Original Article

Depiction of Health
2019; 10(2): 129-143
http://dohweb.tbzmed.ac.ir

The Precision of Neonatal Birth Outcomes Prediction Using the Bagging Neural Network

Somayeh Heshmat Alvandi[1], Ali Asghar Pourhaji Kazem*[1], Morteza Ghojazadeh[2], Mohammad Heidarzadeh[3], Saeed Dastgiri[4]

Article Info:

Article History:
Received: 04/17/2019
Accepted: 07/09/2019
Published: 09/21/2019

Keywords:
Neonatal Mortality
Data Mining
Bagging Neural Network
Decision Tree
Nearest Neighbor

Abstract

Background and Objectives: The high rate of neonatal mortality is a major problem in health care systems all around the world. The accurate estimation of neonatal mortality is a prerequisite for the development of future health strategies that leads to the improvements in neonatal health. Providing a predictive model is, therefore, essential to reduce the neonatal mortality rate and reducing health care costs. The purpose of this study was to produce a model based on the data mining techniques to increase the accuracy of the prediction of the outcome of the neonatal mortality using a bagging neural network model in Rapidminer software.

Material and Methods: This study was conducted on 8053 births (including 1605 cases and 6448 controls) across the country in 1394. The study variables including maternal diseases, mother age, gestational age, child gender, birth weight, birth order, abnormalities were selected as predictive factors for bagging neural network method. We compared bagging neural network with neural network, decision tree and nearest neighbor. Some criteria including the area under ROC curve, precision, accuracy and classification error rate were considered in comparing with other data mining models.

Results: The comparison of bagging neural network with other data mining models showed that the bagging neural network gives better results compared to other models: precision (99.21), accuracy (99.17), classification error rate (0.83) and AUC value (0.992).

Conclusion: We conclude that the bagging neural network may help to reduce the cost of health care system, and to improve the community health by preventing the mortality and adverse outcomes in neonates.

Citation: Heshmat Alvandi S, Pourhaji Kazem AA, Ghojazadeh M, Heidarzadeh M, Dastgiri S. The Precision of Neonatal Birth Outcomes Prediction Using the Bagging Neural Network. Depiction of Health 2019; 10(2): 129-143.

1. Department of Computer Engineering, Tabriz Branch, Islamic Azad University, Tabriz, Iran (**Email**: a.pourhajikazem@iaut.ac.ir)
2. Research Development & Coordination Center, Tabriz University of Medical Sciences, Tabriz, Iran
3. Ministry of Health and Medical Education, Tehran, Iran
4. Tabriz Health Services Management Research Center, Tabriz University of Medical Sciences, Tabriz, Iran

*© 2019 The Author(s). This work is published by **Depiction of Health** as an open access article distributed under the terms of the Creative Commons Attribution License (http://creativecommons.org/licenses/by-nc/4.0/). Non-commercial uses of the work are permitted, provided the original work is properly cited.*

مقاله پژوهشی

دقت پیش‌بینی مرگ‌ومیر نوزادان با استفاده از شبکه عصبی تجمیعی

سمیه حشمت الوندی[۱]، علی اصغر پورحاجی کاظم*[۱]، مرتضی قوجازاده[۲]، محمد حیدرزاده[۳]، سعید دستگیری[۴]

چکیده

زمینه و اهداف: نرخ بالای مرگ‌ومیر نوزادان به‌عنوان یک مسئله مهم در بهداشت و سلامت جامعه در سراسر جهان هست. برآورد دقیق مرگ‌ومیر نوزادان پیش‌نیاز توسعه استراتژی‌های بهداشتی آینده هست که منجر به پیشرفت در وضعیت سلامتی نوزادان است؛ بنابراین، برای کاهش مرگ‌ومیر نوزادان و کاهش هزینه‌های مراقبت‌های بهداشتی ایجاد یک مدل پیش‌بینی برای پیشرفت جامعه ضروری است. هدف از این پژوهش ایجاد یک مدل پیش‌بینی، مبتنی بر تکنیک داده‌کاوی جهت بررسی دقت پیش‌بینی پیامد مرگ‌ومیر نوزادان در بدو تولد با استفاده از مدل شبکه عصبی تجمیعی در نرم‌افزار رپیدماینر می‌باشد.

مواد و روش‌ها: این مطالعه بر روی ۸۰۵۳ تولد (شامل ۱۶۰۵ مورد مرگ و ۶۴۴۸ شاهد) در سراسر کشور در سال ۱۳۹۴ انجام شد. متغیرهای مطالعه شامل بیماری‌های مادر، سن مادر، سن حاملگی، جنسیت نوزاد، وزن تولد، مرتبه‌ی تولد و ناهنجاری‌های بدو تولد به‌عنوان متغیرهای پیش‌بینی کننده روش شبکه عصبی تجمیعی مورد استفاده قرار گرفتند. معیارهایی مانند سطح زیر منحنی راک، دقت، صحت و میزان نرخ خطای دسته‌بندی شبکه عصبی تجمیعی محاسبه شدند و با مدل‌های دیگر داده‌کاوی مانند شبکه عصبی، درخت تصمیم و نزدیکترین همسایه مورد مقایسه قرار گرفتند.

یافته‌ها: نتایج حاصل از مقایسه الگوریتم‌های پیش‌بینی نشان داد که شبکه عصبی تجمیعی با میزان دقت ۹۹/۲۱ درصد، صحت ۹۹/۱۷ درصد، نرخ خطای دسته‌بندی ۰/۸۳ درصد و سطح زیر منحنی راک ۰/۹۹۲ نتایج بهتری در پیش‌بینی نسبت به سایر مدل‌های پیش‌بینی داشت.

نتیجه‌گیری: با توجه به نتایج بدست آمده از این پژوهش، شبکه عصبی تجمیعی می‌تواند به کاهش هزینه‌های سیستم مراقبت بهداشتی کمک کند و سلامت جامعه را از طریق پیشگیری از مرگ‌ومیر و پیامدهای ناگوار نوزادان بهبود ببخشد.

کلیدواژه‌ها: مرگ‌ومیر نوزادان، داده‌کاوی، شبکه عصبی تجمیعی، درخت تصمیم، نزدیکترین همسایه

نحوه استناد به این مقاله: حشمت الوندی س، پورحاجی کاظم ع ا، قوجازاده م، حیدرزاده م، دستگیری س. دقت پیش‌بینی مرگ‌ومیر نوزادان با استفاده از شبکه عصبی تجمیعی. تصویر سلامت ۱۳۹۸؛ ۱۰(۲): ۱۲۹-۱۴۳.

۱. گروه مهندسی کامپیوتر، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران (**Email**: a.pourhajikazem@iaut.ac.ir)

۲. مرکز توسعه و هماهنگی پژوهش (RDCC)، دانشکده پزشکی، دانشگاه علوم پزشکی تبریز، تبریز، ایران

۳. وزارت بهداشت، درمان و آموزش پزشکی، تهران، ایران

۴. مرکز تحقیقات مدیریت خدمات بهداشتی درمانی تبریز، دانشگاه علوم پزشکی تبریز، تبریز، ایران

حقوق برای مؤلف(ان) محفوظ است. این مقاله با دسترسی آزاد در **تصویر سلامت** تحت مجوز کریتیو کامنز (http://creativecommons.org/licenses/bync/4.0/) منتشر شده که طبق مفاد آن هرگونه استفاده غیر تجاری تنها در صورتی مجاز است که به اثر اصلی به نحو مقتضی استناد و ارجاع داده شده باشد.

مقدمه

میزان مرگ‌ومیر دوره نوزادی یکی از شاخصهای مهم در ارزیابی سطح سلامت جامعه و تعیین میزان خدمات‌رسانی بهداشتی می‌باشد (۱). بنابراین تأمین سلامت نوزاد به‌عنوان یک شاخص مهم سلامت، نشان دهنده‌ی شرایط اقتصادی و اجتماعی حاکم بر جامعه می‌باشد (۳،۲). بخش مراقبت‌های ویژه نوزادان (Neonatal Intensive Care Unit: NICU) جایی است که نوزادان تازه متولد شده در بیمارستان‌ها مدیریت و درمان می‌شوند. در این بخش تکنولوژی‌های نو و گران‌قیمت و داروهای متنوع بکار می‌رود و پروتکل‌های درمانی سریعاً در حال تغییر می‌باشد. علیرغم این تحولات سریع، مرگ‌ومیر در این بخش بالا می‌باشد و پیش آگهی نوزادان در NICU های مختلف با هم تفاوت دارد (٤). با پیشرفتهای سریع در فناوری مراقبت‌های بهداشتی طی ۳ دهه گذشته و در کنار آن افزایش هزینه‌های مراقبت‌های بهداشتی منجر شده که بررسی پیامد مرگ‌ومیر در بین نوزادان پذیرفته شده در بخش مراقبت ویژه نوزادان به‌عنوان یک چالش مهم محسوب شود (۵).

