

## Application of Fuzzy Evidential Network as Low Birth Weight Prognosis Model

A. Janghorbani<sup>1</sup>, M.H. Moradi<sup>2\*</sup>

<sup>1</sup>Ph.D Student, Bioelectric Department, Biomedical Engineering Faculty, Amirkabir University of Technology, Tehran, Iran

<sup>2</sup> Professor, Bioelectric Department, Biomedical Engineering Faculty, Amirkabir University of Technology, Tehran, Iran

Receipt in the online submission system: 6 August 2017, received in revised form: 6 October 2017, accepted: 21 October 2017

---

### Abstract

Babies are born under 2,500 g., defined as low birth weight (LBW) babies. They are exposed to the higher risks of mortality, congenital malformations, mental retardation, and other physical and neurological impairments. 15.5 % of births around the world are LBW. Reduction of the rate of LBW births to one-third is one of the aims of United Nations Children's Fund program. Prognosis of LBW births can play a critical role in the reduction of these cases. Also, it helps clinicians to make timely and efficient clinical decisions to save these babies' life. In this study, a hybrid framework called fuzzy evidential network with a good ability to manage different aspects of uncertainty is selected as the LBW prognosis model. The accuracy of prognosis and the performance of the fuzzy evidential network in the management of missing values of the clinical database were investigated and compared with well-known prognosis models of LBW. The results showed that the fuzzy evidential network has higher prognosis accuracy (84.8%) than other prognosis models. On the other hand, the fusion of naïve Bayes and the fuzzy evidential network outputs resulted in higher prognosis accuracy (85.2%). In addition, the fuzzy evidential network performance in the management of uncertainty induced by imputation method, was better than other prognosis models of this study. The performance loss of this framework as the results of the missing data increment, is less than other models.

**Key words:** *low birth weight, prognosis model, fuzzy evidential network, missing data, imputation, uncertainty*

---

### \*Corresponding author

**Address:** Bioelectric Department, Biomedical Engineering Faculty, Amirkabir university of Technology, P.O.Box: 15875-4413, Tehran, Iran  
**Tel:** +98-21-64542399  
**Fax:** +98-21-64542399  
**E-mail:** [mhmoradi@aut.ac.ir](mailto:mhmoradi@aut.ac.ir)

## به کارگیری شبکه‌های فازی شواهدی به‌عنوان مدل پیش‌آگهی کم‌وزنی نوزاد هنگام تولد

امین جانقربانی<sup>۱</sup>، محمدحسن مرادی<sup>۲\*</sup>

<sup>۱</sup> دانشجوی دکتری مهندسی پزشکی، گروه بیوالکترونیک، دانشکده مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران  
<sup>۲</sup> استاد، گروه بیوالکترونیک، دانشکده مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران

تاریخ ثبت در سامانه: ۱۳۹۶/۵/۱۵، بازنگری: ۱۳۹۶/۷/۱۴، پذیرش قطعی: ۱۳۹۶/۷/۲۹

### چکیده

نوزادان کم‌وزن در هنگام تولد، نوزادانی با وزن کمتر از ۲۵۰۰ گرم در هنگام تولد هستند. این نوزادان بیشتر از سایر نوزادان، در معرض خطرات مرگ‌ومیر، ناهنجاری‌های مادرزادی، عقب‌ماندگی ذهنی و سایر اختلالات فیزیکی و عصبی هستند. حدود ۱۵/۵٪ از موالید در سطح دنیا، نوزادان با وزن کم در هنگام تولد هستند و کاهش این میزان از موالید به یک‌سوم مقدار فعلی، به‌عنوان یکی از اهداف برنامه یونیسف مطرح شده است. با توجه به موارد ذکر شده، پیش‌آگهی تولد این نوزادان، نقش مهمی در پیش‌گیری از وقوع آن دارد. به‌علاوه، زمینه را برای تصمیم‌گیری‌های بالینی به‌موقع و مؤثر برای حفظ سلامت آنان فراهم می‌آورد. در این پژوهش، از شبکه‌های فازی شواهدی، به‌عنوان مدل پیش‌آگهی تولد نوزادان با وزن کم هنگام تولد، استفاده شد. این شبکه‌ها با استفاده از منطق فازی و تئوری شواهد، قابلیت مدیریت وجوه مختلف عدم قطعیت را دارند. نتایج به‌دست‌آمده از به‌کارگیری شبکه‌های فازی شواهدی و سایر مدل‌های پرکاربرد در این زمینه، مانند درخت تصمیم‌گیری، ماشین بردار پشتیبان و مدل بیز ساده و...، روی پایگاه داده مربوط به سه بیمارستان شهر تهران، نشان داد که شبکه فازی شواهدی با صحت ۸۴٫۸٪، عملکرد بهتری از سایر مدل‌ها دارد. در رویکردی دیگر، ترکیب نتایج شبکه فازی شواهدی با مدل بیز ساده، به افزایش صحت پیش‌آگهی به ۸۵٫۲٪ منجر شد. علاوه بر این، توانایی این شبکه‌ها در برخورد با داده‌های گمشده، به‌عنوان یکی از چالش‌های رایج در مجموعه داده‌های پزشکی، بررسی شد. شبکه فازی شواهدی، بهترین عملکرد را در مدیریت عدم قطعیت ناشی از جانمایی داده‌های گمشده در مقایسه با سایر مدل‌ها، از خود نشان داد و عملکرد آن با افزایش متغیرهای گمشده در هر نمونه، با افت کمتری از سایر روش‌ها روبرو شد.

**کلیدواژه‌ها:** وزن کم هنگام تولد، مدل پیش‌آگهی، شبکه‌های فازی شواهدی، داده‌های گمشده، جانمایی، مدیریت عدم قطعیت

\*نویسنده مسئول

نشانی: گروه بیوالکترونیک، دانشکده مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران، کد پستی ۴۴۱۳-۱۵۸۷۵

تلفن: ۶۴۵۴۲۳۹۹ (۲۱) ۹۸+

دورنگار: ۶۴۵۴۲۳۹۹ (۲۱) ۹۸+

پست الکترونیکی: [mhmoradi@aut.ac.ir](mailto:mhmoradi@aut.ac.ir)

## ۱- مقدمه

در روند تشخیص یا پیش‌آگهی پزشکی، پزشک با تمرکز روی علائم بیماری، که نشانه‌های غیرقطعی و غیردقیق از بیماری هستند، و ترکیب شواهد<sup>۳</sup> از منابع اطلاعاتی مختلف پزشکی و تجارب حرفه‌ای خود، اقدام به تشخیص یا پیش‌آگهی بیماری می‌کند. می‌تواند عدم قطعیت موجود در این فرآیند را براساس سه بعد مستقل از عدم قطعیت، توصیف کرد. این ابعاد عبارت‌اند از: عدم قطعیت فازی، عدم قطعیت تصادفی و عدم قطعیت نقصان دانش<sup>۴</sup> [۷].

در پژوهش‌های مختلف، برای مدیریت و بازنمایی عدم قطعیت، از چارچوب‌های متفاوتی براساس تئوری احتمال بیزی، تئوری شواهد<sup>۵</sup> و منطق فازی استفاده شده است [۸]. در بیشتر چارچوب‌های ذکر شده، تنها یک بعد از عدم قطعیت در نظر گرفته شده است؛ به‌عنوان مثال، تئوری بیزین، تنها از دیدگاه عدم قطعیت تصادفی به عدم قطعیت موجود در مسائل مختلف نگاه می‌کند. در این دیدگاه، عدم قطعیت فازی و عدم قطعیت نقصان دانش، براساس تئوری احتمالات و با رویکردی تصادفی، مدیریت می‌شود [۹]. این رویکرد باعث می‌شود که در برخورد با عدم قطعیت، هیچ تفاوتی بین عدم قطعیت معرفتی<sup>۶</sup> و عدم قطعیت تصادفی، وجود نداشته باشد. در مسائل واقعی و کاربردی، به‌طور معمول جنبه‌های مختلف عدم قطعیت به‌صورت هم‌زمان وجود دارند؛ به همین دلیل، چارچوب‌های تلفیقی<sup>۷</sup> متفاوتی برای مدیریت عدم قطعیت پیشنهاد شدند که از آن جمله می‌توان به چارچوب‌های فازی- شواهدی [۱۰-۱۳] و فازی- احتمالاتی [۱۴-۱۶] اشاره کرد.

