

مدل آمیخته بیزی برای رده‌بندی داده‌های دقیق و نادقيق

ایمانه خدایاری صمع‌آبادی^۱، فرزاد اسکندری^۲

تاریخ دریافت: ۱۳۹۳/۱۲/۱۷

تاریخ پذیرش: ۱۳۹۵/۷/۱۷

چکیده:

رده‌بندی داده‌های دقیق تا کنون با روش‌های مختلف و در ابعاد وسیعی مورد بررسی و تحلیل قرار گرفته است، اما داده‌هایی که برای رده‌بندی مورد استفاده قرار می‌گیرند همیشه مقدار مشخص و دقیقی ندارند. از آنجا که نوع مقیاس داده‌ها متفاوت است، مقدار داده ممکن است در یک بازه قرار گیرد که در این صورت، مسئله رده‌بندی داده‌های نادقيق مطرح می‌شود. در سال‌های اخیر با فرض نرمال بودن توزیع حاکم بر داده‌های نادقيق، برآوردهای مختلفی برای میانگین و واریانس این توزیع ارائه شده است. در این مقاله با فرض این که توزیع حاکم بر داده‌های نادقيق توزیع نرمال دومتغیره باشد، با روش ماکسیمم درست‌نمایی بر روی مقادیر دو سر بازه داده‌های نادقيق، میانگین و واریانس این توزیع را برآورد کرده‌ایم. سپس با استفاده از رده‌بندی ساده بیزی، یک مدل آمیخته بیزی برای رده‌بندی داده‌های دقیق و نادقيق ارائه کرده‌ایم. همچنین دقت و کارایی مدل ارائه شده بررسی شده است.

واژه‌های کلیدی: رده‌بندی داده‌ها، رده‌بندی ساده بیزی، صفت عددی نادقيق، برآورد ماکسیمم درست‌نمایی، دقت.

وجود داشته باشد. به عنوان مثال، برای سوال‌هایی از قبیل «در

هفته چند ساعت تلویزیون تماشا می‌کنید؟» پاسخ دقیقی نداریم؛ ولی اگر جواب را به صورت بازه در نظر بگیریم، پاسخ گویی به این سوال آسان‌تر می‌شود. بنا بر این علاوه بر داده‌هایی که مقدار مشخص و دقیقی دارند، داده‌هایی نیز هستند که متعلق به بازه‌ای از مقادیرند و ما آن‌ها را داده‌های نادقيق می‌نامیم.

برای اولین بار بیلارد و دیدی^[۵] یک مدل رگرسیونی برای رده‌بندی داده‌های نادقيق با استفاده از نقاط مرکزی داده‌های نادقيق ارائه کردند، اما استفاده از این مدل باعث از بین رفتن داده‌های اصلی می‌شود. برای رفع این مشکل، کاروالیو و همکاران^[۶] مدل آن‌ها را با به کار گیری دامنه داده‌های نادقيق توسعه دادند. علاوه بر مدل‌های رگرسیونی، مدل‌های خوش‌بندی نیز مورد توجه قرار گرفتند^[۷، ۸، ۹، ۱۰]. همچنین کین و همکاران^[۱۱] رده‌بندی داده‌های نادقيق را با درخت تصمیم انجام دادند؛ اما مدل آن‌ها فقط یک نوع داده‌های نادقيق را رده‌بندی می‌کند. بنا بر این کین و همکاران^[۱۲] با در نظر

یکی از کاربردهای یادگیری ماشین،^۳ رده‌بندی^۴ است. در هر روش رده‌بندی، از یک الگوریتم یادگیری استفاده می‌شود تا به کمک مجموعه‌ای از نمونه‌های آموزشی، مدلی را برای رده‌بندی داده‌ها به دست آورد. سپس می‌توان از مدل به دست آمده در مراحل بعدی برای پیش‌بینی ردۀ نمونه‌هایی استفاده کرد که در نمونه‌گیری‌های مختلف ایجاد می‌شود. بنا بر این یادگیری آن یک یادگیری با ناظر^۵ است. در یادگیری با ناظر، مجموعه‌ای از نمونه‌های آموزشی وارد مدل رده‌بندی می‌شوند تا تابعی مناسب برای رده‌بندی نمونه‌های جدید ارائه کند. رده‌بندی درخت تصمیم، شبکه عصبی، نزدیک ترین همسایه، ماشین بردار پشتیبان و رده‌بندی ساده بیزی از جمله روش‌های رده‌بندی داده‌ها می‌باشند؛ اما داده‌هایی که برای رده‌بندی مورد استفاده قرار می‌گیرند، همیشه مقدار مشخص و دقیقی ندارند. در واقع نوع مقیاس داده‌ها ممکن است متفاوت بوده؛ در بازه‌ای از مقادیر

۱ مقدمه

^۱ کارشناسی ارشد علوم کامپیوتر موسسه آموزش عالی غیاث الدین جمشید کاشانی

^۲ دانشیار گروه آمار دانشگاه علامه طباطبائی

^۳ machine learning

^۴ classification

^۵ supervised learning

می‌کند [۱۶]:

$$P(C_k | A_1, \dots, A_n) = \frac{P(C_k)P(A_1, \dots, A_n | C_k)}{P(A_1, \dots, A_n)} \quad (1)$$

رده‌بندی ساده بیزی، احتمال شرطی رده‌ها را با فرض این که صفت‌ها از یکدیگر مستقل شرطی‌اند، به دست می‌آورد. بنا بر این رابطه (۱) می‌تواند به صورت زیر جایگزین شود:

$$P(C_k | A_1, \dots, A_n) = \frac{P(C_k) \prod_{i=1}^n P(A_i | C_k)}{P(A_1, \dots, A_n)} \quad (2)$$

از آنجاکه $P(A_1, \dots, A_n)$ برای هر C_k ثابت است، برای به دست آوردن محتمل‌ترین رده، کافی است رده‌ای را انتخاب کنیم که رابطه (۲) را مکسیمم کرده است.

