

# همبستگی ماکسیمال

یاشار طالبی‌راد و حسین نادری

## چکیده

در این مقاله ابتدا به بررسی علت مهم بودن همبستگی ماکسیمال<sup>۱</sup> و یکی از کاربردهای آن در تئوری اطلاعات اشاره می‌کنیم و به تعریف آن می‌پردازیم. سپس خواص ابتدایی آن را اثبات می‌کنیم و در انتها چند نامساوی پرکاربرد را بیان و اثبات می‌کنیم.

## ۱ مقدمه

موضعی روی داده‌ها، متغیرهای تصادفی جدیدی می‌سازند که به  $A$  و  $B$  نزدیک باشند. عملیات موضعی روی متغیر تصادفی‌ای مثل  $X$  به معنی اعمال تابعی مانند  $f$  روی  $X$  و به دست آوردن  $X' = f(X)$  است. حال فرض کنید آلیس و باب به جای این که فقط یک نمونه از  $X$  و  $Y$  داشته باشند، بتوانند به تعداد دلخواهی از آن نمونه تولید کنند؛ یعنی  $X^n$  و  $Y^n$  را داشته باشند. یک مدل پرکاربرد برای این مسأله، شبیه‌سازی غیرتعاملی<sup>۴</sup> نام دارد. شبیه‌سازی غیرتعاملی وقتی اتفاق می‌افتد که به ازای هر  $\epsilon > 0$ ، توابع قطعی  $f, g$  وجود داشته باشند که  $d_{TV}((f(X^n), g(Y^n)), (A, B)) < \epsilon$  که در تعریف بالا  $d_{TV}$  برابر است با

$$d_{TV}(A, B) = \sup_{T \in \mathcal{F}} \{|\mathcal{P}_A(T) - \mathcal{P}_B(T)|\}$$

قضیه ۱. شبیه‌سازی غیرتعاملی امکان‌پذیر است اگر و فقط اگر  $(A, B)$  در بستار<sup>۵</sup> مجموعه‌ی زیر باشد:

$$\{(A', B') \mid A' \rightarrow X^n \rightarrow Y^n \rightarrow B'\}$$

اما بررسی شرط فوق نیز آسان نیست چون نمی‌توان اعضای

یکی از مباحث مهم در تئوری اطلاعات، حفظ حریم داده<sup>۲</sup> است. مسأله‌هایی که در این مبحث مطرح می‌شوند را معمولاً به این شکل شبیه‌سازی می‌کنند که دو نفر (مثل آلیس و باب) که از دو منبع اطلاعاتی مختلف (مثل  $X$  و  $Y$ ) که توزیع توأم آن‌ها داده شده اطلاعات دریافت می‌کنند، آیا می‌توانند دو متغیر تصادفی  $A$  و  $B$  را که توزیع آن‌ها نیز داده شده است شبیه‌سازی کنند یا خیر؛ و اگر پاسخ بله است چگونه این کار را انجام دهند. معیارهای وابستگی<sup>۳</sup> مانند همبستگی ماکسیمال در پاسخ‌دادن به چنین سؤال‌هایی کمک می‌کنند.

## ۲ مدل‌سازی ریاضی

با توجه به این که شبیه‌سازی صد درصدی معمولاً در کاربردهای واقعی غیرممکن است، در اکثر موارد کفایت فقط به مقدار لازم به توزیع  $A$  و  $B$  نزدیک شویم. یعنی آلیس و باب با انجام عملیات

<sup>1</sup>Maximal Correlation

<sup>2</sup>Data Privacy

<sup>3</sup>Measures of Dependence

<sup>4</sup>Non-interactive Simulation

<sup>5</sup>Closure

این نامساوی به نامساوی پردازش اطلاعات<sup>۶</sup> معروف است. با استفاده از این نامساوی، می‌توان به کران‌هایی در قضیه ۱ دست یافت. اما هر معیار وابستگی این ویژگی را ندارد. برای مثال ضریب همبستگی پیرسون ویژگی‌های ۱ و ۲ را ندارد. یکی دیگر از این معیارهای وابستگی، اطلاعات متقابل<sup>۸</sup> است. با استفاده از نامساوی پردازش اطلاعات برای اطلاعات متقابل در قضیه ۱ می‌توان گفت

$$I(A, B) \leq I(X^n; Y^n) = nI(X; Y)$$

اما سمت راست نامساوی وقتی  $n \rightarrow \infty$  برابر صفر یا بینهایت می‌شود. پس این معیار کمک چندانی نمی‌کند.

