

STATISTICAL PATTERN RECOGNITION

باز شناسایی آماری الگو
عباس برزگری نژاد

بهار ۱۴۰۴

ابر صفحه‌های تصمیم‌گیری (*Decision Hyper planes*)

تنها عاملی که باعث غیر خطی شدن معادله

$$g_i(x) = -\frac{1}{2}x^T [\Sigma_i]^{-1}x + \frac{1}{2}x^T [\Sigma_i]^{-1}\mu_i + \frac{1}{2}\mu_i^T [\Sigma_i]^{-1}x - \frac{1}{2}\mu_i^T [\Sigma_i]^{-1}\mu_i + \ln(P(w_i)) + C_i$$

گردید عبارت $x^T [\Sigma_i]^{-1}x$ می‌باشد. حال اگر فرض کنیم که ماتریس کوواریانس در تمام کلاسها یکسان می‌باشد یعنی

$$[\Sigma_i] = [\Sigma]$$

لذا فرم درجه دوم $x^T [\Sigma_i]^{-1}x$ در تمام توابع جدا کننده یکسان خواهد بود. از این رو این عبارت در محاسبه ماکزیمم بی‌اثر خواهد بود و در معادلات صفحه تصمیم‌گیری عاملی خنثی می‌گردد. همانطور که قبلاً نیز اشاره کردیم $g_i(x)$ یک تابع جدا کننده می‌باشد که با استفاده از آزمون تصمیم‌گیری زیر ما را در انتخاب یاری می‌رساند:

$$\forall i \neq j \quad g_i(x) > g_j(x) \text{ اگر } x \text{ در کلاس } W_i \text{ قرار دارد}$$

بنابراین ابر صفحه‌های تصمیم‌گیری با استفاده از معادلات زیر بدست می‌آید:

$$g_i(x) = -\frac{1}{2}x^T[\Sigma_i]^{-1}x + \frac{1}{2}x^T[\Sigma_i]^{-1}\mu_i + \frac{1}{2}\mu_i^T[\Sigma_i]^{-1}x - \frac{1}{2}\mu_i^T[\Sigma_i]^{-1}\mu_i + \ln(P(w_i)) + C_i \quad C_i = -\frac{l}{2}\ln 2\pi - \frac{1}{2}\ln|[\Sigma_i]^{-1}|$$

$$g_{ij}(x) \equiv g_i(x) - g_j(x) = 0$$

با ثابت فرض کردن ماتریس کوواریانس در تمام کلاسها به وضوح مقدار C_i نیز در تمام توابع جدا کننده یکسان خواهد بود بنابراین می توان عبارتهای $x^T[\Sigma_i]^{-1}x$ و C_i را از این توابع حذف نمود و به تابع اصطلاح یافته زیر رسید:

$$g_i(x) = W_i^T x + W_{i0}$$

که در آن

$$W_i = [\Sigma_i]^{-1}\mu_i$$

$$W_{i0} = -\frac{1}{2}\mu_i^T[\Sigma_i]^{-1}\mu_i + \ln(P(w_i))$$

توابع جداکننده برای چگالی نرمال

تابع چگالی احتمال نرمال را مجدداً در نظر بگیرید:

$$P_i(x) = \frac{1}{(2\pi)^{\frac{L}{2}} |\Sigma_i|^{\frac{1}{2}}} \exp\left(-\frac{1}{2} [x - \mu_i]^T [\Sigma_i]^{-1} (x - \mu_i)\right), \quad i=1, \dots, M$$

می‌توان تابع جداکننده را به صورت زیر در نظر گرفت:

$$g_i(x) = \ln P(X|w_i) + \ln P(w_i)$$

اگر $P(X|w_i) \sim N(\mu_i, [\Sigma_i])$ باشد در این صورت خواهیم داشت:

$$g_i(x) = -\frac{1}{2} (X - \mu_i)^T |[\Sigma_i]^{-1}| (X - \mu_i) - \frac{L}{2} \ln 2\pi - \frac{1}{2} \ln |[\Sigma_i]| + \ln(P(w_i))$$

در این بخش قصد داریم تابع جداکننده و دسته بندی‌های حاصله را به ازای تعدادی از حالت‌های خاص شرح می‌دهیم:

حالت اول:

$$[\Sigma_i] = \sigma^2 I$$

در همه کلاسها ماتریس کوواریانس ثابت و قطری می باشد

حالت دوم:

$$[\Sigma_i] = [\Sigma]$$

در همه کلاسها ماتریس کوواریانس ثابت می باشد

حالت سوم:

$$[\Sigma_i] = \textit{Arbitrary}$$

در هر کلاس ماتریس کوواریانس خاص خود آن کلاس می باشد.

حالت اول: $[\Sigma_i] = \sigma^2 I$

وقتی که ماتریس کوواریانس ثابت است ولی ماتریس قطری است. ماتریس قطری روی قطر اصلی همه واریانس و بقیه جاها صفر می باشد:

$$[\Sigma_i] = \begin{bmatrix} \sigma^2 & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & \sigma^2 \end{bmatrix}$$

$$[\Sigma_i]^{-1} = \frac{1}{\sigma^2} I$$

$$[\Sigma_i][\Sigma_i]^{-1} = I$$

$$\left| \begin{bmatrix} \sigma^2 & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & \sigma^2 \end{bmatrix} \right| = (\sigma^2)^n$$

از آنجا که هر دو مقدار $|\Sigma_i|$ و $\frac{L}{2} \ln 2\pi$ مستقل از مقدار i می باشند، لذا می توان آن ها را نادیده گرفت. بنابراین توابع جدا کننده ساده زیر بدست می آیند:

$$g_i(x) = -\frac{1}{2\sigma^2} (X - \mu_i)^T (X - \mu_i) + \ln(P(w_i))$$

$$g_i(x) = -\frac{1}{2\sigma^2} \|X - \mu_i\|^2 + \ln(P(w_i))$$

یادآوری:

$$X = (x_1, x_2, \dots, x_n)$$

$$\|x\|_p = \left(\sum_{i=1}^n |x_i|^p \right)^{\frac{1}{p}} \quad \text{Or} \quad \|x\|_p = \sqrt{|x_1|^p + |x_2|^p + \dots + |x_n|^p}$$

$$\text{if } p = 2 \Rightarrow \|x\| = \sqrt{|x_1|^2 + |x_2|^2 + \dots + |x_n|^2}$$

بسط فرم درجه دوم $(X - \mu_i)^T (X - \mu_i)$ منجر به تابع زیر می شود

$$g_i(x) = -\frac{1}{2\sigma^2} (X^T X - 2\mu_i^T X + \mu_i^T \mu_i) + \ln(P(w_i))$$

$X^T X$ چون اندیس i ندارد در همه کلاسها ثابت هست و می توان از آن صرف نظر کرد. بنابراین توابع جداکننده خطی در حالت اول بدین صورت در می آیند:

$$g_i(x) = -\frac{1}{2\sigma^2} (-2\mu_i^T X + \mu_i^T \mu_i) + \ln(P(w_i))$$

پس:

$$g_i(x) = W_i^T x + W_{i0}$$

که در آن

$$W_i = \frac{1}{\sigma^2} \mu_i$$

$$W_{i0} = -\frac{1}{2\sigma^2} \mu_i^T \mu_i + \ln(P(w_i))$$

W_{i0} را آستانه تحمل (*Threshold*) یا اریب (*bias*) در جهت i ام می نامیم.