فرض کنید نمونه T_j ، دارای n صفت A_1, \dots, A_n باشد که از بین آن p صفت، صفت عددی دقیق و $n-p$ صفت باقی‌مانده، صفت عددی نادقيق‌اند. احتمال این که نمونه T_j در رده C_k باشد، به صورت زیر به دست می‌آید:

$$\begin{aligned} P(C_k | T_j) &= \arg \max_{C_k \in C} P(C_k) \\ &\times \prod_{i=1}^p P(A_i | C_k) \times \prod_{i=p+1}^n P(A_i | C_k) \end{aligned} \quad (3)$$

برای همه رده‌ها $P(C_k | T_j)$ محاسبه و T_j بر اساس رده‌ای با بیشترین احتمال، رده‌بندی می‌شود.

در این مقاله رده C_k به ازای $k = 1, \dots, p$ معین فرض شده است.

تعريف ۱.۲. A_i صفت عددی دقیق^۷ است هرگاه هر یک از مقادیر عددی A_{ij} دقیق باشد. A_{ij} زامین مقدار از صفت به ازای $i = 1, \dots, m$ و $j = 1, \dots, n$ است.

تعريف ۲.۲. A_i صفت عددی نادقيق^۸ است هرگاه هر یک از مقادیر عددی A_{ij} نامشخص و متعلق به بازه‌ای از مقادیر $[a_{ij}, b_{ij}]$ به ازای $j = 1, \dots, n$ باشد.

تعريف ۳.۲. نمونه، مقادیر صفت‌های A_1, \dots, A_n که در کنار یکدیگرند و اطلاعاتی درباره قرار گرفتن در یک رده را نشان می‌دهند.

گرفتن توزیع نرمال یک متغیره برای داده‌های نادقيق، برآورده برای میانگین و واریانس آن به دست آورده و با استفاده از رده‌بندی ساده بیزی، رده‌بندی بیزی جدیدی را برای انواع داده‌های دقیق و نادقيق ارائه کردند. لوراده‌ماخر و بیلارد [۱۴] برآوردهایی را برای انواع داده‌های نمادین^۹ با روش ماسکسیمم درست‌نمایی ارائه کردند. داده‌های نمادین، توصیف افراد و گروه‌ها را ممکن می‌سازد و شامل داده‌هایی با مقادیر وزن‌دار یا بدون وزن، بازه‌ای، بافت‌نگاشتی، چندمقداری و ... است. آن‌ها با توجه به این که داده‌های نمادین یک ساختار داخلی دارند که در داده‌های کلاسیک وجود ندارد، پارامترهای میانگین و واریانس را برای داده‌های بافت‌نگاشت، بازه‌ای و ... با روش ماسکسیمم درست‌نمایی برآورد کرده‌اند.

در این مقاله توزیع داده‌های نادقيق را توزیع نرمال دو متغیره فرض کرده‌ایم و برآورد میانگین و واریانس مقادیر کران پایین و بالای آن را با روش ماسکسیمم درست‌نمایی به دست آورده‌ایم. سپس با استفاده از رده‌بندی ساده بیزی، یک مدل آمیخته بیزی برای رده‌بندی داده‌های دقیق و نادقيق با همان دقت مدل کین و همکاران [۱۳] ارائه می‌کنیم. این مقاله ۶ بخش دارد. در بخش اول، مقدمه‌ای از رده‌بندی داده‌های نادقيق بیان شده است. در بخش دوم، روش رده‌بندی ساده بیزی را معرفی می‌کنیم. در بخش سوم و چهارم با روش ماسکسیمم درست‌نمایی، برآورد میانگین و واریانس یک صفت عددی دقیق و نادقيق را به دست می‌آوریم. در بخش پنجم، الگوریتم آمیخته بیزی را برای رده‌بندی داده‌های عددی دقیق و نادقيق ارائه می‌کنیم. همچنین نرمال بودن داده‌های آموزشی بررسی می‌شود. در بخش ششم نتایج عددی مدل آمیخته بیزی را به صورت شبیه‌سازی و در ساختار یک مثال عددی مورد بررسی و دقت مدل پیشنهادی نیز مورد ارزیابی قرار خواهد گرفت.

۲ رده‌بندی ساده بیزی

یکی از روش‌های کاربردی یادگیری ماشین، روش رده‌بندی ساده بیزی است. این روش برای رده‌بندی نمونه جدید، با داشتن مقادیر صفت‌های A_1, \dots, A_n که توصیف‌کننده نمونه جدید است، محتمل‌ترین رده (C_k) را به صورت زیر شناسایی

^۶ symbolic data

^۷ certain numerical attribute

^۸ uncertain numerical attribute

در این توزیع، کوواریانس، بردار میانگین μ و ماتریس واریانس-کوواریانس Σ به صورت زیر است:

$$\text{Cov}[a_{ij}, b_{ij}] = \rho_{i12}\sigma_{i1}\sigma_{i2}, \quad \mu = \begin{pmatrix} \mu_{i1} \\ \mu_{i2} \end{pmatrix},$$

$$\Sigma = \begin{pmatrix} \sigma_{i1}^2 & \sigma_{i1}\sigma_{i2}\rho_{i12} \\ \sigma_{i1}\sigma_{i2}\rho_{i12} & \sigma_{i2}^2 \end{pmatrix}.$$

بنا بر این احتمال شرطی صفت عددی نادقيق A_i در رده C_k به صورت زیر به دست می‌آید:

$$P(A_{ik}|C_k) = \frac{1}{2\pi|\Sigma|^{\frac{1}{2}}} \times \exp\left(-\frac{1}{2}(A_{ik} - \mu)^T \Sigma^{-1} (A_{ik} - \mu)\right) \quad (4)$$