در [۳] بیان شده که یک خاصیت خوب دیگر می‌تواند خاصیت تانسوری<sup>۹</sup> باشد. گفته می‌شود معیار وابستگی  $C$  خاصیت تانسوری دارد وقتی  $C(X^n; Y^n) = C(X; Y)$ . به این ترتیب اطلاعات متقابل به علت جمعی<sup>۱۰</sup> بودن، تانسوری نیست. یک معیار مشابه که این مشکل را حل می‌کند، همبستگی ماکسیمال نام دارد که اثباتی از تانسوری بودن آن در [۵] ارائه شده است. تازگی ثابت شده است که مفهومی به نام نوار ابرانقباض پذیری<sup>۱۱</sup> کران‌های بهتری از همبستگی ماکسیمال نتیجه می‌دهد. به تعدادی از این کران‌ها در [۵] اشاره شده است.

## ۴ تعاریف اولیه

تعریف ۱. همبستگی ماکسیمال بین دو متغیر تصادفی  $X, Y$  عبارت است از بیشینه‌ی ضریب همبستگی پیرسون بین  $f(X)$  و  $g(Y)$  روی همه توابع  $f$  و  $g$ .

مجموعه‌ی بالا را به سادگی مشخص کرد. اما به‌جای مشخص کردن اعضا، می‌توان کران‌هایی پیدا کرد که اعضای آن مجموعه باید در آن کران‌ها صدق کنند. به این ترتیب اگر  $A, B$  و  $X$  و  $Y$  داده‌شده ای در آن کران‌ها صدق نکرد، می‌توان مطمئن بود که  $(A, B)$  در آن مجموعه نیست و بنابراین شبیه‌سازی غیرتعاملی امکان‌پذیر نیست. معیارهای وابستگی در یافتن این نوع کران‌ها کمک می‌کنند.

## ۳ معیارهای وابستگی

تاکنون معیارهای متعددی برای اندازه‌گیری میزان وابستگی دو متغیر تصادفی تعریف شده است. برای مثال یکی از پرکاربردترین آن‌ها، ضریب همبستگی پیرسون<sup>۶</sup>

$$\rho(X; Y) = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y}$$

است. هر معیار وابستگی خوب است چند ویژگی زیر را داشته باشد:

۱. تحت عملیات موضعی عوض نشود.
۲. میزان وابستگی ۰ است اگر و فقط اگر دو متغیر مستقل باشند.
۳. میزان وابستگی ۱ است اگر و فقط اگر رابطه‌ی قطعی‌ای بین دو متغیر تصادفی وجود داشته باشد.

بنابراین خاصیت ۱ بیان می‌کند که وابستگی دو متغیر تصادفی در یک زنجیر مارکوف، یا گذر از یک کانال، یا انجام عملیات موضعی زیاد نشود. به طور دقیق‌تر برای هر معیار وابستگی  $C$  و هر زنجیر مارکوف  $X \rightarrow Y \rightarrow Z$  باید داشته باشیم:

$$C(X; Z) \leq C(X; Y)$$

<sup>6</sup>Pearson Correlation Coefficient

<sup>7</sup>Data-Processing Inequality

<sup>8</sup>Mutual Information

<sup>9</sup>Tensorization

<sup>10</sup>Additive

<sup>11</sup>Hypercontractivity Band

به عبارت دیگر

$$\begin{aligned}\rho_m(X; Y) &= \max_{f, g} |\rho(f(X); g(Y))| \\ &= \max_{f, g} \frac{|\text{Cov}(f(X), g(Y))|}{\sigma_{f(X)} \sigma_{g(Y)}}\end{aligned}$$