مدل‌های گرافیکی احتمالاتی، یکی از ابزارهای رایج در مدل‌های پیش‌آگهی پزشکی به‌شمار می‌روند [۱۷-۲۰]. در این مدل‌ها، فرض می‌شود که تمام جنبه‌های عدم قطعیت موجود در مسأله، با رویکرد احتمالاتی قابل‌مدیریت است و در دانش موجود، هیچ‌گونه نقصی، مانند داده‌های گمشده، ابهام یا جهل، وجود ندارد. چنین شرایطی، کمتر در مسائل واقعی وجود دارد [۲۱]. شبکه‌های فازی شواهدی [۲۲]، به‌تازگی به‌عنوان یک چارچوب تلفیقی برای مدیریت هم‌زمان عدم قطعیت معرفتی و تصادفی، معرفی شدند. این شبکه‌ها، به‌عنوان نسخه گسترش‌یافته شبکه‌های شواهدی<sup>۸</sup>، در دسته‌بندی مدل‌های گرافیکی قرار می‌گیرند [۲۳]. جنبه‌های مختلف عدم قطعیت در شبکه‌های

وزن نوزاد هنگام تولد، یکی از شاخص‌های مهم مرگ‌ومیر یا ابتلای نوزاد به بیماری‌های مختلف است [۱]. نارسی نوزادان، اغلب براساس سن بارداری و وزن نوزادان در هنگام تولد تعیین می‌شود. نوزادان نارس و نوزادان با وزن کم هنگام تولد (LBW<sup>۱</sup>)، بیشتر از سایر نوزادان در معرض خطرات مرگ‌ومیر، ناهنجاری‌های مادرزادی، عقب‌ماندگی ذهنی و سایر اختلالات فیزیکی و عصبی هستند [۲].

براساس تعریف سازمان بهداشت جهانی، به نوزاد با وزنی کمتر از ۲۵۰۰ گرم در هنگام تولد، نوزاد LBW گفته می‌شود. براساس آمار این سازمان، حدود ۱۵/۵٪ از تولدها در سطح دنیا، نوزادان LBW هستند و کاهش این میزان از موالید به یک‌سوم مقدار فعلی، به‌عنوان یکی از اهداف دهه کنونی در برنامه یونیسیف مطرح شده است [۳].

در همین راستا، مطالعات فراوانی برای شناسایی عوامل خطر مؤثر بر تولد این نوزادان انجام شده است. در این مطالعات، روش‌های رگرسیون مانند رگرسیون لجستیکی برای بررسی معناداری و تأثیر فاکتورهای خطر متفاوت، به‌کار گرفته شدند [۱، ۴]. در سال‌های اخیر، پژوهش‌ها برای افزایش صحت پیش‌آگهی LBW، به‌سوی استفاده از روش‌های مختلف داده‌کاوی و یادگیری ماشین متمایل شد [۲، ۳، ۵، ۶].

پیش‌آگهی در علم پزشکی مانند دیگر جنبه‌های آن، تحت تأثیر وجوه مختلف عدم قطعیت است. به همین دلیل پیش‌بینی‌های پزشکان درباره روند درمان، وضعیت بیمار در آینده و همچنین ارزیابی خطری که بیمار را تهدید می‌کند، به‌صورت مبهم، غیرشفاف، غیردقیق و همراه با خطا است؛ بنابراین ارائه مدل‌های پیش‌آگهی پزشکی برای بررسی روند درمان بیمار و همچنین ارزیابی خطری که بیمار را تهدید می‌کند، ضروری به‌نظر می‌رسد. این مدل‌ها باید توانایی مدیریت انواع مختلف عدم قطعیت و قابلیت پردازش حجم بزرگی از داده‌ها را داشته باشد. به‌کارگیری روش‌های مختلف داده‌کاوی و یادگیری ماشین در مسائل مختلف تشخیص یا پیش‌آگهی پزشکی<sup>۲</sup>، ناشی از تلاش برای مدیریت این عدم قطعیت و افزایش صحت و دقت پیش‌آگهی پزشکی است.

<sup>۵</sup> Evidence theory<sup>۶</sup> Epistemic uncertainty<sup>۷</sup> Hybrid framework<sup>۸</sup> Evidential network<sup>۱</sup> Low Birth Weight<sup>۲</sup> Medical prognosis<sup>۳</sup> Evidence<sup>۴</sup> Incompleteness

## ۲-۱- مجموعه داده

مجموعه داده استفاده‌شده در این مطالعه، شامل اطلاعات مادران باردار موجود در بایگانی بیمارستان‌های مهدیه، طالقانی و هدایت از مناطق جغرافیایی شمالی و جنوبی شهر تهران در نیمه اول سال است. انتخاب بیمارستان‌ها از نواحی مختلف جغرافیایی، برای پوشش کامل سطوح فرهنگی، اجتماعی و اقتصادی است. این مجموعه داده، شامل اطلاعات ۱۲۵ مادر نوزاد LBW و ۱۲۵ مادر نوزاد با وزن طبیعی است. در پژوهش انجام‌شده روی همین مجموعه داده، عوامل مؤثر بر تولد نوزادان LBW، شناسایی شده و اهمیت آن‌ها، بررسی شد [۲۵]. در این مطالعه، از میان این اطلاعات و عوامل، متغیرهایی انتخاب شدند که در طول شش ماه اول بارداری ثبت شده بودند و ماهیت پیش‌آگهی مدل را حفظ می‌کرد. نام این متغیرها و نوع آن‌ها در جدول ۱ ارائه شده است.

جدول (۱) - متغیرهای مدل پیش‌آگهی و نوع آن‌ها

نام متغیر	نوع متغیر
سن	پیوسته
وزن	پیوسته
قد	پیوسته
افزایش وزن در دوران بارداری	پیوسته
BMI مادر	پیوسته
فاصله زمانی با بارداری‌های قبلی	گسسته
وضعیت روحی مادر	گسسته
وضعیت تغذیه مادر	گسسته
سطح تحصیلات مادر	گسسته
بیماری‌های عفونی مادر	گسسته
فشار خون بالای مادر در بارداری	گسسته
مصرف دخانیات	گسسته
تولد نوزاد LBW (تصمیم‌گیری)	گسسته

## ۲-۲- شبکه‌های فازی شواهدی

شبکه‌های فازی شواهدی، یکی از انواع سیستم‌های اعتبارپایه<sup>۱</sup> هستند. سیستم‌های اعتبارپایه، در واقع یک چارچوب کلی برای مدیریت و بازنمایی عدم قطعیت و استنباط در فضای غیرقطعی هستند. در این سیستم‌ها، بازنمایی دانش با استفاده از ساختار گرافیکی و اعتبارهای تعریف‌شده انجام می‌شود. فرآیند

فازی شواهدی، براساس تئوری مجموعه‌های فازی و تئوری شواهد، مدیریت و بازنمایی می‌شود. همچنین، مدیریت داده‌های از دست رفته، جهل، ابهام و تردید در دانش، با استفاده از تئوری شواهد به‌طور مؤثری اجرا می‌شود.

با توجه به ماهیت و نوع داده‌های موجود برای پیش‌آگهی نوزادان LBW، عدم قطعیت فازی، یکی از جنبه‌های مهم عدم قطعیت در این مسأله به‌شمار می‌رود. داده‌های گمشده یا ثبت‌نشده نیز یکی دیگر از مسائل رایج در مجموعه داده‌های پزشکی واقعی است. این امر اغلب به دلیل تفاوت داده‌های ثبت‌شده در بیماران مختلف، اندازه‌گیری‌های نادرست و خطای انسانی در وارد کردن دستی اطلاعات، رخ می‌دهد [۲۴]. موارد ذکرشده، شبکه‌های فازی شواهدی را به‌عنوان یکی از نامزدهای قدرتمند برای به‌کارگیری، در قالب مدل پیش‌آگهی نوزادان LBW، مطرح می‌کند.

در این پژوهش، از شبکه‌های فازی شواهدی به‌عنوان مدل پیش‌آگهی تولد نوزادان LBW، استفاده شد و انواع مختلف عدم قطعیت در این مسأله، با تئوری متناسب با آن، بازنمایی و مدیریت شد.

در ادامه، در بخش مواد و روش‌ها، ابتدا مجموعه داده استفاده‌شده در این مطالعه، معرفی خواهد شد. پس از آن، اصول کلی شبکه‌های فازی شواهد، معرفی شده و روش تخمین پارامترهای شبکه، روش به‌کارگیری آن به‌عنوان مدل پیش‌آگهی تولد نوزادان LBW و مدیریت داده‌های گمشده، تشریح خواهند شد. در بخش یافته‌ها و بحث، نتایج حاصل از اعمال مدل پیش‌آگهی ذکرشده برای مجموعه داده این مطالعه، ارائه خواهد شد و نتایج آن با سایر مدل‌های پیش‌آگهی اعمال شده در سایر مطالعات، مقایسه خواهد شد. در نهایت، در بخش نتیجه‌گیری، با مروری بر پژوهش انجام‌شده در این مقاله، پیشنهاداتی برای ادامه مطالعات و پژوهش‌های آینده ارائه خواهد شد.

## ۲- مواد و روش‌ها

در این بخش، ابتدا مجموعه داده این مطالعه، معرفی شده و سپس اصول کلی شبکه‌های فازی شواهدی، الگوریتم تخمین پارامترهای شبکه و ساختار استفاده‌شده به‌عنوان مدل پیش‌آگهی نوزادان LBW، تشریح شده‌است. در نهایت، روش مدیریت داده‌های گمشده در چارچوب شبکه‌های فازی شواهدی، توضیح داده شده‌است.

