

# پیش‌بینی تولد نوزادان با وزن کم در هر یک از بازه‌های دوران بارداری، با به کارگیری روش‌های هوش مصنوعی فازی و غیر فازی، بدون استفاده از اندازه‌گیری‌های حاصل از سونوگرافی

مهتاب فرجبخش<sup>۱</sup>، دکتر حمیدرضا مراتب<sup>۲</sup>، دکتر مرجان منصوریان<sup>۳</sup>، معصومه گودرزی خویگانی<sup>۴</sup>

## مقاله پژوهشی

### چکیده

**مقدمه:** وزن کم نوزاد در زمان تولد را می‌توان مهم‌ترین عامل در بیماری و مرگ و میر نوزادان دانست. نوزادانی که در زمان تولد وزن کمی دارند، بیشتر در معرض بیماری‌ها قرار می‌گیرند. به همین دلیل، پیش‌بینی احتمال کم وزن بودن نوزاد پیش از تولد، از اهمیت بالایی برخوردار است.

**روش‌ها:** در این مطالعه، یک سیستم تشخیصی به کمک رایانه ارائه شد که به کمک آن می‌توان گروه وزنی نوزاد را در زمان تولد پیش‌بینی کرد و نوزادان را در دو گروه نوزاد با وزن کم و وزن طبیعی طبقه‌بندی نمود. همچنین، ارتباط میان وزن کم نوزاد در زمان تولد و فاکتورهای ثبت شده از مادران باردار در سه ماهه‌ی اول، دوم و سوم بارداری مورد بررسی قرار گرفت. مجموعه‌ی داده‌های مورد استفاده در این مطالعه شامل اطلاعات گرفته شده از ۵۲۶ زن باردار با ۹۵ متفاوت مختلف ثبت شده از آن‌ها است. برای طبقه‌بندی نمونه‌های این مطالعه از روش‌های کلاس‌بندی (Classifier) نزدیک‌ترین همسایه‌ها، شبکه‌های عصبی احتمالاتی و دو نوع کلاس‌بند عصبی - فازی انطباقی استفاده گردید. علاوه بر آن، انتخاب ویژگی به روش پی‌درپی نیز برای کاهش اندازه‌ی فضای ویژگی‌ها مورد استفاده قرار گرفت.

**یافته‌ها:** صحت طبقه‌بندی با استفاده از کلاس‌بندهای نزدیک‌ترین همسایه‌ها، شبکه‌ی عصبی احتمالاتی و کلاس‌بند عصبی - فازی انطباقی با استفاده از دو الگوریتم گرادیان مزدوج مدرج و شرایط زبانی، با انتخاب ویژگی به ترتیب برابر با ۸۳، ۹۳، ۸۰ و ۸۳ درصد گزارش شد.

**نتیجه‌گیری:** از میان کلاس‌بندهای مورد استفاده، توان بهترین کلاس‌بند مورد استفاده در این مطالعه با استفاده از روش‌های مناسب اعتبارسنجی، ۹۶ درصد و خطای نوع اول آن ۱/۰ بوده است. با توجه به این نتایج، سیستم تشخیصی ارائه شده از لحاظ بالینی معتبر می‌باشد.

**وازگان کلیدی:** سیستم‌های تشخیصی پزشکی به کمک رایانه، روش اعتبارسنجی مقاطعه، وزن کم نوزاد در زمان تولد، روش پی‌درپی انتخاب ویژگی

**ارجاع:** فرجبخش مهتاب، مراتب حمیدرضا، منصوریان مرجان، گودرزی خویگانی معصومه. پیش‌بینی تولد نوزادان با وزن کم در هر یک از بازه‌های دوران بارداری، با به کارگیری روش‌های هوش مصنوعی فازی و غیر فازی، بدون استفاده از اندازه‌گیری‌های حاصل از سونوگرافی. مجله دانشکده پزشکی اصفهان ۱۳۹۴؛ ۳۳(۳۲۱): ۲۷-۱۴

۱- دانشجو، گروه مهندسی پزشکی، دانشکده فنی مهندسی، دانشگاه اصفهان، اصفهان، ایران

۲- استادیار، گروه مهندسی پزشکی، دانشکده فنی مهندسی، دانشگاه اصفهان، اصفهان، ایران

۳- استادیار، گروه آمار و اپیدمیولوژی، دانشکده بیهداشت، دانشگاه علوم پزشکی اصفهان، اصفهان، ایران

۴- دانشجوی دکتری، گروه مامایی، دانشکده پرستاری و مامایی، دانشگاه علوم پزشکی اصفهان، ایران

نویسنده‌ی مسؤول: دکتر مرجان منصوریان

Email: j\_mansourian@hlth.mui.ac.ir

## مقدمه

سیستم‌های تشخیصی پزشکی مبتنی بر رایانه به علت پتانسیل بالقوه‌ی خود و به منظور بهبود کیفیت مراقبت‌های بهداشتی رواج پیدا کرده‌اند. استفاده از این سیستم‌ها با هدف حمایت و بهبود تصمیم‌گیری‌های بالینی پزشکان بدون صرف هزینه‌های بیشتر درمانی و یا اتلاف وقت جهت پایش‌های متوالی، از کاربرد بالایی برخوردار است (۱۶). این سیستم‌ها می‌توانند به کمک تکنیک‌های هوش مصنوعی، در تولید و یکپارچه سازی اطلاعات بیمار، انجام ارزیابی‌های پیچیده و ارائه نتایج به پزشکان مورد استفاده قرار گیرند.

روش متداول پیش‌بینی وزن نوزاد پیش از زمان تولد با استفاده از اندازه‌گیری‌های حاصل از سونوگرافی جهت یافتن شاخص‌های مناسب و استفاده از آن‌ها در فرمول‌های مربوط انجام می‌گیرد (۲۰-۲۷). اگرچه این روش تخمین مناسبی را از وزن نوزاد در زمان تولد ارائه می‌دهد، اما در تمامی این مطالعات (۲۰-۲۷) نوزاد پس از مدت زمان کمی بعد از انجام سونوگرافی به دنیا می‌آید و در این صورت زمان کافی برای تغییر یا بهبود وزن نوزاد در زمان تولد وجود نخواهد داشت.

هدف از انجام مطالعه‌ی حاضر، بررسی تأثیر ویژگی‌های فردی، باروری و عملکرد تغذیه‌ی مصرفی مادر در طول دوره‌ی بارداری بر وزن نوزاد در زمان تولد و بررسی توانایی ویژگی‌های ذکر شده جهت پیش‌بینی گروه وزنی نوزاد در سه ماهه‌ی اول، دوم و سوم بارداری و در نهایت طراحی یک سیستم تشخیصی پزشکی بر پایه‌ی رایانه جهت پیش‌بینی گروه وزنی نوزاد پیش از تولد بود. در پژوهش حاضر مجموعه‌ای از کلاس‌بندهای (Classifier) فازی و