برای بررسی چند خاصیت ابتدایی درباره‌ی استقلال، نیاز به تعریف تابع مشخصه<sup>۱۴</sup> داریم. تابع مشخصه‌ی متغیر تصادفی  $X$  عبارت است از

$$\varphi_X(s) = E[e^{isX}]$$

همچنین برای بردار تصادفی  $(X, Y)$  به این صورت تعریف می‌شود

$$\varphi_{X, Y}(s, t) = E[e^{isX} \times e^{itY}]$$

تابع مشخصه مانند تابع توزیع احتمال، رفتار متغیر تصادفی را به طور یکتا مشخص می‌کند. به این معنی که  $X_1$  و  $X_2$  هم‌توزیع‌اند اگر و فقط اگر  $\varphi_{X_1} = \varphi_{X_2}$ .

لم ۱. متغیرهای تصادفی  $X$  و  $Y$  مستقل‌اند اگر و فقط اگر به‌ازای هر  $s$  و  $t$  داشته باشیم  $\varphi_{X, Y}(s, t) = \varphi_X(s)\varphi_Y(t)$ .

برهان. ابتدا فرض کنید  $X$  و  $Y$  مستقل باشند. چون هر تابع‌هایی از متغیرهای مستقل خود نیز مستقل‌اند، برای هر  $t$  و  $s$  دو متغیر  $e^{isX}$  و  $e^{itY}$  نیز مستقل‌اند. در نتیجه

$$E[e^{isX} e^{itY}] = E[e^{isX}] E[e^{itY}]$$

برای طرف دیگر ابتدا توجه کنید ضرب توزیع متغیرهای تصادفی  $X \sim P_X$  و  $Y \sim P_Y$  یعنی  $P_X \times P_Y$  تابع مشخصه‌ای برابر  $E[e^{isX}] E[e^{itY}]$  دارد که طبق فرض همان تابع مشخصه بردار تصادفی  $(X, Y)$  است. چون تبدیل فوریه<sup>۱۵</sup> وارون‌پذیر است لذا تابع مشخصه یکتاست و  $P_X \times P_Y = P_{(X, Y)}$  که یعنی  $X$  و  $Y$  مستقل‌اند و حکم ثابت می‌شود. ■

قضیه ۲. متغیرهای تصادفی حقیقی  $X$  و  $Y$  مستقل‌اند اگر و فقط اگر  $\rho_m(X; Y) = 0$ .

برهان. ابتدا فرض کنید  $X$  و  $Y$  مستقل باشند. چون هر تابع‌هایی از متغیرهای مستقل، خود نیز مستقل‌اند، برای هر  $f$  و  $g$  داریم  $E[f(X)g(Y)] = E[f(X)]E[g(Y)]$  و در نتیجه

$$\forall f, g: \quad \rho(f(X); g(Y)) = \frac{\text{Cov}(f(X), g(Y))}{\sigma_X \sigma_Y} = 0$$

که در آن  $f$  و  $g$  توابع ثابت نیستند. وقتی یکی از  $X$  یا  $Y$  به طور قریب‌به‌یقین<sup>۱۲</sup> ثابت باشد، همبستگی ماکسیمال<sup>۱۳</sup> تعریف می‌شود. همچنین  $\text{Cov}$  به معنی کوواریانس و  $\sigma_X$  همان انحراف معیار  $X$  است که به‌ترتیب عبارتند از

$$\begin{aligned}\text{Cov}(X, Y) &= E[(X - E[X])(Y - E[Y])] \\ &= E[X\bar{Y}] - E[X]E[\bar{Y}]\end{aligned}$$

$$\sigma_X = \sqrt{\text{Var}(X)} = \sqrt{\text{Cov}(X, X)} = \sqrt{E[|X|^2] - |E[X]|^2}$$

دقت کنید تعریف‌های بالا تعمیم حالت متغیر تصادفی حقیقی به حالت مختلط هستند.

