مجله دانشکده پیراپزشکی دانشگاه علوم پزشکی تهران (پیاورد سلامت)
دوره ۱۳ شماره ۳ مرداد و شهریور ۱۳۹۸، ۲۵۰-۲۴۱

مقاله پژوهشی

تشخیص ابتلا به سرطان پستان با استفاده از روش‌های درخت تصمیم، شبکه عصبی و بیز ساده به‌منظور ارایه مدل بومی ویژه استان فارس

آزیتا یزدانی[۱]، علی اصغر صفایی[۲]، رضا صفدری[۳]، مریم زحمت کشان[٤]

دریافت مقاله : دی ۱۳۹۷
پذیرش مقاله : اردیبهشت ۱۳۹۸

* نویسنده مسئول :
علی اصغر صفایی؛
دانشکده علوم پزشکی دانشگاه تربیت مدرس
Email :
aa.safaei@modares.ac.ir

چکیده

زمینه و هدف: سرطان پستان شایع‌ترین سرطان و اصلی‌ترین علت مرگ ناشی از سرطان در زنان سراسر جهان به‌شمار می‌رود. تکنولوژی‌هایی مثل داده کاوی، به متخصصان این حوزه، امکان بهبود تصمیم‌گیری را در زمینه‌ی تشخیص زودهنگام فراهم آورده‌اند. هدف از این پژوهش توسعه‌ی مدل تشخیص خودکار سرطان پستان با به‌کارگیری روش‌های داده کاوی و انتخاب مدل بومی ویژه بیماران استان فارس با بالاترین دقت تشخیص می‌باشد.

روش بررسی: در این مطالعه، تعداد ٦٥٤ پرونده در دسترس از بیماران کلینیک تخصصی سرطان پستان مطهری شیراز به‌عنوان نمونه مورد استفاده قرار گرفت که بعد از عملیات پیش پردازش این تعداد به ٦٢١ پرونده کاهش یافت. برای هر کدام از نمونه‌ها دارای ۲۲ ویژگی در پرونده پزشکی ثبت شده بود که در نهایت ۱۰ ویژگی تاثیرگذار در ساخت مدل استفاده شد. از سه روش درخت تصمیم، بیز ساده و شبکه عصبی مصنوعی به‌منظور تشخیص ابتلا به سرطان پستان و روش 10-fold cross-validation برای ساخت و ارزیابی مدل بر روی مجموعه داده‌ی جمع‌آوری شده بهره گرفته شد.

یافته‌ها: نتایج به‌دست آمده از سه تکنیک ذکر شده نشان داد که هر سه مدل، نتایج امیدبخشی در تشخیص این سرطان دارند. در نهایت، شبکه عصبی مصنوعی، بالاترین دقت ۹٤/٤۹٪(حساسیت ۹٦/۱۹٪، ویژگی ۸٦/۳٦٪)، در تشخیص ابتلا به سرطان پستان به خود اختصاص داد.

نتیجه گیری: بر طبق نتایج حاصل از درخت تصمیم ایجاد شده، ریسک فاکتورهایی چون سن، وزن، سن شروع قاعدگی، یائسگی، مدت زمان مصرف OCP و سن اولین بارداری از جمله عوامل موثر در ابتلای زنان به سرطان پستان در استان فارس شناخته شدند.

واژه‌های کلیدی: سرطان پستان، مدل تشخیص، درخت تصمیم، بیز ساده، شبکه عصبی، عوامل خطرزا

۱ استادیار گروه فناوری اطلاعات سلامت، دانشکده مدیریت و اطلاع رسانی پزشکی، دانشگاه علوم پزشکی شیراز، شیراز، ایران
۲ استادیار گروه انفورماتیک پزشکی، دانشکده علوم پزشکی، دانشگاه تربیت مدرس، تهران، ایران
۳ استاد گروه مدیریت اطلاعات سلامت، دانشکده پیراپزشکی، دانشگاه علوم پزشکی تهران، تهران، ایران
٤ دکتری تخصصی مدیریت اطلاعات سلامت، مرکز تحقیقات بیماری های غیر واگیر، دانشگاه علوم پزشکی فسا، فسا، ایران

