JRU
Journal of Research in Urology
J Res Urol, 2024; 8(1): --- Doi: 10.32592/jru.8.1.--
https://urology.umsha.ac.ir/

Original Article

Prediction of Urinary Tract Infection for Hospital-admitted Patients based on Demographic and Historical Data, as well as Machine Learning Approaches

Sajjad Farashi[1,2*], Hossein Emad Momtaz[3*]

1. Neurophysiology Research Center, Institute of Neuroscience and Mental Health, Avicenna Health Research Institute, Hamadan University of Medical Sciences, Hamadan, Iran
2. Urology and Nephrology Research Center, Avicenna Institute of Clinical Sciences, Avicenna Health Research Institute, Hamadan University of Medical Sciences, Hamadan, Iran
3. Department of Pediatrics, School of Medicine, Ekbatan Hospital, Hamadan University of Medical Sciences, Hamadan, Iran

Article history:
Received: 16 June 2024
Revised: 03 December 2024
Accepted: 11 December 2024

*Corresponding author: Sajjad Farashi, Neurophysiology Research Center, Institute of Neuroscience and Mental Health, Avicenna Health Research Institute, Hamadan University of Medical Sciences, Hamadan, Iran

Email: sajjad_farashi@yahoo.com

Hossein Emad Momtaz
Department of Pediatrics, School of Medicine, Ekbatan Hospital, Hamadan University of Medical Sciences, Hamadan, Iran

Email: hemmtz@yahoo.com

Abstract

Background and Objective: Urinary tract infection (UTI) is one of the common infections that affects the urinary system. UTI can be detected using analysis of urine culture which is a time-consuming and error-prone procedure. The fast prediction of UTI helps to start antibiotic medication at the correct time and prior to the culture report. The present study aimed to assess the potential of artificial intelligence for UTI prediction.

Materials and Methods: The current study was conducted based on the published data from a retrospective cohort study that was performed on 300, 000 human samples in Denmark. The performance of machine learning algorithms, including support vector machines, decision trees, linear discriminant analysis, and linear regression models, was investigated for UTI prediction according to historical and demographical features.

Results: The obtained results pointed out that UTI prediction using a linear discriminant analysis model with an accuracy of 65.16±0.64% was possible. Among the features, age had a significant effect on UTI prediction where the model accuracy rates for elderly, adult, young, and infant cases were reported as 73.64, 86.25, 39.42, and, 60.60%, respectively. In addition, the results demonstrated that the classification performance was better for adults compared to younger participants. The most informative features were also suggested according to the neighborhood component analysis.

Conclusion: The results of this study highlighted the potential of artificial intelligence for fast UTI prediction; nonetheless, the performance needs to be enhanced by the addition of other fast-accessible features.

Keywords: Infection, Machine learning, Prognosis, Urinary tract

Please cite this article as follows: Farashi S, Momtaz HE. Prediction of Urinary Tract Infection for Hospital-admitted Patients based on Demographic and Historical Data, as well as Machine Learning Approaches. J Res Urol 2024; 8(1):---. DOI: 10.32592/jru.8.1.-

Copyright © 2024 Journal of Research in Urology. This is an open-access article distributed under the terms of the Creative Commons Attribution-NonCommercial 4.0 International License (http://creativecommons.org/licenses/by-nc/4.0/) which permits copy and redistribute the material just in noncommercial usages, provided the original work is properly cite

JRU
تحقیقات در ارولوژی
دوره ۸، شماره ۱، بهار و تابستان ۱۴۰۳، صفحات: ---
https://urology.umsha.ac.ir/
UMSHA Press

مقاله اصلی

پیش‌بینی عفونت ادراری در بیماران بستری در بیمارستان براساس داده‌های دموگرافیک و سوابق پزشکی مبتنی‌بر رویکردهای یادگیری ماشین

سجّاد فراشی[۱،۲*]، حسین عماد ممتاز[۳*]

۱. پژوهشکده علوم اعصاب و سلامت روان، پژوهشگاه سلامت ابن‌سینا، دانشگاه علوم‌پزشکی همدان، همدان، ایران
۱. مرکز تحقیقات اورولوژی و نفرولوژی، پژوهشکده علوم بالینی ابن‌سینا، پژوهشگاه سلامت ابن‌سینا، دانشگاه علوم‌پزشکی همدان، همدان، ایران
۲. گروه اطفال، دانشکده پزشکی، دانشگاه علوم‌پزشکی همدان، همدان، ایران

تاریخ دریافت مقاله: ۱۴۰۳/۰۳/۲۷
تاریخ ویرایش مقاله: ۱۴۰۳/۰۹/۱۳
تاریخ پذیرش مقاله: ۱۴۰۳/۰۹/۲۱

تمامی حقوق نشر برای دانشگاه علوم‌پزشکی همدان محفوظ است.

* نویسنده مسئول: سجّاد فراشی، پژوهشکده علوم اعصاب و سلامت روان، پژوهشگاه سلامت ابن‌سینا، دانشگاه علوم‌پزشکی همدان، همدان، ایران

ایمیل: sajjad_farashi@yahoo.com

حسین عماد ممتاز، گروه اطفال، دانشکده پزشکی، دانشگاه علوم‌پزشکی همدان، همدان، ایران

ایمیل: hemmtz@yahoo.com

چکیده

سابقه و هدف: عفونت ادراری (UTI) یکی از عفونت‌های شایع است که سیستم ادراری را تحت‌تأثیر قرار می‌دهد. روش تشخیص استاندارد UTI تجزیه‌وتحلیل کشت ادرار است. بااین‌حال، این روش تشخیصی زمان‌بر بوده و به‌شدت مستعد خطاست. با توجه به اینکه پیش‌بینی سریع عفونت ادراری به شروع به‌موقع مصرف آنتی‌بیوتیک و کنترل بهینه‌تر عفونت ادراری کمک می‌کند، توسعه روش‌های تشخیص سریع‌تر موردتوجه محقّقان این حوزه قرار دارد.

مواد و روش‌ها: مطالعه حاضر براساس داده‌های منتشرشده یک مطالعه کوهورت گذشته‌نگر که در کشور دانمارک و با حجم نمونه ۳۰۰۰۰۰ به انجام رسیده، انجام شده است. در مطالعه حاضر و براساس داده موجود، توانمندی الگوریتم‌های یادگیری ماشین شامل بردارهای پشتیبان، درخت تصمیم‌گیر، آنالیز تفکیک‌کننده خطّی و ماشین رگرسیون خطّی در پیش‌بینی عفونت ادراری براساس پیش‌گوکننده‌هایی نظیر سوابق پزشکی و داده‌های دموگرافیک برای بیماران بستری در بیمارستان ارزیابی شده است.

یافته‌ها: نتایج این مطالعه نشان داد که طبقه‌بندی تفکیک‌کننده خطّی با دقت ۰/۶۴±۶۵/۱۶ پیش‌بینی UTI را با استفاده از ویژگی‌های دموگرافیک و سوابق پزشکی بیمار انجام می‌دهد. از میان ویژگی‌ها، سن تأثیر قابل‌توجهی بر پیش‌بینی UTI داشت؛ به‌نحوی‌که دقت مدل در تشخیص UTI در نمونه‌های کهن‌سال، بزرگ‌سال، کودک و جوان به ترتیب ۷۳/۶۴، ۸۶/۲۵، ۳۹/۴۲ و ۶۰/۶۰ بوده است. ویژگی‌های با قدرت تمایز بالا نیز با توجه به تجزیه‌وتحلیل مؤلّفه‌های همسایگی پیشنهاد شد.