بقای نوزاد از مهم‌ترین چالش‌های دنیای امروز است (٦). مطابق گزارش سازمان بهداشت جهانی سالیانه چهار میلیون نوزاد در چهار هفته اول تولدشان می‌میرند که ۷۵ درصد از این مرگ‌ها در طول هفته اول زندگی‌شان می‌باشد (۸،۷). مرگ‌ومیر نوزادان نشان دهنده‌ی جدی بودن مشکل بهداشت عمومی و در نتیجه یک تهدید برای توسعه جهانی می‌باشد (۹). مرگ‌ومیر دوره پریناتال (Perinatal) بطور فزاینده‌ای مسئله مهم بهداشت عمومی کشورهای در حال توسعه است (۱۱،۱۰)؛ بطوریکه دوسوم این مرگ‌ومیرها در ۱۰ کشور که اکثراً آسیایی هستند اتفاق می‌افتد (۱۲). به‌طور کلی ۹۸ درصد از مرگ‌ومیر نوزادان در کشورهای در حال توسعه گزارش شده است (۱٤،۱۳) که این میزان دو برابر بیشتر از میزان مرگ‌ومیر ناشی از ایدز است. مطالعات اپیدمیولوژیک در کشورهای توسعه یافته بر این موضوع تأکید دارد (٦). عواملی مانند کمبود مشاوره زنان باردار، میزان درآمد پایین و نرخ بارداری بالا در این کشورها بر میزان مرگ‌ومیر دوره نوزادی دخالت دارند (۱۵). ایران به‌عنوان کشوری با مرگ‌ومیر متوسط محسوب می‌شود. نرخ مرگ‌ومیر نوزادان در ایران ۱۷ مرگ در هر ۱۰۰۰ تولد زنده است، در حالی‌که در کشورهای توسعه یافته ۵ در هر ۱۰۰۰ تولد زنده است (۱٦).

هاولینگ (Houweling) و همکاران در پژوهش خود از مدل رگرسیون برای پیش‌بینی خطر مرگ در سه موقعیت شروع بارداری، حین زایمان و ۵ دقیقه بعد از زایمان برحسب منحنی مشخصه عملکرد (Area Under the receiver operating characteristic Curve: AUC) استفاده کردند که در ابتدای بارداری، منحنی مشخصه عملکرد ۰/۵۹ و در شروع زایمان، منحنی مشخصه عملکرد ۰/۷۳ و در ۵ دقیقه پس از زایمان، منحنی مشخصه عملکرد ۰/۸۵ بود (۱۷). در پژوهش وینچر (Vincer) و همکاران، از مدل رگرسیون لجستیک چندگانه جهت طراحی مدل پیش‌بینی استفاده شد. در این پژوهش از داده‌های در دسترس دوره‌ای مربوط به جمعیت زنان باردار ۰+۲۳ تا ۶+۳۰ هفته بارداری و نوزادانی که کمتر از ۳۱ هفتگی بارداری به دنیا آمده‌اند با فاکتورهای قبل از تولد برای پیش‌بینی مرگ‌ومیر استفاده شد که نتایج حاصل از پیش‌بینی مدل رگرسیون لجستیک، نرخ حساسیت ۶۰ درصد و ویژگی ۹۲ درصد را نشان داد (۱۸). پژوهش مارکو (Marco) و همکاران بر اساس اطلاعات گروهی از نوزادان متولد شده کمتر از ۳۰ هفته بارداری یا وزن تولد کمتر از ۱۵۰۱ گرم انجام شد و از میان روش‌های مختلف یادگیری ماشین، شبکه‌های عصبی مصنوعی انتخاب شد و نتیجه پیش‌بینی با مدل رگرسیون لجستیک مقایسه شد. این مطالعه نشان داد که حتی با استفاده از اطلاعات محدود تنها تا ۵ دقیقه پس از تولد، رویکرد شبکه عصبی دارای مزیت قابل توجهی نسبت به رویکردهای دیگر و رگرسیون لجستیک می‌باشد. منحنی مشخصه عملکرد برای شبکه عصبی ۰/۹۱ برآورد شد (۱۹). در مطالعه رضاییان (Rezaeian) و همکاران از شبکه عصبی جهت پیش‌بینی مرگ‌ومیر استفاده شد. در این پژوهش از پرونده نوزادان نارس با سن حاملگی کم‌تر از ۳۷ هفته در بیمارستان قائم‌شهر استفاده شد که صحت مدل به میزان ۹٤/٥٦ درصد و دقت ۹٤/۵ درصد ارزیابی شد (۵).

بررسی مطالعات پژوهشی نشان داد که بیشتر تمرکز مطالعات پیشین بر پیش‌بینی احتمال زنده ماندن نوزادان نارس می‌باشند که در اکثر این مطالعات، پیش‌بینی مرگ‌ومیر نوزادان با استفاده از رگرسیون لجستیک انجام شده است. با توجه به اینکه کاهش میزان نرخ مرگ‌ومیر نوزادان از اولویت‌های کلیدی سلامت در کشورهای در حال توسعه است (۱۰)؛ بنابراین نیاز به ابزاری با حساسیت بالا می‌باشد که توانایی بیشتری در پیش‌بینی احتمال مرگ‌ومیر نوزاد را داشته باشد. با بررسی‌های انجام شده، شبکه‌های عصبی قدرت بهتری در پیش‌بینی و کشف روابط پیچیده بین داده‌ها را دارند (۲۰) و با توجه به اینکه در مرگ‌ومیر نوزادی عوامل متعدد با روابط پیچیده دخالت دارند از الگوریتم تجمیعی بگینگ جهت افزایش دقت طبقه‌بندی و بهینه‌سازی عملکرد شبکه عصبی استفاده شد. این الگوریتم قادر است عملکرد طبقه‌بندی الگوریتم‌های ناپایدار مانند شبکه عصبی را با استفاده از جمع-آوری خودراه‌اندازها بهبود ببخشد (۲۱). لذا این مطالعه با هدف تولید مدل پیش‌بینی مبتنی بر تکنیک داده‌کاوی جهت بررسی دقت به‌نام شبکه عصبی تجمیعی انجام شد که به

لحاظ کاربردی می‌توان بر اساس نتایج حاصل از این تحقیق پیش‌بینی پیامد مرگ نوزاد را در بدو تولد انجام داد و پیشنهاداتی مؤثر را به دستگاه‌های برنامه‌ریزی و اجرایی کشور به منظور توجه بیشتر به جامعه در خصوص بهداشت و خدمات‌رسانی بهداشتی ارائه نمود. بنابراین نتایج این پژوهش می‌تواند در جهت اقدامات مؤثر به مسئولین بهداشتی کشور ارائه گردد. بنابراین با توجه به در دسترس بودن حجم وسیعی از داده‌های مادر و نوزاد وزارت بهداشت کشور و نیاز شدید به کشف اطلاعات و دانش از این داده‌ها از یک‌سو و افزایش مرگ‌ومیر نوزادی از سوی دیگر، پژوهش حاضر مدلی جهت پیش‌بینی مرگ‌ومیر نوزادان ارائه داده است که با حداقل نرخ خطا و حداکثر میزان دقت به پیش‌بینی مرگ‌ومیر نوزادان پرداخته شود.

مواد و روش‌ها

مطالعه‌ی حاضر از نوع مقطعی و تشخیصی می‌باشد که بر اساس متغیرهای ورودی، به پیشگویی وضعیت بقاء نوزاد در بدو تولد می‌پردازد. جامعه آماری مادران باردار مراجعه کننده به مراکز درمانی و دانشگاهی کشور جهت زایمان بوده که از لحاظ نمونه‌گیری نیز تمام شماری و بر اساس داده‌های وزارت بهداشت بوده است. دسترسی به مجموعه داده‌های این مطالعه از طریق سامانه ثبت تولد وزارت بهداشت انجام شده است. دیتاست مورد استفاده این پژوهش، پایگاه داده مادر و نوزاد شامل ۱۵۰۹۰۸۱ رکورد و ۶۰ فیلد می‌باشد که هر رکورد از این مجموعه داده‌ها مربوط به پرونده‌های مادران باردار مراجعه‌کننده جهت زایمان و نوزادان متولد شده در سال ۱۳۹۴ می‌باشد.

در این مطالعه تمامی موارد مرگ‌ومیر نوزادان به تعداد ۱۶۰۵ مورد در سطح کل کشور در سال ۱۳۹٤ انتخاب شد و برای این منظور چهار برابر نیز گروه شاهد (٦٤٤٨ تولد زنده) انتخاب شد. انتخاب گروه کنترل به‌صورت تصادفی از تمامی شهرهای ایران بر اساس نسبت مرگ‌ومیر در هر مرکز درمانی و بیمارستانی می‌باشد. برای ورودی شبکه - عصبی تجمیعی از متغیرهای تأثیرگذار برای پیش‌بینی مرگ-ومیر نوزاد استفاده شد و متغیرهای مربوط به تاریخ، زمان و اسامی که تأثیری در پیامد مرگ‌ومیر نداشتند از مطالعه حذف شدند. در نهایت ۳۲ متغیر در مطالعه باقی ماند. متغیرهای مورد استفاده در این مطالعه شامل عوامل خطر مادری ازجمله بیماری‌های مادر مانند دیابت، فشارخون، بیماری قلبی و...، سن مادر، سن حاملگی، تعداد بارداری قبلی، تعداد سقط، ناهنجاری بدو تولد نوزاد شامل ناهنجاری گوارشی، سیستم عصبی و...، جنسیت نوزاد، وزن نوزاد، رتبه تولد، نیازمندی به احیاء نوزاد، آپگار دقیقه اول و دقیقه پنجم جهت پیش‌بینی مورد استفاده قرار گرفتند. برای طراحی و پیاده سازی مدل شبکه عصبی تجمیعی از نرم‌افزار رپیدماینر ورژن ۹،۲ استفاده شد. با توجه به نیازمندی داده‌های مناسب جهت کشف و استخراج دانش پنهان از داده‌ها، در مرحله اول، پیش‌پردازش (Preprocessing) داده‌ها در رپیدماینر انجام شد و پایگاه داده موجود از لحاظ وجود داده‌های پرت مورد بررسی قرار گرفت. روش پیشنهادی جهت حذف داده‌های پرت به این صورت است که تعداد n رکورد پرت بر اساس فاصله خود از تعداد k نزدیکترین همسایه در مجموعه داده مورد شناسایی قرار می‌گیرند که در این مطالعه برای محاسبه این فاصله از فاصله اقلیدسی استفاده شد. در علم ریاضیات فاصله اقلیدسی به فاصله معمولی بین دو نقطه گفته می‌شود که توسط قضیه فیثاغورس بدست می‌آید. در مختصات دکارتی اگر دو نقطه $Q=(Q1, Q2,..., Qn)$ و $P=(P1, P2,..., Pn)$ در فضای اقلیدسی n بعدی باشند، آنگاه فاصله بین این دو نقطه با استفاده از رابطه (۱) تعریف می‌گردد:

(۱)

$$d(P,Q)=\sqrt{(P_1-Q_1)^2+(P_2-Q_2)^2+\ldots+(P_n-Q_n)^2}=\sqrt{\sum_{i=1}^{n}(P_i-Q_i)^2}$$

بنابراین بعد از محاسبه فاصله به هر نقطه عددی اختصاص داده می‌شود که این عدد بیانگر فاصله می‌باشد و در انتها n نقطه که بزرگ‌ترین اعداد اختصاص داده شده را دارند، به‌عنوان داده‌های پرت شناسایی شده و از مجموعه دیتاست مورد نظر حذف شدند (۲۲).

