکی استفاده می شود، جایی که یک پزشک ممکن است زیر مجموعه کوچکی از تصاویر را برچسب گذاری کند و از آنها برای آموزش یک مدل استفاده نماید. سپس از این مدل برای طبقه بندی بقیه تصاویر بدون برچسب در مجموعه داده استفاده می شود. از مجموعه داده برچسب گذاری شده برای آموزش یک مدل کاری استفاده شده که در تئوری باید از مدل های بدون نظارت بهتر عمل کند. در نهایت، یادگیری تقویتی، تکنیک آموزش یک الگوریتم برای یک کار خاص است که در آن هیچ پاسخ واحدی، صحیح نیست، بلکه یک نتیجه کلی مورد نظر است. مسلماً این نزدیک ترین یادگیری به یادگیری انسانی می باشد. زیرا از آزمون و خطا یا پاداش و جریمه در مسیر یادگیری استفاده می کند. استفاده از این نوع، در پزشکی کمتر شایع است.¹² یادگیری عمیق زیرمجموعه ای از یادگیری ماشین است.^{13و14} یادگیری ماشین به کامپیوترها امکان می دهد از داده های گذشته بیاموزند و پیش بینی کنند. در حالی که یادگیری عمیق با استفاده از شبکه های عصبی مصنوعی، داده های بدون نظارت را تحلیل و پردازش می کند.¹⁵ تفاوت کلیدی بین این دو در این است که مدل های یادگیری ماشین برای بهبود دقت به راهنمایی انسان نیاز دارند؛ اما مدل های یادگیری عمیق می توانند به طور خودکار خطاها را تصحیح کنند.¹⁴ هدف یادگیری ماشین، ارائه حدس های مفید در حوزه هایی است که راه حل های دقیقی برای آن ها وجود ندارد. در حالی که یادگیری عمیق، دنیا را به صورت سلسله مراتبی از مفاهیم تو در تو بازنمایی می کند.¹³ یادگیری ماشین برخلاف تصور رایج که نیازمند داده های بزرگ است، می تواند به طور مؤثری در مجموعه داده های کوچک نیز به کار گرفته شود.¹⁶ در حالی

با عفونت متعاقب آرتروپلاستی، از XGBoost در تشخیص بهتر SSI استفاده شده است.²⁴ همچنین RF و UMAP (Uniform Manifold Approximation and Projection) و زنجیره مارکوف جهت تشخیص، CRP PJI (C- Reactive Protein) را به عنوان مهم‌ترین فاکتور تشخیص دهنده شناسایی کردند. کاهش (BUN) (Blood Urea Nitrogen)، کاهش هموگلوبین (Hb)، افزایش Total Protein و افزایش ALT از مهم‌ترین عوامل دیگر، جهت تشخیص PJI بودند. ترکیب بیومارکرها نیز از اهمیت برخوردار است. برای مثال CRP بالا و هموگلوبین پایین، ترکیبی بی‌نظیر برای تشخیص PJI بود. ضمناً با استفاده از زنجیره مارکوف که تغییر احتمالات را بررسی می‌کند، افرادی که PJI دارند، بعد از جراحی احتمال بالاتری برای انتقال آن به گروه‌های با خطر بالاتر دارند. یعنی PJI یک ریسک برای عفونت مجدد است.²⁵ همچنین با استفاده از K-means clustering و درخت PCA (Principal Component Analysis) و تصمیم، نرخ تشخیص‌های نامشخص برای PJI بهبود یافته است.²⁶ استفاده از SVM (Support Vector Machine) و پلتفرم TRACE4 جهت بررسی اهمیت یافته‌های MRI، نشان داده است که اختصاصی‌ترین یافته‌ها در MRI جهت تشخیص PJI، شامل سینوویت، سینوویت لایه‌بندی (Lamellated Synovitis) شده و ادم اکستراکپسولر است و حساس‌ترین یافته با NPV (Negative Predictive Value) بالا، ادم استخوان می‌باشد. همچنین تخریب استخوان و توده بافت نرم اطراف مفصلی و غشای فیبروتیک، با شکست THA از نوع عفونی، ارتباط نداشتند و احتمالاً نشانه غیرعفونی بودن شکست درمان است.²⁷ با استفاده از یادگیری عمیق (Deep Learning) در استفاده از اسکن دینامیک استخوان (Dynamic Bone Scan - DBS) نیز پیشرفت‌هایی حاصل شده است. مدل DBS-eNet (Dynamic Bone Scan Efficient Neural Network) نسبت به روش‌های دیگر، حساسیت و ویژگی بالاتری برای سینی‌گرافی استخوان جهت تشخیص PJI ایجاد کرده است. حتی تشخیص از متخصصین طب هسته‌ای به ویژه در عفونت پروتز اطراف زانو (نسبت به هیپ) نیز بهتر بوده است.²⁸

همچنین در موارد راجعه شدن PJI بعد از ریویژن، از مدل یادگیری عمیق (Artificial Neural Network) ANN استفاده شده است که طبق آن I&D (Irrigation and Debridement) قبلی با یا بدون تعویض کومپوننت، قوی‌ترین پیش‌بینی کننده بوده است. همچنین ویژگی‌های میکروبیولوژیکال شامل انتروکوکوس و MRSA (Methicillin Resistant Staphylococcus Aureus)، به عنوان ریسک فاکتور راجعه شدن است (MRSA توسط مدل ANN به عنوان ریسک فاکتور کشف شده است). مضاف بر آن، بیش از چهار بار جراحی باز قبلی، متاستاز، HIV/ایدز (Human Immunodeficiency Virus)، سوءمصرف مواد و چاقی از ریسک فاکتورهای راجعه شدن PJI، محسوب می‌شوند.²⁰ در صورتی که PJI پس از یک ریویژن به علت غیرعفونی رخ داده باشد، می‌توان با مدل ANN پیش‌بینی را صورت داد. ریسک فاکتورهای آن شامل جراحی باز قبل از جراحی، سوءمصرف مواد، چاقی و دیابت است.²¹ با استفاده از RF (Random Forest) می‌توان شکست درمان پس از I&D در PJI را هم پیش‌بینی کرد که از معیارهای قدیمی مثل KLIC و CRIME80 (دو سیستم امتیازدهی برای پیش‌بینی موفقیت شست و شو دریدمان در عفونت اطراف پروتز) قوی‌تر است.¹⁸ همچنین می‌توان از ANN، جهت ارزیابی ریسک فاکتورهای SSI، بعد از آرتروپلاستی نیز استفاده کرد. قوی‌ترین پیش‌بینی کننده‌های آن شامل CCI (Canadian Classification of Health Interventions)، چاقی و سیگار است. مدل یادگیری عمیق، اهمیت چاقی را نسبت به قبل، بالاتر تخمین زده است که این به دلیل توانایی مدل در استفاده از داده‌های پیچیده و غیرخطی است.²² در مورد ریسک ترشح پس از همی‌آرتروپلاستی می‌توان از مدل Stacking استفاده نمود که طبق آن چهار ریسک فاکتور اصلی ترشح شامل حجم مایع جمع شده از درن، چاقی مرضی، کلاس خونی و BMI بالا می‌باشد.²³ قسمت پیش‌بینی در جدول 1، جمع‌بندی شده است.