وزن نوزاد در زمان تولد را می‌توان مهم‌ترین عامل در بیماری و مرگ و میر نوزادان دانست. سازمان بهداشت جهانی (World Health Organization) یا WHO وزن کمتر از ۲۵۰۰ گرم را به عنوان وزن کم (LBW) یا Low birth weight تعريف کرده است که عامل بسیار مهمی در تعیین میزان بیماری‌ها و ناتوانی‌های افراد در دوران کودکی و بزرگسالی می‌باشد (۱) و از آن جمله می‌توان به بیماری‌ها و مشکلات روانی در دوران کودکی (۲)، بیماری‌های قلبی و عروقی در بزرگسالی (۳-۴)، بیماری مزمن کلیه (Chronic kidney disease) یا CKD (۵)، نارسایی کلیوی (۶)، پرفشاری خون (۷) و بیماری‌های واپسیه به آن اشاره کرد. عوامل بسیار زیادی همچون کالری مصرفی مادر (۱)، وضعیت مصرف بعضی از ریزمغذی‌ها مانند روی در بدن مادر (۸-۱۰)، کمبود ویتامین B<sub>۱۲</sub> در بدن مادر (۱۱)، شاخص‌های آنتروپومتریک در مادران (۱۲)، سن مادر (۱۳)، کم‌خونی مادر، پارگی زودرس کیسه‌ی آب در بارداری (Premature rapture of membrane) یا PROM، وجود نسبت فامیلی بین پدر و مادر (۱۴)، پرفشاری خون و پری‌اکلامپسیا (Preeclampsia) (۱۵) می‌توانند وزن نوزاد در زمان تولد را تحت تأثیر قرار دهند. بررسی عوامل مؤثر بر وزن نوزاد در زمان تولد و مطالعه‌ی شدت تأثیر هر یک از این عوامل از اهمیت بالایی برخوردار است. شناخت صحیح عوامل مؤثر بر وزن نوزاد در زمان تولد کمک می‌کند تا در صورت فقدان یک یا چند عامل در دوران بارداری، اقدامات لازم در جهت رفع کمبود عامل مورد نظر صورت گیرد و احتمال تولد نوزاد با وزن کم کاهش یابد.

بارداری و سایر ویژگی‌های جمعیت‌شناختی، باروری و فعالیت فیزیکی مادر مورد بررسی قرار گرفت. ویژگی‌های اندازه‌گیری شده از مادران شامل «سن مادر، وزن مادر پیش از بارداری، پارگی زودرس کیسه‌ی آب، میزان ریزمغذی‌ها و درشت مغذی‌های مصرف شده توسط مادر، وضعیت پری‌اکلامپسیا، میزان فعالیت فیزیکی مادر، وزن اضافه شده به مادر در دوره‌ی بارداری در طول دوره‌های سه ماهه‌ی اول، دوم و سوم بارداری» بود. متغیر پارگی زودرس کیسه‌ی آب به عنوان تنها مورد زایمان زودرس در مطالعه لحاظ گردید. به جز این مورد، سایر مادران دوران بارداری را به صورت کامل سپری کرده بودند. امروزه در علوم پزشکی زیاد بودن عوامل مؤثر بر یک پدیده‌ی پزشکی همواره با وجود روابط پیچیده‌ی همبستگی میان آن‌ها همراه است. بر این اساس، طراحی یک سیستم تشخیصی با استفاده از ابزاری به عنوان کلاس‌بند طوری انجام می‌گیرد که پیچیدگی سیستم‌های بیولوژیک و عوامل مؤثر غیر خطی مدل‌بندی شوند. روش‌های مختلف کلاس‌بندی نسبت به یکدیگر دارای مزایا و معایبی هستند؛ به نحوی که استفاده از هر یک شرایط خاص خود را می‌طلبد. در ادامه برخی از روش‌های کلاس‌بندی متناسب با داده‌های مورد بررسی معرفی شده است.

کلاس‌بند نزدیک‌ترین همسایه‌ها (kNN) یا k-Nearest neighbors) غیر پارامتری (Non-parametric lazy algorithm) از نیز نامیده می‌شود، بر اساس تعداد مشخصی (k) از نزدیک‌ترین نمونه‌های گروه آموزشی در فضای ویژگی‌ها عمل می‌کند (۲۲). در این الگوریتم، تعداد k تا از نزدیک‌ترین همسایه‌های نمونه‌ی مورد نظر از

غیر فازی جهت طبقه‌بندی وزن نوزاد در زمان تولد به گروه‌های کم وزن یا وزن طبیعی، بر اساس ویژگی‌های ثبت شده از مادران در سه ماهه‌ی اول، دوم و سوم بارداری مورد استفاده قرار گرفت.

## روش‌ها

داده‌های مورد استفاده توسط پرسش‌نامه‌هایی در چهار مرحله از ۷۰۰ زن باردار ایرانی مراجعه کننده به ۱۸ مرکز بهداشتی و ۱۲ مرکز خصوصی و با استفاده از روش مصاحبه جمع‌آوری شد. علاوه بر آن، رژیم غذایی (یادآمد غذایی) ۴۸ ساعته‌ی زنان ۳۴-۳۷ و ۱۱-۱۵، ۲۶ و ۲۷ واجد شرایط در هفته‌های

بارداری مورد ارزیابی قرار گرفت. مواردی همچون تولد نوزادان چند قلو، مرده‌زایی، مادران سیگاری و مادران دارای بیماری‌های مزمن (مانند دیابت و پرفشاری خون) معیارهای خروج از مطالعه بودند. در نهایت داده‌های جمع‌آوری شده از ۵۲۶ زن باردار که پرسش‌نامه‌ی کامل و معتبر داشتند، تجزیه و تحلیل گردید. فعالیت بدنی مادر نیز با استفاده از یک پرسش‌نامه‌ی معتبر اندازه‌گیری شد. تمام مصاحبه کننده‌ها تحت شرایط همسان آموزش دیدند و سوابق همه‌ی بیماران توسط افراد متخصص جمع‌آوری شده بود (۲۱). داده‌های یادآمد غذایی با استفاده از نرم‌افزار Nutrition-IV مورد تجزیه و تحلیل قرار گرفت. همه افراد شرکت کننده در مطالعه به صورت آگاهانه به روند کلی و پروتکل پرسش‌نامه رضایت داده بودند. انجام آزمایش توسط دانشگاه علوم پزشکی اصفهان و بر اساس اعلامیه‌ی Helsinki تصویب شد.

ارتباط میان LBW و حدود ۴۰ نوع از بخش‌های تغذیه‌ای مادران در طول سه ماهه‌ی اول، دوم و سوم

جستجوی شبکه‌ی جامع (Exhaustive grid search) انتخاب شد. عملکرد شبکه‌ی عصبی احتمالاتی به برآوردتابع چگالی احتمال (PDF) یا Parzen Probability density function پنجره‌ی (Parzen window) بسیار نزدیک است. پنجره‌ی Parzen یک الگوریتم غیر پارامتری است که تخمینی از توابع چگالی احتمال را با استفاده از انطباق (Superposition) تعدادی پنجره ارائه می‌کند. کلاس‌بند پنجره‌های Parzen طبقه‌بندی را بعد از محاسبه‌ی تابع چگالی احتمال، با استفاده از نمونه‌های آموزش برای هر کلاس اعمال می‌کند.

از مزایای استفاده از کلاس‌بند شبکه‌های عصبی می‌توان به سرعت بالای فرایند آموزش، ساختار موازی شبکه، امکان هم‌گرایی شبکه به کلاس‌بند بهینه برای داده‌های دارای گروه آموزش با اندازه‌ی بزرگ و امکان اضافه یا حذف نمونه‌های گروه آموزش بدون نیاز به آموزش گسترده‌ی مجدد شبکه اشاره کرد. بر این اساس، PNN با سرعت بالاتری نسبت به بسیاری از شبکه‌های عصبی دیگر می‌آموزد و موفقیت بالایی در انواع برنامه‌های کاربردی دارد (۲۶). مزیت بالای این شبکه نسبت به دیگر شبکه‌های عصبی، عدم حساسیت آن نسبت به داده‌های پرت و نوع توزیع متغیرها می‌باشد. این کلاس‌بند آماری نسبت به توزیع مساوی داده‌ها در هر کلاس نیز محدودیتی ندارد (۲۷).