که دترمینان ماتریس واریانس-کوواریانس عبارت است از:

$$|\Sigma| = \sigma_{i1}^2 \sigma_{i2}^2 (1 - \rho_{i12}^2).$$

با جایگذاری بردار میانگین، دترمینان و وارون ماتریس واریانس-کوواریانس در رابطه (۴) داریم:

$$P(A_i|C_k) = \frac{1}{2\pi\sigma_{i1}\sigma_{i2}\sqrt{1-\rho_{i12}^2}} \exp\left\{-\frac{1}{2(1-\rho_{i12}^2)} \times \left[\left(\frac{a_{ij}-\mu_{i1}}{\sigma_{i1}}\right)^2 + \left(\frac{b_{ij}-\mu_{i2}}{\sigma_{i2}}\right)^2 - 2\rho_{i12}\left(\frac{a_{ij}-\mu_{i1}}{\sigma_{i1}}\right)\left(\frac{b_{ij}-\mu_{i2}}{\sigma_{i2}}\right) \right] \right\} \quad (5)$$

از رابطه (۵) تابع درستنامایی زیر نتیجه می‌شود:

$$L(\mu, \Sigma; A_i) = \prod_{j=1}^m \left\{ \left(\frac{1}{2\pi\sigma_{i1}\sigma_{i2}\sqrt{1-\rho_{i12}^2}} \right) \exp\left\{-\frac{1}{2(1-\rho_{i12}^2)} \times \left[\left(\frac{a_{ij}-\mu_{i1}}{\sigma_{i1}}\right)^2 + \left(\frac{b_{ij}-\mu_{i2}}{\sigma_{i2}}\right)^2 - 2\rho_{i12}\left(\frac{a_{ij}-\mu_{i1}}{\sigma_{i1}}\right)\left(\frac{b_{ij}-\mu_{i2}}{\sigma_{i2}}\right) \right] \right\} \right\} \quad (6)$$

برآورد مقادیر $\hat{\mu}_{i1k}$ ، $\hat{\mu}_{i2k}$ ، $\hat{\sigma}_{i1k}$ ، $\hat{\sigma}_{i2k}$ و $\hat{\rho}_{i12k}$ که به ازای آن

رابطه (۶) ماکسیمم می‌شود، عبارت است از [۱۴]:

$$\hat{\mu}_{i1k} = \frac{1}{m} \sum_{j=1}^m a_{ij}$$

$$\hat{\mu}_{i2k} = \frac{1}{m} \sum_{j=1}^m b_{ij}$$

$$\hat{\sigma}_{i1k}^2 = \frac{1}{m-1} \sum_{j=1}^m (a_{ij} - \hat{\mu}_{i1k})^2$$

$$\hat{\sigma}_{i2k}^2 = \frac{1}{m-1} \sum_{j=1}^m (b_{ij} - \hat{\mu}_{i2k})^2$$

$$\hat{\rho}_{i12k} = \frac{1}{m\hat{\sigma}_{i1k}\hat{\sigma}_{i2k}} \sum_{j=1}^m (a_{ij} - \hat{\mu}_{i1k})(b_{ij} - \hat{\mu}_{i2k})$$

۳ برآورد ماکسیمم درستنامایی صفت

عددی دقیق

برآورد ماکسیمم درستنامایی روشنی برای برآورد کردن پارامترهای یک مدل آماری است. فرض کنید داده‌ها از توزیع نرمال پیروی می‌کنند و میانگین و واریانس آن مجهول است. با استفاده از ماکسیمم درستنامایی و با داشتن اطلاع مربوط به نمونه‌ای محدود از جمعیت، می‌توان میانگین و واریانس توزیع آن را به دست آورد. این روش، میانگین و واریانس را مجهول در نظر می‌گیرد و مقادیری را به آن‌ها نسبت می‌دهد که با توجه به اطلاع موجود، محتمل‌ترین حالت باشد.

اگر A_i صفت عددی دقیق باشد و از توزیع نرمال تعیت کند، برای رده‌بندی ساده‌بیزی می‌توان از توزیع نرمال زیر استفاده کرد [۱۵]:

$$P(A_i|C_k) = \frac{1}{\sqrt{2\pi\sigma_{ik}^2}} \exp\left\{-\frac{(x - \mu_{ik})^2}{2\sigma_{ik}^2}\right\},$$

که x نشان‌دهنده مقدار صفت A_i از نمونه جدید است. برآورد میانگین و واریانس این توزیع به‌کمک:

$$\hat{\mu}_{ik} = \frac{1}{m} \sum_{j=1}^m a_{ij}$$

$$\hat{\sigma}_{ik}^2 = \frac{1}{m-1} \sum_{j=1}^m (a_{ij} - \hat{\mu}_{ik})^2$$

که در آن m تعداد نمونه‌های رده C_k و a_{ij} مقادیر صفت عددی دقیق A_i به‌ازای $j = 1, \dots, m$ است.

۴ برآورد ماکسیمم درستنامایی صفت

عددی نادقيق

اگر A_i صفت عددی نادقيق باشد و مقادیر کران پایین و بالای آن از توزیع نرمال تعیت کند، با تعریف میانگین $E[a_{ij}] = \mu_{i1}$ و واریانس $var(a_{ij}) = \sigma_{i1}^2$ برای مقادیر کران پایین ($a_{i1}, a_{i2}, \dots, a_{im}$) و میانگین ($b_{i1}, b_{i2}, \dots, b_{im}$) و واریانس $E[b_{ij}] = \mu_{i2}$ برای مقادیر کران بالا ($b_{i1}, b_{i2}, \dots, b_{im}$) $var(b_{ij}) = \sigma_{i2}^2$ برای مقادیر کران بالا ($b_{i1}, b_{i2}, \dots, b_{im}$) می‌توانیم توزیع نرمال دومتغیره برای صفت عددی نادقيق A_i را به صورت زیر در نظر بگیریم:

$$A_i := \begin{pmatrix} a_{ij} \\ b_{ij} \end{pmatrix} \sim N(\mu, \Sigma), \quad j = 1, \dots, m$$

۵ الگوریتم رده‌بندی

- گام اول: فایل داده‌های آموزشی (D_k) را به ازای k انتخاب کنید.

$$k = 1, 2, \dots, p$$

- گام دوم: تعداد نمونه‌های D_k در m قرار داده می‌شود.
- گام سوم: هر صفت A_i از D_k را به ازاء $n = 1, \dots, i = n$ در نظر بگیرید.
- گام چهارم:

◦ اگر A_i صفت عددی دقیق باشد،

۱. مقادیر ستون A_i در a_{ij} قرار داده می‌شود.