با در نظر گرفتن این نکته که هدف اصلی در این مطالعه پیش‌بینی مرگ‌ومیر نوزادان در بدو تولد می‌باشد و فیلد مربوط به وزن نوزاد به‌عنوان یکی از متغیرهای تأثیر-گذار در پیامد مرگ‌ومیر نوزادی می‌باشد جهت افزایش دقت پیش‌بینی مدل، این فیلد با استفاده از روش گسسته-سازی به مقادیر گسسته تبدیل شد. هدف گسسته‌سازی تبدیل داده‌های عددی به نوع اسمی است. با این عمل مقادیر عددی یک صفت خاصه به چندین بازه تقسیم می-شود که در این مطالعه برای گسسته‌سازی تعداد بازه‌ها ۳ در نظر گرفته شده است. بنابراین با استفاده از این عملگر، فیلد وزن نوزاد که از مقدار ۲٦۰ گرم الی ۷۰۰۰ گرم متغیر می‌باشد به سه بازه کم وزنی (Low weight)، وزن نرمال (Normal weight) و وزن بالا (High weight) تقسیم شد.

برای ارزیابی و اعتبارسنجی مدل پیش‌بینی از عملگر اعتبارسنجی متقابل با ده تکرار (10- Cross-Validation Fold) استفاده شد که این عملگر هر بار از کل داده‌های مورد استفاده ۹۰ درصد برای آموزش شبکه عصبی تجمیعی و ۱۰ درصد را برای ارزیابی و آزمایش مدل شبکه عصبی تجمیعی استفاده می‌کند. دلیل انتخاب ده تکرار برای این عملگر به این دلیل می‌باشد که با بررسی‌های انجام شده بهترین انتخاب برای بدست آوردن دقیق‌ترین مدل پیش‌بینی است. قابل ذکر است که در این مطالعه جزئیات مدل‌سازی و اعتبار سنجی متقابل در روش‌های دیگر داده‌کاوی مانند شبکه عصبی، درخت تصمیم و نزدیکترین همسایه نیز همانند شبکه عصبی تجمیعی در نظر گرفته شده است.

شبکه‌های عصبی مصنوعی به‌عنوان یک شاخه از علم هوش مصنوعی یک معماری فراگیر شناخته شده با الهام از مکانیزم شناخت بصری موجودات زنده است (۲۳) که الگوریتم‌های آن با تقلید از ساختار مغز انسان طرح‌ریزی شده‌اند (۲۴). یک شبکه عصبی از اجتماع عناصر پردازشی به‌هم پیوسته به نام نرون‌ها تشکیل می‌شود (۲۱). نرون‌ها در یک شبکه عصبی در لایه‌های مختلف قرار می‌گیرند و معماری خاصی را بر مبنای ارتباطات بین نرون‌ها تشکیل می‌دهند. ساختار انعطاف‌پذیر شبکه‌های عصبی و توانایی آنها در یادگیری از نمونه‌ها، این شبکه‌ها را قادر می‌سازد که بتوانند روابط پیچیده غیرخطی یا الگوهای مخفی بین متغیرهای وابسته و مستقل را شناسایی کنند (۲۵). محبوب‌ترین شکل معماری شبکه‌های عصبی، شبکه‌های پرسپترون (Multilayer Perceptron) چند لایه می‌باشند. شبکه‌های پرسپترون از یک لایه ورودی، تعدادی لایه پنهان و یک لایه خروجی تشکیل می‌شوند. در شکل ۱ یک شبکه پرسپترون با یک لایه پنهان نشان داده شده است.

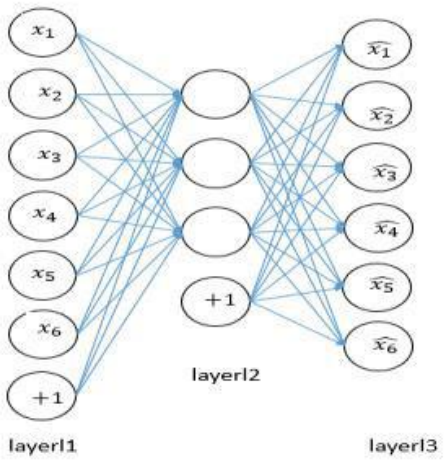

شکل ۱. شبکه پرسپترون با یک لایه پنهان

در مدل پیشنهادی ما از شبکه عصبی پرسپترون چند لایه تجمیعی استفاده شد که الگوریتم یادگیری مذکور مبتنی بر تابع اصلاح خطا می‌باشد و به وسیله الگوریتم انتشار به عقب (Back propagation) آموزش داده می‌شود. در این روش مقدار خروجی مورد نظر با خروجی مطلوب مقایسه می‌شود و با استفاده از آن خطا جهت هدایت آموزش مشخص می‌شود. اگر خروجی سیستم y باشد و خروجی سیستم مورد نظر d شناخته شده است، سیگنال خطا را می‌توان به صورت زیر تعریف کرد.

(۲)

$$E=d-y$$

این الگوریتم تلاش می‌کند سیگنال‌های خطا را در هر تکرار حداقل کند و درنتیجه وزن‌ها در طی مراحل به‌صورت خودکار بهبود یابند. این فرآیند مربوط به اصلاح وزن‌ها در تمام عناصر سیستم ادامه می‌یابد تا بهترین وزن‌ها که صحیح‌ترین خروجی را برای سیستم ایجاد می‌کند، شناسایی و انتخاب شوند (۲۶).

روش پیشنهادی در این مطالعه شبکه‌های عصبی با روش الگوریتم تجمیعی بگینگ است. در الگوریتم‌هایی تجمیعی دو ایده بگینگ (Bagging) و بوستینگ (Boosting) وجود دارد که هر دو ایده برای بهبود مشکلات طبقه‌بندی و یادگیری بهتر در الگوریتم‌های ناپایدار یادگیری ماشین مانند شبکه عصبی، درخت تصمیم و رگرسیون (Regression) مورد استفاده قرار می‌گیرند (۲۷). روش الگوریتم‌های تجمیعی بر پایه ساخت مجموعه‌ای از دسته‌بندها می‌باشد. با توجه به اینکه تکنیک بگینگ برای داده‌های عددی با حجم و ابعاد بالا مناسب می‌باشد، در این مطالعه از این روش استفاده شد. این الگوریتم یک روش گروهی قدرتمند است که قادر می‌باشد عملکرد طبقه‌بندی شبکه عصبی را با استفاده از جمع‌آوری خودراه‌اندازها بهبود ببخشد (۲۱). در این الگوریتم نمونه های خودراه‌انداز به‌صورت تصادفی و با استفاده از نمونه‌برداری با جایگذاری از مجموعه داده مورد نظر ایجاد می‌شوند که ساخت دسته‌بندهای متعدد نیز بر اساس هرکدام از این نمونه‌های خودراه‌انداز انجام می‌گیرد. سپس این الگوریتم مجموعه‌ای از دسته‌بندهای ساخته شده را می‌گیرد و در مرحله بعد ترکیب خروجی حاصل از تک‌تک دسته‌بندها با یکدیگر از طریق اکثریت رأی صورت می‌گیرد و در نهایت دسته‌بند نهایی c با کارایی بهتر از تک‌تک دسته‌بندهای استفاده شده در الگوریتم ساخته می‌شود که در نتیجه این عملکرد دسته‌بندها خطای یکدیگر را پوشش می‌دهند. الگوریتم بگینگ در جدول ۱ آورده شده است. بگینگ یا دسته‌بند مسئله ناپایداری و بی‌ثباتی را با استفاده از قانون تصمیم‌گیری حل می‌کند؛ بنابراین واریانس و

خطای پیش‌بینی را کمتر می‌کند و همچنین کمک می‌کند تا مسئله بیش برازش رخ ندهد (۲۸).

جدول ۱: الگوریتم بگینگ

1. Repeat for b = 1, 2, . . ., B

(a) Construct a bootstrap sample $\{(x_1^n,y_1^n),(x_2^n,y_2^n),\ldots,(x_n^n,y_n^n)\}$ by randomly drawing n times with replacement from the data $\{(x_1,y_1),(x_2,y_2),\ldots,(x_n,y_n)\}$

(b) Fitting the bootstrapped classifier C_b on corresponding bootstrap sample

2. Output the final classifier $C(x)=B^{-1}\sum_{b=1}^{B} c_b(x)$

شکل شماره ۲ مربوط به سطح اول طراحی مدل پیش‌بینی این مطالعه در نرم‌افزار رپیدماینر می‌باشد که به‌ترتیب از عملگرهای انتخاب متغیرهای ورودی، تعیین نقش متغیر، گسسته‌سازی، تبدیل نوع داده‌ای به عددی و عملگر اعتبارسنجی متقابل تشکیل شده است.