<sup>۱</sup> Valuation based system

را با چارچوب تشخیصی  $\theta_{v_i} = \{s_{i1}, s_{i2}, \dots, s_{in}\}$  در نظر بگیریم، دانش موجود دربارهٔ حالت این متغیر، براساس شواهد موجود و با اختصاص باور پایه بیان می‌شود. اختصاص باور پایه، روی مجموعه توانی  $2^{\theta_{v_i}}$ ، که در واقع مجموعه تمام زیرمجموعه‌های ممکن برای  $\theta_{v_i}$  است، به صورت نگاشت بیان شده است و در رابطه ۲ تعریف می‌شود.

$$m : 2^{\theta_{v_i}} \rightarrow [0, 1] \quad (2)$$

بر این اساس، باور پایه می‌تواند به هر زیرمجموعه غیرتهی از مجموعه توانی اختصاص یابد. به زیرمجموعه‌ای از مجموعه توانی، که مقدار باور پایه آن مخالف صفر است، مجموعه کانونی<sup>۸</sup> گویند.

باور پایه می‌تواند به زیرمجموعه‌های غیرتکین از متغیرها اختصاص یابد. برای مثال، اگر مجموعه  $D = \{v_1, v_2\}$  را به عنوان دامنهٔ یک اعتبار در نظر بگیریم، که هر کدام از متغیرهای  $v_1$  و  $v_2$  به ترتیب دارای چارچوب تشخیصی  $\theta_{v_1} = \{S_{11}, S_{12}\}$  و  $\theta_{v_2} = \{S_{21}, S_{22}\}$  هستند، تابع باور تعریف شده روی چارچوب تشخیصی هم‌زمان این دو متغیر، به صورت رابطه ۳ تعریف می‌شود.

$$\begin{aligned} m^{\theta_D} : 2^{\theta_D} &\rightarrow [0, 1] \\ \theta_D &= \theta_{v_1} \times \theta_{v_2} \\ \sum_{H \in \theta_D} m(H) &= 1 \end{aligned} \quad (3)$$

در این چارچوب، جهل کلی دربارهٔ حالت متغیرهای  $D$  به صورت رابطه (۴) بیان می‌شود.

$$\begin{aligned} m(H) &= 1 \\ H &= \theta_D \end{aligned} \quad (4)$$

**(ج) عملگر ترکیب:** ترکیب، یک عملگر دوتایی روی اعتبارها است، که جوش اطلاعاتی و تجمیع دانش موجود از منابع اطلاعاتی مختلف را بر عهده دارد [۲۷]. در شبکه‌های فازی شواهدی، قانون ترکیب دمپستر - شافر، که در رابطه ۵ ارائه شده است، به عنوان عملگر ترکیب انتخاب شده است.

$$m^{\theta_D}(H) = \frac{\sum_{H_1 \cap H_2 = H} m_1^{\theta_{D_1}}(H_1) m_2^{\theta_{D_2}}(H_2)}{1 - \sum_{H_1 \cap H_2 = \emptyset} m_1^{\theta_{D_1}}(H_1) m_2^{\theta_{D_2}}(H_2)} \quad (5)$$

استنباط، براساس دو عملگر ترکیب<sup>۱</sup> و حاشیه‌سازی<sup>۲</sup> انجام می‌شود. در شبکه‌های فازی شواهدی، اعتبارها و عملگرهای ترکیب و حاشیه‌سازی، براساس منطق فازی و تئوری شواهد بیان می‌شود. به‌طور خلاصه، می‌توان شبکه‌های فازی شواهدی را با یک مجموعه پنج‌عضوی  $\{V, \theta_v, \phi, \oplus, \downarrow\}$  بازنمایی کرد [۲۶]. در ادامه، هریک از اعضای این مجموعه را معرفی خواهیم کرد.

### الف) مجموعه متغیرها ( $V$ ) و مجموعه چارچوب‌های

تشخیصی<sup>۳</sup>  $(\theta_v)$ :  $V = \{v_1, v_2, \dots, v_n\}$  بیانگر مجموعه تمام متغیرهای شبکه‌های شواهدی است. برای هر متغیر در این شبکه‌ها، مجموعه‌ای از حالات ممکن تعریف می‌شود، که چارچوب تشخیصی آن نام دارد. در شبکه‌های فازی شواهدی، برخلاف شبکه‌های شواهدی، حالات ممکن برای هر متغیر، می‌توانند متغیرهای زبانی و فازی یا قطعی<sup>۴</sup> باشند؛ درحالی‌که این مجموعه در شبکه‌های شواهدی، این مجموعه تنها شامل حالات قطعی و متقابل منحصربفرد برای هر متغیر است [۲۷].  $\theta_v$ ، مجموعه تمام مجموعه‌های تشخیصی متغیرهای موجود در شبکه‌های فازی شواهدی است. برای مجموعه  $D \subset V$ ، چارچوب تشخیصی هم‌زمان به صورت رابطه ۱ تعریف می‌شود.

$$\begin{aligned} \theta_D &= \times \{\theta_{v_i}\} \\ v_i &\in D \end{aligned} \quad (1)$$

**(ب) مجموعه اعتبارها ( $\phi$ ):** اعتبارها در شبکه‌های فازی شواهدی، بیانگر دانشی هستند که درباره حالات ممکن برای یک زیرمجموعه از متغیرهای شبکه وجود دارد. این اعتبارات در شبکه‌های فازی شواهدی، براساس اختصاص مقادیر باور پایه<sup>۵</sup> به حالات ممکن برای این مجموعه متغیرها، بیان می‌شود. این اعتبارها، به دو دسته تقسیم می‌شوند. دسته اول، اعتبارهای پیشین هستند، که بازنمایانگر دانش موجود در منابع مختلف اطلاعاتی درباره ارتباط بین حالات مختلف یک مجموعه از متغیرها است. دسته دوم، اعتبارهای ورودی است که بیانگر اطلاعات به دست آمده براساس شواهد موجود درباره وضعیت هریک از متغیرها در لحظه استنباط است. اعتبارها در شبکه‌های فازی شواهدی، براساس توابع باور<sup>۶</sup> بیان می‌شوند. اگر متغیر  $v_i$

<sup>۵</sup> Basic Belief Assignment (BBA)

<sup>۶</sup> Belief function

<sup>۷</sup> Power set

<sup>۸</sup> Focal set

<sup>۱</sup> Combination

<sup>۲</sup> Marginalization

<sup>۳</sup> Frame of discernment

<sup>۴</sup> Crisp

موجود در شبکه تغییر کند، نیازی به محاسبه مجدد برای ترکیب و حاشیه‌سازی تمام اعتبارها نیست و محاسبات تنها در گره‌هایی انجام می‌شوند که اعتبار آن‌ها، مرتبط با اعتبارهای تغییر یافته است. اطلاعات بیشتر درباره استنباط در شبکه‌های شواهدی در چارچوب درخت مجاورت دودویی، در [۲۷] ارائه شده است.

#### ۴-۲- تصمیم‌گیری در شبکه‌های فازی شواهدی

پس از فرآیند استنباط در شبکه‌های فازی شواهدی، باور پایه (اعتبار) مجموعه‌های کانونی مربوط به متغیرهای تصمیم‌گیری، مشخص می‌شود. بر اساس این باور پایه، دو معیار باور<sup>۳</sup> و برازایی<sup>۴</sup> تعریف می‌شود.

معیار باور، که در واقع بیانگر تمام اطلاعات و دانش حامی صحت فرضیه مجموعه A و تمام زیرمجموعه‌های آن است، به صورت رابطه ۸ مطرح می‌شود.

$$Bel(A) = \sum_{B \subset A, B \neq \emptyset} m^\theta(B) \quad (8)$$

معیار برازایی، که بیانگر میزان دانشی است که مانع از شک کردن در صحت فرضیه مجموعه A می‌شود، به صورت رابطه ۹ تعریف می‌شود.

$$Pl(A) = \sum_{B \cap A \neq \emptyset} m^\theta(B) \quad (9)$$

بر این اساس، احتمال صحت فرضیه مجموعه A در بازه‌ای با کران‌های برابر با مقادیر بالا وجود دارد [۲۸]؛ به گونه‌ای که  $Prob(A) \in [Bel(A), Pl(A)]$  برای محاسبه مقدار این احتمال، از رابطه ۱۰ استفاده می‌شود [۲۱].

$$BetP(B) = \sum_{B \subset A \in \theta} \frac{1}{|A|} \frac{m^\theta(A)}{1 - m^\theta(\emptyset)} \quad (10)$$

که در آن مقدار  $m^\theta(\emptyset)$ ، جرم باور مربوط به فرضیه‌های خارج از چارچوب تشخیصی یک متغیر است. در مسائلی با چارچوب تشخیصی محدود، این مقدار برابر با صفر در نظر گرفته می‌شود.

