



دانشگاه تهران
دانشکده علوم ریاضی، آمار و علوم کامپیوتر

روش‌های خطی طبقه‌بندی

پروژه کارشناسی آمار

ریسا علی محمدی

استاد راهنما

دکتر مرتضی ایمنی

خرداد ۱۳۹۶

با سپاس از ...

خرداد ۱۳۹۶

کلیه حقوق مادی مترتب بر نتایج مطالعات، ابتکارات
و نوآوری‌های ناشی از تحقیق موضوع این پایان‌نامه
متعلق به دانشگاه تهران است.

فهرست مطالب

فهرست تصاویر

پنج

فصل ۱ آنالیز تفکیک کننده‌ی خطی و درجه دوم

شش

۱.۱	آنالیز تفکیک کننده‌ی خطی	شش
۲.۱	آنالیز تفکیک کننده درجه دوم	نه
۳.۱	آنالیز تفکیک کننده منظم	نه
۴.۱	محاسبه‌ی LDA و QDA	ده
۵.۱	کاهش بعد در آنالیز تفکیک کننده خطی	دوازده
۶.۱	ارتباط LDA و رگرسیون لوزستیک	دوازده

فصل ۲ معرفی بسته های نرم افزاری موجود در نرم افزار R

شانزده

۱.۲	مقدمه	شانزده
۲.۲	تحلیل مشخصه‌ی خطی (LDA)	شانزده
۳.۲	تحلیل مشخصه‌ی درجه‌ی دوم (QDA)	هجده
۴.۲	پیش‌بینی	هجده

فهرست تصاویر

هشت	شکل ۱	۱.۱
ده	شکل ۲	۲.۱
یازده	شکل ۳	۳.۱
سیزده	شکل ۴	۴.۱
سیزده	شکل ۵	۵.۱
پانزده	شکل ۶	۶.۱

فصل ۱

آنالیز تفکیک کننده‌ی خطی و درجه دوم

۱,۱ آنالیز تفکیک کننده‌ی خطی

برای طبقه‌بندی بهینه احتیاج به دانستن احتمالات پسین $Pr(G|X)$ داریم، که در آن طبقه G و X مشاهده است. فرض کنید $f_k(x)$ چگالی شرطی نقطه‌ی x در کلاس $G = k$ و π_k احتمال پیشین کلاس k باشد. به طوری که $\sum_{k=1}^K \pi_k = 1$. در این صورت بنابر فرمول بیز داریم

$$Pr(G = k|X = x) = \frac{f_k(x)\pi_k}{\sum_{K=1}^K f_k(x)\pi_k} \quad (1.1)$$

در آنالیز تفکیک کننده‌ی خطی و درجه دو از چگالی گاوسی برای (f_k) استفاده می‌شود. با این حال ترکیب‌های انعطاف پذیرتری از چگالی‌های گاوسی، امکان مرزهای تصمیم غیرخطی را فراهم می‌آورد. هم چنین برآورد چگالی ناپارامتری کلی برای چگالی هر کلاس بیشترین انعطاف پذیری را نتیجه می‌دهد. یک حالت خاص دیگر مدل‌های بیز ساده انگارانه است که در آن چگالی هر کلاس را حاصل ضرب چگالی‌های حاشیه‌ای در نظر می‌گیرند، به این معنا که فرض کنیم مشاهده‌ها در هر کلاس مستقل شرطی هستند. حال چگالی گاوسی چند متغیره به صورت زیر را برای f_k در نظر بگیرید.

$$f_k(x) = \frac{1}{(2\pi)^{\frac{p}{2}} |\Sigma_k|^{\frac{1}{2}}} \quad (2.1)$$

$$\exp\left\{-\frac{1}{2}(x - \mu_k)^T \Sigma^{-1}(x - \mu_k)\right\} \quad (3.1)$$