2- تشخیص (Diagnosis)

با استفاده از تکنیک یادگیری ماشین می‌توان بهترین روش‌های تشخیصی برای هر بیماری را تعیین کرد. در رابطه

جدول 1- استفاده از ML در ارزیابی عوامل پیش‌بینی کننده

نویسنده/ سال انتشار	مدل (ML)	تفسیر پذیری (Interpretability)	نوع آرتروپلاستی	توضیحات	نتایج
Yeo I et al. (2023) ¹⁷	- ANN - SGB - SVM - RF - Elastic-Net - Penalized Logistic Regression	- Accuracy > 94.0% - AUC = 0.84 - Calibration Intercept = 0.09 - Calibration Score = 1.06 - Brier: 0.054 - هر 5 مدل، عملکرد عالی از نظر Discrimination و Calibration - Decision Curve Analysis - از ANN بقیه بهتر است.	Primary TKA	جهت جلوگیری از Overfitting، یک Five-Fold Cross Validation و همچنین Validation 80-20 و Recursive Feature Elimination استفاده شد.	- پیش‌بینی کننده‌های CCI، شامل CCI، چاقی و سیگار بودند. - CCI از همه مهم‌تر است. چاقی طبق یافته ML نسبت به گذشته اهمیت بیشتری پیدا کرد.
Akash A Shah (2021) ¹⁴	- Autoprognosis: شامل 5 مدل ML Benchmark - Logistic regression (A Liner Classifier) - Random Forest (A Tree Based Ensemble Classifier) - AdaBoost - Gradient Boosting Machine - XGBoost (Boosting Ensemble Classifier)	- discrimination (AUROC: 0.732 ± 0.01) - Brier score of 0.007 ± 0.002 - Calibration plot رسم گردیده که نشان دهنده بهتر بودن مدل اتوپروگنوز بوده است.	THA	- هایپر پارامترهای هر مدل با Grid Search انتخاب شد. برای رگرسیون لجستیک از L2 Regularisation استفاده شد. - استفاده از Five-Fold Cross Validation و Validation 80-20 جهت اعتبارسنجی.	- مدل اتوپروگنوز، بهتر از مدل‌های بررسی شده دیگر بود. 5 ویژگی مهم سو تغذیه، دمانس، بدخیمی، COPD، پوشش بیمه بر اساس اتوپروگنوز جهت پیش‌بینی PJI اهمیت داشته‌اند.
Christian Klemm et al. (2021) ¹⁵	- ANN - SGB - ENP	- Discrimination در مدل ANN دارای AUC=0.84 در گروه تست بود. - همچنین مدل با Calibration و Decision Curve Analysis تایید شد. - سایر مؤلفه‌ها در گروه تست: Intercept: 0.06, Slope: 1.09, Brier: 0.052	Revision TKA	- جهت جلوگیری از Overfitting یک Five-Fold Cross Validation و همچنین Validation 80-20 و Recursive Feature Elimination استفاده شد. - جهت Tune کردن هر هایپر پارامتر از Coarse Grained و Grid Search و Repeated Random Sub-Sampling استفاده شد.	- قوی‌ترین پیش‌بینی کننده برای PJI ریکارنت، I&D قبلی با یا بدون تعویض کمپوننت مدولار است. - پس از آن، < 4 بار جراحی باز قبلی و میکروبیولوژی (انتروکوکوس، MRSA) هم قوی‌اند. - MRSA به عنوان ریسک فاکتور کشف شد. - تایید فاکتورهای متاستاز، ایدز، سوء مصرف مواد و چاقی، منطبق با پژوهش‌های گذشته.

• قوی‌ترین پیش بینی کننده برای PJI ریکارنت، جراحی باز قبلی پیش از جراحی ریزون بود. • سو مصرف مواد، چاقی و دیابت نیز از پیش بینی کننده های قوی هستند.	• استفاده از Five-Fold Cross Validation 80-20 و Recursive Feature Elimination جهت جلوگیری از Overfitting. • استفاده از Coarse Grained Grid Repeated Search و Sub-Sampling جهت Tune کردن هر هاپیر پارامتر	Aseptic Revision TKA	• Discrimination در مدل ANN دارای RO-$AUC=0.78$ بود. • همچنین مدل با Calibration و Decision Curve Analysis تایید شد. بر اساس موارد فوق، ANN نسبت به دو مدل دیگر بهتر بود. • سایر مؤلفه‌ها در گروه تست: • Intercept:0.10 • Slope:1.09 • Brier:0.055	• ANN • SVM • KNN	Christian Klem et al. (2024)¹⁶
پیش بینی کننده شکست درمان I & D پس از PJI است و از CRIME80 و KLIC قوی‌تر است.	جهت Validation از 8-Fold Cross Validation استفاده شد.	THA TKA	با توجه به $AUC = 0.74$ مدل RF قابل اعتمادترین بود.	• RF • Logistic Regression with all variables • Stepwise (Forward) Logistic Regression • Stepwise (Forward) Logistic Regression including all integration with the variable	Noam Shohat (2020)¹³
• نتایج دقیق‌تر در پیش‌بینی ترشح بعد از همی آرتروپلاستی با استفاده از مدل 2 (متا). • حجم مایع جمع‌شده از درن، چاقی مرضی، کلاس خونی و BMI بالا، چهار ریسک فاکتور مهم برای ترشح بر اساس مدل Stacking بود.	• افزایش قدرت تعمیم مدل با آموزش نتایج مدل‌های دیگر (آموزش یابنده سطح اول)، به صورت ورودی به مدل LR (آموزش یابنده متا) در روش Stacking. • استفاده از F1measure جهت بررسی دقت و حساسیت	همی آرتروپلاستی	• موارد زیر مربوط به مدل Stacking است: • Accuracy = 0.89 • f1 = 0.84 • kappa = 0.81 • precision = 0.88 • Sensitivity = 0.80 • Specificity = 0.98	• linear discriminant analysis • decision tree • KNN • GBM • LR به عنوان مدل متا جهت stacking	Sultan Turhan (2023)¹⁸