#### ۵-۲- تخمین اعتبارها در شبکه‌های فازی شواهدی

همان‌گونه که پیش‌تر ذکر شد، دو دسته اعتبار در شبکه‌های فازی شواهدی وجود دارد. هر دو دسته این اعتبارها می‌تواند

در رابطه بالا،  $m_1^{\theta_b}$  و  $m_2^{\theta_b}$ ، دو باور پایه اختصاص یافته از سوی دو منبع اطلاعاتی مختلف روی دامنه D هستند.  $H_1$ ، H و  $H_2$  نیز زیرمجموعه‌هایی از  $\theta_D$  هستند. اگر  $m_1^{\theta_{D_1}}$  و  $m_2^{\theta_{D_2}}$ ، به ترتیب روی دامنه  $D_1$  و  $D_2$  تعریف شده باشد، برای اعمال عملگر ترکیب روی این دو باور، باید هر دو روی دامنه باور مشترک  $D = D_1 \cup D_2$  گسترش یابند. برای این منظور، از عملیات گسترش پوچ<sup>۱</sup> استفاده می‌شود. این عملیات طبق رابطه ۶ اجرا می‌شود.

$$m_1^{\uparrow D}(H) = \begin{cases} m_1^{\theta_{D_1}}(H_1) & H = H_1 \times \theta_{D_2}, H_1 \subset \theta_{D_1} \\ 0 & \text{Otherwise} \end{cases} \quad (6)$$

د) عملگر حاشیه‌سازی: این عملگر، وظیفه تمرکز بر جنبه‌های خاص از اطلاعات را برعهده دارد و دانش موجود درباره یک مجموعه از متغیرها را به دانش متمرکز بر یک زیرمجموعه از مجموعه ذکر شده، تبدیل می‌کند. در شبکه‌های فازی شواهدی، این عملگر به صورت رابطه ۷ تعریف شده است.

$$m^{\theta_D \downarrow \theta_{D_1}}(A) = \sum_{B \subset \theta_D | (B \downarrow \theta_{D_1}) = A} m^{\theta_D}(B) \quad (7)$$

#### ۳-۲- استنباط در شبکه‌های فازی شواهدی

فرآیند استنباط، به معنای ترکیب تمام اعتبارهای شبکه شواهدی و به دست آوردن اعتبار هم‌زمان مربوط به تمام متغیرها و سپس حاشیه‌سازی آن روی مجموعه متغیرهای موردنظر (متغیرهای تصمیم) است. این فرآیند در بیشتر موارد، از نظر محاسباتی ناممکن می‌شود. در این شرایط، استنباط براساس محاسبات محلی، می‌تواند راه‌حل این مسأله باشد. در این روش، اعتبار هم‌زمان حاشیه‌شده روی مجموعه متغیرهای تصمیم‌گیری، بدون محاسبه صریح اعتبار هم‌زمان کل شبکه، به دست می‌آید. بر این اساس، اعتبار محلی مربوط به متغیرهایی که عضو مجموعه تصمیم‌گیری نیستند، با یکدیگر ترکیب شده و گام به گام روی تک‌تک آن‌ها حاشیه‌سازی می‌شوند. برای بهینه‌سازی محاسبات استنباط، از ساختاری به نام درخت مجاورت دودویی<sup>۲</sup> استفاده می‌شود. این ساختار، براساس ترتیب حذف متغیرهای غیرتصمیم‌گیری تولید می‌شود و نتایج حاصل از فرآیند ترکیب اعتبارات محلی و حاشیه‌سازی روی متغیرهای تصمیم‌گیری، روی گره‌های این درخت ذخیره می‌شوند. با استفاده از این ساختار، در زمان‌هایی که برخی از اعتبارهای

<sup>۳</sup> Belief

<sup>۴</sup> Pluasibility

<sup>۱</sup> Vacuous extension

<sup>۲</sup> Binary Joint Tree (BJT)

در این وضعیت، باور حالات  $S_1$  و  $S_n$ ، به سادگی و براساس درجه عضویت مقدار مشاهده شده به تابع عضویت هریک از این حالات، محاسبه می شود.

$$\begin{aligned} m^{\theta_v} \{s_1\} &= \mu_{s_1}(V) \\ m^{\theta_v} \{s_n\} &= \mu_{s_n}(V) \end{aligned} \quad (13)$$

برای محاسبه باور سایر حالات، بردار عضویت  $\mu'(V) = [\mu_{s_2}(V), \dots, \mu_{s_{n-1}}(V)]$  در نظر گرفته می شود. تابع استفاده شده برای نگاشت این بردار درجه عضویت به بردار باور هریک از حالات فازی، باید به گونه ای باشد که با هر چه کمتر شدن اختلاف درجه عضویت ها به مجموعه های فازی، باور اختصاص یافته به مجموعه کانونی، شامل تمام حالات فازی بردار عضویت  $\mu'(V)$ ، بیشینه شود. تابع  $f(\mu'(V))$  را به صورت زیر در نظر بگیرد.

$$f(\mu'(V)) = \frac{\prod_{i=2}^{n-1} \mu_{s_i}(V)}{\sum_{i=2}^{n-1} \mu_{s_i}(V)} \quad (14)$$

این تابع تحت قید  $\sum_{i=2}^{n-1} \mu_{s_i}(V) < 1$ ، زمانی به مقدار بیشینه خود ( $f_{\max}$ ) می رسد که  $\mu_{s_i}(V) = \frac{\sum_{i=2}^{n-1} \mu_{s_i}(V)}{n-2}$ . بنابراین با استفاده از این تابع، باور هریک از مجموعه های کانونی مربوط به حالات فازی، به صورت ذکر شده در رابطه ۱۵ تعیین می شود.

$$\begin{aligned} m_{\text{total}} &= \sum_{i=2}^{n-1} \mu_{s_i}(V) \\ m^{\theta_v} \{s_2, s_3, \dots, s_{n-1}\} &= m_{\text{total}} \times \left( \frac{\prod_{i=2}^{n-1} \mu_{s_i}(V)}{\sum_{i=2}^{n-1} \mu_{s_i}(V)} \right) \\ m_{\text{Rem}} &= m_{\text{total}} - m^{\theta_v} \{s_2, s_3, \dots, s_{n-1}\} \\ m^{\theta_v} \{s_i\} &= \frac{\mu_{s_i}(V)}{\sum_{i=2}^{n-1} \mu_{s_i}(V)} \times m_{\text{Rem}} \end{aligned} \quad (15)$$

#### ۲-۵-۲- تخمین اعتبارهای پیشین

اعتبارهای پیشین در شبکه های فازی شواهدی، به نوعی بیانگر دانش موجود درباره حالات هم زمان و تعاملات دو متغیر است. برای مثال، اگر دو متغیر  $v_1$  و  $v_2$  را به ترتیب با چارچوب های تشخیصی  $\theta_{v_1} = \{s_{11}, s_{12}\}$  و  $\theta_{v_2} = \{s_{21}, s_{22}\}$  در نظر بگیریم، باور پیشین برای بازنمایی تعاملات بین این دو متغیر، روی دامنه  $D = \{v_1, v_2\}$  و با چارچوب تشخیصی  $\theta_D = \theta_{v_1} \times \theta_{v_2}$  تعریف

توسط شخصی خبره و براساس مشاهدات او از وضعیت متغیرها و دانش و تجربیات وی درباره مسأله مورد بررسی، تعیین شود. در مواردی که این دانش به طور کامل وجود نداشته باشد یا شخص خبره در دسترس نباشد، بهره گیری از روش ها و الگوریتم های مبتنی بر داده، می تواند بسیار مفید و راهگشا باشد. در ادامه این بخش، روش های مبتنی بر داده برای تعیین اعتبارهای شبکه فازی-شواهدی بررسی خواهد شد.