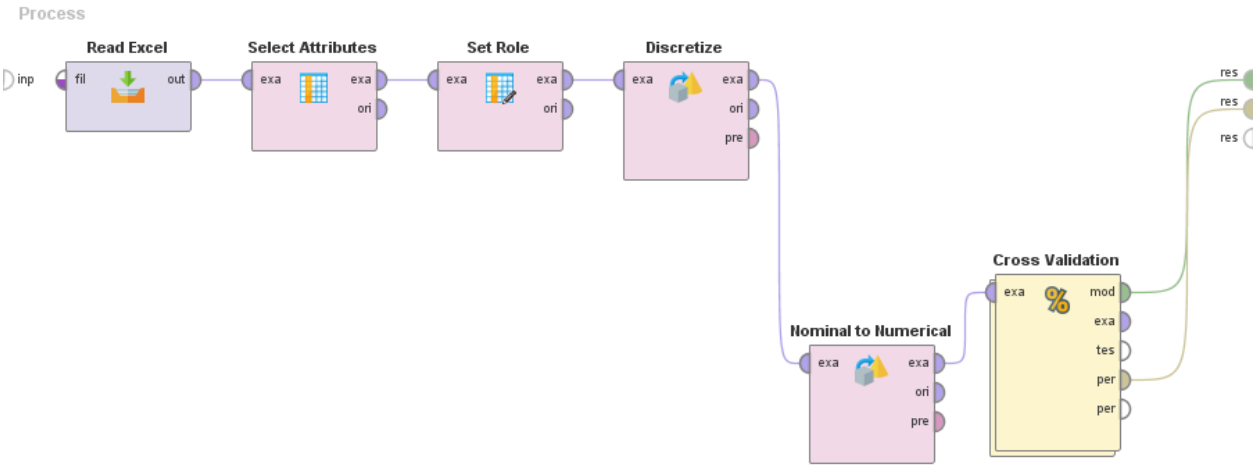

شکل ۲. سطح اول مدل پیش‌بینی در نرم‌افزار رپیدماینر

روش پیشنهادی برای بهبود عملکرد شبکه عصبی با استفاده از الگوریتم بگینگ می‌باشد. این الگوریتم برای تولید خروجی نهایی از ترکیب پیش‌بینی‌های چندین شبکه عصبی به‌عنوان طبقه‌بندی پایه استفاده می‌کند (۲۷).

شکل شماره ۳ سطح دوم طراحی مدل پیش‌بینی می‌باشد که مربوط به تکنیک تجمیعی بگینگ و کارایی مدل طراحی شده می‌باشد.

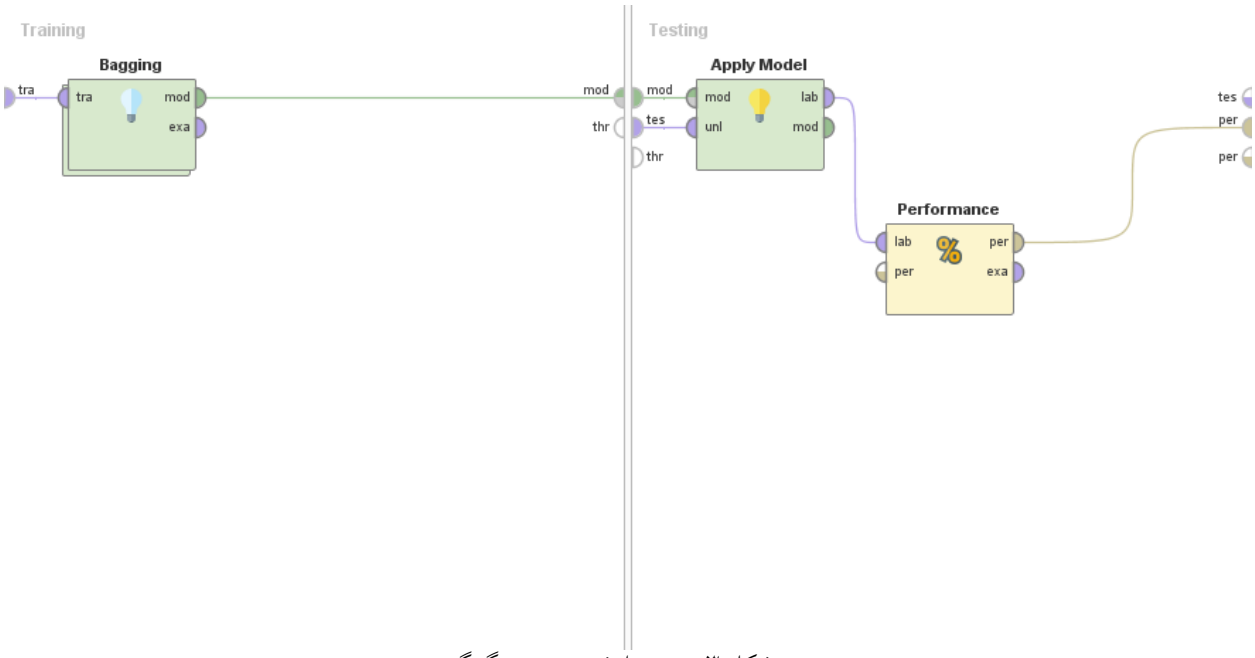

شکل ۳. زیر پردازش دسته‌بند بگینگ

در این مطالعه مجموعه داده‌ها با استفاده از الگوریتم بگینگ به مجموعه‌ای از خودراه‌اندازها که از داده‌های نمونه به‌صورت تصادفی انتخاب شدند، تقسیم شد و مجموعه‌ای از دسته‌بندهای پایه با استفاده از نمونه‌های خودراه‌انداز ساخته شد و با استفاده از الگوریتم یادگیری شبکه عصبی آموزش داده شد و درنهایت مدل با ۱۰ تکرار دسته‌بند و میزان نرخ نمونه‌برداری ۰/۹ ایجاد شد.

در طراحی شبکه عصبی تجمیعی از یک لایه ورودی، یک لایه پنهان و یک لایه خروجی استفاده شد. در لایه ورودی از ۳۵ گره ورودی یا نرون استفاده شد که ۳٤ گره مربوط به متغیرهای ورودی (غیر از ویژگی برچسب) و یک گره به‌عنوان گره آستانه می‌باشد. در لایه خروجی از کلاسهای مرگ و تولد زنده نوزاد به عبارت دیگر دو نرون استفاده شد. با توجه به بررسی‌های انجام شده نتایج حاصل از دو لایه پنهان در طراحی مدل نیز تفاوت قابل‌توجهی نسبت به یک لایه پنهان نداشته است؛ بنابراین در این مطالعه از یک لایه پنهان با تعداد ۲۰ نرون استفاده گردید. نرون‌ها می‌توانند از توابع محرکی متفاوتی مانند تابع محرک خطی و توابع سیکموئیدی برای تولید خروجی استفاده کنند که در این تحقیق برای انتقال اطلاعات در لایه پنهان از تابع انتقال سیکموئید استفاده شد. شکل شماره ٤ سطح سوم طراحی مدل و مربوط به شبکه - عصبی می‌باشد.

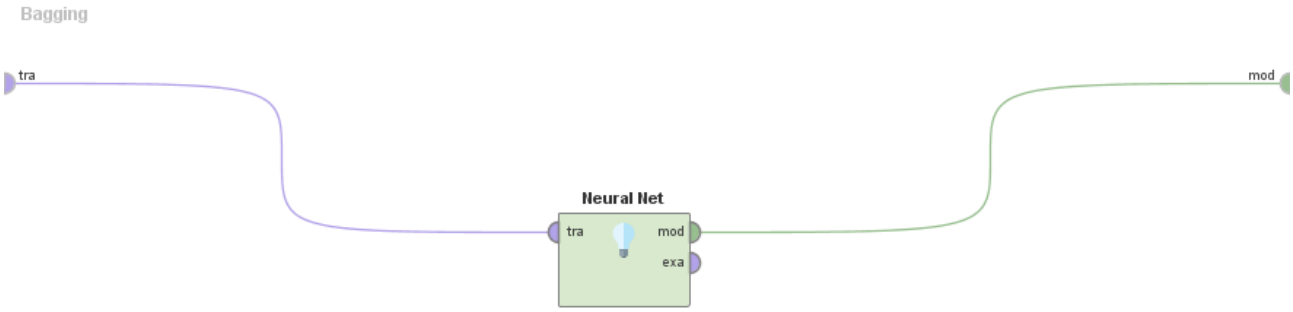

شکل٤. عملگر شبکه عصبی

برای دسترسی به شبکه‌ای با بهترین عملکرد، شبکه‌های مختلف با ساختارهای مختلف آموزش داده شد و در نهایت شبکه‌ای با کمترین نرخ خطا و بیشترین میزان صحت و دقت بدست آمد. معیارهایی مانند دقت (precision)، صحت

(accuracy) و میزان نرخ خطای دسته‌بندی (classification error rate) و سطح زیر منحنی راک (Area under curve) شبکه عصبی تجمیعی محاسبه شدند و با مدل‌های دیگر داده‌کاوی مانند شبکه عصبی، درخت تصمیم و نزدیکترین همسایه مورد مقایسه قرار گرفتند. با توجه به نتیجه پژوهش که شامل تولد زنده و مرگ-ومیر بود برای ارزیابی بهتر این شبکه‌ها از ماتریس آشفتگی نیز استفاده شد و سپس با استفاده از آن، مقادیر حساسیت و ویژگی محاسبه گردید. الگوریتم‌های درخت تصمیم و نزدیکترین همسایه در ادامه توضیح داده شده‌اند.