نتیجه‌گیری: نتایج این مطالعه پتانسیل هوش مصنوعی را برای پیش‌بینی سریع UTI نشان می‌دهد. بااین‌حال، عملکرد سیستم پیش‌بینی‌کننده با افزودن ویژگی‌های دیگر قابل‌افزایش خواهد بود.

واژگان کلیدی: دستگاه ادراری، عفونت، پیش‌بینی، یادگیری ماشین

استناد: فراشی، سجاد؛ عمادممتاز. پیش‌بینی عفونت ادراری در بیماران بستری در بیمارستان براساس داده‌های دموگرافیک و سوابق پزشکی مبتنی‌بر رویکردهای یادگیری ماشین.تحقیقات در ارولوژی، بهار و تابستان ۱۴۰۳: ۸ (۱): ---

مقدمه

عفونت‌های دستگاه ادراری Urinary tract infection(UTI) عفونت‌های شایعی هستند که چندین قسمت از دستگاه ادراری ازجمله کلیه‌ها و مثانه را تحت‌تأثیر قرار می‌دهند. براساس گزارش‌ها، ۵۰ درصد از زنان حداقل یک‌بار عفونت ادراری را در طول زندگی خود تجربه می‌کنند [۱]. عفونت‌های ادراری همچنین یکی از علل اصلی مرگ‌ومیر در دنیا هستند. UTI ازنظرِ بالینی براساس علائم بالینی و تجزیه‌وتحلیل کشت ادرار تشخیص داده می‌شود. بااین‌حال، راهبردهای تشخیص‌دهنده فعلی کمتر از حدّ مدّنظرِ

بهینه و همچنین زمان‌بر هستند [۲]. زمان طولانی موردنیاز برای در دسترس بودن جواب آزمایش‌های کشت ادرار (حدود ۴۸ تا ۷۲ ساعت) و همچنین روش‌های مورداستفاده برای تهیه نمونه ادرار که بسیار مستعد آلوده شدن نمونه به آلودگی‌های محیطی هستند، ازجمله موارد مشکل‌ساز در تشخیص‌های فعلی عفونت‌های ادراری‌اند. علاوه‌براین، روش‌های تشخیص بالینی فعلی نیز تا ۳۳ درصد مستعد خطا هستند [۳]. این مسائل ضرورت توسعه روش‌های تشخیصی مکمّل را برجسته می‌کنند.

چندین عامل ازجمله عفونت‌های ادراری قبلی، سن [۴]، دیابت [۵]، قرار گرفتن در معرض محرّک‌های محیطی و عوامل ژنتیکی [۶]، فعالیت جنسی و بی‌اختیاری ادرار [۷] از ریسک فاکتورهای بالقوّه عفونت ادراری هستند. علاوه‌براین، علائم عصبی حاد ممکن است باUTI در ارتباط باشند [۸]. ازاین‌رو، براساس شواهد موجود می‌توان انتظار داشت که مشخصه‌های دموگرافیک و سوابق پزشکی حاوی اطلاعات ارزشمندی برای پیش‌بینی احتمال UTI در زمان فعلی یا آینده باشند.

هوش مصنوعی (AI) یکی از استراتژی‌های ممکن برای تشخیص و پیش‌بینی UTI است [۹]. هوش مصنوعی با استفاده از الگوریتم‌های یادگیری ماشین سعی می‌کند از برنامه‌های کامپیوتری برای تجزیه‌وتحلیل داده‌های به‌دست‌آمده از ادرار انسان (یعنی داده‌های آزمایشگاهی) و داده‌های مشاهده‌ای، داده‌های سوابق پزشکی و غیره استفاده کند تا الگوهای پنهان مرتبط با سلامت دستگاه ادراری را از این‌دست داده‌ها شناسایی کند. هدف اصلی هوش مصنوعی، یافتن مهم‌ترین عوامل مخدوش‌کننده، یافتن رابطه و تعامل بین عوامل و درنتیجه شناسایی موارد فعلی ریسک یا پیش‌بینی نتایج آینده است. به‌طور خلاصه، هوش مصنوعی در غربالگری سلامت ادرار برای استخراج قوانین مفید برای تشخیص، پیش‌بینی و ارزیابی درمان استفاده می‌شود [۱۰].

برتون و همکاران (۲۰۱۹) از هوش مصنوعی برای یافتن مهم‌ترین مشخصه‌های نمونه‌های ادرار جهت پیش‌بینی ضرورت کشت باکتریایی استفاده کردند [۱۱]. این مطالعه نشان داد که رویکرد هوش مصنوعی ممکن است به کاهش ۳۹/۱ درصدی در لزوم کشت ادرار در تشخیص UTI منجر شود. گروهی از محقّقان مدلی را برای تشخیص کودکان با خطر عفونت ادراری بالا ایجاد کردند. این مدل متغیّرهایی مانند سن، جنسیت، نژاد، فشارخون، سوزش ادرار، مواجهه قبلی با آنتی‌بیوتیک‌ها و نسبت آلبومین و کراتینین ادرار را دربر می‌گرفت. سطح زیرمنحنی مشخصه عملکرد برای کار طبقه‌بندی (شناسایی کودکانِ درمعرض‌خطر) برای مطالعه آن‌ها ۰/۷۶ بود. این مدل می‌توانست مداخله پزشکی را برای کودکان UTI بهینه‌تر کند [۱۲]. اوزکان و همکاران (۲۰۱۸) با استفاده از معاینه معمول ادرار و تصاویر سونوگرافی پزشکی از سیستم ادراری و استفاده از چندین ابزار یادگیری ماشین (شامل شبکه‌های عصبی مصنوعی، ماشین‌های بردار پشتیبان، درخت‌های تصمیم‌گیر و جنگل تصادفی) سیستمی را برای تشخیص UTI پیشنهاد کردند [۱۰]. چنین سیستمی با استفاده از شبکه عصبی مصنوعی دقت طبقه‌بندی ۹۸/۳٪ را به دست می‌داد. گادالا Gadalla و همکاران (۲۰۱۹) به‌منظور تشخیصUTI از الگوریتم‌های یادگیری ماشین برای یافتن نشانگرهای زیستی ایمونولوژیک در نمونه‌های ادرار استفاده کردند. براساس مطالعه نان، با توجه به نتایج یادگیری ماشین، این امکان وجود دارد که بتوان برای موارد آسیب‌پذیر، راهکار درمانی مشخصی را ارائه کرد و از این طریق مخاطرات درمان را کاهش داد [۱۳]. جنگ Jeng و همکاران (۲۰۲۲) مدل‌های یادگیری ماشین را برای پیش‌بینی UTI عودکننده پیشنهاد کردند [۱۴]. آنان یک مدل جنگل تصادفی را با دقت ۷۰ درصد برای پیش‌بینی پیشنهاد دادند. دونگ و همکاران (۲۰۲۲) عملکرد تشخیصی ترکیب AI و میکروتصویربرداری جریان را برای غربالگری سریع UTI بررسی کردند [۱۵]. نتایج این مطالعه توانمندی هوش مصنوعی را برای شناسایی سریع UTI نشان داد. اگرچه تاکنون چندین مطالعه برای توسعه ماشین‌های هوشمند جهت پیش‌بینیUTI انجام شده است، با توجه به پایین بودن دقت روش‌های پیشنهادی و یا دشواریِ در دسترس بودن داده‌های موردنیاز، همچنان نیاز به انجام مطالعات بیشتر وجود دارد.