کلاسیفایر یا دسته بندهایی که از توابع جداکننده خطی استفاده می کنند یک ماشین خطی می نامیم. در این مرحله صرفاً توجه داشته باشید که سطوح تصمیم برای یک ماشین خطی، قطعاتی از ابرصفحه های تعریف شده بوسیله معادلات خطی

$$g_i(x) = g_j(x)$$

با حداکثر احتمالات ثانویه، می باشند. برای حالت خاص در نظر گرفته شده این معادله را می توان بدین صورت در نظر گرفت:

$$g_{ij}(x) \equiv g_i(x) - g_j(x) = 0$$

$$\frac{1}{\sigma^2} \mu_i^T X - \frac{1}{2\sigma^2} \mu_i^T \mu_i + \ln(P(w_i)) - \left[\frac{1}{\sigma^2} \mu_j^T X - \frac{1}{2\sigma^2} \mu_j^T \mu_j + \ln(P(w_j)) \right] = 0$$

$$\frac{1}{\sigma^2} (\mu_i - \mu_j)^T X - \frac{1}{2\sigma^2} (\mu_i^T \mu_i - \mu_j^T \mu_j) + \ln\left(\frac{P(w_i)}{P(w_j)}\right) = 0$$

چون

$$\mu_i^T \mu_i - \mu_j^T \mu_j = (\mu_i - \mu_j)^T (\mu_i + \mu_j)$$

$$(\mu_i - \mu_j)^T X - \frac{1}{2} (\mu_i - \mu_j)^T (\mu_i + \mu_j) + \sigma^2 L n \left(\frac{P(w_i)}{P(w_j)} \right) = \cdot$$

$$(\mu_i - \mu_j)^T \left[X - \left(\frac{1}{2} (\mu_i + \mu_j) - \frac{\sigma^2}{(\mu_i - \mu_j)^T (\mu_i - \mu_j)} (\mu_i - \mu_j) L n \left(\frac{P(w_i)}{P(w_j)} \right) \right) \right] = \cdot$$

بنابراین

$$W^T (X - X_0) = 0$$

که در آن

$$W = (\mu_i - \mu_j)$$

,

$$X_0 = \frac{1}{2} (\mu_i + \mu_j) - \frac{\sigma^2}{\|\mu_i - \mu_j\|^2} (\mu_i - \mu_j) L n \left(\frac{P(w_i)}{P(w_j)} \right)$$

حالت دوم: $[\Sigma_i] = [\Sigma]$

یکی دیگر از حالات ساده زمانی رخ می دهد که ماتریس کوواریانس به ازای تمام کلاس ها یکسان باشد. از آنجا که هر دو مقدار $|\Sigma_i|$ و $\frac{L}{2} \ln 2\pi$ مستقل از مقدار i می باشند، لذا می توان آن ها را نادیده گرفت. این ساده سازی منجر به تابع جدا کننده زیر می شود:

$$\begin{aligned} g_i(x) &= -\frac{1}{2} (X - \mu_i)^T [\Sigma]^{-1} (X - \mu_i) + \ln(P(w_i)) \\ &= -\frac{1}{2} [x^T [\Sigma]^{-1} x - x^T [\Sigma]^{-1} \mu_i - \mu_i^T [\Sigma]^{-1} x + \mu_i^T [\Sigma]^{-1} \mu_i] + \ln(P(w_i)) \end{aligned}$$

در رابطه فوق با توجه به اینکه عبارت درجه دوم $x^T [\Sigma]^{-1} x$ مستقل از مقدار i می باشد، لذا می توان آن را نادیده گرفت. پس خواهیم داشت:

$$g_i(x) = \mu_i^T [\Sigma]^{-1} x - \frac{1}{2} \mu_i^T [\Sigma]^{-1} \mu_i + \ln(P(w_i))$$

$$W_i = [\Sigma]^{-1} \mu_i$$

$$W_{i0} = -\frac{1}{2} \mu_i^T [\Sigma]^{-1} \mu_i + \text{Ln}(P(w_i))$$

خواهیم داشت:

$$g_i(x) = W_i^T x + W_{i0}$$

چون جدا کننده ها خطی می باشند، لذا مرزهای تصمیم گیری باز هم ابرصفحه ها می باشند. اگر R_i و R_j پیوسته باشند، مرز بین آن ها معادله ای به صورت زیر می باشد:

$$g_{ij}(x) \equiv g_i(x) - g_j(x) = 0$$

$$\mu_i^T [\Sigma]^{-1} x - \frac{1}{2} \mu_i^T [\Sigma]^{-1} \mu_i + \text{Ln}(P(w_i)) - \mu_j^T [\Sigma]^{-1} x + \frac{1}{2} \mu_j^T [\Sigma]^{-1} \mu_j - \text{Ln}(P(w_j)) = 0$$

$$(\mu_i - \mu_j)^T [\Sigma]^{-1} X - \frac{1}{2} (\mu_i - \mu_j)^T [\Sigma]^{-1} (\mu_i + \mu_j) + \text{Ln} \left(\frac{P(w_i)}{P(w_j)} \right) = \cdot$$

$$(\mu_i - \mu_j)^T [\Sigma]^{-1} \left[X - \left(\frac{1}{2} (\mu_i + \mu_j) - \frac{\text{Ln} \left(\frac{P(w_i)}{P(w_j)} \right)}{(\mu_i - \mu_j)^T [\Sigma]^{-1} (\mu_i - \mu_j)} (\mu_i - \mu_j) \right) \right] = \cdot$$

بنابراین

$$W^T (X - X_0) = 0$$

که در آن

$$W = [\Sigma]^{-1} (\mu_i - \mu_j)$$

,

$$X_0 = \frac{1}{2} (\mu_i + \mu_j) - \frac{\text{Ln} \left(\frac{P(w_i)}{P(w_j)} \right)}{(\mu_i - \mu_j)^T [\Sigma]^{-1} (\mu_i - \mu_j)} (\mu_i - \mu_j)$$

حالت سوم: $[\Sigma_i] = \text{Arbitrary}$

در این حالت ماتریس های کوواریانس در هر دسته متفاوت می باشند. تنها عبارتی که مستقل از i می باشد، عبارت $\frac{L}{2} \ln 2\pi$ است که می توان آن را نادیده گرفت و لذا توابع جداکننده بدست آمده ذاتاً درجه دوم می باشند:

$$\begin{aligned} g_i(x) &= -\frac{1}{2} (X - \mu_i)^T [\Sigma_i]^{-1} (X - \mu_i) + \ln(P(w_i)) - \frac{1}{2} \ln|[\Sigma_i]| \\ &= -\frac{1}{2} [x^T [\Sigma_i]^{-1} x - x^T [\Sigma_i]^{-1} \mu_i - \mu_i^T [\Sigma_i]^{-1} x + \mu_i^T [\Sigma_i]^{-1} \mu_i] + \ln(P(w_i)) - \frac{1}{2} \ln|[\Sigma_i]| \\ &= -\frac{1}{2} x^T [\Sigma_i]^{-1} x + \mu_i^T [\Sigma_i]^{-1} x - \frac{1}{2} \mu_i^T [\Sigma_i]^{-1} \mu_i - \frac{1}{2} \ln|[\Sigma_i]| + \ln(P(w_i)) \end{aligned}$$