در آنالیز تفکیک کننده خطی (LDA) فرض می‌کنیم کلاس‌ها ماتریس‌های واریانس کواریانس برابر دارند یعنی، $\Sigma_k = \Sigma$ برای $k = 1, \dots, K$. به عنوان ملاکی از میزان درستی گروه بندی $G = k$ نسبت به گروه بندی $G = l$ برای مشاهده $X = x$ از لگاریتم نسبت درستنمایی به صورت زیر استفاده می‌کنیم

$$\log \frac{Pr(G = k | X = x)}{Pr(G = l | X = x)} = \log \frac{f_k(x)}{f_l(x)} + \log \frac{\pi_k}{\pi_l} \quad (4.1)$$

$$2(\mu_l^T - \mu_k^T)\Sigma^{-1}x - (\mu_l - \mu_k)^T \Sigma^{-1}(\mu_l - \mu_k) + \log \frac{\pi_l}{\pi_k} \quad (5.1)$$

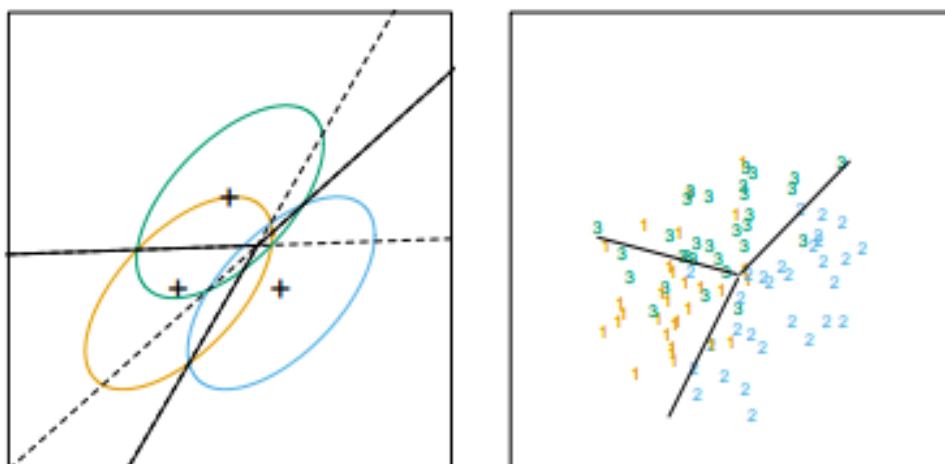
همانطور که می‌بینید، برابری ماتریس کواریانس گروه‌ها باعث حذف جملات درجه دوم از x میشود. بنابراین اگر از ملاک (۳/۱) برای طبقه بندی استفاده شود، مرزهای تصمیم ابر صفحه‌های P بعدی (بعد X) و به عبارت بهتر خطی خواهند بود. با توجه به (۳/۱) قرار می‌دهیم.

$$\sigma_k(x) = X^T \Sigma^{-1} \mu_k - \frac{1}{2} \mu_k^T \Sigma^{-1} \mu_k + \log \pi_k \quad (6.1)$$

و گروه بهینه برای x برابر است با $G(x) = \operatorname{argmax}_k \sigma_k(x)$. در عمل پارامترهای μ_k, σ, π_k مجهول هستند. بنابراین این پارامترها با مقادیر برآوردی زیر جایگزین می‌شوند.

$$\widehat{\pi}_k = \frac{N_k}{N}, \quad (7.1)$$

$$\widehat{\mu}_k = \sum \frac{x_i}{N_k}, \quad (8.1)$$



شکل ۱.۱

پانل سمت چپ سه توزیع گاوسین را نشان می‌دهد با کواریانس یکسان و میانگین متفاوت شامل خطوطی با چگالی ثابت و در هر مورد دربردارنده احتمال 95% است. مرز تصمیم بیز بین هر جفت از کلاس‌ها نشان داده شده است و مرز تصمیم بیز جدا کننده هر ۳ کلاس با خطوط پررنگ نشان داده شده است و در شکل سمت راست نمونه‌ای ۳۰ تایی را می‌بینیم که همه از توزیع گاوسین آمده‌اند و مرز تصمیم خطی LDA برازش داده شده است.

$$\hat{\Sigma} = \sum_{k=1}^K \sum \frac{(x_i - \mu_k)(x_i - \mu_k)^T}{N - K}, \quad (9.1)$$