کلاس‌بند عصبی-فازی انطباقی (ANFC) یا Adaptive neuro-fuzzy classifier روش‌های متعارف بازشناسنخست الگو (Pattern recognition) برای خوشه‌بندی نمونه‌های آموزشی و نسبت دادن خوشه‌ها به یک کلاس، با محدودیت‌های مختلف و عدم وجود راه حل مؤثری

گروه آزمایش انتخاب می‌شوند و با توجه به این که خروجی بیشتر نمونه‌های گروه آموزش در چه کلاسی قرار داشته باشد، همان کلاس به عنوان خروجی نمونه‌ی گروه آزمایش انتخاب می‌گردد. به عبارت دیگر، رایج‌ترین کلاس موجود در میان همسایه‌ها به عنوان کلاس نمونه‌ی جدید انتخاب می‌گردد (۲۳).

شبکه‌های عصبی احتمالاتی (Probabilistic neural network) اساس نظریه‌ی طبقه‌بندی Bayesian و برآورد تابع چگالی احتمال استوار است. به جهت آسان بودن آموزش در این شبکه و زیرساخت آماری آن در Bayesian PNN به ابزار مؤثری برای حل بسیاری از مسایل طبقه‌بندی تبدیل شده است. در واقع در این شبکه‌ی عصبی با جایگزینی تابع فعالیت (Activation function) سیگموئید (که در بسیاری از شبکه‌های عصبی استفاده می‌شود) با تابع نمایی، یک شبکه‌ی احتمالاتی که می‌تواند مرزهای تصمیم‌گیری غیر خطی را نیز پوشش دهد، ایجاد می‌شود. این شبکه یک شبکه‌ی عصبی رو به جلو (Feed forward network) با چهار لایه‌ی ورودی (Input layer)، جمع‌زنی (Pattern layer)، الگو (Output layer) و خروجی (Decision layer) است. در شبکه‌های عصبی احتمالاتی برای هر نمونه در بردار آموزش یک گرهی مخفی (Hidden node) وجود دارد (۲۴). هر گرهی مخفی یک نقطه‌ی مرکزی (Center point) که همان بردار ورودی برای هر نمونه است و یک شاخص پراکندگی (Spread factor) و  $\sigma$  دارد (۲۵).

در مطالعه‌ی حاضر شاخص پراکندگی با استفاده از

می‌تواند شاخص‌های کلاس‌بند عصبی- فازی را بهینه کند. روش SCG برای تنظیم اندازه‌ی گام به جای استفاده از جستجوی خط (Line search step)، از روش محدوده‌ی اطمینان (Trust region step) استفاده می‌کند. روش جستجوی خط برای تشخیص اندازه‌ی گام به شاخص‌های بیشتری نیاز دارد که باعث می‌شود در هر روش یادگیری، زمان بیشتری صرف آموزش گردد. در روش محدوده‌ی اطمینان، فاصله‌ای که در آن عملکرد مدل قابل قبول باشد، در هر مرحله (گام) به روز می‌شود. روش‌های محدوده‌ی اطمینان نسبت به روش‌های جستجوی خط بسیار مقاوم‌تر (Robust) هستند. نقطه ضعف روش جستجوی خط در روش SCG، با استفاده از تکنیک محدوده‌ی اطمینان حذف شده است (۲۹). بر اساس مطالعه‌ی Møller (۳۰)، روش SCG دارای هم‌گرایی خطی بسیار بالایی در بسیاری از مسایل می‌باشد.

کلاس‌بند عصبی- فازی انطباقی با استفاده از Adaptive neuro-fuzzy مقادیر زبانی [LHS] (classifier using linguistic hedges در این روش کلاس‌بند عصبی- فازی انطباقی با استفاده از شرایط زبانی مورد استفاده قرار می‌گیرد. شرایط زبانی عباراتی هستند که میزان اهمیت یک مجموعه‌ی فازی (Fuzzy sets) را برای قوانین فازی (Fuzzy rules) مشخص می‌کنند. در واقع به کمک شرایط زبانی می‌توان عبارات زبانی دیگری را به وجود آورد. عباراتی همچون «بسیار زیاد، تا حدودی، نسبتاً و بیشتر یا کمتر» نمونه‌هایی از شرایط زبانی هستند. به طور مثال عبارت زبانی ثانویه‌ی «بسیار جوان =  $A^S$ » با استفاده از LHS می‌تواند از عبارت زبانی اولیه‌ی «جوان = A» به وجود آید. استفاده از

برای شناسایی مرز میان خوش‌ها مواجه است. در مقابل، طبقه‌بندی فازی مرز میان دو کلاس همسایه را به صورت مرز پیوسته‌ای که ممکن است با کلاس‌های مجاور نیز تداخل (Overlap) داشته باشد، در نظر می‌گیرد و هر یک از نمونه‌های موجود را به صورت نسبی (Partial) به عضویت کلاس‌های موجود درمی‌آورد. به طور خلاصه، قوانین فازی اگر- آنگاه (Fuzzy if-then rules) برای توصیف یک الگوریتم طبقه‌بندی مورد استفاده قرار می‌گیرد. سیستم داخلی ANFC سیستمی برای تقریب توابع است، ولی (Adaptive neuro-fuzzy inference system) عملکرد ANFIS برای طبقه‌بندی مطلوب نیست (۲۸). در مطالعه‌ی حاضر یک کلاس‌بند عصبی- فازی دیگر برای طبقه‌بندی مورد استفاده قرار گرفت. در ادامه به توصیف دو الگوریتم که جهت بهینه‌سازی شاخص‌های این کلاس‌بند استفاده شده‌اند، پرداخته می‌شود.

کلاس‌بند عصبی- فازی با استفاده از الگوریتم گرادیان مزدوج مدرج [ Adaptive neuro-fuzzy classifier using scaled conjugate gradient [(SCG) algorithm

روش‌های مبتنی بر شبکه (Network based methods) را می‌توان با استفاده از روش‌های مبتنی بر گرادیان آموزش داد. یکی از کلاس‌بندهای مبتنی بر شبکه، کلاس‌بند عصبی- فازی است که شامل ترکیبی از تکنیک‌های قدرتمند طبقه‌بندی فازی با استفاده از قابلیت‌های شبکه‌های عصبی می‌باشد. الگوریتم گرادیان مزدوج مدرج بر اساس آموزش با نظرات به روش گرادیان مرتبه‌ی دوم (Second-order gradient) عمل می‌نماید و (supervised learning procedure

می‌یابد. این روش، روش پی‌درپی (Sequential) نیز نامیده می‌شود (۳۲).

در مطالعه‌ی حاضر، روند انتخاب ویژگی با مجموعه‌ای خالی از ویژگی‌ها شروع شد و ویژگی‌های جدید تا جایی به ویژگی‌های قبلی اضافه گردید که صحت نتایج طبقه‌بندی با کلاس‌بند مورد نظر دیگر افزایش پیدا نکرد [روش پایین به بالا (Bottom-up) یا رو به جلو (Forward)]. این روش که با برنامه‌ی Matlab نوشته شده، تمام حالت‌های ممکن برای ترکیب‌های ۹۵ ویژگی موجود را بررسی کرده است.