.۲

$$\hat{\mu}_{ik} = \frac{1}{m} \sum_{j=1}^m a_{ij}$$

.۳

$$\hat{\sigma}_{ik}^2 = \frac{1}{m-1} \sum_{j=1}^m (a_{ij} - \hat{\mu}_{ik})^2$$

- ۴. احتمال شرطی صفت عددی دقیق A_i با توزیع نرمال حاصل می‌شود:

$$Pc_{ik} = N(\mu_{ik}, \sigma_{ik}).$$

◦ اگر A_i صفت عددی نادقيق باشد،

$$\hat{\mu}_{i1} = \frac{1}{m} \sum_{j=1}^m a_{ij}$$

.۱

$$\hat{\mu}_{i2} = \frac{1}{m} \sum_{j=1}^m b_{ij}$$

.۲

$$\hat{\sigma}_{i1}^2 = \frac{1}{m-1} \sum_{j=1}^m (a_{ij} - \hat{\mu}_{i1})^2$$

.۳

$$\hat{\sigma}_{i2}^2 = \frac{1}{m-1} \sum_{j=1}^m (b_{ij} - \hat{\mu}_{i2})^2$$

.۴

$$\rho_{i12} = \frac{1}{m\hat{\sigma}_{i1}\hat{\sigma}_{i2}} \sum_{j=1}^m (a_{ij} - \hat{\mu}_{i1})(b_{ij} - \hat{\mu}_{i2})$$

.۵

پس از برآورد میانگین و واریانس مقادیر کران پایین و بالای صفت عددی نادقيق به روش ماکسیمم درست‌نمایی و جایگذاری آن در توزیع نرمال دو متغیره، احتمال قرار گرفتن صفت عددی نادقيق A_i در رده C_k به دست می‌آید. در این مقاله برای رده‌بندی انواع داده‌های دقیق و نادقيق، نمونه‌های آموزشی که از توزیع نرمال تبعیت می‌کنند، به الگوریتم رده‌بندی داده می‌شوند و با استفاده از مدل به دست آمده، قرار گرفتن نمونه جدید در رده مناسب پیش‌بینی می‌شود (شکل ۱).



شکل ۱. نحوه رده‌بندی نمونه جدید

اکنون فرض کنید به تعداد $p = 1, 2, \dots, p$ فایل داده‌های آموزشی مفروض است که هر کدام دارای نمونه‌هایی است که در یک رده قرار دارند.

۱.۴ نحوه انتخاب فایل داده‌های آموزشی

- ۱. در ابتدا از توزیع یکنواخت در بازه $(0, 1)$ ، تعداد n مشاهده اختیار می‌کنیم، به طوری که

$$P(D_k) = \frac{n_k}{n_1 + n_2 + \dots + n_p} = \frac{n_k}{n}, \quad k = 1, \dots, p$$

- ۲. اعداد تولید شده را از کوچک به بزرگ مرتب می‌کنیم، به طوری که

$$\frac{n_1}{n} = \hat{n}_1, \quad \frac{n_2}{n} = \hat{n}_2, \dots, \quad \frac{n_p}{n} = \hat{n}_p$$

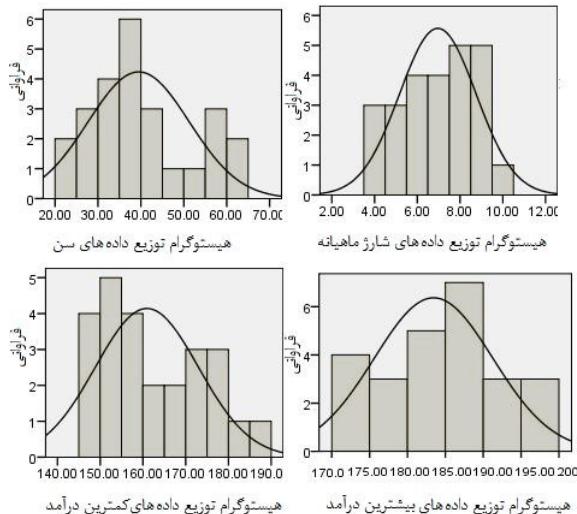
$$\sum_{k=1}^p \hat{n}_k = 1$$

- ۳. انتخاب فایل داده‌های آموزشی بر اساس گروهی است که بیشترین تعداد مشاهده را داشته باشد، یعنی

$$D_k = \max(\hat{n}_1, \dots, \hat{n}_p).$$

هریک از مقادیر نمونه جدید به عنوان ورودی به الگوریتم رده‌بندی داده می‌شود و خروجی آن، قرار گرفتن نمونه جدید در رده مناسب است. نکته مهم این است که فرض نرمال بودن داده‌های آموزشی باید برقرار باشد. لذا در بخش (۱.۵) به بررسی نرمال بودن داده‌ها می‌پردازیم.

چولگی معیاری از تقارن یا عدم تقارن تابع توزیع است. در یک توزیع کاملاً متقاضی، چولگی صفر است. برای یک توزیع نامتقاضی، ضریب چولگی مثبت یا منفی است. هرچه مقدار چولگی از صفر بیشتر فاصله داشته باشد، عدم تقارن، شدیدتر است.