ترکیب نوآورانه اجازه می‌دهد تا نظارت بر SSI به صورت آبی و سریع انجام شود و استراتژی‌های پیشگیرانه را تقویت کند و فرصت‌های جدیدی برای پیشگیری از شیوع بیماری ارائه دهد.³¹

3- آنتی‌بیوتیک و میکروارگانیسم‌های پاتوژن

- استفیلوکوکوس اورئوس
دویس و همکاران،³² یک طبقه‌بندی یادگیری ماشین با استفاده از روش تقویت تطبیقی (Adaptive Boosting) برای پیش‌بینی وضعیت مقاومت به متی‌سیلین در باکتری استفیلوکوکوس اورئوس را توسعه دادند. در این مطالعه، مجموعاً 606 ژنوم باکتریایی از پایگاه داده مرکز یکپارچه‌سازی منابع پاتوسیستم، جمع‌آوری شد. شمارش k-mer در DNA برای نمایش نواحی مقاومت آنتی‌میکروبی در داخل یک ژنوم باکتریایی به کار رفت و سپس برای آموزش الگوریتم استفاده شد. این امر منجر به عملکرد برجسته‌ای که دارای AUC معادل 0/991 و دقت 99/5% بود، گشت. این مدل، مشابه مدل توسعه‌یافته توسط دروئن و همکاران³³ است که دقت بالای 98/7% را برای استفیلوکوکوس اورئوس نشان داد.³⁴

الف - انتروکوکوس فاستوم

در مطالعه‌ای که توسط دروئن و همکاران³³ انجام شد، از مدل پوشش مجموعه برای پیش‌بینی وضعیت حساسیت آنتی‌بیوتیکی 12 پاتوژن، از جمله استفیلوکوکوس اورئوس، انتروکوکوس فاستوم، اشریشیا کلای، کلبسیلا پنومونیه و پسودوموناس آئروژینوزا استفاده گشت. در این تحقیق از 56 آنتی‌بیوتیک مختلف بهره گرفته شد و شمارش DNA k-mer از بانک اطلاعاتی مرکز یکپارچه‌سازی منابع پاتوسیستم استخراج گردید. مدل ساخته شده دارای دقت بسیار بالا و معادل 100% برای انتروکوکوس فاستوم بود. این مدل همچنین قابلیت تفسیر بالایی داشت و به دلیل به‌کارگیری نظریه فشرده‌سازی نمونه و اضافه کردن آموزش‌های جامع، زمان محاسباتی کوتاهی داشت که امکان راهنمایی به کاربرانی بدون دانش قبلی در زمینه یادگیری ماشین (ML) را فراهم می‌کرد.³⁴

Kuo و همکاران در سال 2021، با استفاده از یک مدل Stacking که متاکلاسیفایر آن SVM بود نه تنها بسیاری از ویژگی‌های مهم مشترک فهرست شده در معیارهای ICM2018 (International Consensus Meeting) را برای تشخیص PJI شناسایی کرد، بلکه ویژگی‌های مهم دیگری مانند هموگلوبین و زمان پروترومبین را نیز در نظر گرفت و مقادیر پایه متفاوتی را برای این ویژگی‌ها تنظیم کرد.²⁹ Tao و همکارانش در سال 2022 توانستند با استفاده از ابزار یادگیری عمیق، از تصاویر لام پاتولوژی جهت بهبود معیارهای تشخیصی PJI بهره ببرند که در جدول شماره 2 به آن اشاره کرده‌ایم.³⁰

فلورس بالادو و همکاران، در سال 2023، در مطالعه خود، ابزار جدیدی به نام AI-HPRO (Artificial Intelligence - Hip Prosthesis) را معرفی کردند که ترکیبی از تکنیک‌های پردازش زبان طبیعی (NLP) و الگوریتم پیش‌بینی چندمتغیره XGBoost است تا نظارت بر عفونت‌های محل جراحی (SSI) در بیماران تحت عمل جراحی تعویض مفصل ران را بهبود بخشند. این روش مبتنی بر هوش مصنوعی، به طور قابل توجهی بار کاری نظارت دستی را بیش از 88% کاهش داده و زمان لازم برای بررسی سوابق را از 975 ساعت به تنها 63.75 ساعت کاهش می‌دهد. این کارایی به دیارتمان پیشگیری از عفونت اجازه می‌دهد تا بر روی سایر روش‌های جراحی نظارت کند. نظارت خودکار بر SSI، به طور فزاینده‌ای به خاطر مزایای آن، از جمله کاهش زمان صرف شده برای نظارت، بهبود شیوه‌های ایزوله‌سازی، اعتبار بیشتر برای مقایسه بین‌مرکزی و افزایش رضایت حرفه‌ای، شناخته می‌شود. اجرای تشخیص خودکار SSI از 32% از بیمارستان‌ها در سال 2009 به حدود 83% در سال 2021 افزایش یافته است. در حالی که بیمارستان‌های وابسته به دانشگاه نرخ‌های بالاتری از اتوماسیون را نشان می‌دهند. این راه‌حل‌ها، به کارکنان این امکان را می‌دهند که بر روی کارهای با ارزش بالاتر، مانند توسعه استراتژی‌های کنترل عفونت بر اساس داده‌های نظارتی تمرکز کنند. این مطالعه تأکید می‌کند که مدل NPV، AI-HPRO بالایی نزدیک به 100% و حساسیت 99/7% را نشان می‌دهد که عملکرد بهتری نسبت به مدل‌های قبلی استفاده‌کننده از NLP به تنهایی یا در ترکیب با رگرسیون لجستیک دارد. این