## ۵ خواص

گزاره ۱. برای هر دو متغیر تصادفی  $X, Y$  داریم

$$-1 \leq \rho_m(X; Y) \leq 1$$

برهان. طبق نامساوی کوشی-شوارتز<sup>۱۳</sup> داریم

$$|\text{Cov}(Z, W)|^2 \leq \text{Var}(Z)\text{Var}(W)$$

$$\Rightarrow |\text{Cov}(Z, W)| \leq \sqrt{\text{Var}(Z)\text{Var}(W)}$$

$$\Rightarrow \frac{|\text{Cov}(Z, W)|}{\sqrt{\text{Var}(Z)\text{Var}(W)}} \leq 1 \Rightarrow |\rho(Z; W)| \leq 1$$

با قرار دادن  $Z = f(X)$ ,  $W = g(Y)$  طرف راست نامساوی ثابت می‌شود. طرف چپ بنا بر تعریف بدیهی است. ■

<sup>12</sup>Almost Surely

<sup>13</sup>Cauchy-Schwarz Inequality

<sup>14</sup>Characteristic Function

<sup>15</sup>Fourier Transform

و به همین ترتیب می‌توان  $E[g'(Y)]$  را نیز بدون تغییر همبستگی برابر ۰ کرد. به این کار سنترینگ<sup>۱۶</sup> می‌گویند. حال با فرض این‌که امیدریاضی  $f(X)$  و  $g(Y)$  صفر است قرار دهید  $f' = f/\|f(X)\|$ . در این صورت

$$\begin{aligned}\rho(f'(X); g(Y)) &= \frac{\text{Cov}(f(X)/\|f(X)\|, g(Y))}{\sigma_{f(X)/\|f(X)\|} \sigma_{g(Y)}} \\ &= \rho(f(X); g(Y))\end{aligned}$$

زیرا برای هر عدد حقیقی  $c$  داریم

$$\text{Var}(cZ) = c^2 \text{Var}(Z), \quad \text{Cov}(cZ, W) = c \text{Cov}(Z, W)$$

همچنین

$$\|f'(X)\| = \left\| \frac{f(X)}{\|f(X)\|} \right\| = \frac{\|f(X)\|}{\|f(X)\|} = 1$$

و به همین ترتیب می‌توان  $\|g'(Y)\|$  را نیز بدون تغییر همبستگی برابر ۱ کرد. به این کار اسکیلینگ<sup>۱۷</sup> می‌گویند. به این ترتیب لم ثابت می‌شود.

■

با توجه به لم فوق، برای پیدا کردن همبستگی ماکسیمال بین دو متغیر تصادفی، کفایت توجهمان را به توابع با امید ۰ و نرم ۱ و واریانس مثبت معطوف کنیم. برای سادگی به جای  $f(X)$  از نماد  $f$  و به جای  $g(Y)$  از  $g$  استفاده می‌کنیم. توجه کنید

$$\begin{aligned}\rho(f(X); g(Y)) &= \frac{E[(f - E[f])(g - E[g])]}{\sqrt{(E[f^2] - E[f]^2)(E[g^2] - E[g]^2)}} \\ &= \frac{E[f(X)g(Y)]}{\sqrt{\|f\|^2 \|g\|^2}} = E[f(X)g(Y)]\end{aligned}$$

پس کفایت  $E[f(X)g(Y)]$  را بیشینه کنیم. همچنین داریم

$$\begin{aligned}E[f(X)g(Y)] &= E[E[f(X)g(Y)|Y]] \\ &= E[g(Y)E[f(X)|Y]] \leq \|g(Y)\| \times \|E[f(X)|Y]\|\end{aligned}$$

که در گام آخر از نامساوی کوشی-شوارتز استفاده شده است. حال دقت کنید  $\|g(Y)\| = 1$  و اگر  $f$  را داده شده فرض کنیم، برای بیشینه کردن همبستگی باید بین تمامی  $g$  ها آن تابعی را بیابیم که نامساوی بالا را به تساوی تبدیل کند. می‌دانیم حالت تساوی

<sup>16</sup>Centering

<sup>17</sup>Scaling

که یعنی همبستگی ماکسیمال برابر ۰ است.