#### ۲-۵-۱- تخمین اعتبارهای ورودی

اگر متغیر پیوسته  $v$  با  $n$  حالت  $s_1, s_2, s_3, \dots, s_n$  فرض شود، می توان برای هریک از این حالات، یک مجموعه فازی تعریف کرد که بیانگر متغیر زبانی مرتبط با حالت متغیر است. این مجموعه های فازی در کنار هم، به صورت مجموعه های فازی کامل و در دامنه تغییرات متغیر تعریف می شوند؛ به گونه ای که برای مقدار مشاهده شده  $V$  از متغیر  $v$ ،  $\sum_{i=1}^n \mu_{s_i}(V) = 1$  باشد. برای مقدار مشاهده شده  $V$ ، یک بردار درجه عضویت در حالات فازی به صورت رابطه ۱۱ تعریف می شود.

$$\mu(V) = [\mu_{s_1}(V), \mu_{s_2}(V), \dots, \mu_{s_n}(V)] \quad (11)$$

در مواردی که درجه عضویت مقدار مشاهده شده به توابع عضویت فازی، اختلاف زیادی با هم داشته باشند، می توان باور تعلق به هر مجموعه فازی را برابر با درجه عضویت مقدار مشاهده شده به هر کدام از مجموعه های فازی در نظر گرفت. در برخی از موارد که درجه عضویت به دو یا چند مجموعه فازی، تفاوت معناداری با یکدیگر ندارند، نمی توان درجه عضویت را به عنوان باور تعلق آن مقدار به حالت فازی متغیر در نظر گرفت. در این حالت، ابهامی درباره تعلق مقدار مشاهده شده به توابع عضویت فازی وجود دارد. در تئوری شواهد، این ابهام با اختصاص باور به مجموعه های کانونی غیرتکین، بازنمایی می شود. برای روشن شدن بیشتر این موضوع، فرض کنیم بردار عضویت مقدار مشاهده شده در رابطه ۱۱، شامل شرایط ذکر شده در رابطه ۱۲ باشد.

$$\begin{aligned} |\mu_{s_i}(V) - \mu_{s_j}(V)| &< \varepsilon \\ & \quad \substack{i, j=2, \dots, n-1 \\ i \neq j} \\ |\mu_{s_1}(V) - \mu_{s_j}(V)| &> \varepsilon \\ & \quad \substack{j=2, \dots, n} \\ |\mu_{s_n}(V) - \mu_{s_j}(V)| &> \varepsilon \\ & \quad \substack{j=1, \dots, n-1} \end{aligned} \quad (12)$$

به این مجموعه‌های کانونی، مطابق با رابطه ۱۸ و مشابه با باورهای ورودی، تعیین می‌شود.

$$m^{\theta_b} \{U_{i=2}^{n-1} FS_i\} = m_{total} \times \left( \frac{\prod_{i=2}^{n-1} fuzzyP_i}{\sum_{i=2}^{n-1} fuzzyP_i} \right) \frac{1}{f_{max}} \quad (18)$$

$$m_{total} = \sum_{i=2}^{n-1} fuzzyP_i$$

$$m_{Rem} = m_{total} - m^{\theta_b} \{U_{i=2}^{n-1} FS_i\}$$

$$m^{\theta_b} \{FS_i\} = m_{Rem} \times \left( \frac{fuzzyP_i}{\sum_{i=2}^{n-1} fuzzyP_i} \right)$$

$$i = 2, 3, \dots, n-1$$

که در آن،  $f_{max}$  بیشینه تابع  $f = \frac{\prod_{i=2}^{n-1} fuzzyP_i}{\sum_{i=2}^{n-1} fuzzyP_i}$  است. این

بیشینه، زمانی رخ می‌دهد که اختلاف بین احتمال‌های فازی هم‌زمان، برابر با صفر باشد؛ به عبارت دیگر،

$$fuzzyP_i = \frac{1}{n-2} \sum_{i=2}^{n-1} fuzzyP_i \text{ باشد.}$$

## ۲-۶- ساختار شبکه‌های فازی شواهدی به‌عنوان

### مدل پیش‌آگهی

ساختار شبکه فازی شواهدی استفاده شده در این مطالعه برای سه متغیر، در شکل ۱ نشان داده شده است. در این ساختار، که یکی از ساختارهای رایج شبکه‌های فازی شواهدی است [۲۶]، هرکدام از متغیرهای موجود در شبکه فازی شواهدی به‌عنوان یک منبع اطلاعاتی در نظر گرفته شده است؛ در نهایت اطلاعات هریک از این منابع، در قالب درخت دودویی و در فرآیند استنباط، با هم ترکیب می‌شوند و باور نهایی برای متغیر تصمیم‌گیری، که همان تولد نوزاد LBW است، به‌دست می‌آید. درخت مجاورت دودویی مربوط به شبکه فازی شواهدی شکل ۱، که براساس دنباله حذف متغیر  $\{V_1, V_2, V_3\}$  به‌دست آمده است، در شکل ۲ نشان داده شده است.

می‌شود. این باور پیشین، دانش موجود درباره هرکدام از زیرمجموعه‌های این چارچوب تشخیصی را بیان می‌کند. در شبکه‌های فازی شواهدی، برای بازنمایی این دانش، از احتمال هم‌زمان فازی  $fuzzyP(v_1, v_2)$  استفاده می‌شود.

یکی از روش‌های تخمین احتمال هم‌زمان فازی براساس مشاهدات، روش تخمین بیشینه احتمال فازی است<sup>۱</sup> است. در این روش، مقدار احتمال هم‌زمان فازی برای دو رخداد فازی  $A$  و  $B$ ، طبق رابطه ۱۶ محاسبه می‌شود.

$$fuzzyP(v_1 = A, v_2 = B) = \frac{\sum_{i=1}^N \mu_A(V_{1i}) \times \mu_B(V_{2i})}{N} \quad (16)$$

که در آن  $V_{1i}$  مقدار مشاهده شده برای متغیر  $v_1$  و  $V_{2i}$  مقدار مشاهده شده برای متغیر  $v_2$  در نمونه  $i$ ام مشاهدات و  $N$  تعداد کل مشاهدات از وضعیت این دو متغیر است. در مواردی که یک یا هر دو متغیر، فازی نباشند، با توجه به مقدار مشاهده شده، مقدار درجه تعلق به حالت موردنظر، صفر یا یک در نظر گرفته می‌شود. در مواردی که اختلاف معناداری بین دو احتمال فازی هم‌زمان وجود نداشته باشد، برای بیان شک موجود در دانش به‌دست آمده درباره حالات هم‌زمان این دو متغیر، باور هم‌زمان به زیرمجموعه‌های غیرتکین از چارچوب تشخیصی این اعتبار اختصاص می‌یابد.

باور  $m_1$  را با دامنه  $D = \{v_1, v_2\}$  در نظر بگیرید. احتمال فازی هم‌زمان مربوط به زیرمجموعه‌های تکین چارچوب تشخیصی ( $FS_i$ )، دارای شرایط ذکر شده در رابطه ۱۷ هستند.

$$\begin{aligned} |fuzzyP(FS_i) - fuzzyP(FS_j)| &< \varepsilon, \quad i, j = 2, \dots, n-1 \\ |fuzzyP(FS_1) - fuzzyP(FS_j)| &> \varepsilon, \quad j = 2, \dots, n \\ |fuzzyP(FS_n) - fuzzyP(FS_j)| &> \varepsilon, \quad j = 1, \dots, n-1 \end{aligned} \quad (17)$$

باور مجموعه‌های کانونی، که احتمال فازی هم‌زمان آن‌ها اختلاف معناداری با سایر مجموعه‌های کانونی دارد، برابر با احتمال فازی هم‌زمان آن مجموعه‌های تک‌عضوی است.

$$\begin{aligned} m^{\theta_b} \{FS_1\} &= fuzzyP(FS_1) \\ m^{\theta_b} \{FS_n\} &= fuzzyP(FS_n) \end{aligned} \quad (18)$$

برای بازنمایی تردید موجود در دانش استخراج شده درباره مجموعه‌های کانونی، که اشتراک آن‌ها تهی نیست، باور مربوط

<sup>۱</sup> Maximum Likelihood Estimation (MLE)



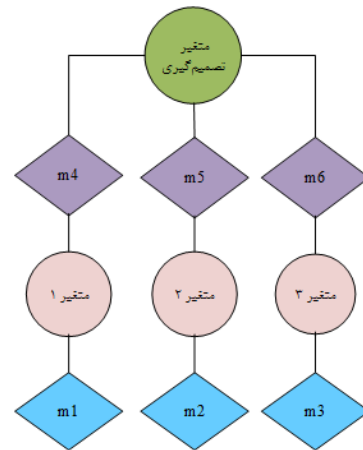
یکی از نقاط قوت تئوری شواهد، توانایی مدل کردن صریح جهل کلی است. در مواردی که اطلاعات بیمار، ناقص باشد یا اطلاعات به درستی ثبت نشده باشند؛ به این معناست که هیچ اطلاعی درباره وضعیت آن متغیر، در دسترس نیست. بر این اساس، باور ورودی مربوط به آن متغیر، با استفاده از جرم باور پوچ معرفی، مقداردهی می‌شود. در این روش، اگر مقدار متغیر  $V_i$ ، مشاهده نشده باشد، آن گاه باور ورودی آن  $\{\theta_{V_i}\} = 1$  در نظر گرفته می‌شود. به این ترتیب، چارچوب پیشنهادی می‌تواند به سادگی داده‌های مربوط به بیماران مختلف با تعداد پارامتر پزشکی متفاوت را، بدون نیاز به جانمایی<sup>۱</sup> و تخمین داده گمشده، به عنوان ورودی گرفته و خروجی مورد نظر را محاسبه کند.