با استفاده از ملاک (۴/۱) و قاعده بیان شده، بین دو طبقه ۱ و ۲، مشاهده x در طبقه ۲ گروه بندی می‌شود، اگر

$$X^T \Sigma^{-1} (\hat{\mu}_2 - \hat{\mu}_1) > \frac{1}{\varphi} \hat{\mu}_2^T \Sigma^{-1} \hat{\mu}_2 - \frac{1}{\varphi} \hat{\mu}_1^T \Sigma^{-1} \hat{\mu}_1 + \log \frac{N_1}{N} - \log \frac{N_2}{N} \quad (10.1)$$

و در طبقه ۱ گروه بندی می‌شود، اگر

$$X^T \Sigma^{-1} (\hat{\mu}_2 - \hat{\mu}_1) < \frac{1}{\varphi} \hat{\mu}_2^T \Sigma^{-1} \hat{\mu}_2 - \frac{1}{\varphi} \hat{\mu}_1^T \Sigma^{-1} \hat{\mu}_1 + \log \frac{N_1}{N} - \log \frac{N_2}{N} \quad (11.1)$$

بنابراین ابر صفحه جدا کننده این دو طبقه به صورت زیر است

$$\frac{1}{\varphi} \hat{\mu}_2^T \Sigma^{-1} \hat{\mu}_2 = \frac{1}{\varphi} \hat{\mu}_1^T \Sigma^{-1} \hat{\mu}_1 + \log \frac{N_1}{N} - \log \frac{N_2}{N} \quad (12.1)$$

۲,۱ آنالیز تفکیک کننده درجه دوم

در آنالیز تفکیک درجه دوم (QDA) ماتریس واریانس کواریانس گروه‌ها یکسان در نظر گرفته نمی‌شود و بنابراین ملاک تفکیک درجه دوم در این حالت برابر است با

$$\sigma_k(x) = -\frac{1}{p} \log |\Sigma_k| - \frac{1}{2} (x - \mu_k)^T \Sigma_k^{-1} (x - \mu_k) + \log \pi_k \quad (۱۳.۱)$$

با استفاده از مرز تصمیم بین هر جفت مشاهده از کلاس k و l یک معادله درجه ۲ است. شکل ۲.۱ (؟؟) مرزهای تفکیک درجه دوم و خطی سه کلاس گوسی را نشان می‌دهد. در این حالت ابر منحنی جدا کننده درجه دوم دو طبقه مثلاً ۱ و ۲ به صورت زیر است.

$$x^T (\widehat{\Sigma}_1^{-1} - \widehat{\Sigma}_2^{-1}) x - 2x^T (\widehat{\Sigma}_1^{-1} \widehat{\mu}_1 - \widehat{\Sigma}_2^{-1} \widehat{\mu}_2) = \widehat{\mu}_2^T \widehat{\Sigma}_2^{-1} \widehat{\mu}_2 - \widehat{\mu}_1^T \widehat{\Sigma}_1^{-1} \widehat{\mu}_1 + \log |\widehat{\Sigma}_2| - \log |\widehat{\Sigma}_1| + \log \frac{N_1}{N} - \log \frac{N_2}{N} \quad (۱۴.۱)$$


هر چه قدر اختلاف پراکندگی دو کلاس بیشتر باشد، ضریب قسمت درجه دوم و در نتیجه انحناى مرز تفکیک کننده به سمت کلاس با پراکندگی کمتر، بیشتر خواهد شد (تغیر به سمت کلاس با پراکندگی کمتر و تحذب به سمت کلاس با پراکندگی بیشتر).

۳,۱ آنالیز تفکیک کننده منظم

فریدمن (۱۹۸۹) یک توافق بین LDA و QDA مطرح کرد، که تلفیقی از کواریانس‌های جداگانه در روش QDA کواریانس‌های مشترک در روش LDA را در نظر می‌گیرد. ماتریس کواریانس منظم در این روش به صورت زیر است.

$$\Sigma_k(\alpha) = \alpha \Sigma_k + (1 - \alpha) \Sigma, \quad (۱۵.۱)$$

پارامتر تنظیم α می‌تواند بر پایه کارایی مدل داده‌های اعتبارسنجی و یا به وسیله ملاک‌های اعتبارسنجی متقابل انتخاب شود، که در ادامه توضیح داده می‌شود. برای یک اصلاح مشابه اجازه می‌دهد که Σ به صورت زیر تفکیک شود.