نحوه‌ی اعتبارسنجی (Validation method) در روش‌های کلاس‌بندی: در مطالعه‌ی حاضر نحوه‌ی عملکرد کلاس‌بندهای ذکر شده با استفاده از روش اعتبارسنجی Leave-One-Out مورد بررسی قرار گرفت. در این روش خطای استفاده از  $n-1$  نمونه‌ی گروه آموزش محاسبه و آزمایش کلاس‌بند مورد استفاده بر روی نمونه‌های باقی‌مانده انجام شد. این محاسبات برای تمام زیرمجموعه‌ها با اندازه‌ی  $n-1$  بار تکرار گردید و در نهایت جهت تعیین خوب بودن معیار در نظر گرفته شده برای سنجش اعتبار کلاس‌بند، از مجموعه داده‌های آموزشی با اندازه‌ی  $n-1$  میانگین گرفته می‌شود. بعضی از مزایای استفاده از روش Leave-One-Out، نزدیکی بسیار زیاد عملکرد پیش‌بینی شده توسط این روش با نحوه‌ی عملکرد سیستم واقعی، حداقل استفاده از داده‌ها و کارکرد مناسب در برخورد با مجموعه داده‌ها با اندازه‌ی کوچک می‌باشد (۳۳-۳۴).

معیارهای سنجش عملکرد مورد استفاده برای کلاس‌بندهای دودویی (Binary classifier)، با

این روش، صحت کلاس‌بندی را به ویژه در مواردی که کلاس‌ها با هم همپوشانی دارند، افزایش می‌دهد. علاوه بر استفاده از شرایط زبانی برای کلاس‌بندی، می‌توان از این عبارات جهت انتخاب ویژگی‌های مرتبط نیز بهره برد (۳۱). در این روش میزان تأثیر ویژگی‌هایی که باعث همپوشانی میان کلاس‌ها می‌شوند، کاهش می‌یابد و به جای آن تأثیر ویژگی‌های دیگر بارزتر می‌شود. اگر شرط زبانی  $P = 1$  برای یک ویژگی، نشان دهنده‌ی اهمیت بالای آن ویژگی و شرط زبانی  $P = 0$ ، به معنای حذف آن ویژگی خواهد بود. شرایطی از این قبیل می‌توانند کارایی طبقه‌بندی به کمک این کلاس‌بند را افزایش دهند.

نحوه‌ی انتخاب ویژگی (Feature selection) یا (FS) در روش‌های مختلف کلاس‌بندی هدف از انتخاب ویژگی، پیدا کردن مجموعه‌ای از ویژگی‌های جدید با اندازه‌ی  $d$  از مجموعه‌ای از تعداد  $D$  متغیرهایی است که در ابتدا اندازه‌گیری شده‌اند. انتخاب ویژگی به نحوی انجام می‌شود که در آن  $D < d$  (در صورت امکان  $D > d$ ) باشد تا بتوان معیار انتخاب مورد نظر را به مقدار حداقل (به عنوان مثال صحت) یا حداقل (به عنوان مثال خطای) رساند. انتخاب ویژگی به روش قطعی (Deterministic feature selection) با انتخاب زیرمجموعه‌ای از ویژگی‌ها آغاز می‌شود و با تکرار روند انتخاب، برخی از ویژگی‌ها به ویژگی‌های قبلی اضافه یا برخی از ویژگی‌ها از آن‌ها حذف می‌شود. این روند تا زمانی که صحت نتایج کلاس‌بند مورد نظر به مقدار دلخواه برسد یا دیگر تغییر نکند، ادامه

(Sequential feature selection) جهت کاهش فضای ویژگی‌ها صورت گرفت. انتخاب درست آزمون‌های آماری و الگوریتم‌های داده‌کاوی تا حدود زیادی به مقیاس اندازه‌گیری داده‌ها و نوع متغیرها بستگی دارد. از آنجایی که داده‌های مورد استفاده در مطالعه‌ی حاضر از نوع داده‌های مخلوط (Mixed-type data) بود، فاصله‌ی عمومی (Generalized Minkowski distance) Minkowski برای اندازه‌گیری شباهت‌ها و تفاوت‌ها بین دو نمونه (به خصوص در کلاس‌بند kNN) مورد استفاده قرار گرفت (۳۶). از آنجایی که فاصله‌ی عمومی Minkowski داده‌های ترتیبی را پوشش نمی‌دهد، تبدیل داده‌های ترتیبی به فاصله‌ی امتیازدهی یکنواخت (Monotonic random scoring) یا (MRS) انجام شد. در این روش، اعداد تصادفی با توزیع نرمال و یکنواخت تولید می‌شوند و به جای اعدادی که مقیاس ترتیبی دارند، مورد استفاده قرار می‌گیرند (۳۷). شرح روش‌های ذکر شده به طور خلاصه در ادامه آمده است.

استفاده از موارد مثبت صحیح (True positive) یا (TP)، مثبت کاذب (False positive) یا (FP)، منفی صحیح (True negative) یا (TN) و منفی کاذب (FN) یا (False negative) (۳۵) که در جدول ۱ آمده است. حساسیت (Sensitivity) یا (Se) و ویژگی (Specificity) یا (Sp)، صحت (Accuracy) یا (Acc) و دقت (Precision) یا (Pr) برای کلاس‌بندهای مورد استفاده در مطالعه‌ی حاضر، در بخش یافته‌ها شرح داده شده است.

در مطالعه‌ی حاضر مجموعه‌ای از کلاس‌بندهای فازی و غیر فازی جهت طبقه‌بندی وزن نوزاد به گروه‌های کم وزن (LBW) یا وزن طبیعی (NBW یا Normal Birth Weight) ویژگی‌های ذکر شده مورد استفاده قرار گرفت. کلاس‌بندهای استفاده شده شامل کلاس‌بند نزدیک‌ترین همسایه‌ها (kNN)، شبکه‌ی عصبی احتمالاتی (PNN) و کلاس‌بند عصبی - فازی انتلاقی (ANFC) با استفاده از دو الگوریتم گرادیان مزدوج مدرج (SCG) و شرایط زبانی (LHS) می‌باشد. علاوه بر آن، انتخاب ویژگی‌ها با استفاده از روش پس درپی

جدول ۱. معیارهای سنجش عملکرد مورد استفاده برای کلاس‌بندهای دودویی

معیار	رابطه
صحت	$(TP + TN) / (TP + TN + FP + FN)$
دقت	$(TP) / (TP + FP)$
حساسیت	$(TP) / (TP + FN)$
ویژگی	$(TN) / (TN + FP)$
یادآوری (Recall)	توان (Power) = حساسیت
امتیاز F <sub>1</sub>	$(Pr \times RL) / (Pr + RL \times 2)$
خطای نوع اول ( $\alpha$ )	رابطه‌ی میان داده‌های با برچسب مثبت و برچسب اختصاص داده شده توسط کلاس‌بند
خطای نوع دوم ( $\beta$ )	رد به غلط فرض صفر توسط کلاس‌بند
	قابلیت میان داده‌های با برچسب مثبت و برچسب اختصاص داده شده توسط کلاس‌بند

TP: True positive; TN: True negative; FP: False positive; RL: Recall; Pr: Precision; LBW: Low birth weight; NBW: Normal birth weight

LBW: تعداد نوزادان که به درستی توسط الگوریتم به عنوان LBW تشخیص داده شده‌اند، FP: تعداد نوزادان NBW که به اشتباه توسط الگوریتم به عنوان LBW تشخیص داده شده‌اند، TN: تعداد نوزادان NBW که به درستی توسط الگوریتم به عنوان NBW تشخیص داده شده‌اند، FN: تعداد نوزادان LBW که به اشتباه توسط الگوریتم به عنوان NBW تشخیص داده شده‌اند، مثبت = LBW و منفی = NBW

تغذیه‌ای مادران با توجه به گروه وزنی نوزادان آن‌ها برای بعضی از ویژگی‌های (متغیرهای) ثبت شده (از میان ۹۵ ویژگی موجود) در جدول ۲ ارایه شده است.