درخت تصمیم از گراف درخت مانند برای طبقه‌بندی داده‌ها استفاده می‌کند. این الگوریتم نمونه‌ها (Instances) را بر اساس مقادیر ویژگی‌هایشان طبقه‌بندی می‌کند. درخت شامل یک گره ریشه (بالاترین گره درخت)، شاخه‌ها و گره-های برگ است که در آن تمامی گره‌های غیر برگ (Non Leaf) نشان دهنده یک تست یا آزمون بر روی یک خصوصیت یا ویژگی خاص است. هر شاخه نتایج حاصل از این آزمون را نشان می‌دهد و هر گره برگ دارای برچسب کلاس است (۲۹).

الگوریتم نزدیکترین همسایه از ساده‌ترین الگوریتم‌های یادگیری ماشین می‌باشد. این الگوریتم بر اساس یادگیری مقایسه‌ای عمل می‌کند. نمونه‌های آموزشی توسط صفات عددی n بعدی توصیف می‌شوند. هر نمونه نشان دهنده‌ی یک نقطه در یک فضای n بعدی است. بدین ترتیب، همه نمونه‌های آموزشی در یک فضای الگوی ناملموس نگهداری می‌شوند. هنگامی‌که یک نمونه ناشناخته داده می‌شود، نزدیکترین همسایه، در فضای الگو k نمونه آموزشی نزدیک به نمونه ناشناخته را جستجو می‌کند. "نزدیکی" به‌صورت فاصله اقلیدسی بین دو نقطه تعریف می‌شود (۲۹).

دسترسی از سامانه وزارت بهداشت بوده است و در این داده‌ها جهت ملاحظه جوانب اخلاقی تمام اطلاعات به‌صورت محرمانه بررسی و تجزیه و تحلیل شده است و هیچ گونه اطلاعاتی که حاکی از اطلاعات شخصی نمونه‌ها باشد، آشکار نشده است.

یافته‌ها

برای ورودی شبکه عصبی تجمیعی، متغیرهای عوامل خطر مادری، سن مادر، سن حاملگی، تعداد بارداری قبلی، تعداد سقط، ناهنجاری بدو تولد، جنسیت، مرتبه تولد، وزن تولد، احیاء نوزاد، آپگار دقیقه اول و پنجم نوزاد مورد استفاده قرار گرفت و متغیر فرجام نوزاد به‌عنوان متغیر هدف یا پاسخ در نظر گرفته شد که همگی متغیرهای مرتبط و تأثیرگذار در نتایج مرگ‌ومیر نوزادان و قابل تأیید متخصصین می‌باشند. به منظور ارزیابی نتایج حاصل از شبکه عصبی تجمیعی از معیار دقت، صحت، نرخ خطای طبقه‌بندی، مربعات خطا، ضریب همبستگی، ضریب کاپا، ویژگی، حساسیت و منحنی راک استفاده شد.

نتایج تأثیر حاصل از تغییر مقادیر پارامترها بر میزان صحت عملکرد شبکه عصبی تجمیعی در جداول شماره ۲ الی ٤ آورده شده است. جدول ۲ مربوط به مقایسه مقادیر مختلف تعداد نرون‌های شبکه عصبی به ازای ۲۰ سیکل آموزشی و تأثیر آن بر صحت الگوریتم می‌باشد. همان‌گونه که در جدول ۲ مشاهده می‌شود به ازای ۵۷ نرون و ۲۰ سیکل آموزشی میزان صحت مدل به حد مطلوب خود رسیده است. جدول ۳ مقایسه مقادیر مختلف تعداد سیکل آموزشی شبکه عصبی به ازای ۵۷ نرون و نرخ یادگیری ۰/۳ و تأثیر آن بر صحت الگوریتم می‌باشد. همان‌گونه که در این جدول مشاهده می-شود به ازای ۲۰ سیکل آموزشی صحت مدل به حد مطلوب خود رسیده است.

جدول ٤ مربوط به مقایسه مقادیر مختلف نرخ نمونه-برداری دسته‌بند به ازای ۵۷ نرون، نرخ یادگیری ۰/۳، ۲۰ سیکل آموزشی شبکه عصبی و ۱۰ تکرار دسته‌بند و تأثیر آن بر صحت الگوریتم می‌باشد. همان‌گونه که در جدول ٤ مشاهده می‌شود به ازای نرخ نمونه‌برداری ۰/۹ میزان صحت مدل به حد مطلوب خود رسیده است.

جدول۲. مقایسه تأثیر مقادیر مختلف تعداد نرون‌ها بر صحت الگوریتم به ازای ۲۰ سیکل آموزشی

صحت پیش‌بینی	نرخ خطای طبقه‌بندی	تعداد لایه مخفی	تعداد نرون‌ها
۹۹/۱۷ درصد	۰/۸۳ درصد	۱	۵۷
۹۹/۱۲ درصد	۰/۸۸ درصد	۲	۷۷
۹۹/۰۹ درصد	۰/۹۱ درصد	۳	۹۷

جدول ۳. مقایسه تأثیر مقادیر مختلف تعداد سیکل آموزشی بر صحت الگوریتم به ازای ۵۷ نرون و نرخ یادگیری ۰/۳

صحت پیش‌بینی	نرخ خطای طبقه‌بندی	تعداد سیکل آموزشی
۹۹/۱۲ درصد	۰/۸٦ درصد	۱۲
۹۹/۱٦ درصد	۰/۸٤ درصد	۱٦
۹۹/۱۷ درصد	۸۳/ ۰درصد	۲۰

جدول۴. مقایسه تاثیر مقادیر مختلف نرخ نمونه بنداری دسته‌بند بر صحت الگوریتم به ازای ۱۰ تکرار دسته‌بند

صحت پیش‌بینی	نرخ خطای طبقه‌بندی	نرخ نمونه‌برداری
۹۹/۱۱ درصد	۰/۹۳ درصد	۰/۳
۹۹/۰۸ درصد	۰/۹۲ درصد	۰/٦
۹۹/۱۷ درصد	۰/۸۳ درصد	۰/۹

با بررسی‌های انجام شده و مقایسه مقادیر مختلف پارامترهای شبکه عصبی در نهایت شبکه عصبی تجمیعی با تعداد ۵۷ نرون و با یک لایه پنهان، نرخ یادگیری ۰/۳، ۲۰ سیکل آموزشی، میزان نرخ نمونه‌برداری بگینگ ۰/۹ و ۱۰ تکرار دسته‌بند به‌عنوان مدل پیش‌بینی مورد استفاده قرار گرفت. در جدول ۵ پارامترهای ارزیابی شبکه عصبی تجمیعی برای این تحقیق آورده شده است.

جدول ۵. پارامترهای ارزیابی مدل شبکه عصبی تجمیعی

نام پارامتر	میزان ارزیابی
دقت	۹۹/۲۱ درصد
صحت	۹۹/۱۷ درصد
نرخ خطای طبقه‌بندی	۰/۸۳ درصد
ضریب کاپا	۰/۹۷٤
ضریب همبستگی	۰/۹۷٤
مربعات خطا	۰/۰۰۸ +/−۰/۰۷۸

با توجه به جدول ۵ در شبکه‌های عصبی جهت سنجش عملکرد از شاخص‌های ارزیابی مانند نرخ خطای طبقه‌بندی، مربعات خطا (Squared Error)، ضریب همبستگی (Correlation) و ضریب کاپا (kappa) نیز استفاده شد. نرخ خطای طبقه‌بندی جهت سنجش میزان صحت روش طبقه‌بندی می‌باشد. مربعات خطا نیز یک معیار مهم در تشخیص عملکرد شبکه عصبی می‌باشد و در صورتی که میزان تغییرات در پارامترهای شبکه پس از هر سیکل خیلی کوچک گردد؛ بطوریکه میزان گرادیان خطا کوچک گردد، الگوریتم به پایان خواهد رسید. در واقع مربعات خطا تفاوت میان مقدار پیش‌بینی شده توسط مدل و مقدار واقعی می‌باشد و یک ابزار خوبی جهت مقایسه خطاهای پیش‌بینی است (۲۰). ضریب همبستگی نیز یک معیار مهم در تعیین همبستگی بین متغیرها و کارایی مدل می‌باشد. ضریب کاپا میزان دقت الگوریتم را نشان می‌دهد (۳۰) و در نهایت می‌توان گفت مناسب‌ترین الگوریتم نرخ خطای کمتر، مربعات خطای پایین، ضریب همبستگی بالا و ضریب کاپای بالاتری دارد. با توجه به اینکه این مطالعه پیش‌بینی وضعیت بقاء نوزاد می‌باشد برای ارزیابی بهتر مدل از ماتریس درهم‌ریختگی یا اغتشاش (Confusion Matrix) جهت محاسبه دو معیار مهم دیگر مانند حساسیت و ویژگی استفاده گردید. ماتریس اغتشاش برای مجموعه داده‌های شبکه عصبی تجمیعی در جدول ٦ نمایش داده شده است. این ماتریس دارای چهار قسمت

می‌باشد: مثبت حقیقی(True Positive: TP)، مثبت کاذب (False Positive: FP)، منفی حقیقی (True Negative: TN) و منفی کاذب (Negative: FN False).