در مطالعه حاضر، رهیافت یادگیری ماشین برای مجموعه‌ای از داده‌های آنلاین UTI که در دسترس عموم قرار دارند، مورداستفاده قرار گرفته است. به‌صورت ویژه، ارتباط بین برخی از فاکتورهای موارد مشکوک به عفونت ادراری نظیر سن، جنسیت، سابقه عفونت و سابقه سایر بیماری‌ها با خطر عفونت ادراری بررسی شده است. علاوه‌براین، کاربرد این دسته از فاکتورها برای تعیین حساسیت یک بیمار بستری در بیمارستان به UTI قبل از در دسترس بودن نتیجه کشت ادرار بررسی شده است. فرض این مطالعه بر این است که عوامل ذکرشده در بالا امکان توسعه یک مدل (ماشین هوشمند) برای پیش‌بینی UTI پیش از در دسترس قرار گرفتن جواب آزمایش کشت ادرار را به دست می‌دهند.

روش کار

توصیف داده

مجموعه‌داده‌های مورداستفاده در مطالعه حاضر داده‌های در دسترس عمومی هستند که ازطریق لینک doi.org/۱۰.۵۰۶۱/dryad.6djh9w107 قابل‌دسترس‌اند [۱۶]. این داده مربوط به بیماران بستری‌شده با علائم UTI در چهار بیمارستان در جنوب دانمارک است. برای بیماران بستری‌شده، از نتایج کشت ادرار برای برچسب زدن هر بیمار به‌عنوان مبتلا به UTI یا سالم (گروه شاهد یا غیرمبتلا) استفاده شده است. برای هر بیمار، داده‌هایی ازجمله تاریخ و محلّ بستری، اطلاعات دموگرافیک (جنس، سن و شناسه بیمار)، کدهای تشخیص سوابق بیماری (بیماری انسدادی مزمن ریه، احتباس ادرار و بیماری عصبی)، تعداد UTI های قبلی، کاتتر ادراری ساکن (IUC) و نوع بستری (حاد یا

برنامه‌ریزی‌شده) ثبت شده است. کدهای تشخیصی، متغیّرهای طبقه‌بندی هستند [بله (۱) یا خیر (۰)]، درحالی‌که تعداد UTIهای قبلی، کاتترهای ادراری ساکن (IUC) و همچنین متغیّر سن، متغیّرهای عددی هستند. این متغیّرها به‌عنوان عوامل خطر برای پیش‌بینی UTI در آینده در نظر گرفته شده‌اند. حجم نمونه این مجموعه‌داده ۳۰۱۹۰۳ (۵۳/۸۵ درصد زن) و میانگین سنّ شرکت‌کنندگان ۲۶/۹۰±۵۰/۰۴ سال است. داده‌ها در بازه ژانویه ۲۰۱۷ تا آوریل ۲۰۱۸ و می ۲۰۱۸ جمع‌آوری شده‌اند. بازه زمانی ثبت داده‌ها (بیش از یک سال) تضمین کرده است که نتایج تجزیه‌وتحلیل‌ها نسبت به تغییرات فصلی بیماری‌های عفونت دستگاه ادراری حسّاس نباشد [۱۶].

فضای ویژگی

مجموعه‌داده استفاده‌شده در این مطالعه شامل اطلاعات متفاوتی برای هر شرکت‌کننده است که ازآن‌جمله می‌توان به سنّ شرکت‌کننده، جنسیت (مرد یا زن)، بستری مجدّد (درست یا نادرست)، وجود بیماری مزمن انسدادی ریه (COPD)، احتباس ادرار، بیماری عصبی، تعداد عفونت‌های دستگاه ادراری مرتبط با بیمارستان قبلی (previous_HAI_UTI)، عفونت‌های دستگاه ادراری مرتبط با جامعه (previous_CAI_UTI) و تعداد کاتتر ادراری ساکن (IUT) اشاره کرد. در این مطالعه، ترکیب CAI قبلی و HAI یک متغیّر منفرد (یعنی عفونت‌های قبلی) در نظر گرفته شده است. این اطلاعات به‌عنوان مجموعه ویژگی‌های اوّلیه در نظر گرفته شده‌اند. با استفاده از روش‌های آماری و همچنین تحلیل هم‌بستگی، ارتباط احتمالی بین ویژگی‌های اوّلیه بررسی شد و روش‌های کاهش بُعد داده مانند تجزیه‌وتحلیل مؤلّفه‌های اصلی (PCA) و تجزیه‌وتحلیل مؤلّفه‌های همسایگی (NCA) [۱۷] برای کاهش اندازه فضای ویژگی استفاده شدند.

الگوریتم‌های یادگیری ماشین و طبقه‌بندی

هدف اصلی مطالعه حاضر ایجاد یک مدل پیش‌بینی براساس اطلاعات دموگرافیک و سوابق بیماری بیماران بستری‌شده در بیمارستان جهت پیش‌بینی احتمال عفونت ادراری است. برای این منظور، انواع مختلفی از طبقه‌بندهای با ناظر شامل درخت‌های تصمیم‌گیر (decision tree)، ماشین‌های بردار پشتیبان (SVM)، نزدیک‌ترین K همسایگی (KNN)، آنالیز تفکیک‌کننده خطّی (discriminant analysis) و طبقه‌بندی رگرسیون خطّی مورداستفاده قرار گرفتند. با استفاده از روش‌های بهینه‌سازی پارامترها که با انتخاب تصادفی ۱۰٪ از داده‌های آموزش و روش جست‌وجوی تصادفی صورت پذیرفته است، پارامترهای بهینه هر روش یادگیری ماشین یافت شده‌اند. براین‌اساس، برای طبقه‌بند درخت تصمیم‌گیر، حداقل اندازه برگ ۳ و حداکثر تعداد تقسیم‌بندی ۷ تنظیم شد. برای طبقه‌بندی‌کننده SVM، از یک هسته خطّی استفاده شد؛ زیرا مشاهدات ما نشان داد که این هسته بهترین نتیجه را به دست می‌دهد. برای طبقه‌بندی KNN، تعداد همسایگی ۱۰۰ و برای طبقه‌بند تفکیک‌کننده خطّی از کرنل خطّی استفاده شد. برای یادگیری، اعتبارسنجی و آزمایش مدل، مجموعه‌داده با استفاده از روش نمونه‌گیری تصادفی بدون جایگزینی به داده‌های آموزش، تست و اعتبارسنجی تقسیم شد. عملکرد طبقه‌بند آموزش‌دیده با استفاده از داده‌های آموزش براساس داده‌های اعتبارسنجی و مجموعه‌داده‌های آزمایشی ارزیابی شد. هر طبقه‌بند توسط یک مجموعه‌داده (۹۰٪ از کل مجموعه‌داده آموزش) آموزش داده و با استفاده از مجموعه‌داده دیگر (۱۰٪ از کل مجموعه‌داده آموزش) اعتبارسنجی گردید. به‌منظور جلوگیری از بیش‌برازش مدل، از روش اعتبارسنجی متقابل K-fold (K=۱۰) استفاده شده است. عملکرد طبقه‌بند برای پیش‌بینی UTI با استفاده از داده‌های تست با حسّاسیت، ویژگی و دقت به ترتیب با استفاده از روابط ۱-۳ ارزیابی شد:

$$SE = \frac{TP}{TP+FN} \quad (۱)$$

$$SP = \frac{TN}{TN+FP} \quad (۲)$$

$$ACC = \frac{TP+TN}{TP+TN+FP+FN} \quad (۳)$$

که در آن TP ، FN، TN و FP به ترتیب نشان‌دهنده مثبت درست، منفی کاذب، منفی درست و مثبت کاذب بودند. قابل‌ذکر است که بخش بزرگی از مجموعه‌داده (۹۳/۷۴ درصد) مربوط به موارد غیرمبتلا بود. این مسئله سبب نامتعادل شدن و بالانس نبودن مجموعه‌داده شده است. با توجه به بزرگ‌تر بودن حجم نمونه در گروه سالم، به‌منظور نزدیک کردن حجم داده‌ها در دو گروه سالم و بیمار، از روش down-sampling با انتخاب تصادفی نمونه‌ها استفاده شده است.