شکل ۲. بافت‌نگاشت فراوانی صفت‌های «رده پرداخت کرده»

کشیدگی نشان‌دهنده ارتفاع یک توزیع است. به عبارت دیگر کشیدگی معیاری از بلندی منحنی در نقطه ماقسیم است. همیشه کشیدگی را با کشیدگی توزیع نرمال مقایسه می‌کنند. مقدار کشیدگی برای توزیع نرمال برابر با ۳ است.

در حالت کلی چنانچه مقدار چولگی و کشیدگی داده‌ها خارج از بازه (۰-۲) باشد، داده‌ها از توزیع نرمال برخوردار نیستند و باید قبل از هر آزمونی که با نتیجه آن با فرض نرمال بودن داده‌ها برقرار است، آن را به توزیع نرمال نزدیک‌تر کرد. وقتی این دو شاخص در حالت نرمال قرار نداشته باشند، می‌توان حدس زد که توزیع داده‌ها نرمال نیست. برای اثبات این ادعا می‌توان از آزمون‌های آماری استفاده کرد. هنگام بررسی نرمال بودن داده‌ها فرض صفر را مبنی بر این که توزیع داده‌ها نرمال است، در نظر می‌گیریم و همانند اکثر آزمون‌ها، آن را در سطح خطای ۵ درصد بررسی می‌کنیم. با توجه به این که نمونه‌های آموزشی این مقاله کمتر از ۲۰۰۰ نمونه است، بررسی نرمال بودن داده‌ها را با آزمون شاپیرو-ویلک^۹ در نرم‌افزار SPSS انجام داده‌ایم [۲، ۳].

$$\theta_{ik}^* = \begin{bmatrix} \mu_{i1} \\ \mu_{i2} \end{bmatrix}$$

$$\Sigma_{ik}^* = \begin{bmatrix} \sigma_{i1}^2 & \sigma_{i1}\sigma_{i2}\rho_{i12} \\ \sigma_{i1}\sigma_{i2}\rho_{i12} & \sigma_{i2}^2 \end{bmatrix}$$

۸. احتمال شرطی صفت عددی نادقيق A_i با توزیع نرمال دو متغیره زیر به دست می‌آید:

$$Pu_{ik} = N(\theta_{ik}^*, \Sigma_{ik}^*)$$

- گام پنجم: $i+1 \leftarrow i$ و تا زمانی که $i \leq n$ باشد به گام سوم بر می‌گردد.

- گام ششم:

$$P(D_k) = \frac{D_k}{\text{تعداد کل نمونه‌ها}}$$

- گام هفتم:

$$Pf_k = P(D_k) \times \prod_{i=1}^n Pu_{ik} \times P_{C_{ik}}$$

- گام هشتم: $k+1 \leftarrow k$ و تا زمانی که $p \leq k$ باشد، به گام اول بر می‌گردد.

- گام نهم: رده‌ای که بیشترین Pf_k را دارد، به عنوان خروجی قرار داده می‌شود.

۱.۵ بررسی نرمال بودن داده‌ها

در اغلب آزمون‌های پارامتری، مفروضات مقدماتی بسیاری وجود دارند که تا این مفروضات برآورده نشوند، نتایج به دست آمده از آزمون، نامعتبر خواهد بود. مهمترین این مفروضات، فرض نرمال بودن داده‌ها است. منظور از نرمال بودن توزیع داده‌ها این است که بافت‌نگاشت فراوانی داده‌ها تقریباً به صورت منحنی نرمال باشد. نمودار بافت‌نگاشت فراوانی نمونه‌های آموزشی رده «پرداخت کرده» (جدول ۳)، در شکل ۲ نشان داده شده است. ضریب چولگی و ضریب کشیدگی دو شاخص اساسی توزیع داده‌ها هستند که با داشتن آنها تا حدی می‌توان به نرمال بودن داده‌ها پی برد.

^۹ Shapiro-Wilk

۶ نتایج عددی

رده‌بندی را با توجه به تعداد رده‌بندی درست و نادرست انجام شده توسط مدل رده‌بندی در مقایسه با نتایج واقعی نشان می‌دهد و عموماً برای الگوریتم‌های یادگیری با ناظر استفاده می‌شود. ماتریس درهم‌ریختگی برای دو رده ($n = 2$) در شکل ۳ نشان داده شده است که شامل ۴ عنصر TP، TN، FP و FN است [۴]: TP، تعداد نمونه‌هایی که رده واقعی آن‌ها «پرداخت کرده» بوده و به درستی در رده «پرداخت کرده» رده‌بندی شده‌اند. TN، تعداد نمونه‌هایی که رده واقعی آن‌ها «پرداخت نکرده» بوده و به درستی در رده «پرداخت نکرده» رده‌بندی شده‌اند. FP، تعداد نمونه‌هایی که رده واقعی آن‌ها «پرداخت نکرده» بوده و به اشتباه در رده «پرداخت کرده» رده‌بندی شده‌اند. FN، تعداد نمونه‌هایی که رده واقعی آن‌ها «پرداخت کرده» بوده و به اشتباه در رده «پرداخت نکرده» رده‌بندی شده‌اند.

جدول ۱. نمونه‌های جدید

نمونه	سن	شارژ ماهانه (دلار)	درآمد ماهانه (دلار)
۵۱	۴۲	۹	[۹۰ و ۶۵]
۵۲	۲۶	۶	[۱۸۰ و ۱۶۰]
۵۳	۳۱	۵	[۹۰ و ۱۰۰]
۵۴	۵۰	۸	[۱۵۵ و ۱۶۵]

حساسیت،^{۱۲} ویژگی^{۱۳} و دقت^{۱۴} از جمله معیارهای عملکرد مسائل رده‌بندی هستند. این معیارها به‌طور خلاصه در ادامه شرح داده شده‌اند [۱].