جدول 2- استفاده از ML در ارزیابی فاکتورهای مربوط به تشخیص

نویسنده / سال انتشار	مدل	تفسیر پذیری (Interpretability)	نوع آرتروپلاستی	توضیحات	نتایج
Guosong Wu et al. (2023) ¹⁹	XGBoost	- ROC AUC of 0.906 (95% CI 0.835-0.978) - PR AUC of 0.637 (95% CI 0.528-0.746) - F1 Score of 0.79 (0.67-0.90)	THA TKA	جهت بهینه سازی از Grid Search استفاده شد.	- مدل از داده های ساختار یافته (مثلاً کدهای ICD10) و غیر ساختار یافته (نوشته های پرستاران مدل سازی شده با تکنیک Bag of word و SSI (TF-IDF جهت تشخیص استفاده می کند. - فواید شناسایی SSI دقیق تر، کاهش بار کاری خصوصاً برای تیم های نظارتی، صرفه جویی در زمان و هزینه، استفاده بهینه از داده های غیر ساختاری که اغلب جدی گرفته نمی شوند.
Alvaro Flores-Balado (2023) ²⁶	AI-HPRO استفاده از Natural Language Processing (NLP) و Extreme Gradient Boosting طراحی شد.	- Sensitivity (99.18%) - Specificity (91.01%) - F1-score of 0.32 - AUC of 0.989 - accuracy of 91.27% - Negative predictive value of 99.98%.	THA		- کاهش بیش از 88% بار کاری نظارت دستی و زمان لازم برای بررسی سوابق از 975 ساعت به تنها 63/75 ساعت توسط این روش مبتنی بر هوش مصنوعی. - انجام سریع نظارت بر SSI، تقویت استراتژی های پیشگیرانه، ارائه فرصت جدید برای پیشگیری از شیوع بیماری توسط این ترکیب نوآورانه.
Eryo Kawakami et al. (2023) ²⁰	RF جهت افتراق از k-NonPJI و Mean UMAP با توجه به هم پوشانی مشخصات در گروه ها، جهت طبقه بندی فرعی به گروه های پرخطر و کم خطر استفاده شد. البته در این مطالعه از زنجیره مارکوف هم استفاده شد تا احتمال باقی ماندن در گروه فعلی در طی زمان نیز بررسی شود.	RO-AUC:0.778	THA	جهت مقایسه، از مدل logistic Regression هم استفاده شد که AUC:0.743 بود.	- CRP مهم ترین فاکتور تشخیص دهنده برای PJI شناسایی شد. - کاهش Hb و BUN و افزایش total protein و ALT از مهم ترین عوامل دیگر جهت تشخیص PJI بودند. - ترکیب بیومارکرها نیز از اهمیت برخوردار است. برای مثال CRP بالا و هموگلوبین پایین ترکیبی بی نظیر برای تشخیص PJI بود. - افراد دارای PJI بعد از جراحی احتمال بالاتری برای انتقال به گروه های با خطر بالاتر دارند (PJI یک ریسک برای عفونت مجدد).
Pearl R Paranjap (2023) ²¹	Unsupervised: K-means clustering & PCA. Supervised: The decision tree algorithm	- Area under the curve (AUC) of 0.993, with high sensitivity and specificity (99.1%). - برای مارکرها AD و MID از SHAP استفاده شد.	TKA و THA	Overfitting درخت تصمیم با استفاده از Cost Complexity Pruning اصلاح شد.	این مدل با استفاده از بیومارکرها های سینوویال و سن بیمار، به طور قابل توجهی نرخ تشخیص های نامشخص PJI را از 7/4 به 1/3 کاهش داد.