مقدمه

طبق گزارش سازمان بهداشت جهانی، سرطان پستان شایع‌ترین سرطان در میان زنان است که سالیانه ۱.۵میلیون زن به آن مبتلا می‌شوند و همچنین علت اصلی مرگ و میر ناشی از سرطان در زنان سراسر جهان به شمار می‌رود(۱). اگرچه دانشمندان علت دقیق سرطان پستان را نمی‌دانند، اما برخی از عوامل خطرزا که موجب افزایش احتمال ابتلای زنان به این سرطان می‌شوند، شناسایی شده‌اند. برخی از مهم‌ترین این ریسک فاکتورها شامل سن، سابقه خانوادگی و خطر ژنتیکی و غیره می‌باشند که در تشخیص‌های اولیه استفاده می‌شوند. در تشخیص‌های زود هنگام این سرطان، ۹۷٪ از زنان برای ۵ سال یا بیشتر زنده مانده‌اند(۲). با توجه به نرخ رشد وقوع سرطان پستان در سطح جهان، تشخیص زودهنگام سرطان پستان در کاهش تلفات حیاتی امری ضروری به‌نظر می‌رسد(۳). تشخیص کارآمد، دقیق و زود هنگام سرطان پستان یک مشکل مهم پزشکی در دنیای واقعی است. به‌تازگی روش‌های یادگیری ماشین و داده کاوی به‌طور گسترده در پیش‌بینی‌ها، به‌ویژه در تشخیص پزشکی استفاده می‌شوند. تشخیص پزشکی یکی از مشکلات عمده در برنامه‌های کاربردی پزشکی است(٤). با گسترش استفاده از رایانه‌ها به همراه ابزارهای خودکار، حجم زیادی از اطلاعات پزشکی جمع‌آوری و در اختیار محققان علوم پزشکی قرار گرفته است که با به‌کارگیری تکنیک‌های داده کاوی روابط و الگوهای پنهان در این حجم زیاد داده‌های جمع‌آوری شده کشف می‌شوند(۵). داده کاوی شامل روش‌های مختلف با اهداف گوناگون است. طبقه‌بندی و خوشه‌بندی دو روش رایج در داده کاوی هستند که در علوم پزشکی نیز استفاده می‌شوند. مشکلات تشخیص سرطان پستان اساسا در محدوده‌ی مشکلات طبقه‌بندی مورد بحث قرار می‌گیرند(٦). تاکنون تحقیقات گسترده‌ای در خصوص پیش‌بینی احتمال مبتلا شدن به سرطان پستان(۷)، تشخیص مبتلا بودن به سرطان پستان(۸)، پیش‌بینی مدت زمان بقای بیمار مبتلا به سرطان پستان(۹) و در نهایت احتمال عود مجدد سرطان پستان(۱۰) صورت گرفته است. Umer Khan و همکاران (۱۱) یک مدل ترکیبی بر اساس درخت تصمیم‌گیری فازی بر روی بانک اطلاعاتی "SEER" را بررسی کردند، آنها با استفاده از ترکیبات مختلف، تعدادی از قوانین درخت تصمیم‌گیری، انواع توابع عضویت فازی و تکنیک‌های استنتاج را آزمایش و بررسی نمودند. همچنین عملکرد هر یک از پیش آگهی‌های سرطان را مقایسه کردند و طبقه‌بندی درخت تصمیم‌گیری ترکیبی فازی با دقت ۸۵٪ را قوی‌تر و متعادل تر از طبقه‌بندی‌های مستقل کریسپ ارزیابی نمودند. Abdelaal و همکاران(۱۲) توانایی طبقه‌بندی SVM با Tree Boost و Tree Forest را در آزمایش داده‌های بانک اطلاعاتی ماموگرافی "DDSM" برای استخراج ویژگی‌های توده ماموگرافی بررسی کردند. در این پژوهش، تکنیک SVM نتایج امیدبخشی را برای افزایش دقت تشخیصی طبقه‌بندی داده‌های آموزشی نشان داد. سروستانی و همکاران مقایسه‌ای بین توانایی‌های شبکه‌های عصبی مختلف نظیر شبکه‌های عصبی چند لایه پرسپترون، نقشه خود سازماندهی (SOM)، تابع پایه شعاعی (RBF) و شبکه عصبی مصنوعی احتمالی ارایه داده اند. در این پژوهش از مجموعه داده‌های "WBC" و "NHBCD" برای طبقه‌بندی داده‌ها استفاده شده است. در نهایت PNN با میانگین زمانی ۱/٤۸۷ و کارایی ۱۰۰ درصد بهترین نتیجه را برای طبقه‌بندی در بین الگوریتم‌های شبکه عصبی مصنوعی ارایه داده است. هدف این پژوهش بررسی عملکرد ساختار شبکه‌های عصبی برای تشخیص سرطان پستان بود که نتایج آن نشان داد که شبکه‌های عصبی مصنوعی را می‌توان به‌طور موثری برای تشخیص سرطان پستان مورد استفاده قرار داد(۱۳). مطالعه‌ای که توسط Chao و همکاران(۱٤) انجام شد از ماشین بردار پشتیبان، رگرسیون لجستیک و درخت تصمیم C.5 به‌منظور طبقه بندی نرخ بقای بیماران مبتلا به سرطان پستان و از روش 10-fold cross-validation برای ساخت مدل استفاده شد. نتایج این مطالعه نشان می‌دهد که ایجاد ابزار طبقه‌بندی برای طبقه‌بندی مدل‌ها، به طور متوسط به دقت ۹۰ درصد برای هر سه مدل دست یافت. در این مطالعه SVM با دقت ۹۵/۱۵٪ بهترین تکنیک برای ساخت سه طبقه‌بندی در سیستم طبقه‌بندی بقای بیماران بود و رگرسیون لجستیک و درخت تصمیم به‌ترتیب به دقت ۹۵/۱٪ و ۹۳/۹۵٪ دست یافتند.

در مطالعه‌ی Cakır و Demirel (۱۵)، روش‌های درمان سرطان پستان با استفاده از داده کاوی بررسی گردید که در آن از الگوریتم‌های مختلفی همچون IBL، پرسپترون چند لایه و درخت تصمیم بهره گرفته شده است و سیستم نرم افزاری برای کمک به پزشک انکولوژی برای پیشنهاد استفاده از روش‌های درمان در مورد بیماران مبتلا به سرطان پستان توسعه داده شده است. نتایج این مطالعه، IBL با دقت ۹/٦۳ برای هورمون تراپی، پرسپترون چندلایه با دقت ۹۲٪ برای تاموکسیفن، درخت تصمیم با دقت ۹۷/۷۸٪ برای شیمی درمانی و پرسپترون چندلایه با دقت ۹۵/۲۸٪ برای رادیوتراپی را به عنوان بهترین الگوریتم‌ها ارایه داده است.

در مطالعه‌ی Aličković و Subasi (۱٦) روش‌های مختلف داده کاوی برای تشخیص سرطان پستان بررسی گردیده است. در این مطالعه، از مجموعه داده‌های سرطان پستان بانک اطلاعاتی "Wisconsin" استفاده شده است. نتایج به‌دست آمده با مدل Rotation Forest با ۱٤ ویژگی مبتنی بر GA نشان می‌دهد که بالاترین دقت طبقه‌بندی(۹٤/٤۸٪) بوده است. هدف از این پژوهش، توسعه‌ی مدل تشخیص سرطان پستان

با تمرکز بر سه الگوریتم طبقه‌بندی درخت تصمیم، بیز ساده و شبکه عصبی مصنوعی و انتخاب مدل با بالاترین دقت تشخیص به‌منظور بهبود تصمیم‌گیری پزشکان در امر تشخیص زودهنگام این سرطان می‌باشد. در ادامه این مقاله، در ابتدا مجموعه داده‌ی جمع‌آوری شده از کلینیک تخصصی سرطان پستان مطهری شیراز و روش پژوهش تشریح خواهند شد. سپس، مراحل آماده سازی مجموعه داده‌ها و روش‌های ایجاد مدل بررسی می‌گردند. در نهایت نتایج به دست آمده از روش‌های مختلف مقایسه و ارزیابی خواهند شد.