شکل ۲.۱

شکل سمت چپ دسته‌ی اول متغیرهای کانونی LDA را برای داده‌های مصوت نشان می‌دهد. شکل سمت راست نگاشت حاصل از استفاده از $FDA/BRUTO$ برای برازش مدل را نشان می‌دهد که در آن مقادیر برازیده‌ی توابع رگرسیونی نمایش داده شده است. به وضوح جداسازی داده‌های مصوته در قالب ۱۱ گروه بهبود یافته است.


$$\Sigma(\gamma) = \gamma\Sigma + (1 - \gamma) \sigma^2 I, \quad (۱۶.۱)$$

که در آن $\alpha \in [0, 1]$

جایگزینی Σ در (۱۰.۱) با $\Sigma(\gamma)$ منجر به یک خانواده کلی‌تر از ماتریس‌های کواریانس مانند $\Sigma(\gamma, \alpha)$ می‌شود که با جفت پارامتر γ و α اندیس گذاری شده است.

۴.۱ محاسبه‌ی LDA و QDA

محاسبه‌ی ابر صفحه‌ها و یا ابر منحنی‌های تفکیک کننده در روش LDA و QDA نیاز به محاسبات پیچیده مکرر دارد. به خصوص زمانی که بعد P بالا باشد، این محاسبات نیز سنگین تر خواهند شد. با این حال تجزیه منعامد ماتریس‌های کواریانس به صورت زیر به ما امکان درک و محاسبه ساده تریاز طبقه بندی در این روش می‌دهد. فرض کنید ماتریس کواریانس Σ_k به صورت $\Sigma_k = U_k D_k U_k^T$ تجزیه شده باشد، که در آن ماتریس بردارهای ویژه D_k و U_k ماتریس قطری با اعضای قطر اصلی مقادیر ویژه σ_k باشد. در این صورت با قرار دادن $x_k^* = D_k^{-1} U_k^T x_k$ در روش QDA و $x^\alpha = D^{-1} U^T x$ در روش LDA (با تجزیه $\Sigma = U D U^T$) داریم



شکل ۳.۱

داده‌های شبیه‌سازی شده در یک صفحه که توسط روش $K - Means$ به سه خوشه (آبی، نارنجی و سبز) تقسیم شده اند.

$$Cov(x_k^\alpha) = D_k^{-1} U_K^T D_k^{-1} = I \quad (17.1)$$

و به طور مشابه $cov(x^*) = I$ با توجه به متعامد یکه بودن بردارهای ویژه

$$U^T U = U_k^T U_k = I. \quad (18.1)$$

بنابراین برای داده‌های تبدیل یافته X^* کافی است، هر مشاهده با توجه به تنها فاصله اقلیدسیش از مرکز هر طبقه $\widehat{\mu}_k$ و احتمال پیشین آن طبقه $\widehat{\pi}_k$ طبقه بندی می‌شود، یعنی بر اساس

$$\sigma_k(x) = \log \widehat{\pi}_k - \frac{1}{2} \|x - \widehat{\mu}_k\|^2 \quad (19.1)$$

۵,۱ کاهش بعد در آنالیز تفکیک کننده خطی

روش های معمول کاهش بعد به دنبال یافتن ترکیب های خطی مانند $y = \alpha x$ با بعد کمتر از x هستند، به طوری که دارای بیشترین پراکندگی باشند. با این حال در روش های طبقه بندی مانند LDA و QDA بهتر است این کاهش بعد به گونه ای باشد که پراکندگی بین طبقات حداکثر شود. با در نظر گرفتن یک طبقه بندی مشخص می توان پراکندگی کل Σ را به صورت زیر تفکیک کرد

$$T = \sum_{k=1}^K (x_i - \mu)^T (x_i - \mu) = \sum_{k=1}^K \Sigma (x_i - \mu_k)^T + \sum_{k=1}^K N_k (\mu_k - \mu)^T (\mu_k - \mu) = W + B, \quad (20.1)$$