بنابراین:

$$g_i(x) = x^T [W_i] x + w_i^T x + w_{i0}$$

$$[W_i] = -\frac{1}{2} [\Sigma_i]^{-1}$$

$$w_i = [\Sigma_i]^{-1} \mu_i$$


$$w_{i0} = -\frac{1}{2} \mu_i^T [\Sigma_i]^{-1} \mu_i - \frac{1}{2} \ln|[\Sigma_i]| + \ln(P(w_i))$$

که در آن

مثال (نواحی تصمیم برای داده های نرمال دو بعدی):

همانطور که در شکل نیز مشاهده می کنید، فرض کنید W_1 مجموعه شامل چهار نقطه سیاه و W_2 نقاط قرمز باشند. بردارهای امید ریاضی و ماتریس های کوواریانس را بدین صورت در نظر بگیرید:

$$\mu_1 = \begin{bmatrix} 3 \\ 6 \end{bmatrix}; \quad \Sigma_1 = \begin{pmatrix} 1/2 & 0 \\ 0 & 2 \end{pmatrix} \text{ and } \mu_2 = \begin{bmatrix} 3 \\ -2 \end{bmatrix}; \quad \Sigma_2 = \begin{pmatrix} 2 & 0 \\ 0 & 2 \end{pmatrix}$$



برای بدست آوردن ناحیه های تصمیم ابتدا عکس ماتریس های کوواریانس را محاسبه می کنیم:

$$\Sigma_1^{-1} = \begin{pmatrix} 2 & 0 \\ 0 & 1/2 \end{pmatrix} \text{ and } \Sigma_2^{-1} = \begin{pmatrix} 1/2 & 0 \\ 0 & 1/2 \end{pmatrix}$$

با فرض برابری احتمالات اولیه ($P(W_1) = P(W_2) = 0.5$) و جایگذاری در $g_1(x)$ و $g_2(x)$ خواهیم داشت:

$$g_1(x) = -x_1^2 - \frac{1}{4}x_2^2 + 6x_1 + 3x_2 - 18 - \ln 2$$

$$g_2(x) = -\frac{1}{4}x_1^2 - \frac{1}{4}x_2^2 + \frac{3}{2}x_1 - x_2 - \frac{13}{4} - \frac{1}{2}\ln 4 - \ln 2$$


برای بدست آوردن مرز تصمیم داریم:

$$g_{12}(x) \equiv g_1(x) - g_2(x) = 0$$

$$\Rightarrow -3x_1^2 + 18x_1 + 16x_2 - 59 - 4\ln 2 = 0$$

$$\Rightarrow x_2 = \frac{3}{16}x_1^2 - \frac{18}{16}x_1 + \frac{59 - 4\ln 2}{16}$$

$$\Rightarrow x_2 = 0.1875x_1^2 - 1.125x_1 + 3.5142$$



تخمین توابع چگالی احتمال نامعلوم

در بیشتر موارد، توابع چگالی احتمال کلاسها ناشناخته بوده و مجبور به تخمین زدن آن از روی داده موجود می‌باشیم.

گاهی اوقات شکل توزیع (گوسی یا ریلی) معین و پارامترها (میانگین، واریانس) نامعین؛ و در برخی موارد توزیع نامعین و پارامترها (میانگین، واریانس) معین می‌باشند.

۲,۵ تخمین پارامتر با روش حداکثر شباهت (درست‌نمایی)

در یک مسئله M کلاس بردارهای ویژگی بصورت توابع شباهت $p(x|\omega_i)$ در شکل پارامتری به بردارهای ناشناخته θ_i وابسته است. هدف تخمین پارامترهای تابع بصورت $p(x|\omega_i;\theta_i)$ از روی یک مجموعه بردار ویژگی معین (مجموعه داده آموزش) برای هر کلاس می‌باشد.

فرض کنید داده هر کلاس مستقل از کلاسهای دیگر می‌باشد (جهت تخمین پارامترها)

نمونه‌های تصادفی از تابع $p(X; \theta)$ می‌باشند و تابع چگالی احتمال توام $p(X; \theta)$ را از روی مجموعه $X = \{x_1, \dots, x_N\}$ تشکیل می‌دهیم

با فرض استقلال آماری بین نمونه‌ها، داریم

$$p(X; \theta) \equiv p(x_1, x_2, \dots, x_N; \theta) = \prod_{k=1}^N p(x_k; \theta)$$

تابع بالا را تابع درست‌نمایی θ بر حسب X نامیده و روش **حداکثر درست‌نمایی** (ML) مقدار θ را برای ماکزیمم کردن این تابع تخمین می‌زند. یعنی:

$$\hat{\theta}_{ML} = \arg \max_{\theta} \prod_{k=1}^N p(x_k; \theta)$$

شرط لازم برای ماکزیمم شدن تابع بالا آن است که گرادیان تابع درست‌نمایی بر حسب θ صفر باشد. یعنی:

$$\frac{\partial \prod_{k=1}^N p(x_k; \theta)}{\partial \theta} = \mathbf{0}$$

با توجه به یکنوا بودن تابع لگاریتم، تابع درست‌نمایی لگاریتمی را به صورت زیر تعریف می‌کنیم:

$$L(\theta) \equiv \ln \prod_{k=1}^N p(x_k; \theta)$$

با جایگزینی تابع لگاریتمی به جای تابع چگالی، داریم:

$$\frac{\partial L(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}} = \sum_{k=1}^N \frac{\partial \ln p(\mathbf{x}_k; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} = \sum_{k=1}^N \frac{1}{p(\mathbf{x}_k; \boldsymbol{\theta})} \frac{\partial p(\mathbf{x}_k; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} = \mathbf{0} \quad (2.59)$$

شکل ۲.۱۴ این روش را در حالتی که پارامتر نامعلوم منحصر بفرد است شرح می دهد. بر آورد گر ML متناظر با نقطه پیک یا ماکزیمم تابع لگاریتم درستمایی می باشد.




FIGURE 2.14

The maximum likelihood estimator θ_{ML} corresponds to the peak of $p(X; \theta)$.

برآوردگر ML دارای خواص خیلی مطلوبی می باشد که در اینجا به آن ها اشاره می کنیم:
۱. برآوردگر ML مجاناً ناریب می باشد. یعنی:

$$\lim_{N \rightarrow \infty} E[\hat{\theta}_{ML}] = \theta_0$$

آماره $\hat{\theta}$ یک برآوردگر سازگار پارامتر θ است اگر و تنها اگر به ازای هر ثابت مثبت c

$$\lim_{n \rightarrow \infty} P(|\hat{\theta} - \theta| < c) = 1$$

۲. برآوردگر ML مجاناً سازگار می باشد. یعنی برای مقادیر بزرگ از N ، واریانس تخمین به صفر میل می کند:

$$\lim_{N \rightarrow \infty} E[\|\hat{\theta}_{ML} - \theta_0\|^2] = 0$$

توجه کنید که سازگاری یک خاصیت مجانبی، یعنی، خاصیت حدی یک برآوردگر است؛

قضیه: اگر $\hat{\Theta}$ برآوردگری ناریب برای پارامتر θ باشد و وقتی $n \rightarrow \infty$ ، $\text{var}(\hat{\Theta}) \rightarrow 0$ ، آنگاه $\hat{\Theta}$ برآوردگری سازگار برای θ است.