روش بررسی

- **مجموعه داده**

داده‌های جمع‌آوری شده در این پژوهش از میان داده‌های موجود در بانک اطلاعاتی کلینیک تخصصی سرطان پستان شهیدمطهری شیراز به‌دست آمده است. این داده‌ها شامل دو جدول مشخصات بیمار و اطلاعات مربوط به مراجعات بیمار می‌باشد. از میان این داده‌ها، با توجه به نظر پزشک و بر اساس فرم‌های نظرسنجی فیلدهایی که در تشخیص سرطان پستان بسیار موثر و حایز اهمیت هستند انتخاب گردیدند. این فیلدها در علم پزشکی با عنوان فاکتور شناخته می‌شوند. هر رکورد شامل ۲۲ ریسک فاکتور قابل پیشگیری و غیرقابل پیشگیری و یک ویژگی کلاس که دارای یکی از دو مقدار سالم و یا مبتلا به سرطان پستان می‌باشد. در این مطالعه تعداد ٦٥٤ پرونده‌ی در دسترس از مراجعه‌کنندگان به کلینیک تخصصی سرطان پستان شهیدمطهری شیراز که دارای دو کلاس افراد سالم و افراد مبتلا به سرطان پستان بودند، جمع‌آوری گردید. تعداد نمونه‌های این مجموعه داده بعد از انجام پیش پردازش و حذف داده‌های پَرت به‌تعداد ٦٢١ نمونه کاهش یافت که شامل ٤٢١ نمونه از افراد سالم و ۲۰۰ نمونه از افراد بیمار می‌باشد. جدول ۱ دربردارنده ویژگی‌های مجموعه داده مورد استفاده در این پژوهش به‌همراه نوع و بازه مقادیر آنهاست.

جدول ۱: ویژگی‌های مجموعه داده سرطان پستان

نام فاکتور	شرح	نوع داده	بازه مقادیر داده ها
سن	تاریخ تولد	تاریخ شمسی	۹۲-۲٤
وضعیت تاهل	وضعیت تاهل	رشته‌ای	مجرد-متاهل-مطلقه
وزن	وزن بیمار در زمان ابتلا	عددی صحیح	۱۳۲-۳۸
قد	قد بیمار مبتلا	عددی صحیح	۱۸۳-۱٤۰
سن قاعدگی	شروع قاعدگی بیمار	عددی صحیح	۲۲-۱۳
سن حاملگی	اولین حاملگی بیمار	عددی صحیح	٤٦-۱۳
تعداد زایمان	تعداد زایمان بیمار	عددی صحیح	۱٤-۰
تعداد سقط	تعداد سقط جنین در بیمار	عددی صحیح	٦-۰
شیردهی	تعداد ماه‌های شیردهی	عددی صحیح	۱۰۰۰-۰
وضعیت یائسگی	آیا بیمار یائسه شده یا خیر	رشته‌ای	Negative-positive
سن یائسگی	سن یائسه شدن بیمار	عددی صحیح	٦۱-۳۰
OCP	استفاده بیمار از قرص ضدبارداری	رشته‌ای	Negative-positive
مدت OCP	تعداد ماه‌هایی که از OCP استفاده کرده	عددی صحیح	۳٦۰-۰
HRT	سابقه هورمون درمانی	رشته‌ای	Negative-positive
سابقه بیماری پستان	سابقه بیماری خوش خیم پستان از قبل(کیست، توده چربی و ...)	رشته‌ای	Negative-positive
جراحی پستان	آیا بیمار سابقه جراحی پستان داشته است؟	رشته‌ای	Negative-positive
پرتو درمانی	آیا بیمار سابقه پرتو درمانی دارد؟	رشته‌ای	Negative-positive
سابقه خانوادگی	آیا بیمار سابقه فامیلی سرطان پستان دارد؟	رشته‌ای	Negative-positive
سیگار	آیا بیمار سابقه مصرف سیگار دارد؟	رشته‌ای	Negative-positive
قلیان	آیا بیمار سابقه استعمال قلیان دارد؟	رشته‌ای	Negative-positive
الکل	آیا بیمار سابقه مصرف الکل دارد؟	رشته‌ای	Negative-positive
ورزش	آیا بیمار فعالیت ورزشی منظم دارد؟	رشته‌ای	Negative-positive

در جدول ۱ تمامی ریسک فاکتورهای که در پرونده بیماران ثبت شده‌اند با جزئیات نمایش داده شده است. از این ۲۲ ریسک فاکتور به‌عنوان ویژگی در فرایند مدل سازی بهره گرفته خواهد شد.

• پیش پردازش

اهمیت آماده سازی داده‌ها به‌دلیل این واقعیت است که فقدان داده با کیفیت برابر با فقدان کیفیت در نتایج کاوش است و ورودی بد، خروجی بد به‌دنبال دارد(۱۷). وظیفه اصلی پیش پردازش داده‌ها، سازماندهی داده‌ها در شکل‌های استاندارد برای داده‌کاوی و یا سایر عملیات مبتنی بر کامپیوتر است که در ادامه بدان اشاره شده است.

• ویژگی‌های فاقد مقدار

در پرونده‌های جمع‌آوری شده برخی از ویژگی‌ها فاقد مقدار بودند که از روش "impute missing value" با استفاده از الگوریتم نزدیک‌ترین همسایه با اندازه k=۵ و معیار فاصله اقلیدسی به‌منظور مقداردهی به آن‌ها استفاده شد.