### یافته‌ها

میانگین سنی مادران شرکت کننده،  $4 \pm 26$  سال با شیوع حدود ۶ درصدی LBW در میان آنان بود. ویژگی‌های جمعیت‌شناختی و شاخص‌های

جدول ۲. نحوه توزیع مجموعه‌ی داده‌ها در نمونه‌های LBW و NBW

گروه وزنی نوزاد				ویژگی
LBW	NBW			
(۲۰-۳۸) $25 \pm 4$	(۱۶-۳۹) $26 \pm 4$			سن (سال)
خیر (۷۶)	خیر (۸۵)			پارگی زودرس کیسه‌ی آب (درصد)
خیر (۷۶)	خیر (۹۳)			پری‌اکلامپسیا (درصد)
پسر (۶۰)	دختر (۵۲)			جنسیت نوزاد (درصد)
میانگین $\pm$ انحراف معیار حداکثر-حداقل	میانگین $\pm$ انحراف معیار حداکثر-حداقل	دوره‌ی بارداری		ویژگی
۶-۳۶	۱۴ $\pm$ ۸	۰-۵۴	سه ماهه‌ی اول	فعالیت فیزیکی
۵-۴۷	۱۶ $\pm$ ۱۰	۱-۵۶	سه ماهه‌ی دوم	(MET-hours)
۰-۳۴	۱۵ $\pm$ ۱۰	۰-۴۸	سه ماهه‌ی سوم	
۲-۶	۱۰ $\pm$ ۷	۰-۴۵	سه ماهه‌ی اول	اسید لینولئیک
۲-۲۷	۱۲ $\pm$ ۶	۱-۴۳	سه ماهه‌ی دوم	(گرم) (Linoleic acid)
۱-۳۶	۱۲ $\pm$ ۸	۱-۴۰	سه ماهه‌ی سوم	
۶-۴۵	۲۳ $\pm$ ۱۰	۳-۶۱	سه ماهه‌ی اول	اسید اولیک (Olic acid)
۱۰-۶۵	۲۴ $\pm$ ۱۳	۸-۶۸	سه ماهه‌ی دوم	(گرم)
۱-۶۴	۲۴ $\pm$ ۱۱	۸-۶۳	سه ماهه‌ی سوم	
۸-۳۷	۲۰ $\pm$ ۷	۱-۵۶	سه ماهه‌ی اول	ویتامین B <sub>۲</sub> (گرم)
۸-۴۶	۲۴ $\pm$ ۱۰	۴-۵۱	سه ماهه‌ی دوم	
۱۲-۵۷	۲۸ $\pm$ ۱۱	۳-۶۶	سه ماهه‌ی سوم	
۱-۳	۲ $\pm$ ۱	۰-۸	سه ماهه‌ی اول	ویتامین B <sub>۱</sub> (گرم)
۱-۳	۲ $\pm$ ۱	۰-۴	سه ماهه‌ی دوم	
۱-۴	۲ $\pm$ ۱	۰-۴	سه ماهه‌ی سوم	
۲-۱۳	۶ $\pm$ ۳	۱-۳۵	سه ماهه‌ی اول	روی (Zinc) (گرم)
۳-۳۱	۸ $\pm$ ۶	۰-۳۲	سه ماهه‌ی دوم	
۳-۲۶	۱۰ $\pm$ ۶	۱-۴۰	سه ماهه‌ی سوم	
۲۲۰-۱۹۲۴	۷۶۹ $\pm$ ۳۷۰	۸۰-۲۴۰۹	سه ماهه‌ی اول	کلسیم (گرم)
۳۳۰-۱۸۶۶	۸۳۵ $\pm$ ۳۴۸	۱۲۸-۲۸۲۴	سه ماهه‌ی دوم	
۴۰۰-۱۸۶۲	۹۳۵ $\pm$ ۳۴۷	۹۶-۲۴۲۱	سه ماهه‌ی سوم	
۴۲۵-۶۶۷۴	۲۸۷۸ $\pm$ ۱۵۷۱	۱۵۶-۸۶۶۰	سه ماهه‌ی اول	سدیم (گرم)
۱۰۰۲-۷۲۵۴	۳۱۱۴ $\pm$ ۱۵۴۴	۳۴۲-۸۴۱۰	سه ماهه‌ی دوم	
۱۱۵-۷۲۲۹	۳۴۰۰ $\pm$ ۱۷۷۶	۳۰۸-۹۷۳۶	سه ماهه‌ی سوم	

LBW: Low birth weight; NBW: Normal birth weight

MET-hours: معادل متابولیک هر ساعت کار و فعالیت ضرب در مدت زمان فعالیت در روز

جدول ۳. نتایج معیارهای صحت، دقت، حساسیت و ویژگی برای کلاس‌بندهای استفاده شده با انتخاب ویژگی

کلاس‌بند	معیار ویژگی (درصد)	حساست (درصد)	دقت (درصد)	صحت (درصد)
kNN	۹۰/۰۰	۹۶/۶۷	۹۰/۶۳	۹۳/۳۳
PNN	۹۳/۳۳	۷۳/۳۳	۹۱/۶۷	۸۲/۳۳
ANFC (SCG)	۸۰/۰۰	۸۰/۰۰	۸۰/۰۰	۸۰/۰۰
ANFC (LHs)	۱۰۰/۰۰	۶۶/۶۶	۱۰۰/۰۰	۸۳/۳۳

kNN: k-Nearest neighbors; PNN: Probabilistic neural network; ANFC (SCG): Adaptive neuro-fuzzy classifier (scaled conjugate gradient); ANFC (LHs): Adaptive neuro-fuzzy classifier (linguistic hedges)

کلاس‌بند (SCG) ANFC شامل «وضعیت ویتامین B<sub>۳</sub> در سه ماهه‌ی اول، وضعیت اسید اولیک در سه ماهه‌ی دوم و وضعیت کلسیم در سه ماهه‌ی دوم» و (LHs) ویژگی‌های انتخاب شده برای کلاس‌بند ANFC شامل «پارگی زودرس کیسه‌ی آب، وضعیت روی در بدن مادر در سه ماهه‌ی سوم و وضعیت کلسیم در سه ماهه‌ی دوم» بود.

عملکرد کلاس‌بند نزدیک‌ترین همسایه‌ها با استفاده از انتخاب ویژگی نسبت به دیگر کلاس‌بندها بهتر بود. انتخاب ویژگی به طور قابل ملاحظه‌ای صحت طبقه‌بندی را افزایش داد. در تحقیق حاضر، مقادیر فرد تعداد همسایه‌ها (k) از مقدار ۱۵-۳ تغییر داده شد و در نهایت بالاترین صحت طبقه‌بندی با استفاده از روش اعتبارسنجی متقطع برای  $k=3$  مشاهده گردید. بالاترین مقدار صحت کلاس‌بند PNN نیز برای شاخص گسترش برابر با  $1/6$  به دست آمد.