قضیه: اگر $\hat{\Theta}$ یک برآوردگر ناریب θ باشد و

$$\text{var}(\hat{\Theta}) = \frac{1}{n \cdot E \left[\left(\frac{\partial \ln f(X)}{\partial \theta} \right)^2 \right]}$$

آنگاه، $\hat{\Theta}$ یک برآوردگر ناریب با کمترین واریانس θ است.

در اینجا، کمیت واقع در مخرج کسر را اطلاع درباره θ نامند که به وسیله نمونه تأمین می شود بنابراین، هرچه واریانس کمتر باشد، اطلاع بیشتر است.

برآوردگرهای ناریب معمولاً برحسب واریانسهایشان با هم مقایسه می‌شوند. اگر $\hat{\Theta}_1$ و $\hat{\Theta}_2$ دو برآوردگر ناریب پارامتر θ باشند و واریانس $\hat{\Theta}_1$ کوچکتر از $\hat{\Theta}_2$ باشد، گوییم که $\hat{\Theta}_1$ به طور نسبی کاراتر از $\hat{\Theta}_2$ است.

۳. برآوردگر ML مجانباً کارا می‌باشد. یعنی کران پایین کرامر-رائو (کوچکترین واریانس ممکن) را برآورد می‌کند.

۴. برای مقادیر بزرگ N این برآوردگر دارای توزیع نرمال می‌باشد.

مثال ۱:

اگر X_1, X_2, \dots, X_n نمونه‌ای تصادفی از جامعه‌ای با چگالی

$$f(x) = \begin{cases} e^{-(x-\delta)} & x > \delta \\ 0 & \text{سایر جاها} \end{cases}$$

باشد، نشان دهید که \bar{X} برآوردگری اریب برای δ است.
چون میانگین جامعه عبارت است از

$$\mu = \int_{\delta}^{\infty} x \cdot e^{-(x-\delta)} dx = 1 + \delta$$

نتیجه می‌شود که $E(\bar{X}) = 1 + \delta \neq \delta$ و بنابراین \bar{X} یک برآوردگر اریب δ است.

مثال ۲:

نشان دهید که \bar{X} یک برآوردگر نااریب با کمترین واریانس، برای میانگین μ جامعه‌ای نرمال است.

حل. چون

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}, \quad -\infty < x < \infty$$

نتیجه می‌شود که

$$\ln f(x) = -\ln \sigma\sqrt{2\pi} - \frac{1}{2} \left(\frac{x-\mu}{\sigma} \right)^2$$

به طوری که

$$\frac{\partial \ln f(x)}{\partial \mu} = \frac{1}{\sigma} \left(\frac{x-\mu}{\sigma} \right)$$

و بنابراین

$$E \left[\left(\frac{\partial \ln f(X)}{\partial \mu} \right)^2 \right] = \frac{1}{\sigma^2} \cdot E \left[\left(\frac{X - \mu}{\sigma} \right)^2 \right] = \frac{1}{\sigma^2} \cdot 1 = \frac{1}{\sigma^2}$$

در نتیجه

$$\frac{1}{n \cdot E \left[\left(\frac{\partial \ln f(X)}{\partial \mu} \right)^2 \right]} = \frac{1}{n \cdot \frac{1}{\sigma^2}} = \frac{\sigma^2}{n}$$

و چون \bar{X} نااریب است و طبق قضیه $\text{var}(\bar{X}) = \frac{\sigma^2}{n}$ نتیجه می‌شود که \bar{X} یک برآوردگر نااریب با کمترین واریانس برای μ است.

مثال ۳:

برآورد ML از یک داده N نقطه‌ای با میانگین معلوم μ و واریانس نامشخص را بیابید. این نقاط توسط یک تابع چگالی احتمال گوسی یک بعدی تولید شده‌اند.

$$L(\sigma^2) = \ln \prod_{k=1}^N p(x_k; \sigma^2) = \ln \prod_{k=1}^N \frac{1}{\sqrt{2\pi}\sqrt{\sigma^2}} \exp\left(-\frac{(x_k - \mu)^2}{2\sigma^2}\right)$$

$$L(\sigma^2) = -\frac{N}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{k=1}^N (x_k - \mu)^2$$

$$-\frac{N}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{k=1}^N (x_k - \mu)^2 = 0$$

$$\hat{\sigma}_{ML}^2 = \frac{1}{N} \sum_{k=1}^N (x_k - \mu)^2$$

$$E[\hat{\sigma}_{ML}^2] = \frac{1}{N} \sum_{k=1}^N E[(x_k - \mu)^2] = \frac{N-1}{N} \sigma^2$$

تخمین بالا دارای بایاس می باشد. حال اگر N بسمت بی نهایت میل کند خواهیم داشت:

$$E[\hat{\sigma}_{ML}^2] = \left(1 - \frac{1}{N}\right)\sigma^2 \approx \sigma^2$$

مثال ۴:

فرض کنید بردارهای ناشی از یک توزیع نرمال با ماتریس کوواریانس معلوم و میانگین نامعلوم باشند. یعنی: $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N$

$$p(\mathbf{x}_k; \boldsymbol{\mu}) = \frac{1}{(2\pi)^{l/2} |\Sigma|^{1/2}} \exp\left(-\frac{1}{2}(\mathbf{x}_k - \boldsymbol{\mu})^T \Sigma^{-1}(\mathbf{x}_k - \boldsymbol{\mu})\right)$$

بر آوردن ML از بردار میانگین نامعلوم را بدست می آوریم:
به ازای N نمونه موجود خواهیم داشت:

$$L(\boldsymbol{\mu}) \equiv \ln \prod_{k=1}^N p(\mathbf{x}_k; \boldsymbol{\mu}) = -\frac{N}{2} \ln((2\pi)^l |\Sigma|) - \frac{1}{2} \sum_{k=1}^N (\mathbf{x}_k - \boldsymbol{\mu})^T \Sigma^{-1}(\mathbf{x}_k - \boldsymbol{\mu})$$

با استفاده از گرادیان تابع درستنمایی نسبت به $\boldsymbol{\mu}$ داریم:

$$\hat{\boldsymbol{\mu}}_{ML} = \frac{1}{N} \sum_{k=1}^N \mathbf{x}_k$$

مثال ۵:

اگر X_1, X_2, \dots, X_n نمونه‌ای تصادفی به اندازه‌ی n از جامعه‌ی نرمال با میانگین μ و واریانس σ^2 باشد، برآوردهای درست‌نمایی ماکسیمم توأم این دو پارامتر را پیدا کنید.