که در آن W تغییرات داخل طبقات و B پراکندگی بین طبقات نامیده می شود. فیشر مساله کاهش بعد در LDA را به این صورت مطرح می کند که ضرایب خطی $y = \alpha x$ با پراکندگی داخل طبقات $\alpha^T W \alpha$ و پراکندگی بین طبقات $\alpha^T B \alpha$ را طوری بیابیم که $\alpha^T W \alpha$ حد اکثر و در نتیجه $\alpha^T W \alpha$ مینیمم شود. بنابراین مساله فیشر ماکزیمم کردن مقدار خارج قسمت زیر است،

$$\max_{\alpha} \frac{\alpha^T B \alpha}{\alpha^T W \alpha} \quad (21.1)$$

یا به طور معادل


$$\max_{\alpha} \alpha^T B \alpha \quad \alpha^T W \alpha = 1 \quad (22.1)$$

با یک تبدیل $B^T = \alpha^T W^{-1}$ می توان دریافت که α در رابطه (۱۶.۱) صدق کند بیشترین مقدار ویژه $W^{-1}B$ است.

۶,۱ ارتباط LDA و رگرسیون لوجستیک


مدل رگرسیون لوجستیک به صورت زیر برای طبقه بندی مشاهدات به K کلاس یک روش طبقه بندی است که ارتباط نزدیکی با روش LDA دارد.

$$\log \frac{Pr(G = k | X = x)}{Pr(G = K | X = x)} = \beta_{k^0} + \beta_k^T x, \quad k = 1, \dots, K-1. \quad (23.1)$$



شکل ۴.۱

نرخ های خطای آموزشی و آزمون داده های مصوتہ، مانند تابعی از بعد فضای فرعی تفکیک کننده، در این مورد بهترین نرخ خطا برای دو بعد است. شکل ۴.۱۱ مرز تصمیم در این فضا را نشان می دهد.



شکل ۵.۱

مرزهای تصمیم برای داده های آموزشی مصوتہ را نشان می دهد. در فضای فرعی دو بعدی با اولین دو متغیر استاندارد اندازه گرفته شد.

در این روش ضرایب β_k و β_{k_0} براساس روش درستنمایی ماکزیمم و در نظر گرفتن توزیع چند جمله‌ای برای G به شرط X با احتمال زیر برآورد می‌شوند.

$$Pr(G = k|X = x) = \frac{\exp \beta_{k_0} + \beta_k^T x}{1 + \sum_{l=1}^{K-1} \exp \{\beta_{l_0} + \beta_l^T x\}}. \quad (24.1)$$

همانطور که در بخش اول این فصل گفتیم در روش LDA داریم:

$$\log \frac{Pr(G = k|X = x)}{Pr(G = K|X = x)} = \log \frac{\pi_k}{\pi_K} - \frac{1}{2}(\mu_k - \mu_K)^T \Sigma^{-1}(\mu_k - \mu_K) + x^T \Sigma^{-1}(\mu_k - \mu_K) = \alpha_{k_0} + \alpha_K^T x. \quad (25.1)$$


بنابراین به نظر می‌رسد که روش LDA و رگرسیون لجستیک یکی هستند، با این حال تفاوت نهفته در روش برآورد ضرایب است. یک تفاوت عمده این دوروش این است که رگرسیون لجستیک تنها از توزیع نرمال G به شرط X استفاده می‌کند در حالی که روش LDA توزیع توأم G و X را به صورت زیر در نظر می‌گیرد.

$$Pr(X, G = k) = Pr(X) \cdot Pr(G = k|X) \quad (26.1)$$

که در آن برای محاسبه احتمال حاشیه‌ای $Pr(X)$ فرض می‌شود $X|G = k \sim N(\mu, \Sigma)$ تفاوت دوم این است که در روش LDA احتمالات پیشین $Pr(G = k) = \pi_k$ نیز در نظر گرفته می‌شوند. بنابراین تابع چگالی حاشیه‌ای X برابر است با

$$f_x(X) = \sum_{k=1}^K \pi_k \cdot \Phi(x; \mu_k, \Sigma), \quad (27.1)$$

که در آن Φ تابع چگالی نرمال با میانگین μ_k و ماتریس واریانس کواریانس Σ است. در نظر گرفتن توزیع حاشیه‌ای X در روش LDA باعث می‌شود مشاهدات دور از مرز تصمیم نقش برابری در برآورد ماتریس کواریانس مشترک با مشاهدات نزدیک به مرز تصمیم داشته باشند. بنابراین روش LDA نسبت به مشاهدات دور است و استوار نیست. با این حال و با تمام این تفاوت‌ها، اغلب، طبقه بندی حاصل از هر روش بسیار شبیه به هم هستند.