در روش دیگر، داده‌های گمشده براساس سایر داده‌های مجموعه داده و با استفاده از روش‌های مختلف، جانمایی می‌شوند [۳۰]. طبیعی است که استفاده از روش‌های جانمایی، باعث ایجاد بی‌دقتی و وارد شدن نوعی عدم قطعیت در فضای ورودی شود، که به نظر می‌رسد چارچوب ارائه شده، بتواند این بی‌دقتی و عدم قطعیت را بهتر از سایر مدل‌ها مدیریت کند.


### ۳- یافته‌ها و بحث

#### ۳-۱- عملکرد شبکه‌های فازی شواهدی روی مجموعه داده کامل

در این مطالعه برای متغیرهای پیوسته، حالات فازی با استفاده از توابع عضویت فازی بی‌شکل<sup>۲</sup>، که به طور کامل در دامنه متغیر قرار گرفتند، تعریف شدند. برای به کارگیری شبکه‌های فازی شواهدی، به عنوان مدل پیش‌آگهی تولد نوزادان LBW، ابتدا باورهای پیشین و باورهای ورودی این شبکه، براساس الگوریتم‌های ذکر شده در بخش قبل، تعیین شدند. برای تعیین باورهای پیشین، طبق روش ارزیابی تقاطعی LOO<sup>۳</sup>، داده آزمون کنار گذاشته شده و با استفاده از سایر داده‌ها، باورهای پیشین برآورد شدند. سپس براساس داده آزمون، باورهای ورودی تعیین می‌شوند. پس از تخمین این باور، باورها در قالب الگوریتم استنباط و درخت مجاورت دودویی، با یکدیگر ترکیب شده و باور متغیر تصمیم‌گیری، که همان برچسب تولد نوزادان کم‌وزن است، محاسبه می‌شوند. با در نظر گرفتن آستانه ۰/۵، این باور به برچسب هر داده تبدیل می‌شود.



شکل (۱) - شمایی از شبکه فازی شواهدی استفاده شده در این مطالعه برای سه متغیر



شکل (۲) - درخت مجاورت دودویی به دست آمده از شبکه فازی شواهدی شکل ۱، براساس دنباله حذف متغیر  $\{V_1, V_2, V_3\}$

#### ۲-۷- مدیریت داده‌های گمشده در شبکه‌های فازی شواهدی

همان‌طور که در مقدمه ذکر شد، داده‌های گمشده، یکی از موارد رایج در مجموعه داده‌های پزشکی است. وجود داده‌های گمشده در پرونده پزشکی مادران، به دلیل متفاوت بودن مراکز درمانی در طول مدت بارداری یا تفاوت افرادی که اطلاعات مادران باردار را ثبت می‌کنند، امری عادی و رایج است. علی‌رغم وجود نداشتن مقادیر گمشده در مجموعه داده این مطالعه، برای ارزیابی عملکرد این مدل در برخورد با داده‌های گمشده، مجموعه داده‌های مختلفی با حذف تصادفی برخی متغیرهای هر نمونه، تولید شده و برای ارزیابی عملکرد شبکه‌های فازی شواهدی در مدیریت این عدم قطعیت، استفاده شد.

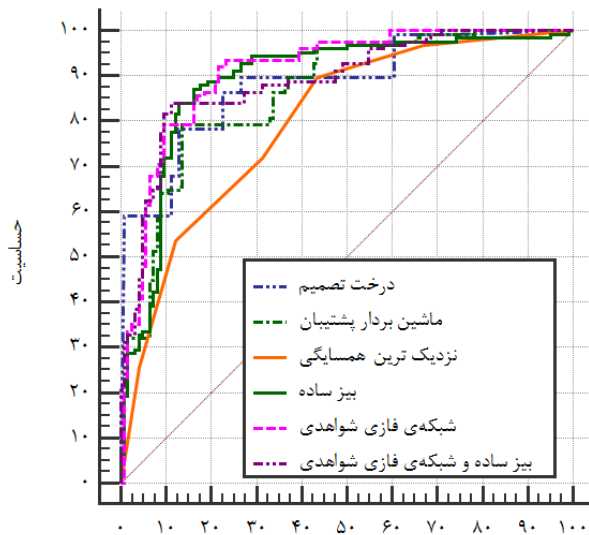
<sup>۳</sup> Leave One Out

<sup>۱</sup> Imputation

<sup>۲</sup> Pi membership function

### ۲-۳- بررسی عملکرد مدل‌های مختلف پیش‌آگهی روی مجموعه داده با داده‌های گمشده

برای ارزیابی عملکرد شبکه‌های فازی شواهدی در برخورد با داده‌های گمشده، تعداد معینی از متغیرهای هر داده‌آزمون، به‌طور تصادفی حذف شدند. در برخورد با این داده، دو روش در نظر گرفته شدند. در روش اول، باور ورودی مربوط به این متغیر، یک باور پوچ در فرض شد، که بیانگر جهل کامل نسبت به وضعیت آن متغیر بود. در روش دوم، داده‌گمشده با استفاده از روش جانپی نزدیک‌ترین همسایگی، جانپی شده و باورهای ورودی براساس مقدار جانپی‌شده، تعیین شد. برای بررسی اثر افزایش تعداد متغیرهای گمشده در هر نمونه، این پارامتر از ۱ تا ۵ افزایش یافت و برای هر کدام از آن‌ها، عملکرد شبکه‌فازی شواهدی، با دو روش ذکرشده بررسی شد.



شکل (۳) - نمودار ROC مربوط به مدل‌های مختلف پیش‌آگهی

در زمانی که تمام متغیرهای مدل پیش‌آگهی مشخص نیستند، سایر مدل‌ها قابلیت ارائه خروجی ندارند؛ از این‌رو برای ارزیابی عملکرد این مدل‌ها، به‌ناچار فقط روش جانپی متغیرهای حذف‌شده، در نظر گرفته شد. با توجه به فرآیند تصادفی حذف متغیرها، این فرآیند به‌ازای هر کدام از مقادیر تعداد متغیر حذف‌شده، ۲۵ تکرار شده و میانگین و واریانس صحت پیش‌آگهی، در جدول ۳ ارائه شده است. همان‌طور که مشاهده می‌شود، شبکه‌فازی شواهدی، بدون نیاز به جانپی داده‌گمشده و در مواردی که تعداد متغیرهای حذف‌شده محدود هستند،

برای ارزیابی عملکرد این روش، از معیارهای صحت، حساسیت، تشخیص<sup>۱</sup> و سطح زیر نمودار (AUC) ROC<sup>۲</sup> استفاده شد. همچنین روش‌های مشهور دیگری از روش‌های یادگیری ماشین برای مقایسه عملکرد شبکه‌های فازی شواهدی، به‌عنوان مدل پیش‌آگهی، استفاده شدند. این روش‌ها، که برخی از آنها در مطالعات پیشین برای پیش‌بینی تولد نوزادان LBW به‌کار گرفته شدند، عبارت‌اند از: درخت تصمیم‌گیری [۳، ۵]، ماشین‌های بردار پشتیبان، مدل بیز ساده [۶، ۵] و k نزدیک‌ترین همسایگی (K=5).

در شکل ۳، نمودار ROC مربوط به مدل‌های مختلف رسم شده است. براساس این نمودار و همچنین برچسب حاصل برای هر داده، معیارهای کمی صحت، حساسیت، تشخیص و سطح زیر نمودار ROC (AUC)، برای مدل‌های مختلف محاسبه شده و در جدول ۲ ارائه شده‌اند.

معیارهای کمی ارائه‌شده در جدول ۲، نشان‌دهنده برتری شبکه‌های فازی شواهدی در پیش‌آگهی تولد نوزادان LBW است. شبکه‌های فازی شواهدی در معیار تشخیص، ضعیف‌تر از مدل بیز ساده عمل کرده است، اما در معیار حساسیت، برتری قابل توجهی نسبت به آن دارد. در مدل‌های پیش‌آگهی و ارزیابی خطر، خطاهای مثبت کاذب، اثرات بد کمتری نسبت به خطاهای منفی کاذب دارند. در واقع، هدف اصلی در این مدل‌ها، شناسایی افراد در معرض خطر برای تصمیم‌گیری به‌موقع و پیش‌گیری از عواقب ناشی از مشکل موردبررسی است. بنابراین، بالا بودن حساسیت مدل فازی شواهدی نسبت به سایر مدل‌ها، می‌تواند نقطه قوت بزرگی برای این مدل به‌شمار آید، که تا حدودی ضعف ناشی از پایین بودن تشخیص آن را جبران می‌کند. برای جبران این نقطه ضعف، رویکرد ترکیب نتایج حاصل از دو مدل ساده بیز با بیش‌ترین تشخیص و شبکه‌فازی شواهدی با بیش‌ترین حساسیت، در نظر گرفته شد. برای این منظور، در مواردی با وجود اختلاف بین برچسب دو مدل ساده بیز و شبکه‌فازی شواهدی، برچسب داده‌آزمون براساس خروجی مدلی انتخاب شد که مطابق با احتمال خروجی آن، برچسبی با قابلیت اطمینان بالاتری ارائه می‌کرد. نتایج حاصل از این روش پ به افزایش صحت طبقه‌بندی و تشخیص منجر شد؛ اما حساسیت و AUC نسبت به شبکه‌فازی شواهدی، کاهش پیدا کرد. نتایج حاصل از این ترکیب، در جدول ۲ ارائه شده است.