## بحث

بهترین کلاس‌بند مورد استفاده در مطالعه‌ی حاضر، کلاس‌بند kNN با استفاده از انتخاب ویژگی‌ها با توان ۹۶ درصد و خطای نوع اول  $\alpha = 0/1$  بود. با توجه

صحت طبقه‌بندی کودکان دارای وزن کم و وزن طبیعی با استفاده از کلاس‌بندهای نزدیک‌ترین همسایه‌ها (kNN)، شبکه‌های عصبی احتمالاتی (PNN) و عصبی - فازی انطباقی (ANFC) با استفاده از دو الگوریتم گرادیان مزدوج مدرج (SCG) و شرایط زبانی (LHs)، بدون استفاده از انتخاب ویژگی به ترتیب برابر با ۴۸، ۵۰، ۵۰ و ۵۰ درصد به دست آمد. از آنجایی که صحت طبقه‌بندی در این حالت از لحاظ بالینی قابل قبول نبود، انتخاب ویژگی‌ها به روش پی در پی بر روی داده‌ها اعمال گردید. نحوه‌ی عملکرد کلاس‌بندهای انتخاب شده با استفاده از انتخاب ویژگی در جدول ۳ قابل مشاهده است.

ویژگی‌های انتخاب شده برای کلاس‌بند kNN شامل «پارگی زودرس کیسه‌ی آب، وضعیت اسید لینولئیک در بدن مادر، وضعیت روی در بدن مادر در سه ماهه‌ی سوم، وضعیت کلسیم در سه ماهه‌ی دوم و وضعیت سدیم در سه ماهه‌ی اول»؛ ویژگی‌های انتخاب شده برای کلاس‌بند PNN نیز شامل «پری‌اکلامپسیا، فعالیت فیزیکی در سه ماهه‌ی سوم، وضعیت ویتامین B<sub>۳</sub> در سه ماهه‌ی سوم، وضعیت ویتامین B<sub>۱</sub> در سه ماهه‌ی دوم و وضعیت روی در سه ماهه‌ی اول»؛ ویژگی‌های انتخاب شده برای

در پژوهش حاضر علاوه بر کلاس‌بندی‌های بررسی شده، دو کلاس‌بند عصبی- فازی نیز برای طبقه‌بندی داده‌ها مورد استفاده قرار گرفت. نتایج حاصل از این دو کلاس‌بند، قابلیت بالای آن‌ها برای تصمیم‌گیری پزشکی در مطالعه را تضمین می‌کند. چارچوب کلی استفاده شده در سیستم‌های فازی جهت مقابله با عدم وجود مرزهای تصمیم‌گیری دقیق برای مجموعه‌ی عالیم، تشخیص‌ها و بیماری‌ها، به خوبی عمل نموده، آن را به ابزار مفیدی برای ساخت سیستم‌های خبره و متخصص برای تصمیم‌گیری‌های پزشکی تبدیل کرده است.

با توجه به مطالعاتی که در بخش مقدمه نیز به آن‌ها اشاره شد (۱۰-۸)، ویژگی‌های انتخاب شده در چهار کلاس‌بند مورد استفاده در مطالعه‌ی حاضر از جمله پارگی زودرس کیسه‌ی آب، وضعیت اسید لینولئیک، روی، سدیم، ویتامین B<sub>۲</sub>، ویتامین B<sub>۱</sub>، اولیک و کلسیم، وضعیت پری‌اکلامپسیا و میزان LBW فعالیت فیزیکی مادر همگی از لحاظ بالیستی با مرتبط هستند. ویژگی‌های انتخاب شده برای کلاس‌بند عصبی- فازی انطباقی با استفاده از الگوریتم گرادیان مزدوج مدرج، همگی از داده‌های گرفته شده از مادر در سه ماهه‌ی اول و دوم بارداری استخراج شدند. در نتیجه، با استفاده از این کلاس‌بند می‌توان احتمال تولد نوزاد با وزن کم را در دو ماه اول بارداری پیش‌بینی کرد و در صورت نیاز با تنظیم رژیم غذایی مادر و فعالیت فیزیکی او، خطر تولد نوزاد کم وزن را کاهش داد. بدین وسیله می‌توان از LBW و عواقب آن مانند بیماری‌ها و مشکلات روانی در دوران کودکی، بیماری‌های قلبی و عروقی در بزرگسالی، بیماری مزمون کلیه، بیماری فشار خون و

به این موضوع، سیستم تشخیصی پزشکی ارائه شده در مطالعه از لحاظ بالینی قابلیت استفاده را دارد و قابل اعتماد است. با این حال، کاهش خطای نوع اول تا مقدار ۵۰٪ می‌تواند اعتبار این طبقه‌بندی را افزایش دهد. استفاده از روش اعتبارسنجی Leave-One-Out در مطالعه‌ی حاضر باعث مصنونیت در برابر خطای نوع سوم شده است.

صحت بالای کلاس‌بند kNN را می‌توان به دلیل مقاومت این کلاس‌بند نسبت به نوع توزیع و وضعیت فضای نمونه‌ها دانست. حتی اگر کلاس‌های موجود به صورت خطی جداپذیر نباشند، باز هم این کلاس‌بند می‌تواند مرزهای تصمیم‌گیری (Decision boundary) را با استفاده از خطوط متقاطع انتخاب کند. در عین حال، تعداد کم شاخص‌های مورد نیاز برای استفاده‌ی بهینه از این کلاس‌بند باعث سادگی کار با آن می‌شود. علاوه بر آن، اگر نمونه‌ی جدیدی به فضای نمونه‌ها اضافه شود، طبقه‌بندی با این کلاس‌بند به راحتی بهروز می‌شود. به طور کلی این کلاس‌بند در مطالعات همه‌گیرشناختی به خوبی عمل می‌کند.

کلاس‌بند شبکه‌های عصبی احتمالاتی می‌تواند طبقه‌بندی را به صورت دقیقی انجام دهد. مزیت بالای این شبکه‌ها نسبت به دیگر شبکه‌های عصبی، عدم حساسیت آن‌ها نسبت به داده‌های پرت و نوع توزیع متغیرها می‌باشد. این کلاس‌بند آماری نسبت به توزیع مساوی داده‌ها در هر کلاس نیز محدودیتی ندارد. در مطالعه‌ی حاضر با افزایش تعداد نمونه‌های NBW، باز هم صحت و دقت به دست آمده برابر با نتایج به دست آمده از اعمال ۳۰ نمونه‌ی NBW به این شبکه‌ی عصبی بود.

محدودیت‌ها به شمار می‌رود. همچنین روش ارائه شده در مقاله‌ی حاضر به منظور تخمین وزن نهایی نوزاد بود و تغییرات سیر بارداری را در نظر نگرفت. هدف نهایی مطالعه‌ی حاضر، ساخت یک سیستم تشخیصی پزشکی با کمک رایانه و دارای قابلیت پیش‌بینی وزن کم نوزاد در زمان تولد با استفاده از تغذیه‌ی مادر و وضعیت سلامت فیزیکی او در سه ماهه‌ی اول، دوم یا سوم بارداری بود. این سیستم تغذیه‌ی مادر و تواند متخصصین زنان و زایمان و مادران باردار را در تصمیم‌گیری صحیح و تشخیص مناسب نوع تغذیه‌ی مادران یاری دهد. اهمیت دیگر تخمین وزن جنین، پیشگویی موفقیت زایمان طبیعی می‌باشد که بهتر است اواخر بارداری انجام شود. این مورد اهمیت مطالعه‌ی مزبور را نشان می‌دهد.