• اختصاصی‌ترین یافته‌ها در <i>MRI</i> جهت تشخیص <i>PJI</i> طبق آمار یادگیری ماشین، شامل سینوویت، سینویت لایه‌بندی شده و ادم اکستراکپسولر است. • همچنین حساس‌ترین با <i>NPV</i> بالا، ادم استخوان می‌باشد. • تخریب استخوان و توده بافت نرم اطراف مفصلی و غشای فیبروتیک با شکست <i>THA</i> از نوع عفونی ارتباط نداشتند و احتمالاً نشانه غیرعفونی بودن شکست درمان است.	Nested five-fold cross validation	THA	الف - تمام ویژگی‌های <i>MRI</i>: (1) گروه اینترنال: Accuracy 82%, AUC 81% 92% sensitivity 62% specificity 79% PPV, 83% NPV (2) گروه اکسترنال: Accuracy 88%, AUC 89% 92% sensitivity 79% specificity 89% PPV, 83% NPV ب - ادم مغز استخوان (1) گروه اینترنال: Accuracy 80%, AUC 74% 81% sensitivity 76% specificity 66% PPV, 88% NPV (2) گروه اکسترنال: Accuracy 75%, AUC 79% 68% sensitivity 89% specificity 93% PPV, 60% NPV	SVM TRACE4 platform	Domenico Albano et al. (2023)²²
• نسبت به مدل‌های طبقه‌بندی اصلی، حساسیت و ویژگی بالاتری برای تشخیص <i>PJI</i> ایجاد کرد. • تشخیص از متخصصین طب هسته‌ای به ویژه در عفونت پروتز اطراف زانو، بهتر بوده است.	• پیش‌پردازش داده‌های مربوط به هیپ به صورت <i>DOI</i> و داده‌های مربوط به زانو به صورت استاندارد • مشخص شدن داده‌هایی با تاثیر بیشتر توسط <i>Grad-CAM</i> • استفاده از <i>DCA</i> جهت ارزیابی فایده بالینی مدل	THA TKA	• Diagnostic accuracies : زانو: 87.74% هیپ: 86.36% • AUC: زانو: 0.957 هیپ: 0.906	DBS-eNet که یک شبکه عصبی موثر و جزئی از یادگیری عمیق است.	Liangbin g Nie (2023)²³
• عملکرد مدل در تشخیص <i>PJI</i> مزمن با معیارهای جامعه عفونت استخوان و مفاصل اروپا در سال 2018 مقایسه شد. • شناسایی بسیاری از ویژگی‌های مشترک فهرست شده در معیارهای <i>ICM 2018</i> برای تشخیص <i>PJI</i>. • در نظر گرفتن ویژگی‌های مهم دیگری مانند هموگلوبین و زمان پروترومبین و تنظیم مقادیر پایه متفاوت برای این ویژگی‌ها. • هدف شناسایی تصاویر با بزرگ‌نمایی بالا از بخش‌های پاتولوژیک بافت نرم اطراف مفاصل در برابر معیارهای تشخیصی عفونت حاد بوده است. • از شبکه عصبی کانولوشنی برای شناسایی و تجزیه و تحلیل تصاویر استفاده کرده است. این تکنیک نشان می‌دهد که می‌توان با مقایسه روش جدید با استراتژی‌های استاندارد، به دقت تشخیصی بهتری دست یافت. • این مطالعه نشان‌دهنده پتانسیل بالای یادگیری عمیق در بهبود تشخیص عفونت‌های حاد از طریق تجزیه و تحلیل تصاویر پاتولوژیک است، هرچند که بهبود مستمر داده‌های آموزشی برای دستیابی به دقت بهینه ضروری است.	5-fold cross-validation	THA TKA	• AUC: 0.988 • Accuracy: 96.4% • Recall: 0.981 • F1 score: 0.97 • Matthews correlation coefficient: 0.926 • Precision: 0.96	Two-level stacked generalization architecture: • Meta-classifier: SVM • Base classifiers: RF, EGB, LR, naïve bayesian	Kuo F.C. (2021)²⁴
• تبدیل فروزن سکشن 20 بیمار با استفاده از اسکنر <i>UN</i> و اسکنر <i>McUddy</i> به تصاویر الکترونیکی. • تقسیم کل تصویر به‌طور مصنوعی تحت بزرگ‌نمایی بالا (400x) و مشاهده با استفاده از نرم‌افزار <i>IViewer</i> • ذخیره تصاویر الکترونیکی قطعه‌بندی در فرمت <i>TIFF</i>. • مطالعه تصاویر و تشخیص پاتولوژیک بر اساس معیارهای تشخیصی <i>ICM 2018</i> توسط دو پاتولوژیست • اگر تعداد گلبول‌های سفید خون در بزرگ‌نمایی بالا بیشتر از 10 باشد، مثبت و در غیر این صورت منفی تلقی می‌شود. • استفاده از مدل شبکه کانولوشنال یادگیری عمیق <i>Resnet</i> برای آموزش. • خواندن و تشخیص سیستم تصاویر مثبت و منفی مطابق با شاخص‌های تشخیصی <i>ICM 2018</i> توسط سیستم تصویرخوان هوشمند خودساخته با استفاده از دو مجموعه	• تبدیل فروزن سکشن 20 بیمار با استفاده از اسکنر <i>UN</i> و اسکنر <i>McUddy</i> به تصاویر الکترونیکی. • تقسیم کل تصویر به‌طور مصنوعی تحت بزرگ‌نمایی بالا (400x) و مشاهده با استفاده از نرم‌افزار <i>IViewer</i> • ذخیره تصاویر الکترونیکی قطعه‌بندی در فرمت <i>TIFF</i>. • مطالعه تصاویر و تشخیص پاتولوژیک بر اساس معیارهای تشخیصی <i>ICM 2018</i> توسط دو پاتولوژیست • اگر تعداد گلبول‌های سفید خون در بزرگ‌نمایی بالا بیشتر از 10 باشد، مثبت و در غیر این صورت منفی تلقی می‌شود. • استفاده از مدل شبکه کانولوشنال یادگیری عمیق <i>Resnet</i> برای آموزش. • خواندن و تشخیص سیستم تصاویر مثبت و منفی مطابق با شاخص‌های تشخیصی <i>ICM 2018</i> توسط سیستم تصویرخوان هوشمند خودساخته با استفاده از دو مجموعه	Revision TKA THA	• AUC: 0.8136 • Average accuracy: 93.3% • Average recall rate: 0.9739 • F1 score: 0.9482	ResNet34 deep learning convolutional network	Tao Y. (2022)²⁵

ب - اشرشیا کولی

موردی دیگر از مطالعه‌ای که توسط مرادی‌گراوند و همکاران³⁵ انجام شد، آموزش درخت تصمیم تقویت‌شده با گرادیان به‌عنوان مدلی برای پیش‌بینی مقاومت اشرشیا کلای به 11 آنتی‌بیوتیک رایج بود. داده‌هایی شامل محتوای ژنی، سال ایزولاسیون، ساختار جمعیتی و اطلاعات مربوط به پلی‌مورفیسم از 1936 نمونه توالی ژنوم کامل اشرشیا کلای برای آموزش مدل جمع‌آوری شد. عملکرد این مدل یادگیری ماشین با یک روش مبتنی بر قانون که در همان مطالعه توسعه یافته بود، مقایسه شد و نتیجه نشان داد که مدل یادگیری ماشین با دقت متوسط 91/0% عملکرد بهتری نسبت به روش مبتنی بر قانون و همچنین مدل توسعه‌یافته توسط دروئن و همکاران که دقت 81/8% را برای اشرشیا کلای به دست آورد، داشته است.³⁴