• تشخیص مقادیر ناهنجار(پَرت)

در ادامه عملیات پیش پردازش، نوبت به داده‌هایی می‌رسد که اصطلاحا پرت هستند. مقادیر این دسته از داده‌ها نرمال نیستند. به‌عبارتی برخی از نمونه‌ها دارای ویژگی‌هایی با مقادیر غیراستاندارد هستند به‌عنوان مثال اندازه قد فرد رکورد ۱۷۵، "۰" ثبت شده است که این اندازه با اندازه سایر نمونه‌ها فاصله زیادی دارد. برای حذف داده‌های پرت از "Detect Outlier" با پارامتر فاصله اقلیدسی بهره گرفته شد. به این ترتیب، رکوردهایی که دارای فاصله بیشتری نسبت به مابقی نمونه‌ها هستند شناسایی و بنابر استاندارد، ۵ درصد آنها ، حذف گردیدند. نتیجه این فرایند حذف ۳۳ رکورد از مجموع داده‌های جمع‌آوری شده، بود.

• گسسته سازی

هدف از این روش، این است که داده‌ها را بر حسب قواعدی در دسته‌بندی‌هایی قرار دهیم و دسته‌ای را که تعداد داده‌های موجود در آن بسیار کم باشد، کنار گذاریم. در موارد بسیار، پزشکان بر اساس دسته‌بندی‌هایی که بر اساس وضعیت‌های مختلف وجود دارد نسبت به تشخیص، اقدام می‌نمایند. به‌عنوان مثال فشار خون همسان در دو فرد کهنسان و نوجوان نشان از وضعیت‌های متفاوتی دارد؛ بنابراین در این مثال عملیات گسسته سازی بر اساس سن افراد صورت گرفته است. برای این منظور از "Discretize" استفاده شد. در این مرحله ویژگی‌هایی همچون سن، وزن و غیره که دارای مقادیر پیوسته عددی بودند، با استفاده از تکنیک گسسته سازی به‌چندین دسته تقسیم‌بندی شدند(جدول ۲).

• انتخاب ویژگی

از آنجایی‌که تعداد ویژگی‌های موجود در پرونده بیماران زیاد است، باید از بین این ویژگی‌ها، ویژگی‌های تاثیرگذار را به‌منظور ساخت مدل انتخاب کنیم. برای این منظور از ضریب جینی استفاده شد. در این مرحله از "Weight by Gini Index" به‌منظور وزن‌دهی به ویژگی‌ها بهره گرفته شد. ویژگی‌ها بعد از دریافت وزن می‌توانند به کمک "Select by Weights" انتخاب شوند. ۱۰ ویژگی که دارای بیش‌ترین وزن بودند، انتخاب شدند و بعد از تایید توسط پزشکان متخصص در فرایند تولید مدل استفاده شدند(جدول۲).

جدول ۲: ویژگی‌های برگزیده به همراه رده و ضریب جینی

ویژگی	رده ویژگی		ضریب جینی
سن	کمتر از ۳۰	۱	۰/۰۳
	۳۰-۴۰	۲	
	۴۰-۵۰	۳	
	بالای ۵۰	٤	
وزن	کمتر از ۵۰	۱	۰/۰۷
	۵۰-۶۰	۲	
	۶۰-۷۰	۳	
	بالاتر از ۷۰	٤	
سن شروع قاعدگی	زیر ۱۲ سالگی	۱	۰/۱۳
	۱۲-۱۶	۲	
	بالای ۱۶ سالگی	۳	
سن یائسگی	زیر ۴۰ سال	۱	۰/۲۶
	۴۰-۵۰	۲	

	بالای ۵۰ سال	۳	
مدت زمان مصرف OCP	زیر ۲۰ ماه	۱	۰/۲۸
	۲۰–۳۰	۲	
	بالای ۵۰ ماه	۳	
سن اولین بارداری	زیر ۲۰ سال	۱	۰/۳۵
	۲۰–۳۰	۲	
	۳۰–۴۰	۳	
	بالای ۴۰ سال	٤	
سابقه خانوادگی	دارد	۱	۰/٤۱
	ندارد	۰	
سابقه بیماری پستان	دارد	۱	۰/٤۱
	ندارد	۰	
فعالیت ورزشی	دارد	۱	۰/٤۷
	ندارد	۰	
تعداد ماه‌های شیردهی	کمتر از ۲٤ ماه	۱	۰/۵۱
	۲٤–٤۸	۲	
	بالای ٤۸	۳	

با بهره‌گیری از ضریب جینی ۱۰ ویژگی که تاثیر بیشتری در فرایند مدل سازی خواهند داشت انتخاب شدند. این ۱۰ ویژگی به‌ترتیب اهمیت در جدول ۲ نشان داده شده‌اند.

- **اِعمال روش‌های طبقه‌بندی روی داده‌ها**

به‌طورکل روش‌های طبقه‌بندی کننده مختلفی تاکنون به‌منظور تشخیص سرطان پستان مورد استفاده قرارگرفته اند. سه روش بیز ساده، درخت تصمیم و شبکه عصبی مصنوعی در این مطالعه استفاده شده‌اند. تمامی مراحل پیاده سازی مدل، در نرم افزار RapidMiner صورت گرفته است. در شکل ۱ مدل شبکه عصبی بر روی داده‌های مطالعه نشان داده شده است:

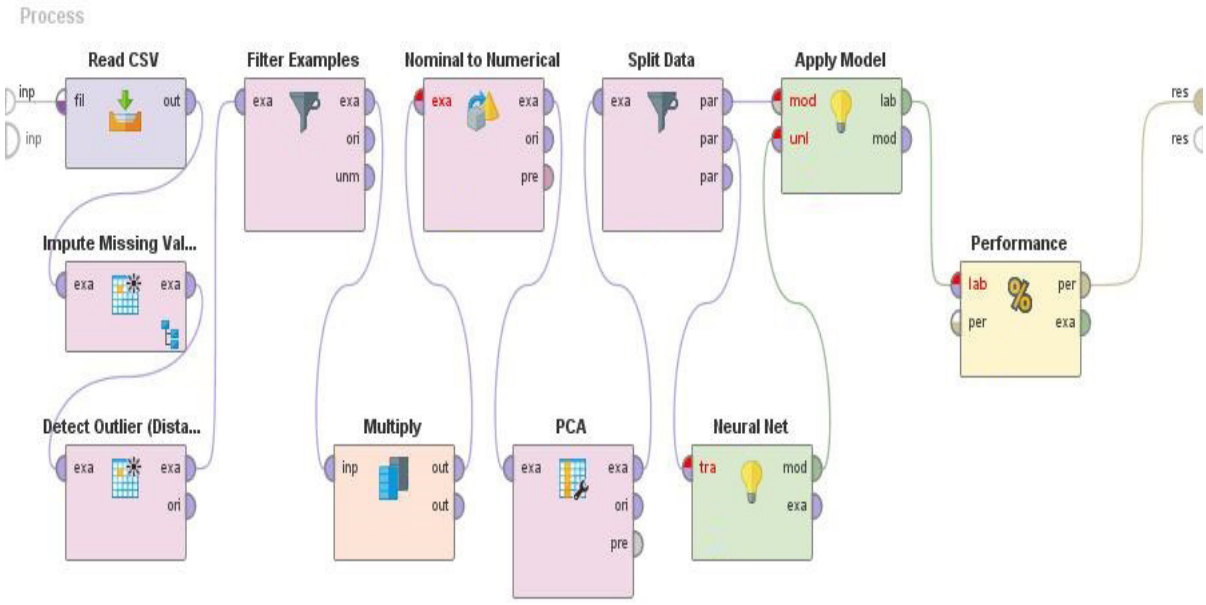

شکل ۱: مدل شبکه عصبی بر روی داده‌ها در نرم‌افزار RapidMiner

شکل شماره ۲، تصویر کامل مدل‌های درخت تصمیم، بیزساده و شبکه‌عصبی در نرم‌افزار RapidMiner را نشان داده‌است.

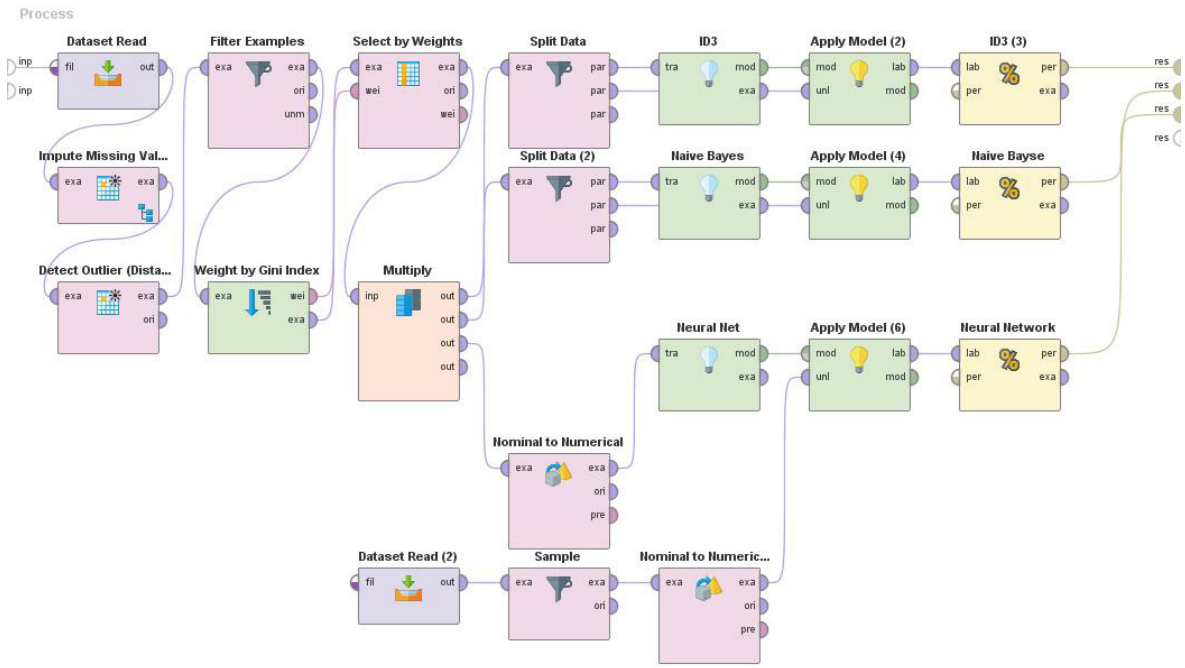

شکل ۲: شکل کامل پیاده سازی سه مدل در نرم‌افزار RapidMiner

یافته‌ها

در این مطالعه مجموعه داده مراجعه کنندگان به کلینیک تخصصی سرطان پستان شهیدمطهری شیراز جمع‌آوری و عملیات پیش پردازش بر روی نمونه‌ها انجام گرفت. در ادامه سه الگوریتم طبقه‌بندی با روش "10-fold cross validation" برای ایجاد و ارزیابی مدل بر روی مجموعه داده‌ها انتخاب گردیدند. نتایج به‌دست آمده از سه تکنیک درخت تصمیم، شبکه عصبی مصنوعی و بیز ساده با استفاده از چهار معیار دقت (Accuracy)، صحت (Precision)، حساسیت (Sensitivity) و ویژگی (Specificity) و معیار اف (F–measure) مورد ارزیابی قرارگرفتند. در ارزیابی‌های صورت گرفته، هر سه مدل نتایج امیدبخشی را در تشخیص بیماری سرطان پستان نشان دادند. جدول ۳ نتایج ارزیابی سه مدل مذکور را نشان می‌دهند.