آنالیز آماری

برای مقایسه ویژگی‌های گروه‌های مبتلا و سالم (شاهد)، از آزمون کای ۲ استفاده شد. فرضیه صفر این بود که دو گروه با در نظر گرفتن یک ویژگی خاص متفاوت هستند. علاوه‌براین، ارتباط بین متغیّرها با استفاده از آزمون کوکران- مانتل- هنزل [۱۸] ارزیابی شد. اگر مقدار p کوچک‌تر از ۰/۰۵ باشد، فرضیه ارتباط بین متغیّرها رد می‌شود. رابطه خطّی بین متغیّرها با استفاده از هم‌بستگی پیرسون و chi-squared p-value محاسبه شد.

یافته ها

آنالیز آماری داده

در مجموعه‌داده اصلی، ۶/۲۶٪ موارد UTI مثبت بودند، درحالی‌که سایر داده‌ها (۹۳/۷۴٪) نمونه‌های UTI منفی بودند.

۵۸/۴۵ درصد موارد در گروه مبتلا زن و در گروه سالم ۵۳/۵۳ درصد زن بودند. به‌منظور بررسی هم‌بستگی بین عوامل، تجزیه‌وتحلیل آماری و همچنین تحلیل هم‌بستگی انجام شد. متغیّرهای حشوRedundant Variables را می‌توان داده‌های زائد در نظر گرفت که تأثیر قابل‌توجهی بر عملکرد طبقه‌بندی نخواهند داشت. تجزیه‌وتحلیل آماری با استفاده از آزمون کای ۲ برای مقایسه نسبت برابر COPD (χ^2 برابر p،۷۵۲/۲۵ کوچک‌تر از ۰/۰۰۱)، احتباس ادرار (χ^2 برابر ۱۶۵۶/۹ و p کوچک‌تر از ۰/۰۰۱) و اختلالات عصبی (χ^2 برابر ۸۰۴ و p کوچک‌تر از ۰/۰۰۱) فرضیه صفر را رد کرد. این نتیجه نشان‌دهنده اهمیت این عوامل مخدوش‌کننده برای تمایز بین UTI و موارد سالم (شاهد) بود. برای آزمون اثر متقابل احتمالی بین این سه عامل، از آزمون کوکران مانتل هانزل استفاده شد.

همچنین، تحلیل هم‌بستگی بین زوج متغیّرها با استفاده از هم‌بستگی پیرسون انجام شد. نتایجْ هم‌بستگی ضعیفی را بین این عوامل نشان داد [COPD در مقابل احتباس ادرار (مقدار هم‌بستگی پیرسون برابر ۰/۰۳۵، p کوچک‌تر از ۰/۰۰۱)؛ COPD در مقابل اختلالات عصبی (مقدار هم‌بستگی برابر ۰/۰۵۳، p کوچک‌تر از ۰/۰۰۱)؛ احتباس ادرار در مقابل اختلالات عصبی (مقدار هم‌بستگی برابر ۰/۰۴۷، p کوچک‌تر از ۰/۰۰۱)]. این آزمون‌ها نشان داد که بین سه عامل COPD، احتباس ادرار و اختلالات عصبی اثر متقابل بسیارکوچک (کوچک‌تر از ۰/۵)، اما معناداری وجود دارد. دراین‌راستا، این متغیّرها را می‌توان متغیّرهای غیرهمبسته‌ای در نظر گرفت که آن‌ها را برای اهداف طبقه‌بندی مناسب می‌کند. علاوه‌براین، تجزیه‌وتحلیل هم‌بستگی نشان داد که هیچ رابطه خطّی بین عفونت قبل از بستری، حین بستری و موارد کاتتر ادراری ساکن وجود ندارد (مقدار هم‌بستگی برابر صفر). با در نظر گرفتن سنّ نمونه‌ها، چهار گروه کودکان (۰-۱۴ سال)، جوانان (۱۵-۲۴ سال)، بزرگ‌سالان (۲۵-۶۴ سال) و سالمندان (بیش از ۶۵ سال) در نظر گرفته شدند. آزمون t مستقل نشان داد که تفاوت معنی‌داری در تعداد دفعات بروز عفونت‌های ادراری پیشین بین نمونه‌های مبتلا و غیرمبتلا در بازه‌های سنّیِ مختلف وجود ندارد (p<۰/۰۱). مقایسه گرافیکی میزان UTI در شکل ۱ برای جنسیت‌ها و بازه‌های سنّی مختلف نشان داده شده است.

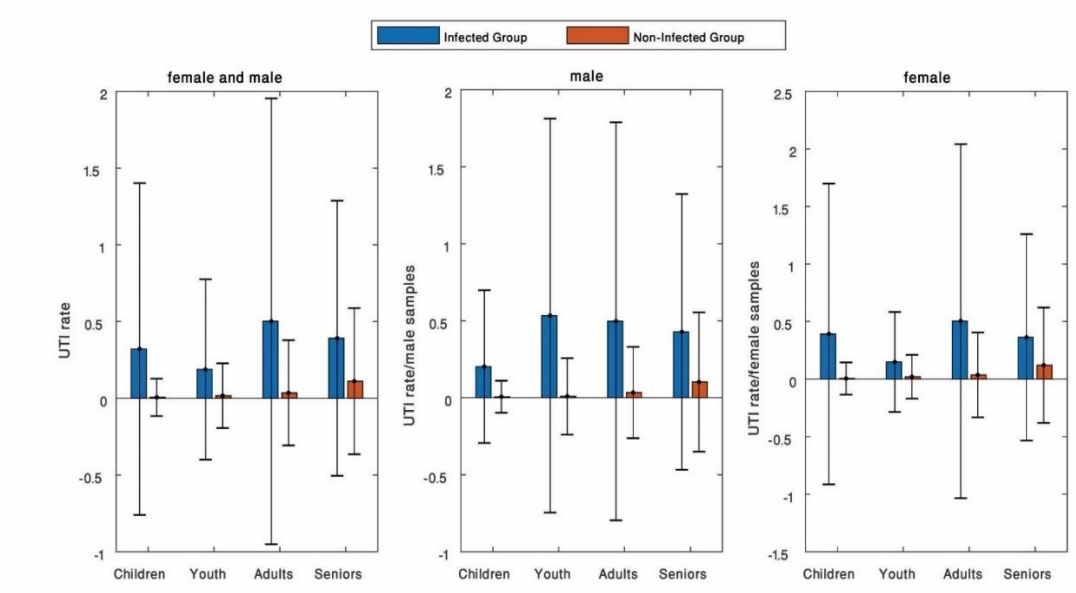

شکل ۱- مقایسه میانگین تعداد عفونت‌های پیشین UTI بین بازه‌های سنّی مختلف برای گروه‌های مبتلا و سالم