ماتریس درهم‌ریختگی		رده تشخیص داده شده	
		پرداخت کرده	پرداخت نکرده
رده واقعی	پرداخت کرده	TP	FN
	پرداخت نکرده	FP	TN

شکل ۳. ماتریس درهم‌ریختگی برای دو رده

حساسیت:

حساسیت نشان می‌دهد اگر نتیجه واقعی برای نمونه جدید «پرداخت کرده» باشد، در چند درصد موارد مدل نیز نتیجه

^{۱۰} accuracy rate

^{۱۱} confusion matrix

^{۱۲} sensitivity

^{۱۳} specificity

^{۱۴} accuracy

نحوه یادگیری مدل ارائه شده، بر اساس یادگیری با ناظر است؛ یعنی با استفاده از نمونه‌های آموزشی در ابتدا مدل رده‌بندی آموزش داده می‌شود و سپس بر اساس این آموزش‌ها می‌تواند نمونه جدید را در رده مناسب قرار دهد. در این مقاله نمونه ۵۰ نمونه مختلف از بازپرداخت اقساط افرادی که در دو رده (پرداخت کرده. پرداخت نکرده) قرار دارند، به عنوان نمونه‌های آموزشی برای یادگیری مدل رده‌بندی استفاده شده است که در آن سن و شارژ ماهانه از جمله صفت‌های عددی دقیق و درآمد ماهانه به عنوان صفت عددی نادقيق در نظر گرفته شده است (جدول ۳). نرمال بودن داده‌های مربوط به هر صفت عددی دقیق یا نادقيق که در یک رده قرار دارند، با نرم‌افزار SPSS بررسی و سپس نمونه‌های هر رده در یک دادگان از نرم‌افزار Matlab ذخیره می‌شود. با فراخوانی هر یک از این دادگان‌ها توسط الگوریتم رده‌بندی ارائه شده، نمونه جدید در رده مناسب قرار می‌گیرد. به عنوان مثال، نمونه‌های جدول ۱، نمونه‌های جدیدی هستند که پس از برآورد پارامترهای مربوط به هر یک از صفت‌های عددی دقیق و نادقيق در رده مناسب قرار گرفته‌اند نمونه‌های ۵۲ و ۵۴ در رده افرادی رده‌بندی شده‌اند که اقساط خود را پرداخت کرده‌اند و نمونه‌های ۵۱ و ۵۳ در رده افرادی که اقساط خود را پرداخت نکرده‌اند. برآورد پارامترهای میانگین و واریانس هر یک از صفت‌های عددی دقیق و نادقيق مربوط به رده‌های «پرداخت نکرده» و «پرداخت کرده» به ترتیب در جدول‌های ۴ و ۵ آورده شده است.

۶.۱ ارزیابی مدل آمیخته بیزی

مهترین ارزیابی معیار کارایی یک الگوریتم رده‌بندی، دقت یا نرخ صحبت^{۱۰} رده‌بندی است که نشان می‌دهد مدل طراحی شده چند درصد از کل نمونه‌های آزمایشی را به درستی رده‌بندی کرده است. برای به دست آوردن دقت مدل، در ابتدا باید با مفهوم ماتریس درهم‌ریختگی^{۱۱} آشنا شویم. ماتریس درهم‌ریختگی، یک ماتریس $n \times n$ است که چگونگی عملکرد یک الگوریتم

و تحلیل قرار گرفته است. از میان این روش‌ها، ردهبندی ساده بیزی، یادگیری را به خوبی انجام می‌دهد و نیاز به برآورد تکراری پارامترها ندارد و می‌تواند حجم عظیمی از داده‌ها را ردهبندی کند [۱۷]. بنا بر این در این مقاله برای ردهبندی داده‌های دقیق از ردهبندی ساده بیزی استفاده نموده‌ایم. از آنجا که داده‌ها ممکن است متعلق به بازه‌ای از مقادیر باشند، ردهبندی نادقيق مطرح شده است. برآوردهای مختلفی برای میانگین و واریانس توزیع حاکم بر داده‌های نادقيق با فرض نرمال بودن توزیع آن، بر اساس یادگیری باناظر انجام شده است [۱۲، ۱۳]. در این مقاله فرض کردۀایم توزیع داده‌های نادقيق، توزیع نرمال دومتغیره است. بر روی هر یک از مقادیر دو سر بازه داده‌های نادقيق، برآوردهای میانگین و واریانس را با روش ماکسیمم درستنمایی به دست آورده‌ایم. سپس بر اساس ردهبندی ساده بیزی، یک مدل آمیخته‌ی بیزی برای ردهبندی داده‌های دقیق و نادقيق ارائه کردۀایم که میزان ویژگی، حساسیت و دقت به دست آمده از آن، می‌تواند این روش را در کنار روش‌های ردهبندی داده‌های دقیق و نادقيق، به عنوان الگوریتمی کم‌هزینه و کاربردی قرار دهد.