جدول ۳: ارزیابی مدل‌های تشخیص سرطان پستان

	دقت	صحت	حساسیت	ویژگی	معیار اف
درخت تصمیم	٪۹۳/۵۰	٪۹۷/۰۲	٪۹۵/۱٤	٪۸۵/۰	٪۹٦/۰۷
شبکه عصبی	٪۹٤/٤۹	٪۹۷/۱۲	٪۹٦/۱۹	٪۸٦/۳٦	٪۹٦/٦۵
بیز ساده	٪۹۰/٦۷	٪۹٦/۱۲	٪۹۲/۵۲	٪۸۱/۸۲	٪۹٤/۲۸

شبکه عصبی مصنوعی با دقت تشخیص ٪۹٤/٤۹، یک مدل با دقت قابل قبول به‌منظور استفاده در فرایند تشخیص ابتلا به سرطان پستان نسبت به دو روش درخت تصمیم و بیز ساده ارایه داده است. به‌منظور بررسی کارایی الگوریتم‌ها از ماتریس درهم ریختگی استفاده می‌شود. مطابق با این ماتریس، مدل ایجاد شده توسط الگوریتم‌های شبکه عصبی مصنوعی، با میزان ٪۹٦/۱۹ بالاترین حساسیت در تشخیص صحیح افراد بیمار و با مقدار ٪۸٦/۳٦ بالاترین ویژگی در تشخیص درست افراد سالم را دارد(جدول ۵).

جدول ۴: ماتریس درهم ریختگی درخت تصمیم

	کلاس واقعی ابتلا به سرطان	کلاس واقعی سالم	صحت
کلاس پیش بینی ابتلا به سرطان	۹۸	۳	٪۹۷/۰۲
کلاس پیش بینی سالم	۵	۱۷	٪۷۷/۲۷
حساسیت	٪۹۵/۱٤	٪۸۵	

جدول ۵: ماتریس درهم ریختگی شبکه عصبی مصنوعی

	کلاس واقعی ابتلا به سرطان	کلاس واقعی سالم	صحت
کلاس پیش بینی ابتلا به سرطان	۱۰۱	۳	٪۹۷/۱۲
کلاس پیش بینی سالم	٤	۱۹	٪۸۲/٦۰
حساسیت	٪۹٦/۱۹	٪۸٦/۳٦	

جدول ۶: ماتریس درهم ریختگی بیز ساده

	کلاس واقعی ابتلا به سرطان	کلاس واقعی سالم	صحت
کلاس پیش بینی ابتلا به سرطان	۹۹	٤	٪۹٦/۱۲
کلاس پیش بینی سالم	۸	۱۸	٪٦۹/۲۳
حساسیت	٪۹۲/۵۲	٪۸۱/۸۲	

ساختار درخت تصمیم مجموعه‌ای از قوانین اگرآنگاه را در اختیار ما قرار می‌دهد(شکل ۳). این قوانین از ترکیبات عطفی و فصلی بین ویژگی‌های درخت تولید می‌شوند. صحت قوانین با نظر پزشک متخصص بررسی و تحلیل گردید. در ادامه به دو قانون برگرفته از درخت تصمیم تولید شده اشاره می‌کنیم:

۱- If (سن فرد=۳) And (وزن=٤) And (فعالیت ورزشی=۰) And(سن اولین بارداری=٤) Then class=سرطان

۲- If (سن=٤) And (مدت زمان استفاده از OCP=۳) And (سن شروع قاعدگی=۱) And (سن یائسگی=۱) Then Class=سرطان

تفسیر قانون اول بیان می‌کند که زنان بین ۳۰ تا ٤۰ سال که وزن آنها بالای ۷۰ کیلوگرم است و هیچ‌گونه فعالیت ورزشی ندارند و اولین بارداری آن‌ها بعد از سن چهل سالگی می‌باشد، بیش از سایر زنان در معرض ابتلا به سرطان پستان قرا دارند. تفسیر قانون دوم نشان می‌دهدکه زنان بالای ۵۰ سال که مدت زمان مصرف قرص OCP در آنها بالاتر از ۵۰ ماه میباشد و سن شروع قاعدگی و یائسگی آنها به ترتیب کمتر از ۱۲ سالگی و کمتر از ٤۰ سالگی است در معرض ابتلا به سرطان پستان قرار دارند.

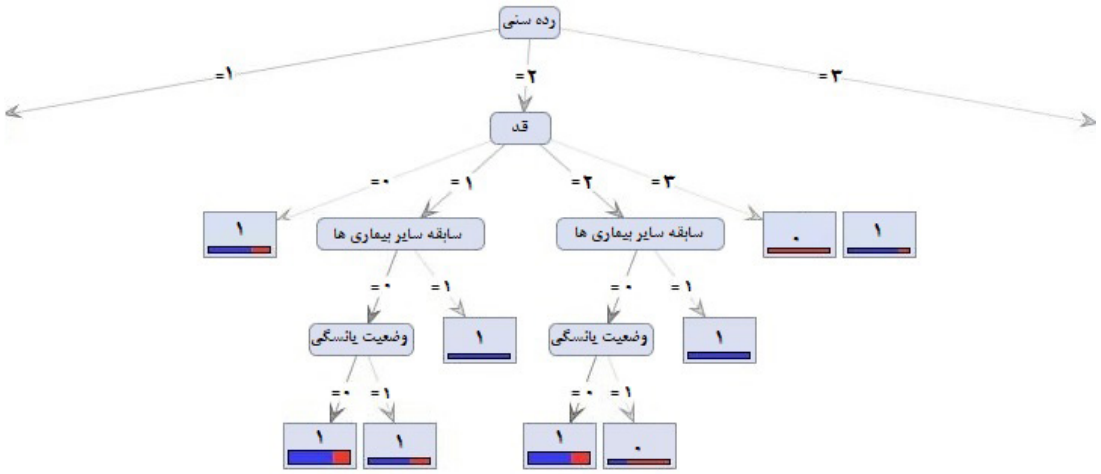

شکل ۳: بخشی از درخت تصمیم تولید شده

بحث

در این مطالعه با توجه به اهمیت مدل بومی پیش بینی تشخیص بیماری سرطان پستان، مجموعه داده کاملا بومی استان فارس از کلینیک تخصصی سرطان پستان شهیدمطهری شیراز جمع‌آوری و عملیات پیش پردازش بر روی نمونه‌ها انجام گرفت. در ادامه سه الگوریتم طبقه‌بندی که بیش‌ترین استفاده را در کارهای مشابه داشتند با روش ten-fold cross validation برای ایجاد مدل بر روی نمونه داده‌های بومی انتخاب گردیدند. در ارزیابی‌های صورت گرفته هر سه مدل نتایج امیدبخشی را در تشخیص بیماری سرطان پستان نشان دادند. درخت تصمیم با دقت ٪۹۳/۵۰(حساسیت ۹۵/۱٤، ویژگی ٪۸۵/۰) بیز ساده دقت ٪۹۰/٦۷