<sup>۲</sup> Receiver Operating Characteristic

<sup>۱</sup> Specificity

نمودار تغییرات این نسبت برای مدل‌های مختلف، در شکل ۵ نشان داده شده است. همان‌طور که از نتایج جدول ۳ مشخص است، عملکرد مدل نزدیک‌ترین همسایگی در داده‌های کامل، با دادگان جانمایی شده یکسان است. دلیل این امر را می‌توان ناشی از ماهیت عملکرد این مدل دانست. در واقع این مدل، برچسب نزدیک‌ترین داده را به داده‌آزمون اختصاص می‌دهد. طبیعی است که جانمایی متغیر گمشده با مقدار متناظر آن در نزدیک‌ترین همسایه، به شباهت هرچه بیشتر داده‌آزمون به داده‌های همسایه منجر می‌شود؛ بنابراین نمی‌توان انتظار تغییر زیادی در نتایج مدل نزدیک‌ترین همسایگی بر داده‌های جانمایی شده داشت. همان‌طور که در شکل ۴ مشخص است، با افزایش تعداد متغیرهای گمشده در هر نمونه، عملکرد مدل‌های پیش‌آگهی نسبت به عملکرد آن‌ها روی داده‌کامل، افت می‌کند. این افت عملکرد، به دلیل عدم قطعیتی است که در طول فرآیند جانمایی ایجاد شده است. نتایج به دست آمده، نشان می‌دهند که میزان افت عملکرد در شبکه‌فازی شواهدی، کمتر از سایر مدل‌ها است و این شبکه، توانسته توانمندی خود را با وجود افزایش تعداد متغیرهای گمشده، تا حد خوبی حفظ کند. عملکرد مدل ساده‌بیزی، که می‌توان آن را به‌عنوان نسخه‌احتمالاتی شبکه‌های فازی شواهدی مطرح کرد، با افزایش تعداد متغیرهای گمشده، افت شدیدی یافته است. با مقایسه این دو عملکرد در این دو مدل، می‌توان نتیجه گرفت مدیریت عدم قطعیت ناشی از جانمایی اطلاعات در چارچوب فازی شواهدی، به‌طور مؤثرتری نسبت به چارچوب احتمالاتی مطلق، انجام شده است. نتایج نشان می‌دهند، علاوه بر برتری مطلق صحت پیش‌آگهی در شبکه‌فازی شواهدی روی مجموعه داده با متغیرهای گمشده، این شبکه‌ها توانسته‌اند با افزایش تعداد متغیرهای گمشده، کارایی خود را در مقایسه با مدل بیزی ساده حفظ کنند. عملکرد شبکه‌های فازی شواهدی روی داده‌های با ۵ متغیر گمشده، به ۹۴٪ عملکرد اولیه خود می‌رسد؛ درحالی‌که این مقدار برای مدل بیزی ساده، ۸۸٪ عملکرد اولیه آن است. ماشین‌های بردار پشتیبان، به‌عنوان یکی از ابزارهای قدرتمند یادگیری ماشین و طبقه‌بندی، بعد از شبکه‌های فازی شواهدی، بهترین عملکرد را در حفظ کارایی خود در برابر افزایش تعداد متغیرهای گمشده دارد. درخت تصمیم، به‌ازای از دست دادن یک متغیر، بیشترین افت ناگهانی دقت را در میان سایر مدل‌ها تجربه می‌کند؛ درحالی‌که سایر مدل‌ها، افت تدریجی عملکرد را با افزایش داده‌های گمشده دارند.

عملکردی بهتر از مدل نزدیک‌ترین همسایگی و درخت تصمیم دارد. همچنین در تعداد داده‌گمشده محدود، عملکرد این مدل تقریباً قابل‌رقابت با ماشین بردار پشتیبان و مدل بیز ساده است؛ درحالی‌که بار محاسباتی سنگین جانمایی داده‌های گمشده با استفاده از روش نزدیک‌ترین همسایگی [۳۰]، در این روش به‌طور کامل حذف شده است. از سوی دیگر، شبکه‌فازی شواهدی، چارچوبی در اختیار ما قرار داده است که می‌تواند تعداد متفاوت متغیر را به‌عنوان ورودی، گرفته و فرآیند پیش‌آگهی را انجام دهد؛ درحالی‌که این موضوع برای سایر مدل‌ها، امکان‌پذیر نیست.

جدول (۲) - معیارهای کمی حاصل از مدل‌های مختلف پیش‌آگهی تولد نوزادان LBW

مدل	صحت (%)	تشخص (%)	حساسیت (%)	AUC
ماشین بردار پشتیبان	۸۲٫۴	۸۵٫۶	۷۹٫۲	۰٫۸۶
بیز ساده	۸۲٫۸	۸۷٫۲	۷۸٫۴	۰٫۸۸
نزدیک‌ترین همسایگی	۷۰٫۴	۶۸٫۸	۷۲	۰٫۸۰
درخت تصمیم	۸۲٫۴	۸۶٫۴	۷۸٫۴	۰٫۸۸
شبکه‌فازی شواهدی	۸۴٫۸	۷۷٫۶	۹۲	۰٫۹۰
ترکیب بیز ساده و شبکه‌فازی شواهدی	۸۵٫۲	۸۹٫۶	۸۰٫۸	۰٫۸۹

با افزایش تعداد متغیرهای گمشده و مدل کردن باور ورودی این متغیرها با باور پوچ، طبیعی است که منابع اطلاعاتی، محدود می‌شوند و فرآیند استنباط تنها براساس باورهای پیشین انجام می‌شود؛ بنابراین با افزایش تعداد داده‌های گمشده و محدود شدن اطلاعات، جانمایی داده‌های گمشده، امری ضروری به‌نظر می‌رسد. با اجرای فرآیند جانمایی اطلاعات گمشده براساس نزدیک‌ترین همسایگی، باورهای ورودی براساس این داده‌های جانمایی شده، تعیین شده و فرآیند استنباط انجام شد. نتایج به‌دست آمده نشان‌دهنده برتری شبکه‌فازی شواهدی در مدیریت عدم قطعیت ناشی از جانمایی داده‌گمشده، نسبت به سایر مدل‌ها است.

برای بررسی عمیق‌تر اثر عدم قطعیت ناشی از جانمایی متغیرهای از دست‌رفته بر عملکرد مدل‌ها، نسبت صحت پیش‌آگهی مدل روی داده‌های جانمایی شده به صحت پیش‌آگهی مدل روی داده‌های کامل، برای مدل‌های پیش‌آگهی مختلف بررسی شد.

جدول (۳) - صحت پیش‌آگهی مدل‌های مختلف روی مجموعه داده با داده‌های گمشده


روش حذف شده تعداد متغیر	شبکه فازی شواهدی با باور پوچ	شبکه فازی شواهدی با جانهی	ماشین بردار پشتیبان با جانهی	مدل ساده بیزی با جانهی	نزدیک‌ترین همسایگی با جانهی	درخت تصمیم با جانهی
	۱	۸۲.۸۳ ± ۱.۲	۸۴.۴۱ ± ۰.۰۵	۸۱.۷۴ ± ۰.۰۸	۸۲.۱۴ ± ۰.۱	۷۰.۸۸ ± ۱.۲
۲	۷۹.۱۲ ± ۱.۳	۸۳.۷۴ ± ۱.۰۰	۸۰.۵۴ ± ۱.۲	۸۰.۸۶ ± ۱.۳	۷۰.۵۹ ± ۱.۴	۳۶.۷۸ ± ۰.۱
۳	۷۶.۶۸ ± ۲.۵	۸۲.۸۱ ± ۱.۲	۷۹.۷۱ ± ۱.۵	۷۹.۵۸ ± ۱.۴	۷۱.۸۴ ± ۱.۲	۲۰.۷۸ ± ۰.۱
۴	۷۵.۰۴ ± ۱.۵	۸۱.۳۰ ± ۱.۶	۷۸.۲۸ ± ۱.۳	۷۶.۵۲ ± ۱.۸	۷۰.۲۷ ± ۲.۰۰	۴۷.۷۷ ± ۲.۱
۵	۷۲.۷۵ ± ۲.۱۵	۷۹.۸۲ ± ۲.۰	۷۷.۶۹ ± ۱.۶	۷۲.۹۱ ± ۲.۱	۷۰.۰۳ ± ۲.۳	۷۲.۷۶ ± ۷.۱

به‌دست‌آمده از این مطالعه، نشان‌دهنده برتری این ساختار بر سایر مدل‌های معروف یادگیری ماشین بود. ترکیب نتایج دو مدل بیز ساده و شبکه فازی شواهدی، به بهبود نتایج منجر شد؛ به طوری که ترکیب این دو مدل، بیشترین صحت و تشخیص را به همراه داشت؛ اما حساسیت و AUC آن نسبت به مدل شبکه فازی شواهدی، کاهش یافت. در این پژوهش، عملکرد این شبکه‌ها در برخورد با داده‌های گمشده و مدیریت عدم قطعیت ناشی از آن، در مقایسه با سایر مدل‌ها بررسی شد و نتایج به‌دست‌آمده نشان‌دهنده برتری شبکه‌های فازی شواهدی بود. در این بررسی، شبکه‌های فازی شواهدی، کم‌ترین افت کارایی نسبت به کارایی اولیه را در مقایسه با سایر مدل‌ها داشت. افزایش صحت پیش‌آگهی و همچنین تعیین بازه وزن نوزاد، می‌تواند به‌عنوان موضوعاتی برای ادامه پژوهش‌ها مطرح شود. در این راستا، استفاده از ساختارهای پیچیده‌تر برای این شبکه‌ها و ارائه الگوریتم‌هایی برای یادگیری پارامترهای توابع عضویت فازی و استفاده از دانش شخص خبره در ساختار و پارامترهای توابع عضویت، می‌تواند مفید شود.