جدول ۲. دقت، حساسیت، ویژگی در مدل بیزی کین و

همکاران و مدل آمیخته بیزی

همکاران و مدل آمیخته بیزی	مدل کین و همکاران	مدل آمیخته بیزی	
۳۴	۳۴	TP	
۳۴	۳۴	TN	
۱	۱	FP	
۱	۱	FN	
۰.۹۷	۰.۹۷	حساسیت	
۰.۹۷	۰.۹۷	ویژگی	
۰.۹۷	۰.۹۷	دقت	

«پرداخت کرده» خواهد داشت، که از رابطه زیر حساب می‌شود:

$$\frac{TP}{TP + FN} = \text{حساسیت} \quad (7)$$

ویژگی:

ویژگی نشان می‌دهد اگر نتیجه واقعی برای نمونه جدید «پرداخت نکرده» باشد، در چند درصد موارد مدل نیز نتیجه «پرداخت نکرده» خواهد داشت، که از رابطه زیر به دست می‌آید:

$$\frac{TN}{FP + TN} = \text{ویژگی} \quad (8)$$

دقت:

دقت به معنای درصد رده‌های درست پیش‌بینی شده است. در این معیار، دو مقدار TP و TN مهم‌ترین مقادیری هستند که در یک مسئله دو رده‌ای باید بیشینه شوند و از رابطه زیر حساب می‌شود:

$$\frac{TN + TP}{TN + FN + TP + FP} = \text{دقت} \quad (9)$$

به منظور ارزیابی کارایی مدل ردهبندی ارائه شده و مدل کین و همکاران [۱۳]، نمونه‌های آموزشی را یکبار دیگر به عنوان نمونه‌های آزمایشی مورد بررسی قرار داده‌ایم، که هر دو مدل نتایج درستی را نشان داده‌اند. علاوه بر آن، ۷۰ نمونه آزمایشی جدید را که خروجی درست آن را می‌دانستیم، با نتایج حاصل از هر دو مدل ردهبندی مورد بررسی قرار داده‌ایم، که نتایج آن در جدول ۲ نشان داده شده است.

بحث و نتیجه گیری

تا کنون ردهبندی داده‌های دقیق با روش‌های مختلفی از قبیل رگرسیون، خوشبندی، درخت تصمیم، بیزی و غیره مورد بررسی

جدول ۳. نمونه‌های آموزشی

اقساط خود را پرداخت کرده‌اند				اقساط خود را پرداخت نکرده‌اند			
نمونه	سن	شارژ ماهانه	درآمد ماهانه	نمونه	سن	شارژ ماهانه	درآمد ماهانه
[۱۷۰ و ۱۴۵]	۵	۳۲	۲۶	[۱۰۰ و ۶۰]	۱۰	۴۵	۱
[۱۷۵ و ۱۴۷]	۴	۳۸	۲۷	[۹۸ و ۷۵]	۸	۳۵	۲
[۱۸۰ و ۱۵۸]	۷	۲۵	۲۸	[۹۳ و ۸۸]	۷	۲۸	۳
[۱۸۵ و ۱۴۸]	۶	۲۹	۲۹	[۱۰۰ و ۸۵]	۷	۲۶	۴
[۱۹۰ و ۱۵۱]	۸	۲۲	۳۰	[۱۰۰ و ۹۵]	۸	۵۶	۵
[۱۸۸ و ۱۵۶]	۶	۳۵	۳۱	[۹۲ و ۶۵]	۹	۵۸	۶
[۱۷۹ و ۱۵۰]	۴	۴۰	۳۲	[۱۱۰ و ۷۹]	۱۰	۳۹	۷
[۱۸۷ و ۱۴۷]	۴	۲۷	۳۳	[۹۴ و ۸۶]	۶	۴۲	۸
[۱۷۴ و ۱۵۵]	۶	۳۰	۳۴	[۱۱۰ و ۹۷]	۷	۵۰	۹
[۱۷۷ و ۱۵۰]	۵	۳۴	۳۵	[۹۸ و ۶۶]	۹	۶۰	۱۰
[۱۸۹ و ۱۵۰]	۶	۲۳	۳۶	[۱۰۰ و ۸۳]	۸	۳۶	۱۱
[۱۸۵ و ۱۵۵]	۷	۳۳	۳۷	[۹۹ و ۹۰]	۹	۴۰	۱۲
[۱۷۰ و ۱۶۰]	۸	۵۰	۳۸	[۱۰۰ و ۹۴]	۱۰	۵۳	۱۳
[۱۸۵ و ۱۷۰]	۷	۳۵	۳۹	[۱۰۰ و ۸۰]	۴	۲۵	۱۴
[۱۹۰ و ۱۷۲]	۹	۴۲	۴۰	[۱۰۰ و ۹۰]	۴	۳۰	۱۵
[۱۸۹ و ۱۶۵]	۸	۶۱	۴۱	[۹۰ و ۸۷]	۸	۴۰	۱۶
[۱۹۰ و ۱۷۹]	۹	۴۳	۴۲	[۹۵ و ۸۵]	۵	۲۵	۱۷
[۱۹۵ و ۱۸۰]	۹	۴۸	۴۳	[۱۲۰ و ۱۱۵]	۵	۵۰	۱۸
[۱۸۰ و ۱۷۷]	۸	۵۵	۴۴	[۱۳۰ و ۱۲۰]	۶	۳۳	۱۹
[۱۹۸ و ۱۷۰]	۹	۶۱	۴۵	[۹۵ و ۸۰]	۷	۲۹	۲۰
[۱۸۰ و ۱۶۵]	۱۰	۵۵	۴۶	[۸۵ و ۷۰]	۸	۳۴	۲۱
[۱۸۳ و ۱۷۵]	۹	۳۷	۴۷	[۷۵ و ۶۵]	۵	۲۷	۲۲
[۱۹۵ و ۱۸۵]	۷	۳۶	۴۸	[۱۱۵ و ۹۰]	۶	۳۵	۲۳
[۱۸۰ و ۱۶۰]	۸	۵۹	۴۹	[۸۵ و ۶۵]	۶	۴۹	۲۴
[۱۷۲ و ۱۵۳]	۵	۳۷	۵۰	[۱۰۵ و ۹۶]	۴	۳۰	۲۵