جدول۶. ماتریس اغتشاش برای مجموعه داده‌های شبکه

	مرگ نوزاد	تولد زنده
پیش‌بینی مرگ نوزاد	۱۵۵۵	۱۷
پیش‌بینی تولد زنده	۵۰	٦٤٣١

TP: تعداد نوزادانی که واقعاً فوت شده‌اند و مدل هم بدرستی آنها را موارد فوتی معرفی کرده است.
TN: تعداد نوزادانی که فوت نشده‌اند و مدل هم بدرستی آنها را تولد زنده معرفی کرده است.
FN: تعداد نوزادانی که فوت شده‌اند و مدل به اشتباه آنها را زنده به دنیا آمده معرفی کرده است
FP: تعداد نوزادانی که زنده به دنیا آمده‌اند و مدل به اشتباه آنها را موارد فوتی معرفی کرده است
عناصر ماتریس اغتشاش به‌صورت زیر است:

TN=6431، TP=1555 ،FN=50 ،FP=17

(۳)

$$Sensitivity = (TP / TP + FN) \times 100$$

(٤)

$$Specificity = (TN / TN + FP) \times 100$$

در این مطالعه حساسیت یا sensitivity عبارت است از نسبت تعداد نوزادان فوت شده (تشخیص داده شده توسط شبکه عصبی تجمیعی) به کل نوزادان فوت شده که ۹٦/۸۸ درصد محاسبه شد. به عبارت دیگر شبکه عصبی تجمیعی ۹٦/۸۸ درصد موارد مرگ‌ومیر را بطور صحیح ارزیابی کرده است. ویژگی یا Specificity عبارت است از نسبت تعداد نوزادان سالم و با تولد زنده (تشخیص داده شده توسط شبکه عصبی تجمیعی) به کل نوزادان با تولد زنده که ۹۹/۷٤ درصد محاسبه شد. به عبارت دیگر شبکه عصبی مصنوعی طراحی - شده ۹۹/۷٤ درصد نوزادان زنده و سالم در بدو تولد را بدرستی ارزیابی نموده است (۳۱).

منحنی مشخصه عملکرد سیستم یا همان منحنی راک یکی دیگر از روش‌های مهم برای مقایسه عملکرد مدل‌های پیش‌بینی می‌باشد که استفاده از این منحنی در تصمیم‌گیری پزشکی، تشخیص و پیش‌بینی زودهنگام بیماری کاربردهای قابل توجهی دارد که هر چه مساحت زیر منحنی راک بیشتر باشد عملکرد مدل طبقه‌بندی بهتر خواهد بود (۳۲). بنابراین در این پژوهش برای ارزیابی مدل پیش‌بینی از این منحنی نیز استفاده شد. شکل‌های شماره ۵ و ۶ مربوط به ماتریس درهم‌ریختگی (confusion matrix) و منحنی راک شبکه عصبی تجمیعی می‌باشد که سطح زیر منحنی برابر با ۰/۹۹۲ می‌باشد.

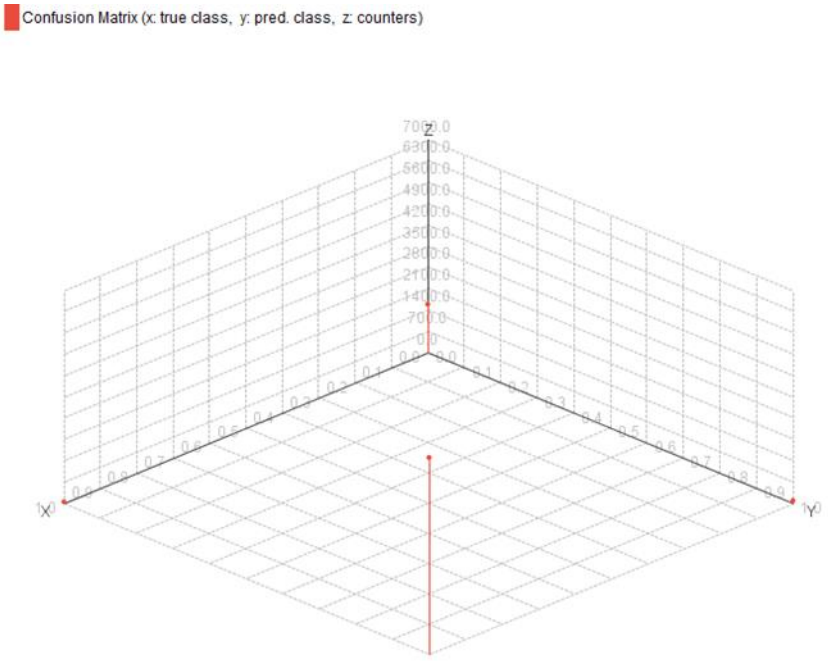

شکل ۵. نمودار ماتریس درهم‌ریختگی

شکل ٦. سطح زیر منحنی راک برای شبکه عصبی تجمیعی

بر اساس بررسی‌های انجام شده دقت، صحت، منحنی مشخصه عملکرد، نرخ خطای طبقه‌بندی حاصل از سه مدل داده‌کاوی ازجمله شبکه عصبی، درخت تصمیم و نزدیکترین همسایه با مدل پیشنهادی ما در این تحقیق مورد مقایسه قرار گرفت که نتایج حاصل از مقایسه چندین مدل در جدول ۷ آورده شده است.

جدول ۷. مقایسه دقت پیش‌بینی در بین مدل‌های بررسی‌شده

مدل	دقت پیش‌بینی	صحت پیش‌بینی	حساسیت	ویژگی	منطقه زیر منحنی	ضریب کاپا	نرخ خطای طبقه‌بندی
شبکه عصبی تجمیعی	۹۹/۲۱ درصد	۹۹/۱۷ درصد	۹٦/۸۸ درصد	۹۹/۷٤ درصد	۰/۹۹۲	۰/۹۷٤	۰/۸۳ درصد
شبکه عصبی	۹۹/۱۵ درصد	۹۹/۰۸ درصد	۹٦/۵۷ درصد	۹۹/۷۱ درصد	۰/۹۹۱	۰/۹۷۱	۰/۹۲ درصد
درخت تصمیم	۹۹/۰۵ درصد	۹۹/۰٦ درصد	۹٦/۱٤ درصد	۹۹/۷۸ درصد	۰/۹۷۹	۰/۹۷۰	۰/۹٤ درصد
نزدیکترین همسایه	۹۸/۹۱ درصد	۹۷/۷۹ درصد	۹۵/٦٤ درصد	۹۸/۳۳ درصد	۰/۵۰۰	۰/۹۳۱	۲/۲۱ درصد

مطابق جدول ۷ شبکه عصبی تجمیعی در مقایسه با چند مدل دیگر خصوصاً نسبت به شبکه عصبی بدون بگینگ در دقت، صحت، سطح زیر منحنی، ضریب کاپا و نرخ خطای طبقه‌بندی بهبود داشته است. میزان دقت در شبکه عصبی از ۹۹/۱۵ درصد به ۹۹/۲۱ درصد و میزان صحت از ۹۹/۰۸ درصد به میزان ۹۹/۱۷ درصد در شبکه عصبی تجمیعی افزایش یافته است و نرخ خطای طبقه‌بندی از ۰/۹۲ درصد به ۰/۸۳ درصد در شبکه تجمیعی کاهش یافته است که منطقه زیر منحنی کرو نیز بهبود کارایی در شبکه تجمیعی را اثبات می‌کند. ارزیابی نتایج مدل‌های طراحی شده نشان داد که الگوریتم شبکه عصبی تجمیعی بهترین نتایج را در دقت به میزان ۹۹/۲۱ درصد و صحت به میزان ۹۹/۱۷ درصد و نرخ خطای طبقه‌بندی ۰/۸۳ درصد داشته است و مدل پیش‌بینی نزدیکترین همسایه با میزان دقت ۹۸/۹۱ درصد، میزان صحت ۹۷/۷۹ درصد و نرخ خطای ۲/۲۱ درصد بدترین نتایج را داشته است.

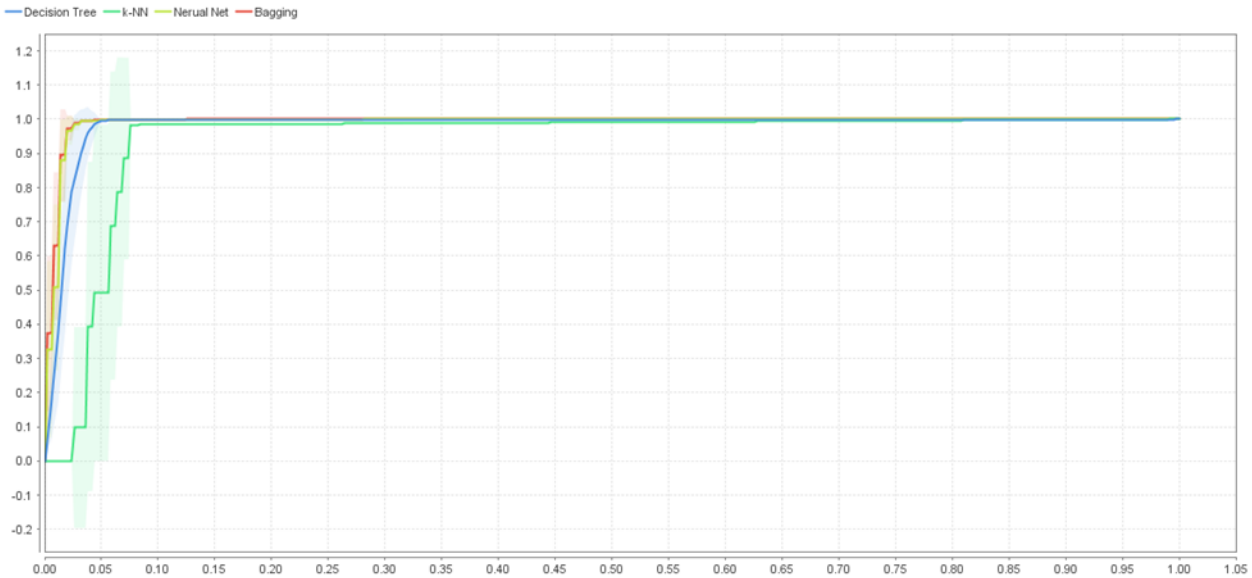

شکل ۷. مقایسه سطح زیر منحنی مدل‌های پیش‌بینی

مناطق زیر منحنی راک همان‌طور که در شکل ۷ مشاهده می‌شود، نشان دهنده‌ی این است که الگوریتم بگینگ یا تجمیعی از مساحت زیر منحنی بالاتری نسبت به بقیه الگوریتم‌ها برخوردار است؛ بنابراین مدل شبکه عصبی تجمیعی مطابق با نمودار راک که دارای سطح زیر منحنی بالاتری می‌باشد، نسبت به مدل‌های دیگر مناسب‌تر است.