ج - کلبسیلا پنومونیه

دروئن و همکاران،³³ مدلی مبتنی بر طبقه‌بندی فنوتیپی دوتایی (حساس یا مقاوم) ساختند که دقت 95/0% را برای کلبسیلا پنومونیه به‌دست آورد. همچنین در مطالعه‌ای دیگر توسط نگوین و همکاران،³⁶ غلظت حداقل بازدارنده MIC (Minimum Inhibitory Concentration) کلبسیلا پنومونیه با استفاده از مدل درخت تقویت شده با گرادیان پیش‌بینی شد تا سطح مقاومت آنتی‌بیوتیکی را تعیین کند. این مدل با داده‌هایی از 1668 ژنوم (Whole Genome Sequence) مربوط به باکتری آموزش دید و موفق به دستیابی به دقت کلی 92% شد.³⁴

د - سودومونا آئروژینوزا

با استفاده از توالی‌های ژنومی و داده‌های ترانسکریپتومی از 414 نمونه پسودوموناس آئروژینوزا، خالدی و همکاران،³⁷ یک طبقه‌بندی‌کننده ماشین بردار پشتیبان (SVM) برای پیش‌بینی حساسیت پسودوموناس آئروژینوزا را به چهار آنتی‌بیوتیک رایج ضد پسودوموناس شامل سفیتازیدیم، مروپنم، سیپروفلوکساسین و توبرامایسین ساختند. این مدل حساسیت و ارزش پیش‌بینی

بالایی معادل 0/9-0/8 یا بیشتر از 0/9 به‌دست آورد که قابل مقایسه با مدل دروئن و همکاران³³ با دقت 93/9% برای پسودوموناس آئروژینوزا بود. با این حال، با وجود توسعه مدل‌های پیش‌بینی برای گونه‌های مختلف، هنوز تلاش کمی برای توسعه نرم‌افزاری که بتواند دسترسی آسانی را برای عموم فراهم کند، وجود دارد. در این راستا، آون و همکاران،³⁸ نرم‌افزاری ساده به نام PhenotypeSeeker ساختند که از مقادیر MIC و همچنین فنوتیپ‌های دوتایی برای تعیین مقاومت پسودوموناس آئروژینوزا به سیپروفلوکساسین استفاده می‌کند و این کار با استفاده از دو مدل رگرسیون انجام می‌شود. این روش دارای دقت 88/0% بود. K-merهای 200 ژنوم برای توسعه مدل، جمع‌آوری شد و مدل می‌توانست با ژنوم‌های Assembled، در کمتر از 5 ساعت برای هر فنوتیپ ساخته شود و پیش‌بینی فنوتیپ را فقط در یک ثانیه تولید کند.³⁴ جمع‌بندی موارد مربوط به باکتری‌ها و حساسیت به آنتی‌بیوتیک‌ها، در جدول شماره 3 ذکر شده است.

پاسخ به سوالات متداول بیماران PJI توسط ChatGPT

ژیاوژون و همکاران،³⁹ در سال 2024، پاسخ‌های ChatGPT به سوالات متداول مردم در مورد PJI پس از TKA و THA را مورد ارزیابی قرار دادند. آن‌ها، 12 گروه از سوالات پرسیده شده شایع (Frequently Asked Question - FAQ) را از وبسایت پانزدهمین مرکز مهارت‌های بالینی بین‌المللی شناسایی نمودند و پاسخ‌های AI-Chatbot ChatGPT با استفاده از یک تیم بین‌رشته‌ای جهت بررسی *Accuracy* آنالیز شد. در کل، اگرچه بخش کمی از پاسخ‌ها به شفاف‌سازی حداقل (Minimal Clarification) نیاز داشت، اما جواب‌ها حتی در صورت وجود اختلاف نظر، بدون سوگرایی (Unbiased) و مبتنی بر منبع (Evidence-based) بود. بنابراین استفاده از ChatGPT4 به عنوان ابزاری قدرتمند در آموزش بیماران می‌تواند مفید باشد.

جدول 3- استفاده از ML جهت ارزیابی حساسیت آنتی بیوتیکی

نویسنده / سال انتشار	مدل ML	تفسیر پذیری	نوع استفاده
Davis J.J. (2016) ²⁷	Adaptive boosting	Area under the receiver operating characteristic curve: 0.991 Accuracy: 99.5%, F1 score: 0.995	استفاده از متد pAST بر پایه ML و pAST NGS - جهت ارزیابی حساسیت استافیلوکوکوس اورئوس به آنتی بیوتیک متی سیلین
Drouin A. (2019) ²⁸	Set Covering Machine	Accuracy: · <i>Staphylococcus aureus</i> : 98.7% · <i>Enterococcus faecium</i> : 100.0% · <i>Escherichia coli</i> : 81.8% · <i>Klebsiella pneumoniae</i> : 95.0% · <i>Pseudomonas aeruginosa</i> : 93.9%	استفاده از متد pAST بر پایه ML و pAST NGS - ارزیابی حساسیت باکتری های زیر به آنتی بیوتیک های ذکر شده در مقابلشان: · استافیلوکوکوس اورئوس: متی سیلین · اتروکوکوس فاسیوم: ونکوما یسین · اشرشیا کلای: کوآموکسی کلاو · کلبسیلا پنومونیه: جنتاما یسین · پseudomonas آئروژینوزا: لوفلوکساسین
Moradi garavand D. (2018) ³⁰	Gradient-boosting decision tree	Average accuracy: 91.0%	استفاده از متد pAST بر پایه ML و pAST NGS - جهت ارزیابی حساسیت اشرشیا کلای به 11 آنتی بیوتیک
Nguyen, M. (2018) ³¹	Gradient-boosting tree	Average accuracy: 92.0%	استفاده از متد pAST بر پایه ML و pAST NGS - جهت ارزیابی MICs برای کلبسیلا پنومونیه جهت تعیین درجه مقاومت به 20 آنتی بیوتیک
Khaledi, A. (2020) ³²	Support vector machine	· Using single-nucleotide polymorphism's information or gene expression data alone: Sensitivity and Predictive value: 0.8-0.9 · In combination: Sensitivity and Predictive value: >0.9	استفاده از متد pAST بر پایه ML و pAST NGS - جهت ارزیابی حساسیت پseudomonas آئروژینوزا به چهار آنتی بیوتیک زیر: · سفنازیدیم · مروپنم · سیپروفلوکساسین · تویراما یسین
Aun, E. (2018) ³³	· Logistic regression برای فنوتیپ های باینری (حساس یا مقاوم) · Linear regression برای فنوتیپ های (MIC value) وسته	· Logistic regression: Accuracy: 88.0%, F1-measure: 0.88 Sensitivity: 0.90, Specificity: 0.87 · Linear regression: Coefficient of determination (R^2): 0.42 Pearson correlation coefficient: 0.68 Spearman correlation coefficient: 0.84	استفاده از متد pAST بر پایه ML و pAST NGS - جهت ارزیابی حساسیت پseudomonas آئروژینوزا به سیپروفلوکساسین