برای طرف دیگر قضیه، اگر  $\rho_m(X; Y) = 0$  باشد، برای  $s$  و  $t$  ثابت قرار دهید  $f(X) = e^{isX}$  و  $g(Y) = e^{itY}$ . توجه کنید که هر تابعی از  $e^{isX}$  تابعی از  $X$  نیز هست، و هر تابعی از  $e^{itY}$  تابعی از  $Y$  نیز هست پس بنا بر تعریف

$$\rho_m(e^{isX}; e^{itY}) \leq \rho_m(X; Y)$$

ولی  $\rho_m(X; Y) = 0$  و  $\rho_m(e^{isX}; e^{itY}) \geq 0$  پس

$$\rho_m(e^{isX}; e^{itY}) = 0 \Rightarrow \text{Cov}(e^{isX}, e^{itY}) = 0$$

$$\Rightarrow E[e^{isX} \overline{e^{itY}}] = E[e^{isX}] E[\overline{e^{itY}}]$$

اما  $\overline{e^{itY}} = e^{-itY}$  پس با تغییر متغیر  $t \leftarrow -t$  و طبق لم ۱،  $X$  و  $Y$  مستقل اند.

لم ۲. برای هر دو تابع  $f$  و  $g$  می‌توان دو تابع  $f'$  و  $g'$  یافت به طوری که

$$E[f'(X)] = E[g'(Y)] = 0$$

$$\|f'(X)\| = \|g'(Y)\| = 1$$

$$\rho(f'(X); g'(Y)) = \rho(f(X); g(Y))$$

که در این جا  $\|Z\| = \|Z\|_2 = \sqrt{E[|Z|^2]}$ .

برهان. ابتدا فرض کنید  $f' = f - E[f(X)]$ . در این صورت داریم

$$\rho(f'(X); g(Y)) = \frac{\text{Cov}(f(X) - E[f(X)], g(Y))}{\sigma_{f(X) - E[f(X)]} \sigma_{g(Y)}}$$

اما می‌دانیم واریانس و کوواریانس با اضافه شدن عددی ثابت به متغیر تصادفی تغییر نمی‌کنند. یعنی

$$\text{Var}(Z+c) = \text{Var}(Z), \quad \text{Cov}(Z+c, W) = \text{Cov}(Z, W)$$

پس  $E[f'(X)] = 0$  و

$$\rho(f'(X); g(Y)) = \frac{\text{Cov}(f(X), g(Y))}{\sigma_{f(X)} \sigma_{g(Y)}} = \rho(f(X); g(Y))$$

## ۶ کاربردها

همان‌طور که در ابتدای متن اشاره کردیم، یکی از کاربردهای همبستگی ماکسیمال در محاسبه کران‌هایی برای بررسی شبیه‌سازی غیرتعاملی است. چند کران پرکاربرد را در این قسمت بیان و اثبات می‌کنیم.

لم ۳. فرض کنید  $X \rightarrow Y \rightarrow Z$  یک زنجیر مارکوف باشد. چون  $Z$  و  $X$  به شرط  $Y$  مستقل‌اند، برای هر دو تابع  $f$  و  $g$  داریم

$$E[f(X)|Y]E[g(Z)|Y] = E[f(X)g(Z)|Y] \Rightarrow$$

$$\begin{aligned} E[f(X)g(Z)] &= E[E[f(X)g(Z)|Y]] \\ &= E[E[f(X)|Y]E[g(Z)|Y]] \end{aligned}$$

لم ۴. اگر  $X \rightarrow Y \rightarrow Z$  زنجیر مارکوف باشد،  $E[f(X)g(Z)] \leq \rho_m(X; Y)\rho_m(Z; Y)$

برهان. طبق لم بالا داریم

$$E[f(X)g(Z)] = E[E[f(X)|Y]E[g(Z)|Y]]$$

$$\stackrel{(a)}{\leq} \|E[f(X)|Y]\| \times \|E[g(Z)|Y]\| \stackrel{(1)}{\leq} \rho_m(X; Y)\rho_m(Z; Y)$$