بحث

این مطالعه بر روی داده‌های پایگاه داده مادر و نوزاد سال ۱۳۹۴ کلیه مراکز درمانی و دانشگاهی کشور انجام شد که قادر است وضعیت بقاء نوزاد را در ۲۴ ساعت اولیه تولد پیش‌بینی نماید. بررسی مطالعات قبلی نشان می‌دهد که اطلاعات ساعات اولیه پس از تولد در پیش‌بینی تأثیر بهتری دارد. با بررسی پژوهش‌های پیشین انجام شده، مرگ‌ومیر نوزادان در جوامع از شایع‌ترین مشکلات سلامتی و بهداشتی بخصوص در جوامع در حال توسعه می‌باشد (۱۱). بنابراین تحقیقات در این زمینه می‌تواند جهت کاهش مرگ‌ومیر نوزادان، کمک به سلامت جامعه مادران، کاهش هزینه‌های بهداشتی درمانی و در جهت توسعه‌مندی جوامع، کمک فراوانی نماید؛ بنابراین نیاز به مدل پیش‌بینی مرگ‌ومیر نوزادی با میزان دقت بالاتر و نرخ خطای کمتر بود و با بررسی مطالعات گذشته در این زمینه نتایج مدل‌های پیش‌بینی شبکه عصبی از دقت بالاتری نسبت به رگرسیون، درخت تصمیم و... برخوردارند و با توجه به اینکه تاکنون مدلی برای پیش‌بینی مرگ‌ومیر نوزادان در بدو تولد با استفاده از شبکه عصبی تجمیعی جهت بررسی دقت صورت نگرفته بود در مطالعه حاضر سعی شد که نتایج پیش‌بینی حاصل از مطالعات پیشین بهبود داده شود. در این مطالعه شبکه عصبی تجمیعی طراحی و مورد استفاده قرار گرفت که نتایج حاصل از تحقیق حاکی از آن است که این شبکه می‌تواند وضعیت بقاء نوزاد را در بدو تولد بدرستی تشخیص دهد و پیشنهادات مؤثر را به دستگاه‌های برنامه‌ریزی و اجرایی کشور در جهت توجه بیشتر به جامعه در خصوص بهداشت و امکانات ارائه نمود.

در این مطالعه متغیرهای مورد استفاده جهت پیش‌بینی شامل ریسک فاکتورهای مهم در سلامت مادر و نوزاد بود که فیلدهای بی‌تأثیر در پیش‌بینی با نظر متخصصان از مطالعه حذف شدند و با انتخاب متغیرهای ورودی که همبستگی بیشتری با متغیر هدف وجود دارد، نتایج بهتری حاصل شد. مطالعات پیشین نشان داد که پیش‌بینی وضعیت بقاء نوزادی تا ۲۴ ساعت از تولد اهمیت بیشتری از پیش‌بینی در بدو تولد دارد که این پیش‌بینی فقط با استفاده از داده‌های پریناتال امکان‌پذیر می‌باشد که در این مطالعه نیز از داده‌های پریناتال استفاده شد.

در این مطالعه ابتدا شبکه عصبی تجمیعی برای پیدا کردن میزان و تعداد نرون مناسب آموزش داده شد و مدل شبکه عصبی سه لایه با ۵۷ نرون، نرخ یادگیری ۰/۳، تعداد سیکل آموزشی ۲۰، نرخ نمونه‌برداری دسته‌بند ۰/۹ و میزان تکرار دسته‌بند به تعداد ۱۰ تکرار ایجاد شد. نتایج حاصل از دقت، صحت، میزان نرخ خطای شبکه عصبی تجمیعی، ضریب کاپا و سطح زیر منحنی با چند الگوریتم دیگر داده‌کاوی ازجمله شبکه عصبی، درخت تصمیم و نزدیکترین همسایه مقایسه شدند. بررسی و ارزیابی مدل‌های ایجادشده، نشان داد که الگوریتم شبکه عصبی تجمیعی بهترین نتایج را در دقت، صحت و نرخ خطای طبقه‌بندی را به‌ترتیب با مقادیر ۹۹/۲۱ درصد، ۹۹/۱۷ درصد و ۰/۸۳ درصد داشته است و تکنیک با بدترین نتایج متعلق به نزدیکترین همسایه با میزان دقت ۹۸/۹۱ درصد، میزان صحت ۹۷/۷۹ درصد و نرخ خطای ۲/۲۱ درصد بوده است.

این مطالعه نقاط قوت بسیاری دارد ازجمله اینکه مدل طراحی شده دارای دقت بالا و نرخ خطای بسیار کم نسبت به مطالعه‌های پیشین مشابه در این زمینه می‌باشد که این یکی از موفقیت‌های این مطالعه در جهت پیش‌بینی مرگ‌ومیر نوزادی می‌باشد که همراه با تشخیص پزشکان می‌تواند در سلامت جامعه مادران و نوزادان بسیار مفید واقع شود. نقطه موفقیت دیگر این تحقیق استفاده از داده‌های پریناتال می‌باشند. متغیرهایی که در مطالعه حاضر استفاده شده‌اند همگی به‌عنوان فاکتورهای مؤثر در پیامد مرگ‌ومیری نوزادان در بدو تولد می‌باشد که مورد تأیید مطالعات قبلی نیز می‌باشند. از نقاط قوت دیگر این مطالعه استفاده از تعداد نمونه با حجم بالا و در سطح کشوری می‌باشد که تمام مرگ‌ومیرها و تولدهای زنده را در کلیه مناطق محروم و پیشرفته کشور ایران شامل می‌شود.

از محدودیت‌های این مطالعه کیفیت داده‌ها می‌باشد. بیشتر داده‌های مورد استفاده در این مطالعه ماهیت باینری داشتند. با توجه به اینکه تخمین مدل پیش‌بینی بر اساس بازه‌ها می‌باشد و با توجه به کم بودن تعداد بازه‌ها در این حالت (صفر و یک)، امکان تخمین نادرست مدل وجود دارد که این می‌تواند دقت مدل پیش‌بینی را کمتر نماید. از دیگر محدودیت‌های این مطالعه، عدم تکمیل اطلاعات مربوط به بعضی از فیلدها مانند عوامل خطر مادری، وزن نوزاد و... در مراکز درمانی می‌باشد که می‌تواند مدل پیش‌بینی را دچار اختلال کند که هر دو محدودیت با توجه به اینکه دیتاست کشوری می‌باشد و پژوهشگران دخالتی ندارند، اجتناب‌ناپذیر می‌باشد.

نتیجه‌گیری

تولد نوزاد یکی از زیباترین پدیده‌ها در طول زندگی برای افراد خانواده می‌باشد که گاهی این پدیده می‌تواند همراه با پیشامدهای ناگواری باشد. در حال حاضر سیستم برنامه-

ریزی جهت سلامت مادران و نوزادان با کاستی‌هایی مواجه می‌باشد که بدون مرتفع نمودن آنها دستیابی به جامعه‌ای در راستای توسعه‌مندی و با حداقل مرگ‌ومیر نوزادی ممکن نمی‌باشد. توجه ویژه به دوران نوزادی و مراقبت از مادرانی که در معرض خطر پیامد مرگ‌ومیر نوزادی می‌باشند و ارائه آموزش‌های بهداشتی و مراقبت‌های ویژه این مادران می‌تواند در کاهش مرگ‌ومیر نوزادان تأثیر بسزایی داشته باشد. مطالعه حاضر، مدل پیش‌بینی برای پیش‌بینی وضعیت بقاء نوزاد را با استفاده از شبکه عصبی تجمیعی ارائه داده است که بر اساس یافته‌های این مطالعه این مدل از دقت بالایی برخوردار می‌باشد و می‌توان بر اساس نتایج حاصله از تحقیق، پیش‌بینی پیامد مرگ‌ومیر نوزادان را در زمان تولد انجام داد و پیشنهادات مؤثر را به دستگاه‌های برنامه‌ریزی و اجرایی کشور جهت توجه بیشتر به جامعه در خصوص بهداشت و امکانات ارائه نمود.