نتایج طبقه‌بندی

با در نظر گرفتن مجموعه ویژگی‌های اصلی (سن، جنس، بستری مجدّد، COPD، احتباس ادرار، بیماری عصبی، تعداد UTI های قبلی و تعداد IUC)، نتایج طبقه‌بندی با استفاده از انواع مختلف طبقه‌بندی‌ها برای پیش‌بینی UTI در جدول ۱ گزارش شده است. براساس نتایج جدول ۱، حداکثر دقت به طبقه‌بند درخت تصمیم‌گیر مربوط می‌شود؛ به‌نحوی‌که با کاهش ابعاد ویژگی با روش NCA و PCA دقت به ترتیب ۷۱/۷۸٪ و ۶۹/۵۶٪ بوده است. دقت بالاترِ طبقه‌بندِ درخت تصمیم‌گیر برای تکرارهای مختلف طبقه‌بندی (با استفاده از مجموعه‌های مختلف داده‌های آموزش و تست) همراه با تغییرپذیری نسبتاً بالایی است، درحالی‌که سایر طبقه بندها نتایجی با تغییرپذیری کمتر به دست می‌دهند. طبق نتایج جدول ۱، طبقه‌بند بعدی با دقت بالاتر، طبقه‌بند تفکیک‌کننده خطّی بود. دراین‌راستا، این دو نوع طبقه‌بند (درخت تصمیم‌گیر و تفکیک‌کننده خطّی) برای تفسیر نتایج انتخاب شدند. ازآنجایی‌که حسّاسیت (نرخ تشخیص درست موارد مبتلا به عفونت ادراری) بیشتر از ویژگی (نرخ تشخیص درست موارد غیرمبتلا به عفونت ادراری) مدّنظر بوده است، طبقه‌بند تفکیک‌کننده خطّی با مجموعه

ویژگی اوّلیه (بدون کاهش بُعد) در این مطالعه انتخاب شد (جدول ۱ را ببینید). با توجه به شکل ۲، دو متغیّر سن (x۱) و تعداد UTI های قبلی (x۷) عوامل خطر مهمّی بودند که پیش‌بینی UTI های آینده را امکان‌پذیر می‌کنند. سنّ ۵۷/۵ سال یک مقدار بحرانی بود، به‌گونه‌ای‌که افراد بالای ۵۷/۵ سال و عفونت‌های قبلی در معرض خطر بیشتری برای UTI بودند. درحالی‌که برای افراد کمتر از ۵۷/۵ سال و خطر کمتر UTI قبلی، احتمال UTI ممکن است به‌طور قابل‌توجهی کاهش یابد. برای افراد بالای ۵۷/۵ سال، سنّ بحرانیِ دیگر ۷۷/۵ سال بود که در آن خطر عفونت ادراری بدون سابقه قبلی UTI نیز قابل‌توجه بوده است.

جدول ۱. عملکرد طبقه‌بندی‌های مختلف برای پیش‌بینی UTI براساس داده‌های دموگرافیک و سابقه بیماری؛ خطای طبقه‌بندی با استفاده از رهیافت ۱۰-fold cross-validation در فاز آموزش و به‌صورت (۱-دقت) ×۱۰۰ محاسبه شده است. برای این منظور، داده‌های آموزش با نسبت ۸۰ به ۲۰ جهت آموزش و اعتبارسنجی به‌صورت تصادفی تفکیک شده‌اند.

ویژگی	طبقه‌بندی	خطای طبقه‌بندی برای داده‌های اعتبارسنجی	حسّاسیت	ویژگی	دقّت	AUC (Area Under Curve)
Original feature set	Decision Tree	۲۹/۰۴±۰/۱۸	۷۴/۹۲±۱۳/۰۶	۷۴/۹۲±۱۳/۰۶	۶۷/۷۶±۱۰/۶۶	۰/۷۱±۰/۰۰
	SVM	۲۸/۱۶±۰/۰۸	۶۱/۵۰±۱/۳۲	۸۲/۲۰±۱/۵۲	۶۳/۵۷±۱/۰۴	۰/۷۲±۰/۰۰
	KNN	۲۹/۹۱±۰/۲۹	۵۴/۶۰±۰/۷۰	۸۵/۹۹±۰/۸۹	۵۷/۷۴±۰/۶۱	۰/۷۰±۰/۰۰
	Discriminant analysis	۲۷/۹۹±۰/۱۴	۸۰/۹۳±۱/۰۲	۶۳/۴۱±۰/۷۹	۶۵/۱۶±۰/۶۴	۰/۷۲±۰/۰۱
	Linear classifier	۲۸/۲۶±۰/۵۹	۶۱/۶۶±۰/۶۴	۸۲/۱۴±۱/۰۹	۶۳/۷۱±۰/۵۵	۰/۷۲±۰/۰۰
Reduced feature set by PCA	Decision Tree	۲۹/۱۳±۰/۲۷	۶۹/۳۰±۱۳/۱۵	۷۱/۹۱±۱۲/۷۸	۶۹/۵۶±۱۰/۵۷	۰/۷۱±۰/۰۰
	SVM	۲۸/۱۷±۰/۰۹	۶۱/۳۸±۱/۷۹	۸۱/۹۲±۲/۲۹	۶۳/۴۳±۱/۴۲	۰/۷۲±۰/۰۰
	KNN	۲۹/۵۹±۰/۲۶	۵۵/۰۷±۰/۶۶	۸۵/۳۱±۱/۰۲	۵۸/۰۹±۰/۵۹	۰/۷۰±۰/۰۰
	Discriminant analysis	۲۷/۹۷±۰/۱۶	۶۳/۵۲±۰/۷۹	۸۰/۸۳±۱/۰۳	۶۵/۲۵±۰/۶۷	۰/۷۲±۰/۰۰
	Linear classifier	۲۸/۲۹±۰/۶۵	۵۶/۷۷±۱۷/۵۸	۸۳/۱۵±۶/۵۸	۵۹/۴۱±۱۵/۲۱	۰/۷۰±۰/۰۶
Reduced feature set by NCA	Decision Tree	۲۹/۲۲±۰/۲۲	۷۲/۰۱±۱۲/۰۲	۶۹/۷۴±۱۱/۷۴	۷۱/۷۸±۹/۶۵	۰/۷۱±۰/۰۰
	SVM	۲۸/۶۲±۰۰.۰	۵۴/۷۹±۰/۴۱	۸۶/۶۳±۰/۴۲	۵۷/۹۷±۰/۳۷	۰/۷۱±۰/۰۰
	KNN	۲۹/۷۲±۰/۳۲	۵۴/۸۲±۰/۷۱	۸۵/۹۴±۱/۰۷	۵۷/۹۳±۰/۶۰	۰/۷۰±۰/۰۰
	Discriminant analysis	۲۸/۰۲±۰/۱۲	۶۳/۵۴±۰/۳۶	۸۰/۸۶±۰/۴۲	۶۵/۲۷±۰/۲۹	۰/۷۲±۰/۰۰
	Linear classifier	۲۸/۱۲±۰/۲۶	۶۱/۲۵±۰/۴۵	۸۲/۳۱±۰/۵۹	۶۳/۳۶±۰/۴۳	۰/۷۲±۰/۰۰