برای بهبود نتایج به دست آمده، می‌توان با معرفی وزن برای نمونه‌ها در فاصله‌ی Minkowski و تنظیم آن با استفاده از روش‌های بهینه‌سازی تصادفی مانند روش بهینه‌سازی ازدحام ذرات (Particle swarm optimization) یا PSO، قابلیت تعمیم‌پذیری آن‌ها را افزایش داد. اگرچه آزمایش خون به دلیل تهاجمی بودن در زمان بارداری توصیه نمی‌شود (به جز در موقع ضروری) (۴۱)، اما بررسی‌های دقیق اندازه‌گیری شاخص‌های خونی جهت مطالعات آینده پیشنهاد می‌شود.

### تشکر و قدردانی

بدین‌وسیله از معاونت تحقیقات و فناوری دانشگاه علوم پزشکی اصفهان به دلیل حمایت مالی از این پژوهش سپاسگزاری می‌نماییم.

بیماری‌های وابسته به آن جلوگیری به عمل آورد. در مقایسه با تحقیقات مشابه که در آن‌ها LBW با استفاده از اندازه‌گیری‌های حاصل از سونوگرافی تا حدود ۷ روز پیش از تولد پیش‌بینی شده است (۲۰-۲۷)، مطالعه‌ی حاضر نسبت به دیگر مطالعات دارای رویکرد جدید و مزایای بیشتری بود؛ چرا که در مطالعه‌ی حاضر احتمال کم وزن بودن نوزاد در زمان تولد را می‌توان در همان ماه‌های ابتدای بارداری پیش‌بینی کرد. با وجود این که استفاده از اندازه‌گیری‌های حاصل از سونوگرافی صحت نتایج بالایی دارد، اما توجه به این موضوع که نوزاد تا هفت روز پس از اندازه‌گیری به دنیا آمده است، از عیوب این روش به شمار می‌رود.

یکی از محدودیت‌های مطالعه‌ی حاضر، کم بودن تعداد نمونه‌های گرفته شده از مادران با نوزادان LBW (۳۰ نفر) در برابر تعداد کل نمونه‌ها بود. با این وجود، از آن‌جایی که در گذشته نیز مطالعاتی (۳۸-۳۹) مشابه پژوهش حاضر با تعداد نمونه‌های کم LBW انجام شده است، می‌توان از این محدودیت چشم پوشید. به عنوان مثال می‌توان به تحقیقات Nahum و همکاران (۳۸) و Weinberger و همکاران (۳۹) اشاره کرد که در آن‌ها تعداد نمونه‌های LBW به ترتیب برابر با ۴۱ و ۷۴ بود. افزایش تعداد نمونه‌ها در مطالعه‌ی حاضر، قابلیت آن را برای تعمیم نتایج به کل جمعیت افزایش می‌دهد. یکی از مسائل در نظر گرفته شده برای آینده‌ی مطالعه، افزایش تعداد نمونه‌ها خواهد بود. نکته‌ی دیگر این‌که عوامل رژیمیکی در وزن هنگام تولد نوزاد نقش مهمی دارد (۴۰) که در مطالعه‌ی حاضر به دلیل بررسی‌های پر هزینه‌ی رژیمیکی لحاظ نشد و به عنوان یکی دیگر از

## References

1. Kramer MS. Determinants of low birth weight: methodological assessment and meta-analysis. *Bull World Health Organ* 1987; 65(5): 663-737.
2. Singh GK, Kenney MK, Ghandour RM, Kogan MD, Lu MC. Mental Health Outcomes in US Children and Adolescents Born Prematurely or with Low Birthweight. *Depress Res Treat* 2013; 2013: 570743.
3. Pfab T, Slowinski T, Godes M, Halle H, Priem F, Hocher B. Low birth weight, a risk factor for cardiovascular diseases in later life, is already associated with elevated fetal glycosylated hemoglobin at birth. *Circulation* 2006; 114(16): 1687-92.
4. Liew G, Wang JJ, Duncan BB, Klein R, Sharrett AR, Brancati F, et al. Low birthweight is associated with narrower arterioles in adults. *Hypertension* 2008; 51(4): 933-8.
5. White SL, Perkovic V, Cass A, Chang CL, Poulter NR, Spector T, et al. Is low birth weight an antecedent of CKD in later life? A systematic review of observational studies. *Am J Kidney Dis* 2009; 54(2): 248-61.
6. Vikse BE, Irgens LM, Leivestad T, Hallan S, Iversen BM. Low birth weight increases risk for end-stage renal disease. *J Am Soc Nephrol* 2008; 19(1): 151-7.
7. Barker D, Bull A, Osmond C, Simmonds SJ. Fetal and placental size and risk of hypertension in adult life. *BMJ* 1990; 301(6746): 259-62.
8. Rwebembeera AA, Munubhi EK, Manji KP, Mpembeni R, Philip J. Relationship between infant birth weight </=2000 g and maternal zinc levels at Muhimbi National Hospital, Dar Es Salaam, Tanzania. *J Trop Pediatr* 2006; 52(2): 118-25.
9. Agarwal R, Virmani D, Jaipal M, Gupta S, Sankar MJ, Bhatia S, et al. Poor zinc status in early infancy among both low and normal birth weight infants and their mothers in Delhi. *Neonatology* 2013; 103(1): 54-9.
10. Badakhsh M, Khamseh ME, Seifoddin M, Kashanian M, Malek M, Shafiee G, et al. Impact of maternal zinc status on fetal growth in an Iranian pregnant population. *Gynecological Endocrinology* 2011; 27(12): 1074-6.
11. Muthayya S, Kurpad AV, Duggan CP, Bosch RJ, Dwarkanath P, Mhaskar A, et al. Low maternal vitamin B12 status is associated with intrauterine growth retardation in urban South Indians. *Eur J Clin Nutr* 2006; 60(6): 791-801.
12. Khan N, Jamal M. Maternal risk factors associated with low birth weight. *J Coll Physicians Surg Pak* 2003; 13(1): 25-8.
13. Reichman NE, Pagnini DL. Maternal age and birth outcomes: data from New Jersey. *Fam Plann Perspect* 1997; 29(6): 268-72, 295.
14. Bener A, Salameh KM, Yousafzai MT, Saleh NM. Pattern of Maternal Complications and Low Birth Weight: Associated Risk Factors among Highly Endogamous Women. *ISRN Obstet Gynecol* 2012; 2012: 540495.
15. Xiong X, Mayes D, Demianczuk N, Olson DM, Davidge ST, Newburn-Cook C, et al. Impact of pregnancy-induced hypertension on fetal growth. *Am J Obstet Gynecol* 1999; 180(1 Pt 1): 207-13.
16. Hunt DL, Haynes RB, Hanna SE, Smith K. Effects of computer-based clinical decision support systems on physician performance and patient outcomes: a systematic review. *JAMA* 1998; 280(15): 1339-46.
17. Melamed N, Yoge Y, Meizner I, Mashiach R, Bardin R, Ben-Haroush A. Sonographic fetal weight estimation: which model should be used? *J Ultrasound Med* 2009; 28(5): 617-29.
18. Yu J, Wang Y, Chen P. Fetal Weight Estimation Using the Evolutionary Fuzzy Support Vector Regression for Low-Birth-Weight Fetuses. *Browse Journals and Magazines* 2009; 13(1): 57-66.
19. Hadlock FP, Harrist RB, Sharman RS, Deter RL, Park SK. Estimation of fetal weight with the use of head, body, and femur measurements-a prospective study. *Am J Obstet Gynecol* 1985; 151(3): 333-7.
20. Scott F, Beeby P, Abbott J, Edelman D, Boogert A. New formula for estimating fetal weight below 1000 g: comparison with existing formulas. *J Ultrasound Med* 1996; 15(10): 669-72.
21. Goodarzi Khoigani M, Paknahad Z, Mardanian F. The relationship between nutrients intake and preeclampsia in pregnant women. *J Res Med Sci* 2012; 17(Suppl 2): S210-S217.
22. Cover T, Hart P. Nearest neighbor pattern classification. *IEEE Information Theory Society* 1967; 13(1): 21-7.
23. Giri D, Acharya UR, Martis RJ, Sree SV, Lim TC, Ahamed T, et al. Automated diagnosis of Coronary Artery Disease affected patients using LDA, PCA, ICA and Discrete Wavelet Transform. *Knowledge-Based Systems* 2013; 37: 274-82.
24. El Emary IMM, Srinivasan R. On the application of various probabilistic neural networks in solving different pattern classification problems. *World Applied Sciences Journal* 2008; 4(6): 772-80.
25. Georgiou VL, Pavlidis NG, Parsopoulos KE,