محدودیت‌ها

شایع‌ترین محدودیت‌های موجود در مطالعات یادگیری ماشین، شامل گذشته‌نگر بودن مطالعات و تعداد کم بیماران بوده است.

بحث و نتیجه‌گیری

استفاده از یادگیری ماشین و یادگیری عمیق با کمک در ارزیابی ریسک PJI، بهبود روند معیارسازی جهت تشخیص و تعیین پیش‌آگهی PJI و همچنین ارزیابی حساسیت باکتری‌ها نسبت به آنتی‌بیوتیک‌ها، دریچه‌ای جدید رو به مدیریت این عارضه از آرتروپلاستی گشوده است. از فواید

استفاده از یادگیری ماشین در مطالعات فوق، افزایش دقت و سرعت آنالیز است؛ چرا که مدل‌ها می‌توانند در آن واحد با در نظر گرفتن تمامی ویژگی‌های یک الگوریتم، این کار را انجام دهند و در عین حال بر خلاف متدهای سنتی، قادر به آنالیز متغیرهای پیچیده و غیر خطی نیز می‌باشند. امید است در آینده‌ای نه چندان دور با رفع هر چه بیش‌تر محدودیت‌های مطالعات، ضمن افزایش دقت مطالعات، نرم‌افزارهای مبتنی بر یادگیری ماشین نیز توسعه یابند تا طبابت با تصمیم‌گیری‌های هرچه دقیق‌تر و در زمانی به صرفه‌تر توأم شود. مسلماً مدیریت هر چه بهتر این عارضه از آرتروپلاستی، به بهبود فرایند درمان منتج می‌شود.

References:

1. Rothbauer F, Zerwes U, Bleß H-H, Kip M. Prevalence of hip and knee arthroplasty. White Paper on Joint Replacement: Status of Hip and Knee Arthroplasty Care in Germany; 15-39; 2018.
2. Gademan MG, Hofstede SN, Vliet Vlieland TP, Nelissen RG, Marang-Van de Mheen PJ. Indication criteria for total hip or knee arthroplasty in osteoarthritis: a state-of-the-science overview. BMC musculoskeletal disorders; 11-17:1; 2016.
3. Cushner F, Agnelli G, FitzGerald G, Warwick D. Complications and functional outcomes after total hip arthroplasty and total knee arthroplasty: results from the Global Orthopaedic Registry (GLORY). 2010.
4. Dobson PF, Reed MR. Prevention of infection in primary THA and TKA. EFORT open reviews; 5-13(10): 604; 2020.
5. Rodriguez-Merchan EC, Delgado-Martinez AD. Risk factors for periprosthetic joint infection after primary total knee arthroplasty. Journal of Clinical Medicine. 2022; 11(20): 6128.
6. Parvizi J, Tan TL, Goswami K, Higuera C, Della Valle C, Chen AF, et al. The 2018 definition of periprosthetic hip and knee infection: an evidence-based and validated criteria. The Journal of arthroplasty; 33(5): 1309.e2; 2018.
7. Sherrell JC, Fehring TK, Odum S, Hansen E, Zmistowski B, Dennen A, et al. The Chitranjan Ranawat Award: fate of two-stage reimplantation after failed irrigation and débridement for periprosthetic knee infection. Clinical Orthopaedics and Related Research®. 2011; 25-469: 18.
8. Gardner J, Gioe TJ, Tatman P. Can this prosthesis be saved?: implant salvage attempts in infected primary TKA. Clinical Orthopaedics and Related Research®. 2011; 6-469: 970.
9. Sousa R, Abreu MA. Treatment of prosthetic joint infection with debridement, antibiotics and irrigation with implant retention-a narrative review. Journal of bone and joint infection; 17-108: (3)3; 2018.
10. Davis JS, Metcalf S, Clark B, Robinson JO, Huggan P, Luey C, et al., editors. Predictors of treatment success after periprosthetic joint infection: 24-month follow up from a multicenter prospective observational cohort study of 653 patients. Open Forum Infectious Diseases; 2022: Oxford University Press US.
11. R. Z, R. AAA, Z. AA, A. OM, R. MSM. Investigating the Role of Artificial Intelligence Technology Development in Medicine and Health Promotion. Iranian Journal of Surgery, 1-23: (2)32; 2024.
12. Choi RY, Coyner AS, Kalpathy-Cramer J, Chiang MF, Campbell JP. Introduction to machine learning, neural networks, and deep learning. Translational vision science & technology. 2020; 9-14(2).
13. Tiwari T, Tiwari T, Tiwari S. How Artificial Intelligence, Machine Learning and Deep.
14. Sasikala S, Subhashini S, Alli P, Angelina JJR. Deep Learning Applications in Medical Imaging: Artificial Intelligence, Machine Learning, and Deep Learning. DeepLearning Applications in Medical Imaging: IGI Global; p.178-208; 2021.
15. Alaskar H, Saba T. Machine learning and deep learning: a comparative review. Proceedings of Integrated Intelligence Enable Networks and Computing: IIENC: 50-143; 2020-2021.
16. Cui Z. Machine learning and small data. Educational Measurement: Issues and Practice. 8-12:40(4); 2021.
17. Tripathi AN, Sharma B. A Depth of Deep Learning for Big Data and its Applications. International Journal of Engineering Research & Technology (IJERT) ISSN. 78-81; 2020-2021.
18. Shohat N, Goswami K, Tan TL, Yayac M, Soriano A, Sousa R, et al. 2020 Frank Stinchfield Award: identifying who will fail following irrigation and debridement for prosthetic joint infection: a machine learning-based validated tool. The Bone & Joint Journal. 2020; 102 (7 Supple B): 9-11.
19. Shah AA, Devana SK, Lee C, Kianian R, van der Schaar M, SooHoo NF. Development of a novel, potentially universal machine learning algorithm for prediction of complications after total hip arthroplasty. The Journal of arthroplasty. 1655e1(5): 36-62; 2021.
20. Klemm C, Laurencin S, Uzosiike AC, Burns JC, Costales TG, Yeo I, et al. Machine learning models accurately predict recurrent infection following revision total knee arthroplasty for periprosthetic joint infection. Knee Surgery, Sports Traumatology, Arthroscopy; 25-30(8): 82-90; 2022.
21. Klemm C, Yeo I, Harvey M, Burns JC, Melnic C, Uzosiike AC, et al. The use of artificial intelligence for the prediction of periprosthetic joint infection following aseptic revision total knee arthroplasty. The Journal of Knee Surgery. 37(02): 66-158; 2024.
22. Yeo I, Klemm C, Robinson MG, Esposito JG, Uzosiike AC, Kwon Y-M. The use of artificial neural networks for the prediction of surgical site infection following TKA. The Journal of Knee Surgery. 36(06):43-637; 2023.
23. Turhan S, Canbek U, Dubektas-Canbek T, Dogu E. Predicting Prolonged Wound Drainage after Hemiarthroplasty for Hip Fractures: A Stacked Machine Learning Study. Clinics in Orthopedic Surgery. 15(6): 894; 2023.
24. Wu G, Cheliger C, Southern DA, Martin EA, Xu Y, Leal J, et al. Development of machine learning models for the detection of surgical site infections following total hip and knee arthroplasty: a multicenter cohort study. Antimicrobial Resistance & Infection Control. 12(1): 88; 2023.
25. Kawakami E, Kobayashi N, Ichihara Y, Ishikawa T, Choe H, Tomoyama A, et al. Monitoring of blood biochemical markers for periprosthetic joint infection