پیشنهاد کارهای آتی

یکی از مواردی که می‌تواند به این تحقیق و تحقیقات آتی کمک کند پیش‌بینی نقایص مادرزادی در زمان تولد می‌باشد که یکی از علل مهم مرگ‌ومیر نوزادی می‌باشد. جهت این پیش‌بینی می‌توان از داده‌های قبل از بارداری و حین بارداری و بعد از زایمان مادران جهت پیش‌بینی نوزاد با ناهنجاری مادرزادی در بدو تولد استفاده نمود که ایجاد و ثبت پایگاه داده ثبت مداوم پرونده‌های الکترونیکی از وضعیت و سوابق پزشکی در هر سه دوره ذکر شده با حجم نمونه بالا مورد نیاز می‌باشد با در اختیار داشتن این اطلاعات می‌توان به‌دقت مدل بالاتری به‌منظور پیش‌بینی وقوع ناهنجاری مادرزادی نوزاد قبل از تولد دست یافت. این مدل می‌تواند به‌منظور پیش‌بینی میزان احتمال بروز ناهنجاری در زمان تولد مورد استفاده قرار گیرد که کمک فراوانی به سلامت خانواده‌ها و جامعه خواهد نمود.

ملاحظات اخلاقی

دسترسی از سامانه وزارت بهداشت بوده است و در این داده‌ها جهت ملاحظه جوانب اخلاقی تمام اطلاعات به‌صورت محرمانه بررسی و تجزیه و تحلیل شده است و هیچ گونه اطلاعاتی که حاکی از اطلاعات شخصی نمونه‌ها باشد، آشکار نشده است.

تضاد منافع

بدین‌وسیله نویسندگان اعلام می‌کنند که این پژوهش هیچ‌گونه تضاد منافعی با سازمان‌ها و اشخاص دیگری ندارد.

تقدیر و تشکر

این مقاله برگرفته از پایان‌نامه کارشناسی ارشد با کد ۱۰۲٤۱۰۱۰۹٦۲۰۲۷ می‌باشد. نویسندگان بر خود لازم می‌دانند که از مساعدت‌های اساتید، سازمان وزارت بهداشت، تمامی مادران و کارکنان مراکز درمانی که برای اجرای این پروژه همکاری‌های شایانی نموده‌اند، صمیمانه تشکر نمایند.

References

1. Ghorat F, Ghafarzadeh R, Esfehani RJ. Perinatal mortality and its associated risk factors: A study in the north-east of Iran. Iran J Neonatol. 2016;7(1):47–51.
2. Babaei H, Dehghan M, Pirkashani LM. Study of causes of neonatal mortality and its related factors in the neonatal intensive care unit of Imam Reza hospital in Kermanshah , Iran during (2014-2016). Int J Pediatr. 2018;6(53):7641–9. doi:10.22038/ijp.2017.28212.2441
3. Hsu ST, Hsieh CJ, Chen HW, Jeng SF, Wu HC, Chen MH, et al. Nationwide birth weight and gestational age-specific neonatal mortality rate in Taiwan. Pediatr Neonatol. 2015;56(3):149–58. doi:10.1016/j.pedneo.2014.07.006
4. Gilchrist J, Ennett CM, Frize M, Bariciak E. Neonatal mortality prediction using real-time medical measurements. 2011 IEEE Int Symp Med Meas Appl. 2011;65–70. doi:10.1109/MeMeA.2011.5966653
5. Rezaeian A, Nasimi F, Moghadam FP. Predicting mortality rate of preterm infants in neonatal. J Maz Univ Med. 2015;26(140):85–94. (Persian)
6. Zeinalzadeh AH, Khodaei R, Heidarzadeh M, Mirnia K. Causes of neonatal mortality in the neonatal intensive care unit of taleghani hospital. Iran J Neonatol (IJN). 2017;8(3):58–61. doi:10.22038/ijn.2017.25853.1340
7. Koum D, Essomba N, Odile N, Ngwe I, Ndanga M. Factors associated with early neonatal morbidity and mortality in an urban district hospital. Int J Latest Res Sci Technol. 2015;5(3):9–43.
8. Bashtian MH, Armat MR, Khakshour A. Assessment of the recorded causes of neonatal hospitalization and the related factors in neonatal wards and NICUs in Bojnord. Iran J Neonatol. 2014;5(2):21–4.
9. Suleiman MB, Mokuolu OA. Perinatal mortality in a northwestern Nigerian city: A wake up call. Front Pediatr. 2014;2:1–7. doi:10.3389/fped.2014.00105
10. Mustufa MA, Korejo R, Shahid A, Nasim S. Infection remains a leading cause of neonatal mortality among infants delivered at a tertiary

hospital in Karachi, Pakistan. J Infect Dev Ctries. 2014;8(11):1470-5. doi:10.3855/jidc.3569
11. Schmidt S, Bounnack S, Hoehn T. Neonatal mortality and morbidity in the post-implementation period of a neonatal teaching program in provincial hospitals in Laos. Public Health [Internet]. 2017;154:123–9. doi:org/10.1016/j.puhe.2017.10.021
12. Imtiaz J, Harris H, Sohail S, Amna Z, Naushaba M, Omrana P, et al. Neonatal mortality, risk factors and causes: a prospective population-based cohort study in urban Pakistan. Bull World Health Organ. 2009;87(2):130–8. doi:org/10.2471/BLT.08.050963
13. Muhammed G, Kibria A, Burrowes V, Choudhury A, Sharmeen A, Ghosh S, et al. Determinants of early neonatal mortality in Afghanistan : an analysis of the Demographic and Health Survey 2015. Global Health. 2018;1–12.
14. Zafari M, Akbarzadeh H, Tofighi M, Tahmasebi H. A study of frequency and causes of neonatal mortality. Clin Pract. 2012;1(3):21–4. doi:10.5923/j.cp.20120103.02
15. Yamey G, Horváth H, Schmidt L, Myers J, Brindis CD. Reducing the global burden of Preterm Birth through knowledge transfer and exchange: A research agenda for engaging effectively with policymakers. Reprod Health. 2016;13(1):1–9.doi:10.1186/s12978-016-0146-8
16. Heidarnia MA, Abadi A, Motlagh ME. Neonatal mortality rate in Iran : the Iranian Perinatal Mortality Surveillance System. J Pediatr Neonatal Individ Med. 2018;7(2):3–7. doi:10.7363/070217
17. Houweling TAJ, Klaveren D Van, Das S, Azad K, Tripathy P, Manandhar D, et al. A prediction model for neonatal mortality in low- and middle-income countries: an analysis of data from population surveillance sites in India, Nepal and Bangladesh. Int J Epidemiol. 2018;1–13. doi: 10.1093/ije/dyy194
18. Vincer MJ, Armson BA, Allen VM, Allen AC, Stinson DA, Whyte R, et al. An algorithm for predicting neonatal mortality in threatened very preterm birth. J Obstet Gynaecol Canada. 2015;37(11):958–65.doi:10.1016/S1701-2163(16)30045-7
19. Podda M, Bacciu D, Micheli A, Bellù R, Placidi G, Gagliardi L. A machine learning approach to estimating preterm infants survival: development of the Preterm Infants Survival Assessment (PISA) predictor. Sci Rep. 2018;8(1):1–9. doi:10.1038/s41598-018-31920-6
20. Chang C, Liao C, Description AS. Parameter sensitivity analysis of artificial neural network for predicting water turbidity. Int J Geol Environ Eng. 2012;6(10):657–60
21. Shi L, Xi L, Ma X, Hu X. Bagging of artificial neural networks for bankruptcy prediction. In: Proceedings - International Conference on Information and Financial Engineering, ICIFE 2009. Zhengzhou, China; 2009. p. 154–6.
22. Nabil M. Hewahi MKS. Class outliers mining: Distance-based approach (BSc report). Int J Intell Technol. 2006;2(1):55–68.
23. Gu J, Wang Z, Kuen J, Ma L, Shahroudy A, Shuai B, et al. Recent advances in convolutional neural networks. Pattern Recognit. 2018;77:354–77. doi:10.1016/j.patcog.2017.10.013
24. Zhang L, Suganthan PN. A survey of randomized algorithms for training neural networks. Inf Sci (Ny). 2016;146–55. doi:10.1016/j.ins.2016.01.039
25. Liu W, Wang Z, Liu X, Zeng N, Liu Y, Alsaadi FE. A survey of deep neural network architectures and their applications. Neurocomputing. 2017;234(October 2016):11–26. doi:10.1016/j.neucom.2016.12.038
26. Ishthaq Ahamed K, Akthar S. Survey on artificial neural network learning technique algorithms. Int Res J Eng Technol [Internet]. 2016;3(2):36–9
27. Kim M, Kang D. Expert Systems with Applications Ensemble with neural networks for bankruptcy prediction. Expert Syst Appl. 2010;37(4):3373–9. doi:10.1016/j.eswa.2009.10.012
28. Lemmens A, Croux C. Bagging and boosting classification trees to predict churn. J Mark Res. 2006;43(2):276–86. doi:10.1509/jmkr.43.2.276
29. Krishnaiah V, Narsimha G, Chandra NS. Survey of classification techniques in data mining. Int J Comput Sci. 2014;2(9):65–74
30. Aziz N, Minallah N, Junaid A, Gul K. Performance analysis of artificial neural network based land cover classification. Int J Mar Environ Sci. 2017;11(5):422–6
31. Aalaei S, Shahraki H, Rowhanimanesh A, Eslami S. Feature selection using genetic algorithm for breast cancer diagnosis: experiment on three different datasets. Iran J Basic Med Sci. 2016;19(5):476-82
32. Li J, Sun J, Liu L, Pan H, Liu H, Yang J-J, et al. Comparison of different machine learning approaches to predict small for gestational age infants. IEEE Trans Big Data. 2016;7790(c):1–14. doi:10.1109/tbdata.2016.2620981