(حساسیت ۹۲/۵۲٪، ویژگی ۸۱/۸۲٪) و در نهایت شبکه عصبی دقت ۹۴/۴۹٪ (حساسیت ۹۶/۱۹٪، ویژگی ۸۶/۳۶٪). شبکه عصبی با بالاترین دقت پیش‌بینی بر روی مجموعه داده‌های بومی، یک مدل با دقت قابل قبول به‌منظور استفاده در تشخیص ابتلا به سرطان پستان در بیماران ایرانی خصوصا استان فارسی را ارایه داد.

جدول ۷: مقایسه‌ی دقت مدل پیشنهادی با کارهای پیشین

کارهای پیشین	درخت تصمیم	بیزساده	شبکه عصبی
لطیف و همکاران(۱۸)	٪۹۲	٪۹۱	–
محمودی و همکاران(۱۹)	٪۹۳/۹۴	٪۹۵/۹	٪۹۵/۱
دهقان و همکاران(۲۰)	–	٪۹۸/۳	٪۹۷/۵
طلوعی و همکاران(۲۱)	٪۹۳/۶	–	٪۹۴/۷
مدل ارائه شده	٪۹۳/۵۰	٪۹۰/۶۷	٪۹۴/۴۹

بر اساس جدول ۷، نتیجه‌ی مطالعه‌ی ارایه شده با کارهای مشابه ارزیابی گردید. بر اساس این ارزیابی، دقت‌های به‌دست آمده بسیار نزدیک به کارهای پیشین بوده و در بعضی موارد نیز دقت بهتری در برداشته است. با توجه به این‌که به‌منظور ساخت مدل در این مطالعه از داده‌های استان فارس بهره گرفته شده است، لذا به‌منظور تشخیص ابتلا به سرطان پستان در بیماران بومی این استان، استفاده از این مدل نسبت به سایر مدل‌های ساخته شده بر روی داده‌های غیربومی، می‌تواند نتایج بهتری را در برداشته باشد.

با توجه به اینکه این مدل بر روی داده‌های استان فارس ایجاد گردیده است، می‌توان نقش دیتاست‌های بومی را در جهت بهبود فرایند تشخیص بیماری‌های بومی ارزیابی نمود، اما با توجه به در دسترس نبودن مدل‌های دیگر، از این موضوع می‌توان به‌عنوان محدودیت مطالعه صورت گرفته یاد کرد.

نتیجه‌گیری

با توجه به‌اهمیت تشخیص زودهنگام سرطان پستان در مراحل اولیه، انتظار می‌رود به‌کارگیری سیستم‌های تشخیصی مبتنی بر مدل‌های تولید شده از روش‌های مختلف داده‌کاوی، همچون شبکه عصبی مصنوعی که دقت قابل قبولی در این پژوهش ارایه داده است، در جهت پشتیبانی از فرایند تصمیم‌گیری پزشکان موثر واقع گردند. بر اساس ارزیابی صورت گرفته در این مقاله، سه مدل ایجاد شده خصوصا درخت تصمیم، بر روی مجموعه داده‌های جمع‌آوری شده می‌توان مهم‌ترین عوامل موثر در تشخیص سرطان پستان را عواملی چون سن، اضافه وزن، سن شروع قاعدگی و یائسگی، مدت زمان مصرف OCP و سن اولین بارداری دانست. نتایج بررسی این پژوهش بر روی جامعه مورد مطالعه، نشان می‌دهد که زنان بالای ۵۰ سال که یائسه هستند و از مشکل چاقی رنج می‌برند نسبت به سایر گروه های سنی، بیشتر در معرض خطر ابتلا به سرطان پستان قرارگرفته اند. همچنین از دیگر عوامل خطرزا، در این پژوهش حاملگی دیررس می‌باشد که با همراه شدن با عواملی چون مصرف بالای OCP، احتمال ابتلا به این سرطان را افزایش می‌دهد. بنابراین پیشنهاد می‌گردد که در برنامه ریزی‌های پیشگیری از ابتلا به این سرطان تغییر سبک زندگی افراد، افزایش فعالیت‌های ورزشی مورد توجه ویژه قرار گیرند تا از شیوع بیش از پیش این سرطان جلوگیری گردد.

منابع

1. Hübner-Bloder G & Ammenwerth E. Key performance indicators to benchmark hospital information systems–A Delphi study. Methods of Information in Medicine 2009; 48(6): 508-18.

2. Beckmann KR, Lynch JW, Hiller JE, Farshid G, Houssami N, Duffy SW, et al. A novel case–control design to estimate the extent of over-diagnosis of Breast cancer due to organised population-based mammography screening. International Journal of Cancer 2015; 136(6): 1411-21.

3. Chaurasia V & Pal S. A novel approach for Breast cancer detection using data mining techniques. International Journal of Innovative Research in Computer and Communication Engineering 2014; 2(1): 1-17.

4. Liou DM & Chang WP. Applying data mining for the analysis of Breast cancer data. Data Mining in Clinical Medicine 2015; 1246(1): 175-89.

5. Js S, Shenoy PD, KR V & Patnaik LM. Cancer prognosis prediction model using data mining techniques. Data Mining and Knowledge Engineering 2014; 6(1): 21-9.