- using ensemble machine learning and UMAP embedding. *Archives of Orthopaedic and Trauma Surgery*. 6057(10): 67-143; 2023.
26. Paranjape PR, Thai-Paquette V, Miamidian JL, Parr J, Kazin EA, McLaren A, et al. Achieving high accuracy in predicting the probability of periprosthetic joint infection from synovial fluid in patients undergoing hip or knee arthroplasty: the development and validation of a multivariable machine learning algorithm. *Cureus*. 15(12); 2023.
 27. Albano D, Gitto S, Messina C, Serpi F, Salvatore C, Castiglioni I, et al. MRI-based artificial intelligence to predict infection following total hip arthroplasty failure. *La radiologia medica*. 128(3): 6-340; 2023.
 28. Nie L, Sun Z, Shan F, Li C, Ding X, Shen C. An artificial intelligence framework for the diagnosis of prosthetic joint infection based on 99 mTc-MDP dynamic bone scintigraphy. *European Radiology*. 33(10): 803-6794; 2023.
 29. Kuo F-C, Hu W-H, Hu Y-J. Periprosthetic joint infection prediction via machine learning: comprehensible personalized decision support for diagnosis. *The Journal of Arthroplasty*. 37(1): 41-132; 2022.
 30. Tao Y, Hu H, Li J, Li M, Zheng Q, Zhang G, et al. A preliminary study on the application of deep learning methods based on convolutional network to the pathological diagnosis of PJI. *Arthroplasty*. 4(1): 49; 2022.
 31. Flores-Balado Á, Méndez CC, González AH, Gutierrez RM, de las Casas Cámara G, Cordero BV, et al. Using artificial intelligence to reduce orthopedic surgical site infection surveillance. *Workload: Algorithm design, validation, and implementation in 4 Spanish hospitals. American Journal of Infection Control*. 51(11): 9-1225; 2023.
 32. Davis JJ, Boisvert S, Brettin T, Kenyon RW, Mao C, Olson R, et al. Antimicrobial resistance prediction in PATRIC and RAST. *Scientific reports*. 6(1): 27930; 2016.
 33. Drouin A, Letarte G, Raymond F, Marchand M, Corbeil J, Laviolette F. Interpretable genotype-to-phenotype classifiers with performance guarantees. *Scientific reports*. 9(1): 4071; 2019.
 34. Chong YY, Chan PK, Chan VWK, Cheung A, Luk MH, Cheung MH, et al. Application of machine learning in the prevention of periprosthetic joint infection following total knee arthroplasty: a systematic review. *Arthroplasty*. 5(1): 38; 2023.
 35. Moradigaravand D, Palm M, Farewell A, Mustonen V, Warringer J, Parts L. Prediction of antibiotic resistance in *Escherichia coli* from large-scale pan-genome data. *PLoS computational biology*. 14(12): e1006258; 2018.
 36. Nguyen M, Brettin T, Long SW, Musser JM, Olsen RJ, Olson R, et al. Developing an in silico minimum inhibitory concentration panel test for *Klebsiella pneumoniae*. *Scientific reports*. 8(1): 421; 2018.
 37. Khaledi A, Weimann A, Schniederjans M, Asgari E, Kuo TH, Oliver A, et al. Predicting antimicrobial resistance in *Pseudomonas aeruginosa* with machine learning-enabled molecular diagnostics. *EMBO molecular medicine*. 12(3): e10264; 2020.
 38. Aun E, Brauer A, Kisand V, Tenson T, Remm M. A k-mer-based method for the identification of phenotype-associated genomic biomarkers and predicting phenotypes of sequenced bacteria. *PLoS computational biology*. 14(10): e1006434; 2018.
 39. Hu X, Niemann M, Kienzle A, Braun K, Back DA, Gwinner C, et al. Evaluating ChatGPT responses to frequently asked patient questions regarding periprosthetic joint infection after total hip and knee arthroplasty. *Digital Health*. 10: 20552076241272620; 2024.