### ۵- مراجع

[1] Scowitz IKT, Santos IS, Domingues MR, Matijasevich A, Barros AJ. Prognostic factors for low birthweight repetition in successive pregnancies: a cohort study. BMC pregnancy and childbirth. 2013;13:20.

[2] Pourahmad S, Hamdami E, Vaziri F, Bazrafshan K. A Comparison of the Effective Factors of Preterm Birth Versus Low Birth Weight in Southern Iran Using Artificial Neural Network. International Journal of Women's Health and Reproduction Sciences. 2017;5:55-59.



شکل (۴) - نسبت صحت پیش‌آگهی مدل روی داده جانهی شده به صحت پیش‌آگهی مدل روی داده کامل، به‌ازای تعداد پارامترهای حذف‌شده مختلف

دو مدل شبکه فازی شواهدی و ماشین بردار پشتیبان، حتی با از دست دادن ۵ متغیر، افت عملکردی شدید درخت تصمیم را با از دست دادن یک متغیر تجربه نمی‌کنند. بعد از این افت شدید، درخت تصمیم، با افزایش تعداد متغیرها، عملکرد آن افت بیشتری نمی‌کند؛ اما هنوز افت عملکرد آن از دو مدل برتر، بیشتر است.

### ۴- نتیجه‌گیری

در این مطالعه، از شبکه‌های فازی شواهدی، به‌عنوان یک مدل پیش‌آگهی برای تولد نوزادان LBW، استفاده شد. نتایج

- graphical model selection techniques. *Methods of Information in Medicine*. 1999;38:37-42.
- [18] Verduijn M, Rosseel PMJ, Peek N, de Jonge E, de Mol BAJM. Prognostic Bayesian networks: II: An application in the domain of cardiac surgery. *Journal of Biomedical Informatics*. 2007;40:619-630.
- [19] van Gerven MAJ, Taal BG, Lucas PJF. Dynamic Bayesian networks as prognostic models for clinical patient management. *Journal of Biomedical Informatics*. 2008;41:515-529.
- [20] Peelen L, de Keizer NF, Jonge Ed, Bosman R-J, Abu-Hanna A, Peek N. Using hierarchical dynamic Bayesian networks to investigate dynamics of organ failure in patients in the Intensive Care Unit. *Journal of Biomedical Informatics*. 2010;43:273-286.
- [21] Benavoli A, Ristic B, Farina A, Oxenham M, Chisci L. An Application of Evidential Networks to Threat Assessment. *Aerospace and Electronic Systems, IEEE Transactions on*. 2009;45:620-639
- [22] Janghorbani A, Moradi MH. Fuzzy Evidential Network and Its Application as Medical Prognosis and Diagnosis Models. *Journal of Biomedical Informatics*. 2017;72:96-107.
- [23] Laâmari W, Ben Yaghlane B, Simon C. On the Complexity of the Graphical Representation and the Belief Inference in the Dynamic Directed Evidential Networks with Conditional Belief Functions. In: Hüllermeier E, Link S, Fober T, Seeger B, editors. *Scalable Uncertainty Management: Springer Berlin Heidelberg*; 2012. p. 206-218.
- [24] Tsai C-F, Chang F-Y. Combining instance selection for better missing value imputation. *Journal of Systems and Software*. 2016;122:63-71.
- [۲۵] شیما طباطبایی، مرادی محمدحسین. تعیین عوامل خطر پیش بینی کننده کم وزنی هنگام تولد نوزادان متولد تهران در سال ۱۳۸۶. نشریه علمی پژوهشی دانشکده پرستاری و مامایی. ۱۳۸۹;۲۹:۲۰-۳۵
- [26] Aguirre F, Sallak M, Vanderhaegen F, Berdjag D. An evidential network approach to support uncertain multiviewpoint abductive reasoning. *Information Sciences*. 2013;253:110-125.
- [27] Shenoy PP. Binary join trees for computing marginals in the Shenoy-Shafer architecture. *International Journal of Approximate Reasoning*. 1997;17:239-263.
- [28] Simon C, Weber P. Evidential Networks for Reliability Analysis and Performance Evaluation of Systems With Imprecise Knowledge. *Reliability, IEEE Transactions on*. 2009;58:69-87.
- [29] Shahpari A, Seyedin SA. Using Mutual Aggregate Uncertainty Measures in a Threat Assessment Problem Constructed by Dempster&Shafer Network. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*. 2015;45:877-886.
- [30] Liu Z-g, Pan Q, Dezert J, Martin A. Adaptive imputation of missing values for incomplete pattern classification. *Pattern Recognition*. 2016;52:85-95.
- [3] Hange U, Selvaraj R, Galani M, Letsholo K. A Data-Mining Model for Predicting Low Birth Weight with a High AUC. *Computer and Information Science: Springer*; 2018. p. 109-121.
- [4] Whitmore G, Su Y. Modeling low birth weights using threshold regression: results for US birth data. *Lifetime Data Analysis*. 2007;13:161-190.
- [5] Firouzi Jahantigh F, Nazarnejad R, Firouzi Jahantigh M. Investigating the Risk Factors for Low Birth Weight Using Data Mining: A Case Study of Imam Ali Hospital, Zahedan, Iran. *Journal of Mazandaran University of Medical Sciences*. 2016;25:171-188.
- [6] Senthilkumar D, Paulraj S. Prediction of low birth weight infants and its risk factors using data mining techniques. *Proceedings of the 2015 International Conference on Industrial Engineering and Operations Management 2015*. p. 18.194-6
- [7] Blockley D. Analysing uncertainties: Towards comparing Bayesian and interval probabilities'. *Mechanical Systems and Signal Processing*. 2013;37:30-42.
- [8] He Y, Mirzargar M, Kirby RM. Mixed aleatory and epistemic uncertainty quantification using fuzzy set theory. *International Journal of Approximate Reasoning*. 2015;66:1-15.
- [9] Aguirre F, Sallak M, Schön W, Qiu S. On the distinction between aleatory and epistemic uncertainty and its implications on reliability and risk analysis. *European Safety and Reliability Conference, ESREL 2013*.
- [10] Khatibi V, Montazer GA. A fuzzy-evidential hybrid inference engine for coronary heart disease risk assessment. *Expert Systems with Applications*. 2010;37:8536-8542.
- [11] Dutta P. Uncertainty Modeling in Risk Assessment Based on Dempster-Shafer Theory of Evidence with Generalized Fuzzy Focal Elements. *Fuzzy Information and Engineering*. 2015;7:15-30.
- [12] Tang H. A novel fuzzy soft set approach in decision making based on grey relational analysis and Dempster-Shafer theory of evidence. *Applied Soft Computing*. 2015;31:317-325.
- [13] Straszecka E. Combining uncertainty and imprecision in models of medical diagnosis. *Information Sciences*. 2006;176:3026-3059.
- [14] Di Tomaso E, Baldwin JF. An approach to hybrid probabilistic models. *International Journal of Approximate Reasoning*. 2008;47:202-218.
- [15] Liu W-Y, Yue K, Su J-Y, Yao Y. Probabilistic representation and approximate inference of type-2 fuzzy events in Bayesian networks with interval probability parameters. *Expert Systems with Applications*. 2009;36:8076-8083.
- [16] Liao Q, Qiu Z, Zeng J. Fuzzy Bayesian Networks and its application in pressure equipment's security alerts. In: Ding Y, Wang H, Xiong N, Hao K, Wang L, editors. *ICNC: IEEE*; 2011. p. 1507-1511.
- [17] Sakellaropoulos Gc Fau - Nikiforidis GC, Nikiforidis GC. Development of a Bayesian Network for the prognosis of head injuries using