6. Araújo T, Aresta G, Castro E, Rouco J, Aguiar P, Eloy C, et al. Classification of Breast cancer histology images using convolutional neural networks. PloS One 2017; 12(6): e0177544.

7. Chaurasia V, Pal S & Tiwari BB. Prediction of benign and malignant Breast cancer using data mining techniques. Journal of Algorithms & Computational Technology 2018; 12(2): 119-26.

8. Lu J, Hales A, Rew DA, Keech M, Fröhlingsdorf C, Mills-Mullett A, et al. Data mining techniques in health informatics: A case study from Breast cancer research, Switzerland: International Conference on Information Technology in Bio-and Medical Informatics, 2015.

9. Ruiz A, Sebagh M, Wicherts DA, Castro-Benitez C, van Hillegersberg R, Paule B, et al. Long-term survival and cure model following liver resection for Breast cancer metastases. Breast Cancer Research And Treatment 2018; 170(1): 89-100.

10. Ojha U & Goel S. A study on prediction of Breast cancer recurrence using data mining techniques, Noida: 7th International Conference on Cloud Computing, Data Science & Engineering-Confluence, 2017.

11. Umer Khan M, Choi JP, Shin H & Kim M. Predicting Breast cancer survivability using fuzzy decision trees for personalized healthcare, Vancouver, British Columbia, Canada: 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2008.

12. Abdelaal MMA, Sena HA, Farouq MW & Salem ABM. Using data mining for assessing diagnosis of Breast cancer. Available at: https://annals-csis.org/proceedings/2010/pliks/158.pdf. 2010.

13. Sarvestani AS, Safavi AA, Parandeh NM & Salehi M. Predicting Breast cancer survivability using data mining techniques, USA: 2nd International Conference on Software Technology and Engineering, 2010.

14. Chao CM, Yu YW, Cheng BW & Kuo YL. Construction the model on the Breast cancer survival analysis use support vector machine, logistic regression and decision tree. Journal of Medical Systems 2014; 38(10): 106.

15. Cakır A & Demirel B. A software tool for determination of Breast cancer treatment methods using data mining approach. Journal of Medical Systems 2011; 35(6): 1503-11.

16. Aličković E & Subasi A. Breast cancer diagnosis using GA feature selection and rotation forest. Neural Computing and Applications 2017; 28(4): 753-63.

17. Blake R & Mangiameli P. The effects and interactions of data quality and problem complexity on classification. Journal of Data and Information Quality 2011; 2(2): 8.

18. Latif AM, Momeny M, Sarram R, Agha Sarram M, Pour Ahmadi A & Haj Ebrahimi Z. Using data mining and genetic algorithm for diagnosis of Breast cancer. Iranian Quarterly Journal of Breast Disease 2016; 9(1): 45-56[Article in Persian].

19. Mahmoodi MS, Mahmoodi SA, Haghighi F & Mahmoodi SM. Determining the stage of Breast cancer by data mining algorithms. Iranian Quarterly Journal of Breast Diseases 2014; 7(2): 36-44[Article in Persian].

20. Dehghan P, Mogharabi M, Zabbah I, Layeghi K & Maroosi A. Modeling Breast cancer using data mining methods. Journal of Health and Biomedical Informatics 2018; 4(4): 266-78[Article in Persian].

21.Toloiee-Ashlaghi A, Pourebrahimi A, Ebrahimi M & Ghasem-ahmad L. Using data mining techniques for prediction Breast cancer recurrence. Iranian Journal of Breast Diseases 2013; 5(4): 23-34[Article in Persian].

Diagnosis of Breast Cancer Using Decision Tree, Artificial Neural Network and Naive Bayes to Provide a Native Model for Fars Province

Azita Yazdani[1] (Ph.D) - Ali Asghar Safaei[2] (Ph.D.) - Reza Safdari[3] (Ph.D.) - Maryam Zahmatkeshan[4] (Ph.D.)

1 Assistant Professor, Department of Health Information Technology, School of Management and Medical Informatics, Shiraz University of Medical Sciences, Shiraz, Iran

2 Assistant Professor, Department of Medical Informatics, School of Medical Sciences, Tarbiat Modarres University, Tehran, Iran

3 Professor, Department of Health Information Management, School of Allied Medical Sciences, Tehran University of Medical Sciences, Tehran, Iran

4 Ph.D. in Health Information Management, Noncommunicable Diseases Research Center, Fasa University of Medical Sciences, Fasa, Iran

Abstract

Received: Dec 2018

Accepted: Apr 2019

Background and Aim: Breast cancer is the most common type of cancer and the main cause of death from cancer in women worldwide. Technologies such as data mining, have enabled experts in this area to improve decision making in the early diagnosis of the disease. Therefore, the purpose of this research is to develop an automatic diagnostic model for Breast cancer by employing data mining methods and selecting the model with the highest accuracy of diagnosis for Fars province.

Materials and Methods: In this study, 654 available patient records of Motahari Breast cancer Clinic in Shiraz" were used as the sample. The number of records was reduced to 621 after the pre-processing operation. These samples had 22 features that ultimately ten were used as effective features in the design of the model. Three types of Decision tree, Naive Bayes and Artificial neural network were used for diagnosis of Breast cancer and 10-fold cross-validation method for constructing and evaluating the model on the collected data set.

Results: The results of the three techniques mentioned all three models showed promising results in detecting Breast cancer. Finally, the artificial neural network accounted for the highest accuracy of 94/49%(sensitivity 96/19%, specificity 86/36%) in the diagnosis of Breast cancer.

Conclusion: Based on the results of the decision tree, the risk factors such as age, weight, age of menstruation, menopause, duration of OCP usage, and the age of the first pregnancy were among the factors affecting the incidence of Breast cancer in women of Fars province.

Keywords: Breast Cancer, Diagnostic Model, Decision Tree, Naive Bayes, Artificial Neural Network, Risk Factors

*** Corresponding Author:**
Safaei AA
Email:
aa.safaei@modares.ac.ir