که در آن (a) از نامساوی کوشی-شوارتز نتیجه شده است. ■

یک نتیجه‌ی مهم این لم این است که

$$\begin{aligned} \rho_m(X; Z) &= \max_{f, g} E[f(X)g(Z)] \\ &\leq \rho_m(X; Y)\rho_m(Z; Y) \leq \rho_m(X; Y) \end{aligned}$$

که نامساوی آخر از گزاره ۱ نتیجه شده است. این نتیجه همان نامساوی پردازش اطلاعات برای همبستگی ماکسیمال است. از آنجایی که توزیع توأم  $X$  و  $Y$  را می‌توان به شکل یک کانال مخابراتی و یک توزیع ورودی برای آن نیز بیان کرد، گاهی به جای محاسبه‌ی همبستگی  $X$  و  $Y$ ، همبستگی توزیع کانال و توزیع ورودی را بررسی می‌کنند. مثال‌هایی از این نوع بررسی در [۵] آمده

نامساوی کوشی-شوارتز وقتی اتفاق می‌افتد که دو متغیر تصادفی در راستای هم، یعنی ضریبی از هم باشند، یعنی

$$g(Y) = cE[f(X)|Y]$$

اما باید  $\|g\| = 1$  و  $E[g] = 0$  باشد. پس

$$g(Y) = \frac{E[f(X)|Y]}{\|E[f(X)|Y]\|}$$

و برای این  $f$  و  $g$  بهینه طبق نامساوی بالا داریم

$$\begin{aligned} \rho_m(X; Y) &= \max_{f: E[f]=0, \|f\|=1} \|E[f(X)|Y]\| \\ &= \max_{f: E[f]=0, \|f\|=1} \sqrt{E[E[f(X)|Y]^2]} \quad (I) \end{aligned}$$

به همین ترتیب می‌توان برای  $f(X)$  نیز رابطه مشابهی پیدا کرد

$$f(X) = \frac{E[g^*(Y)|X]}{\|E[g^*(Y)|X]\|}$$

که در این جا  $g^*$  جواب بهینه‌سازی زیر است

$$\rho_m(X; Y) = \max_{g: E[g]=0, \|g\|=1} \|E[g(Y)|X]\|$$

پس  $f$  و  $g$  بهینه که در همبستگی ماکسیمال صدق می‌کنند، باید در این روابط نیز صدق کنند، که به آن‌ها معادلات نقطه ثابت<sup>۱۸</sup> می‌گویند. با استفاده از این روابط و الگوریتم امیدریاضی شرطی متناوب<sup>۱۹</sup> می‌توان از یک حدس اولیه شروع کرد و به طور تکراری<sup>۲۰</sup> به  $f$  و  $g$  بهینه میل کرد. منبع [۱] به این الگوریتم و کاربردهای آن به تفصیل پرداخته است.

برای حالت‌های خاصی از  $X$  و  $Y$ ، روش‌های ساده‌ای برای محاسبه‌ی  $\rho_m$  ارائه شده است. برای مثال در [۴] ثابت شده اگر حداقل یکی از  $X$  و  $Y$  الفبای دوحرفی داشته باشد، داریم

$$\rho_m^*(X; Y) = \left( \sum_{x, y} \frac{p(x, y)^2}{p(x)p(y)} \right) - 1$$

<sup>18</sup>Fixed-Point Equations

<sup>19</sup>Alternating Conditional Expectation algorithm

<sup>20</sup>Iterative

توجه کنید طبق نتیجه‌ی لم ۴

$$\frac{\rho_m(X; Z)}{\rho_m(Z; Y)} \leq \rho_m(X; Y)$$

اثباتی برای رخ دادن تساوی در نامساوی بالا در [۴] ارائه شده است. یکی از توزیع‌های پرکاربرد برای  $X$  و  $Y$ ، توزیع نرمال دومتغیره است. در [۲] همبستگی ماکسیمال برای این توزیع

$$\rho_m(X; Y) = |\rho(X; Y)|$$

محاسبه شده است. همچنین قضیه‌ی زیر را داریم

$$\rho_m^2(X; Y) \leq 1 - 2^{-2I(X; Y)} \leq (2 \ln 2)I(X; Y)$$

اثباتی از این قضیه در [۴] آمده است. نکته‌ی جالب راجع به این نامساوی این است که همبستگی ماکسیمال را به اطلاعات متقابل ربط می‌دهد.