شکل ۶.۱

دو کلاس که توسط ابر صفحه‌ها مجزا شده‌اند. خط نارنجی حداقل مربعات را که کدام یکی از داده‌های آموزشی نادرست طبقه‌بندی شده‌اند را نشان می‌دهد. هم‌چنین دو ابر صفحه مجزا کننده‌ی ابر پایه الگوریتم آموزشی پرسپترون با مبدا‌های تصادفی متفاوت ساخته شده‌اند.

فصل ۲

معرفی بسته های نرم افزاری موجود در نرم افزار R

۱,۲ مقدمه

از مهم ترین و معروف ترین روش های یادگیری خطی که برای حل مسائل دسته بندی استفاده می شوند، روش های تحلیل مشخصه هستند. از بین بسته های متعدد موجود برای نرم افزار R، بسته ی معروف MASS که توسط دانشگاه آکسفورد تهیه شده و آخرین نسخه ی آن در اپریل ۲۰۱۶ عرضه شده است، شامل دستورهایی برای برازش مدل های تحلیل مشخصه ی خطی و درجه ی دوم است که در ادامه ی متن به ترتیب آن ها را شرح خواهیم داد. لازم به ذکر است که بنا به تشابه اغلب گزینه های این دو دستور، با ذکر وجود گزینه تنها یک بار شرح آن داده خواهد شد.

۲,۲ تحلیل مشخصه ی خطی (LDA)

تحلیل مشخصه ی خطی توسط بسته ی مذکور از طریق دستور $lda()$ انجام می شود. با توجه به شکل داده، این دستور به دو طریق قابل اجراست:

۱. در صورتی که مشخص (یا مطلوب) باشد که متغیر پاسخ (کلاس) با کدامین متغیرهای مشخصه در ارتباط است، این متغیرها از طریق گزینه ی $formula = groups \sim x_1 + x_2 + \dots$ مشخص می شوند، به طریقی که $groups$ نشان دهنده ی متغیر پاسخ و از جنس فاکتور ($factor$) است و x_i ها متغیرهای مشخصه هستند. در این صورت گزینه ی $data$ داده ی حاوی این متغیرها را معین می کند. در صورتی که تمامی متغیرهای درون $data$ (به جز پاسخ) به عنوان متغیر مشخصه در نظر گرفته شده باشد، می توان از نوشتار $formula = groups \sim$ نیز استفاده کرد. هم چنین در صورت استفاده از گزینه ی $formula$

می توان با ذخیره ی مدل و استفاده از دستور *update* رابطه و متغیرهای مورد استفاده را بروز رسانی کرد.

۲. در صورتی که ارتباط بین متغیرهای مشخصه با متغیر کلاس از پیش تعیین شده نباشد، داده که در قالب *data frame* یا ماتریس (*matrix/Matrix*) است توسط گزینه ی *x* مشخص می شود. در این حالت گزینه ی *grouping* برداری از جنس فاکتور است که مشاهدات پاسخ را مشخص می کند.

در واقع استفاده از دستور (*lda(x = discriminants, grouping = result)* از حالت دوم که به آن *lda.default* گفته می شود، معادل است با استفاده از دستور (*lda(result ~ discriminants)*. نکته ی لازم به ذکر دیگر آن است که روش دوم نسبت به روش اول—که به آن *lda.formula* گفته می شود—سریع تر است.

گزینه ی دیگر دستور *prior.lda* است که بردار احتمالات پیشین عضویت در کلاس ها را مشخص می کند. به طور مثال در صورتی که احتمالات پیشین برای یک مسأله ی سه کلاسه برابر با $0.1, 0.3, 0.6$ باشد، بایستی از نوشتار $prior = c(0.1, 0.3, 0.6)$ استفاده شود. در صورتی که احتمالات پیشین تعیین نشود این مقادیر با استفاده از مشاهدات کل مجموعه داده برآورد می شوند.