حل. چون تابع درست‌نمایی به صورت

$$L(\mu, \sigma^2) = \ln \prod_{k=1}^N \frac{1}{\sqrt{2\pi}\sqrt{\sigma^2}} \exp\left(-\frac{(x_k - \mu)^2}{2\sigma^2}\right) = -\frac{N}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{k=1}^N (x_k - \mu)^2$$

است، با گرفتن مشتق جزئی $L(\mu, \sigma^2)$ نسبت به μ و σ^2 نتیجه می‌شود که

$$\frac{\partial [L(\mu, \sigma^2)]}{\partial \mu} = \frac{1}{\sigma^2} \cdot \sum_{k=1}^N (x_k - \mu)$$

$$\frac{\partial [L(\mu, \sigma^2)]}{\partial \sigma^2} = -\frac{N}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{k=1}^N (x_k - \mu)^2$$

از برابر گرفتن اولین مشتق جزئی با صفر و حل آن برحسب μ به دست می آوریم.

$$\hat{\mu}_{ML} = \frac{1}{N} \sum_{k=1}^N x_k$$

و با برابر گرفتن دومین مشتق جزئی با صفر و حل آن برحسب σ^2

$$\hat{\sigma}_{ML}^2 = \frac{1}{N} \sum_{k=1}^N (x_k - \hat{\mu}_{ML})^2$$

لازم است توجه شود که ما ثابت نکرده ایم که $\hat{\sigma}$ یک برآورد درست‌نمایی ماکسیمم است، بلکه تنها ثابت کرده ایم که $\hat{\sigma}^2$ یک برآورد درست‌نمایی ماکسیمم σ^2 است. با این حال، می‌توان نشان داد که برآوردکننده‌های درست‌نمایی ماکسیمم دارای این خاصیت ناوردایی هستند که اگر $\hat{\Theta}$ یک برآوردکننده درست‌نمایی ماکسیمم θ و تابع مفروض $g(\theta)$ پیوسته باشد، آنگاه $g(\hat{\Theta})$ نیز یک برآوردکننده درست‌نمایی ماکسیمم $g(\theta)$ است. از اینجا نتیجه می‌گیریم که

$$\hat{\sigma} = \sqrt{\frac{1}{n} \cdot \sum_{i=1}^n (x_i - \bar{x})^2}$$

نیز یک برآورد درست‌نمایی ماکسیمم σ است، که از s متفاوت است زیرا در آن، Σ را به جای $n-1$ بر n تقسیم می‌کنیم.

مثال ۶:

اگر x_1, x_2, \dots, x_n مقادیر یک نمونه‌ی تصادفی از جامعه‌ای نمایی باشند، برآورد درست‌نمایی ماکسیمم پارامتری θ ی جامعه را پیدا کنید.
حل. چون تابع درست‌نمایی به صورت

$$L(\theta) = f(x_1, x_2, \dots, x_n; \theta) = \prod_{i=1}^n f(x_i; \theta) = \left(\frac{1}{\theta}\right)^n \cdot e^{-\frac{1}{\theta}(\sum_{i=1}^n x_i)}$$

است، با مشتق‌گیری از $\ln L(\theta)$ نسبت به θ

$$\frac{d[\ln L(\theta)]}{d\theta} = -\frac{n}{\theta} + \frac{1}{\theta^2} \cdot \sum_{i=1}^n x_i$$

به دست می‌آید. از برابر گرفتن این مشتق با صفر و حل آن نسبت به θ ، برآورد درست‌نمایی ماکسیمم زیر را به دست می‌آوریم

$$\hat{\theta} = \frac{1}{n} \cdot \sum_{i=1}^n x_i = \bar{x}.$$

بنابراین، برآوردکننده‌ی درست‌نمایی ماکسیمم عبارت است از $\hat{\Theta} = \bar{X}$.

مثال ۷:

با مفروض بودن x «موفقیت» در n آزمایش، برآورد درست‌نمایی ماکسیمم پارامتر θ را در توزیع دو جمله‌ای نظیر پیدا کنید.

حل. برای پیدا کردن مقداری از θ که

$$L(\theta) = \binom{n}{x} \theta^x (1-\theta)^{n-x}$$

را ماکسیمم می‌کند، بهتر است از این واقعیت استفاده کنیم که مقدار θ که $L(\theta)$ را ماکسیمم می‌کند، تابع

$$\ln L(\theta) = \ln \binom{n}{x} + x \cdot \ln \theta + (n-x) \cdot \ln(1-\theta)$$

را نیز ماکسیمم می‌کند. بنابراین، نتیجه می‌گیریم که

$$\frac{d[\ln L(\theta)]}{d\theta} = \frac{x}{\theta} - \frac{n-x}{1-\theta}$$

و با برابرگرفتن این مشتق با 0 و حل آن نسبت به θ ، درمی یابیم که تابع درستنمایی دارای ماکسیمم در $\theta = \frac{x}{n}$ است. این مقدار، برآورد درستنمایی ماکسیمم پارامتر θ در توزیع دوجمله‌ای است و $\hat{\Theta} = \frac{X}{n}$ را برآوردکننده‌ی درستنمایی ماکسیمم نظیر می‌نامیم.

تخمین ماکزیمم احتمال پسین (Maximum A Posteriori Probability)

برای رسیدن به برآورد ML، θ را پارامتر نامعلوم در نظر می گیریم. در این تخمین θ را بردار تصادفی فرض می کنیم و مقدارش را بشرط مشاهده نمونه های داده تخمین می زنیم. نقطه شروع ما $p(\theta | X)$ می باشد. با توجه به قضیه بیز داریم:

$$p(\theta)p(X|\theta) = p(X)p(\theta|X)$$

$$p(\theta|X) = \frac{p(\theta)p(X|\theta)}{p(X)}$$

درستنمایی

تخمین ماکزیمم احتمال پسین (MAP) در نقطه ای تعریف می شود که احتمال $p(\theta|X)$ را ماکزیمم کند:

$$\hat{\theta}_{MAP} : \frac{\partial}{\partial \theta} p(\theta|X) = 0 \quad \text{or} \quad \frac{\partial}{\partial \theta} (p(\theta)p(X|\theta)) = 0$$

لازم به ذکر است که اختلاف تخمین های ML و MAP در وجود $p(\theta)$ می باشد.