جدول ۴. تخمین پارامترهای نمونه‌های جدید در ردۀ پرداخت نکرده

نمونه ۵۴	نمونه ۵۳	نمونه ۵۲	نمونه ۵۱	
۳۹	۳۹	۳۹	۳۹	میانگین سن
۱۱۹/۴۱۶۷	۱۱۹/۴۱۶۷	۱۱۹/۴۱۶۷	۱۱۹/۴۱۶۷	انحراف معیار سن
۷/۰۴۰۰	۷/۰۴۰۰	۷/۰۴۰۰	۷/۰۴۰۰	میانگین شارژ
۳/۶۲۲۳	۳/۶۲۲۳	۳/۶۲۲۳	۳/۶۲۲۳	انحراف معیار شارژ
۸۴/۲۴۰۰	۸۴/۲۴۰۰	۸۴/۲۴۰۰	۸۴/۲۴۰۰	میانگین کمترین درآمد
۱۴/۷۸۵۴	۱۴/۷۸۵۴	۱۴/۷۸۵۴	۱۴/۷۸۵۴	انحراف معیار کمترین درآمد
۹۸/۴۸۰۰	۹۸/۴۸۰۰	۹۸/۴۸۰۰	۹۸/۴۸۰۰	میانگین بیشترین درآمد
۱۱/۴۰۹۵	۱۱.۴۰۹۵	۱۱/۴۰۹۵	۱۱/۴۰۹۵	انحراف معیار بیشترین درآمد

جدول ۵. تخمین پارامترهای نمونه‌های جدید در ردۀ پرداخت کرده

نمونه ۵۴	نمونه ۵۳	نمونه ۵۲	نمونه ۵۱	
۳۹/۴۸۰۰	۳۹/۴۸۰۰	۳۹/۴۸۰۰	۳۹/۴۸۰۰	میانگین سن
۱۳۸/۶۷۶۷	۱۳۸/۶۷۶۷	۱۳۸/۶۷۶۷	۱۳۸/۶۷۶۷	انحراف معیار سن
۶/۹۶۰۰	۶/۹۶۰۰	۶/۹۶۰۰	۶/۹۶۰۰	میانگین شارژ
۳/۲۰۶۷	۳/۲۰۶۷	۳/۲۰۶۷	۳/۲۰۶۷	انحراف معیار شارژ
۱۶۰/۹۲۰۰	۱۶۰/۹۲۰۰	۱۶۰/۹۲۰۰	۱۶۰/۹۲۰۰	میانگین کمترین درآمد
۱۲/۰۴۱۳	۱۲/۰۴۱۳	۱۲/۰۴۱۳	۱۲/۰۴۱۳	انحراف معیار کمترین درآمد
۱۸۳/۴۴۰۰	۱۸۳/۴۴۰۰	۱۸۳/۴۴۰۰	۱۸۳/۴۴۰۰	میانگین بیشترین درآمد
۷/۸۳۲۰	۷/۸۳۲۰	۷/۸۳۲۰	۷/۸۳۲۰	انحراف معیار بیشترین درآمد

مراجع

- [۱] باقرزاده خیابانی و اخوان نیاکی (۱۳۹۲). ارائه یک مدل ترکیبی به جهت پیش‌بینی بیماری دیابت نوع ۲. هفتمین کنفرانس داده‌کاوی ایران.
- [۲] Marques, D. J.P. (2003). *Applied Statistics: Using SPSS, STATISTICA, and MATLAB*, Springer Science and Business Media.
- [۳] Surhone, L. M., Timpledon, M.T., and Marseken, S.F. (2010). *Shapiro-Wilk Test*, VDM Publishing.
- [۴] Alpaydin, E. (2004). *Introduction to Machine Learning*, MIT Press.
- [۵] Billard, L. and Diday, E. (2000). Regression analysis for interval-valued data, *Data Analysis: Classification and Related Methods*, Springer, 369-374.
- [۶] Carvalho, F., Lima Neto, E., and Tenorio, C. (2004). A new method to fit a linear regression model for interval valued data, *Advances in Artificial Intelligence*, Springer, 295-306.
- [۷] Carvalho, F., Brito, P., and Bock, H. H. (2006). Dynamic clustering for interval data based on L2 distance, *Computational Statistics*, Springer , **21** ,231–250.
- [۸] Chavent, M., Carvalho, F., Lechevallier, Y., and Verde, R. (2006). New clustering methods for interval data, *Computational Statistics*, Springer, **21** , 211–229.
- [۹] Cormode, G. and McGregor, A. (2008). Approximation algorithm for clustering uncertain data, *Proceedings of the twenty-seventh ACM SIGMOD-SIGACT-SIGART symposium on Principles of database systems*, 191–199.
- [۱۰] Kriegel, H. and Pfeifle, M. (2005). Density based clustering of uncertain data, *Proceedings of the eleventh ACM SIGKDD international conference on Knowledge discovery in data mining* , 672–677.
- [۱۱] Qin, B., Xia, Y., and Li, F. (2009). DTU: a decision tree for uncertain data, *Advances in Knowledge Discovery and Data Mining* , Springer, 4–15.
- [۱۲] Qin, B., Xia,Y., and Li, F. (2010). A Bayesian classifier for uncertain data, *Proceedings of the 2010 ACM Symposium on Applied Computing*, 1010–1014.
- [۱۳] Qin, B. , Xia, Y. , Wang, S., and Du,X. (2011). A novel Bayesian classification for uncertain data, *Knowledge-Based Systems*, Elsevier, **24**, 1151-1158.
- [۱۴] Le, R. and Billard, L. (2011). Likelihood functions and some maximum likelihood estimators for symbolic data, *Statistical Planning and Inference*, **141**, 1593-1602.
- [۱۵] Wackerly, D. Mendenhall, W., and Scheaffer, R. (2007). *Mathematical Statistics with Applications*, Cengage Learning.
- [۱۶] Mitchell, T. (1997). *Machine Learning*, McGraw-Hill science.

- [17] Wu, X. , Kumar, V., Quinlan, J. R., and Motoda, H. (2008). Top 10 algorithms in data mining, *Knowledge and Information Systems*, Springer ,**14** ,1-37.