در واقع یک متغیر وقتی به عنوان یک متغیر مشخصه کارساز و قابل استفاده است که حاوی اطلاعات باشد، بر این اساس به طور مثال متغیرهای ثابت ناکارآمد هستند. چنین متغیرهای کم اطلاع یا فاقد اطلاعی موجب معکوس ناپذیر شدن ماتریس بین دسته ای می شوند که فرآیند حل مسأله را با مشکل روبرو می کند. از این رو بایستی حتی الامکان از چنین رویدادی جلوگیری کرد. در این راستا گزینه ی *tol* حدی را تعیین می کند و در صورتی که انحراف معیار یک بردار از این مقدار کم تر باشد آن متغیر و ترکیب های آن را در فرآیند یادگیری نمی پذیرد. مقدار پیش فرض این گزینه برابر با 10^{-4} است.

در شرایطی که نیاز باشد تنها بخشی از داده ها در فرآیند آموزش به کار گرفته شوند، نوشتار *subset* برای تعیین این زیرمجموعه از داده ها قابل استفاده است. این زیرمجموعه ممکن است از قبل تعیین شده باشد که در این صورت تنها نام آن مقابل *subset =* قرار می گیرد یا به هر طریق دیگری مانند نمونه گیری یا برشی از داده ها تعیین شود.

برای تعیین نحوه ی برآورد میانگین و واریانس طی فرآیند یادگیری از گزینه ی *method* استفاده می کنیم. مقادیر ممکن این گزینه برابرند با: *moment* (برآورد گشتاوری/میانگین و واریانس نمونه ای)، *mle* (برآوردهای حداکثر درست نمایی)، *t* (برآورد استوار بر اساس توزیع *t-student*) و *mve* (برآورد مکان و مقیاس چندمتغیره که در واقع به تعبیری میانگین و واریانس قسمت مناسبی از داده ها را محاسبه می کند). در صورتی که از برآوردهای استوار استفاده شود، گزینه ی *nu* درجه ی آزادی توزیع *t* مدنظر را تعیین می کند.

در نهایت گزینه ی *na.action* که نحوه ی برخورد با داده های گمشده را تعیین می کند و گزینه ی *CV* که انجام شدن یا نشدن اعتبارسنجی متقابل را مشخص می کند، نیز از گزینه های ممکن دستور *lda()* هستند.

در صورتی که $CV = T$ یعنی اعتبارسنجی متقابل انجام شود، خروجی دستور شامل کلاس های برآورد

شده برای مشاهدات و برآورد توزیع پسین هر کلاس برای هر مشاهده است که توسط روش بیشینه‌ی پسین (MAP) برآورد می‌شوند.

اما در صورتی که اعتبارسنجی متقابل انجام نگیرد، خروجی دستور lda شامل این موارد می‌شود: توزیع پیشین ($prior$)، میانگین‌ها ($means$)، ماتریس نرمال‌ساز ($scaling$)، مقدار svd که مشخص‌کننده‌ی نسبت انحراف معیار بین گروهی به درون گروهی را مشخص می‌کند و توان دوم آن مقدار آماره‌ی F مرکزی است، تعداد مشاهدات (N) و در نهایت تابع فراخوانی شده ($call$).

۳,۲ تحلیل مشخصه‌ی درجه‌ی دوم (QDA)

در مورد دستور $qda()$ برای انجام تحلیل مشخصه‌ی درجه‌ی دوم، تمامی گزینه‌ها و خروجی‌ها تشریحی مشابه با دستور $lda()$ دارند و مازاد بر آن در خروجی qda ، گزینه‌ی $ldet$ برداری از دترمینان ماتریس اغتشاش است و lev سطوح پاسخ را نشان می‌دهد.

فرم کلی دستورهای lda و qda :

$$lda(formula, data, method, na.action, prior = proportions, CV = F, nu, ...) \quad (۱.۲)$$

$$qda(formula, data, method, na.action, prior = proportions, CV = F, nu, ...) \quad (۲.۲)$$

۴,۲ پیش‌بینی

برای پیش‌بینی از مدل‌های تحلیل مشخصه می‌توان مانند اغلب مدل‌هایی که در محیط R ساخته می‌شوند به این صورت عمل کرد که مدل در یک مؤلفه مانند $model$ ذخیره شود و سپس با استفاده از دستور $predict()$ و معرفی داده‌ی جدید، پیش‌بینی مقادیر نظیر این داده‌ی جدید مانند کلاس برآورد شده و یا توزیع پسین انجام گیرد.