FIGURE 2.15

ML and MAP estimates of θ will be approximately the same in (a) and different in (b).



likelihood $p(\mathcal{D}|\theta)$ as a function of the mean

$\boldsymbol{\theta} = (\theta_1, \dots, \theta_p)^t$ فرض کنید:

$$l(\boldsymbol{\theta}) \equiv \ln p(\mathcal{D}|\boldsymbol{\theta})$$

$$p(\mathcal{D}|\boldsymbol{\theta}) = \prod_{k=1}^n p(\mathbf{x}_k|\boldsymbol{\theta}).$$

$$\nabla_{\boldsymbol{\theta}} l = \sum_{k=1}^n \nabla_{\boldsymbol{\theta}} \ln p(\mathbf{x}_k|\boldsymbol{\theta}).$$

$$\hat{\boldsymbol{\theta}} = \arg \max_{\boldsymbol{\theta}} l(\boldsymbol{\theta}),$$

$$\nabla_{\boldsymbol{\theta}} l = \mathbf{0}.$$

مثال ۸

فرض کنید تابع مورد نظر دارای توزیع نرمال با μ نامعلوم باشد:

$$\ln p(\mathbf{x}_k | \boldsymbol{\mu}) = -\frac{1}{2} \ln [(2\pi)^d |\boldsymbol{\Sigma}|] - \frac{1}{2} (\mathbf{x}_k - \boldsymbol{\mu})^t \boldsymbol{\Sigma}^{-1} (\mathbf{x}_k - \boldsymbol{\mu})$$

$$\nabla_{\boldsymbol{\theta}} \ln p(\mathbf{x}_k | \boldsymbol{\mu}) = \boldsymbol{\Sigma}^{-1} (\mathbf{x}_k - \boldsymbol{\mu}).$$

$$\sum_{k=1}^n \boldsymbol{\Sigma}^{-1} (\mathbf{x}_k - \hat{\boldsymbol{\mu}}) = \mathbf{0},$$

$$\hat{\boldsymbol{\mu}} = \frac{1}{n} \sum_{k=1}^n \mathbf{x}_k.$$

مثال ۹

فرض کنید تابع مورد نظر دارای توزیع نرمال با μ و ماتریس کوواریانس نامعلوم باشد:

$$\theta_1 = \mu \quad \text{و} \quad \theta_2 = \sigma^2$$

$$\ln p(x_k | \boldsymbol{\theta}) = -\frac{1}{2} \ln 2\pi\theta_2 - \frac{1}{2\theta_2} (x_k - \theta_1)^2$$

$$\nabla_{\boldsymbol{\theta}} l = \nabla_{\boldsymbol{\theta}} \ln p(x_k | \boldsymbol{\theta}) = \begin{bmatrix} \frac{1}{\theta_2} (x_k - \theta_1) \\ -\frac{1}{2\theta_2} + \frac{(x_k - \theta_1)^2}{2\theta_2^2} \end{bmatrix}.$$

$$\sum_{k=1}^n \frac{1}{\hat{\theta}_2} (x_k - \hat{\theta}_1) = 0$$

$$-\sum_{k=1}^n \frac{1}{\hat{\theta}_2} + \sum_{k=1}^n \frac{(x_k - \hat{\theta}_1)^2}{\hat{\theta}_2^2} = 0,$$

که در آن $\hat{\theta}_1$ و $\hat{\theta}_2$ برآورد های ML برای θ_1 و θ_2 می باشند. با جایگزینی $\hat{\mu} = \hat{\theta}_1$, $\hat{\sigma}^2 = \hat{\theta}_2$ خواهیم داشت:

$$\hat{\mu} = \frac{1}{n} \sum_{k=1}^n x_k$$

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{k=1}^n (x_k - \hat{\mu})^2.$$

آنتروپی

جدول ۱-۱. ماتریس تصمیم‌گیری چند شاخصه

شاخص‌ها / گزینه‌ها	C_1	$C_2 \dots$	$C_j \dots$	C_n
A_1	a_{11}	$a_{12} \dots$	$a_{1j} \dots$	a_{1n}
A_2	a_{21}	$a_{22} \dots$	$a_{2j} \dots$	a_{2n}
\vdots	\vdots	\vdots	\vdots	\vdots
A_i	a_{i1}	$a_{i2} \dots$	$a_{ij} \dots$	a_{in}
\vdots	\vdots	\vdots	\vdots	\vdots
A_m	a_{m1}	$a_{m2} \dots$	$a_{mj} \dots$	a_{mn}

می‌توان گفت A_i نشان‌دهنده‌ی گزینه i ام، c_j نشان‌دهنده‌ی شاخص j ام و a_{ij} نشان‌دهنده ارزش گزینه i ام، از نظر شاخص j ام می‌باشد.

مثال ۱-۱

فرض کنید یک دانش‌آموخته‌ی دانشگاهی، قصد دارد از بین ۴ شغل، با توجه به ۵ شاخص، یکی را انتخاب کند. «شاخص‌ها» عبارتند از درآمد، وجهه‌ی اجتماعی، سختی کار، مسافت و امنیت اجتماعی (درآمد، برحسب ده‌هزار تومان و مسافت، برحسب کیلومتر است). ارزش هر شغل از نظر هر شاخص، در جدول ۱-۲ آمده است.

جدول ۱-۲. ماتریس تصمیم برای مثال ۱-۱

A_i / C_j	C_1	C_2	C_3	C_4	C_5
A_1	۱۵	زیاد	نسبتاً زیاد	۱۰	زیاد
A_2	۱۲	متوسط	متوسط	۳	خیلی زیاد
A_3	۲۰	خیلی زیاد	زیاد	۳۰	متوسط
A_4	۳۰	کم	خیلی زیاد	۱	کم

در ماتریس تصمیم (جدول ۱-۲)، ملاحظه می‌شود که از پنج شاخص موجود (C_j)، دو شاخص (C_1 و C_4) کمی بوده و بقیه‌ی آن‌ها، کیفی می‌باشد.

اغلب، شاخص‌ها در مدل‌های MADM از مقیاس‌های مختلف بوده و غالباً در تعارض با یکدیگرند. در اغلب مواقع، گزینه‌ای که بهینه باشد (ایده‌آل از هر شاخص را تامین کند)، وجود ندارد. علاوه بر این برخی شاخص‌ها جنبه‌ی مثبت (C_j^+) و برخی جنبه‌ی منفی (C_j^-) دارند. بنابراین «گزینه‌ی بهینه» در یک مدل MADM، یک گزینه‌ی ذهنی A خواهد بود که بهترین ارزش از هر شاخص را تامین کند. در اکثر مواقع، دسترسی به A غیرممکن است؛ اما انتخاب مناسب‌ترین گزینه به‌طور نسبی در هر صورت، امکان‌پذیر خواهد بود.


۱-۵. تبدیل شاخص‌های کیفی به کمی

همان‌طور که گفتیم، می‌توان راهکارهای انتخابی را توسط دو نوع شاخص توصیف کرد:

۱- شاخص‌های کمی (قیمت، درآمد، مسافت، و....)،

۲- شاخص‌های کیفی (وجهه‌ی اجتماعی، سختی، امنیت، زیبایی، و....).

می‌توان با استفاده از روش‌های مختلفی، شاخص‌های کیفی را به شاخص‌های کمی تبدیل کرد؛ ولی بهترین روش، روش‌هایی هستند که از مقیاس‌های فاصله‌ای و رتبه‌ای یا مقیاس دوقطبی استفاده می‌نمایند. یک روش عمومی در اندازه‌گیری یک شاخص کیفی با مقیاس فاصله‌ای، استفاده از «مقیاس دوقطبی فاصله‌ای» است که به قرار زیر می‌باشد:



این اندازه‌گیری، براساس یک مقیاس یازده نقطه‌ای می‌باشد که صفر، کمترین ارزش و ۱۰، بیشترین ارزش را به خود اختصاص می‌دهد. این اندازه‌گیری، برای

۷-۱. ارزیابی اوزان شاخص‌ها

همان‌طور که در قسمت‌های قبل گفته شد، هر مساله‌ای که فرد تصمیم‌گیرنده با آن مواجه است، ممکن است دارای چندین شاخص باشد. بنابراین، «دانستن اهمیت نسبی شاخص‌ها»، ضرورت دارد. از این رو، به هر شاخص، یک وزن داده می‌شود، به صورتی که مجموع اوزان شاخص‌ها، برابر با یک باشد. این وزن‌ها، اهمیت نسبی (درجه‌ی ارجحیت) هر شاخص را نسبت به بقیه، برای تصمیم‌گیری مورد نظر نشان می‌دهد. برای ارزیابی اوزان شاخص‌ها، روش‌های مختلفی وجود دارد که برخی از آن‌ها عبارتند از:

الف) روش آنتروپی

ب) روش لینمپ^۱

ج) روش کمترین مجذورات موزون

د) روش بردار ویژه.