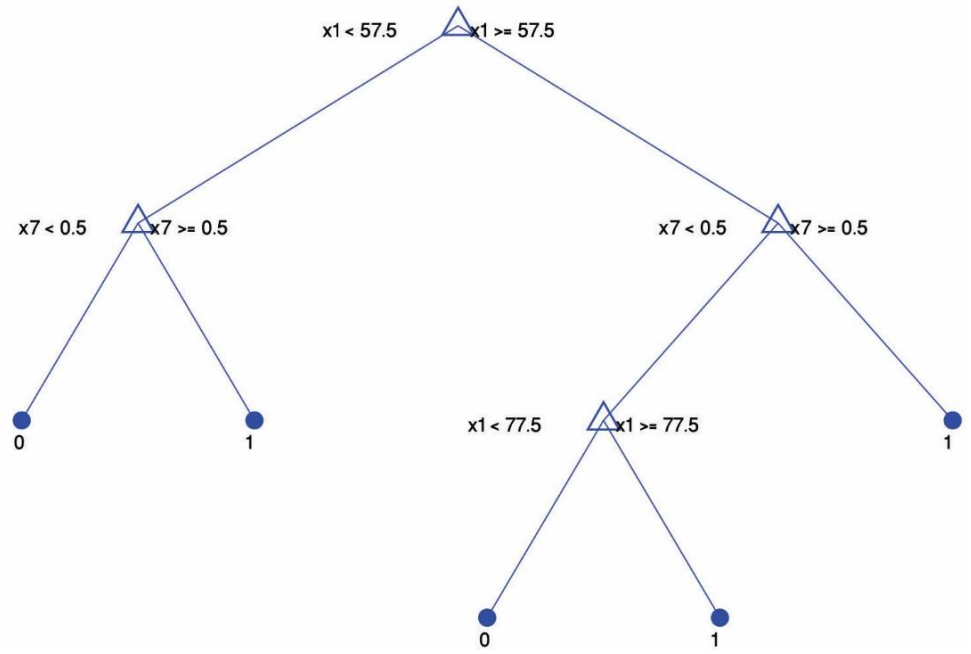

شکل ۲. شماتیک نمودار طبقه‌بندِ درخت تصمیم‌گیر با بهترین دقّت طبقه‌بندی: X۱ سن، و x۷ تعداد UTI قبلی

روش NCA برای کاهش بُعد ویژگی، وزنی را برای هریک از ویژگی‌ها با توجه به اهمیت آن ویژگی در طبقه‌بندی به دست

می‌آورد. وزن‌های به‌دست‌آمده در جدول ۲ گزارش شده‌اند. براساس جدول ۲، بااهمیت‌ترین ویژگی‌ها براساس NCA به ترتیب سن، سابقه قبلی عفونت ادراری، بستری مجدّد و بیماری عصبی بودند. سایر ویژگی‌ها مانند جنسیت، COPD، احتباس ادرار و IUC های قبلی سهم قابل‌توجهی در طبقه‌بندی نداشتند.

نتایج شکل ۲ و جدول ۲ تأثیر قابل‌توجه سن را بر پیش‌بینی UTI نشان می‌دهند. به‌عنوان تحلیل دیگری، سن از فضای ویژگی حذف شد و طبقه‌بندی مجدّداً انجام گرفت (طبقه‌بندی: درخت تصمیم‌گیر؛ روش کاهش بُعد فضای ویژگی: NCA). تنها ویژگی‌هایی که با روش NCA وزنی بالاتر از ۰/۱ را به دست داده‌اند، برای طبقه‌بندی استفاده شدند. نتایج نشان داد که حذف سن از فضای ویژگی حسّاسیت و دقّت طبقه‌بندی را به ترتیب به ۹۱/۲۰٪ (۰/۲۱) و ۸۵/۲۰٪ (۰/۱۸) افزایش داد، درحالی‌که ویژگی به‌طور قابل‌توجهی به ۳۲/۴۵ (۰/۹۲) درصد و سطح زیر ROC به ۰/۶۲ کاهش یافت. در چنین مواردی، UTI قبلی، IUC قبلی، بیماری عصبی و احتباس ادراری بااهمیت‌ترین فاکتورها در پیش‌بینی عفونت ادراری بودند (به ترتیب دارای وزن ۲/۸۵، ۲/۵۰، ۱/۹۸ و ۱/۸۹). جنسیت و IUC قبلی مجدّداً برای تشخیص اهمیت نداشتند (وزن برابر ۰).

علاوه‌براین، هنگامی‌که از طبقه‌بندِ تفکیک‌کننده خطّی (بدون کاهش ویژگی) استفاده شد، دقّت و حسّاسیت به ترتیب ۹۱/۲۷±۸۳/۰ و ۸۹/۳۸±۰/۲۵ درصد بود، درحالی‌که ویژگی به ۷۱/۸۹±۳۴/۰ درصد کاهش یافت. این تجزیه‌وتحلیل‌ها همراه با نتایج شکل ۲ ممکن است نشان دهد که سن شاید باید به‌عنوان یک عامل تمایزدهنده در نظر گرفته شود. دراین‌راستا، طبقه‌بندی مجدّد برای سنین مختلف [کودکی (۰-۱۴)، جوانی (۱۵-۲۴)، بزرگ‌سالی (۲۵-۶۴) و سالمندی (۶۵ و بالاتر)] انجام شد و نتایج در جدول ۳ گزارش شده است.

جدول ۲. وزن ویژگی‌ها در مدل پیش‌بینی UTI براساس روش NCA

ویژگی	وزن
Age	۵/۲۹
Gender	۰
Readmission	۱/۷۲
COPD	۰
Urinary retention	۰
Neurological disease	۱/۰۷
Previous UTI	۲/۷۵
Previous IUC	۰

جدول ۳. عملکرد طبقه‌بندی UTI برای زیرگروه‌های سنّی مختلف؛ بااهمیت‌ترین ویژگی‌ها برای هر زیرگروه در ستون آخر گزارش شده است.

زیرگروه (٪)	دقّت	حسّاسیت	ویژگی	ROC	ویژگی‌های مهم
کودک ۱۳/۰۷	۶۰/۶۰±۱۷/۴۷	۶۰/۷۸±۲۱/۹۴	۵۹/۰۰±۲۵/۵۸	۰/۵۹±۰/۰۶	Previous UTI; Gender; urinary retention; Readmission
جوان ۶/۱۴	۳۹/۴۲±۲/۴۱	۳۳/۲۴±۲/۵۹	۹۳/۳۳±۴/۷۱	۰/۶۳±۰/۰۳	Previous UTI; Gender; Readmission; previous IUC; neurological disease
بزرگ‌سال ۳۹/۱۲	۸۶/۲۵±۰/۳۶	۹۱/۹۷±۰/۳۰	۳۴/۸۴±۳/۱۴	۰/۶۳±۰/۰۲	Previous UTI; previous IUC; Gender; neurological disease; COPD
کهن‌سال ۴۱/۶۷	۷۳/۶۴±۱۳/۲۳	۷۷/۲۷±۱۶/۵۵	۴۰/۸۹±۱۶/۶۹	۰/۵۹±۰۰.۰	Previous UTI; previous IUC; Readmission;

نتایج

مهم‌ترین نتایج مطالعه حاضر اهمیت سن در پیش‌بینی عفونت ادراری فارغ از جنسیت و همچنین توانایی الگوریتم‌های یادگیری ماشین در پیش‌بینی عفونت ادراری با تکیه بر تعداد محدودی ویژگی بوده است. تجزیه‌وتحلیل‌های آماری نشان داد که تعداد قبلی عفونت‌های ادراری بین موارد فعلی UTI و موارد غیر UTI تفاوت معنی‌داری نداشت. بااین‌حال، همان‌طور که شکل ۱ نشان می‌دهد، میانگین تعدادUTI های قبلی در افراد مبتلای فعلی در مقایسه با نمونه‌های غیرمبتلای فعلی بیشتر بود. این مسئله نشان می‌دهد که سابقه عفونت باید به‌عنوان یک عامل مهم برای پیش‌بینی UTI در نظر گرفته شود و این پیامد تحت‌تأثیر جنسیت نیز نخواهد بود.

تعداد موارد ابتلا به عفونت برای هر دو گروه «مبتلا» و «غیرمبتلا» عمدتاً در بزرگ‌سالی (بزرگ‌سالان و سالمندان) در مقایسه با نمونه‌های جوان‌تر (کودکان و افراد جوان) بیشتر بود. برای نمونه‌های غیرمبتلا، میزان بروز نسبت به سن افزایش نشان می‌داد، درحالی‌که برای نمونه‌های مبتلا یک رابطه غیرخطّی بین سن و میزان ابتلا مشاهده شد. برخی از مطالعات کاهش بروز UTI را در سنین میان‌سالی و سپس افزایش میزان آن با افزایش سن را گزارش کرده‌اند [۱۹].