- Vrahatis MN. Optimizing the performance of probabilistic neural networks in a bionformatics task [Online]. [cited 2004]; Available from: URL:  
[http://www.math.upatras.gr/~kostasp/papers/GPPAV\\_PNN.pdf](http://www.math.upatras.gr/~kostasp/papers/GPPAV_PNN.pdf)
- 26.** Specht DF. Probabilistic neural networks. *Neural Networks* 1990; 3(1): 109-18.
- 27.** Hajmeer M, Basheer I. A probabilistic neural network approach for modeling and classification of bacterial growth/no-growth data. *J Microbiol Methods* 2002; 51(2): 217-26.
- 28.** Jang J. ANFIS: adaptive-network-based fuzzy inference system. *IEEE Systems, Man, and Cybernetics Society* 1993; 23(3): 665-85.
- 29.** Borkar P, Malik L. Acoustic signal based traffic density state estimation using adaptive Neuro-Fuzzy classifier. *Proceedings of the International Conference on Fuzzy Systems*; 2013 Jul 10; Hyderabad, India. 2013.
- 30.** Møller MF. A scaled conjugate gradient algorithm for fast supervised learning. *Neural Networks* 1993; 6(4): 525-33.
- 31.** Cetisli B. The effect of linguistic hedges on feature selection: Part 2. *Expert Systems with Applications* 2010; 37(8): 6102-8.
- 32.** Jain A, Zongker D. Feature selection: Evaluation, application, and small sample performance. *IEEE Transactions On Pattern Analysis And Machine Intelligence* 1997; 19(2): 153-8.
- 33.** Refaeilzadeh P, Tang L, Liu H. Cross-Validation. In: LIU L, Tamer Özsü M, Editors. Encyclopedia of database systems. New York, NY: Springer; 2009. p. 532-8.
- 34.** Meijer RJ, Goeman JJ. Efficient approximate k-fold and leave-one-out cross-validation for ridge regression. *Biom J* 2013; 55(2): 141-55.
- 35.** Sokolova M, Lapalme G. A systematic analysis of performance measures for classification tasks. *Information Processing & Management* 2009; 45(4): 427-37.
- 36.** Ichino M, Yaguchi H. Generalized Minkowski metrics for mixed feature-type data analysis. *IEEE Transactions on Systems Man and Cybernetics* 1994; 24(4): 697-708.
- 37.** Marateb HR, Mansourian M, Adibi P, Farina D. Manipulating measurement scales in medical statistical analysis and data mining: A review of methodologies. *J Res Med Sci* 2014; 19(1): 47-56.
- 38.** Nahum GG, Pham KQ, McHugh JP. Ultrasonic prediction of term birth weight in Hispanic women. Accuracy in an outpatient clinic. *J Reprod Med* 2003; 48(1): 13-22.
- 39.** Weinberger E, Cyr DR, Hirsch JH, Richardson T, Hanson JA, Mack LA. Estimating fetal weights less than 2000 g: an accurate and simple method. *AJR Am J Roentgenol* 1984; 142(5): 973-7.
- 40.** Yaghootkar H, Freathy RM. Genetic origins of low birth weight. *Curr Opin Clin Nutr Metab Care* 2012; 15(3): 258-64.
- 41.** Cunningham F, Leveno K, Bloom S, Spong CY, Dashe J. *Williams Obstetrics* 24/E. 24<sup>th</sup> ed. New York, NY: McGraw-Hill Education; 2014.

## Prediction of Low Birth Weight in Infants via Artificial Intelligence Techniques without Using Sonographic Measurements

Mahtab Farahbakhsh<sup>1</sup>, Hamid Reza Marateb PhD<sup>2</sup>, Marjan Mansourian PhD<sup>3</sup>,  
Masoomeh Goodarzi-Khoigani MSc<sup>4</sup>

### Original Article

#### Abstract

**Background:** Birth weight is probably the most important factor affecting neonatal mortality and morbidity. Compared with normal weight infants, low-birth-weight (LBW) infants may be more at risk for many health problems. The prediction of low birth weight is important as it may cause mental and physical health problems in childhood and adulthood. We assessed a computer-aided diagnosis system to classify infants to low or normal birth weight categories.

**Methods:** In the present study, the association between the low birth weight and the intake of about 40 types of macro- and micronutrients during the first (1<sup>st</sup> Tr), second (2<sup>nd</sup> Tr.) and third (3<sup>rd</sup> Tr.) trimesters was assessed based on demographic and reproductive characteristics, physical activity and nutrients intake in pregnant women. The dataset used in this study contained 526 pregnant women with 95 input features. The used classifiers were k-Nearest Neighbors (kNN), Probabilistic Neural Network (PNN), and two Adaptive Neuro-Fuzzy Classifiers (ANFC-SCG: Scaled Conjugate Gradient, ANFC-LHs: Linguistic Hedges). Also, sequential feature selection (FS) was applied on the low birth weight risk factors to reduce the feature space.

**Findings:** The accuracy of the classifiers kNN, PNN, ANFC-SCG and ANFC-LHs were 48%, 50%, 50% and 50% without feature selection and 93%, 83%, 80% and 83% with feature selection, respectively.

**Conclusion:** Among the tested classifiers, the statistical power and type I error ( $\alpha$ ) of the best configuration (FS-kNN;  $k = 3$ ) were 96% and 0.10 in the Leave-One-Out validation framework, showing that the proposed diagnosis system is clinically reliable. Also, using Leave-One-Out cross-validation, the guarding against Type III error was granted.

**Keywords:** Computer-aided medical diagnosis, Leave-one-out cross validation, Low birth weight, Sequential feature selection

**Citation:** Farahbakhsh M, Marateb HR, Mansourian M, Goodarzi-Khoigani M. Prediction of Low Birth Weight in Infants via Artificial Intelligence Techniques without Using Sonographic Measurements. J Isfahan Med Sch 2015; 33(321): 14-27

1- Student, Department of Biomedical Engineering, School of Engineering, University of Isfahan, Isfahan, Iran

2- Assistant Professor, Department of Biomedical Engineering, School of Engineering, University of Isfahan, Isfahan, Iran

3- Assistant Professor, Department of Biostatistics and Epidemiology, School of Health, Isfahan University of Medical Sciences, Isfahan, Iran

4- PhD Student, Department of Midwifery, School of Nursing and Midwifery, Isfahan University of Medical Sciences, Isfahan, Iran

**Corresponding Author:** Marjan Mansourian PhD, Email: j\_mansourian@hslth.mui.ac.ir