روش آنتروپی و لینمپ، براساس «ماتریس تصمیم‌گیری» است در حالی که روش کمترین مجذورات موزون و روش بردار ویژه، نیاز به ماتریس تصمیم‌گیری ندارد. اکنون روش آنتروپی توضیح داده می‌شود، روش بردار ویژه (که گاهی روش AHP گفته می‌شود) در قسمت ۴-۸-۱ توضیح داده می‌شود.

روش آنتروپی

«آنتروپی^۲» یک، مفهوم بسیار با اهمیت در علوم اجتماعی، فیزیک و تئوری اطلاعات می‌باشد. وقتی که داده‌های یک ماتریس تصمیم‌گیری، به طور کامل مشخص شده باشد، می‌توان از روش آنتروپی، برای ارزیابی وزن‌ها استفاده کرد.

ایده‌ی روش فوق، این است که هر چه پراکندگی در مقادیر یک شاخص، بیشتر باشد، آن شاخص از اهمیت بیشتری برخوردار است.

آنتروپی در نظریه‌ی اطلاعات، یک معیار عدم اطمینان است که با توزیع احتمال مشخص P_i بیان می‌شود.

اندازه‌گیری این عدم اطمینان (E_i) ، توسط شانون^۱، به صورت زیر بیان شده است:

$$E_i = S(p_1, p_2, \dots, p_n) = -k \sum_{i=1}^n [p_i \times \ln p_i]$$

k مقداری ثابت است و به منظور این که E_i بین صفر و یک باشد، اعمال می‌شود. E از توزیع احتمال p_i براساس مکانیزم آماری، محاسبه شده و مقدار آن در صورت تساوی p_i ها با یکدیگر (یعنی $p_i = \frac{1}{n}$)، ماکزیمم مقدار ممکن خواهد بود که بدین صورت محاسبه می‌شود:

$$\begin{aligned} -k \sum_{i=1}^n p_i - \ln p_i &= -k \left\{ \frac{1}{n} \ln \frac{1}{n} + \frac{1}{n} \ln \frac{1}{n} + \dots + \frac{1}{n} \ln \frac{1}{n} \right\} = -k \left\{ \ln \frac{1}{n} \left(\frac{n}{n} \right) \right\} \\ &= -k \times \ln \frac{1}{n} \end{aligned}$$

k به عنوان مقدار ثابت، به صورت زیر محاسبه می‌شود:

$$k = \frac{1}{\ln(m)}$$

«ماتریس تصمیم‌گیری»، حاوی اطلاعاتی است که آنتروپی می‌تواند به عنوان معیاری برای ارزیابی آن به کار رود. فرض کنید که ماتریس تصمیم‌گیری، به این صورت باشد:

شاخصها / گزینه‌ها	C_1	C_v	...	C_n
A_1	a_{11}	a_{1v}	...	a_{1n}
A_2	a_{21}	a_{2v}	...	a_{2n}
\vdots	\vdots	\vdots	...	\vdots
A_m	a_{m1}	a_{mv}	...	a_{mn}

با استفاده از این ماتریس، P_{ij} به صورت زیر محاسبه می‌شود:

$$P_{ij} = \frac{a_{ij}}{\sum_{i=1}^m a_{ij}} \quad ; \quad \forall i, j$$

و آنتروپی شاخص J (E_j) به صورت زیر محاسبه می‌شود:

$$E_j = -k \sum_{i=1}^m [p_{ij} \ln p_{ij}] \quad ; \quad \forall j$$

عدم اطمینان یا درجه‌ی انحراف (d_j) از اطلاعات به‌دست آمده برای شاخص J ، بیان می‌کند که شاخص مربوطه (J)، چه میزان اطلاعات مفید برای تصمیم‌گیری، در اختیار تصمیم‌گیرنده قرار می‌دهد. مقدار (d_j) به صورت زیر به‌دست می‌آید:

$$d_j = 1 - E_j \quad ; \quad \forall j$$

سپس مقدار وزن W_j به صورت زیر به‌دست می‌آید:

$$w_j = \frac{d_j}{\sum_{j=1}^n d_j} \quad ; \quad \forall j$$

اگر تصمیم‌گیرنده از قبل، وزن ذهنی مشخصی مثل λ_j را برای شاخص J در نظر گرفته باشد، در این صورت وزن تعدیل شده (w_j)، به شرح زیر محاسبه می‌شود:

$$w_j = \frac{\lambda_j w_j}{\sum_{j=1}^n \lambda_j w_j} \quad ; \quad \forall_j$$

به طور خلاصه، می‌توان برای به دست آوردن اوزان شاخص‌ها، گام‌های زیر را طی کرد:

$$P_{ij} = \frac{a_{ij}}{\sum_{i=1}^m a_{ij}} \quad ; \quad \forall_j \quad \text{گام ۱- محاسبه‌ی } P_{ij}$$

$$E_j = -k \sum_{i=1}^m [p_{ij} \ln p_{ij}] \quad ; \quad \forall_j \quad \text{گام ۲- محاسبه‌ی مقدار آنتروپی } E_j$$

$$d_j = 1 - E_j \quad ; \quad \forall_j \quad \text{گام ۳- محاسبه‌ی مقدار عدم اطمینان } d_j$$

$$w_j = \frac{d_j}{\sum_{j=1}^n d_j} \quad ; \quad \forall_j \quad \text{گام ۴- محاسبه‌ی اوزان } w_j$$

$$w_j = \frac{\lambda_j w_j}{\sum_{j=1}^n \lambda_j w_j} \quad ; \quad \forall_j \quad \text{گام ۵- محاسبه‌ی اوزان تعدیل شده } w_j$$

λ_j اوزان ذهنی (قضاوتی) می‌باشند (توجه: در صورتی که اوزان ذهنی (قضاوتی) موجود نباشد، مرحله‌ی ۵ منتفی است.)

دقت کنید که در روش آنتروپی، مثبت یا منفی بودن شاخص‌ها، تاثیری در روش محاسبه‌ی وزن‌ها نخواهد داشت.

مثال ۴-۱

دوباره مساله‌ی فرد دانش آموخته را در نظر بگیرید و با روش آنتروپی، وزن شاخص‌ها را حساب کنید.