## ۷ نتیجه‌گیری

همان‌طور که دیدیم، همبستگی ماکسیمال در تئوری اطلاعات و حفظ حریم داده کاربردهای بسیاری دارد و کمک می‌کند بفهمیم چه موقع یک شبیه‌سازی امکان‌پذیر نیست.

## ۸ تشکر

در پایان از استادان گران‌قدر دکتر سلمان ابوالفتح بیگی و دکتر پویا شریعت‌پناهی که بدون رهنمودهای ایشان نگارش این نوشته ناممکن بود کمال سپاس‌گزاری را داریم.

است. یک مسأله‌ی پرکاربرد در این خصوص، تکرار یک کانال است. یعنی  $X \rightarrow Y \rightarrow Z$  که در آن  $(X, Y)$  با  $(Z, Y)$  هم‌توزیع باشد. یک نامساوی مهم برای این حالت را که از لم بالا نتیجه می‌شود این‌جا آورده‌ایم.

نتیجه ۱. اگر  $X \rightarrow Y \rightarrow Z$  زنجیر مارکوف باشد و  $(X, Y)$  با  $(Z, Y)$  هم‌توزیع باشد، داریم

$$\rho_m^2(X; Y) = \max_{f: E[f]=0, \|f\|=1} E[f(X)f(Z)]$$

برهان. چون  $(X, Y)$  با  $(Z, Y)$  هم‌توزیع است داریم

$$E[f(X)|Y] = E[f(Z)|Y]$$

$$\Rightarrow E[f(X)|Y]^2 = E[f(X)|Y]E[f(Z)|Y]$$

$$\Rightarrow E[E[f(X)|Y]^2] = E[E[f(X)|Y]E[f(Z)|Y]]$$

$$= E[E[f(X)f(Z)|Y]] = E[f(X)f(Z)]$$

اما طبق (I) داریم

$$\begin{aligned} \rho_m^2(X; Y) &= \max_{f: E[f]=0, \|f\|=1} E[E[f(X)|Y]^2] \\ &= \max_{f: E[f]=0, \|f\|=1} E[f(X)f(Z)] \end{aligned}$$

و حکم ثابت می‌شود.

دقت کنید چون

$$\begin{aligned} &\max_{f: E[f]=0, \|f\|=1} E[f(X)f(Z)] \\ &\leq \max_{f, g: E[f]=E[g]=0, \|f\|=\|g\|=1} E[f(X)g(Z)] \\ &= \rho_m(X; Z) \end{aligned}$$

می‌توان نتیجه گرفت  $\rho_m^2(X; Y) \leq \rho_m(X; Z)$ . همچنین طبق نتیجه‌ی لم قبل داریم

$$\rho_m(X; Z) \leq \rho_m(X; Y)\rho_m(Z; Y) = \rho_m^2(X; Y)$$

که نتیجه می‌دهد  $\rho_m(X; Z) = \rho_m^2(X; Y)$ .

نتیجه ۲.

$$\sup_{\substack{X \rightarrow Y \rightarrow Z \\ \rho_m(Y; Z) \neq 0}} \frac{\rho_m(X; Z)}{\rho_m(Z; Y)} = \rho_m(X; Y)$$

## مراجع

- [3] A. Renyi. On measures of dependence. *Acta Mathematica Hungarica*.
- [4] T. Linder S. Asoodeh, F. Alajaji. On maximal correlation, mutual information and data privacy. 2015 IEEE 14th Canadian Workshop on Information Theory (CWIT).
- [5] Y. Park Z. Yin. Hypercontractivity, maximal correlation and non-interactive simulation.
- [1] J. Friedman L. Beriman. Estimating optimal transformations for multiple regression and correlation. *Journal of the American Statistical Association*, 1985.
- [2] H. O. Lancaster. Some properties of the bivariate normal distribution considered in the form of the contingency table. *Biometrika*, Volume 44, Issue 1-2, page 289–292, 1957.