مطابق جدول ۱، دقّت پیش‌بینی UTI بین ۵۷ تا ۷۱ درصد متغیّر بود. این مسئله نشان می‌دهد که ویژگی‌های ساده دموگرافیک و سابقه بیماری بهتر از یک تصمیم تصادفی می‌توانند

در پیش‌بینی UTI عمل کنند. برای انواع مختلف مجموعه ویژگی‌ها و طبقه‌بندها، مشخصه ویژگی طبقه‌بند عمدتاً بهتر از حسّاسیت آن بود. این بدان‌معناست که طبقه‌بند بهتر می‌تواند موارد منفی واقعی (پیش‌بینی درست موارد غیرمبتلا) را در مقایسه با موارد مثبت درست (پیش‌بینی واقعی موارد مبتلا) پیش‌بینی کند. با مقایسه دقّت طبقه‌بندِ درخت تصمیم‌گیر (گزینه با حداکثر دقت)، زمانی‌که کاهش بُعد فضای ویژگی با استفاده از روش‌های PCA یا NCA اعمال شد، عملکرد طبقه‌بند می‌تواند بهبود یابد. برای سایر طبقه‌بندها، کاهش ویژگی تأثیر معنی‌داری را بر روی بهره‌وری تشخیص نشان نداد. این مسئله ممکن است به‌دلیل رابطه مستقل بین متغیّرهای درنظرگرفته‌شده باشد.

با توجه به شکل ۲، دو سنّ بحرانی برای پیش‌بینی UTI (۵۷/۵ و ۷۷/۵ سال) برای داده مورد تجزیه‌وتحلیل در این مطالعه به دست آمده‌است؛ به‌گونه‌ای‌که عفونت UTI پس از این سنین به‌طور قابل‌توجهی افزایش نشان می‌دهد. مطالعات قبلی گزارش کرده‌اند که میزان بروز برای ۶۵-۷۴ سال ۰/۰۵ در هر فرد در سال افزایش و برای مردان و زنان، بروز UTI در سنین بالای ۸۵ سال به‌طور قابل‌توجهی جهش می‌یابد [۲۰].

هنگامی‌که تمام بازه‌های سنّی در نظر گرفته شدند (کودکی و بزرگ‌سالی)، ویژگی جنسیت تأثیر ناچیزی بر پیش‌بینی UTI داشت (جدول ۲ را ببینید). درحالی‌که برای دوره‌های سنّی مختلف، جنسیت باید به‌عنوان یک ویژگی مهم در نظر گرفته شود (جدول ۳ را ببینید). با توجه به متون، UTI در زنان شایع‌تر است. اما در بین افراد مسن تفاوتی بین جنس‌های مختلف در ابتلا به UTI مشاهده نمی‌شود [۲۱]. این مسئله مطابق با نتایج گزارش‌شده در جدول ۳ بود که در آن جنسیت به‌عنوان یک ویژگی دارای اهمیت برای سنین مختلف، به‌جز برای سالمندان، بود. علاوه‌براین، طبق نتایج جدول ۳، دقت طبقه‌بندِ پیش‌بینی‌کننده UTI برای گروه‌های بزرگ‌سال و سالمند در مقایسه با گروه‌های کودک و جوان به‌طور معنی‌داری بیشتر بود. این نتایج و وزن بااهمیت‌ترین ویژگی‌ها برای دوره‌های سنّی مختلف (جدول ۳) تأکید می‌کند که هر سیستم هوشمند برای پیش‌بینی UTI باید تصمیم را به شیوه‌ای متفاوت برای دوره‌های سنّیِ مختلف اتّخاذ کند.

با توجه به جدول ۱، بهترین دقت طبقه‌بندی توسط طبقه‌بند درخت تصمیم‌گیر (۷۱/۷۸) برای مجموعه ویژگی‌های کاهش‌یافته به دست آمد. درحالی‌که یک طبقه‌بند تفکیک‌کننده خطّی بدون هیچ کاهشی در بُعد مجموعه ویژگی‌های اوّلیه، دقت ۶۵/۱۶ را به دست داد. در مقایسه با عملکرد سیستم پیش‌بینی‌کننده پیشنهادی در این مطالعه، اوزکان و همکاران (۲۰۱۸) از داده‌های معاینه معمولی (شامل سوابق بیماری، معاینه بالینی و داده‌های معاینه اولتراسوند) استفاده کردند و با استفاده از شبکه‌های عصبی مصنوعی، دقت طبقه‌بندی بالای ۹۸/۳۰ درصد را به دست آوردند [۱۰]. بااین‌حال، حجم نمونه مطالعه مذکور نسبتاً پایین و به اندازه ۵۹ نفر بوده است. برای زنان، هکرلینگ و همکاران (۲۰۰۷) از ترکیبی از الگوریتم ژنتیک و شبکه عصبی مصنوعی برای پیش‌بینی UTIاستفاده کردند. حجم نمونه برای مطالعه مذکور ۲۱۲ زن در محدوده سنّی ۱۹ تا ۸۴ سال بود. متغیّرهای پیش‌بینی‌کننده برای این مطالعه تکرّر ادرار، آزمایش خون و فاکتورهای استخراج‌شده از آزمایش ادرار بودند. دقت به‌دست‌آمده ٪۷۶/۴ با فاصله اطمینان ٪۹۵ برابر با ۷۰-۸۱/۸ بود [۲۲]. مولر و همکاران (۲۰۲۱) با مجموعه ویژگی‌های مشابه مطالعه ما، طبقه‌بندی با ROC از ۰/۸۲ تا ۰/۸۴ برای موارد مبتلا به UTI در جامعه و ۰/۷۱ تا ۰/۷۷ برای موارد بیمارستانی مبتلا به UTI پیشنهاد کردند [۱۴]. این مقدار برای مطالعه حاضر ۰/۷تا ۰/۷۲ بوده است.

محدودیت‌های مطالعه

داده مورداستفاده در این مطالعه دربردارنده تعداد بسیار محدودی ویژگی بوده است. این مسئله بر روی دقّت طبقه‌بند جهت پیش‌بینی عفونت ادراری تأثیرگذار بوده است. ازسوی‌دیگر، با توجه به نامتعادل بودن گروه‌ها در داده مورداستفاده که می‌تواند سبب سوگیری نتایج شود، از روش‌های کاهش داده استفاده شد که خود می‌تواند سبب از دست رفتن بخشی از اطلاعات موجود در دادگان شود.

نتیجه‌گیری

بیماری‌های عفونت ادراری از شایع‌ترین عفونت‌ها در جوامع بشری هستند. استاندارد طلایی برای تشخیص چنین عفونت‌هایی، آزمایش کشت ادرار است که فرایندی زمان‌بر و مستعد خطا خواهد بود. هر تحلیلی که به پیش‌بینی، تشخیص یا یافتن موارد مشکوک کمک کند، ممکن است هزینه کار تشخیصی را کاهش و دقت نتیجه را افزایش دهد. در این مطالعه، پتانسیل اطلاعات دموگرافیک و سوابق پزشکی بیمار مشکوک به عفونت ادراری برای پیش‌بینی احتمال عفونت ادراری بررسی شد. این دسته ویژگی‌ها به‌سهولت در دسترس خواهند بود. نتایج این مطالعه نشان داد که چنین ویژگی‌های ساده‌ای می‌توانند سیستم‌های هوشمندی را برای پیش‌بینی احتمال ابتلا به UTI برای یک بیمار بستری در بیمارستان ارائه دهند. حتّی اگر دقت پیش‌بینی خیلی بالا نباشد (تا ٪۷۱ در مطالعه حاضر)، نتیجه مطالعه حاضر بر برتری سیستم‌های هوشمند بر پیش‌بینی تصادفی UTI تأکید دارد. چنین سیستم هوشمندی را می‌توان با ویژگی‌های پیچیده‌تر برای افزایش دقّت، حسّاسیت و ویژگی پیش‌بینی غنی کرد.