جدول ۶-۱. ماتریس تصمیم فرد دانش آموخته

$A_i \backslash C_j$	C_1	C_2	C_3	C_4	C_5
A_1	۱۵	زیاد	نسبتاً زیاد	۱۰	زیاد
A_2	۱۲	متوسط	متوسط	۳	خیلی زیاد
A_3	۲۰	خیلی زیاد	زیاد	۳۰	متوسط
A_4	۳۰	کم	خیلی زیاد	۱	کم

ابتدا مقادیر شاخص‌های کیفی را طبق روش‌های گفته شده، به کمی تبدیل می‌کنیم. نتایج آن، در جدول ۶-۷ آورده شده است.

جدول ۶-۷. ماتریس کمی

$A_i \backslash C_j$	C_1	C_2	C_3	C_4	C_5
A_1	۱۵	۷	۴	۱۰	۷
A_2	۱۲	۵	۵	۳	۹
A_3	۲۰	۹	۳	۳۰	۵
A_4	۳۰	۳	۱	۱	۳
Σ	۷۷	۲۴	۱۳	۴۴	۲۴

گام اول : در این مرحله، با استفاده از فرمول زیر، مقدار P_{ij} را برای تمامی شاخص‌ها و راهکارها به دست می‌آوریم.

$$P_{ij} = \frac{a_{ij}}{\sum_{i=1}^n a_{ij}} \Rightarrow P_{11} = \frac{15}{77} = 0/195, \quad P_{21} = \frac{12}{77} = 0/156$$

$$P_{31} = \frac{20}{77} = 0/260, \quad P_{41} = \frac{30}{77} = 0/389$$

نتایج گام اول، در جدول ۶-۸ آورده شده است.

جدول ۱-۸. نتایج گام اول

$A_i \backslash C_j$	C_1	C_2	C_3	C_4	C_5
A	۰/۱۹۵	۰/۲۹۲	۰/۳۰۸	۰/۲۲۷	۰/۲۹۲
A	۰/۱۵۶	۰/۲۰۸	۰/۳۸۵	۰/۰۶۸	۰/۳۷۵
A	۰/۲۶۰	۰/۳۷۵	۰/۲۳۱	۰/۶۸۲	۰/۲۰۸
A	۰/۳۸۹	۰/۱۲۵	۰/۰۷۷	۰/۰۲۳	۰/۱۲۵

گام دوم: در این گام، با استفاده از فرمول $E_j = -k \sum [p_{ij} \ln p_{ij}]$ ، مقدار اطمینان را به دست می آوریم:

$$E_1 = -0.771 [0.195 \ln(0.195) + 0.156 \ln(0.156) + 0.260 \ln(0.260) + 0.389 \ln(0.389)] = 0.956$$

$$E_2 = -0.771 [0.292 \ln(0.292) + 0.208 \ln(0.208) + 0.375 \ln(0.375) + 0.125 \ln(0.125)] = 0.947$$

$$E_3 = -0.771 [0.308 \ln(0.308) + 0.385 \ln(0.385) + 0.231 \ln(0.231) + 0.077 \ln(0.077)] = 0.913$$

$$E_4 = -0.771 [0.227 \ln(0.227) + 0.068 \ln(0.068) + 0.682 \ln(0.682) + 0.023 \ln(0.023)] = 0.625$$

$$E_5 = -0.771 [0.292 \ln(0.292) + 0.375 \ln(0.375) + 0.208 \ln(0.208) + 0.125 \ln(0.125)] = 0.947$$

همان طور که گفتیم، K به این ترتیب به دست می آید: $k = \frac{1}{\ln(m)} = \frac{1}{\ln(5)} = 0.771$

جدول ۱-۹. نتایج گام دوم

E_1	E_2	E_3	E_4	E_5
۰/۹۵۶	۰/۹۴۷	۰/۹۱۳	۰/۶۲۵	۰/۹۴۷

گام سوم: در این گام، مقدار عدم اطمینان d را به دست می آوریم (جدول ۱-۱۰).

جدول ۱۰-۱. نتایج گام سوم

d_j	d_1	d_2	d_3	d_4	d_5	$\sum d_j$
$1 - E_j$	۰/۰۴۴	۰/۰۵۳	۰/۰۸۷	۰/۳۷۵	۰/۰۵۳	۰/۶۱۲

گام چهارم: اکنون اوزان شاخص‌ها را به دست می‌آوریم:

$$w_j = \frac{d_j}{\sum d_j} \Rightarrow w_1 = \frac{0/044}{0/612} = 0/072 \quad w_2 = \frac{0/053}{0/612} = 0/087$$

$$w_3 = \frac{0/087}{0/612} = 0/142 \quad w_4 = \frac{0/375}{0/612} = 0/613 \quad w_5 = \frac{0/053}{0/612} = 0/087$$

جدول ۱۱-۱. نتایج گام چهارم

w_1	w_2	w_3	w_4	w_5
۰/۰۷۲	۰/۰۸۷	۰/۱۴۲	۰/۶۱۳	۰/۰۸۷

توجه داشته باشید که $\sum_{j=1}^n w_j = 1$ می‌باشد. اگر تصمیم‌گیرنده هیچ اوزان قضاوتی (ذهنی) ارائه نکرده باشد همین اوزان را به عنوان اوزان شاخص‌ها در نظر می‌گیریم؛ اما اگر از سوی فرد تصمیم‌گیرنده اوزانی پیشنهاد شده باشد، به گام بعدی می‌رویم.

گام پنجم: در این قسمت، اوزان تعدیل شده را محاسبه می‌کنیم. فرض کنید که تصمیم‌گیرنده به شاخص‌ها، وزن‌های ۰/۱، ۰/۲، ۰/۱۵، ۰/۳، و ۰/۲۵ را به ترتیب برای شاخص اول تا پنجم نسبت داده باشد. در این حالت، ابتدا باید $\sum \lambda_j w_j$ را به دست آوریم و سپس اوزان تعدیل شده را محاسبه کنیم.

جدول ۱۲-۱. نتایج گام پنجم

	۵	۴	۳	۲	۱	جمع
λ_j	۰/۱	۰/۲	۰/۱۵	۰/۳۰	۰/۲۵	۱
w_j	۰/۰۷۲	۰/۰۸۷	۰/۱۴۲	۰/۶۱۳	۰/۰۸۷	۱
$\lambda_j w_j$	۰/۰۰۷	۰/۰۱۷	۰/۰۲۱	۰/۱۸۴	۰/۰۲۲	۰/۲۵۱
w_j^f	۰/۰۲۸	۰/۰۶۸	۰/۰۸۴	۰/۷۳۳	۰/۰۸۷	۱

برای مثال، w_1^f و w_p^f به این صورت محاسبه شده‌اند:

$$w_1^f = \frac{\lambda_1 w_1}{\sum \lambda_j w_j} = \frac{0/007}{0/251} = 0/028 \quad \text{و} \quad w_p^f = \frac{\lambda_p w_p}{\sum \lambda_j w_j} = \frac{0/017}{0/251} = 0/068$$

بنا به تجربه‌ی نگارنده، روش آنروپی به شاخص‌ها وزن‌های دور از انتظاری می‌دهد. روش AHP (که بعداً گفته می‌شود) وزن‌های معقول‌تری برای شاخص‌ها نسبت به آنروپی محاسبه می‌کند؛ زیرا اساس کارش، نظرات تصمیم‌گیرنده (و نه ماتریس تصمیم‌گیری) است.

با تشکر