تشکّر و قدردانی

از معاونت تحقیقات و فنّاوری دانشگاه علوم‌پزشکی همدان کمال تشکّر را جهت پشتیبانیِ به‌عمل‌آمده داریم. مطالعه حاضر مستخرج از طرح تحقیقاتی ۱۴۰۳۰۸۱۵۷۰۰۷ است.

تضاد منافع

هیچ‌گونه تضاد منافعی در پژوهش حاضر وجود ندارد.

ملاحظات اخلاقی

این مطالعه با کد اخلاق IR.UMSHA.REC. ۱۴۰۳. ۵۶۹ در کمیته اخلاق دانشگاه علوم‌پزشکی همدان ثبت شده است.

سهم نویسندگان

تجزیه‌وتحلیل داده و نگارش نسخه اوّلیه مقاله را سجّاد فراشی و تحلیل نتایج را حسین عماد ممتاز برعهده داشته‌اند.

حمایت مالی

حمایت مالی این مطالعه ازجانب دانشگاه علوم‌پزشکی همدان به انجام رسیده است (شماره طرح: ۱۴۰۳۰۸۱۵۷۰۰۷).

REFERENCES

1. Barnett BJ, Stephens DS. Urinary tract infection: an overview. *Am J Med Sci*. 1997;**314**(4):245-249. PMID: 9332263 DOI: 10.1097/00000441-199710000-00007
2. Goździkiewicz N, Zwolińska D, Polak-Jonkisz D, Zhang F, Mo... The use of artificial intelligence algorithms in the diagnosis of urinary tract infections-a literature review. *J Clin Med*. 2022;**11**(10):2734. PMID: 35930733 DOI: 10.3390/jcm11102734
3. Schmiemann G, Kniehl E, Gebhardt K, Matejczyk MM, Hummers-Pradier E. The diagnosis of urinary tract infection: a systematic review. *Dtsch Arztebl Int*. 2010;**107**(21):361-367. PMID: 20539810
4. Storme O, Tirán Saucedo J, Garcia-Mora A, Dehesa-Dávila M, Naber KG. Risk factors and predisposing conditions for urinary tract infection. *Ther Adv Urol*. 2019;**11**:1756287218814382. PMID: 31105772 DOI: 10.1177/1756287218814382
5. Nitzan O, Elias M, Chazan B, Saliba W. Urinary tract infections in patients with type 2 diabetes mellitus: review of prevalence, diagnosis, and management. *Diabetes Metab Syndr Obes*. 2015;**8**:129-136. PMID: 25759592 DOI: 10.2147/DMSO.S51792
6. Scholes D, Hooton TM, Roberts PL, Stapleton AE, Gupta K, Stamm WE. Risk factors for recurrent urinary tract infection in young women. *J Infect Dis*. 2000;**182**(4):1177-1182. PMID: 10979915 DOI: 10.1086/315827
7. Hu KK, Boyko EJ, Scholes D, Normand E, Chen CL, Grafton J, et al. Risk factors for urinary tract infections in postmenopausal women. *Arch Intern Med*. 2004;**164**(9):989-993. PMID: 15136308
8. Hufschmidt A, Shabarin V, Rauer S, Zimmer T. Neurological symptoms accompanying urinary tract infections. *Eur Neurol*. 2010;**63**(3):180-183. PMID: 20197663 DOI: 10.1159/000289098
9. Goździkiewicz N, Zwolińska D, Polak-Jonkisz D. The use of artificial intelligence algorithms in the diagnosis of urinary tract infections-a literature review. *J Clin Med*. 2022;**11**(10):2734. PMID: 35628861 DOI: 10.3390/jcm11102734
10. Ozkan IA, Koklu M, Sert IU. Diagnosis of urinary tract infection based on artificial intelligence methods. C*omput Methods Programs Biomed.* 2018;**166**:51-59. PMID: 30415718 DOI: 10.1016/j.cmpb.2018.10.007
11. Burton RJ, Albur M, Eberl M, Cuff SM. Using artificial intelligence to reduce diagnostic workload without compromising detection of urinary tract infections. *BMC Med Inform Decis Mak.* 2019;**19**. DOI:10.1186/s12911-019-0878-9
12. Advanced Analytics Group of Pediatric Urology and ORC Personalized Medicine Group. Targeted workup after initial febrile urinary tract infection: using a novel machine learning model to identify children most likely to benefit from voiding cystourethrogram. *J Urol*. 2019;**202**(1):144-152. PMID: 30810465 DOI: 10.1097/JU.0000000000000186
13. Gadalla AAH, Friberg IM, Kift-Morgan A, Zhang J, Eberl M, Topley N, et al. Identification of clinical and urine biomarkers for uncomplicated urinary tract infection using machine learning algorithms. *Sci Rep*. 2019;**9**(1):19694. PMID: 31873085 DOI: 10.1038/s41598-019-55523-x
14. Jeng SL, Huang ZJ, Yang DC, Teng CH, Wang MC. Machine learning to predict the development of recurrent urinary tract infection related to single uropathogen, Escherichia coli. *Sci Rep*. 2022;**12**(1):17216. PMID: 36241875
15. Dong F, Yao Y, Chen Y, Guo Y, Jing C, Wu J. Diagnostic performance of urine analysis based on flow microimaging and artificial intelligence recognition technology in suspected urinary tract infection patients. *Scand J Clin Lab Invest*. 2022;**82**(5):385-390. PMID: 35852133 DOI: 10.1080/00365513.2022.2100273
16. Møller JK, Sørensen M, Hardahl C. Prediction of risk of acquiring urinary tract infection during hospital stay based on machine-learning: A retrospective cohort study. *PLoS One*. 2021;**16**(3):e0248636. PMID: 33788888 DOI: 10.1371/journal.pone.0248636
17. Yang W, Wang K, Zuo W. Neighborhood Component Feature Selection for High-Dimensional Data. *J Comput*. 2012;7(1): 161-168 . DOI:10.4304/jcp.7.1.161-168
18. MANTEL N, HAENSZEL W. Statistical aspects of the analysis of data from retrospective studies of disease. *J Natl Cancer Inst*. 1959;**22**(4):719-748. PMID: 13655060 DOI:10.1093/jnci/22.4.719
19. Eriksson I, Gustafson Y, Fagerström L, Olofsson B. Prevalence and factors associated with urinary tract infections (UTIs) in very old women. *Arch Gerontol Geriatr*. 2010;**50**(2):132-135. PMID: 19349084 DOI: 10.1016/j.archger.2009.02.013
20. Griebling TL. Urologic diseases in america project: trends in resource use for urinary tract infections in men. *J Urol*. 2005;**173**(4):1288-1294. PMID: 15758784 DOI: 10.1097/01.ju.0000155595.98120.8e
21. Harrington RD, Hooton TM. Urinary tract infection risk factors and gender. *J Gend Specif Med*. 2000;**3**(8):27-34. PMID: 11253265
22. Heckerling PS, Canaris GJ, Flach SD, Tape TG, Wigton RS, Gerber BS. Predictors of urinary tract infection based on artificial neural networks and genetic algorithms. *Int J Med Inform*. 2007;**76**(4):289-296. PMID: 16469531 DOI: 10.1016/j.ijmedinf.2006.01.005.